

Alessandro Brandolisio

Michael Leitl

Karel J. Golta

THE AI

Das
unverzichtbare
Arbeitsbuch
für Macher,
Entscheider und
Innovatoren

MIT KÜNSTLICHER INTELLIGENZ DIE ZUKUNFT SICHERN

TOOL BOOK

MURMANN

**MIT KÜNSTLICHER INTELLIGENZ
DIE ZUKUNFT SICHERN**

Alessandro Brandolisio

Michael Leitl

Karel Golta

THE AI TOOLBOOK

MURMANN

BASIS

Warum Sie jetzt mit AI starten sollten

Ab in die Höhe!

Etwas wagen und davon profitieren **008**

Im Höhenflug

Warum AI für uns unverzichtbar wird **010**

Langstrecke

AI benötigt Daten – viele Daten **011**

Landung in Sicht!

AI-Projekte zielgerichtet planen **013**

Auf geht's!

Der Umgang mit dem Buch **015**

Brainbytes

Sieben Grundsätze zu AI **016**

BRIEFING

Was Sie vorab wissen müssen

Definition

Was ist AI? **024**

Einordnung

Wie sich Mensch und Maschine unterscheiden **026**

Systematisch trainieren

Wie Maschinen lernen **027**

Rohstoff Daten

Was Maschinen zum Lernen brauchen **032**

Faktor Mensch

Welche Experten für AI nötig sind **034**

Zeit ist Geld

Wie lange AI-Projekte dauern **035**

EINSTEIGEN

Wie der AI Planner funktioniert

Die Tools

Was wir zum Springen brauchen **039**

Den Planner nutzen

Struktur und Ergebnis **044**

Das Szenario

Gefährden Elterntaxis das Leben von Kindern? **046**

1. Ziel definieren

Houston, wir haben ein Problem **048**

2. Daten recherchieren

Quellen der Erkenntnis **062**

3. Lernkonzept erstellen

Die Algorithmen **084**

4. Entscheidung treffen

AI oder keine AI? **100**

Fazit **117**

SPRINGEN

Wie Sie mit
AI arbeiten können

Recode Innovation

Springen bewirkt Veränderung **121**

Wo AI Innovatoren helfen kann

Vielfältige Einsatzbereiche **126**

1. Trends entdecken 128

2. Erkenntnis gewinnen 144

3. Persona erstellen 162

4. Ideen sichten 180

5. Designs entwickeln 198

6. Tests durchführen 218

Fazit 239

SICHER LANDEN

Wie Sie AI im
Unternehmen
skalieren

1. Intro 242

2. Ziele für AI definieren 250

3. Daten richtig nutzen 255

4. AI-Projekte sind anders 260

5. Partner finden 272

6. Governance 278

7. Ethik 284

**8. Menschen und
Organisation 291**

9. AI als Strategie 300

Fazit 307

Die Autoren **308**

Die Entstehung **309**

Das Netzwerk **310**

Danke **311**

Glossar

Basis

Warum Sie jetzt
mit AI starten
sollten





Ab in die Höhe!

Etwas wagen und davon profitieren

Wann müssen die Arme
weg vom Gurt?

Ich weiß Bescheid,
er weiß auch Bescheid

Er gibt mir den Gurt in die Hand. Ich bekomme den Anzug.
«Hier nimm!»

Es geht alles ganz schnell. Das Flugzeug steht auf der Startbahn. Der Motor wird angeworfen. Ich zwänge mich in den Anzug, er ist eng, ein Overall. Der Trainer ruft: «Schnell, schnell! Wir müssen los!» Ich atme schwer.

Die Einführung war kurz. Eine knapp gehaltene Ansprache: «Wenn ich auf deine Schultern klopfe, nimmst du die Arme vom Gurt!» Was, ja?

Kann ich mir das merken? Bis nachher, also bis ich nachher in der Luft ...

«Und wenn die Luke offen ist, klappt du die Beine unter das Flugzeug!»

Was? Beine UNTER das Flugzeug? Wie? Wann? Er drängt mich in Richtung Flugzeug. «Komm schon!» Er gibt mir noch eine Brille. Schon sitzen wir in der Maschine. Wir heben ab. Ich atme zum ersten Mal ein bisschen durch. Verdammt, ist das hoch! Was mache ich hier? Mein Adrenalin schießt in die Höhe. Wer hatte diese wahnsinnige Idee? Was soll ich hier? Das Surren des Flugzeugmotors ist zu hören. Der Höhenmesser zeigt fast 4000 Meter. Der Trainer blickt mich lächelnd ernst an.

Ich muss mich einhaken. Es ist so weit. Der Gurt wird strammgezogen. Der Trainer deutet auf die Brille, ich ziehe sie an – eine Art Skibrille. Noch muss ich warten, sitze an die Wand gelehnt. Meine Hände sind feucht vor Schweiß. Kopfkino. Was alles passieren kann? Alarm! Das Herz rast. Ich sehe mich, wie ich auf dem Boden zerschelle, wie sich der Schirm nicht öffnet, wie alles aus ist. Dann klopft mir der Trainer auf die Schulter. Er klemmt sich hinter mich, hakt sich bei mir ein. Mein Gott!

Ich schiebe mich zur Luke, langsam, ganz langsam bewege ich mich dahin. Mein Herz pocht wie wild. Ich weiß nicht, wo ich hinschauen soll. Nach unten ist der Wahnsinn. Und dann, ein leichter Stoß, wir kippen aus dem Flugzeug. Ganz kurz ist alles wie in Watte und dann, ich fliege. ICH FLIEGE!!! Mit mehr als 200 Stundenkilometern. Der Luftwiderstand zerrt an den Klamotten, an meinem Gesicht, an mir. Wahnsinn! Dieses Gefühl. Im freien Fall Richtung Erde fliegen. Diese unglaubliche Aussicht. Wie weit man blicken kann. Der Horizont, dort hinten, die Städte, alles ist direkt unter mir.

Das Gesicht verzerrt. Die Backen flattern. Es ist unglaublich. Wie wenn man in eine endlose Freiheit springt. Ich weiß nicht, wie lange dieses Gefühl anhält, eine Minute, eine Sekunde, eine Stunde? Ich falle, zwischen Himmel und Erde, vollkommen losgelöst von allem. Nichts zählt mehr, nur dieser Augenblick, nichts und niemand bremst einen, alles ist leicht, fantastisch.

Dann öffnet sich der Schirm

Wir bremsen ab. Wir schweben. Herrlich! Dieses Schweben, dieses schwerelos über der Erde schweben. Wir nähern uns dem Boden. Langsam, gemächlich, sicher. Wir kommen unten an, mir zittern die Beine, als wir auf der Erde aufsetzen.

Ich habe es wirklich getan!

Mein erster Fallschirmsprung. Ein Tandemsprung, hinter mir der Sprungtrainer. Jetzt, wo ich das überstanden habe, werde ich noch viel mehr überstehen können. Ich bin durch die Wolken gerast, ich bin aus unglaublichen 4000 Metern gesprungen. Es war ein Trainer dabei, ja, ich war sicher. Aber dass ich meine nackte Angst, meine Panik bezwungen habe, was ist schon alles andere im Vergleich?

Einfach springen. Etwas wagen, etwas erleben. Und maximal davon profitieren. Nachhaltig, vielleicht für immer.

Liebe Leserinnen und Leser, Sie müssen nicht springen. Keine Angst. Doch wir wollen Sie in diesem Buch animieren, Ängste zu überwinden, Bedenken zu zerstreuen oder zumindest die Aussicht auf eine Belohnung in den Vordergrund stellen. Wir wollen Sie auffordern, etwas zu tun, was viele vor sich herschieben. Wir wollen Sie in eine Situation bringen, vor der Sie bisher viel Respekt hatten.

Wir zeigen in diesem Buch, wie man Künstliche Intelligenz nutzt, um innovativ zu sein.

Wir wollen Sie mit dem Unbekannten bekannt machen. Wir werden Ihnen zeigen, wie man Künstliche Intelligenz nutzt. Für Innovation. Für die Zukunft Ihres Unternehmens. Wir nehmen Sie mit auf diese Reise und begleiten Sie bei Ihrem ersten Sprung.

Im Höhenflug

Warum AI für uns unverzichtbar wird

Dieses Buch ist ein Beitrag zur Innovation des Innovationsprozesses.

Dieses Buch fördert die Kombination von menschlicher Kreativität und maschineller Effizienz. Wir Autoren glauben an das intelligente Zusammenspiel zwischen Mensch und Maschine, und zwar aus der Notwendigkeit der Gegenwart heraus.

Das Rad der Moderne dreht sich immer schneller. Innovationszyklen werden schnelllebig, Technologien komplexer, und Menschen, ganz gleich wie kompetent, systematisch und kreativ sie vorgehen, können mit der Innovationsgeschwindigkeit und der Innovationsqualität oft nur noch schwer Schritt halten. Tatsächlich liegen viele Zusammenhänge, die heute zu Innovationen führen, in immer größeren Datenmengen verborgen.

Die großen, marktbeherrschenden Techfirmen haben auf dem Gebiet der Künstlichen Intelligenz riesige Fortschritte gemacht und beachtliche Durchbrüche erreicht. Es ist höchste Zeit, allen das Wissen und den Leitfaden künstlich-intelligenter Innovation zur Verfügung zu stellen. Allen, auch denen, die nicht über die Budgets von Einhörnern verfügen.

Innovationsmanager, Projektleiter, Entscheider: Sie alle können hier lernen, den Mehrwert von AI-Systemen abzuschätzen. Am Ende des Buches werden die Leserinnen und Leser in der Lage sein, Herausforderung und Entscheidung zusammenzuführen: für oder gegen AI.

Wir versprechen, Sie werden in der Lage sein, den ersten Schritt zu machen und sich mit dem unbekannten Thema Künstliche Intelligenz vertraut zu machen. Wie unser Flugschüler werden auch Sie mit uns den ersten Sprung gemacht haben – und sicher gelandet sein.

Wir wollen mit diesem Buch helfen, Innovatoren den Umgang mit AI zu erleichtern, Handwerkszeug zu liefern und die Hemmschwelle zu senken, einfach anzufangen. Das setzt allerdings eines voraus.

Den Mut, zu springen – und im Unbekannten zu landen.

Langstrecke

AI benötigt Daten – viele Daten

**Trends spiegeln
Veränderungen wider –
und Veränderungen
erzeugen Bedürfnisse.**

Die Zukunft
von Innovation

Eine Woche vor dem Coronavirus-Ausbruch schlug das AI-Modell der kanadischen Firma BlueDot Alarm. Es erkannte eine Unregelmäßigkeit, den Ausbruch einer neuen Krankheit im chinesischen Wuhan. Die AI-Anwendung signalisierte am 31. Dezember 2019, dass eine Krankheitswelle bevorstand und warnte vor Reisen in die Region – übrigens zehn Tage, bevor die Weltgesundheitsorganisation (WHO) ihre Warnung aussprach. Und das nur, weil BlueDot beziehungsweise deren AI-Anwendung ihre Arbeit gemacht hatte.

Die AI-Anwendung hatte in den Tagen zuvor zahllose regionale Nachrichten in insgesamt 65 Sprachen, offizielle staatliche Gesundheitswarnungen, Meldungen über Tier- und Pflanzenkrankheiten sowie entsprechende Foren und Blogs durchsucht. Zudem hatte das Programm Zugriff auf internationale Fluggast-Datenbanken, unter anderem, weil Fluglinien zum Kundenstamm von BlueDot zählen.

In jedem Fall ermöglichte das systematische Durchsuchen der zugänglichen Datenquellen eine weitgehend korrekte Vorhersage der Verbreitung des Virus in den ersten Tagen nach dem Auftreten sowie der Verbreitung von Wuhan aus nach Bangkok, Seoul, Taipei und Tokio.

Lernende Algorithmen, wie der des Start-ups BlueDot, liefern in der Welt von morgen das Futter für Innovationen. Trends spiegeln Veränderungen wider – und Veränderungen erzeugen Bedürfnisse. Um jedoch eine korrekte Vorhersage treffen zu können, war ein Aspekt besonders entscheidend: die menschliche Kompetenz. Nachdem das Programm nämlich alle Daten ausgewertet hatte, setzten sich Epidemiologen daran, die Schlussfolgerungen der AI auf ihre Wissenschaftlichkeit zu prüfen. Und als sowohl die Künstliche als auch die menschliche Intelligenz ihre Expertise eingebracht hatten, wurden die Warnungen verschickt.

Kamran Khan, Arzt und Gründer von BlueDot, sagte, man habe dem Computerprogramm mithilfe maschinellen Lernens beigebracht, menschliche Sprache zu differenzieren. **«Unsere AI kann Nachrichten über mögliche Ausbrüche, kleine Gerüchte in Foren oder Blogs sowie Hinweise auf ungewöhnliche Ereignisse aufnehmen»**, betonte Khan.

**Innovativ ist, auf
maschinelle Vorhersagen
zurückzugreifen.**

Fazit

Daraus ergab sich das Bild einer bevorstehenden Epidemie. Hätte es ein tieferes Vertrauen gegeben, hätten Menschen und Regierungen die Signale der AI-Anwendung ernster genommen – man hätte die globale Katastrophe unter Umständen verhindern, zumindest aber eindämmen können.

Wenn eine AI ein Virus vorhersehen kann, wird sie auch in der Lage sein, andere Bedürfnisse und Veränderungen zu ermitteln. AI-Systeme werden es erleichtern, Produktinnovationen oder einen neuen Service zu gestalten. Denn die Maschine arbeitet so, wie kein Mensch arbeiten kann. Sie scannt Datenberge und entdeckt Muster. Sie liest Blogs, Nachrichten, Postings in unvorstellbarer Menge und wahnsinnig schnell. Sie beherrscht das Spiel mit Versuch und Irrtum wie kein Zweiter. Und das Beste dabei: Die Maschine wird nie müde. Sie scannt immer weiter.

Die Maschine mag uns Aufgaben abnehmen. Aber es liegt an unserer Urteilsfähigkeit, welche Aufgabe wir sie machen lassen. Auf der Reise durch die Welt der Künstlichen Intelligenz, die wir mit Ihnen in diesem Buch antreten, werden Sie eine Menge neuer Möglichkeiten kennenlernen. Sie werden erfahren, was mithilfe maschinellen Lernens alles möglich ist, und lernen, eine neue Perspektive einzunehmen: die der Maschine. Auf diese Weise werden Sie auch einschätzen können, wann es auf die Fähigkeiten des Menschen ankommt und wann besser die Maschine zum Zuge kommt. Denn häufig ist es sinnvoller, sich im Team zusammenzusetzen, zu brainstormen, gemeinsam rasch eine Idee zu entwickeln.

**AI ist nicht per se
die Lösung für alles**

Doch die Maschinen helfen uns, wenn die Fragen komplexer werden, wenn die Trends nicht eindeutig zu erkennen sind, wenn unkonventionelle Lösungen gebraucht werden, wenn der Geistesblitz auf sich warten lässt – weil die Aufgabe zu unübersichtlich ist. Dann können die Maschinen übernehmen.

Wie bringen wir Maschinen dazu, im Innovationsprozess zu helfen? Antworten liefern die folgenden Kapitel.

Landung in Sicht!

AI-Projekte
zielgerichtet planen

**Das Buch zeigt, wie
Innovationsprozesse
automatisiert werden
können.**

Briefing

Im Buch arbeiten wir mit der Metapher des Fallschirmsprungs. Entsprechend sind die folgenden Kapitel benannt. Wir nehmen Sie mit auf den Sprung in die Welt der Künstlichen Intelligenz und begleiten Sie als Ihr persönlicher Trainer:

Wir beginnen mit dem Briefing. Es vermittelt in aller Kürze, was Innovatoren über AI wissen müssen. Wir machen vertraut mit dem Fachvokabular (zum Beispiel mit dem Unterschied zwischen Supervised und Unsupervised Learning), erklären die unterschiedlichen Fähigkeiten von Algorithmen und zeigen, was Deep Learning bedeutet.

Einsteigen

Im Kapitel «Einsteigen» stellen wir das Arbeitswerkzeug vor: das AI Planner Framework und die dazugehörigen Hilfsmittel. Sie lernen umfangreiche Templates, Checklisten und Tools kennen und erfahren anhand von Beispielen, wie sie angewandt werden. Wir haben diese Hilfsmittel Schritt für Schritt aufbereitet. Zahlreiche Leitfragen und Selbstchecks helfen, die Methodik selbstständig für eigene Herausforderungen anzuwenden. Am konkreten Beispiel erfahren Sie, wie die Methodik in der Praxis funktioniert. Wir wollen Ihnen einen klaren Kompass geben – und vor allem das hierfür notwendige Handwerkszeug.

Springen

Das Springen vertieft dieses Wissen. Wir definieren Machine-Learning-Tools für sechs wichtige Jobs-to-be-done im Innovationsprozess und erklären sie anhand von Beispielen nachvollziehbar und transparent. Sie erfahren, wie diese Tools helfen, neue Geschäftschancen zu entdecken oder Insights zu analysieren, damit die AI aus Hunderten von Nutzerbeobachtungen signifikante Muster ableiten kann. Wir erkunden die Bedürfnisse von Innovatoren und die Möglichkeiten, wie Künstliche Intelligenz dabei unterstützen kann. In diesem Kapitel lernen Sie, welches Equipment es gibt. Außerdem erfahren Sie, an welcher Stelle Tools eingesetzt werden, um maschinelles Lernen zu nutzen, um komplexe Aufgaben schneller, in höherer Qualität und mit überraschendem Ergebnis zu erledigen.

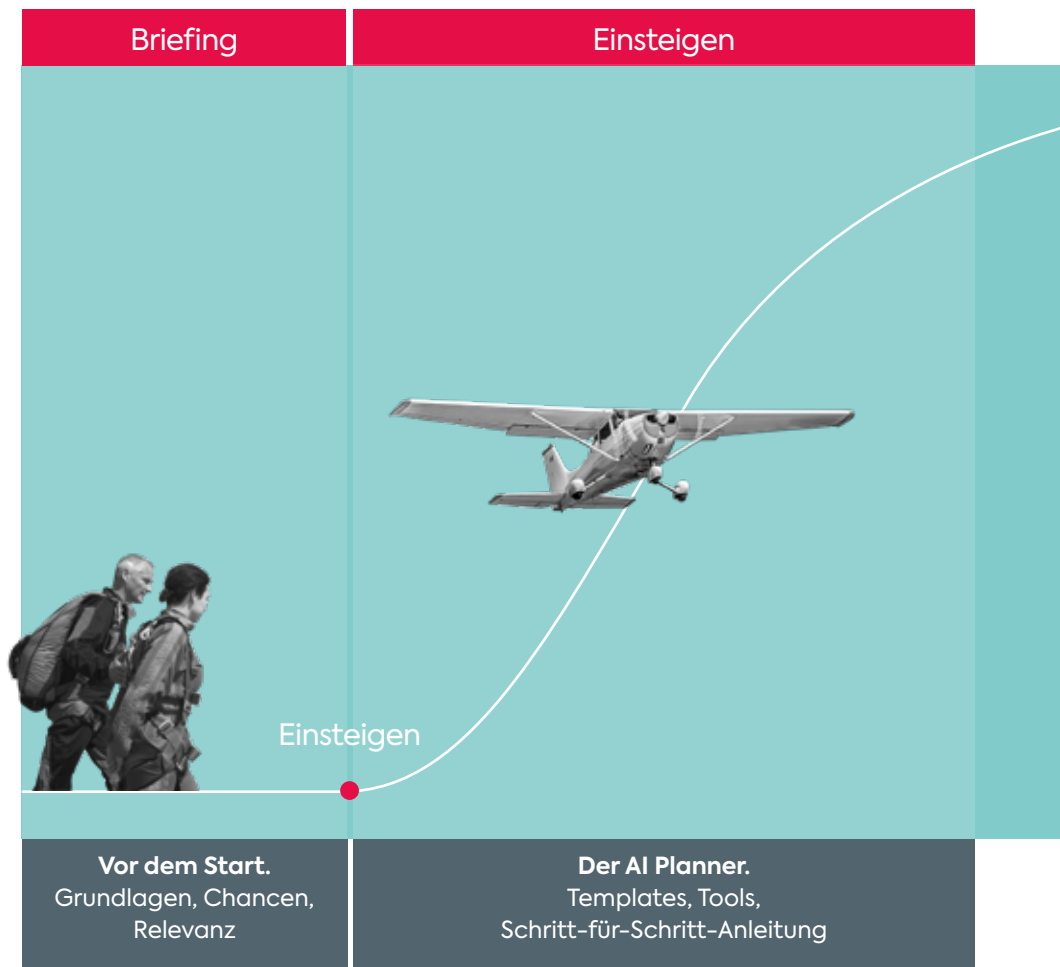
Das Buch ist also eine schrittweise Hinführung an die Automatisierung von Innovationsprozessen – das ist die Entwicklung, auf die wir zusteuern.

Sicher landen Im Schlusskapitel «Sicher landen» erfahren Sie, wie die AI-Einführung in den Unternehmensalltag gelingt, welche Hürden zu überwinden sind und welche Expertise und Fachkräfte dabei unterstützen. Man springt ins Ungewisse, landet aber sicher.

Unter einer sicheren Landung verstehen wir die sichere Anwendung unserer Tools und die Implementierung von AI im Unternehmen. Ohne Angst vor dem Unbekannten. Dann haben wir es geschafft. Dann fühlen wir die Euphorie und können das nächste Mal gar nicht erwarten. Und genau dazu bietet das Buch eine einfache Navigation.

Der Fallschirmsprung

Wir begeben uns gemeinsam auf die Reise und lernen alles, um innovative AI-Konzepte zu entwickeln.




Auf geht's!

Der Umgang mit dem Buch

Noch ein paar Sätze zur Handhabung des Buches. Die wichtigsten Inhalte gibt es am Schluss des Buches auch noch einmal als Glossar zum Ausklappen – so haben Sie die Briefing-inhalte während des Sprungs immer sichtbar zur Hand.

Und keine Angst. Das Buch ist so aufgebaut, dass alle Inhalte Schritt für Schritt vertieft werden. Nach dem Einsteigen werden alle Elemente des AI Planners anhand von praktischen Beispielen ausgefüllt und ausführlich erklärt. So können Sie nach Lektüre des Buches ihre ersten eigenen Experimente mit AI wagen.



Brainbyte 1: **Es gibt nicht die eine AI.**

Wir neigen dazu, Künstliche Intelligenz zu vermenschlichen. Sie ist jedoch kein Ding, kein Computerprogramm und schon gar kein Wesen. Der Begriff ist nur der Name für eine wissenschaftliche Disziplin. Und in diesem Fach gibt es viele verschiedene Gebiete, die unterschiedliche Methoden anwenden. Wenn man über AI spricht, sollte man vermeiden, AI als zählbares Substantiv zu verwenden: eine AI, zwei AIs und so weiter. Das bedeutet, dass die AI eine Sammlung von Konzepten, Problemen und Methoden zu ihrer Lösung ist. Da AI eine Disziplin ist, sollte man nicht «eine AI» sagen, genau wie man nicht «eine Chemie» sagt. Trotzdem ist die Verwendung von AI als zählbares Substantiv vor allem in den Medien weit verbreitet. Das ist häufig der besseren Lesbarkeit geschuldet – und wird auch in diesem Buch teilweise so eingesetzt.

Brainbytes

Sieben Grundsätze zu AI

Brainbyte 2: **Das Kino sagt nicht die Wahrheit über AI.**

Von einer wie in Filmen oft suggerierten «Persönlichkeit» ist die im Alltag angewendete AI Lichtjahre entfernt. Keines der Systeme ist wirklich intelligent.

Aus Filmen kennen wir Künstliche Intelligenz vor allem als niedliche und gewitzte Kameraden oder auch als furchteinflößende Terminatoren. In die Köpfe vieler Menschen haben sich Geschichten von alles beherrschenden Maschinen eingebrannt, es sind die Science-Fiction-Märchen von maschinen-gesteuerter Kontrolle, es sind fiktive Wesen, die das Bild der Künstlichen Intelligenz prägen. Der Terminator.

Nach einer Allensbach-Umfrage aus dem Jahr 2019 sind es tatsächlich in erster Linie Filmerfindungen, die die Vorstellung vieler Deutscher von AI geprägt haben. Ein Fünftel der Befragten (20 Prozent) gab an, dass der Droide R2-D2 aus Star Wars ihrer Vorstellung von Künstlicher Intelligenz am nächsten kommt. Auf den weiteren Plätzen folgen der besagte Terminator (17 Prozent), Commander Data aus Star Trek (17 Prozent), dann das denkende, sprechende, handelnde Auto K.I.T.T. aus Knight Rider (16 Prozent).

Was wir über AI wissen, wissen wir häufig aus dem Kino. Wenn wir den Begriff AI hören, denken wir an sprechende Blechbüchsen. Dieses Denken hat leider Folgen. Denn was im Kino stattfindet, ist weit entfernt von der Realität, eine technische Spielerei. Deshalb lassen viele, vor allem auch viele Unternehmen, das Thema noch ungern an sich heran.

Hinzu kommt die Lust am Schrecken. Der Nervenkitzel, das Unbekannte zu beherrschen. Berichte von Unfällen mit selbstfahrenden Autos, die Passanten töten, oder Berichte von «Drohnen» und automatischen Waffensystemen bestätigen viele Menschen in ihrer Ablehnung von AI und in ihrer Furcht vor aggressiv handelnden Maschinen. AI-Tools sind in der Vorstellung immer noch mehr Terminatoren, die die Weltherrschaft an sich reißen wollen, als smarte Systeme, die helfen, innovativ zu sein. In Wirklichkeit ist es genau anders herum. Terminiert wird, wer sich nicht auf die Zukunft vorbereiten will.

Brainbyte 3: **Algorithmen helfen.**

Positive AI-Geschichten gehen in den Medien oft unter. Oder es wird ihnen nicht ausreichend Beachtung geschenkt.

Oder sie werden erst gar nicht geschrieben, man liest eben lieber die negative Bestätigung. So verpassen wir durchaus positive Nachrichten, dass Algorithmen beispielsweise Bauern in Entwicklungsländern helfen, ihre Äcker besser zu bewirtschaften, oder Krankheiten zu diagnostizieren, wo der nächste Arzt weit weg ist. Oder in der Medizin bleibend, dass mithilfe Künstlicher Intelligenz Brustkrebs früher und mit höherer Genauigkeit diagnostiziert werden kann. Dass wichtige Ressourcen, wie Wasser und Dünger, viel effizienter eingesetzt werden können und so viel mehr Menschen zur Verfügung stehen. **Dass überhaupt mit der Zusammenführung, Analyse und Bewertung von Daten in einer Vielzahl von Bereichen besser, genauer, sicherer gearbeitet werden kann – allen Schreckensszenarien zum Trotz.**

Eine Maschine kann menschliches Verhalten beobachten und Zusammenhänge aufzeigen, die wir so nicht gesehen hätten.

Generell gesehen bezeichnet Künstliche Intelligenz nur ein Fachgebiet der Computerwissenschaft. Das Fachgebiet befasst sich mit der Frage, wie Maschinen lernen können. Kaum beschäftigt sich die Disziplin mit der Frage, wie autonom denkende und handelnde Persönlichkeiten geschaffen werden. Allerdings kann die Maschine sehr genau menschliches Verhalten beobachten und Zusammenhänge aufzeigen, die wir so nicht gesehen hätten.

Brainbyte 4: **AI ist nicht so intelligent, wie man glaubt.**

Von einer wie in Filmen oft suggerierten «Persönlichkeit» ist die im Alltag angewendete AI Lichtjahre entfernt. Keines der Systeme ist wirklich intelligent.

Obwohl Computer Menschen vielleicht bei komplexen Rechenaufgaben um Längen schlagen oder bei automatisierbaren Aufgaben eine ungeschlagene Geschwindigkeit erreichen, ist ihre Kompetenz in vielen anderen Bereichen heute noch sehr begrenzt und eher mit denen «einer Ratte» vergleichbar. Die Ratteneinschätzung stammt übrigens von Yann LeCun, dem Leiter der AI-Abteilung von Facebook. Er wählte das Nagetier als Vergleichsmodell. Denn die scheinbare Intelligenz der Maschinen rührt daher, dass sie lernen können. Sie lernen aus ihrem Tun. Mehr nicht. Auch Ameisen können im Schwarm intelligent wirken. In Wirklichkeit folgen sie nur einer Spur aus Duftstoffen. Sobald Tiere auf einer Spur

zurückkehren, weil sie etwas zu Fressen gefunden haben, verstärkt sich der Duft, und immer mehr Ameisen folgen dem Pfad zur Nahrung – eine Ameisenstraße entsteht.

Ein Algorithmus ist daher eher intelligent wie eine Ameise: Er wertet Feedback aus, probiert neue Wege und wählt nur diejenigen aus, die das positive Signal verstärken. Mit anderen Worten: Der Algorithmus lernt. Die Maschine lernt.

Brainbyte 5: **Die Maschine kennt uns besser, als wir glauben.**

Wie die Maschine lernt, was sie bereits gelernt hat, das sehen wir an den vielen Aufgaben, die sie übernommen hat. Längst sind viele unserer Routineaufgaben automatisiert. Wir haben uns daran gewöhnt, von digitalen Helfern umgeben zu sein. Beim Onlinekauf lassen wir uns vorschlagen, was die Maschine findet, was gut zu uns passen würde.

AI ist im Alltag bereits weiter verbreitet, als viele ahnen. Von der Fotoverwaltung im Handy bis zu Urlaubsplanung erleichtern Algorithmen sehr viele Aufgaben.

Im Finanzbereich entscheiden Systeme wie Robo-Advisors, wann welche Wertpapiere gekauft oder verkauft werden sollten. Digitale Werbeanzeigen werden längst nicht mehr zufällig gestreut, und wer eine Reise bucht, weiß: Preise von Sitzplätzen in Flugzeugen und Hotelübernachtungen werden bei vielen Anbietern automatisch an die Nachfrage angepasst. Sie können im Minutentakt variieren. Die Firma Oracle wiederum hat die erste selbststeuernde Datenbank entwickelt. Sie wartet und organisiert sich selbst, achtet auf Sicherheitslücken. Bei der Produktion und in der Logistik von Firmen sind maschinelle Systeme längst Alltag, um Engpässe und Nachfrage zu steuern. Auch im Marketing und Vertrieb werden potenzielle Kunden zuverlässig und genau identifiziert und zu einer «Kundenreise» inspiriert. Und nicht wenige von uns wundern sich, wenn sie am Tisch über ein Produkt sprechen, beispielsweise einen neuen Fernseher oder eine neue Sportausrüstung, und kurz darauf ploppen in den Netzwerken die Werbungen zu genau jenen Themen auf.

Brainbyte 6: **Für unsere Angst vor AI gibt es keinen Grund.**

Unternehmen müssen einerseits neue Geschäftsfelder erkunden, sich gegen die Veränderung von Branchen wappnen. Viele der Unternehmen spüren einen permanenten Druck zu

innovieren. Auf der anderen Seite wird es immer schwerer, bahnbrechende Erfindungen zu machen. Die Unternehmen merken, dass ihre Fähigkeiten nicht mehr ausreichen. Die Probleme, zum Beispiel im Zusammenhang mit dem Klimawandel oder den Herausforderungen beim Übergang in eine nachhaltige Kreislaufwirtschaft, werden immer komplexer.

Doch mit der Technik zu «springen», davor scheuen sich noch viele. Diese Furcht vor dem Sprung nennen wir bei AI auch «Blackbox-Effekt». Man weiß oft nicht, was auf Basis von Daten als Ergebnis herauskommt, wie man auch nicht genau sagen kann, wie die Maschine zu ihren Entscheidungen gelangt ist. Man muss es einfach riskieren. Aber, für viele scheint der Schritt zur Nutzung von AI gleichermaßen angstbesetzt zu sein wie ein von uns gezeichneter Fallschirmsprung aus 4000 Metern Höhe. Dabei landen die allermeisten sicher – weil sie eine gute Anleitung haben. Einen Trainer.

Sich durch immer größere Datenmengen zu pflügen und dort Schätze zu heben, wird nicht mehr ohne AI gehen.

Manche Bedingungen zwingen vielleicht zur Landung auf dem Hinterteil anstatt im Stehen. In seltenen Fällen landet man mit dem Notschirm. Aber man landet. Sicher. Das geht eben nur, wenn man auch gesprungen ist. Und auch nur dann erlebt man die Euphorie und hat einen nachhaltigen Vorteil. Nur dann kann man weitermachen, irgendwann ohne Trainer. Blicken viele Unternehmen ehrlich auf das Vorhanden- oder besser: das Nichtvorhandensein von Daten, gleicht das ebenfalls einem Sprung mit einem Fallschirm. Denn ohne saubere, klug zusammengeführte Daten ist die Umsetzung von AI-Anwendungen nahezu undenkbar. Das muss organisiert und das muss vor allem verstanden werden. Doch es fehlen Experten. Es ist tatsächlich schwierig, AI-Experten zu finden und einzustellen. Selbst Führungskräfte zu finden, die das Thema verstehen, managen und umsetzen, ist ein schwieriges Unterfangen.

Brainbyte 7: **Die Zukunft hat längst begonnen.**

Maschinelles Lernen übernimmt immer mehr Aufgaben unseres Alltags. Routineaufgaben werden automatisiert, Entscheidungen werden automatisiert, immer mehr digitale Helfer umgeben uns und nehmen uns Aufgaben ab. Wir nutzen keine Straßenkarte mehr, wir wägen Routen und Fahr-

Es spricht vieles dafür, dass sich mit AI die Natur des Innovationsprozesses verändern wird.

zeiten ab. Wir vertrauen auf Google Maps oder andere Mobilitäts-Apps, die uns den Weg weisen, vor Gefahren warnen und uns an Verabredungen erinnern.

Die Technologie wird immer komplexer, die Zusammenhänge, die Details, auf die es ankommt, liegen in immer größeren Datenmengen verborgen. Sich durch diese Datenberge zu pflügen, dort die Schätze zu heben, wird nicht mehr ohne AI gehen. Ein Lichtblick: Der Umgang mit Daten und AI wird immer leichter.

Maschinelles Lernen ist ein Werkzeug, das auf dem besten Weg ist, so einfach nutzbar zu werden, wie schon jetzt das Bauen einer Webseite.

Was für Nichtinformatiker ein nahezu aussichtsloses Unterfangen war, wird mehr und mehr einer breiten Öffentlichkeit zugänglich. Auch die Hardware entwickelt sich rasant weiter: Inzwischen existieren Steckkarten für PCs, die speziell für das Programmieren und Betreiben neuronaler Netze entworfen wurden. Die Kosten liegen bei wenigen Hundert Euro, erschwinglich für jeden. Doch selbst wenn es erschwinglich ist, braucht es ein Vorgehen, das wir immer anwenden, um ein Problem zu durchdenken. Es reicht nicht, einer Maschine zu sagen: Löse das Problem! Es reicht aber auch nicht, sich auf das bisherige Vorgehen bei Innovationsprozessen zu verlassen und diese lediglich auf die AI zu übertragen. Es spricht vieles dafür, dass sich mit AI die Methode des Erfindens verändert und sich die Natur des Innovationsprozesses verändern wird.

Wir revolutionieren den Innovationsprozess auf zwei Arten: Zum einen können wir viele Entscheidungen besser auf konkrete Fakten stützen, wo vorher viel Bauchgefühl im Spiel war: Zum Beispiel bei der Analyse von Kundenbedürfnissen und Trends. Zum anderen wird die Qualität der Lösungsfindung stark erhöht, weil mit der Fähigkeit der Mustererkennung radikalere, unkonventionellere Lösungen möglich werden, auf die Menschen allein nie gekommen wären.

Machen wir uns also zum Einsteigen bereit.

Briefing

Was Sie
vorab wissen
müssen





Im Briefing geht es um die Möglichkeiten, Chancen, aber auch Limitationen, die mit der AI und dem maschinellen Lernen verbunden sind.

Definition

Was ist AI?

Bevor wir einsteigen, beginnen wir mit einem kurzen Briefing. Es enthält die wichtigsten Begriffe, die im Zusammenhang mit dem Thema Künstliche Intelligenz (Artificial Intelligence, AI) häufig genannt werden.

Wir beginnen mit einer Definition von AI und sehen uns zunächst an, wie Maschinen lernen. Wir sehen uns die unterschiedlichen Lernarten an und welche Arten von Daten dazu notwendig sind.

Schließlich stellen wir die für ein AI-Projekt nötigen Experten vor und geben einen Überblick über deren Zeitbedarf.

Bevor wir Begriffe und Methoden etablieren, wollen wir klären: Wovon sprechen wir, wenn wir von Künstlicher Intelligenz, von AI sprechen?

Was ist eigentlich «künstlich» an der Künstlichen Intelligenz? Gibt es die eine AI, und wenn nein, wie werden die einzelnen AI-Begriffe voneinander abgegrenzt? Und welche Daten sind wichtig und richtig, welche Datenquellen gibt es? Was sind überhaupt Daten? Und muss jeder Code-Editoren beherrschen, muss jeder lernfähige Programme entwickeln können? Muss man das alles gar nicht wissen? Nur anwenden? Und wie lernt eigentlich eine Maschine? Kann sie alles lernen? Wo sind die Grenzen?

Etabliert wurde der Begriff «Künstliche Intelligenz» 1956 vom amerikanischen Informatiker Marvin Minsky.

Der Begriff ist insofern nicht eindeutig definierbar, da es an einer genauen Definition von «Intelligenz» mangelt. Außerdem wird der Begriff heute oft synonym für maschinelles Lernen verwendet.

AI bedeutet, dass man der «Maschine» nicht mehr fest einprogrammiert, wie sie Aufgaben ausführen soll. Sondern sie lernt auf der Basis von Daten und Algorithmen, wie sie eine Aufgabe optimal lösen kann. Das geschieht durch permanentes Experimentieren und Trainieren.

AI ist ein Teilgebiet der Informatik, das sich mit der Automatisierung intelligenten Verhaltens und dem maschinellen Lernen befasst.

AI-Programme haben zwei wesentliche Eigenschaften: Erstens **Autonomie**, also die Fähigkeit, Aufgaben in komplexen Umgebungen ohne ständige Anleitung durch einen Benutzer auszuführen.

Und zweitens: **Anpassungsfähigkeit**. Die Fähigkeit, die eigene Leistung zu verbessern, indem man aus der Erfahrung lernt.

Mithilfe dieser Eigenschaften sind AI-Programme viel flexibler und anpassungsfähiger. Sie helfen dem Menschen in der Interaktion mit dem Computer. Denn nun kann dieser sich auf die Menschen einstellen, anstatt anders herum.


Ein weites Land

Künstliche Intelligenz:
Eine Einordnung

Ein Programm, das selbständig denken, handeln und sich anpassen kann

Algorithmen, deren Leistung sich mit der Zeit verbessert, je mehr Daten sie verarbeiten

Fachgebiet des maschinellen Lernens, bei dem mehrschichtige neuronale Netze aus großen Datenmengen lernen



Einordnung

Wie sich Mensch und Maschine unterscheiden

Künstliche und menschliche Intelligenz sind nicht miteinander vergleichbar.

Künstliche und menschliche Intelligenz sind nicht miteinander vergleichbar. Für Menschen ist es normalerweise kein Problem, eine Tasse auf einem Tisch zu greifen, sie an den Mund zu führen und einen Schluck Kaffee daraus zu genießen. Die Bewegung und der Griff nach der Tasse werden durch eine genau geplante Steuerung von verschiedensten Muskelpartien ausgeführt, die sich in einer bestimmten Reihenfolge kontrahieren und entspannen. Der Druck, mit dem wir die Tasse greifen, ist ebenfalls genau abgestimmt, da wir die Tasse nicht zerstören möchten. Wir führen die Tasse zum Mund, riechen, pusten, um uns nicht zu verbrennen, schmecken, schlucken, empfinden. Was uns leicht erscheint, kann für Roboter oder maschinelle Lernsysteme eine nahezu unlösbare Aufgabe darstellen.

Jeder einzelne Aspekt muss gelernt, vertieft, mit anderen koordiniert werden. Selbst für eine banale Sache, wie Kaffee trinken.

Die menschliche Intelligenz umfasst ein breites Spektrum von Fähigkeiten, wie logische, räumliche und emotionale Kognition. Egal, ob der Obstverkäufer um die Ecke oder der Wissenschaftler im Labor, sie alle benötigen kognitive Fähigkeiten, wie Arbeitsgedächtnis, Aufmerksamkeit, strategische Planung, abstrakte Argumentation, das Kategorisieren von Informationen und Mustererkennung, um die Welt und ihre Aufgaben jeden Tag zu verstehen und sie erfolgreich zu meistern.

Obwohl Computer Menschen vielleicht bei komplexen Rechenaufgaben um Längen schlagen oder bei automatisierbaren Aufgaben eine ungeschlagene Geschwindigkeit erreichen, ist ihre Kompetenz (etwa beim Generalisieren von gelernten Fähigkeiten) in vielen anderen Bereichen heute noch sehr begrenzt und eher mit denen einer Ameise vergleichbar.

AI ist ein Dachbegriff für viele Berechnungs- und Automatisierungstechniken. Man unterscheidet zwischen **ANI (Artificial Narrow Intelligence)** und **AGI (Artificial General Intelligence)**:

ANI – Artificial Narrow Intelligence

ANI ist eine Form der AI, die sich darauf konzentriert, eine eng beschriebene Aufgabe zu erfüllen. Diese Form der AI ist heute die vorherrschende in verfügbaren Anwendungen. Sie löst Aufgaben in bestimmten, klar definierten Bereichen, wie zum Beispiel Spracherkennung oder Bilderkennung.

AGI – Artificial General Intelligence

Allgemeine AI oder Künstliche Allgemeine Intelligenz (AGI) bezieht sich auf eine Maschine, die jede intellektuelle Aufgabe bewältigen kann, vergleichbar mit der menschlichen Intelligenz. AGI liegt derzeit (noch) im Bereich der Science-Fiction. In den letzten 50 Jahren gab es trotz aller Bemühungen keine nennenswerten Fortschritte.

Systematisch trainieren

Wie Maschinen lernen

Bevor wir uns genauer anschauen, auf welche verschiedenen Arten eine Maschine neue Fähigkeiten lernen kann, müssen wir grundsätzlich verstehen, wie ein maschineller Lernprozess abläuft, um am Ende ein Resultat zu liefern.

Der Lernprozess lässt sich gut mit einem vertrauten Beispiel illustrieren: dem Kochen einer Suppe. Das ist natürlich nur eine stark vereinfachte Darstellung, repräsentiert aber die grundlegende Vorgehensweise beim maschinellen Lernen. Wir beginnen mit der Aufgabe. Wir wollen eine Suppe kochen. Daraus leitet sich das weitere Vorgehen ab – Zutaten, Rezeptur, Zubereitung.

1. Als erstes brauchen wir Zutaten. Im Falle des Machine Learnings (ML) sind das die **Daten**, mit der wir unser Modell füttern werden. Neben den Zutaten könnten dies auch beispielsweise Vorlieben oder Allergien unserer Gäste sein, die wir berücksichtigen müssen.
2. Die **Algorithmen** bilden die Regeln, die Schritt-für-Schritt Anleitung, also unser Rezept, wie die Zutaten in welcher Reihenfolge miteinander verarbeitet/kombiniert werden.
3. Die Kochutensilien, um die Zutaten nach dem Rezept zubereiten zu können, sind unsere **Hardware**, unsere Ressourcen, ohne die sich unsere Zutaten nicht verarbeiten lassen würden. Für maschinelles Lernen sind das in der Regel Grafikprozessoren (GPUs), die große Datenmengen verarbeiten und unsere Modelle berechnen können.

Die Schwäche von AI: Der Mensch kapiert einfach schneller.

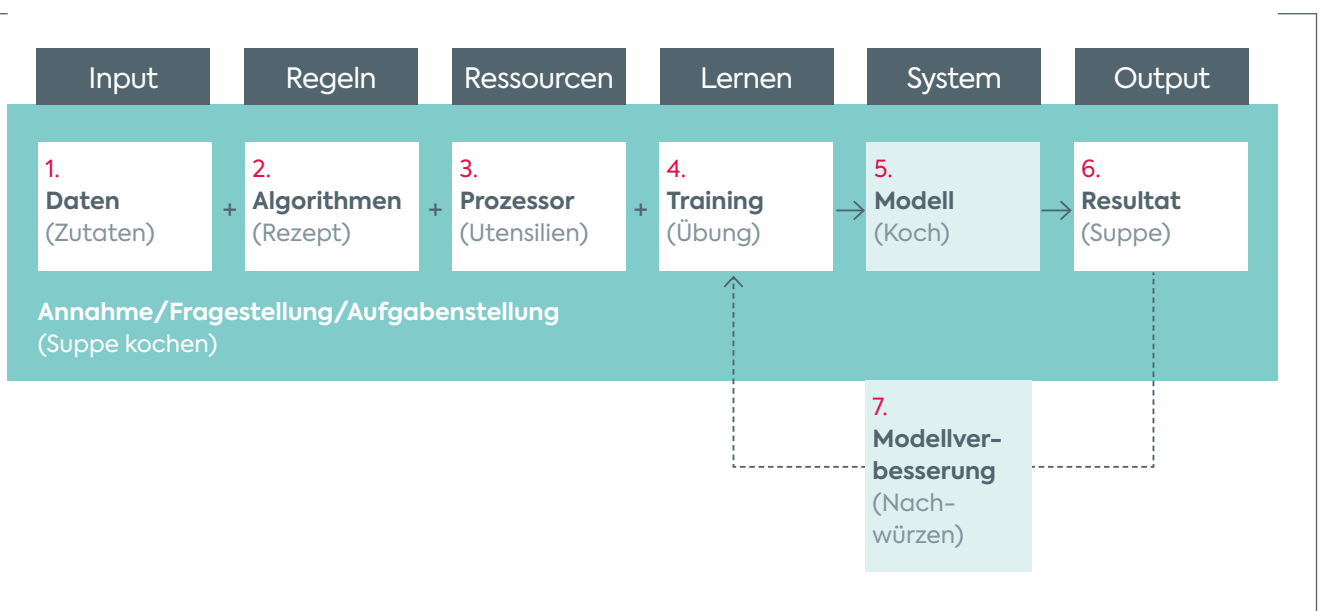
Schwer von Begriff

4. Das **Training**, das auch jeder gute Koch braucht, um mit der Zeit besser zu werden und ein schmackhaftes Resultat liefern zu können, bildet die Grundlage für jedes ML-System.
5. Das trainierte **ML-Modell**, in unserem Fall der Koch, weiß, wie all die vorher genannten Elemente miteinander kombiniert werden müssen.
6. Hier kommen Zutaten, Rezepte, Utensilien und Training zusammen, um am Ende unsere perfekte Suppe zu kreieren, unseren **Output**.
7. Jeder Koch muss seine Gerichte am Ende abschmecken, um sicherzustellen, dass sie auch wirklich schmecken. Das Nachwürzen repräsentiert das Nachtrainieren, die **Iteration unseres Trainingsmodells**. Dadurch liefert es über die Zeit immer bessere Ergebnisse, die Suppe wird zur Meisterleistung.

Ein Kind braucht nur eine einzige Katze zu sehen, um zu lernen, was eine Katze ist. Eine Maschine braucht Zehntausende von Bildern, um ein Objekt akkurat bestimmen zu können. Absichten zu erkennen ist ebenfalls sehr schwierig für eine AI. Wenn ein Mensch beispielsweise die Hand ausstreckt, kann dies mehrere Bedeutungen haben. Anhalten, weil eine Gefahr lauert, per Anhalter fahren oder mit dem Fahrrad abbiegen.

Der ML-Prozess im Überblick

Das Beispiel Suppe kochen zeigt, wie Maschinen lernen.



Diese Absichten zu interpretieren ist für ein Machine-Learning-Modell deshalb so schwierig, weil häufig nicht eine genügend große Masse an Daten vorliegt. Dazu fehlt meist auch das Kontextverständnis.

Beim maschinellen Lernen geht es um die Wissenschaft – man könnte schon fast sagen: Kunst –, Computer so zu programmieren, dass sie von Daten lernen können, um zu Ergebnissen zu kommen. Dazu bauen ML-Algorithmen statistische Modelle, die auf sogenannten **Trainingsdaten basieren**. Diese dienen den Algorithmen als eine Art Anleitung, eine Blaupause, damit sie verstehen, was richtig und was falsch ist.


Je mehr Daten über die Zeit ins System eingespeist werden, desto stärker wird die Leistung dieser Modelle. Das bedeutet, dass die Modelle nicht einfach nur die Daten «auswendig» lernen, um sie dann wiederzugeben, sondern lernen, Muster in den Daten zu erkennen und sie dadurch zu verallgemeinern und auf neue Situationen zu übertragen.

Die Grundlage des Maschinentrainings


Das Besondere bei Machine-Learning-Modellen ist, dass sie den Weg, wie sie Daten interpretieren und ein Ergebnis produzieren, selbst entwickeln. Ein ML-Modell kann dabei mehrere Algorithmen enthalten und auf unterschiedliche Weise lernen beziehungsweise trainiert werden. Wir konzentrieren uns hier auf die drei gängigsten Lernarten.

1. **Supervised Learning (SL)**
2. **Unsupervised Learning (UL)**
3. **Reinforcement Learning (RL)**

Beim **Supervised Learning** lernt ein Programm nach und nach Zusammenhänge und kann Bilder, Musik, Gesichter oder (in der Medizin) auch Tumore erkennen. Damit ein Computerprogramm das alles erkennen kann, braucht es eine Beschreibung. Das kann zum Beispiel eine zu einem Röntgenbild gehörende Diagnose sein. Ist sie nicht vorhanden, muss sie von Hand erstellt werden. In jedem Fall muss der Inhalt eines Bildes in der Beschreibung präzise klassifiziert werden. Sätze werden beispielsweise in grammatikalische Elemente zerlegt und als Artikel, Substantiv und Verb beschriftet, Verkehrsschilder in Stopp, Vorfahrt achten und Tempo 30 klassifiziert.



Supervised Learning: Das ML-Modell lernt Dateninhalte zu gruppieren und Vorhersagen zu erstellen.



Unsupervised Learning: Das ML-Modell sucht selbstständig nach Mustern in großen Datenmengen.

Auf diese Weise kann das Programm den Zusammenhang erlernen. Wird das Ergebnis von Menschen bewertet und neues Trainingsmaterial hinzugefügt, wird die Qualität nach und nach immer besser.

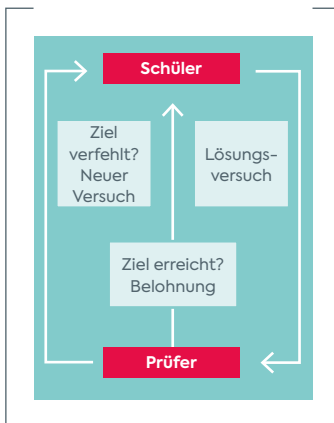
SL ist die am häufigsten eingesetzte Art von maschinellem Lernen, da es die meisten Business und Use Cases betrifft. Wenn die Daten gelabelt sind, kann die Maschine recht schnell trainiert werden und so Ergebnisse liefern. Wichtig: Beim SL definiert man einen Input A, also Daten, und gibt dem Algorithmus vor, wie der Output B aussehen soll.

Beim **Unsupervised Learning** geht es darum, Muster oder «Interessantes» in einer großen Datenmenge zu finden, ohne dass vorgegeben wird, was genau gesucht wird. Es wird ein Input A hineingegeben, ohne zu definieren, was B sein soll – im Gegensatz zum Supervised Learning. Dadurch sind deutlich weniger vorab «gelabelte» Daten nötig.

UL gilt als die große Hoffnung der ML Research Community, da es dem Lernen des menschlichen Gehirns vergleichbar ist. Ein Mensch muss beispielsweise nicht erst 1000 Autos gesehen haben, bevor er sagen kann, was ein Auto ist. Sobald er einmal eines oder wenige mehr gesehen hat, kann er das Konzept Auto auf andere Fahrzeuge übertragen und diese als Autos identifizieren.

Reinforcement Learning funktioniert dagegen ähnlich, wie das Trainieren eines Hundes. Man lässt den Hund alles Mögliche tun und belohnt oder «bestraft» ihn. So lernt der Hund mit der Zeit, wovon mehr gewünscht ist, wodurch die Belohnung zu erwarten ist und welches Verhalten unerwünscht ist, was also keine Belohnung zur Folge hat.

Reinforcement Learning wird vermehrt in der Fertigung angewendet. In der konventionellen Fertigung würde die Maschine zeitgesteuerte Verfahrensschritte durchführen. Durch den Einsatz von RL werden diese Maschinen anpassungsfähig. Sie können auf neue Bedingungen reagieren und sich nun laufend selbst korrigieren. Das funktioniert auch im Gesundheitswesen. Reinforcement Learning wird beispielsweise verwendet, um herauszufinden, welche Art von Diagnose bei



Reinforcement Learning:
Zwei Modelle, Schüler und Prüfer, treten gegeneinander an. Der «Schüler» versucht dabei, durch Trial and Error das beste Ergebnis zu liefern. Der «Prüfer» beurteilt, ob das gewünschte Ergebnis erreicht ist. Durch die Belohnung lernt der «Schüler», den besten Lösungsweg zu ermitteln.

Deep Learning

Der Begriff hat nichts mit den Lernarten zu tun. Er basiert auf dem Konzept von «Neuronalen Netzen», sie sind dem Netz echter Neuronen in unserem Gehirn nachempfunden. Es ist also die Beschreibung einer technischen Architektur. Hier sind viele Verarbeitungsebenen hintereinander angeordnet – daher die Bezeichnung «tief» («deep»). Deep Learning kann bei allen oben angeführten Lernarten eingesetzt werden.

bestimmten Medikamenten am besten funktioniert, durch Trial and Error in Simulationen.

Einfach gesagt: Die Maschine probiert Sachen aus, schaut sich das Ergebnis an und entscheidet dann, wie sie weitermachen und ob sie weitermachen will.

Das hat sich bewährt. Die Robotik wäre beispielsweise ohne RL undenkbar. Daher wird die Bedeutung dieses Feldes stark zunehmen. Vor allem wird RL bei Tests von autonomen Fahrzeugen verwendet. Ein Simulationstraining mit RL ist beim Training von autonomen Fahrzeugen seit einiger Zeit Standard. Mit jeder neuen Trainingssituation werden die bereits vorhandenen «Belohnungen» berücksichtigt und das System dadurch optimiert. Man schult die Maschine so lange mit einem Belohnungssystem in der simulierten Umgebung, bis sie gut genug ist, um wenige bis keine Fehler mehr zu machen.

Hier gibt es allerdings einen Haken. Das Problem ist, dass Simulationen genau das sind: Simulationen. Nichts aber kann unsere Welt genau nachahmen. Wenn es auch nur einen kleinen Unterschied zwischen der Testumgebung und der realen Welt gibt, funktioniert das Modell möglicherweise nicht in dieser neuen Umgebung. Hier kommt es letztlich auf die Simulationsqualität an. Je genauer sie die Realität wiedergibt, desto besser. Außerdem kann bei sicherheitskritischen Themen, wie autonomen Fahrzeugen, nicht auf Tests in der echten Welt verzichtet werden.

Damit sind wir am entscheidenden Punkt angelangt. Um lernen zu können, braucht die Maschine Daten.

Rohstoff Daten

Was Maschinen zum
Lernen brauchen

Quantitative Daten versus
qualitative Daten

Daten – dieses Wort begegnet einem überall. Grundsätzlich sind Daten im heutigen Sprachgebrauch computerlesbare und vom Computer verarbeitbare digitale Informationen, die durch Messung und Beobachtung erhoben und dann gespeichert werden. Daten können dabei einen unterschiedlichen Komplexitätsgrad haben. Während Text oder tabellarische Daten in der Regel eher niederkomplexer sind, liegt die Informationsdichte bei komplexen Daten, wie Musik, Video oder 3-D-Daten, um ein Vielfaches höher. Viele Daten liegen aber natürlich auch in analoger Form vor. Dann müssen sie zunächst digitalisiert werden. Grob lassen sich Daten in zwei Hauptkategorien unterteilen: in Quantitative und Qualitative Daten.

Quantitative Daten können mithilfe von Zahlen gezählt, gemessen und ausgedrückt werden. Sie werden aus Tests und Experimenten, Marktberichten oder Statistiken generiert, die sich zum Beispiel tabellarisch darstellen lassen.

Qualitative Daten sind deskriptiv und konzeptionell. Das sind zum Beispiel Texte und Dokumente, Bilder und Videos.

Strukturierte Daten versus
unstrukturierte Daten

Neben qualitativen und quantitativen Daten spricht man auch von strukturierten und unstrukturierten Daten.

Strukturierte Daten enthalten zum Beispiel Kategorien oder Bezeichnungen für Inhalte. Bilder werden zum Beispiel häufig mithilfe von tabellarischen Informationen ergänzt, um sie besser verarbeitbar zu machen. Diese Metadaten sind strukturiert, das Bild selbst ist unstrukturiert. In der Regel werden sie so formatiert, dass sie in bestehenden Datenbanken leicht durchsucht werden können, beispielsweise in Tabellenform mit Zeilen und Spalten. Strukturierte Daten werden am häufigsten als quantitative Daten kategorisiert. Das ist die Art von Daten, mit der die meisten von uns gewohnt sind, zu arbeiten. Man könnte also sagen, strukturiert sind alle Arten von Daten, die sich in feste Felder und Spalten in relationalen Datenbanken und Tabellen (etwa Excel) einfügen lassen.

Strukturierte Daten sind gut organisiert und somit generell für Computerprogramme leicht lesbar und verständlich. Anwendern, die mit solchen Daten arbeiten sollen, haben es

Strukturierte Daten

Namen, Daten, Adressen,
Kreditkartennummern,
Bestandsinformationen,
Geolokalisierung.

vergleichsweise leicht: Sie können die Daten relativ schnell eingeben, suchen und weiter bearbeiten.

Mehr als 80 Prozent aller heute erzeugten Daten gelten allerdings als unstrukturiert. Und diese Zahl wird im Zusammenhang mit dem Internet der Dinge (IoT) und Social Media weiter steigen.

Unstrukturierte Daten

Text, Video, Audio,
mobile Aktivitäten,
Social-Media-Aktivitäten.

Unstrukturierte Daten haben kein vordefiniertes Format oder eine bestimmte Organisationsform, was die Erfassung, Verarbeitung und Analyse erheblich erschwert. Bei unstrukturierten Daten ist nur der Dateityp bekannt. Der Inhalt liegt aber nicht fein säublich sortiert in voneinander abhängigen Datenfeldern wie in einer Tabelle vor.

Unstrukturierte Daten gehören meist in die Kategorie der qualitativen Daten, da sie keine formalisierte Struktur besitzen. Dadurch können Algorithmen nicht über eine einzelne Schnittstelle auf diese Daten zugreifen. Beispiele für unstrukturierte Daten sind Text, Video, Audio, mobile Aktivitäten, Social-Media-Aktivitäten. Wer unstrukturierte Daten zum Beispiel mithilfe von Machine Learning nutzbar machen kann, ist heute als Unternehmen klar im Vorteil.

Während strukturierte Daten vergleichbar mit der Vogelperspektive auf unseren Kunden sind, können unstrukturierte Daten uns ein viel tieferes Verständnis für das Verhalten, die Bedürfnisse und die Absichten unserer Kunden vermitteln.

Unstrukturierte Daten sind auch für Predictive-Maintenance-Systeme von Bedeutung. So können beispielsweise Daten von Sensoren, die an Industriemaschinen angebracht sind, Hersteller vorab über seltsame Aktivitäten informieren. Mit diesen Informationen kann eine Reparatur durchgeführt werden, bevor die Maschine einen kostspieligen Ausfall erleidet. Unabhängig davon, ob die Daten strukturiert oder unstrukturiert sind, ist die Verfügbarkeit von sehr genauen und relevanten Daten der Schlüssel zum Erfolg für Unternehmen, die AI nutzen wollen.

Faktor Mensch

Welche Experten für AI nötig sind

Wer eine Machine-Learning-Anwendung entwickeln will, benötigt als Team unterschiedliche Experten (siehe Kapitel «Sicher landen – Menschen und Organisation» auf Seite 291). Die Wichtigsten stellen wir an dieser Stelle vor.

Machine Learning/Deep Learning Engineer: Er verleiht Computern die Fähigkeit, bestimmte Aufgaben, wie das Prognostizieren von Kaufverhalten oder das Übersetzen von Texten, zu lernen. Seine Hauptaufgabe ist das Programmieren und Trainieren sowie Anpassen von Machine-Learning-Modellen. Das Ergebnis seiner Arbeit ist vereinfacht gesagt: Software.

Data Scientist/Data Architect: Er wertet vor allem Daten aus. Diese stammen aus unterschiedlichen Quellen innerhalb und außerhalb des Unternehmens. Er versteht die betriebswirtschaftlichen Zusammenhänge, interpretiert die Daten in diesem Kontext und kommuniziert die Ergebnisse an das Management und die Programmierer. Er ist Übersetzer von Zusammenhängen und produziert im Wesentlichen anschauliche Slide Decks oder Datenvisualisierungen.

Data Engineer, Distributed Systems Engineer: Machine-Learning-Anwendungen benötigen häufig sehr großen Datenmengen und viel Rechenleistung. Die Aufgabe des Data Engineers ist es, die Menge an benötigten Daten und die Rechenleistung so gut wie möglich zu reduzieren. Er löst Probleme im Umgang mit Daten. Und verschafft dem Data Scientist und dem Machine Learning Engineer so den Freiraum, sich auf ihre Modelle zu konzentrieren.

Machine Learning/Deep Learning Researcher: Übernimmt Unteraufgaben aus dem Data Engineering und die Modellierung von Algorithmen. Dazu gehört das Sammeln, Labeln und Aufbereiten von Daten sowie das Trainieren von Machine-Learning-Modellen und Auswerten von Forschungsberichten.

Software Engineer: Eine weitere unterstützende Funktion. Ähnlich wie die Researcher kümmern sich auch Software Engineers um das Sammeln und Labeln von Daten. Dazu kümmern sie sich auch um die interne AI-Infrastruktur. Das sind vor allem Aufbau und Wartung von zuverlässigen,

schnellen, sicheren und skalierbaren Software-Systemen für Data Engineering und Modellierung von Algorithmen sowie der betriebswirtschaftlichen Analyse

Zeit ist Geld

Wie lange AI-Projekte dauern

Grundsätzlich lassen sich vorzeigbare Ergebnisse innerhalb von Monaten realisieren – sofern nicht Grundlagenforschung betrieben werden muss.

Machine-Learning-Anwendungen zu programmieren, muss nicht lange dauern. Im Wesentlichen hängt es davon ab, wie aufwendig die einzelnen Schritte im Prozess sind. Daten zusammentragen, den Algorithmus auswählen und anpassen, technische Ressourcen bereitstellen, ML-Modell trainieren, Vorhersagen testen und bewerten.

Für all diese Aufgaben gibt es von Jahr zu Jahr mehr und mehr vorgefertigte Bausteine. Das sind zum Beispiel vorkonfigurierte Cloud-Systeme (sogenannte Boilerplates, wie Azure oder Amazon Web Services), fertige Machine Learning Frameworks (wie Tensorflow) oder sogar fertige Systeme für den jeweiligen Anwendungsfall (wie albert.ai für die Vertriebsunterstützung). Auch sehr gute Datenquellen werden zunehmend öffentlich verfügbar, wie zum Beispiel im stetig wachsenden Open Data Pool. Wer damit sein Problem lösen kann, dem reicht für ein erstes, meist grobes Ergebnis eine Woche Aufwand.

Ein Machine-Learning-Projekt zieht sich in die Länge, wenn in jedem Schritt des Prozesses viel Entwicklungsarbeit anfällt: für die Suche nach korrekten Datenquellen, für das Programmieren von Software etc. Dann kann ein Projekt sechs Monate und mehr dauern (siehe «Time Calculator» auf Seite 104).

Grundsätzlich lassen sich vorzeigbare Ergebnisse innerhalb von Monaten realisieren – sofern nicht Grundlagenforschung betrieben werden muss, wie bei den AI-Projekten zum Beispiel von Google oder universitären Forschungsprojekten.

Einsteigen

Wie der
AI Planner
funktioniert







Der AI Planner ist ein Detektor, mit dem wir verstehen können, welche Datenquellen, Machine Learning Skills und Trainingsparameter für das Erreichen unserer Ziele nötig sind. Das so entstehende AI-Konzept hilft beim Gespräch mit Experten und Projektspensoren.

Die Tools

Was wir zum Springen brauchen

AI-Innovationen brauchen ein konkretes Ziel, valide Datenquellen, ein Lernmodell sowie einen unternehmerischen Mehrwert.

AI Planner

Im Kapitel «Briefing» haben wir gelernt, was AI ist und was lernende Computerprogramme benötigen, um ein Problem zu lösen. Vielleicht haben Sie Lust auf mehr bekommen – und Sie haben all die Beispiele im Kopf, bei denen Unternehmen nahezu Fantastisches mit dem Einsatz von AI erreicht haben. In der Praxis stellen sich schnell eine Menge Fragen: Woher weiß ich, wann der Einsatz dieser Programme sinnvoll ist? Was brauche ich eigentlich an Daten dazu? Und wie viel Aufwand wird das sein? All diese Fragen wollen wir in diesem Kapitel beantworten.

Seit Jahren denken wir in unserer täglichen Arbeit darüber nach, wie sich Innovationsprozesse und -methoden verbessern lassen. Wo wir früher noch mühsam Experteninterviews transkribiert haben, helfen uns nun AI-gestützte Assistenzsysteme bei der Verschriftlichung von Audiomitschnitten. Wir sehen, wie immer mehr maschinelles Lernen alltägliche Routineaufgaben übernimmt – und uns damit tagelange Handarbeit erspart. Bei der Auseinandersetzung mit den Möglichkeiten von AI für das Entwickeln von Innovationen haben wir erkannt, dass beim Einsatz von lernenden Systemen im Unternehmen vier Aspekte berücksichtigt werden müssen: Ein konkretes Ziel, valide Datenquellen, ein Lernmodell sowie der unternehmerische Mehrwert.

Wir haben diese Aspekte in konkrete Aktionen übersetzt, mit klaren Teilaufgaben. Diese Aktionen sind immer gleich – egal, welche Aufgabe wir mithilfe von AI lösen wollen. Um alle Aktionen übersichtlich zusammenzufassen, haben wir den «AI Planner» entwickelt. Mit dessen Framework tragen wir Schritt für Schritt alle notwendigen Informationen zusammen. Am Ende ist er die zentrale Entscheidungshilfe, um uns für oder gegen den Einsatz lernender Systeme zu entscheiden.

Er ist wie ein Detektor, mit dem wir verstehen können, welche Datenquellen, Machine Learning Skills und Trainingsparameter für das Erreichen unserer Ziele nötig sind. Das auf diese Weise entstehende AI-Konzept hilft beim Gespräch mit AI-Experten und Projektspensoren.



1. Ziel
definieren



2. Daten
recherchieren




3. Lernkonzept
erstellen



4. Entscheidung
treffen


AI-Mehrwert



Datenquellen



Maschinen-
fähigkeiten



Vorgehens-
vergleich



Challenge



Datenprüfung



Trainings-
parameter



Entscheiden



Output



Datenerhebung



AI-Toolset Zum AI Planner gehört ein umfangreiches Set an Tools, das hilft, die komplexe Materie zu erfassen und nichts zu verpassen. Am Ende, das können wir Ihnen versprechen, können Sie mit AI-Experten und Ihren Projektsponsoren fundiert diskutieren, ob und warum Ihr geplantes AI-Projekt für das Unternehmen einen Mehrwert stiftet. Oder warum es das gerade nicht tut. Der AI Planner fasst die Ergebnisse aus den folgenden Aktionen zusammen zu einem Steckbrief für das AI-Konzept.

1. Ziel definieren Hier geht es um das Warum. Basierend auf unserem Auftrag, machen wir uns klar, worin der Mehrwert einer AI-Lösung konkret besteht. Daraus leiten wir konkrete Arbeitsaufträge, die Challenges, ab. Schließlich überlegen wir, in welcher Form das gewünschte Ergebnis dargestellt werden soll. Als schlichte Liste, in Form von Visualisierungen, als Sprache oder sogar als konkreter Vorschlag einer Rezeptur oder eines Designs.

2. Daten recherchieren Wir beschreiben, wie die Herausforderung mithilfe von Daten gelöst werden kann. Wir gehen auf die Suche nach passenden Datenquellen im oder außerhalb des Unternehmens – und prüfen, ob sie sich für die Aufgabe eignen. Wir skizzieren schließlich die Reihenfolge der Datenverarbeitung.

3. Lernkonzept erstellen Das Herz des Machine-Learning-Projekts. Wir entscheiden uns für die benötigten Machine Learning Skills und überlegen, wie präzise das AI-Modell arbeiten muss. Alle diese Informationen beeinflussen maßgeblich den Aufwand des AI-Projekts.

4. Entscheidung treffen Um grünes Licht für ein AI-Projekt zu bekommen, benötigen wir Informationen darüber, wie groß die zu erwartenden Vorteile durch das AI-System sein werden. Wir stellen Ergebnisqualität und Aufwand gegenüber – die hier vorgestellte Matrix liefert eine Einordnung, ob sich die Umsetzung lohnt.





1. Ziel definieren

AI-Mehrwert

Auftrag

Erwarteter Mehrwert durch AI

Challenge


Output

Erkennen ☐ **Vorhersagen** ☐ **Erzeugen** ☐


Outputformat




2. Daten recherchieren

Datenquellen

	Typ	Quelle	Warum?
A	<input type="text"/>	<input type="text"/>	<input type="text"/>
B	<input type="text"/>	<input type="text"/>	<input type="text"/>
C	<input type="text"/>	<input type="text"/>	<input type="text"/>
D	<input type="text"/>	<input type="text"/>	<input type="text"/>

Datenprüfung

	Priorität	Beschaffung	Technik
A	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
B	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
C	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
D	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Datenerhebung

Grund für die Datensammlung

Daten-typen

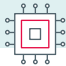
Priorität ☐ ☐ ☐ ☐

Beschaffung ☐ ☐ ☐ ☐


Technik ☐ ☐ ☐ ☐





3. Lernkonzept erstellen

Maschinenfähigkeiten 

	Aufgabe	Quelle	Fähigkeit
A			
B			
C			
D			

Trainingsparameter 

Menschlicher Maßstab	Minimalanforderung
Erwünschtes Zielmaß	Mindestvertrauen


 Recall
  Precision




4. Entscheidung treffen

Vorgehensvergleich 

	Ohne AI	Mit AI
Personal		
Zeit		
Kosten		
Hürden		
AI-Potenzial		

Entscheiden 

Ergebnisqualität/ Geschäftswert	Nichts wie ran!	Nur wenn langfristige strategisch relevant
	Ist es wirklich notwendig?	Auf keinen Fall!
		Risiko/Aufwand



Das Framework

Der AI Planner strukturiert den Prozess für die Entwicklung eines AI-Konzepts. Jedes Element des Planners enthält ein eigenes Template. Hier dokumentieren wir die Ergebnisse aus den jeweiligen Überlegungen. So entsteht Schritt für Schritt ein Steckbrief für das künftige AI-Projekt.

Die Navigation

Dieses Symbol sorgt auf den folgenden Seiten für den richtigen Überblick. Wir zeigen damit, um welche Elemente im AI Planner es gerade geht (hier: «Ziel definieren: AI-Mehrwert», rot).

Den Planner nutzen

Struktur und Ergebnis

Ein gutes Template ist wie ein Schnittmuster: Es weist den Weg zum fertigen Produkt.

Die Arbeit mit Templates hat viele Vorzüge. So eine klar strukturierte Vorlage hat dieselbe Funktion für Projektaufgaben wie Schnittmuster für das Nähen von Kleidung. Ein gutes Template ist eine grafisch ansprechend aufbereitete und durchdachte Anleitung. Es nimmt die Scheu vor komplexen Aufgaben und weist anhand eines erprobten Lösungsmusters Schritt für Schritt den Weg zum konkreten Ergebnis.

Templates gibt es im Film für das Erstellen von Sitcoms, im Geschäftsleben für die Modellierung von Geschäftsmodellen oder das Austüfteln von Konzepten. Der AI Planner leistet dies für die Entwicklung eines AI-Projekts. Auf den folgenden Seiten gehen wir jedes Element des AI Planners Schritt für Schritt gemeinsam durch.

Wir bereiten uns vor auf den Sprung ins Ungewisse. Jeder Handgriff sollte sitzen, bevor wir zum ersten Mal springen. Daher aufgepasst. Und los.

Ausrüstung

Um ein AI-Konzept zu erstellen, sind eine Menge kleiner und großer Aufgaben zu erledigen. Wir haben diese Aufgaben in einzelne Elemente unterteilt, um das unbekannte Feld der Künstlichen Intelligenz überschaubarer zu machen. Jedes Element repräsentiert also einen konkreten Arbeitsschritt. Und dazu präsentieren wir jeweils praktische Hilfsmittel. Mal ist es nur ein Set von Leitfragen, mal eine Checkliste, mal eine komplexere Analysemethode. Die von uns entwickelten Tools helfen dabei, nichts zu übersehen und in jeder Phase des AI-Entwicklungsprojekts die richtigen Fragen zu stellen.

Aufbau

Wie zu Beginn des Kapitels vorgestellt, wird beim AI Planner in jeder der vier Aktionen ein großes Thema abgehandelt: Ziel definieren, Daten analysieren, Lernkonzept erstellen, Entscheidung treffen.

Alle vier Aktionen bauen aufeinander auf. Wir nutzen die Erkenntnisse einer Aktion als Grundlage für die Arbeiten in der nächsten. Jede Aktion hat ihre eigene Komplexität und erfordert andere Perspektiven und Denkweisen und gegebenenfalls das Wissen von Experten.

Stakeholder frühzeitig einbeziehen

Ein AI-Konzept ist ähnlich wie ein Geschäftsmodell eine komplexe Angelegenheit. Es erfordert Wissen aus sehr unterschiedlichen Fachgebieten und mehrfache Perspektivwechsel. Mit dem AI Planner bereiten wir den Boden, um mit den jeweiligen Experten fundiert diskutieren können.

Ansprechpartner

In den folgenden vier Aktionen begeben wir uns ein kleines Stück in die sehr gegensätzlichen Welten von Managern und AI-Experten. Beim **«Ziel definieren»** sprechen wir die Sprache der Produktmanager, denken kundenorientiert.

Beim **«Daten recherchieren»** begeben wir uns auf die Spuren von Datenwissenschaftlern und holen uns bei Bedarf hier Unterstützung.

Das **«Lernkonzept erstellen»** erfordert schließlich eine Auseinandersetzung mit den Fähigkeiten von Maschinen, Lernarten von AI und den Tücken der Wahrscheinlichkeit. Machine-Learning-Experten helfen hier.

Schließlich wollen wir eine **«Entscheidung treffen»** – wir kommen nun in der Welt der Manager, der Entscheiderinnen an und befassen uns mit Kosten, Aufwänden und Chancen.

Das also ist alles, was angehende AI-Innovatoren, was Fallschirmnovizen für ihren ersten Sprung brauchen: Einen Fallschirm, einen Höhenmesser, stabile Stiefel, Brille, Helm und einen Gurt.

Zusätzlich benötigen wir ein Anwendungsszenario, das wir zu Übungszwecken nutzen.



Die Mehrwert-Falle

Noch immer scheitern die meisten Innovationen an einem simplen Problem: Sie finden keine Käufer. Der Mehrwert für die Kunden und das Unternehmen ist daher besonders wichtig. Beides müssen wir immer im Blick behalten.

Das Szenario

Gefährden Elterntaxis das Leben von Kindern?

In manchen Orten werden 30 Prozent aller Schüler von ihren Eltern mit dem Auto zur Schule gefahren. Die Folge: Das erhöhte Verkehrsaufkommen vor den Schulen sorgt für mehr Unfälle. Besonders gefährlich ist es, wenn sich Autotüren zum Aussteigen unvermittelt öffnen und radelnde Kinder dagegenfahren. Zusätzlich werden immer mehr Kinder während sie im Auto zu Schule gebracht werden, verletzt. Das Statistische Bundesamt hat die Zahlen beim Schulweg verletzter Sechsbis Neunjähriger in Deutschland ermittelt: Spitzenreiter mit rund 3087 Verletzten sind die Autokinder. Unter Fußgängern gab es nur 2336 Verletzte, unter Radfahrern waren es mit 1829 noch weniger. Verursacher vieler Unfälle sind autofahrende Eltern. Mit anderen Worten: Mit dem Elterntaxi steigt das Unfallrisiko.

Die Indizien zeigen, das Problem existiert vermutlich bundesweit. Es ist offenbar auch ein Trend zu erkennen – doch ein genauerer Blick in die Untersuchungen zeigt: Es ist nicht klar zu trennen, welche Ursachen die Unfälle genau haben. Ist es eher der allgemein zunehmende Verkehr morgens – oder konzentriert sich das Problem auf den Bereich vor Schulen?

Für unser Szenario soll eine fiktive Expertengruppe im Auftrag des Bundesverkehrsministeriums diese Entwicklung genauer untersuchen. Das Ergebnis dieser Recherche soll die Basis für die Entwicklung von konkreten Lösungen sein.

Mehr Fragen als
Antworten

Ein fiktives Expertenteam soll die steigende Unfallgefahr durch Elterntaxis untersuchen.

Eine genaue Ursachenforschung stellt sich jedoch als sehr aufwendig heraus. Je tiefer die Experten sich in das Thema vertiefen, desto mehr Fragen stellen sich. Was gibt es für Mobilitätstrends? Was lässt sich über das Mobilitätsverhalten von Eltern in urbanen Räumen sagen? Was sagen Stadtentwicklungspläne? Wie werden künftig Schulen geplant? Wie steht es um den Ausbau von Zufahrtsstraßen zu Schulen? Werden sich die Verkehrsflüsse langfristig ändern? Wie viel Schülerinnen und Schüler wird es künftig in Deutschland geben? Wie viele Unfälle ereignen sich vor Schulen? Ist die Zahl der Radunfälle gestiegen, gerade das berühmte Doorings, also dass Radfahrer gegen eine plötzlich geöffnete Autotüre rasen? Gibt es Tote? Steigt die Zahl der Toten? Gibt es Berichte über eine Zunahme von Unfällen? Gibt es Zusammenhänge zwischen Helikoptereltern und Unfällen vor

deutschen Grundschulen? Auf der anderen Seite: Was machen Eltern im ländlichen Raum? Der Weg zur Schule ist weit. Fahren sie auch ihre Kinder zum Unterricht? Gibt es ein Stadt-Land-Gefälle?

Riesiger Aufwand,
hohe Komplexität

Um Antworten zu finden, wären Umfragen denkbar. Zum Beispiel vor Schulen, um die konkrete Situation flächendeckend zu erfassen. Da es bundesweit jedoch über 30 000 allgemeinbildende Schulen gibt, ist der Aufwand sehr groß. Und die Zahl der Einflussfaktoren auf diesen Trend erscheint nach der ersten Recherche überwältigend.

Das Team entscheidet sich dafür, das Problem mithilfe eines AI-Modells anzugehen. Viele Daten im Zusammenhang mit Mobilität werden fast beiläufig zu jeder Minute erhoben. Unfälle mit Kindern werden der Polizei gemeldet, Versicherungen erfahren vom Schulwegeunfall, in sozialen Netzen werden Erlebnisse veröffentlicht, Zeitungen berichten über Unfälle.

Die Aufgabe, einen Beleg für die Hypothese zu finden, dass der Trend zum Elterntaxi zunehmend zur Gefahr für die Kinder wird, soll uns auf den folgenden Seiten begleiten.

Auf der Basis des auf den vorhergehenden Seiten vorgestellten AI Planners werden wir Schritt für Schritt ein AI-Konzept planen, das uns eine Antwort liefern soll. Am Ende kann das Experten-Team entscheiden: Ist der Trend relevant oder nur eingebildete Gefahr? Ist die wahre Ursache gefunden? Lohnt sich die Entwicklung einer Lösung?

Ein Beispiel
zum Üben


Wir werden jedes Element unseres AI Planners auf den folgenden Seiten erklären – und anhand des Schulbeispiels zeigen, wie die konkrete Anwendung funktioniert.

Beginnen wir mit dem ersten Schritt und klären die Zieldefinition. Wir werden zunächst den konkreten Mehrwert einer AI-Lösung ermitteln und unsere Aufgabe genau formulieren. Schließlich überlegen wir bereits, wie das Ergebnis eigentlich genau präsentiert werden soll.

Legen wir also los und steigen ein in die Welt der AI.

1. Ziel definieren

Houston, wir haben ein Problem



Die Frage
«Wie könnten wir ...?»
ist unser Startpunkt.

Auf viele Menschen in der Geschäftswelt üben neue Technologien und Managementtrends unwillkürlich eine gewisse Faszination aus. Wir erleben das bei jeder Welle, egal ob Outsourcing, E-Commerce oder Design Thinking. Die Gefahr, den Nutzen zu überschätzen, schwingt immer mit, das zeigt häufig die Zahl derer, die ihr Engagement einige Jahre später wieder relativieren. Das Forschungsgebiet Künstliche Intelligenz ist da keine Ausnahme.

Mit maschinellem Lernen steht uns heute ein wirkungsvolles Werkzeug zur Verfügung. Viele Anbieter von fertigen AI-Lösungen versprechen atemberaubende Erfolge. Die gibt es, allerdings müssen bestimmte Bedingungen erfüllt sein. Auch und gerade bei AI-Anwendungen gilt das GIGO-Prinzip: Garbage in, Garbage out. Ohne hochwertigen Input und gute Vorbereitung gibt es kein gutes Ergebnis.

Daher beginnen wir im ersten Teil unseres AI Planner dort, wo die meisten Projekte beginnen. Wir stehen vor einer Aufgabe und wissen noch nicht, wie wir sie lösen wollen. Es kann die Entwicklung eines Produkts sein oder einer von außen verordneten Herausforderung zum Beispiel das Einsparen von Kohlendioxid im Produktionsprozess im Kontext des Klimawandels. Ob und an welcher Stelle AI sich konkret für die Lösung unserer Aufgabe einsetzen lässt, wollen wir in diesem Abschnitt herausfinden. Die daraus resultierende typische Frage «Wie könnten wir ...?» stellen wir daher an den Anfang.

Mehrwert

Wir nehmen uns Zeit und analysieren, ob es hier an irgendeiner Stelle eine Teilaufgabe im Projekt gibt, die wie geschaffen für den Einsatz von Künstlicher Intelligenz ist, die uns einen Mehrwert verspricht. Eine AI-Lösung muss keine bahnbrechende Erfindung sein. AI-Systeme sind Software-Roboter: hochspezialisiert auf eine Aufgabe, die einmal gelernt, immer wieder abgearbeitet wird.

Challenge

Das Ergebnis dieser Analyse übernehmen wir, um daraus eine oder mehrere konkrete Herausforderungen abzuleiten. Eine Challenge, das kennen wir zum Beispiel aus dem Design Thinking, basiert immer auf dem Ziel, Nutzerbedürfnisse zu erkennen, daher befassen wir uns in diesem

Teil damit, zu verstehen, wer eigentlich genau unsere Zielgruppe ist – und welche Erwartungen an die Lösung gestellt werden.

Output

Das Ziel frühzeitig zu visualisieren, hilft uns, den Weg dahin besser zu verstehen.

Wir haben nun ein Problem definiert. Es ist klar umrissen, greifbar. Als letzten Teil der Zieldefinition machen wir uns Gedanken darüber, wie das Ergebnis konkret aussehen soll. Es gibt viele AI-Lösungen, die mittlerweile nahezu unerkannt in unserem Alltag arbeiten. Routenplaner weisen uns den optimalen Weg zum Ziel – hier ist das Ergebnis der AI eine Folge von geographischen Daten. Krebsdiagnostikprogramme geben die Wahrscheinlichkeit an, dass ein Röntgenbild einen Tumor anzeigt. Ein Bildbearbeitungsprogramm liefert verfremdete Fotos. Das Ziel frühzeitig zu visualisieren, hilft uns, den Weg dahin besser zu verstehen – und gegebenenfalls auch die Challenge noch einmal nachzubessern.

Grundsätzlich gilt wie in jedem Innovationsprozess: Die Abläufe sind nie statisch. Jeder kleine Schritt führt zu neuen Erkenntnissen. Jede Erkenntnis kann unsere Annahmen verändern und erfordert Anpassungen. Wann immer es nötig ist, gehen wir daher einen Schritt zurück und korrigieren unsere Überlegungen.


Und los gehts. Die erste Aktion wartet. Mehrwert analysieren, Challenge ausarbeiten, Output definieren. Dann ist der erste Teil des AI Planners abgeschlossen.



Iteration ist die Basis für Innovation. Wir haben keine Hemmungen, unsere eigenen Annahmen immer wieder infrage zu stellen, wenn neue Erkenntnisse das erfordern. Nur so vermeiden wir teure Fehltritte.

AI-Mehrwert

Die Grundlagen



Pain Points im Projekt sind mögliche Einsatzpunkte für AI.

AI Value Template

Bevor wir uns entscheiden, unseren definierten Innovationsauftrag mithilfe von AI zu lösen, sollten wir uns darüber im Klaren sein, ob der Einsatz dieser komplexen Technologie überhaupt gerechtfertigt ist.

Am einfachsten ist es, wenn wir uns vor Augen führen, wie wir in einem klassischen Projekt vorgehen würden. Wenn wir feststellen, dass wir beim Ziel, das wir anstreben, in der Umsetzung schnell an unsere Grenzen kommen würden, sollten wir über den Einsatz von AI nachdenken.

AI-Modelle in einem Innovationsprojekt einzusetzen lohnt sich immer dann, wenn einer oder mehrere der folgenden Faktoren im Projekt zutreffen:

Die Zeit im Verhältnis zur nötigen **Ergebnisqualität** ist knapp
Ein hoher **Personalanteil** ist nötig

Eine hohe **Wiederholbarkeit** ist wichtig

Echtzeitergebnisse sind erforderlich

Falls dies nicht der Fall ist, ist ein herkömmliches Vorgehen dem Einsatz von AI immer vorzuziehen, da wir auf bekannte Arbeitsweisen zurückgreifen können, die uns geläufig sind, auch wenn der Einsatz von Technologie uns persönlich reizen mag.

Um zu verstehen, wo in unserem Projekt der Einsatz von AI lohnend sein könnte, zerlegen wir es in seine Bestandteile. Das **AI Value Template** im folgenden Abschnitt hilft dabei, die einzelnen Arbeitsschritte zu strukturieren. Grundsätzlich geht es darum, das nötige Vorgehen zur Lösung des Auftrags zu durchdenken. Wollen wir die beste Idee aus einem Ideenwettbewerb für neue Produkte ermitteln, müssen wir uns erst klar werden, welche **Tätigkeiten und Entscheidungen** konkret nötig sind: eine Ideen-Challenge ausarbeiten, Bewertungen einholen, Ideen auswählen, einen Pitch durchführen. Zu jedem Schritt arbeiten wir heraus, wo genau die spezifischen Schwierigkeiten in der Umsetzung lauern, die **Pain Points**. Diese können ganz unterschiedlich ausfallen: Menschliche Voreingenommenheit (Bias), eine riesige Anzahl von Aufgaben oder Engpässe bei Personal oder Ressourcen. Diese Vorarbeiten liefern uns nun ein konkretes Bild unseres Projekts. Auf dieser Grundlage können wir prüfen, an welcher Stelle uns eine AI-Lösung konkreten **Mehrwert** liefern könnte.

Die Stärken des Menschen

- Unerwartete Stimuli wahrnehmen
- Neue Lösungen zu Problemen entwickeln
- Mit abstrakten Problemen umgehen
- Sich verändern können
- Beobachtungen generalisieren
- Aus Erfahrungen lernen
- Schwierige Entscheidungen bei unvollständiger Datenlage treffen

Die Stärken der Maschine

- Wiederholbare Aufgaben akkurat ausführen
- Große Mengen von Daten speichern
- Gespeicherte Daten zuverlässig wiederfinden
- Mehrere Aufgaben parallel ausführen
- Einfache und komplexe Berechnungen schnell durchführen
- Routineentscheidungen schnell treffen

Wir müssen nüchtern analysieren, inwieweit eine Automatisierung durch AI uns einen geschäftlichen Vorteil bringt. Das kann Zeitgewinn, niedrigere Kosten, höhere Qualität, ein zu erwartender besserer Absatz oder eine höhere Kundenzufriedenheit sein. Strategische Überlegungen klammern wir an dieser Stelle erst einmal bewusst aus – darüber machen wir uns am Ende des AI Planners Gedanken. Indizien, ob sich ein Mehrwert realisieren lässt, gibt der Abgleich mit den Kognitiven Stärken von Menschen und Maschinen (links oben und unten) und den bereits erwähnten Faktoren.

Der geschäftliche Mehrwert durch AI ist eine Hypothese. Er spiegelt unsere Erwartung wider, wie eine AI-Lösung unsere Arbeit verbessert. Er entscheidet, ob es sinnvoll ist, in maschinelles Lernen zu investieren. Im weiteren Verlauf des AI Planners wollen wir diese Hypothese überprüfen.

Wir machen die Erfahrung, dass es in komplexeren Projekten mehrere Arbeitsschritte geben kann, die sich mit AI bearbeiten lassen. Dann kombinieren wir sie zu einer gemeinsamen Challenge.

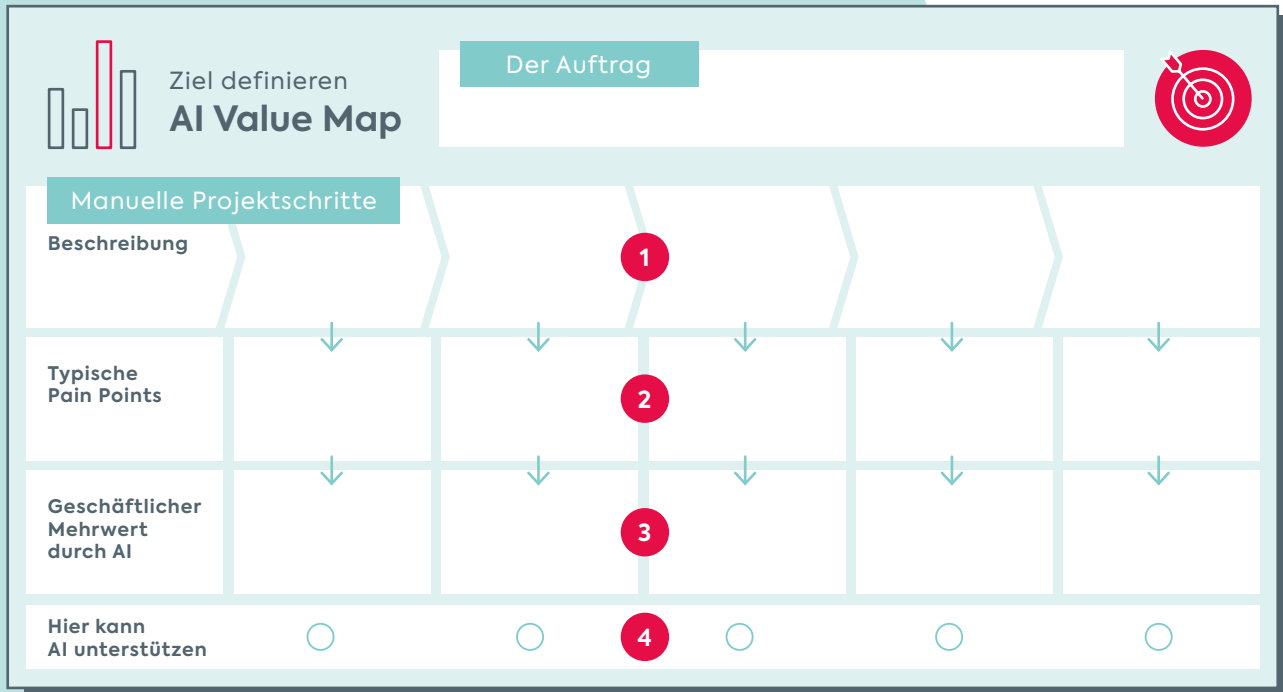
Wir illustrieren jeden Arbeitsschritt immer mit einem Beispiel. Am Anfang des Kapitels haben wir die Situation vor Schulen mit der Masse an Elterntaxis skizziert. Die Fragestellung, ob dieses Problem überall existiert – und ob es relevant ist – zieht sich als roter Faden durch das komplette Kapitel. Der **Auftrag** lautet also: Führt der Elterntaxi-Verkehr zu mehr Staus und Unfällen mit Kindern vor Schulen?

i

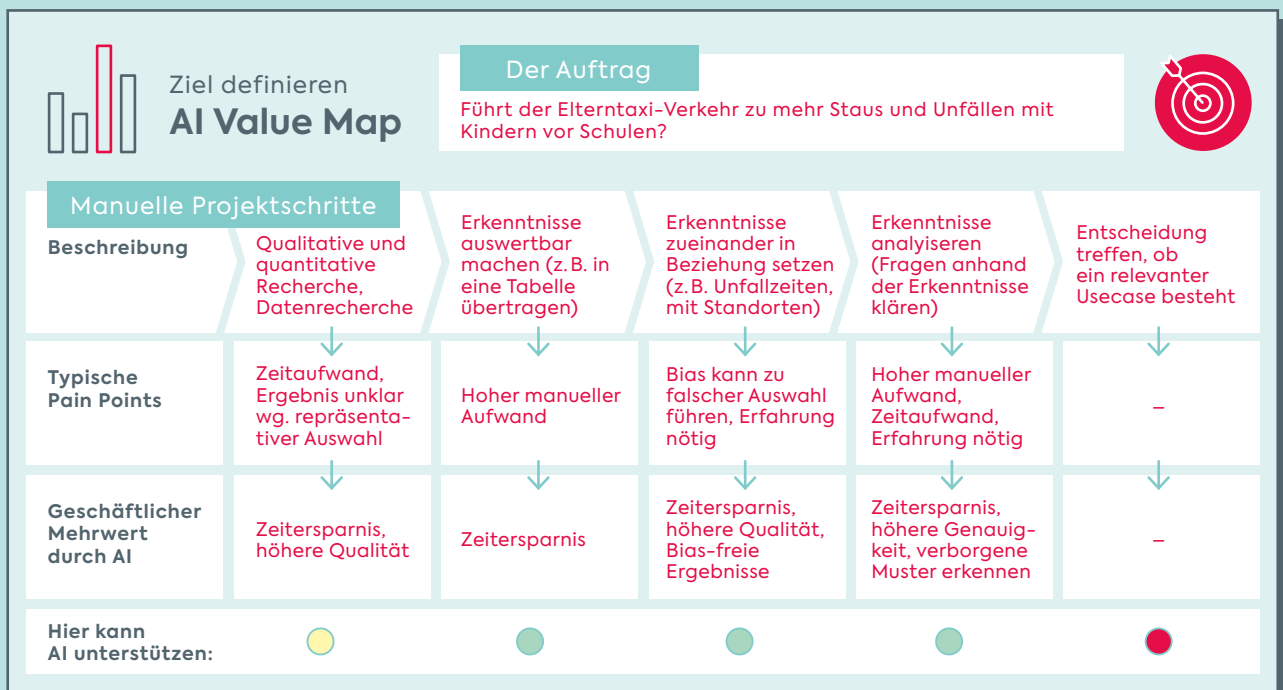
Keine Wunder in Sicht

Die AI-Fähigkeiten sollten stets nüchtern beurteilt werden. Einfache, klar umrissene Aufgaben eignen sich zu Beginn am besten: Ideen filtern, Daten analysieren, Muster erkennen. Wunder vollbringt aber auch eine AI nicht.

Template



Schulbeispiel



AI-Mehrwert

Das Tool

ZIEL DEFINIEREN

Schritt für Schritt

- 1 Wir dokumentieren alle Tätigkeiten und Entscheidungen, die in einem regulären Projekt gemäß unseres Auftrags nötig sind. Etablierte Verfahren, wie die Customer Journey oder Prozesspläne, können als Orientierung dienen.
- 2 Wir prüfen, welche typischen Schwierigkeiten im Rahmen unserer Projektbedingungen bei jedem Schritt auftreten können. Grundsätzlich müssen wir uns fragen: Wie ist das Verhältnis von Qualität der Ergebnisse und menschlichem Aufwand?

Können wir eine angemessene **Ergebnisqualität** im vorgegebenen Zeitraum liefern (kein Bias, große Datenbasis, vorhandene Erfahrung etc.)?

Bräuchten wir übermäßig viel **Personal**, um abliefern zu können?

Muss die Aufgabe über längere Zeit immer wieder durchgeführt werden, ist **die Wiederholbarkeit** wichtig?

Soll das Ergebnis in **Echtzeit** zur Verfügung stehen?


- 3 Wir überprüfen, auf welche Weise sich ein unternehmerischer Mehrwert ergibt, wenn das Problem automatisch mit Computerhilfe gelöst werden könnte: Spart uns das Zeit oder Geld? Erhöht es die Qualität? Sichert uns das mehr Käufer? Beeinflusst es die Kunden-/Nutzerzufriedenheit?
- 4 Im letzten Schritt diskutieren wir, wo uns im Projekt eine AI-Lösung helfen soll, und bewerten das Unterstützungspotenzial in den drei Ampelfarben Grün, Gelb und Rot, um unseren Auftrag im nächsten Schritt so konkret wie möglich fassen zu können.

Das Schulbeispiel

An dieser Abfolge lässt sich schnell erkennen, dass an vier Punkten eine AI-Lösung helfen könnte: die Analyse und Auswertung von Unfallzahlen und Verkehrsdichte vor Schulen sowie die Ableitung von Erkenntnissen aus diesen Daten.

Challenge

Die Grundlagen



**Ohne Fokus
sind Projekte
Zeitbomben.**

Zu Beginn eines jeden Projekts ist es wichtig, sich über das konkrete Ziel klar zu werden.

Das gilt besonders für gehypte Technologien, zu denen auch maschinelles Lernen gehört. Zu groß ist die Versuchung, alles technisch Mögliche umsetzen zu wollen. Wir erleben in Projekten immer wieder, wie Produkt- und Serviceideen mit allem vollgestopft werden, was technisch machbar ist und den Projektbeteiligten besonders gut gefällt. Egal, ob es sich um eine App handelt oder ein Konzept für ein Kundenservice-center. Gibt es keinen klaren Fokus, ufernt ein Entwicklungsprojekt aus. Legionen von gescheiterten Produkten zeugen von derartigem Vorgehen.

Der größte Fehler ist es, die genaue Zielgruppe und ihre Interessen nicht im Blick zu behalten. Ohne Fokus sind Projekte Zeitbomben. Wir widmen uns daher zu Beginn grundsätzlich zuerst der Frage: Warum machen wir das – und für wen?

Eine AI-Challenge besteht aus fünf Aspekten:

1. Die **Herausforderungen** beschreiben, was wir tun wollen. Sie leiten wir ab aus den Projektschritten, die wir anhand des AI-Mehrwerts bereits als besonders vielversprechend identifiziert haben.
2. Die **Zielgruppe** beschreibt, wer das Ergebnis der AI nutzt. Handelt es sich um potenzielle Käufer oder um interne Nutzer aus einer anderen Abteilung im Unternehmen?
3. Der **Geltungsbereich** definiert, wie weit unsere Aufgabe gefasst sein soll. Untersuchen wir einen geografischen Raum, wie alle deutschsprachigen Länder, bestimmte Online-Plattformen oder Branchen?
4. Der **Zeitrahmen** gibt an, wie schnell die Lösung gebraucht wird. Er entscheidet auch, wie stark der Zeitvorteil einer AI-Lösung ins Gewicht fällt.
5. Der **geschäftliche Mehrwert durch AI** zeigt, was wir uns an unternehmerischen Vorteilen erhoffen. Er leitet sich aus den Schritten des AI Value Template ab.

Die Nutzerperspektive

Die fünf Aspekte der Challenge sind deshalb so wichtig, weil sie uns zwingen, die Sicht der Nutzer von Anfang an einzunehmen. Einmal formuliert, geben uns diese Aspekte immer wieder die nötige Orientierung, um uns nicht von den eigenen Interessen und Vorlieben im Projekt ablenken zu lassen.

Empathie entwickeln

Dieses Vorgehen hilft in jedem Fall – unabhängig, ob eine AI im Spiel ist oder nicht. Diese Form der Empathie für die Bedürfnisse des Auftraggebers oder künftigen Käufers zu entwickeln, ist ein Schlüssel für jedes erfolgreiche Projekt. Sie ermöglicht es uns, auch Aspekte zu berücksichtigen, die uns selbst unwichtig erscheinen, den potenziellen Nutzern oder Auftraggebern aber sehr viel bedeuten.

Eine gut formulierte Challenge setzt einen Rahmen für die zu lösende Aufgabe und macht sie greifbar.



Das Ziel im Blick behalten

Eine konkrete Beschreibung des Auftrags ist wie ein gut sichtbarer Leuchtturm. Je konkreter und klarer sie formuliert ist, desto besser. Dann weist sie uns den Weg, selbst wenn wir unterwegs in schweres Wetter geraten sollten.

Template



Ziel definieren
Challenge Guide




Elemente			Zusammenfassung
Herausforderungen 1	Nutzer/Zielgruppe 2		6
Geltungsbereich/ Umfang 3	Zeitraumen 4	Geschäftlicher Mehrwert durch AI 5	

Schulbeispiel



Ziel definieren
Challenge Guide



Elemente			Zusammenfassung
Herausforderungen Erhebung, Analyse und Auswertung von Daten	Nutzer/Zielgruppe Kommunen und Schulen Kinder und Schüler		Führt der Elterntaxi-Verkehr zu mehr Staus und Unfällen mit Kindern vor Schulen? Eine dreimonatige, bundesweite AI-basierte Erhebung, Analyse und Auswertung von Daten soll Klarheit über die Problemlage verschaffen.
Geltungsbereich/ Umfang Bundesweit	Zeitraumen Projektdauer 3 Monate	Geschäftlicher Mehrwert durch AI Detaillierte bundesweite Recherche statt Stichproben	

Challenge

Das Tool

ZIEL DEFINIEREN

Schritt für Schritt

Eine gut formulierter Auftrag entsteht nicht aus heiterem Himmel. Wir nutzen dazu die folgenden Leitfragen.

1

Was sind die Herausforderungen?

Die Tätigkeiten und Entscheidungen, die in der Mehrwertanalyse als wichtig bestimmt wurden.

2

Wer sind die Hauptnutzer?

Geht es um Abteilungen innerhalb des Unternehmens? Einzelne Personen, wie der Bereichsleiter oder die Geschäftsführerin, oder Gruppen, wie bestimmte Teile der Belegschaft? Oder eher um externe Stakeholder, wie Kunden oder Zulieferer?

3

Wie sieht der ungefähre Umfang unseres Projekts aus?

Es macht einen Unterschied, ob Daten nur für eine Stadt oder sogar weltweit analysiert werden sollen. Je größer der Umfang, desto wahrscheinlicher ist es, dass eine AI-Lösung einen deutlichen Vorteil bietet.

4

Wie sieht die Projektdauer aus?

Hier geht es um zwei Themen: Einmal um den Zeitraum, der inhaltlich (zum Beispiel für die Analyse von Daten) relevant ist und um die Zeit, die für das Projekt zur Verfügung steht. Beide Aspekte sind nicht in jedem Projekt gleich wichtig. Diskutiert im Team, welche Angaben hier hervorgehoben werden sollen.

5

Wir übertragen den **geschäftlichen Mehrwert** (die Zeitersparnis, einen strategischen Vorteil, geringere Kosten, weniger Personaleinsatz, ein besseres Nutzungserlebnis etc.) aus dem AI Value Template.

6


Mit all den Detailinformationen, die wir gesammelt haben, können wir den **Auftrag ausformulieren**. Wir bilden aus unseren fünf Aspekten möglichst prägnante, kurze Sätze. So erhalten wir ein klares Zielbild – wie es im Schulbeispiel zu sehen ist.

Das Schulbeispiel

So kann anhand der fünf Challenge-Elemente die Fragestellung präzisiert werden.

Output

Die Grundlagen



**Wir brauchen ein Ziel.
Die Konkretisierung
verleiht unserer Suche
eine Richtung.**

Beispiele
für den Output

Wir haben nun eine konkrete Beschreibung unserer Aufgabe. Wir kennen Rahmenbedingungen und haben eine Vorstellung vom Mehrwert. Nun wollen wir noch eine Stufe konkreter werden. Wir malen uns aus, was uns als Ergebnis unserer Arbeit tatsächlich nützen würde.

Wir legen in diesem Schritt die grobe Form des Ergebnisses fest. Dabei gehen wir in zwei Stufen vor. Zunächst definieren wir, was mithilfe maschinellen Lernens eigentlich konkret gemacht werden soll. Dabei teilen wir die typischen Machine-Learning-Aufgaben grob in drei Kategorien ein:

Erkennen – zum Beispiel Motive in Bildern, Muster in Datensätzen.

Vorhersagen – Veränderungen, die künftig eintreten, wie menschliches Verhalten etwa beim Einkauf, natürliche Phänomene, wie das Wetter oder Eigenschaften von neuen Materialien.


Erzeugen – neue Designs, Texte, Produktkonzepte. Wir teilen Wünsche mit, die Maschine führt sie aus.

Im zweiten Schritt beschreiben wir, wie das Ergebnis konkret aussehen soll. Sind es neue Designs? Eine Rezeptur für ein Produkt? Ein Computercode für ein neues Programm? Eine Empfehlung für ein Vorgehen? Oder eine visuelle Karte mit Einträgen, eine Sprachausgabe für Texte? Die Möglichkeiten sind vielfältig und der Kreativität kaum Grenzen gesetzt.

Diese Konkretisierung hilft uns später bei der Suche nach Datentypen und den geeigneten Machine-Learning-Algorithmen. Wir klären unsere Vorstellung, wonach wir suchen und was aus dem Rohstoff Daten werden soll.

Auf der gegenüberliegenden Seite haben wir einige Beispiele aufgeführt, wie der Output aussehen könnte. Je nach Aufgabe kann das Ergebnis sehr unterschiedlich aussehen: angefangen von einfachen Listen, Heatmaps oder Datenbanken, über komplexe Grafiken, komplette Textberichte oder Animationen bis zu konkreten Designvorschlägen, komplett automatisch erstellten Berichten, technischen Zeichnungen oder Videosequenzen. Im Kapitel «Springen» gehen wir noch näher auf die Möglichkeiten ein, die Künstliche Intelligenz bietet.

Erkennen



Heatmaps
Krebs auf Röntgenbildern,
Surfverhalten auf Websites




Statistik-Charts
Kaufverhalten, Produktivitäts-
messungen, Immobilienpreise



Auslesbare Datenbanken
Wikis, CRM-Systeme,
Knowledge Graphs

Vorhersagen



Cluster Maps und -Grafiken
Trendmaps, Affinitätsdiagramme,
Visualisierung des Spritverbrauchs




Textberichte
Diagnoseberichte, Gesetzes-
texte, Finanzberichte




Animationen
Visualisierung des Wetters, Virus-
ausbreitung, Verkehrsdichte


Erzeugen



2-D-/3-D-Designvorschläge
Rezepturen, ressourcensparende
bionische Strukturen für Möbel





Video- und Soundsequenzen
Deepfakes, digitale Zwillinge,
Werbe- und Filmtrailer



Anweisungen für Anlagen
Energiemanagement,
Robotersteuerung

Template

 Ziel definieren
Output



Die Aktion

☐ Erkennen

☒ 1


☐ Vorhersagen

☐ Erzeugen

Das Format

2

Schulbeispiel

 Ziel definieren
Output



Die Aktion

☒ Erkennen

☐ Vorhersagen


☐ Erzeugen

Das Format

Interaktives Statistik-Chart
aller tatsächlichen Unfälle mit
Kindern zu relevanten Stoßzeiten
über den Verlauf von 5 Jahren


Häufigkeiten


Ursachen


Stoßzeiten

Output

Das Tool

1

Schritt für Schritt

Zunächst entscheiden wir, ob unsere AI-Lösung etwas **erkennen** soll (Objekte, Sprache, Bilder, Gesichter oder Ähnliches), etwas **vorhersagen** (zu erwartende Bestellungen, Trends, voraussichtliche Defekte einer Maschine) oder **selbst produktiv sein** soll (etwa eine Rezeptur, ein Design, ein Text oder eine Anweisung für eine Maschine).

2

Wir versetzen uns in die Lage der künftigen Nutzerin und überlegen, was sie mit der AI-Lösung zu erreichen versucht und wie sie mit dem Ergebnis arbeiten wird. Abhängig von dieser Überlegung suchen wir ein passendes Output-Format. Um unserer Vorstellung auf die Sprünge zu helfen, recherchieren wir, was es an sogenannten Use Cases für Künstliche Intelligenz bereits gibt. Ein möglicher Output könnte eine Heatmap sein, eine Audiodatei, eine Produktzusammensetzung wie in einem Rezeptbuch, eine Statistik (siehe Grafik auf Seite 59).

Das Ergebnis unserer Überlegungen beschreiben wir und visualisieren es in Form einer konkreten Skizze. Das hilft anderen Stakeholdern, die Gedanken schneller nachzuvollziehen.

Prima! Damit haben wir die erste Säule unseres AI-Projekts gemeistert. Wir haben das Ziel definiert.

Das Schulbeispiel

Bei unserer Recherche zu den Elterntaxis geht es um das Erkennen eines Musters. Wir wollen im Ergebnis unsere Hypothese belegen oder widerlegen. Uns interessieren die Tendenz und die Schlussfolgerung, ob mehr Unfälle vor Schulen stattfinden. Die Details der Daten sind dagegen zweitrangig.

Um die Berechnungen gut nachzuvollziehen und anderen präsentieren zu können, wählen wir die Darstellungsform einer interaktiven Statistik. Sie bietet die Möglichkeit, die einzelnen Aspekte wie Häufigkeiten im Zeitverlauf, Ursachen und Zeiten zu illustrieren. Das zeigt plastisch, ob es eine Notwendigkeit zum Handeln gibt – oder nicht.

2. Daten recherchieren

Quellen der Erkenntnis



Alles, was sich irgendwie digital erfassen lässt, eignet sich als Futter für maschinelles Lernen.

Daten sind das Lebenselixier lernender Systeme. Maschinen interpretieren die Welt mithilfe von Daten unterschiedlicher Art. Dabei müssen wir uns von der Vorstellung frei machen, dass es sich dabei nur um Zahlen und Tabelleneinträge handelt. Daten können auch Bilder, Videos, Musik oder Töne, Sprache und Geräusche sowie Gerüche sein. Sensoren, die den Luftraum überwachen, geben uns ebenso Hinweise wie Textdokumente, der Betrieb von Maschinen oder Bewegungsmuster von Menschen.

Um unseren Arbeitsauftrag im Computer abzubilden, müssen wir ihn in Form von Daten beschreiben. Wir müssen daher unser Problem so in seine Bestandteile zerlegen, dass sichtbar wird, welche Daten uns helfen können. Den ersten Schritt dazu haben wir bereits bei der Analyse des AI-Mehrwerts unternommen. Jetzt gehen wir mehr ins Detail. Manchmal ist das sehr einfach. Wer beschließt, dem Computer beizubringen, Texte vorzulesen, braucht einen schriftlichen Text und den gleichen Text als gesprochene Variante. Dann kann die Maschine lernen, den Text zu lesen.

Soll die Maschine vorhersagen, wann Flugzeugturbinen ausfallen, braucht sie die Betriebsdaten der Turbinen über viele Jahre, um die Ausfallmuster identifizieren zu können. Diese Suche gleicht häufig einem **Detektivspiel** und erfordert **Fachwissen** und entsprechende **Recherche**.

Damit ist die Recherche jedoch noch nicht zu Ende.

Daten prüfen

Daten haben Eigenschaften. Sie haben Besitzer. Sie haben eine Geschichte. Diese individuelle Datenpersönlichkeit kann den Einsatz für unser Projekt erleichtern oder erschweren. Daten können unvollständig sein, zu alt, sie können unter Verschluss sein, oder müssen erst noch anonymisiert werden, um den Regeln des Datenschutzes zu entsprechen. All dies muss systematisch geprüft werden. Wir werden daher nach der Datensuche jede einzelne Datenquelle überprüfen und eine Art Steckbrief anlegen. Dieses Dokument ist vergleichbar mit dem Preflight Check vor dem Start eines Flugzeugs oder einer Checkliste im Operationssaal – es hilft uns, die richtigen Fragen zu stellen und auf mögliche Hürden zu stoßen (siehe «Datenprüfung» auf Seite 72).

Der letzte Teil des Abschnitts «Daten recherchieren» besteht darin, eine logische Reihenfolge für die Verarbeitung zu erstellen – und eine Art Bericht für die Diskussion mit Stakeholdern, wie zum Beispiel Datenwissenschaftlern oder dem Management.

Data Journey visualisieren

Wir stellen unsere Ergebnisse bewusst visuell dar. Diese «Data Journey» listet auf einen Blick alle wesentlichen Faktoren auf. Ein Ampelsystem zu den einzelnen Datenquellen zeigt uns, wo potenzielle Gefahren für die Umsetzung unseres Projekts lauern. Die Arbeit mit diesem Dokument hilft uns auch, noch einmal kritisch zu hinterfragen, ob wir alle Faktoren berücksichtigt haben.


Nach Abschluss der Aktion «Daten recherchieren» stehen uns alle Informationen zur Verfügung, die wir als Grundlage für die weiteren Überlegungen und die Verarbeitung der Informationen durch unsere AI-Modelle benötigen. Die Templates, die wir hierfür ausgearbeitet haben, dienen als Dokumentation für die Gespräche mit Experten.



Daten haben Eigenschaften. Sie haben eine Geschichte. Sie haben Besitzer. Diese individuelle Datenpersönlichkeit kann den Einsatz für unser Projekt erleichtern oder erschweren.

Daten- quellen

Die Grundlagen



**Daten sind überall.
Selbst das Denken kann
visualisiert werden.**

Daten sind überall. Grundsätzlich kann heute alles, was wir als Mensch wahrnehmen und fühlen, in irgendeiner Form von Daten dargestellt werden. Nicht einmal Gedanken sind davon ausgenommen – Wissenschaftler arbeiten längst daran, anhand von Hirnströmen das menschliche Denken zu entschlüsseln.

Um zu überlegen, wo wir Daten finden können, beginnen wir am einfachsten mit unseren eigenen Sinnen. Anhand unseres Auftrags, den wir im ersten Abschnitt formuliert haben, überlegen wir, welche Handlungen für die Lösung notwendig sind. Geht es darum, Kundenbedürfnisse zu identifizieren, versetzen wir uns in die Lage der Kunden und denken darüber nach, wo diese Bedürfnisse sichtbar und beobachtbar werden.

Je nach Kontext stoßen wir hier auf unterschiedliche Möglichkeiten. Wir können Menschen beim Handeln beobachten. Wir können heute sogar an ihren öffentlichen Gesprächen teilnehmen. Zum Beispiel in Social Media, wo sie emotionale Highlights und Ärger mitteilen. Das ist eine Datenspur, die maschinell einfach zu erfassen ist.

Auf diese Weise erstellen wir eine Liste mit den Datentypen, die uns sinnvoll erscheinen. Wir gehen gezielt auf die Suche: Wo könnten passende Datentypen auch im eigenen Unternehmen zu finden sein, woher könnten sie extern stammen?

Das Data Directory

Um die Welt der Daten übersichtlicher zu machen, nutzen wir ein Verzeichnis als Inspirationsquelle. Es hilft dabei, sich bewusst zu machen, wo überall Daten versteckt sein können. Im Alltag nehmen wir das in der Regel kaum wahr. Aber es gibt inzwischen an den unterschiedlichsten Stellen nicht nur Kameras, sondern auch Sensoren, die ganz unterschiedliche Informationen dokumentieren. In Archiven lagern Millionen Dokumente, deren Inhalt Muster enthalten können. Datenbanken archivieren Zusammenhänge, die von Maschinen

ausgelesen werden können. Und auch Webseiten bieten Informationen, die sich vergleichsweise einfach auslesen lassen.

Die Vermessung der Welt

Das «Data Directory» (siehe die beiden folgenden Doppelseiten) enthält zwei Teile: Was Menschen produzieren, und was die Umwelt von Menschen prägt, in Anlehnung an die Arbeit von Kate Crawford und Vladan Joler in der Publikation «Anatomy of an AI System». Der Teil «Produktion» ist aufgeteilt in «Industrie und Gesellschaft» sowie «Geistige und kulturelle Güter» sowie entsprechende Subkategorien. Auf diese Weise können wir entlang der menschlichen Produktion nach Anregungen für Datentypen forschen. Das gleiche gilt für den Teil «Umwelt». Die Hauptkategorien hier lauten «Individuum» und «Gesellschaft». Auch hier können wir immer tiefer nach Inspiration für Datentypen suchen.

Da immer mehr digitalisiert und vernetzt wird, werden immer mehr Ergebnisse menschlichen Schaffens als Datensatz sichtbar. Das gilt sowohl für den privaten als auch für den beruflichen Bereich.

Das «Data Directory» ist natürlich kein vollständiges Verzeichnis. Es soll den Blick öffnen, auf die Vielfalt von Datenorten in der heutigen Welt. Es dient vor allem als Quelle der Inspiration: um auf neue Gedanken zu kommen, um neue Verknüpfungen zwischen Datenarten herzustellen und interessante neue Wege zu identifizieren, wie die Welt vermessen werden kann.



Der digitale Zwilling wird Wirklichkeit

Da immer mehr digitalisiert und vernetzt wird, werden immer mehr Ergebnisse menschlichen Schaffens als Datensatz sichtbar. Das gilt sowohl für den privaten als auch für den beruflichen Bereich.

Data Directory: Produktion

Menschen kreieren Daten in unterschiedlichen Bereichen. Beispiel Städte: Dort existieren Zeichnungen und Karten der Architekten und Behörden für Haus- und Städtebau. Wir erzeugen Wetterdaten und Messwerte. Auch im kulturellen Leben hinterlassen wir Daten in Form von Archiven, Webseiten und Tweets.

Was wir herstellen



Infrastruktur und Gesellschaft



Städte

- Architekturpläne und Karten
- Luftaufnahmen und Satellitenbilder
- CCTV-Systeme
- Sensoren (Luft, Lärm, Verkehr ...)
- Wetterdaten
- Radarbilder
- Statistik und Modelle

Wohnen

- Verbrauchszähler (z. B. Google Nest, Stromzähler)
- SmartHome-Systeme
- IoT-Geräte-Daten
- Systeme der inneren Sicherheit
- Marktwert und Hypothek

Versorgung

- Verbrauchsdaten zu Strom, Gas, Wasser etc. und Statistiken
- Karten zur Infrastruktur (Leitungen, Netze etc.)
- Daten zu Energieproduktion und Handel

Mobilität

- Verkehrspläne und Statistiken (z. B. U-Bahn)
- Navigationssysteme (GPS, Google Maps)
- Mautsysteme
- Autokennzeichen
- Ampeln, Verkehrszeichen
- Digitale Parkuhren
- Verkehrsüberwachung
- Echtzeit-Verkehrsdaten (z. B. Google Maps)

- Karten der Infrastruktur
- Sensoren und Kameras
- Echtzeit-Verkehrsdaten
- Anwendungen für Mobilität, wie Uber oder FreeNow
- Fahrkartenverkaufsstellen

Telekommunikation

- SIM-/IMEI-Nummern.
- Benutzer-Standortverfolgung
- Datenspeicherung (Anrufprotokolle, Metadaten)
- Sammlung von Inhalten (Anrufe, SMS, mobile Daten)
- Netzwerk-Karten
- IP-/MAC-Adressen

Geistige und kulturelle Güter



Traditionelle Medien

- Archive von Musik, Kunst und Fotografie
- Interne Nachrichten-Archive
- Datenbanken (z. B. Verzeichnis lieferbarer Bücher, Google-Books-Projekt)
- Anleitungen und DIY-Handbücher

Digitale Medien

- Digitale Bild-, Film und Videodienste
- Webseiten und Blogs
- Social Media
- Livestreaming
- Computerspiele
- Tracking (Käufe, Verhalten, Bewegung)
- 3-D-Druckmodelle

Internet-Dienste

- Benutzer-Profilung
- Verfolgung des Benutzerverhaltens
- Infrastruktur zur Web-Indizierung
- Seiten-Ranking
- Datenfluss-Messungen
- Infrastruktur zur Datenspeicherung

Sprache

- Sprachwissenschaftliche Forschung
- Datenbank für natürliche Sprache
- Sprachkorpora
- Werkzeuge und Techniken zur Verarbeitung natürlicher Sprache
- Programmieren von Sprachen

Wissenschaft

- Forschung und wissenschaftliche Arbeit
- Wissenschaftliche Veröffentlichungen
- Patente (SIPO, Espacenet)
- Vorlesungen, Vorträge (z. B. TED-Talks)

Bildung

- Lehrpläne, Bücher, Online-Kurse
- Vorträge, Workshops, Präsentationen
- Open Source Enzyklopädien (Wikis)
- Wissensaustausch (z. B. Quora)
- DIY-Handbücher (z. B. Instructables, Make)
- Buchhandel (online)

Data Directory: Umwelt

Der Mensch selbst und seine Umwelt sind ebenfalls sehr gut durch Daten beschreibbar. Die folgende Auswahl zeigt, wie vielfältig die Möglichkeiten sind, Verhalten und Eigenschaften von Mensch und Umwelt zu analysieren. Hier ist besonders die Einhaltung von Persönlichkeitsrechten wichtig. Anonymisierung ist Pflicht.



Der Körper

Physiologie

- Biometrie via Fingerabdruck, Handflächenvenen, Handgeometrie, Iris, Gangart, Gesicht
- Geruch

Verhalten

- Analyse körperlichen Ausdrucks wie Gangart, Mimik, Körpersprache
- Dynamik des Tastenanschlags

Gesundheit

- DNA
- äußerliche Messwerte wie Blutdruck, Herzfrequenz
- innere Werte wie Faktoren aus Blutuntersuchungen
- Bilder aus dem Körper durch Ultraschall, MRI, Röntgen
- Datenbanken für Krankheiten
- Bewegungsprotokolle durch Fitness-Tracker, SmartWatches
- Todesursachen durch Autopsiedaten und forensische Anthropologie
- Analyse historischer Aspekte menschlichen Lebens durch archäologische Werkzeuge und Methoden

Die Psyche

Methoden

- Standardisierte Tests und Umfragen
- Interviews und psychologische Profilerstellungstools

Bewegungsprofile

- Verhaltens-Tracking im Internet
- Auswertung digitaler Profile
- Aktivitäts- und Standortverfolgung
- Sport- und freizeitbezogene Tracking-Tools

Alltagsdaten

- Fahrtenbücher (U-Bahn-Karten, Flugticketsysteme ...)
- Aufzeichnungen über Schulnoten
- Aufzeichnungen zur Sozialversicherung
- Individuelle Kreditgeschichte
- Schulden
- Kreditwürdigkeit und Geschichte
- Zahlungsverhalten

Was uns ausmacht



Gesellschaft



Staatliche Institutionen

- Akten der Strafverfolgung
- Führungszeugnis
- Geburts- und Sterbeurkunden
- Familienregister
- Bevölkerungsstatistiken
- Führerschein und Kfz-Register
- Unternehmensregister
- Statistiken der diversen Behörden und Dienste
- Wahlen, Referenden

Soziales Verhalten

- Kommunikationsinhalte und Metadaten
- Nutzungsdaten in sozialen Netzwerken und Online-Plattformen
- Bewertungssysteme (eBay, Airbnb, Amazon, Youtube ...)
- Interaktionen auf Internet-Plattformen

Wirtschaft und Finanzen

Arbeitsdaten

- Tracking, Verhaltensanalyse, RFID-Etiketten ...)
- Dokumente (Verträge, Löhne, Lebensläufe, HR-Aufzeichnungen).
- Produktivitäts- und Kollaborationswerkzeuge

Interne Unternehmensdaten

- Buchhaltung, Marktanteile, Geschäftsprozesse, Kundendaten, Produktionsoutput, Lieferkette

Wirtschaftsdaten

- Nationaleinkommen, BIP, Arbeitslosenquoten, Staatshaushalte


Individuelle Finanzen

- Einkommen, Schulden, Zahlungsverhalten

Währung


- Nationale Währungs- und Wechselkurse, Kryptowährungen, Ingame-Währungen

Template




Daten recherchieren

Datenquellen




A <div>Datentyp</div> <div>1</div> <div>Warum?</div> <div>2</div>	<div>Datenquelle</div> <div>3</div>	B <div>Datentyp</div> <div>Warum?</div>	<div>Datenquelle</div>
C <div>Datentyp</div> <div>Warum?</div>	<div>Datenquelle</div>	D <div>Datentyp</div> <div>Warum?</div>	<div>Datenquelle</div>

Schulbeispiel



Daten recherchieren

Datenquellen



A <div>Datentyp</div> <div>Schulstandorte</div> <div>Warum?</div> <div>Ohne Standort, keine Beziehung zu Verkehr möglich.</div>	<div>Datenquelle</div> <div>Google Maps</div> <div>govdata.de – (Standorte öffentlicher Schulen).</div>	B <div>Datentyp</div> <div>Verkehrsdichte</div> <div>Warum?</div> <div>Zeigt, ob und wann es an Schulen mehr Verkehr gibt.</div>	<div>Datenquelle</div> <div>Google Maps Traffic Layer</div> <div>TomTom – Move APIs</div>
C <div>Datentyp</div> <div>Unfallstatistik</div> <div>Warum?</div> <div>Belegt, ob es eine Gefährdung gibt oder nicht.</div>	<div>Datenquelle</div> <div>Schüler-Unfallversicherung</div> <div>Statistisches Bundesamt</div> <div>Soziale Netzwerke</div>	D <div>Datentyp</div> <div>Warum?</div>	<div>Datenquelle</div>

Daten- quellen

Das Tool

Schritt für Schritt

1

Ausgehend von unserem formulierten Auftrag überlegen wir, welche Datentypen uns Aufschluss über zu analysierende Muster, Verhaltensweisen, Eigenschaften, Verknüpfungen geben können.

Im «Data Directory» (siehe Seite 66–69) gibt es zahlreiche Hinweise zu möglichen Datenspuren. Indem wir den Ästen folgen, kommen wir auf weitere Ideen, wo wir suchen können. Unsere Erfahrung zeigt: Man muss nicht immer alle Daten vollständig erheben, sondern sollte mit einem Grundstock anfangen, der einfach zu erlangen ist und schnell Ergebnisse liefert. Häufig besitzt auch die eigene Organisation Daten, die sich für die Analyse eignen. Das kann das ERP-System, die Kundendatenbank oder Betriebsdaten von Produkten sein. Neben dem «Data Directory» gibt es noch viele andere Verzeichnisse zu offen zugänglichen Datensätzen, wie GovData, das Datenportal der Bundesrepublik.

2

Jeden Datentyp notieren wir im Template und begründen, warum er für die Aufgabe nötig ist.

3

Wir suchen die passenden Quellen für unsere Datentypen. Es gibt international zahlreiche offen zugängliche Datensätze unter dem Stichwort Open Data.

Das Schulbeispiel

Welche Daten könnten die Bewegung von Autos zur Schule darstellen? Wie können wir eine Beziehung zu möglichen Unfällen herstellen? Wir haben exemplarisch drei Datentypen und mögliche Quellen eingetragen:

Schulstandorte – in öffentlichen Datenbanken erhältlich


Verkehrsdichte – durch Google Maps Traffic Layer, in dem die Bewegung von Handys ausgewertet wird

Unfallzahlen – wie sie von Versicherungen und der Polizei erfasst werden

Die Begründung zeigt, welche Erkenntnis wir erwarten und in welcher Beziehung die Daten untereinander stehen.

Daten- prüfung

Die Grundlagen



**Wir vertrauen Daten
niemals ohne genaue
Analyse.**

Datenquellen sind eine Seite der Medaille. Ob die Daten sich sinnvoll verarbeiten lassen, ist die andere Seite. Damit Programmierer mit den Daten arbeiten können, müssen sie bestimmte Voraussetzungen an Datenformate erfüllen. Wieder andere Daten müssen erst anonymisiert werden. Manche Daten sind öffentlich zugänglich, andere lagern hinter verschlossenen Türen. Um zu prüfen, welche Bedingungen unsere Daten erfüllen, unterziehen wir sie einem ausgiebigen Test, dem Data Check.

Die ausgefüllte Data Checklist ist unser Steckbrief, mit dem wir weiterarbeiten können. Sie liefert uns Hinweise auf den Arbeitsaufwand und verschafft uns ein tieferes Verständnis für die Daten, mit denen wir hantieren. Wer lernen, sie genauer zu definieren, einzuordnen und zu bewerten. Dieses Wissen hilft uns, zu entscheiden, ob wir mit unserem Traum vom digitalen Helfer weiterkommen oder nicht. Und die Data Checklist liefert die Grundlage für die Zusammenarbeit mit AI-Experten.

Die Data Checklist berücksichtigt die wichtigsten Faktoren, die für das Verwenden von Daten in einem Machine-Learning-Projekt notwendig sind. Diese sind nach Priorität sortiert. Wir beginnen mit der Frage nach dem Zugang: Können wir die Daten nicht bekommen oder sprengt der Preis für die Nutzung unser Budget, brauchen wir diese Spur nicht weiterzuverfolgen und können uns Alternativen zuwenden. Wenn die Daten zu alt sind, sind sie für das Projekt wahrscheinlich wertlos.

Basisinformation

Die Basisinformation benennt eher formale Aspekte, wie **Eigentümer**, **Zugang** zu den Daten und **Kosten**. Wir prüfen, ob die Daten unter die Kategorie der Open Data Definition fallen – diese Daten sind für alle frei zugänglich – oder ob sie einer Organisation gehören, wie zum Beispiel die Bewegungsdaten von Handys, die Fitnessdaten von Garmin oder die Betriebsdaten der Flugzeugturbinen von General Electric. Bei privaten Daten stellt sich die Frage nach dem Zugang. Darf ich sie nutzen und für geschäftliche Zwecke verarbeiten? Gehören die Daten Unternehmen, ist es sehr wahrscheinlich, dass die Nutzung Geld oder eine andere Form der Gegenleistung kostet. Das dokumentieren wir in der Rubrik «Kosten».

Das Erstellen von Trainingsdatensätzen kann die Projektdauer stark in die Länge ziehen.

Datenqualität

Für eine Bewertung der Datenqualität untersuchen wir, ob die Daten **aktuell** genug für unsere Zwecke sind. Wir betrachten, in welchem **Format** (als Excel-Tabelle, als Datenbank-Format, als Bildformat etc.) die Datensätze vorliegen. Handelt es sich um sogenannte strukturierte Daten (siehe Kapitel «Briefing»), wie sie in Tabellen und relationalen Datenbanken vorkommen, oder um unstrukturierte Daten, wie zum Beispiel eine Sammlung von Patentschriften oder Social Media Posts. Schließlich prüfen wir, ob ihr **Zustand** unseren Ansprüchen genügt – oder zusätzlichen Arbeitsaufwand erfordert.

Beim Thema Zustand steckt der Teufel im Detail. Damit ein ML-Programm lernen kann, benötigt es Trainings-Datensätze zum Erlernen von Regeln und Mustern. Sollen Äpfel auf Fotos erkannt werden, braucht das Programm Bilder mit Äpfeln, die den eindeutigen Hinweis «Apfel» enthalten. Um Krebs zu erkennen, müssen Röntgenbilder inklusive Diagnose vorliegen. Erst wenn der Algorithmus diese Verbindung gelernt hat, ist er in der Lage, autark Diagnosen zu beliebigen Röntgenbildern von Tumorverdachtsfällen zu erstellen. Die Daten müssen also so aufbereitet sein, dass die Maschine sie lesen kann. Ist die Datenqualität zu schlecht, drohen falsche Ergebnisse. Datenwissenschaftler helfen bei der Einschätzung und Bewertung.

Bewertung

Abschließend bewerten wir Datenquellen. Welche **Bedeutung** haben sie für unsere AI-Challenge? Wie einfach ist die **Beschaffung**? Und wie hoch schätzen wir den **Aufwand**, um die Daten technisch zu nutzbar zu machen?




Gute Daten, leichtes Training

Inzwischen gibt es Tausende fertig aufbereitete Datensätze mit Milliarden Daten im Internet. Einige als Open Source, andere mit Lizenzgebühr. Die Nutzung spart unter Umständen viel Zeit beim Training der Modelle.

Template



Daten recherchieren Data Checklist



Datentyp

Warum?

Die Basisinformationen

1

Datenquelle

Alternative Datenquelle

EIGENTÜMER

Wer besitzt sie und die Rechte an ihnen?
Welche Stakeholder sind involviert?

ZUGANG

Wo befinden sie sich?
Wie ist der Zugang geregelt?
Wie lassen sie sich nutzen?

KOSTEN

Welche Kosten fallen an?

Datenqualität

2

AKTUALITÄT

Wie aktuell sind sie?
Wie häufig werden sie aktualisiert?
Wie oft muss ich darauf zugreifen?

FORMAT

Wie liegen sie vor?
Welche Felder liegen vor?

ZUSTAND

Für Aufgabe und Training vorbereitet?
Datensätze (Aufgabe/Training) komplett?
Wie eindeutig sind sie?
Wie groß ist die Datenmenge?
Wie repräsentativ sind sie?

Bewertung

3

Priorität

Beschaffungsaufwand

Technischer Aufwand



hoch



mittel



niedrig

Daten- prüfung

Das Tool

Die Bewertung zeigt, ob wir die Daten für unsere AI-Modelle nutzen können.

Schritt für Schritt

1

Wir nehmen die erste Datenquelle und recherchieren zunächst die Basisinformationen: Eigentümer, Zugang und Kosten. Wichtig sind zum Beispiel Fragen nach Schnittstellen (APIs), Maschinenlesbarkeit und Bezahlmodellen. Manche Anbieter verlangen Geld pro Abruf, andere für die Zahl der Datensätze. Gibt es mehrere Anbieter für dieselben Datenquellen, bewerten wir auch diese. So können wir später abwägen, welche Quelle wir verwenden möchten.

2

Wir überprüfen Aktualität, Format und Zustand unserer Datensätze und vergleichen alles mit dem AI-Auftrag. Ist das Alter relevant, müssen es Echtzeitdaten sein? Liegen Daten noch analog vor? Sind alle Datensätze beschriftet? Eignen sie sich als Trainingsdaten oder müssen diese erst erstellt werden?

3

Schließlich bewerten wir Priorität und Aufwand für die Nutzung nach folgendem Bewertungsschlüssel:

Priorität ...

... **hoch**: ohne Datensatz kein Projekt

... **mittel**: Challenge ohne diese Daten nur bedingt umsetzbar

... **niedrig**: Datensatz nicht essenziell, «Nice to have»

Beschaffungsaufwand ... (Zeit, Geld, Bandbreite, Überzeugungsarbeit («Premiumdaten»), Stakeholdereinbindung)

... **hoch**: viele Personen involviert, hohe Sicherheitsstandards, hohe Kosten, lange Dauer

... **mittel**: alles, was dazwischen ist

... **niedrig**: frei verfügbare, kostenlose Daten

Technischer Aufwand ...

... **hoch**: keine APIs zum Datenaustausch, Bereinigung großer Datenmengen in unterschiedlichen Versionen

... **mittel**: Daten nicht absolut eindeutig, müssen nachgearbeitet werden

... **niedrig**: Daten sind fertig aufbereitet und liegen in einem Data Warehouse (siehe «Sicher landen – Daten richtig nutzen» auf Seite 258)

Nun fahren wir mit der nächsten Datenquelle fort.

In der Regel benötigen wir nicht mehr als eine Handvoll unterschiedlicher Quellen.

Schulbeispiel



Daten recherchieren Data Checklist



Datentyp

Verkehrsdichte

Warum?

Ermittlung der Verkehrsdichte zur Verknüpfung mit Schulstandorten und Unfalldaten

Die Basisinformationen

1

EIGENTÜMER

Wer besitzt sie und die Rechte an ihnen?
Welche Stakeholder sind involviert?

Datenquelle

Open Transport Map

Open Database License

–

Alternative Datenquelle

Google Maps Traffic Layer

Google Maps

–

ZUGANG

Wo befinden sie sich?
Wie ist der Zugang geregelt?
Wie lassen sie sich nutzen?

2

Extern
Öffentlicher Zugang
Öffentliche Web API

Extern
Bezahlung (Menge API-Zugriffe)
Web API

KOSTEN

Welche Kosten fallen an?

–

200 US-Dollar Guthaben, danach
17 US-Dollar pro 1000 Ortssuchen

Datenqualität

AKTUALITÄT

Wie aktuell sind sie?
Wie häufig werden sie aktualisiert?
Wie oft muss ich darauf zugreifen?

3

Stand: September 2020
Aktualisierung wöchentlich
einmalig

Stand: Echtzeit
25 Mio. Aktualisierung/Tag
einmalig

FORMAT

Wie liegen sie vor?
Welche Felder liegen vor?

4

Strukturiert (Kartendaten)
GPS Koordinaten, Tags (Schule ...)

Strukturiert (Kartendaten)
GPS Koordinaten, Tags (Schule ...)

ZUSTAND

Für Aufgabe und Training vorbereitet?
Datensätze (Aufgabe/Training) komplett?
Wie eindeutig sind sie?
Wie groß ist die Datenmenge?
Wie repräsentativ sind sie?

5

Ja, Kategorie «Schule» existiert
Ja, da alle Schulen vermerkt
Wir gehen von Eindeutigkeit aus
Karte DE, inkl. Schulen, 5GB lokal
Repräsentativ

Ja, Kategorie «Schule» existiert.
Ja, da alle Schulen vermerkt
Wir gehen von Eindeutigkeit aus
Online Adressentabelle, 500 KB
Repräsentativ

Bewertung

6

Priorität



Beschaffungsaufwand



Technischer Aufwand



hoch



mittel



niedrig


**Die abschließende
Bewertung ergibt
grünes Licht für die
Verarbeitung.**

Das Schulbeispiel

- 1 Für unsere AI-Aufgabe «Elterntaxi» suchen wir Informationen darüber, wie Eltern ihre Kinder mit dem Auto zur Schule fahren. Wir haben dazu Verkehrsdaten als einen möglichen Datentyp ausgewählt und entsprechende Datenquellen identifiziert. Wie wir bei der Datenprüfung vorgehen, zeigt das Template links am Beispiel der Mobilitätsdaten von Google Traffic und TomTom Traffic Flow Service.
- 2 Eine einfache Recherche zeigt, dass der Zugang zu Googles Kartendaten grundsätzlich möglich ist, für Gelegenheitsnutzer sogar gratis. Eine Schnittstelle definiert den technischen Zugang zu den Daten, eine kommerzielle Nutzung ab einem bestimmten Umfang kostet Geld pro Aufruf der Datensätze.
- 3 Die tiefergehende Recherche legt offen, dass die Daten öfter aktualisiert werden als mein AI-Auftrag es erfordert. Kein Problem also mit der Aktualität.
- 4 Das Datenformat ist maschinenlesbar und enthält zahlreiche Informationsfelder, wie Zeit, Geodaten, Anzahl der Fahrzeuge und vieles mehr.
- 5 Der Zustand ist für unsere Zwecke ausreichend: Die Daten sind umfassend bezeichnet und liegen in hoher Anzahl vor. Sie decken das gesamte Bundesgebiet ab und können als repräsentativ betrachtet werden, weil täglich die Informationen von mehreren Millionen Nutzern einfließen.
- 6 Die abschließende Bewertung ergibt grünes Licht für die Verarbeitung. Das ist gut, denn dieser Datentyp ist entscheidend für den Erfolg unserer AI Challenge.

Daten- erhebung

Die Grundlagen



Ordnung schaffen

Daten liefern erst dann ein Ergebnis, wenn sie miteinander sinnvoll in Beziehung gesetzt werden.

Die Daten sind geprüft, wir haben im einfachsten Fall einen Datentyp mit mehreren möglichen Quellen. Das ist zum Beispiel der Fall, wenn wir auf Bildern ein bestimmtes Motiv erkennen wollen. Der Datentyp sind Fotos mit dem gekennzeichneten Motiv. Nach dem Training können die Fotos aus beliebigen Quellen kommen. Der Datentyp bleibt jedoch gleich. Bei komplexen Themen sind es in der Regel mehrere Datentypen, die miteinander in Beziehung gesetzt werden müssen. Wir zeigen im Kapitel, «Springen» zum Beispiel, wie mithilfe des AI Planners eine Persona automatisch erstellt werden kann. Sie ist im Innovationsprozess eine Stellvertreterin für eine bestimmte Gruppe von Kunden. Dazu benötigen wir eine Reihe unterschiedlicher Datentypen, die uns ein Abbild von Bedürfnissen, Eigenschaften und Aussagen liefert.

Wir bringen daher Ordnung in den Ablauf. Die Daten müssen sortiert werden. Jeder Datentyp hat eine Funktion bei den Bemühungen, unseren AI-Auftrag zu erfüllen. Diese Funktion haben wir bereits im Template bei der Auswahl der Datentypen dokumentiert. Wir wollen mit dem nächsten Template die Beziehung der Daten zueinander sichtbar machen. Diesen logischen Zusammenhang stellen wir in der «Data Journey Map» dar.

Das Bild einer Reise hat dabei viele Vorzüge. Wir sehen Informationen in einer linearen Abfolge, wissen also, was nach bestimmten Aktionen als Nächstes geschieht und welche Daten im Prozess zuerst erhoben werden müssen.

Im Unternehmenskontext gibt es zahlreiche Journey-Map-Typen. Die Customer Journey ist die bekannteste. Sie skizziert die Reise eines Kunden entlang der gesamten Produkt- und Service-Erfahrung: vom ersten Kontakt mit der Marke, über Gespräche mit Freunden, der Information mithilfe von Verkaufsbroschüren, bis zu den Kontakten mit Verkäuferinnen. Es geht weiter mit dem Testen der Ware bis zum Kauf und im schlimmsten Fall mit der Reklamation, falls das Produkt fehlerhaft sein sollte.

Die Journey Map wird auch verwendet, um Personalprozesse zu verbessern – hier betrachtet man die Reise von Bewerbern über das Gespräch mit der Personalabteilung bis zum Vertragsabschluss.

Die Data Journey Map ist das Abschlussdokument unserer Datenrecherche. Dieses Template hilft uns, die bisher gefundenen Informationen übersichtlich so darzustellen, dass uns etwaige Schwachstellen sofort auffallen. Daher tragen wir dort Informationen aus drei Bereichen ein:

1. Der **Grund**, warum ein bestimmter Datentyp notwendig ist, sowie das Ergebnis, das die Maschine daraus ableiten oder erarbeiten soll;
2. Der **Datentyp** und die ausgewählte Primärquelle;
3. Die **Priorität** des Datentyps und der ermittelte **Aufwand** für die Beschaffung der Daten und die technische Aufbereitung (die gerade für das Training einen großen Anteil an der benötigten Zeit haben kann).

Swimlanes nutzen

Wir ordnen die Informationen in sogenannten Swimlanes an und setzen sie auf diese Weise miteinander in Beziehung. So werden AI-Auftrag, unsere Argumente, Datentypen und -quellen, ihre Reihenfolge und Problempunkte visualisiert und ein Gesamtkontext hergestellt.

Das Beispiel auf den folgenden Seiten zeigt, wie das funktioniert und wie wir mit diesem Dokument eine Grundlage für das Gespräch mit Datenexperten und anderen Stakeholdern herstellen.



Schwäche zeigen, ist wahre Stärke

Innovation ist kein starrer Ablauf, sondern ein iterativer Prozess. Wenn wir jetzt Schwächen aufdecken, ersparen wir uns später teure Korrekturarbeiten. Spätestens am Ende jeder Aktion im AI Planner sollten wir prüfen, ob der eingeschlagene Weg noch stimmig ist.

Daten- erhebung

Das Tool

Schritt für Schritt

- 1 Den Arbeitsauftrag und die im Challenge Template dokumentierte Zusammenfassung übertragen.
- 2 Die Argumente, warum wir unseren Datentyp ausgewählt haben, in eine logische Reihenfolge bringen (Was muss ich als Erstes wissen, was als Zweites?). Diese Informationen entnehmen wir den «Data Checklists» für die Datenquellen.
- 3 Welches Ergebnis erwarten wir vom AI-Modell? Diese Information hilft uns, später die AI Skills auszuwählen.

Template



Daten recherchieren Data Journey Map

Auftrag

Wie lautet der Auftrag?

1

Grund für die Datensammlung

Warum brauche ich diese Daten?

2

Was soll die Maschine daraus ableiten oder erarbeiten?

3

Datentyp

Welche Datentypen brauche ich?

4

Was ist die Datenquelle?

5

Prioritäten und Aufwände

Priorität

6

Beschaffungsaufwand

Technischer Aufwand

DATEN RECHERCHIEREN

- 4 Die Datentypen den jeweiligen Argumenten zuordnen.
- 5 Die Datenquellen eintragen. Wir nehmen dazu jeweils die wichtigste Datenquelle. Wir können, falls es in der Bewertung kritische Punkte gibt, auch die Alternative eintragen.
- 6 Für jede Datenquelle fügen wir die Priorität, den Beschaffungs- und den technischen Aufwand aus der «Data Checklist» hinzu und kennzeichnen sie entsprechend ihrer Bewertung.

Wir erkennen nun auf einen Blick, wo Schwierigkeiten zu erwarten sind (siehe Beispiel nächste Seite).

[illegible]

Das Schulbeispiel

Das Schulbeispiel zeigt, wie unser Abschlussdokument aus der Datenrecherche aussehen kann.

- 1 Auftrag und Challenge erinnern uns, in welchem Rahmen wir uns bewegen und welches Ziel wir vor Augen haben.
- 2 Die Daten stehen nun im Kontext zu den Argumenten für ihren Einsatz, wir wissen, welche Ergebnisse zu erwarten sind und wo die Datensätze zu finden sind.

Schulbeispiel



Daten recherchieren Data Journey Map

Auftrag

Wie lautet der Auftrag?

Findet heraus, ob der Elterntaxi-Verkehr zu mehr Staus und Unfällen mit Kindern vor Schulen führt

1

Grund für die Datensammlung

Warum brauche ich diese Daten?

Ohne Standort, keine Beziehung zu Verkehr und Unfällen möglich

Überprüfung, ob es zu Schulzeiten tatsächlich ein erhöhtes Verkehrsaufkommen gibt

Was soll die Maschine daraus ableiten oder erarbeiten?

Definition Schulstandorte (Städte ab 75 000 Einwohner)

Identifikation von Stau zu Schulöffnungs- und Schließzeiten vor Schulen

Datenytyp

2

Welche Datentypen brauche ich?

Standortdaten von Schulen

Historische Staudaten mit Uhrzeiten im Umkreis von Schulen

Verkehrsdichte

Was ist die Datenquelle?

Govdata.de

TomTom – Move API (O/D Analysis)

Google Maps. Traffic Layer

Prioritäten und Aufwände

Priorität



Beschaffungsaufwand



Technischer Aufwand



3

Vor allem aber fällt sofort auf, dass es bei der Auswertung der Krankenhausberichte und Unfallberichte große Schwierigkeiten gibt.

Hier müssen wir mit unserem Team und gegebenenfalls externen Experten überlegen, wie wir die Probleme beseitigen könnten oder kreativ an Lösungen arbeiten. Entweder finden wir alternative Datenquellen oder einen grundsätzlich anderen Weg der Datenanalyse.

Prioritäten und Aufwände



hoch



mittel



niedrig

101
011

Challenge

Welche Challenge resultiert daraus?

Führt der Elterntaxi-Verkehr zu mehr Staus und Unfällen mit Kindern vor Schulen? Eine dreimonatige, bundesweite AI-basierte Erhebung, Analyse und Auswertung von Daten soll Klarheit über die Problemlage verschaffen

Überprüfung, ob erhöhtes Verkehrsaufkommen zu vermehrten Unfällen vor Schulen führt

Korrelieren von Verkehrsdichte und Unfallzahlen

Unfallstatistiken
(der letzten 5 Jahre)

Unfallberichte
der Polizei (der
letzten 5 Jahre)

Krankenhausberichte
(der letzten 5 Jahre)

Online-Lokalnach-
richtenmeldungen
über Unfälle

Schüler-
Unfallversicherung.
Stat. Bundesamt

Unfalldatenbank
der Polizei


Datenbanken
einzelner Kliniken

Diverse

3

3. Lern- konzept erstellen

Die Algorithmen



Wir werden nicht müde zu betonen, dass die Programme aus dem Bereich Künstliche Intelligenz nur fleißig sind, aber nicht intelligent.

Im dritten Schritt «Lernkonzept erstellen» schlägt das Herz des Machine-Learning-Projekts. Hier wird festgelegt, wie aus Daten Erkenntnisse werden. Dazu müssen wir uns mit zwei Aspekten des maschinellen Lernens auseinandersetzen. Was muss die Maschine können? Und wie soll die Maschine trainiert werden? Die Antwort auf diese beiden Fragen beeinflusst maßgeblich den Aufwand des AI-Projekts. Daher haben wir dieses Kapitel in die zwei Teile «Maschinenfähigkeiten» und «Trainingsparameter» unterteilt.

Maschinenfähigkeiten sind im übertragenen Sinn die lernfähigen Algorithmen. Sie lassen sich gut mit den menschlichen Fähigkeiten beschreiben, auch wenn jegliche menschliche Begleiterscheinung, wie Intuition, Absicht, echtes Verständnis, fehlen. Es gibt inzwischen eine ganze Reihe von fertigen Algorithmen oder sogar trainierten Modellen, die im Grunde vergleichbar sind mit Designvorlagen in Word. Für einen bestimmten Zweck können sie als Vorlage dienen und müssen nur noch auf die eigenen Wünsche angepasst werden. Das ist sehr praktisch und vereinfacht die Arbeit ungemein. In vielen Bereichen sind diese Modelle so weit fortgeschritten, dass die Anwender überhaupt keine Fachkenntnisse im Umgang mit Programmiersprachen mehr benötigen, «Machine Learning as a Service» wird dieses Angebot genannt.

Facebooks AI-Abteilung hat beispielsweise browserbasierte Systeme entwickelt, die von den Mitarbeitern nur noch mit Daten gefüllt werden müssen – die Maschine arbeitet lautlos im Hintergrund. Auch andere Techunternehmen, wie Uber, Google und Airbnb, setzen derartige Dienste ein. Für einfache Aufgaben reicht so ein Baustein oft schon, aber um Algorithmen für spezifische Fragestellungen zu entwickeln braucht man in der Regel AI-Spezialisten.

Auch für die Frage, welche Algorithmen konkret infrage kommen, ist AI-Expertise gefragt. Wir können hier eine erste Vorstellung entwickeln, für die Details brauchen wir Experten für maschinelles Lernen. Mit ihnen müssen wir auch die Frage der Trainingsdaten besprechen. Zur Erinnerung aus dem Kapitel «Briefing» (siehe Training, auf Seite 27): Bevor ein AI-Programm Ergebnisse liefert, muss es üben. Es benötigt Daten, die so aufbereitet sind, dass es versteht: Dieser Umriss

auf dem Foto bedeutet Pferd. Das Foto benötigt also das Stichwort «Pferd». Viele solcher Fotos ermöglichen dem Programm, die Umrisse immer besser zuzuordnen. Im nächsten Schritt wird getestet, wie gut es das Erkennen beherrscht. Wir zeigen dem Programm Fotos, von denen wir bereits wissen, dass Pferde abgebildet sind. Die Trefferquote bei diesen Prüfdaten gibt Aufschluss darüber, wie weit das Training fortgeschritten ist. Haben wir keine Trainings-Datensets, müssen sie hergestellt werden. Tausende Trainingsfotos von Hand zu markieren, kann im schlimmsten Fall Monate dauern – und den Projektaufwand maßgeblich erhöhen.

Spezialist oder Generalist?

Das Training soll nicht unendlich lange dauern. Dafür sorgen die **Trainingsparameter**. Sie definieren, wie genau das Ergebnis sein soll. Wir beschreiben in diesem Kapitel, was es mit der Ausbildung der AI zum Generalisten oder zum Spezialisten auf sich hat – und wann eine AI ruhig unpräzise sein darf. Wichtig in diesem Abschnitt ist, dass wir uns klar machen, wie die Folgen eines fehlerhaften Ergebnisses aussehen. Beeinflussen sie das Leben anderer – oder fallen Ungenauigkeiten nicht weiter ins Gewicht? Erst wenn wir das wissen, können wir entscheiden, worauf es beim Training wirklich ankommt.


Bevor wir eigene Trainings-Datensets erstellen, überlegen wir, ob sie schon von anderen erstellt wurden. Viele Bilder, Sprachen, Objekte zum Beispiel aus der Medizin, wurden bereits mit Milliarden einzelner Datenpunkte aufbereitet, beschriftet, kategorisiert. Hier lohnt sich die Recherche, denn sie kann eine enorme Abkürzung sein.



Ohne Trainingsdaten gibt es keine AI. Der Aufwand, dieses Datenset herzustellen, wird häufig unterschätzt. Er kann den Umfang eines AI-Projekts maßgeblich bestimmen.

Maschinen-fähigkeiten

Die Grundlagen



1. Erkennen, analysieren und vorhersagen

Wer weiß, was die lernenden Programme können, kann mit einiger Übung eine Vorauswahl treffen und so den Aufwand für die Umsetzung leichter abschätzen.

Die Fähigkeiten der Machine-Learning-Programme erscheinen auf den ersten Blick schnell übermenschlich. Wenn auf Knopfdruck hochaufgelöste realistische Porträts von Menschen entstehen oder komplette städtebauliche Konzepte, wirkt das oft wie Zauberei. AI-Programme können einzelne Aspekte menschlichen Wirkens nahezu perfekt imitieren, oft nur viel schneller. Sie können sehen, analysieren, schreiben, dichten, neue Variationen schaffen, Entscheidungen treffen. Erst der genauere Blick relativiert die Leistung. Sie sind Spezialisten, trainiert für einen klar umrissenen Auftrag, basierend auf komplexer Mathematik. Abweichungen zerstören oft das Ergebnis. Schlecht aufbereitete Daten ebenfalls. Sie sind eben nur Software-Roboter, komplex aber ohne Verstand.

Für den Laien ist es oft schwierig, sich vorzustellen, welches gigantische Spektrum an Tätigkeiten mit maschinellern Lernen möglich ist. Daher haben wir auf der Basis einer Einteilung von Instituten der Fraunhofer-Gesellschaft eine Übersicht erstellt. Der «AI Skill Navigator» gibt einen Überblick über die wichtigsten Aufgaben, die auf maschinellern Lernen basierende Systeme heute lösen können. Aufgeteilt ist der Navigator in drei Teile.

Diese Gruppe enthält Fähigkeiten, von denen wir alle schon profitiert haben, zum Beispiel Freunde auf einem Bild identifizieren, Urlaubsfotos mit Schiffen gruppieren oder Songs an der Melodie erkennen.

Objekte erkennen und klassifizieren

Auf Bildern werden Objekte lokalisiert (Position auf dem Bild), klassifiziert (als Pferd) oder sogar eindeutig benannt (als das Pferd namens «Black Beauty»).

Audiosignale erkennen und analysieren

Audiosignale werden beispielsweise als Sprache erkannt und in Text umgewandelt, oder Hintergrundgeräusche aus einem Telefonat herausgefiltert.

Dieses Lernmodell ermöglicht das Einordnen von Signalen oder Objekten für die weitere Bearbeitung.

Klassifizierte Daten gruppieren oder sortieren

Diese Fähigkeit ermöglicht das Erkennen von Mustern und hilft, mehrdimensionale Strukturen (mehrfache Zuordnung für dasselbe Objekt) in riesigen Datenmengen zu erkennen.

Informationen extrahieren und Aktionen ableiten

Aus Daten werden bestimmte Informationen extrahiert, wie Geschlecht, Adressen, Markennamen. Befehle oder Fragen werden erkannt und ausgeführt oder beantwortet.

Zielwerte oder Ereignisse schätzen und vorhersagen

Hier werden lineare oder komplexere Zusammenhänge erkannt und für Vorhersagen über künftige Zustände beziehungsweise Ereignisse genutzt. Beispiel hierfür ist die Wartungsvorhersage von Maschinen und Anlagen.

Die erfolgversprechendsten Schritte für einen Entscheidungsprozess auswählen

Hier können Programme oder Roboter anhand von Feedback selbständig lernen, welche Aktionen oder Spielzüge die besten Resultate erzielen können. Das ist eine Alternative zum expliziten Planen und Anpassen von Handlungsfolgen.

2. Verstehen, kommentieren und generieren

Die Fähigkeiten in dieser Gruppe erlauben das Interpretieren von Kontext und die Berücksichtigung von Interaktion.

Sprache (Linguistik) und Emotion verstehen sowie kommunizieren

Hier wird nicht nur ein Wort erkannt, sondern auch eine linguistische Einordnung geleistet. Sätze werden in Bezug zu früheren Äußerungen gesetzt und Dialoge fortgesetzt. Emotionen können anhand der Wortwahl identifiziert werden

Text, Bild und Video semantisch und im Kontext verstehen

Bei Texten, Bildern und Bildfolgen geht es nicht nur darum, einzelne Elemente oder Objekte zu identifizieren, sondern die Szene zu verstehen. Wer interagiert mit wem, was passiert gerade, was könnte als Nächstes geschehen?

Inhalte verschiedener Art kombinieren

Zusammengehörige Text-, Bild-, Audiodaten werden zueinander in Bezug gesetzt, etwa die Aufnahme von Kamera und Mikrophon oder ein radiologisches Bild mit einem dazugehörigen wissenschaftlichen Report.

Neue Inhalte generieren

Maschinen können inzwischen sogar «kreative» Aufgaben durchführen, wie das Schreiben von Gedichten, das Malen von Bildern und Komponieren von Musikstücken, die Animation von Figuren in digitalen Spielen und die Zusammenfassung von Meldungen zu einem Bericht.

3. Unterschiedliche Formen des Lernen

Die letzte Kategorie befasst sich mit der Art und Weise, wie die Programme lernen.

Vorhandenes Wissen mit zusätzlichen

Erkenntnissen kombinieren

Logische Regeln und das formalisierte Wissen von Experten werden durch maschinelles Lernen kombiniert. Das führt dazu, dass ML-Anwendungen effizienter, verständlicher, verlässlicher und kontrollierbarer gestaltet werden, oder deren Fähigkeiten vertieft werden können.

Lernen mit vielen Daten

Wenn es darum geht, viele Merkmale in Trainingsdaten zu verarbeiten, benötigt man sehr viele Daten – in der Größenordnung von Zehntausenden bis Millionen. Sogenannte tiefe neuronale Netze (Deep Learning) sind Mittel der Wahl.

Lernen mit wenigen Daten

Wenn nur wenige brauchbare Trainingsdaten zur Verfügung stehen, möchte man trotzdem bestmöglich daraus lernen. Diese Daten benötigen dann jedoch eine erheblich höhere Qualität und besondere Lernmodelle.

Anpassung an veränderliche Bedingungen

Gelernte Modelle, die für die Lösung einer Aufgabe erfolgreich waren, dienen als Ausgangspunkt für die Lösung neuer, aber ähnlicher Aufgaben. Vorteil: Der Trainingsaufwand sinkt deutlich.

Nutzervertrauen ist ein wichtiger Aspekt für die Akzeptanz von Künstlicher Intelligenz.

**Die grobe Einteilung
hilft uns zu verstehen,
wie Maschinen ticken.**

Automatisiertes, selbständiges Weiterlernen

Der Aufwand, Algorithmen zu entwickeln, wird durch Teilautomatisierung reduziert. Das Programm entwickelt Teile seiner Lernalgorithmen selbst weiter. So können selbstfahrende Autos eine Antwort auf neue Situationen finden (die zuvor durch den Menschen überprüft wurden).

Nachvollziehbare Entscheidungsfindung

Menschen wollen und müssen oft verstehen, wie eine Maschine zu einer Entscheidung gekommen ist und auf welchen Daten und Verknüpfungen diese basiert. Je wichtiger der Aspekt Anwendervertrauen ist, desto bedeutender ist außerdem die Fähigkeit, unempfindlich gegenüber Störungen zu sein, Einschränkungen zu beachten und Kompetenzgrenzen zu berücksichtigen. Bei dieser Maschinenfähigkeit müssen wir uns bewusst sein: Nicht jedes AI-Modell bietet diese Nachvollziehbarkeit (siehe «Blackbox-Effekt» auf Seite 20)


Diese Einteilung ist selbstverständlich nur ein Einstieg. Tatsächlich gibt inzwischen tausende verschiedener Algorithmen, Tendenz steigend. Doch eine solche grobe Einteilung hilft uns Menschen zu verstehen, wie Maschinen ticken. So lassen sie sich die Fähigkeiten relativ einfach den Aufgaben und den zu verarbeitenden Datenquellen in der aktuellen Challenge zuordnen.



AI, ein Scheinriese

Die Fähigkeiten von AI erscheinen beim flüchtigen Betrachten gigantisch, fast wie Zauberei. Doch bei näherem Hinsehen wird das Wunder oft kleiner. Viele Programme sind gut, aber nicht perfekt. Wer AI nutzt, muss Ungenauigkeit wie beim Menschen tolerieren und die Ergebnisse kritisch einordnen können.

Template



Lernkonzept erstellen AI Skill Navigator



1: Erkennen, analysieren und vorhersagen

1

2



Objekte erkennen und klassifizieren
(Auf Bildern Hunde und Katzen auseinanderhalten)



Informationen extrahieren und Aktionen ableiten
(Wenn Babygeschrei über 100 dB, dann stillen)



Klassifizierte Daten gruppieren oder sortieren
(Aus Tierbildern Hunde- und Katzenstapel bilden)



Zielwerte oder Ereignisse schätzen und vorhersagen
(Hurrikan mit Tempo X erreicht Florida in Y)



Audiosignale erkennen und analysieren (Sprache, Geräusche, Musik etc.)
(Einzelne Stimmen und Emotionen erkennen)



Die Erfolg versprechendsten Schritte für einen Entscheidungsprozess auswählen
(In möglichst wenig Zügen einen Zauberwürfel lösen)

2: Verstehen, kommentieren und generieren



Sprache (Linguistik) und Emotionen verstehen, sowie kommunizieren
(Supportanfrage verstehen und passend antworten)



Inhalte verschiedener Art kombinieren
(Röntgenbild und Diagnose, Deepfake Videos)



Text, Bild und Video semantisch und im Kontext verstehen
(Person kniet vor einer anderen = Heiratsantrag)



Neue Inhalte generieren
(Neue Zeitungsartikel, Webdesigns etc. generieren)

3: Lernfähigkeiten



Vorhandenes Wissen mit zusätzlichen Erkenntnissen kombinieren
(Neue Studienerkenntnisse in med. Diagnose einbinden)



Anpassung an veränderliche Bedingungen
(Roboter und Menschen arbeiten zusammen)



Lernen mit vielen Daten
(Autonome Fahrzeuge steuern)



Automatisiertes, selbständiges Weiterlernen
(Wettervorhersagen mit Realität abgleichen und künftige Prognosen anpassen)



Lernen mit wenigen Daten
(Nummernschilder an Mautstation erkennen)



Nachvollziehbare Entscheidungsfindung
(Triage in der Medizin)

Maschinen- fähigkeiten

Das Tool

Schritt für Schritt

Wir haben mit der «Data Journey Map» alle Informationen, die wir benötigen, um zu entscheiden, wie aus Daten ein brauchbares Ergebnis generiert werden soll. Im Feld «Datensammlung/Was soll die Maschine daraus ableiten oder erarbeiten?» haben wir für jede Datenquelle die entsprechende Aufgabe bereits notiert. Die «Data Journey Map» ist damit die Grundlage für die folgenden Überlegungen.

1

Wir prüfen anhand des «AI Skill Navigator», welche Fähigkeiten gebraucht werden, um die jeweils ausgewählten Datentypen der «Data Journey Map» zu verarbeiten.

2

Wir wählen die Fähigkeiten aus, die in die engere Wahl kommen. Es reicht, wenn wir hier unseren menschlichen Maßstab ansetzen und überlegen, was wir tun müssten, um zum Ergebnis zu kommen.

Wir übertragen alle Fähigkeiten in den AI Planner. Dort notieren wir zu jeder Fähigkeit außerdem die damit zu bewältigende Aufgabe der Maschine, sowie die dazugehörige Datenquelle. Die Angaben übertragen wir aus der «Data Journey Map».

Geschafft – das war gar nicht so schwer. Nun gehen wir im nächsten Schritt tiefer ins Detail.

Das Schulbeispiel


Im Fall unserer Schul-Challenge müssen wir für den Datentyp A (Schulstandorte):

1. **Daten gruppieren** – aus bereits klassifizierten Geodaten Schulstandorte gruppieren;
2. **Lernen mit vielen Daten** – wir werten alle Schulstandorte und später auch die Verkehrsdichte aus.

Für die restlichen Datentypen benötigen wir noch «Sprache und Emotionen verstehen», um aus unstrukturierten Berichten Informationen für Unfälle lesen zu können, und «Vorhandenes Wissen mit weiteren Erkenntnissen kombinieren», um aus Berichten Angaben über Unfälle mit Staus zu verknüpfen.

Trainingsparameter

Die Grundlagen



Wann ist gut gut genug?

Ein Ergebnis kann auch perfekt sein, wenn es nur zu 80 Prozent genau ist.

Das Besondere an Machine-Learning-Programmen ist, dass nicht ein Lösungsweg programmiert wird – sondern eine Fähigkeit, sich einen Lösungsweg zu suchen. Daher ist es wichtig, sich Gedanken zu machen, wie das Lernen eigentlich funktionieren soll. Es gibt ein paar Besonderheiten, die wir wissen müssen, wenn wir mit lernenden Systemen arbeiten.

Ähnlich wie Menschen sind sie nicht perfekt. Ihre Ergebnisse sind Wahrscheinlichkeiten. Das heißt, die Resultate können gerade am Anfang eines Trainingsprozesses noch ungenau sein. Stellen wir uns vor, wir wollen bei der Fertigung von Brillengläsern diejenigen aussortieren, die Kratzer haben. Da kann es passieren, dass die Analyseergebnisse nicht nur Brillen mit Kratzern zeigen, sondern auch welche, in denen sich nur das Tageslicht reflektiert, weil das zufällig so ähnlich wirkt.

Weil hundertprozentige Perfektion bei AI-Modellen extrem aufwendig sein kann, müssen wir uns Gedanken darüber machen, wann das Ergebnis ausreichend gut ist. Dazu definieren wir im ersten Schritt das Qualitätsniveau des Modells und legen anschließend den Schwerpunkt des Trainings fest.

Um das **Qualitätsniveau** zu bestimmen, müssen wir überlegen, an welchen für uns **relevanten Einflussfaktoren** das AI-Modell später gemessen werden soll, um seine Leistungsfähigkeit zu evaluieren. Das kann die Geschwindigkeit der Umsetzung sein, Faktoren aus unserem Value Template, der generelle Qualitätsanspruch im Rahmen des Auftrags. Auf dieser Basis betrachten wir vier Aspekte:

Menschlicher Maßstab: Wie viel Aufwand würde es einen Menschen kosten, die Aufgabe zu lösen? Wir fragen uns: Kann die Aufgabe von einem Menschen überhaupt erfüllt werden? Wenn ja, wie schnell, in welcher Qualität und zu welchen Kosten? Wie lange würde ein Projektteam für die Aufgabe mit konventionellen Mitteln brauchen?

Mindestanforderung für Wertgenerierung: Was muss das Modell mindestens leisten, um besser als der Mensch zu sein? Was muss die Maschine mindestens leisten, damit der Einsatz sich für das Unternehmen lohnt? Dazu muss sie Aufgaben nicht zwangsläufig «besser» bearbeiten als der Mensch, wenn

Um das Mindestvertrauensmaß bestimmen zu können, müssen wir Wertbeitrag, Ergebnisqualität und Zielmaß kennen.

sie diese dafür 24 Stunden am Stück ausführen kann. Wie oft muss die Tätigkeit wiederholt werden (will, kann oder soll ein Mensch diese Aufgabe immer wiederholen)?

Wie muss die Tätigkeit skalieren (zum Beispiel zeitgleich: viele Anfragen gleichzeitig abarbeiten; oder in einer Zeitspanne: Tag und Nacht ohne Pause)?

Ist die Tätigkeit durch bestehende Anwendungen schneller durchführbar (zum Beispiel durch vorhandene Schnittstellen (APIs))?

Das **erwünschte Zielmaß** definiert das Optimum, das mit der Maschine erreicht werden soll. Hier kommt die sogenannte Wahrheitsmatrix zum Einsatz (siehe nächste Seite). Leitfragen sind dabei zum Beispiel: Was hat unser Ergebnis für Auswirkungen auf unsere Entscheidungsfindung, Handlungen und Anwender? Wir legen danach das ideale Maß fest, das wir erreichen möchten, und fragen uns dann, wie wir nun mit möglichen Abweichungen vom Zielmaß umgehen.

Mindestvertrauensmaß

Das ist die Selbsteinschätzung des AI-Modells, wie sicher es sich ist, dass eine Aussage stimmt (zum Beispiel wie treffsicher es bisher unbekannte Testdaten richtig zuordnet). Also:

Wie viel Abweichung vom Zielmaß ist tolerierbar? Kann ich mit Abweichungen vom Zielmaß umgehen (vergleiche die Überlegungen im Zusammenhang mit der Wahrheitsmatrix auf den Folgeseiten)? Wenn nicht, brauche ich wahrscheinlich mehr oder bessere Daten für ein höheres Vertrauensmaß.

Wichtig: Die Masse an Daten macht nicht unbedingt ein besseres Ergebnis aus, wenn die Qualität nicht stimmt. Ein Arzt zum Beispiel kann mit einer Abweichung vom Zielmaß leben, weil er als Experte nochmal kontrollieren kann; eine Corona-husten-Test-App dagegen braucht ein hohes Vertrauensmaß, weil man bewusst auf eine Kontrollinstanz verzichten will (Nutzer und Gesundheitsämter wollen schnell entscheiden können, wer in Quarantäne gehen muss). Das Vertrauensmaß übersteigt im Idealfall sogar das Zielmaß. Das stellt sich nach einigen Trainings- und Testdurchläufen heraus.

Wenn wir über die Zeit höhere Vertrauensgrade erreichen möchten, überlegen wir, wie wir Nutzer durch die Anwendung unserer AI-Lösung bei der Verbesserung des Modells einbinden können (siehe «Virtuous Cycle of AI» auf Seite 302).

Nachdem wir das Qualitätsniveau unseres AI-Modells definiert haben, können wir uns um das Training selbst kümmern. Der Wermutstropfen ist: Wir können dem Lernmodell entweder beibringen, wie ein Spezialist zu arbeiten oder wie ein Generalist.

Spezialisten lieben Genauigkeit

Wir wählen die Eigenschaft des **Spezialisten**, um etwas sehr konkret bestimmen zu können. Ein solches AI-Modell könnte zum Beispiel Designs für Sportwagen à la Maserati entwickeln. Designs im Stil von Porsche wären aber nicht möglich. Ein zweites Beispiel: Ein AI-Modell kann so trainiert werden, dass es mit 98-prozentiger Wahrscheinlichkeit am Husten eines Menschen erkennt, ob eine Covid-19-Erkrankung besteht. Ein Keuchhusten würde aber nicht angezeigt. Ein Spezialist beherrscht also jedes kleine Merkmal exakt, hat dafür aber einen gewissen Tunnelblick.

Als Kennzahl für die Optimierung zum Spezialist dient die **«Genauigkeit» (engl. «Precision»)**. Die Genauigkeit der Prognose ist das Verhältnis der richtig positiven Treffer zu allen prognostizierten positiven Treffern. Sie zeigt den Anteil der von einem AI-Modell als krank eingestuften Personen, die tatsächlich krank sind (siehe Wahrheitsmatrix rechts). Die Genauigkeit ist eine gute Wahl, wenn wir einen hohen Preis für ein falsch positives Ergebnis zahlen müssten (Unschuldiger muss wegen falscher Bilderkennung ins Gefängnis).

Vorteil: Wir benötigen relativ kleine Trainingsdatensätze, können durch Training aber eine sehr hohe Genauigkeit erreichen. Das Training geht aufgrund der kleineren Trainingsdatensätze deutlich schneller als beim Generalist.

Nachteil: Diese AI-Modelle auf neue Aufgaben anzupassen ist aufwendig (zum Beispiel künftig auch Lungenentzündung zu erkennen). Hier muss man besonders darauf achten, dass die Qualität und die repräsentative Auswahl der Trainingsdaten hoch sind, sonst kann es leicht zu falschen Ergebnissen, wie zum Beispiel zu Rassismus bei der Erkennung von Verbrechern auf Fotos, kommen.

Generalisten lieben Vielfalt

Wir entscheiden uns für die Eigenschaft des **Generalisten**, wenn wir ein großes Aufgabenspektrum haben. Um das

		Vorhergesagter Wert	
		negativ	positiv
Tatsächlicher Wert	negativ	richtig negativ	falsch positiv
	positiv	falsch negativ	richtig positiv

Die Wahrheitsmatrix hilft, die Konsequenzen falscher Entscheidungen zu durchdenken. Beispiel Krebsdiagnose auf Röntgenbildern: Eine AI kann Krebs diagnostizieren, wo keiner ist (falsch positiv) oder Krebs übersehen (falsch negativ). Was ist schlimmer?

Beispiel des AI-basierten Autodesigners aufzugreifen: Das AI-Modell soll sowohl Sportwagen als auch SUVs oder ein zweitüriges Coupé entwerfen – und zwar für eingefleischte Maserati-Fans. Generalisten eignen sich auch sehr gut für Trendvorhersagen, etwa wenn es darum geht, die Preisentwicklung für Immobilien zu prognostizieren. Hier werden viele Datentypen, wie Lage, Alter, Zimmerzahl, Quadratmeterpreise in der Nachbarschaft, kombiniert und interpretiert.

Die Kennzahl, die hier verwendet wird, heißt **«Trefferquote» (engl. «Recall»)**. Die Trefferquote ist das Verhältnis der richtig positiven Treffer zu allen **richtig** positiven Treffern (siehe Wahrheitsmatrix links); es ist die Wahrscheinlichkeit, mit der eine Krankheit korrekt als positiv klassifiziert wird. Die Trefferquote ist dann unser Modell der Wahl, wenn wir einen hohen Preis für ein falsch negatives Ergebnis zahlen müssten (als gesund diagnostizierter Patient stirbt an Krebs).

Vorteil: AI-Modelle die Richtung Generalist optimiert werden, können relativ leicht an neue Aufgaben angepasst werden, da sie in der Lage sind, viele Datentypen miteinander in Beziehung zu setzen. Sie lassen sich gewissermaßen recyceln. Die Anforderungen an die Genauigkeit sind geringer als beim Spezialist, und sie verträgt Daten mit unterschiedlich hoher Qualität. Insgesamt sind diese AI-Modelle weniger anfällig für Fehlinterpretationen durch Bias.

Nachteil: Der Trainingsaufwand ist hier höher als beim Spezialisten. Je breiter die AI aufgestellt ist, desto mehr Daten benötigt sie, um die einzelnen Aufgaben auseinanderzuhalten. Die Genauigkeit der Ergebnisse leidet zwar. Bei den für diesen Trainingsansatz gewählten Anwendungsbereichen kann das aber häufig toleriert werden.

Wichtig: Jedes AI-Modell braucht beide Eigenschaften. Die Frage ist nur, welche dominiert: der Spezialist oder der Generalist? Die Diskussion darüber müssen wir führen, die Wahrheitsmatrix (links) dient dazu als Orientierungshilfe. Erst dann können wir im nächsten Schritt abwägen, welchen Schwerpunkt wir dem Training der AI geben müssen.

Template



Lernkonzept erstellen

Trainingsparameter



Qualitätsniveau des Modells

Einflussfaktoren

1

Menschlicher
Maßstab

Mindestanforderung
für Wertgenerierung

Erwünschtes
Zielmaß

Mindestvertrauensgrad
des Modells

2

Schwerpunkt des Trainings

Trefferquote (Recall)

4

Genauigkeit (Precision)



Argumente

Argumente

3



Trainingsparameter

Das Tool

Zu diesem Zeitpunkt liegen bereits so viele Informationen vor, dass die meisten Fragen innerhalb eines Workshops beantwortet werden können.

Schritt für Schritt

1

Für die Definition des Qualitätsniveaus müssen wir zuerst beschreiben, was die Qualität unseres Ergebnisses genau ausmacht. Dazu betrachten wir zum Beispiel den Mehrwert, der im Value Template dokumentiert wurde. Es können aus der Datenrecherche auch Angaben über die zu verarbeitende Datenmenge sein (kleine Datenmengen benötigen komplexere AI-Modelle), eine hohe Geschwindigkeit in der Umsetzung oder auch eine höhere Präzision der Analyse.

2

Wir gehen die vier Evaluationskriterien durch und definieren: Den **menschlichen Maßstab**. Wie lange würde ein Projektteam für die Aufgabe mit konventionellen Mitteln benötigen? Die **Mindestanforderung für die Wertgenerierung**, um festzulegen, was das AI-Modell mindestens leisten muss, um seinen Einsatz zu rechtfertigen; Das **erwünschte Zielmaß**, das wir als bestes Ergebnis erreichen wollen; Den **Mindestvertrauensgrad des Modells**, der den Wert festlegt, wie stark sich das AI-Modell mindestens an das Zielmaß angenähert haben muss, bevor es uns ein Ergebnis liefert. Die Höhe dieses Werts hängt von den Konsequenzen falscher Ergebnisse ab (siehe Wahrheitsmatrix).

3

Wir gehen nacheinander die verschiedenen Argumente für die beiden Trainingsschwerpunkte zum Spezialisten (Genauigkeit, Precision) und zum Generalisten (Trefferquote, Recall) durch. Wir ziehen die bereits vorliegenden Informationen aus Value Template, Data Checklist und Data Journey Map zu Rate, wenn es um die Bewertung der einzelnen Argumente, wie Datenqualität, Geschwindigkeit oder Bias, geht.

4

Wir diskutieren im Team anhand der Wahrheitsmatrix und der gesammelten Argumente, welche Folgen eine Optimierung des Trainingsmodells auf hohe Genauigkeit oder hohe Trefferquote haben könnte. Hilft uns eher ein Spezialist, oder doch eher der Generalist? Das Ergebnis dokumentieren wir auf dem Template, indem wir den Schieberegler entsprechend markieren. Eine hundertprozentige Optimierung auf eine der beiden Eigenschaften ist so gut wie unmöglich. Wir müssen also vor allem die Tendenz der Optimierung festlegen.

Schulbeispiel



Lernkonzept erstellen Trainingsparameter



Evaluationskriterien

Einflussfaktoren

Geschwindigkeit, Genauigkeit, verarbeitete Datenmenge

Menschlicher Maßstab

4 Menschen führen 100 Recherchetermine in 25 Städten in 3 Monaten durch, um die Verkehrssituation vor Schulen zu überprüfen, und analysieren zusätzlich die Verkehrsstatistiken der letzten 5 Jahre.

Mindestanforderung für Wertgenerierung

Auswertung von mindestens 40 % aller Schulstandorte in Deutschland mit passenden Verkehrsdaten und Unfallstatistiken der letzten 5 Jahre.

1

Erwünschtes Zielmaß

Auswertung von mind. 60 % aller Schulstandorte in Deutschland mit passenden Verkehrsdaten und Unfallstatistiken der letzten 5 Jahre (da kein erhöhtes Risiko wie z. B. bei der medizinischen Diagnose besteht).

Mindestvertrauensgrad des Modells

75 % der Schülerunfälle vor Schulen zu den Stoßzeiten werden tatsächlich identifiziert.

Erforderliche Genauigkeit

Trefferquote (Recall)

2

Genauigkeit (Precision)



Argumente

Diverse Arten von Daten abfragen und miteinander in Beziehung setzen.

Ggf. Trends vorhersagen

75 % Genauigkeit sind ausreichend für unseren Zweck, immer noch viel höher als durch Menschen möglich.

Weniger Trainingsaufwand, da nicht so präzise notwendig.



Argumente

Hohe Treffergenauigkeit, die Unfälle von Kindern ihrem Schulweg zuzuordnen (wir möchten ein Projekt machen, das Kinder im Fokus hat).

Das Schulbeispiel

Wir haben hier als Orientierungsparameter für die Leistungsfähigkeit des Systems drei Faktoren gewählt: Geschwindigkeit (weil das Projekt unter Zeitdruck steht), Genauigkeit (weil wir eine valide Grundlage für finanzielle Entscheidungen haben wollen) und Datenmenge (weil wir viele Daten miteinander kombinieren müssen).

1

Den Rahmen definieren

Das Beispiel zeigt auch, wie wir, ausgehend von unserem gewohnten Vorgehen, die Anforderungen für die Maschine ableiten können. So dienen die Annahmen für die Zeit, die ein Projektteam braucht, als Vergleichsmaßstab.

Die Mindestanforderung wird abgeschätzt aus dem Wunsch, einen einigermaßen repräsentativen Überblick über das Geschehen an Schulstandorten zu bekommen und eine Vorstellung eines sich über die Jahre entwickelnden Trends.

2

Die Genauigkeit des Ergebnisses bestimmen

Unser Zielmaß ist nicht Perfektion. Da wir mit unserer Lösung kein erhöhtes Risiko eingehen, Menschenleben direkt zu gefährden (wie zum Beispiel bei der medizinischen Diagnose), reichen uns 60 Prozent der ausgewerteten Schulstandorte. Damit wir den Aussagen des Modells auch vertrauen können, muss ein Maß für die Verlässlichkeit seiner Aussage angegeben werden. Zur Einordnung nutzen wir die Wahrheitsmatrix.

Nun überlegen, wir welche Argumente für die beiden Trainingskennzahlen Genauigkeit (Precision) und Trefferquote (Recall) sprechen. Wir sehen, dass weit mehr Gründe für die Trefferquote als für die Genauigkeit sprechen.

		Vorhergesagter Wert	
		positiv	negativ
Tatsächlicher Wert	positiv	Verkehrsaufkommen vor Schulen zu Stoßzeiten führt zu mehr Unfällen.	Unfälle vor Schulen zu Stoßzeiten ermittelt, obwohl sie nicht vorkommen.
	negativ	Keine Unfälle vor Schulen zu Stoßzeiten ermittelt, obwohl sie vorkommen.	Verkehrsaufkommen vor Schulen zu Stoßzeiten führt nicht zu mehr Unfällen.

Die Wahrheitsmatrix, ausgefüllt für das Schulbeispiel.

4. Entscheidung treffen

AI oder keine AI?



Ein Vergleich ist wichtig, denn ein AI-Projekt ergibt nur dann Sinn, wenn es tatsächlich einen geschäftlich begründbaren Mehrwert gibt.

Der Moment der Wahrheit naht. Wie immer im Geschäftsleben, gibt es nichts umsonst. Um unsere Projektspensoren überzeugen zu können, ihre Taschen für das AI-Projekt zu öffnen, benötigen wir valide Einschätzungen der Vorteile gegenüber dem klassischen Vorgehen. Was wir bisher gemacht haben, was wir gesammelt, analysiert und ausgelotet haben, ermöglicht es uns, zu vergleichen: den Aufwand des klassischen Vorgehens mit dem Aufwand zur Erstellung eines Machine Learning Tools. Wir wechseln also erneut die Perspektive und betrachten geschäftliche Parameter, wie Aufwand, Risiko und Nutzen.

Damit der Vergleich systematisch erfolgt, liefern wir in den folgenden beiden Abschnitten eine konkrete Anleitung für das Vorgehen. Wir haben zu Beginn des AI Planners Hypothesen bezüglich des zu erwartenden Mehrwerts aufgestellt. Nun können wir anhand des Vergleichs zeigen, ob die Annahmen zutreffen, und wir können belegen, warum das so ist. Deshalb war es wichtig, sich mit dem Vorteil für die Nutzer auseinanderzusetzen, mit dem Aufwand, die Daten zu bekommen, den Möglichkeiten der maschinellen Umsetzung. Erst mit diesen Informationen ist eine seriöse Einschätzung des geschäftlichen Mehrwerts möglich.

Im Ergebnis können wir auf der Basis der gesammelten Informationen nun beurteilen, ob wir einen, sagen wir Quick-and-Dirty-Weg wählen, der hilft, dramatisch Kosten zu sparen, wenn man die Lösung beispielsweise nur einmal für eine ganz spezifische Anwendung braucht. In diesem Fall könnte eine Umsetzung zum Beispiel schnell und günstig in Form eines Hackathons innerhalb weniger Tage durchgeführt werden.

Oder wir stellen fest, dass zum Beispiel der Aufwand, die Trainingsdaten aufzubereiten zu hoch ist (entweder werden viele Leute gebraucht, das kostet Geld, oder es dauert zu lange). Das führt möglicherweise dazu, dass wir Abstriche machen und lieber konventionell arbeiten – ohne AI.

Es kann auch sein, dass wir feststellen, dass der strategische Wert, den Einstieg in die Welt der AI zu wählen, so hoch ist, dass der Mehraufwand gerechtfertigt ist. In diesem Fall

sollte allerdings nach den ersten Gehversuchen eine übergreifende AI-Strategie entwickelt werden (siehe Kapitel «Sicher landen»).

Neue Risiken

Neue Technologien bergen naturgemäß auch neue Risiken. Der Umgang mit AI erfordert nicht nur neues Know-how im Unternehmen – welche Spezialisten erforderlich sind, zeigen wir im Kapitel «Sicher landen». Es entstehen auch gänzlich neue Fragestellungen, die Aspekte, wie den Datenschutz, die Ethik und die Sicherheit der Informationssysteme, betrifft. Das hängt auch damit zusammen, dass teilweise die Grenzen der Unternehmens-IT geöffnet werden müssen, um zum Beispiel externe Daten durch Maschinen analysieren zu können. Oder automatische Entscheidungen nach ethischen Gesichtspunkten statt nach Computerlogik geprüft werden müssen.


Der Aufwand, diese Risiken zu beherrschen, ist nicht zu unterschätzen. Generell gilt, dass kleinere, überschaubare Projekte als Einstieg erheblich lohnender sind. Damit sind kleine Helfer gemeint, die lästige Routine-Aufgaben lösen können. Angaben aus Rechnungsdokumenten in Tabellen übertragen, Bilder erkennen und vieles mehr. Sollen komplette Produktionsprozesse im globalen Maßstab auf Basis von AI optimiert werden, ist der Proof of Concept, der erste Lösungsansatz, zwar einigermaßen schnell erstellt – das Herstellen eines sicheren, Industriestandards entsprechenden Programms kann jedoch sehr viel Zeit und Geld kosten und ist als Einstieg nicht zu empfehlen.



Es gibt bei jedem Projekt das Risiko des Scheiterns. Doch die fundierte Analyse mithilfe des AI Planners liefert ein solides Fundament für das Finale: die Entscheidung für oder gegen AI.

Vorgehens- vergleich

Die Grundlagen



Das finale Assessment ermöglicht eine qualifizierte Entscheidung für oder gegen AI.

Für die Bewertung des geschäftlichen Mehrwerts betrachten wir alle Informationen, die wir bisher gesammelt haben, unter fünf Gesichtspunkten: Haben wir die nötigen Experten für das AI-Projekt? Wird es einen Zeitvorteil geben? Wie hoch sind die Kosten des Projekts? Gibt es Hürden, die die Umsetzung gefährden, und welche Risiken ergeben sich daraus? Und schließlich betrachten wir die Potenziale, die sich aus dem Projekt für unser Unternehmen ergeben.

Personal: In der Regel kennen sich die Mitarbeiter klassischer IT-Abteilungen nur selten mit maschinellern Lernen aus. Wir müssen hinterfragen, wo das nötige Know-how herkommen soll. Brauche ich spezielle AI-Skills? Reicht die Fortbildung existierender Mitarbeiter oder müssen Spezialisten angestellt, extern beschäftigt werden? Falls neue Mitarbeiter benötigt werden, geht der Faktor sowohl in Personal als auch in Kosten auf.

Zeit: Um den Zeitaufwand zu beurteilen, nutzen wir den «Time Calculator» (siehe folgende Doppelseite). Er hilft uns bei der Einschätzung des Zeitaufwands. Folgende Aspekte helfen, den Aufwand konkreter zu bestimmen. Wie lange brauchen wir für die Einrichtung der Infrastruktur (kann intern und extern sein)? Wie lange braucht die Datenbeschaffung und -aufbereitung (wie lange brauche ich für die gesamte Data Journey)? Und wie lange braucht das Training? Für den Vergleich reichen Erfahrungswerte aus der Praxis.

Kosten: Wir berücksichtigen unter anderem die Kosten für Workshops (falls sie von externen Experten durchgeführt werden), für Mitarbeiter-Trainings, Honorare oder Gehälter. Auch die Ausgaben für den Zugang zu Daten und das Aufbereiten durch externe (zum Beispiel Clickworker) oder interne Dienstleister. Auch die Überlegung, die Entwicklung selbst zu machen (make) oder bereits existierende Lösungen einzukaufen (buy), spielt hier eine Rolle. Oder es gelingt, auf bestehende kostenlose (Open Source) AI-Frameworks oder Plattformen auszuweichen (siehe «Sicher landen» auf Seite 272).

Hürden: Was bedeutet das AI-Projekt für die Organisation? Gibt es Silos, die erst zur Zusammenarbeit bewegt werden müssen? Wie hoch ist der Aufwand für Change Management, wenn zum Beispiel erst Überzeugungsarbeit für den internen Einsatz von AI geleistet werden muss? Gibt es strategische oder politische Gründe, die gegen AI sprechen? Auch die Fragen des Datenschutzes und eventueller ethischer Stolpersteine (wie beim autonomen Fahren) sollten durchdacht werden. Wir bewerten außerdem, ob die vorhergenden Faktoren Personal, Zeit und Kosten hier zu Problemen führen.

AI-Potenzial: Der Einsatz von AI mit seiner Geschwindigkeit und Leistungsfähigkeit kann große Vorteile bringen. Wir prüfen, ob für das Unternehmen die Technologieführerschaft ein strategischer Vorteil ist, ob Wettbewerbsvorteile in Form eines Alleinstellungsmerkmals entstehen, es First-of-a-kind-Produkte gibt, also Angebote, die es so noch nicht gibt und durch die wir uns komplett neue Märkte erschließen können. Auch die Zeit bis zur Marktreife, ein neues Qualitätsniveau durch den Einsatz von AI oder die automatisierte Individualisierbarkeit meiner Produkte/Services können Potenziale darstellen – oder schlicht die zu erwartende Kostenersparnis durch Automatisierung.

Diesen Vergleich führen wir gemeinsam mit Experten durch. Das Ergebnis ist eine valide Grundlage für eine Entscheidung durch die Projektspensoren.



Mit kaltem Blick

Bei der Entscheidung für Innovationen müssen wir sämtliche Emotionen aus dem Spiel lassen. Wir bewerten nüchtern, mit «kaltem Blick», die Vor- und Nachteile. Wenn der klassische Weg mehr Erfolg verspricht, lassen wir die Finger von AI.

Time Calculator

Die Zeiten sind Erfahrungswerte für die Gesamtdauer aus der Praxis. Die Schätzungen enthalten unter anderem auch übliche Wartezeiten im Projekt.



Daten

Wenn das Datensammeln und -aufbereiten mehr als drei Monate braucht, sollte das Projekt kritisch hinterfragt werden oder eine hohe strategische Bedeutung haben.

Algorithmen

Die unten angegebenen Werte setzen bei Gelb und Rot voraus, dass ein Data Scientist zum Team gehört. Ohne diesen Experten lassen sich allenfalls fertige Algorithmen oder Systeme verwenden (Grün).

Ressourcen

Zu AI-Systemen gehört eine spezielle Technik. Brauchen wir eigene Hardware oder setzen wir auf die Cloud? Hier hängt der Zeitaufwand zur Beschaffung stark von den verwendeten Ressourcen ab.

Fertige Datensätze, bei denen es nur um die reine Auswertung geht, aber nicht um die Vollständigkeit

Dauer: 1–5 Tage

Wenige Quellen, aber in guter Qualität

Dauer: 1–4 Wochen

Daten aus vielen Quellen, über die man selbst nicht die Hoheit hat oder deren Qualität man nicht kennt, verschiedene Formate

Dauer: 4–12 Wochen

Fertige oder getestete Algorithmen oder Systeme

Dauer: 1 Tag

Daten müssen mit mehr als einem Algorithmus ausgewertet werden

Dauer: 2–5 Tage

Bestehende oder fertige Algorithmen können nicht verwendet werden

Dauer: 1–4 Wochen

Moderate Datenmenge und einheitlicher Algorithmus, keine Bild- oder Sprachdaten

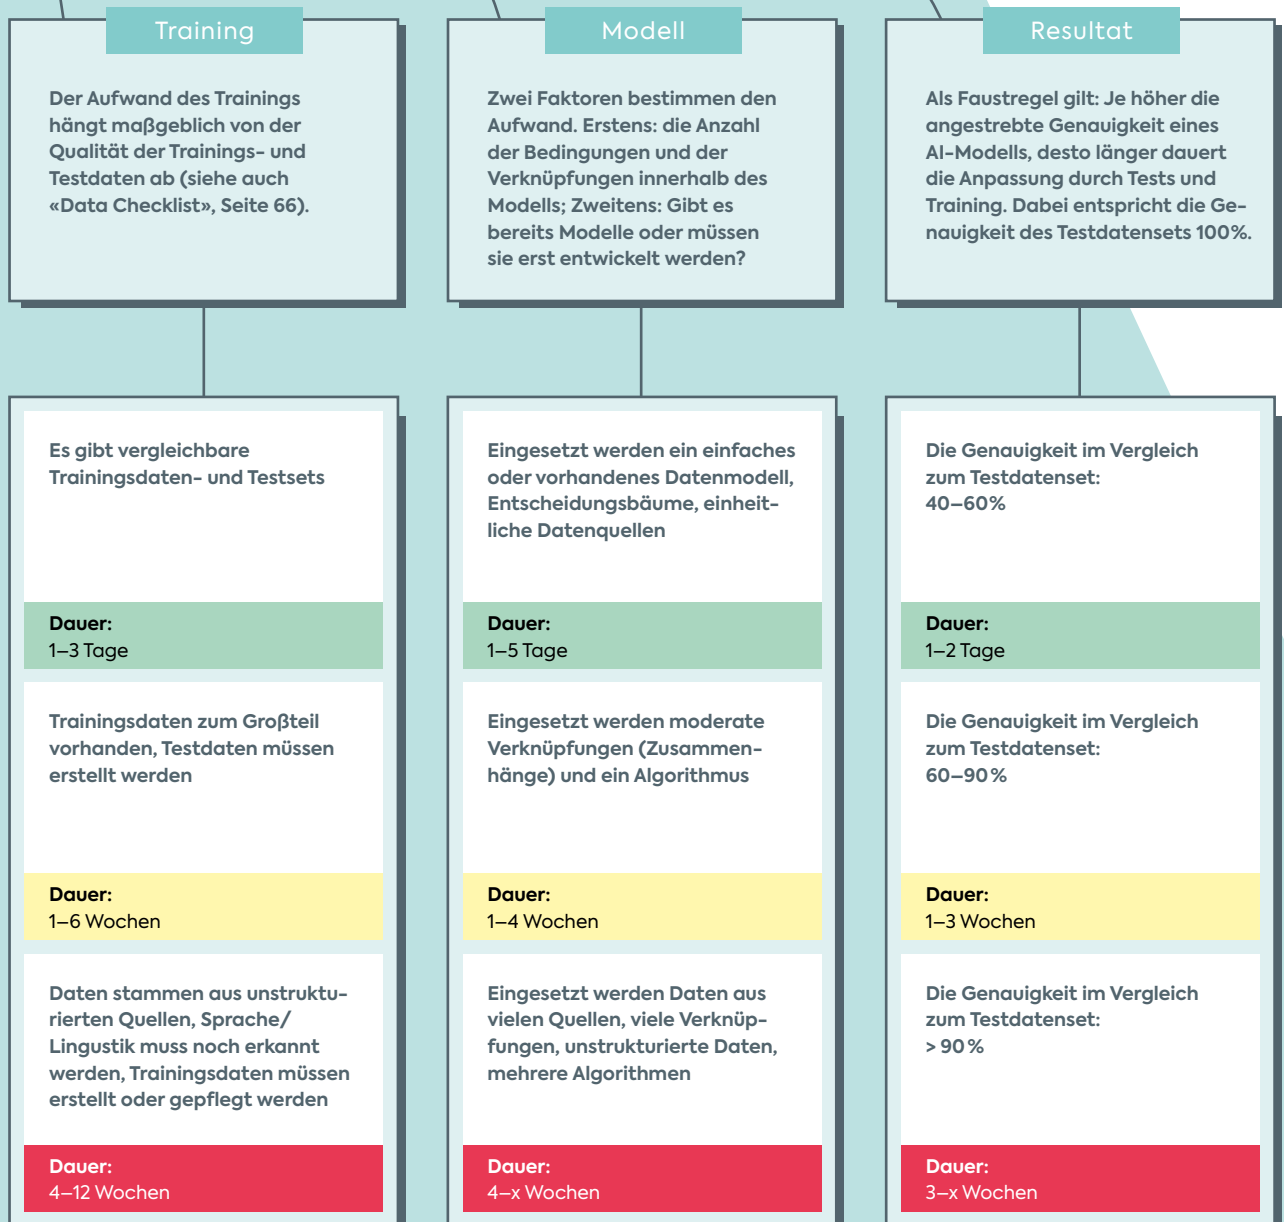
Dauer für die Vorbereitung der digitalen Infrastruktur: 2–5 Tage

Mehrere Algorithmen werden eingesetzt, mehrere Aufgaben werden parallel gelöst


Dauer für Vorbereitung digitaler Infrastruktur: 1–4 Wochen

Massendaten und Echtzeitdaten sowie komplexe Algorithmen werden verwendet


Dauer für Vorbereitung digitaler Infrastruktur: 4–6 Wochen



Template



Entscheidung treffen
Business Check



Kriterien	ohne AI	mit AI
<div>1</div> <div>Personal (FTE)</div>		
<div>2</div> <div>Zeit</div>		
<div>3</div> <div>Kosten</div>		
<div>4</div> <div>Hürden</div>		
<div>5</div> <div>AI-Potenzial</div>		

Vorgehens- vergleich

Das Tool

Schritt für Schritt

Im Template «Business Check» stellen wir den Aufwand für unser Projekt nach klassischem Vorgehen dem Aufwand mit AI gegenüber. Wir sehen so auf einen Blick Stärken und Schwächen der beiden Wege. Die Leitfragen helfen dabei, den Vergleich durchzuführen.

- 1 Personal:** Fehlen spezielle AI-Fähigkeiten? Brauchen wir Trainings/Fortbildungen? Brauchen wir Berater oder neue Mitarbeiter?
Falls neue Mitarbeiter benötigt werden, geht der Faktor in Personal und Kosten auf.
- 2 Zeit:** Wie lange brauchen wir für die Einrichtung der Infrastruktur (kann intern und extern sein)?
Wie lange braucht die Datenbeschaffung und -aufbereitung (für die komplette Data Journey?)
Wie lange dauert das Training?
Eine grobe Einordnung der Aufwände bietet der Time Calculator auf Seite 104–105.
- 3 Kosten:** Zu beziffernde Faktoren sind unter anderem Workshops, Fortbildung Datenbeschaffung und -aufbereitung Machine Training, kostenpflichtige AI-Frameworks/Plattformen.
- 4 Hürden:** Gibt es erwartbare Probleme organisatorischer, strategischer oder politischer Art? Ist der Datenschutz gewährleistet? Müssen ethische Fragen geklärt werden? Sind die Kosten vertretbar – oder sind sie hoch und müssen durch andere Vorteile gerechtfertigt sein? Gibt es nicht zu bewältigende Engpässe im Bereich Personal?
- 5 AI-Potenzial:** Aspekte sind hier unter anderem Technologieführerschaft, Wettbewerbsvorteile (USP), First-of-a-kind-Produkte, Time-to-Market, höhere Qualität von Ergebnissen, automatisierte Individualisierbarkeit meiner Produkte/Services und Kostenersparnis durch Automatisierung.

Schulbeispiel



Entscheidung treffen Business Check



Kriterien	ohne AI	mit AI
1 Personal (FTE)	4 Rechterspezialisten 1 Datenvisualisierungsexperten 1 Projektleiterin	Hackathon mit AI-Spezialisten 1 Projektleiter mit AI-Projekterfahrung
2 Zeit	1 Monat Vorbereitung Projektmanagement 1 Monat Interviewpartner-Rekrutierung 3–4 Monate Recherchephase	1 Monat Vorbereitung Projektmanagement 1–2 Wochen Durchführungszeit
3 Kosten	Mittel – hoch	Mittel
3 Hürden	Ungenaue Erhebungsergebnisse Möglicherweise keine Unfälle während der Recherchephase Menschlicher Bias durch qualitative Recherche Hohe laufende Kosten	Projektleiter nötig, der sich mit AI auskennt Wenig Expertise im Team Möglicherweise nicht genügend maschinenlesbare Datenquellen verfügbar, die als Input dienen können Hohe Initialkosten
4 AI-Potenzial	Erfahrungssammlung für zukünftige AI-gestützte Innovationsprojekte Höhere Genauigkeit der Ergebnisse Kostenersparnis durch Automatisierung Projekt erweiterbar auf Europa und die Welt Sichere Schulwege, weniger Unfälle	


Das Schulbeispiel

Das ausgefüllte Template deckt auf einen Blick die Stärken und Schwächen beider Lösungswege auf.

- 1 Das klassische Vorgehen benötigt mehr **Personal und mehr Zeit**, um die Aufgabe durchzuführen als eine AI-Lösung. Das Projekt ließe sich zwar schneller durchführen – aber nur indem mehr Mitarbeiter für die Recherche eingesetzt werden.
- 2 Die **Kosten** sind vergleichsweise ähnlich – sie bestehen beim Vorgehen ohne AI vor allem aus Honoraren und Gehältern. Wir haben das Glück, dass wir größtenteils kostenlose Daten und Open Source Frameworks nutzen können. So bleiben die Kosten für AI niedrig. Es bleiben Ausgaben für AI-Experten und Hackathons zur Entwicklung eines Prototyps.
- 3 Die **Hürden** geben uns weitere Argumente für die Entscheidung: Wir sehen, dass beim Vorgehen ohne AI die Qualität des Ergebnisses gemessen am Aufwand eventuell nicht ausreicht und dass laufende Kosten drohen. Beim Vorgehen mit AI droht eventuell ein Engpass bei der Datenbeschaffung – was zu höherem Zeitaufwand und höheren Kosten führen kann.
- 4 Die **Potenziale** liegen beim Einsatz mit AI vor allem in der höheren Genauigkeit (Stichwort: evidenzbasiertes Entscheiden) und im Erfahrungsgewinn. Und: Der Algorithmus kann auch in anderen Regionen angewandt werden. Die Kostenersparnis existiert zwar, fällt aber vergleichsweise niedrig aus – daher müssen andere Aspekte den Ausschlag für AI geben.

Entscheiden

Die Grundlagen



**Grundsätzlich gilt:
Ohne Geschäftswert
geht nichts.**

Aufwand und Risiken

Geschäftswert und Ergebnisqualität

Nun ist es so weit. Wir sind am Ziel. Alle Daten erhoben, alle Wege ergründet. Auf der Basis des bisher ausgefüllten AI Planners bereiten wir die Entscheidung vor. Dazu betrachten wir die Kriterien Geschäftswert/Ergebnisqualität und Aufwand/Risiko. Ist ein Projekt zu aufwendig oder riskant, sollte für eine Umsetzungsentscheidung daraus auch ein entsprechend hoher Geschäftswert resultieren. Das kann eine bestimmte Umsatzerwartung sein, oder auch die strategische Bedeutung.

In beide Kriterien fließen die Überlegungen und Recherchen ein, die wir im «Business Check» geprüft haben. Wir nutzen dazu die «Decision Matrix». Je nachdem, in welches Feld unser Projekt eingeordnet wird, lautet die Entscheidung im Extremfall «Nichts wie ran» oder «Auf keinen Fall».

Die Matrix hilft, sich schnell darüber klar zu werden, ob AI-Systeme helfen werden – oder nicht. Wir betrachten die im «Business Check» erhobenen Argumente nun noch einmal kritisch bezüglich der Risiken und des Aufwands für das Projekt. Das können Ungewissheiten bei der Umsetzung sein, weil Teile des Algorithmus erst noch erfunden werden müssen (Risiko des Scheiterns) oder erheblicher Zeit- und Personaleinsatz für die Datenaufbereitung nötig ist.

Wir wägen ab, ob die Hürden oder die Potenziale bei unserem AI-Projekt mehr Gewicht haben. Wir betrachten hier bewusst beide Informationen. Es kann sein, dass der Aufwand zwar gering ist, das Risiko des Scheiterns aber hoch – oder umgekehrt. Beide Werte sind jedoch wichtig für die Entscheidung. Risiken gibt es nicht nur bezogen auf Reputation oder Geldvernichtung, sondern auch auf Engpässe – es kann beispielsweise schwierig sein, die richtigen AI-Experten zu finden. Risiken können aber auch nicht existierende interne Prozesse sein.

Kommen wir zur Haben-Seite. Was bekommen wir als Gewinn aus unserem AI-Projekt? Gibt es einen hohen strategischen Wert, der das Unternehmen in den Augen der Kunden attraktiver macht und sich auch auf andere Leistungen auswirkt? Oder gibt es die Möglichkeit, aus kleinen Projekten eine Menge wertvoller Lernerfahrungen zu sammeln? Vielleicht ist es ohnehin strategisches Ziel, neue Technologien zu

erschließen. Es ist wichtig zu verstehen, dass der Geschäftswert sowohl materiell als auch immateriell betrachtet werden sollte.

Auch die Ergebnisqualität ist ein wichtiger Aspekt, der hier in die Beurteilung einfließt. Werden unsere Abläufe besser, schneller, präziser? Steigt die Qualität unserer Produkte oder Services? Wir fragen uns noch einmal nüchtern, worin genau der Vorteil für unser Unternehmen besteht – und wie groß dieser ausfällt.

Change Management

Die Visualisierung unseres Projekts (und im nächsten Schritt künftiger weiterer AI-Projekte) im AI Planner hilft uns dabei, zu entscheiden, ob wir den Schritt in die Welt der Künstlichen Intelligenz wagen wollen oder nicht. Die detaillierte Aufbereitung der Ergebnisse hat aber auch noch einen weiteren Zweck: Sie hilft dabei, die Transparenz der Entscheidungsfindung zu wahren und bei der internen Kommunikation zu helfen.

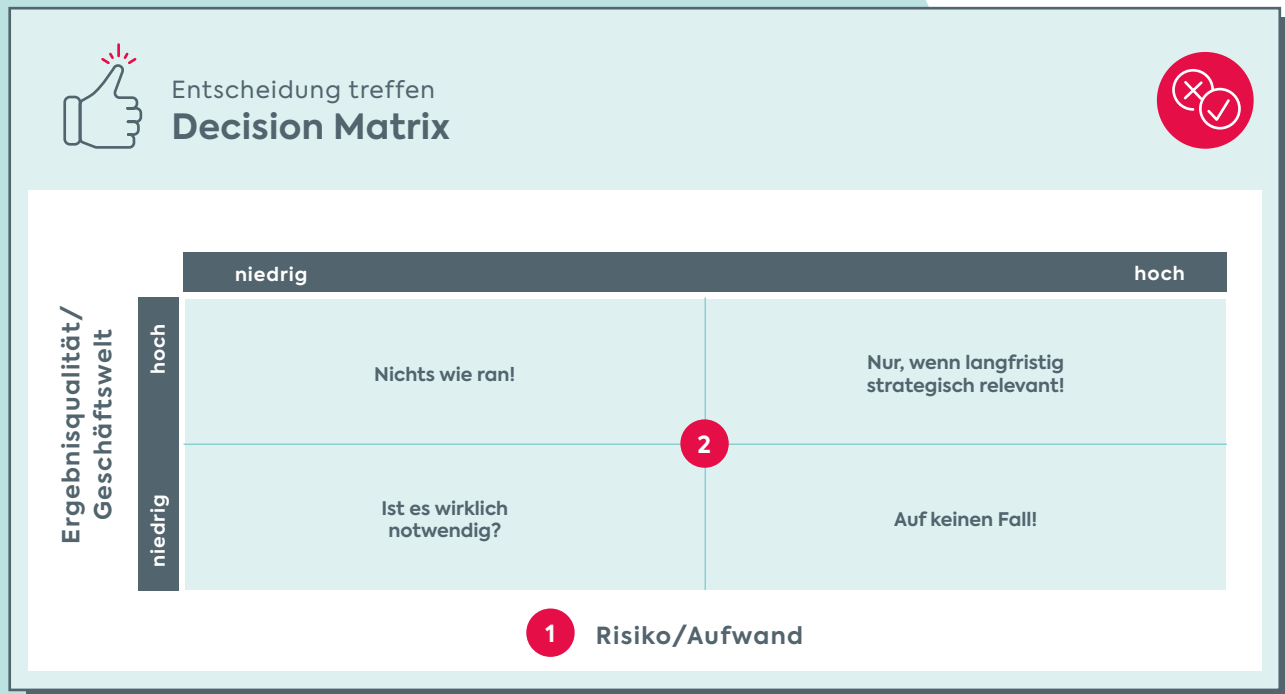
Der systematische Einsatz von maschinellem Lernen kann dazu führen, dass gezielt auch Change Management betrieben werden muss. Denn enthusiastische Technologiebefürworter sind wohl die Triebfedern des Fortschritts, erfahrungsgemäß überwiegt aber die Gruppe der Bewahrer. Eine transparente Argumentationskette und Darstellung des Mehrwerts für Mitarbeiter und Unternehmen helfen daher sowohl bei der internen Diskussion als auch bei der Kommunikation nach außen.



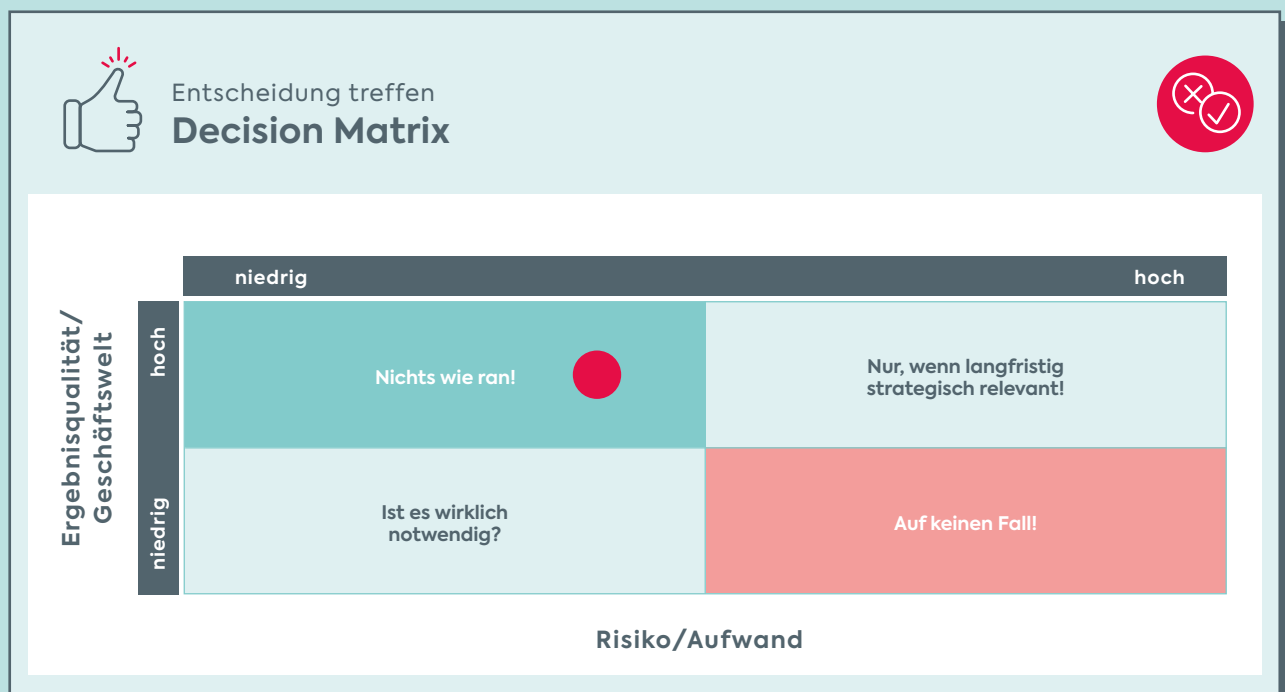
Werte haben viele Gesichter

Wer sich näher mit Innovation auseinandersetzt, erkennt schnell: Erfolg handelt zwar oft, aber nicht immer von Geld. Sehr wertvoll kann Erkenntnis sein – über Sackgassen, Kundenverhalten. Oder neue Fähigkeiten, die in anderen Projekten nützlich sind.

Template



Schulbeispiel



Entscheiden

Das Tool

Schritt für Schritt

Die «Decision Matrix» stellt die Ergebnisqualität und den zu erwartenden geschäftlichen Mehrwert dem mit dem AI-Projekt verbundenen Risiko und dem Aufwand gegenüber.

1

Für die Einordnung in der Matrix stellen wir die Ergebnisse nun in den Kontext unseres Unternehmens oder unserer Organisation und diskutieren mit den Projektsponsoren folgende Fragen:

Passen **Aufwand und Ergebnis** zu unseren übergeordneten Zielen?

Ist der **Mehrwert** für unser Geschäft so hoch, dass sich die Investition für uns lohnt?

Gibt es im **Umfeld** unseres Unternehmens Einflüsse, die uns zwingen, schnell zu automatisieren?

Ist das Projekt **strategisch** von hohem Wert?

Wie hoch ist das **Risiko** des Scheiterns?

2

Wir fassen das Ergebnis unseres Brainstormings in der Matrix zusammen, indem wir das Projekt in eines der vier Felder einordnen.

Das Schulbeispiel

Heureka! Die Entscheidungsmatrix für unser Beispiel zeigt ganz klar auf «Nichts wie ran». Anders hätten wir aus dramaturgischen Gründen natürlich auch nicht entscheiden dürfen.

Doch Hand aufs Herz: Wer sich eine deutschlandweite Interview- und Beobachtungsreihe durch klugen Algorithmus-Einsatz sparen kann – wer würde da nicht zugreifen.



1. Ziel definieren

AI-Mehrwert

Auftrag

Führt der Elterntaxi-Verkehr zu mehr Staus und Unfällen mit Kindern vor Schulen?

Erwarteter Mehrwert durch AI

Durch Erhebung, Analyse und Auswertung von Daten detaillierte bundesweite Recherche statt Stichproben, außerdem Zeitersparnis, höhere Qualität.



2. Daten recherchieren

Datenquellen

	Typ	Quelle	Warum?
A	Schulstandorte	govdata.de	Verbindung zu Staus vor Schulen
B	Verkehrsdichte	Google Maps Traffic Layer	Zeigt Staus an
C	Unfallstatistik	Schüler-Unfallversicherung	Beleg für Gefährdung
D	Unfallberichte der Polizei	interne Unfalldatenbank	Beleg für Gefährdung

Challenge

Führt der Elterntaxi-Verkehr zu mehr Staus und Unfällen mit Kindern vor Schulen?
Eine dreimonatige, bundesweite AI-basierte Erhebung, Analyse und Auswertung von Daten soll Klarheit über die Problemlage verschaffen.

Datenprüfung

	Priorität	Beschaffung	Technik
A	hoch ●	niedrig ●	niedrig ●
B	hoch ●	niedrig ●	niedrig ●
C	hoch ●	mittel ●	hoch ●
D	hoch ●	hoch ●	hoch ●

Output

Erkennen ☒
Vorhersagen ☐
Erzeugen ☐

Outputformat

Interaktives Statistik-Chart aller tatsächlichen Unfälle mit Kindern zu relevanten Stoßzeiten über den Verlauf von 5 Jahren.

Datenerhebung

Grund für die Datensammlung

Lokaler Bezug Stau/Unfall
Check, ob Staus existieren
Beleg für Gefahr
Beleg für Gefahr

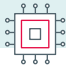
Daten-typen



Schulstandorte
Verkehrsdichte
Unfallstatistik
Unfallberichte Polizei

Priorität ● ● ● ●
Beschaffung ● ● ● ●
Technik ● ● ● ●



3. Lernkonzept erstellen


Maschinenfähigkeiten 		
Aufgabe	Quelle	Fähigkeit
A Relevante Schulen gruppieren	govdata.de	Daten gruppieren, lernen mit vielen Daten
B Korrelieren von Schule/Stau	Google Maps Traffic Layer	Daten gruppieren, Infos extrahieren
C Korrelieren von Schule/Stau/Unfall	Unfalldaten Versicherung	Erkenntnisse ergänzen, lernen mit vielen Daten
D Korrelieren von Schule/Stau/Unfall	Unfalldaten der Polizei	Erkenntnisse ergänzen, lernen mit vielen Daten

Trainingsparameter 	
Menschlicher Maßstab 4 FTE, 100 Termine in 25 Städten in 3 Monaten.	Minimalanforderung Auswertung > 40% aller Schulstandorte, Verkehrsdaten und Unfälle; Zeitraum 5 Jahre.
Erwünschtes Zielmaß Auswertung > 60% aller Schulstandorte, Verkehrsdaten und Unfälle; Zeitraum 5 Jahre.	Mindestvertrauen 75% der Schülerunfälle vor Schulen werden identifiziert.
	
Recall	Precision



4. Entscheidung treffen

Vorgehensvergleich 		
	Ohne AI	Mit AI
Personal	5 Mitarbeiter, 1 Projektleiterin	Hackathon, 1 Projektleiter
Zeit	2 M Vorbereitung, 3–4 M Recherche	1 M Vorbereitung, 1–2 W Durchführung
Kosten	Mittel – hoch	Mittel
Hürden	Ungenauigkeit, Bias, hohe Kosten	Wenig Expertise, wenig Daten, hohe Kosten
AI-Potenzial	Mehr Qualität, Skalierbarkeit, Erfahrung	

Entscheiden 	
Ergebnisqualität/ Geschäftswert	Nichts wie ran!
	Nur wenn langfristig strategisch relevant
Ist es wirklich notwendig?	Auf keinen Fall!
Risiko/Aufwand	

Die Ergebnisse

Ausgefüllt dient der AI Planner als Dokumentation für unsere Recherche. Wir können mit den Ergebnissen souverän die Diskussion mit unterschiedlichen Stakeholdern führen. Mit Projektsponsoren, Datenwissenschaftlern, Mitarbeitern. Wir können Entscheidungen transparent nachvollziehen und begründen. Eine gute Grundlage für Vertrauen.



Die Lösung komplexer Probleme benötigt immer mehr Zeit und immer mehr kluge Köpfe. Um drängende Menschheitsfragen beantworten zu können, brauchen wir die Fortschritte in Künstlicher Intelligenz. Zünden wir den Innovationsturbo.

Fazit

Nun wollen wir
springen

Es ist vollbracht. Wir haben unser Handwerkszeug kennen- gelernt. Wir wissen, welche Elemente ein AI-Projekt benötigt, können grob einschätzen, wie viel Aufwand hinter welcher Aktion steckt und haben eine Idee davon entwickelt, wozu Machine-Learning-Modelle fähig sind.

Wie immer beim Lernen, ist das Handwerkszeug erst der Anfang. Nun wollen wir Springen, unsere ersten Versuche machen und ausprobieren, wie unterschiedlich sich der AI Planner anwenden lässt.

Die folgenden beiden Kapitel «Springen» und «Sicher landen» sind daher voll und ganz der Praxis gewidmet. Wir springen und lernen dabei unterschiedliche Varianten kennen, wie maschinelles Lernen im Innovationsprozess helfen kann. Den Innovationsprozess nehmen wir als Beispiel, weil er uns als leidenschaftlichen Innovatoren besonders am Herzen liegt. Hier können wir kleine und große Anwendungsfälle kennenlernen. Wir werden sehen, wie einfach es ist, Trends automatisiert zu analysieren, die besten Ideen für Projekte aus großen Wettbewerben zu identifizieren oder automatisch neue Designvorschläge von der Maschine serviert zu bekommen.

Innovation
revolutionieren

**Es ist Zeit, den Innova-
tionsprozess selbst ins
Maschinenzeitalter zu
bringen.**

Das Besondere aber ist: Wir werden entdecken, dass die Art und Weise von Innovation selbst radikal verbessert werden kann. Es ist Zeit für einen Durchbruch; es ist Zeit, den Innova- tionsprozess selbst ins Maschinenzeitalter zu bringen. Denn die zu lösenden Aufgaben werden immer komplexer, der Auf- wand, sie zu bewältigen immer größer, bei sinkender Effizienz. Um auch die großen Menschheitsfragen beantworten zu können, muss der Innovationsprozess schneller werden. Und das geht in vielen Fachgebieten nur noch mithilfe der Fort- schritte bei der Künstlichen Intelligenz.

Springen wir also gemeinsam und lernen alles, was für einen eleganten Flug und eine sichere Landung nötig ist.



Springen

Wie Sie mit
AI arbeiten
können





*Wir müssen lernen, auch dort, wo wir
auf das Bauchgefühl vertrauen, Fak-
ten einzusetzen und Entschei-
dungen evidenzbasiert
zu treffen.*

Recode Innovation

Springen bewirkt
Veränderung

**50 Jahre Forschung
auf wenige Wochen
komprimiert.**

Extrem
schwierige
Aufgaben

«It will change everything». Mit dieser Titelzeile verkündete das angesehenen Wissenschaftsmagazin *Nature* am 30. 11. 2020 eine Sensation, geeignet, «die Welt der Biologie zu revolutionieren». Der Google-Tochter DeepMind war gelungen, woran Wissenschaftler seit 50 Jahren arbeiten: eine Methode zu finden, um die räumliche Struktur von Proteinen schnell und zuverlässig zu entschlüsseln. Gelungen ist ihnen das mit einem AI-Modell, das ursprünglich das Brettspiel Go und andere Spiele erlernt hatte – und schließlich den Weltmeister im Go besiegen konnte.

Vier Jahre hat das Team um die Google-Forscher Andrew Senior, John Jumper, Denis Hassabis und Pushmeet Kohli für die Entwicklung und das Training des Modells hinter *Alpha Fold* benötigt. Nun ist es in der Lage, innerhalb von Tagen eine Proteinstruktur abzubilden.

Proteine sind die Arbeitswerkzeuge des menschlichen Körpers. Sie transportieren Stoffwechselprodukte, leiten Signale weiter, ermöglichen die Bewegung von Zellen und vieles mehr. Sie bestehen aus Tausenden Bausteinen in unterschiedlichen Variationen. Ihre räumliche Struktur bestimmt, welche Fähigkeiten sie haben – und wie sie mit anderen Proteinen interagieren können.

Daher ist es zum Beispiel für die Produktion von Arzneimitteln gegen Viren entscheidend, deren Proteinstrukturen zu kennen. Denn nur dadurch erklärt sich, wie zum Beispiel bei Sars-CoV-2 die Vermehrung des Virus funktioniert. Die Struktur zu ermitteln kostet bei unbekannten Proteinen Monate oder sogar Jahre. Da Sars-CoV-2 mit dem bereits gut erforschten SARS-Virus verwandt ist, brauchten mehrere Forscherteams rund um den Globus nur vier Wochen. In dieser Zeit steckten sich jedoch bereits über 73 000 Menschen mit dem neuen Virus an. Und erst mit der Kenntnis der Proteinstruktur konnte die Suche nach einem potenziellen Wirkstoff beginnen.

Das Beispiel illustriert, mit welcher Art von Problemen wir es heute im Zusammenhang mit Innovation wirklich zu tun haben. Der rasante Fortschritt des vergangenen Jahrhunderts führt dazu, dass wir mit extrem schwierigen Aufgaben konfrontiert sind. Die Komplexität hat teilweise einen Grad erreicht,

dass neue Erkenntnisse nur noch durch massiven Einsatz von Forschungsleistung auf globaler Ebene erreichbar sind. Um dem Geheimnis der Gravitationswellen auf die Spur zu kommen, war ein über tausendköpfiges Forscherteam notwendig.

Eine noch größere Herausforderung ist der Klimawandel. Hier sind die zu lösenden Aufgaben zwar nicht so schwierig – dafür ist die Komplexität der Zusammenhänge extrem hoch. Die Vereinten Nationen haben 17 Ziele definiert, die erreicht werden müssen, um dem drohenden Kollaps unserer Umwelt entgegenzuwirken, aufgeteilt in 169 Einzelziele.

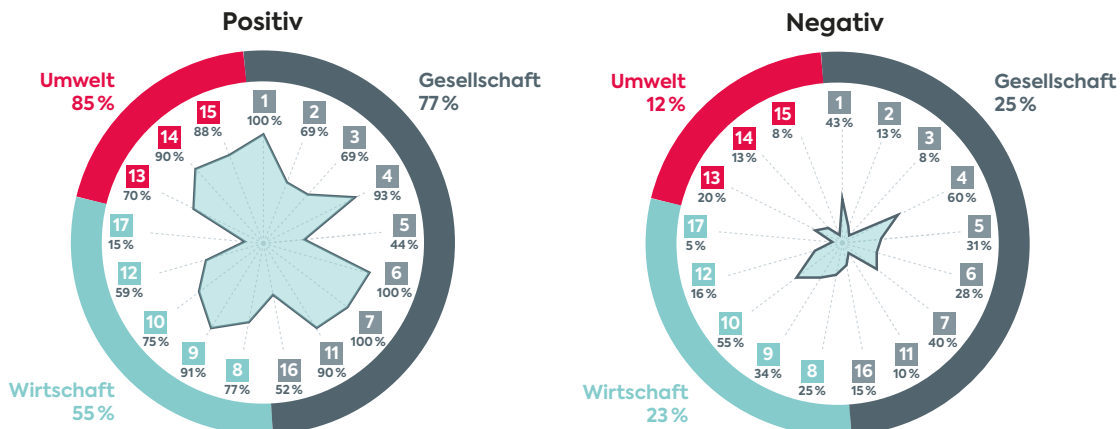
Agenda 2030

Wertvoller Helfer

Die Netzdiagramme (türkis) zeigen, in welchem Ausmaß (in Prozent) AI helfen kann, eines der 17 Nachhaltigkeitsziele zu erreichen (links) oder dieses Ziel eher behindern (rechts). Der Ring fasst die Einzelwerte für die Ziele innerhalb der drei Gruppen Umwelt, Gesellschaft und Wirtschaft zusammen.

Quelle: *Nature Communications* 11, 233 (2020)

Dieser Kampf wird in vielen Bereichen gleichzeitig geführt, grob eingeteilt in Umwelt, Gesellschaft und Wirtschaft, verankert in der Agenda 2030 der Vereinten Nationen. Dazu gehören beispielsweise: «Nachhaltig produzieren und konsumieren», «Weltweit Klimaschutz umsetzen», «Armut in jeder Form und überall beenden», «Hochwertige Bildung weltweit» sowie «Nachhaltig wirtschaften als Chance für alle». Eingebettet in diesen ökologischen und gesellschaftlichen Kontext gibt es aber auch das Ziel, «intelligente Innovationen, moderne Infrastrukturen und eine leistungsfähige Industrie» zu kreieren. Denn: Nachhaltiges Wirtschaftswachstum, nachhaltige Produktion, nachhaltige Städte und nachhaltige Bildungs- und Gesundheitssysteme sind ohne den Faktor Wirtschaft nicht realisierbar.



Innovationen neu definieren

**134 Einzelziele
werden durch AI
schneller erreichbar.**

Als Innovatoren sehen wir die Arbeit am Fundament einer im Sinne der Nachhaltigkeitsziele erfolgreichen Wirtschaft als entscheidenden Erfolgsfaktor für eine lebenswerte Zukunft an. Es geht darum, Innovation neu zu definieren – Künstliche Intelligenz, verbunden mit anderen Hochtechnologien, spielt bei diesem Ansatz eine entscheidende Rolle.

In welchem Ausmaß das möglich ist, zeigt die Untersuchung eines Wissenschaftlerteams des KTH Royal Institute of Technology in Stockholm. Die Forscher untersuchten, wo Methoden der Künstlichen Intelligenz die 169 Einzelziele aus dem Spektrum der 17 Nachhaltigkeitsziele sinnvoll unterstützen können.

Das Ergebnis: 134 der Einzelziele sind mit Unterstützung von Anwendungen aus dem Gebiet der Künstlichen Intelligenz entweder schneller oder in höherer Qualität erreichbar.

Künstliche Intelligenz kann zum Beispiel helfen, das Problem der unterschiedlichen Verfügbarkeit von regenerativen Energieträgern zu lösen – indem Angebot und Nachfrage in sogenannten Smart-Grid-Systemen effizienter ausbalanciert werden. Sie kann dabei helfen, Rohstoffe in Müll besser zu identifizieren, komplexe Simulationen für die Analyse von Lebenszyklusszenarien neuer Produkte durchzuführen und vieles mehr.

Wir sehen: Die Zahl der zu bewältigenden Aufgaben wächst kontinuierlich und ebenso das Niveau der Komplexität. Zu allem Überfluss beobachten wir auf der Seite derer, die die Probleme seit Jahren lösen sollen, dass die Innovations-effizienz – das ist der Output an Innovationsleistung gemessen an der Zahl der beteiligten Innovatoren – seit Jahren abnimmt. Auch die Innovationsfähigkeit sinkt langsam, aber stetig – aller modernen Methoden und Ansätze zum Trotz. Zwar liegen die westlichen Länder in Europa und den USA noch ganz vorne in den Innovationsrankings, doch ein Blick hinter die aggregierten Zahlen offenbart schnell, dass das Fundament der Innovationsfähigkeit bröckelt. Das Weltwirtschaftsforum untersucht alle zwei Jahre die Innovationsfähigkeit der Länder weltweit und betrachtet dabei 109 Faktoren. Dazu gehören bürokratische und rechtliche Hürden, Effizienz der Infrastruktur, von Logistik bis Internet, die Verankerung unternehmerischer Qualitäten und vieles mehr.

Bei 54 der 109 Faktoren verzeichnete das WEF einen Rückgang zur Vorjahresuntersuchung, nur bei 19 eine Verbesserung.

Höchste Zeit also, Innovation auf vielen Ebenen zu verbessern. Wir müssen Wissen besser verfügbar und auswertbar machen. Wir müssen die ursächlichen Gründe für Probleme besser verstehen, um nachhaltig wirksame Lösungen zu entwickeln. Wir benötigen schneller unkonventionelle Konzepte, um technologische Durchbrüche zu erreichen.

Next Level

Wir müssen lernen, auch dort, wo wir auf das Bauchgefühl vertrauen, Fakten einzubeziehen und Entscheidungen evidenzbasiert zu treffen.

Um all dies zu erreichen, wollen wir das Innovieren auf eine neue Stufe heben. Auch aus diesem Grund haben wir den AI Planner entwickelt. Er soll möglichst vielen Menschen helfen, einen Zugang zur sinnvollen Nutzung von Künstlicher Intelligenz zu bekommen, und er soll die Hemmschwelle senken, sich mit diesem Thema überhaupt auseinanderzusetzen.

**Der AI Planner
verschafft Menschen
Zugang zur sinnvollen
Nutzung von Künst-
licher Intelligenz.**

Die genannten Probleme und Innovationsherausforderungen sind zum Teil so groß, dass sie nicht mit einem einzelnen Projekt gelöst werden können. Es ist auch nicht so, dass jedes Problem geeignet ist, um mit AI-Hilfe angegangen zu werden. Zahlreiche Aufgaben können Menschen schlicht schneller und besser erledigen, als es Algorithmen vermögen.

Ziel dieses Kapitels wird es daher sein, zu lernen, wann maschinelles Lernen einen sinnvollen Mehrwert liefert – und wann es eher der Mensch ist, der sich mit einer Aufgabe befassen sollte. Daher reflektieren wir am Ende jeder Aktion im AI Planner, ob es sinnvoll ist, das AI-Konzept weiter auszuarbeiten.

Diese Bewertung muss zwingend in jedem AI-Projekt unternommen werden, und es lohnt sich auf jeden Fall, hier immer mit einer gewissen gesunden Skepsis vorzugehen.

**Auch AI-Modelle
machen Fehler -
insofern sind sie
sehr menschlich.**

Der Begriff «Künstliche Intelligenz» suggeriert zu sehr, dass hier Intelligenz im menschlichen Sinne im Spiel ist. Das ist jedoch nicht der Fall. Wir sprechen von Computerprogrammen, die in diesem Fall erlernten Routinen folgen. Sobald die Situationen, in denen sie arbeiten, vom erlernten Rahmen abweichen, passieren Fehler. Dann rammt ein autonom fahrender Tesla plötzlich einen großen weißen Lkw. Oder ein Muffin wird als Katze identifiziert. AI-Modelle machen Fehler – in dieser Hinsicht sind sie also sehr menschlich. Fehler bedeuten in diesem Zusammenhang: Die Ergebnisse sind immer nur zu einem bestimmten Prozentsatz richtig, je nach Trainingsintensität. Die Frage ist daher bei jedem AI-Projekt aufs Neue: Können wir damit umgehen und macht das AI-Modell weniger oder weniger gravierende Fehler als ein Mensch?

Diese Abwägung müssen wir immer treffen, wenn wir AI-Anwendungen einsetzen. Auch in unserem Innovationsalltag werden wir mit einer Fülle von schwierigen Aufgaben konfrontiert. Sie erfordern einerseits viele repetitive Tätigkeiten, wie es im Rahmen der Analyse von Nutzerbedürfnissen der Fall ist, und erfordern andererseits kreative Leistung. Hier gilt es, die richtige Balance im Einsatz von Mensch und Maschine zu finden.

Um diese Abwägung und die anschließende Ausarbeiten von AI-Konzepten leichter nachvollziehbar zu machen, werden wir auf den folgenden Seiten wichtige sogenannte Jobs-to-be-done innerhalb der Innovationsarbeit vorstellen, die sich eignen, um einen AI-Ansatz in Erwägung zu ziehen.

Wo AI Innovatoren helfen kann

Vielfältige Einsatzbereiche

AI kann viele Aktivitäten im Innovations- und Entwicklungsprozess übernehmen.

Generell richtet sich die Innovationsarbeit nicht nach Funktionen im Unternehmen, sondern nach den Aufgaben, die nacheinander abgearbeitet werden müssen. Im Laufe der Jahrzehnte haben viele Experten unterschiedliche Modelle von Innovationsprozessen entwickelt. Egal, wie diese Prozesse ausgestaltet sind, sie sind sich bis heute in vielen Kernelementen ähnlich. Im Wesentlichen geht es immer darum:

1. **Opportunitäten** und **relevante Trends** identifizieren.
2. **Kunden- und Nutzerbedürfnisse** ermitteln, um festzustellen, ob es überhaupt einen Bedarf an Lösungen gibt.
3. Aus den gewonnenen Erkenntnissen **kreative Lösungen** entwickeln,
4. und diese letztlich über **Prototypen** testen, iterieren und das Geschäftsmodell ausarbeiten.

Wir stellten fest, dass sich die Fähigkeiten lernender Systeme überraschend gut mit den oben beschriebenen Kernen der Innovation decken. Algorithmen können heute wahrnehmen, Entscheidungen treffen, Vorhersagen machen, Wissen extrahieren und Muster erkennen, interaktiv kommunizieren und logische Schlüsse ziehen. Alles Aktivitäten, die Innovatoren im Laufe eines Innovations- und Entwicklungsprozesses kontinuierlich tun müssen.

Es ist nahe liegend, zu überlegen, welche Teilaufgaben von Innovatoren sich für den Einsatz von AI-Modellen eignen. Wir haben uns gefragt: Welches sind die größten Schwierigkeiten, mit denen wir beim Innovieren immer wieder konfrontiert sind? Was nervt im Alltag besonders? Wo sind wir mit der Qualität der Lösungen unzufrieden?

Diese typischen Schmerzpunkte von Innovatoren haben wir mit AI-Experten diskutiert und daraus mithilfe des AI Planners Vorschläge entwickelt, um die Innovationsarbeit an bestimmten Stellen zu automatisieren.

So zeigen wir, wie man Trends mithilfe von AI auf die Spur kommen, Personas automatisch generieren kann oder auch bei der Entwicklung von Prototypen Unterstützung bekommt.

Jedes dieser Themen beschreiben wir ausführlich. Wir zeigen, warum Künstliche Intelligenz für den jeweiligen Zweck sinnvoll ist, und wo bei ähnlichen Fragestellungen bereits maschinelles Lernen eingesetzt wird. Schließlich zeigen wir exemplarisch, wie sich mit dem AI Planner Konzepte zu den jeweiligen Fragestellungen entwickeln lassen und worauf jeweils geachtet werden muss. Ein vollständig ausgefüllter AI Planner fasst die Beispiele übersichtlich und prägnant zusammen.

Auf diese Weise hoffen wir, dass die Vielfalt der Anwendungsmöglichkeiten deutlich wird und es beim Experimentieren mit dem AI Planner keine Berührungängste mehr gibt.



Die Vorlage

Wir haben den AI Planner und alle Templates für die folgenden sechs Beispiele im Online-Whiteboard zum Buch ausgefüllt:
aitoolbook.com/springen

1. Trends entdecken

«Wenn wir bloß wüssten, was wir wissen!» Dieser Stoßseufzer ist oft dort zu hören, wo es darauf ankommt, Wissen neu zu kombinieren. Seit Jahrzehnten versuchen Unternehmen – meist eher weniger erfolgreich –, das Wissen ihrer Mitarbeiter auffindbar zu machen. Es liegt verborgen in Köpfen, zeigt sich in Erfahrung, ist dokumentiert in zahllosen E-Mails, Dokumenten, Berichten, internen und externen Blogs, Vorträgen, Patentschriften – die Liste ließe sich endlos fortsetzen.

Das Wissen über neue Lösungen für Probleme liegt aber nicht nur im eigenen Unternehmen verborgen, sondern ist auch weltweit verteilt auf findige Gründer aus Forschung und Industrie. Diese Gruppe bekommt weltweit Milliarden an Kapital, nur um die Hoffnung von Investoren auf große Gewinne durch Innovationen zu befriedigen. Auch dieser Markt der Start-ups ist eine Quelle des Wissens.

Hinzu kommen die Social Media und Communitys, in denen Fachwissen und persönliche Befindlichkeiten ausgetauscht werden. Die Masse dieser Informationen lässt sich einerseits durch stete Onlinesuche und kontinuierlichen Austausch mit dem beruflichen Netzwerk sichtbar machen – wer hier routiniert ist, hat meist schnell einen guten Überblick über aktuelle Trends. Doch wer das nicht kontinuierlich tut, dem fällt schon die Recherche schwer.

Idealerweise beginnen wir damit, das, was wir suchen, systematisch zu erfassen und zum Beispiel in Form von Zusammenfassungen, in Trendlandkarten oder ähnlichen Darstellungsformen zu dokumentieren.

Was kann AI
hier leisten?

Fußball- und Finanzberichte, Patentschriften und Rechtstexte für Anwälte werden bereits erfolgreich von automatischen Systemen nach den spezifischen Wünschen der Sportbegeisterten, Investoren und Anwälte durchsucht und zusammengefasst. Schon jetzt sind Maschinen die fleißigsten Leser und Leserinnen von Geschäftsberichten. Bei der US-amerikanischen Börsenaufsicht SEC haben Maschinen über 165 Millionen Mal innerhalb eines Jahres via elektronischer Schnittstelle auf deren Dokumente zugegriffen.

Kreativität braucht Impulse

**«Opportunities are
like sunrises.
If you wait too long,
you miss them.»**

William Arthur Ward

Für Innovatoren wären zum Beispiel regelmäßige Informationen zu Start-up-Ideen, neuen Technologien, Konsumentenbedürfnissen in ihren Märkten oder Wettbewerbsbeobachtung wichtige Informationsquellen.

Die besten Ideen fallen uns nicht ein, sondern auf. Die besondere Schwierigkeit bei der Entwicklung von Ideen ist, dass wir sehr viele Impulse aus sehr unterschiedlichen Quellen benötigen, damit unser kreativer Geist auf neue Ideen kommt. Wir müssen genau hinsehen, wo sich mögliche Chancen für uns ergeben.

In der Flut von Informationen in der heutigen Wissensgesellschaft ist es schwieriger denn je, den Überblick zu bewahren. Das Zeitfenster, um unsere Ideen zu platzieren, kann sich innerhalb von kürzester Zeit schließen, wie es der Schriftsteller William Arthur Ward beschreibt. «Opportunities are like sunrises. If you wait too long, you miss them.» Wenn wir überlegen, wie wir manuell nach Trends fahnden könnten, wird schnell klar: Der Prozess ist langwierig und komplex.

Wir müssen zunächst den Markt umfassend scannen, um uns einen Überblick zu verschaffen. Dann grenzen wir unser Suchfeld ein. Meist werden an diesem Punkt konkrete Themen festgelegt, die anschließend tiefergehend analysiert werden. Untermauert werden die gefundenen Informationen (sogenannte Signale) mit Expertenmeinungen oder durch quantitative Recherchen. Wir suchen potenzielle Themenfelder, die interessant sein könnten, grenzen sie ein und recherchieren dann in die Tiefe. In der Auswertung dieser Ergebnisse werden Signale zu Trends kombiniert und für die relevanten Stakeholder so übersetzt, dass sie für sie nutzbar werden. Das geschieht zum Beispiel in Form repräsentativer Bilder und Beschreibungen.

Gerade bei Recherchen kann die Maschine in Bezug auf die zu analysierende Menge und Geschwindigkeit herausragende Vorteile bieten. Bestimmte Muster in einer solchen Datenmasse zu erkennen, ist selbst für eine Armada an Trendforschern eine große Herausforderung. Hier wollen wir uns die Fähigkeiten der Maschine zunutze machen.

Szenario

Online-Fashionstore

Die Gepflogenheiten der Frühjahrs- und Herbstkollektionen in der Modebranche sind längst Geschichte. Angeheizt durch die Aktivitäten von Streetfashion-Blogs und Instagram-Profilen haben sich ganz neue Modelabels etabliert. Sogenannte Ultrafast Fashion Labels, wie Asos, spüren im Wochentakt Trends in den Social Media auf und passen ihre Kollektionen auf die neuesten Vorlieben und Szeneentwicklungen an: vom vermehrten Auftreten bunter Tigermuster auf T-Shirts in Szenevierteln und folglich auch auf Instagram und in anderen Online-Medien. Bis zum Angebot passender Taschen und Jacken in den Online-Shops der neuen Modelabels vergeht nur eine Woche.

Warum AI?

Wie also könnte eine schnellere Trendrecherche aussehen? Kann eine Maschine die klassischen Trendscouts ablösen? In unserem Szenario will ein Online-Modelabel für junge Frauen zum Trendsetter werden und im Wochentakt die Vorlieben der Zielgruppe aufgreifen, um nicht nur die trendigsten Kleidungsstücke anzubieten, sondern aufgrund sich ankündigender Trends diese auch durch die eigenen Designer selbst gestalten zu können. Die Herausforderung für das Team ist, wie datengestützte Trendrecherche dazu beitragen kann, die Zielgruppe besser zu verstehen und daraus die richtigen Schlüsse zu ziehen, mit der Erwartung, dass sie mithilfe von AI plötzlich aufkommende Trends identifizieren können, bevor sie sich in der breiten Masse durchsetzen.

Der AI-Ansatz

Das Besondere an diesem Szenario ist, dass hier User Generated Content in Echtzeit verarbeitet wird. Das sind Beiträge in Blogs und in den Social Media wie Instagram oder Pinterest. Weil Menschen ihre Bedürfnisse zu Mode und anderen Interessen häufig in den Social Media austauschen, lassen sich diese Informationen gut maschinell in einer Trendanalyse auswerten.





1. Ziel definieren

AI-Mehrwert



Auftrag

Echtzeit-Trendbeobachtung und Bewertung der Relevanz der Trends für unseren Women-Online-Fashion-Shop

Erwarteter Mehrwert durch AI

Umfassende datengetriebene Trendvorhersagen in Echtzeit, statt Stichproben. Dadurch höhere Aussagekraft und Objektivität der Ergebnisse.

Große Zeitersparnis

Komplexe Muster aufdecken durch «Big-Picture-Blick»

Challenge



Wie können wir Social Media für unsere Zielmärkte EMEA nutzen, um unserer internen Zielgruppe automatisiert einen Überblick der wichtigsten Fashion-Trends unter jungen Frauen für die nächsten zwei Wochen zu verschaffen?

Output



Erkennen



Vorhersagen



Erzeugen



Outputformat

(Echtzeit-)Trendclustermap und Bewertung der Relevanz für unsere weibliche Zielgruppe



2. Daten recherchieren

Datenquellen



Typ

Quelle

Warum?

A	Social Media Posts zu Mode und Stil	Instagram, Blogs (> 100 000 Follower)	Starker Einfluss auf unsere Zielgruppe
B	Expertenmeinung, Branchennews	Vogue.com fashionnetwork.com trendhunter.com	Reality Check, Check ML-Modell
C	Social Media Posts zu Farben und Materialien	Instagram (z.B. khromacolors, Pantone)	Farben und Material ergänzen Stil-Trends
D	Fashion-Online-Diskussion	thefashionspot.com youlookfab.com forum.glamour.de	Persönlicher Austausch über offene Wünsche

Datenprüfung



Priorität

Beschaffung

Technik

A	hoch	niedrig	niedrig
B	niedrig	mittel	mittel
C	hoch	niedrig	niedrig
D	mittel	niedrig	mittel

Datenerhebung



Grund für die Datensammlung

Stiltrends erkennen	Details zu Trends ergänzen	Wünsche der Nutzer erkennen	Verifikation AI-Modell
---------------------	----------------------------	-----------------------------	------------------------

Daten-typen

Social Media Posts: Fashion und Stil	Social Media Posts: Farben & Materialien	Fashion-Online-Diskussion	Expertenmeinungen, Branchennews
--------------------------------------	--	---------------------------	---------------------------------

Priorität

Beschaffung

Technik

hoch	hoch	mittel	niedrig
niedrig	niedrig	niedrig	mittel
niedrig	niedrig	mittel	mittel



3. Lernkonzept erstellen

Maschinenfähigkeiten		
Aufgabe	Quelle	Fähigkeit
A Stilmuster erkennen und Trends vorhersagen	Instagramprofile (> 100 000 Follower)	Objekte erkennen & gruppieren/ Vorhersagen
B Muster aufdecken, die auf unerfüllte Wünsche deuten	Vogue.com fashionnetwork.com trendhunter.com	Infos & Emotionen extrahieren/ Wissen kombinieren.
C Trends aus Farb- und Stilkombinationen ableiten	Instagram (z.B. khromacolors, Pantone)	Infos extrahieren/ Massendaten/ Auto-Weiterlernen
D Überprüfung erkannter Trends und Expertenmeinung	thefashionspot.com youlookfab.com forum.glamour.de	Infos & Emotionen extrahieren/ Massendaten



4. Entscheidung treffen

Vorgehensvergleich		
	Ohne AI	Mit AI
Personal	5 Researcher, Designer (Umsetzbarkeit), PL	DS, ML, Trend-Experte, Designer, PL
Zeit	1 M Initialrecherche, konstantes Screening	Ganzjähriges Markt-screening, Trendrecherche
Kosten	Mittel – hoch	Mittel
Hürden	Kognitive Grenzen, Bias, Geschwindigkeit	Expertise & Ressourcen, Trainingsaufwand
AI-Potenzial	Wettbewerbsvorteile, Präzision, Trendsetter	

Trainingsparameter	
Menschlicher Maßstab Auswertung 1000 Posts pro Woche; 95% Genauigkeit bei der Klassifikation von Trends	Minimalanforderung Angesagte Trends in Echtzeit anzeigen und kategorisieren
Erwünschtes Zielmaß 75% aller Profile analysiert und alle relevanten 5 Trends daraus abgeleitet haben	Mindestvertrauen 95% richtige Ableitung Stil- und Farbtrends (verifizierbar); 90% richtige Zuordnung, ob Trend
<div><div></div><div></div><div></div><div></div><div></div></div> <div>RecallPrecision</div>	

Entscheiden	
Ergebnisqualität / Geschäftswert	Nichts wie ran!
	Nur wenn langfristig strategisch relevant!
Ist es wirklich notwendig?	Auf keinen Fall!
Risiko/Aufwand	

Trends prognostizieren

Der ausgefüllte AI Planner zeigt die relevanten Informationen zu unserem Szenario eines Online-Modelabels für junge Frauen. Ausgewertet werden Inhalte, die modebewusste Nutzerinnen selbst veröffentlichen haben. Auf diese Weise können Hunderttausende Beiträge durchsucht und analysiert werden. Das Besondere ist, dass mit den gewählten

Maschinenfähigkeiten die gewählten Datenquellen kontinuierlich weiter durchsucht werden – und sich die Trendkarte mit der Zeit aktualisiert und neue Trends anzeigt. Das AI-Modell ist zunächst aufwendiger in der Umsetzung und daher nur sinnvoll, wenn das Projekt strategisch für das Unternehmen wichtig ist.

1



Ziel definieren AI Value Map

Der Auftrag

Echtzeit-Trendbeobachtung und Bewertung der Relevanz der Trends für unseren Women-Online-Fashion-Shop



Manuelle Projektschritte

Beschreibung

Studien, Reports, Branchennews, Foren und Websites analysieren

Social Media nach angesagten Themen durchsuchen

Expertenbefragungen durchführen

Trendsignale ableiten (Clustering der gesammelten Informationen)

Muster in Signalen herausarbeiten und zu Trends synthetisieren

Typische Pain Points

Hoher Zeit- und Personalaufwand, stichprobenhaft, Bias übersieht wichtige Quellen

Hoher Zeit- und Personalaufwand, stichprobenhaft, eingeschränkte Suchfunktionen

Hoher Zeitaufwand, persönlicher Bias, Menschen geben erwünschte Antworten

Hoher Zeitaufwand, unscharf persönlicher Bias, kurze Microtrends werden übersehen

Hoher manueller Aufwand, Zeitaufwand, Erfahrung nötig

Geschäftlicher Mehrwert durch AI

Zeitersparnis, höhere Qualität (Big-Picture-Blick), neue Infoquellen entdecken

Zeitersparnis, höhere Qualität, aufkommende Trends schneller entdecken

Bias-freie Ergebnisse

Zeitersparnis, höhere Genauigkeit, mehr Objektivität

Zeitersparnis, verborgene Muster erkennen: «Unfair Advantage» nutzbar machen

Hier kann AI unterstützen:



2



Ziel definieren Challenge Guide



Elemente

Herausforderungen

Social Media und andere Online-Medien nach angesagten Themen durchsuchen

Trendsignale ableiten und darin Muster erkennen

Nutzer/Zielgruppe

Innovationsdepartment, Marketing, Design Department, Business Development

Zusammenfassung

Wie können wir Social Media für unsere Zielmärkte EMEA nutzen, um unserer internen Zielgruppe automatisiert einen Überblick der wichtigsten Fashion-Trends unter jungen Frauen für die nächsten zwei Wochen zu verschaffen?

Geltungsbereich/ Umfang

EMEA, B2C, junge Frauen zwischen 16 und 32 Jahren

Zeitraumen

Trendanalyse: immer aktueller Input für zweiwöchige Prognose
Projektraumen: 3 Monate

Geschäftlicher Mehrwert durch AI

detaillierte weltweite Recherche statt Stichproben

Wie es geht

1. Ziel definieren

Um einzugrenzen, wo der beste Ansatzpunkt für AI ist, beginnen wir damit, zu analysieren, wie ein klassisches Research-Team vorgehen würde, und wo genau die Schwierigkeiten (Pain Points) liegen.

1

Die ausgefüllte AI Value Map zeigt: Recherche ist ein aufwendiger Prozess, der aus Suchen, Lesen und Inhalte analysieren besteht. Er kostet viel Zeit, vor allem das Herausarbeiten von Mustern unterliegt immer der Gefahr der Verzerrung, weil Quellen übersehen werden oder Muster in großen Datenmengen gar nicht erst entdeckt werden können.


Das Ergebnis der Mehrwertanalyse zeigt: Mit AI-Hilfe können wir Datensätze auswerten, die für die menschliche Recherche nicht ohne Weiteres nutzbar sind, beispielsweise umfangreiche Sammlungen mit Zehn- oder Hunderttausenden von Texten, oder Social Media Posts, die aufgrund eingeschränkter Suchfunktion kaum für Normalleser zugänglich sind. Dazu haben wir den Vorteil der unermüdlich 24 Stunden am Tag arbeitenden Software – so standhaft kann kein Researcher sein.

Für unsere Bedürfnisse eignet sich die Analyse von sogenanntem User Generated Content, also von Beiträgen in den Social Media oder Online-Foren, besonders gut. Dort spiegeln sich Nutzertrends am schnellsten. Daher wollen wir unsere AI-Recherche auf diesen Bereich konzentrieren.

2

Das Challenge Template zeigt nun, wie wir die Aufgabe eingrenzen: Interne und externe Einflussfaktoren der für uns relevanten Trends fließen in die konkrete Formulierung der AI-Challenge ein.

Ein Trendscout beschreibt mit Worten und Fotos, was er als Trend identifiziert hat. Das könnte das AI-Modell auch. Doch wir können auch mithilfe einer Trendcluster Map eine Gewichtung vornehmen. Auf der Karte werden die Stile, Farben und Muster durch Fotobeispiele visualisiert und nach Relevanz angeordnet und hervorgehoben.



Output definieren:
Trendcluster Map

2. Daten recherchieren

User Generated Content bezieht sich auf sehr unterschiedliche Datentypen. Ein Post besteht im Wesentlichen aus Bildern, Texten, Videos sowie Metainformationen, wie Datum, Hashtags, Likes. Diese Features lassen sich nutzen, um Erkenntnisse zu gewinnen und Trends zu identifizieren.

Aufkommende Kleidungsstile, Farb- und Musterkombinationen bei angesagten Influencern oder Plattformen zu entdecken ist an sich einfach. Spannend wird es, wenn wir berücksichtigen, was modebewusste Menschen über bestimmte Produkte in ihrem Netzwerk sagen. Das Kombinieren dieser beiden Perspektiven von Influencerinnen und persönlichen Meinungen sowie das Ableiten von Vorhersagen ist von Hand sehr schwierig und aufwendig. Aber nur so fließt die Konsumentenperspektive in die Trendanalyse ein.

1

So können wir das «Warum» eines Trends besser verstehen. Nachhaltigkeit als bekannter Megatrend zeigt sich zum Beispiel darin, dass Konsumenten darüber sprechen, wie sie selbst nähen, auf Chemikalien achten und vieles mehr. Das Thema trendet und bewegt auch den Markt, spiegelt sich in Modezeitschriften und Wirtschaftsnachrichten wider und schließlich in Angeboten von Mainstream-Labels.

2

Dieser Mechanismus muss verstanden sein, dann fällt es leicht, die Datentypen und -quellen zu suchen. Eine erste Orientierung bei der Suche nach Datentypen liefert das Data Directory (siehe «Einsteigen – Data Directory» auf Seite 66–69). Eine Google-Suche liefert konkrete Quelledetails.

Die Data Journey Map enthält nun die ausgewählten Datenquellen mit den Begründungen für ihre Wahl. Das Beispiel zeigt, wie ausgehend vom übergeordneten Trend immer mehr Detailinformationen ausgewertet und mit dem Gesamtbild verknüpft werden.

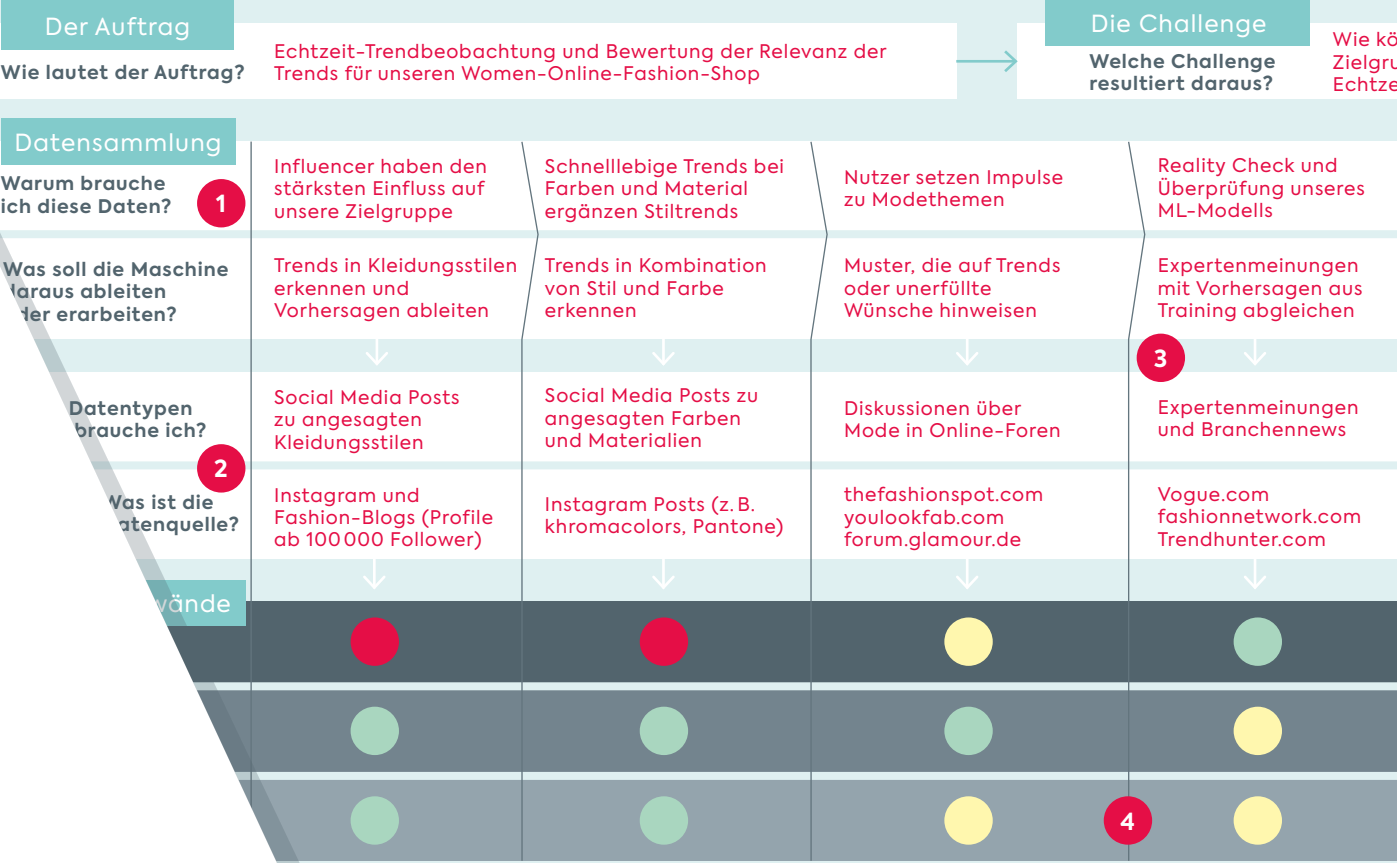
3

Wichtig ist der letzte Schritt: Beim Reality Check testen wir, wie gut die AI-Vorhersagen von Trends zutreffen. Dazu nutzen wir Aussagen von Experten aus der Modebranche oder den einschlägigen Magazinen und Plattformen. Diese Daten werden auch Testdaten genannt. Das Prinzip: Wir sammeln Daten von älteren Trendsignalen – das AI-Modell muss diese



Daten recherchieren

Data Journey Map



Trends erkennen –, und mit den Aussagen der Experten wird geprüft, ob der Trend richtig vorhergesagt wurde.

- 4 Gerade für die letzten beiden Aspekte, das Auswerten persönlicher Meinungen in Online-Diskussionen und die Expertenbewertung, ist der Aufwand höher. Denn in diesem Fall müssen die Daten noch umfassender aufbereitet werden. Wird der Aufwand an dieser Stelle zu hoch eingestuft, können entweder andere Datenquellen ausprobiert werden oder das Team kommt zum Ergebnis, die Konzeptüberlegungen an dieser Stelle zu beenden.

3. Lernmodell entwickeln

Unser Team hat eine ganze Reihe Maschinenfähigkeiten für die Trendmap ausgewählt. Beim Zuordnen der Fähigkeiten zu den Aufgaben entsteht die Struktur des AI-Modells.

- 1 Das Trainingsparameter-Template rechts zeigt, welche Bedingungen für die Trendclustermap gewählt werden. Um die Einflussfaktoren zu bestimmen, muss definiert werden, wie die Qualität von Trendanalysen definiert wird. Die Auswahl der Daten sollte groß genug sein, damit die Zielgruppe gut genug erfasst wird – folglich ist die Menge der untersuchten Social Media Posts wichtig. Dazu kommt, dass die erkannten Kleidungsstile gut genug erkannt und relevante von irrelevanten Beiträgen getrennt werden. Ansonsten wird die Aussagekraft der Trendergebnisse geschmälert.
- 2 In diesen vier Feldern werden die Grenzen definiert, ab denen das Ergebnis einen Mehrwert verspricht. Außerdem zeigt sich hier, wie sicher das AI-Modell bei der Präsentation der Ergebnisse ist (Wahrscheinlichkeit, dass die Prognose stimmt). Um das beschreiben zu können, müssen wir zunächst den Menschlichen Maßstab kennen, das Ergebnis bei traditionellem Vorgehen. In diesem direkten Vergleich wird die Leistungsfähigkeit des AI-Modells besonders deutlich.
- 3 Im letzten Abschnitt tragen wir ein, wie genau die Aufgaben im Analyseprozess erledigt werden sollen. Die Art und Weise beeinflusst den Schwerpunkt des Trainings (siehe «Einstiegen – Lernkonzept erstellen» auf Seite 84). Die Angaben im Template zeigen, dass der Job eher etwas für Generalisten ist. Es ist wichtiger, die unterschiedlichen Kleidungsstile und Informationen richtig zu interpretieren und miteinander in Beziehung zu setzen – als hundertprozentig exakt zu sein. Das Thema Genauigkeit beschränkt sich darauf, dass Kleidung an sich erkannt werden soll. So spart man sich wertvolle Zeit beim Training des Modells.

Aufgabe	AI-Fähigkeit
Muster in Stilen erkennen und Trends vorhersagen	Objekte erkennen und gruppieren, Vorhersagen
Muster aufdecken, die auf unerfüllte Wünsche deuten	Infos und Emotionen extrahieren, Wissen kombinieren
Trends aus Farb- und Stilkombinationen ableiten	Infos extrahieren, Massendaten, Auto-Weiterlernen
Überprüfung erkannter Trends und Expertenmeinung	Infos und Emotionen extrahieren, Massendaten

Zuordnung der Aufgaben zu den jeweiligen AI-Fähigkeiten.

In diesem Fall soll das AI-Modell weiterlernen können. Wenn die neuen Ergebnisse ebenfalls kontinuierlich von Experten bewertet werden, wird das Modell von Zyklus zu Zyklus immer zuverlässiger bei der Erkennung relevanter Trends.



Lernkonzept erstellen Trainingsparameter



Qualitätsniveau des Modells

1

Einflussfaktoren

Menge der analysierten Posts

Erkennungsgenauigkeit (Kleidung, Stil, Stimmung des Posts etc.) pro analysiertem Post

Auswahlgenauigkeit der relevanten Beiträge

Menschlicher Maßstab

Sichtung und Auswertung von 1000 Posts pro Researcher pro Woche

95% Genauigkeit bei der Klassifizierung der Kleidungstrends (bei erfahrenen Researchern)

Mindestanforderung für Wertgenerierung

Angesagte Trends in Echtzeit anzeigen und kategorisieren

2

Erwünschtes Zielmaß

75% aller relevanten Social Media Profile analysiert (> 100 000 Followern) und mindestens 5 Trends daraus abgeleitet (verifizierbar durch Trendexperten)

Mindestvertrauensgrad des Modells

Analyse von 90% aller wichtigen Profile von Influencern und Blogs


95% richtige Ableitung aller entdeckten Stil- und Farbtrends (verifizierbar durch Trendexperten)

90% richtige Zuordnung (Trend/kein Trend)

Schwerpunkt des Trainings

Trefferquote (Recall)

Genauigkeit (Precision)



Argumente

Verschiedenste Fotoinhalte und Kleidungsstücke interpretieren

Verschiedene Datenarten abfragen und kombinieren (Fotos, Likes, Kommentare etc.)

Trends aus Mustern vorhersagen

75% Genauigkeit sind ausreichend für unseren Zweck, dadurch weniger Trainingsaufwand

3



Argumente

Fokus nur auf Kleidung

4. Entscheidung treffen

Mithilfe von AI zum Trendsetter werden.

- 1 Um dieses AI-Konzept umzusetzen, müssen Data Scientists, Machine Learning Engineers, Trendexperten und Designer zusammenarbeiten. Die Trendexperten sind notwendig, um die AI-Ergebnisse zu kuratieren, sie dienen als Trainer der AI – ihre Erfahrung fließt in die Entwicklung des Algorithmus ein. Die Designer übernehmen am Schluss und prüfen die angebotenen Trends auf Umsetzbarkeit. Der Personalaufwand ist etwas geringer als beim klassischen Vorgehen ohne AI. Für ein annähernd gutes Ergebnis wären fünf Trendforscher nötig.
- 2 Der Zeitaufwand stellt sich mit einem Monat als etwa gleich heraus.
- 3 Eine Herausforderung ist für Unternehmen, die sich zum ersten Mal mit AI auseinandersetzen, die fehlende AI-Expertise und die fehlenden IT-Ressourcen. Ansonsten ist zu Beginn der Trainingsaufwand nicht zu unterschätzen. Die Besonderheit der AI-Anwendung liegt allerdings in der Dauer der Nutzung. Je länger sie im Einsatz ist, desto höher wird ihr Wert, weil das laufende Training immer mehr spezifische Unternehmenserfahrung im AI-Modell speichert.
- 4 Die Vorteile liegen ganz klar in der dauerhaften Anwendung. Das klassische Vorgehen wäre deutlich langsamer und unterläge immer der kognitiven Verzerrung. Die automatisierte Echtzeitanalyse kann Wettbewerbsvorteile ermöglichen, weil die Bedürfnisse am Markt schneller erkannt und die dazu passende Produktangebote schneller umgesetzt werden können. Die Chance besteht darin, mithilfe der neu entwickelten Produkte Trendsetter zu werden.

Die Initialkosten sind recht hoch. In unserem Beispiel stuft das Management das Projekt trotz hohen Initialaufwands als strategisch relevant ein, im Hinblick auf das Ziel Trendsetter zu werden. Dahinter steht die Vision, AI als Firmenstrategie einzusetzen (siehe «Sicher Landen – AI als Firmenstrategie» auf Seite 300). Die Erwartung: Langfristig Kosten sparen, weil keine Produkte angeboten werden, die nicht auf echten Kundenbedürfnissen beruhen. Der Vorteil: Weniger Lagerhaltung, weniger Retouren, schnellere Reaktion auf tatsächliche Trends.



Chancen bewerten Business Check



Kriterien	ohne AI	mit AI
1 Personal (FTE)	5 Trendresearcher (Trendrecherche) 2 Trendexperten (Kuration Output) 1 Designer (Umsetzbarkeitsprüfung)	1 ML Engineer (Modell und Training) 1 DS-Experte (Datenaufbereitung) 2 Trendexperten (Überprüfung Trends) 1 Designer (Umsetzbarkeitsprüfung)
2 Zeit	Regelmäßiges Marktscreening und Trendrecherche über das ganze Jahr	1 Monat Initialaufwand Regelmäßiges Screening und Anpassungen des Modells
Kosten	Mittel – hoch (Hohe laufende Kosten durch Personal für Recherche und Anpassung der Inhalte)	Mittel (Vorhandene Modelle und Daten, fehlende Expertise, regelmäßige Anpassung des Modells nötig)
3 Hürden	Geringe Geschwindigkeit Bias bei Recherche Kognitive Grenzen angesichts der Masse an zu durchforstenden Daten	Fehlende AI-Expertise Verfügbarkeit IT-Ressourcen Einbindung in vorhandene Prozesse Möglicher hoher Trainingsaufwand
4 AI-Potenzial	Sehr kurze Time-to-Market Automatisierte präzise Echtzeitanalyse Kostenersparnis durch genaue Bedürfnisanalyse am Markt (weniger Lagerhaltung, weniger Retouren) Technologieführerschaft, First-of-a-kind-Produkte möglich (Trendsetter werden)	



*Automatische Trendanalyse bietet einen strategischen
Vorteil: Trends werden erkannt, sobald sie
entstehen. Neue Produkte lassen sich
so vor dem Wettbewerb
vermarkten.*

Was wir gelernt haben ...

1. **Aufwendige AI-Projekte benötigen einen hohen Mehrwert.**
Die Analyse von Trends in den Social Media für ein Online-Mode-Label ist möglich – aber aufwendig. Sie zahlt sich erst aus, wenn der Fokus auf hoher Wiederholbarkeit (also jede Woche neue Trends visualisieren), großer Verbreitung (zum Beispiel europaweiter Markt) und eventuell der Wiederverwendbarkeit der Anwendung für weitere Projekte liegt.
2. **AI-Modelle können für weitere Aufgaben adaptiert werden.**
Einmal etabliert lässt sich das Analyseprinzip übertragen: Dem AI-Modell ist es egal, ob vielversprechende Technologiefelder aus Start-up-Daten oder die Konsumtrends anhand der Kassendaten von Supermarktfilialen in Kombination mit externen Daten, wie Wetterdaten, extrahiert werden. Wir können auch interne und externe Daten zueinander in Beziehung setzen und Geschäftschancen analysieren. Hauptsache wir trainieren unser Modell entsprechend seiner neuen Aufgabe.
3. **Auch AI-Anwendungen können irren.** Wichtig ist, stets die Datenqualität im Blick zu behalten. Ist die Auswahl der Trainingsdaten fehlerhaft, bekommen wir auch beim Einsatz von AI verzerrte Ergebnisse und damit unbrauchbare Trends. Da ist ein AI-Modell nicht besser als die Menschen, die es trainieren. Es kann sinnvoll sein, zu Beginn Trendexperten einzubinden, um die Qualität der datengetriebenen Trends einschätzen zu können.
4. **AI-Systeme kürzen Prozesse ab.** Sobald wir beginnen, Trends mit anderen Daten zu kombinieren, zeigt sich eine besondere Eigenschaft der Automatisierung mithilfe von AI-Modellen: Sie kann Prozesse deutlich abkürzen. Wo vorher in mehreren Stufen Informationen gesammelt und interpretiert werden und im Unternehmen zu Entscheidungen reifen, geschieht der gesamte Prozess hier automatisch. Am Ende steht eine Entscheidungsempfehlung, zum Beispiel für oder gegen ein Produkt. Dieses Phänomen wird uns in den folgenden Szenarien noch mehrfach begegnen.

2. Erkenntnis gewinnen

Einer der häufigsten Fehler bei der Entwicklung von neuen Geschäftsideen, Produkten und Dienstleistungen ist die mangelnde Einsicht in tatsächlich existierende Kundenbedürfnisse. Häufig sind diese nicht auf den ersten Blick erkennbar, sie verstecken sich, werden verdeckt von vorgeschobenen Aussagen – manchmal können die Nutzer selbst nicht genau ausdrücken, was sie tatsächlich wollen oder was ihr eigentliches Problem ist.

Ein einfaches Beispiel illustriert, was damit gemeint ist. Jeder kennt das Problem beim Renovieren eines Zimmers: Der alte Kleister an den Tapeten haftet an manchen Stellen gar nicht, an anderen bombenfest. Tapetenablöser funktioniert manchmal, aber nicht immer. Moderne Maschinen, die Tapeten mit Dampf ablösen, helfen ebenfalls nicht zuverlässig. Vordergründig brauchen die Nutzer also besseren Tapetenablöser, bessere Geräte für das Entfernen der Tapeten. Tatsächlich geht es aber darum, dass Tapeten zuverlässig und leicht wieder entfernbar sein sollten. Die Erkenntnis: Wir müssen viel früher ansetzen, nämlich bereits an dem Punkt, an dem die Tapete an die Wand gebracht wird.

Nutzer verstehen

Das banale und leicht zu durchschauende Beispiel zeigt, worum es bei der Analyse von Kundenbedürfnissen tatsächlich geht. Wir wollen verstehen, wie sich Nutzer verhalten – und zwar ohne sie durch unsere Eingriffe zu beeinflussen. Die Analysetechniken, die wir dazu einsetzen, sind alt, teilweise übernommen aus der Ethnografie, der Erforschung von Lebensweisen unterschiedlicher Kulturen. In den vergangenen Jahrzehnten haben wir in unterschiedlichen Fachgebieten viel darüber gelernt, wie wir menschliches Verhalten so beobachten können, dass sich daraus valide Schlüsse ziehen lassen. Soziologen betrachten die Entwicklungen von Gesellschaften, Ethnologen soziale Gruppen in ihren jeweiligen Umfeldern – und das Interview ist eine ihrer bevorzugten Methoden, Daten zu erheben. Einzelne Aussagen aus den Gesprächen und Beobachtungen des Verhaltens nennen wir Research-Signale und leiten aus ihnen unsere Erkenntnisse ab.

Lange Zeit war das die bevorzugte Analyseform. Dann kam das Internet.

Heute umgibt die Welt ein unsichtbares Geflecht aus miteinander verbundenen Datenströmen. Jede Sekunde rauschen unvorstellbare Mengen an persönlichen Informationen rund um den Globus. Herzschlag, Standort, Website, Reiseziele, Restaurantbuchungen, Eisprungtage – alle diese teils hoch privaten Informationen sausen um die Welt und hin zu Unternehmen, die aus diesen Informationen präzise Muster von Kundenverhalten zusammensetzen können.

Gelerntes aus Nutzerverhalten, egal, ob konventionell aus der Beobachtung gewonnen oder durch die Analyse von großen Datenmengen, nennen wir Erkenntnisse. In beiden Fällen ist die Grundlage immer ein Fundus von vielen Daten. Viele Erkenntnisse für die Nutzung von Produkten und Dienstleistungen findet man zunächst nicht am PC oder irgendwo im Internet, sondern beim Datensammeln vor Ort, wo die Menschen handeln, arbeiten, leben.

Die qualitative Recherche

Traditionell gehen wir entsprechend unserem Arbeitsauftrag hinaus in die Welt und beobachten die Menschen bei ihren Tätigkeiten. Wir sammeln Eindrücke und Daten. Wir arbeiten Fragebögen aus und machen uns auf der Straße, in Büros, in Fabriken oder U-Bahnen ein Bild vom Verhalten unserer Nutzer – möglicherweise sogar weltweit. Wir sprechen mit unseren Nutzern. Fragen, wie sie Produkte verwenden, wo sie sie aufbewahren. Wir wandern über Äcker, durch Containerterminals, machen Fotos und Videos, Notizen, Vermerke.

Diesen Teil der Recherche nennen wir qualitativ. Wir machen uns ein Bild vor Ort, bauen Empathie zu den Nutzern auf und lernen. Das ist sehr wichtig – auch und gerade wenn wir Computer in unsere Arbeit integrieren. Den Teil der Arbeit, bei dem es auf Empathie und andere zutiefst menschliche Qualitäten ankommt, wollen und sollten wir nicht ersetzen.

Anders sieht es beim mühsamen Auswerten aus. Oft sammeln wir mehrere Tausend Bilder, Aussagen von Nutzern, Beschreibungen von Szenen, die wir auf diese Weise zusammengeführt haben. Unser Büro ist zugепflastert mit Notizen und Fotos. Es ist eine mühsame Kleinarbeit. Für die Bilder legen wir in Datenbanken Legenden an, damit wir wissen, an

**Die Jagd nach
Erkenntnis ist
aufwendig.**

welchem Ort sich die Baustelle befand oder welche Themen hier relevant waren, und leiten aus all den Datensätzen Erkenntnisse ab.

Die quantitative Recherche

Um die qualitativ erhobenen Erkenntnisse zu verifizieren, bedienen wir uns der quantitativen Analyse. Dabei geht es darum, Haltungen, Meinungen, Verhaltensweisen und andere definierte Variablen konkret messbar und vergleichbar zu machen. Das heißt, wir nehmen die Ergebnisse aus der qualitativen Recherche und verallgemeinern und verifizieren sie in einer größeren Stichprobe. Quantitative Forschung verwendet messbare Daten, um Fakten zu formulieren und Muster in der Recherche aufzudecken. Gerade hierfür eignet sich Machine Learning besonders gut.

Quantitative Datenerfassungsmethoden sind in der Regel viel strukturierter als qualitative. Zu den quantitativen Datenerhebungsmethoden gehören verschiedene Formen von Erhebungen: Online-Umfragen, Multiple-Choice-Umfragen, Längsschnittstudien und systematische Beobachtungen.

Wie uns AI helfen kann

Die Arbeit an Erkenntnissen ist sehr zeitraubend und mühsam. Sie kostet viel Geld. Es wäre wünschenswert, diesen Prozess zu verkürzen. In den vergangenen Jahren haben wir begonnen, uns an so vielen Stellen wie möglich die Arbeit zu erleichtern. Es gibt inzwischen zahlreiche Start-ups, die uns helfen, große und kleine Routinearbeiten mithilfe von Machine Learning zu automatisieren. Zum Beispiel können Audioaufnahmen von Interviews inzwischen recht gut automatisch in Text umgewandelt werden. In vielen Fällen müssen wir AI-Modelle also gar nicht selbst entwickeln, sondern können auf existierende, teilweise sogar kostenlose Angebote zurückgreifen.

Möglich wäre aber noch mehr. Denn die Essenz des Ableitens von Erkenntnissen aus sogenannten Signalen – das sind all die Fotos, Aussagen von Nutzern, Videos und Beobachtungen – ist das Erkennen der Muster. Das Verstehen, was tatsächlich hinter einem beobachteten Verhalten steckt. Und hier sind Maschinen wahre Meister. Sie können in Daten versteckte Muster schneller und leichter als Menschen erkennen. Durch den Einsatz von AI ist es zum ersten Mal möglich,

Maschinen übernehmen die Routine, der Mensch glänzt mit Empathie und Vorstellungskraft.

**Maschinelle
Stärke**

anstatt mit Dutzenden von Kollegen und Kolleginnen in die Welt hinauszuziehen und für Wochen oder Monate Recherche zu betreiben, sehr viel qualitative Informationen zu sammeln und später auswerten zu lassen. Hier liegt ein enormer Mehrwert für Innovation, denn falsch verstandene Nutzerbedürfnisse führen im schlimmsten Fall zur Entwicklung von Lösungen, die keiner nutzen möchte.

Wir können die Fähigkeiten von Menschen und Maschinen hier perfekt kombinieren. Die Maschine kann darauf trainiert werden, wiederkehrende Motive, Aussagen, Stimmungen, in Bildern, Videos und Texten zu erkennen und zu markieren. Wir können Sensoren, Kameras und vieles mehr zum Generieren von Daten einsetzen oder nutzen. All dies sind Methoden, die auch in anderen Fachgebieten bereits erfolgreich angewandt werden, wie zum Beispiel in der Marktforschung. So wird in Amazons Go-Läden das Kaufverhalten, also zum Beispiel die Auswahl von Produkten im Regal, über Videoaufzeichnungen und andere Sensordaten analysiert und interpretiert.

**Menschliche
Stärke**

Haben wir es einmal geschafft, die Rohdaten auf diese Weise zu strukturieren und zu Mustern zu kombinieren, fällt es Menschen wiederum leicht, diese Beobachtungen zu generalisieren, aus den Erkenntnissen Lösungskonzepte zu erarbeiten und sie in den Kontext einer Unternehmensstrategie einzubetten.

Wir sehen also, dass sich die Fähigkeiten von Menschen gut mit den spezifischen Möglichkeiten von Maschinen kombinieren lassen. Wie diese Kombination aussehen soll, müssen wir für jeden Einzelfall aufs Neue untersuchen.

Szenario

Flughafen

Warteschlangen sind überall auf der Welt ein Indiz für Engpässe. An Flughäfen sind das die Bereiche Check-in, Sicherheitskontrolle und das Gate. Recht komplex sind die Abläufe an der Sicherheitskontrolle. An einem asiatischen Großflughafen will ein Expertenteam herausfinden, was im Detail so lange dauert.

Für Researcher ist interessant, wie sich die Fluggäste konkret durch die einzelnen Abschnitte an der Sicherheitskontrolle bewegen. Insgesamt handelt es sich um fünf Bereiche: die lange Warteschlange vor dem eigentlichen Kontrollbereich, das Fließband, auf dem Taschen und Kleidung abgelegt werden, der Platz vor dem Scanner, die Zone für das manuelle Abtasten der Fluggäste und schließlich der Bereich nach der Kontrolle, wo die Fluggäste ihre Habseligkeiten wieder einpacken.


Warum AI?

Um hier Muster zu erkennen, müssen die Passagiere beobachtet werden. Und zwar so lange, bis die erkannten Muster auf eine verlässliche Anzahl von Beobachtungen zurückzuführen sind. Interviews von Beteiligten helfen in diesem Beispiel nur wenig, weil deren Eindrücke subjektive Momentaufnahmen sind, und daher die Wirklichkeit oft nur verzerrt wiedergeben. In Interviews nannten die Sicherheitsleute dem Expertenteam zum Beispiel das Aus- und Anziehen der Schuhe als Ursache für Schlangen. Das stellte sich allerdings als falsch heraus. Denn die anderen Passagiere können an dieser Stelle einfach vorbeigehen, ohne warten zu müssen.

Der AI-Ansatz

In diesem Szenario haben sich die Experten entschlossen, die Beobachtung mithilfe von Videokameras durchzuführen. Diese dokumentieren das Entstehen und Auflösen der Warteschlangen, ein AI-Modell soll die Aufzeichnungen analysieren und dem Researchteam kritische Punkte anzeigen sowie Verbesserungspotenziale vorhersagen.


Dieses Szenario illustriert, wie drastisch maschinelles Vorgehen den traditionellen Prozess abkürzen kann. Anders als beim Trendszenario wird nur eine einzige Datenquelle verwendet, die Daten werden zudem selbst erzeugt. Dennoch werden sehr komplexe Aufgaben gelöst.





1. Ziel definieren

AI-Mehrwert



Auftrag

Zeitersparnis und Effizienzsteigerung des Security Checks am Flughafen


Erwarteter Mehrwert durch AI

Zeitersparnis, Qualitäts- und Objektivitätsgewinn durch parallele Auswertung, ohne zeitliche oder personelle Einschränkungen. Viele Beobachtungen gleichzeitig durchführen und auswerten.
Big Picture: alle Beobachtungen zueinander in Beziehung setzen und daraus Erkenntnisse ableiten, statt nur aus einzelnen Momentaufnahmen.




2. Daten recherchieren

Datenquellen



	Typ	Quelle	Warum?
A	Video	Spezialkameras	Muster erkennen in Verhalten und Abläufen
B			
C			
D			


Challenge















Wir wollen eine Woche lang eine Auswahl von Security-Check-Bereichen (durch Kameras) automatisiert analysieren, um Ineffizienzen vor, während und unmittelbar nach der Sicherheitskontrolle aufzudecken (unter Einhaltung des Datenschutzes).


Das Ziel ist es, im Anschluss Gegenmaßnahmen zu entwickeln, die für Fluggäste und Security-Personal den Abfertigungsprozess verbessern.


Datenprüfung





	Priorität	Beschaffung	Technik
A	hoch 	niedrig 	mittel 
B			
C			
D			

Output




Erkennen

Vorhersagen


Erzeugen

Outputformat

Wir benötigen einen Zusammenschnitt von Videos. Diese «Best-ofs» sollen typische Muster zeigen: wenn Fluggäste auf etwas oder jemanden warten und dadurch der Security-Prozess aufgehalten wird. Jeder Ausschnitt benötigt folgende Angaben: durchschnittliche Dauer des gezeigten Prozesses, besondere Auffälligkeiten in Form von Tags; Relevanz für die Challenge als Wahrscheinlichkeit in Prozent.















Datenerhebung



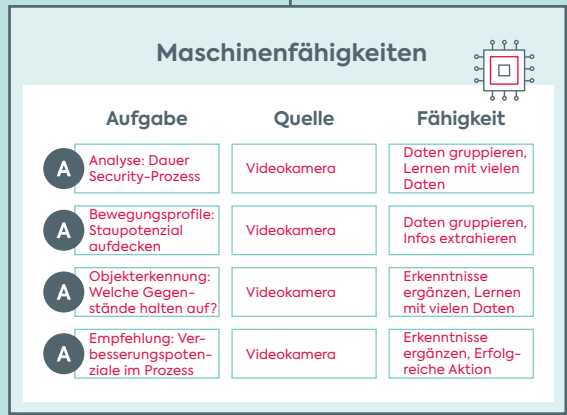
Grund für die Datensammlung

Mustererkennung im Verhalten von Fluggästen und Security-Personal, sowie in Prozessen: Analyse von zeitlichen Abläufen, Erkennung von Wartezeiten, zurückgelegten Wegen etc.

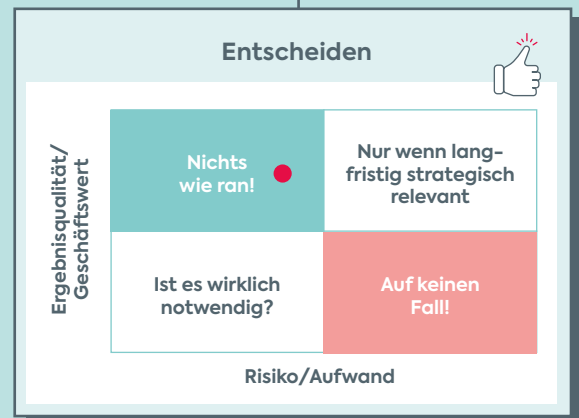
Daten-typen	Video			
Priorität				
Beschaffung				
Technik				



3. Lernkonzept erstellen



4. Entscheidung treffen



Sicherheitscheck am Flughafen

Das Besondere an diesem Beispiel ist die Verwendung nur einer Datenquelle für die Auswertung. Statt einer Gruppe von Beobachtern werden Videokameras eingesetzt und für einen Zeitraum von einer Woche installiert. Sie beobachten alle relevanten Abschnitte am Sicherheitscheck. Trainiert wird das Modell auf messbare Verzögerungen auf dem Weg von einem

Abschnitt zum nächsten. Immer dann, wenn sich in den Videos ähnliche Verzögerungssequenzen häufen, gibt das AI-Modell einen Zusammenschchnitt als Ergebnis aus. Hier greift der Mensch wieder ein und leitet aus den Videomotiven seine Schlussfolgerungen ab. Ersparnis: eine wochenlange und personalintensive Beobachtungszeit.



Ziel definieren AI Value Map

Der Auftrag

Zeitersparnis und Effizienzsteigerung der Sicherheitskontrolle am Flughafen



Manuelle Projektschritte

Beschreibung

Qualitative Recherche mit 3 Researchern an 3 Kontrollstationen

Quantitative Umfragen bei Fluggästen

Expertenbefragungen durchführen

Trendsignale ableiten (Clustering der gesammelten Informationen)

Muster in Signalen herausarbeiten und zu Trends synthetisieren

Typische Pain Points

Hoher Zeit- und Kostenaufwand, Stichprobenhaft, nur Momentaufnahme, Bias

Massendaten, Vergleichbarkeit der Aussagen (emotionsgeleitet)

Hoher Zeitaufwand, persönlicher Bias, Menschen geben erwünschte Antworten

Hoher Zeitaufwand, unscharf, persönlicher Bias, kurze Microtrends werden übersehen

Hoher manueller Aufwand, Zeitaufwand, Erfahrung nötig

Geschäftlicher Mehrwert durch AI

Qualitätsgewinn (Objektivität), Zeitersparnis, Dauereinsatz, Big-Picture-Blick

Zeitersparnis, Objektivität, autom. Abgleich mit qualitativer Recherche

Bias-freie Ergebnisse

Zeitersparnis, höhere Genauigkeit, mehr Objektivität

Zeitersparnis, verborgene Muster erkennen: «Unfair Advantage» nutzbar machen

Hier kann AI unterstützen:



Ziel definieren Output

2



Die Aktion



Erkennen




Vorhersagen



Erzeugen

Das Format

Wir benötigen einen Zusammenschnitt von Videoausschnitten. Diese «Best-ofs» sollen die typischen Muster zeigen, wenn Fluggäste auf etwas oder jemanden warten und dadurch der Security-Prozess aufgehalten wird. Jeder Videoausschnitt benötigt folgende Angaben: durchschnittliche Dauer des gezeigten Prozesses, besondere Auffälligkeiten in Form von Tags, wie «Familie», «Geschäftsreisende», «Kinder», «Koffer» oder «Jacken»; die Wahrscheinlichkeit für Optimierungspotenzial in Prozent.



Dauer



Auffälligkeit



Relevanz

Wie es geht

1. Ziel definieren

**Automatisierte
Forschung: Kameras
übernehmen den Job
der Beobachter.**

Am Anfang eines AI-Projekts steht die Frage nach dem «Wie». Für unser Flughafen-Szenario schlüsseln wir die einzelnen Arbeitsschritte in der AI Value Map auf und arbeiten die jeweiligen Hürden heraus. Dabei zeigt sich: Der langwierigste Teil der Arbeit ist in diesem Fall die Datenbeschaffung und -auswertung.

1

An diesem Punkt müssen wir darüber nachdenken, wie eine Automatisierung der Beobachtungs- und Auswertungsphase funktionieren könnte – denn diese brächte den größten zeitlichen und qualitativen Mehrwert. Wie lassen sich Verzögerungsmuster in Warteschlangen identifizieren? Wie kommen wir an die notwendigen Daten? Eine mögliche Lösung wären Sensoren. Eine andere Videoaufzeichnungen.

Research klassischer Art kommt hier an seine Grenzen, weil das Personal an der Sicherheitskontrolle nicht auf wiederkehrende Dinge achtet. Interviews geben daher nur begrenzt Aufschluss über die tatsächlichen Vorgänge.

Wir entscheiden uns daher für **Videoanalyse durch Spezialkameras**, die automatisch Gesichter unkenntlich machen, damit wir uns um den Datenschutz keine Gedanken machen müssen. Wir formulieren als Challenge:

«Wir wollen eine Woche lang eine Auswahl von Security-Check-Bereichen durch Kameras beobachten lassen, um Ineffizienzen vor, während und unmittelbar nach der Sicherheitskontrolle aufzudecken (unter Einhaltung des Datenschutzes). Das Ziel ist es, anschließend Gegenmaßnahmen zu entwickeln, die den Abfertigungsprozess für Fluggäste und Security-Personal verbessern.»

2

Wichtig ist der Output: Er soll alle notwendigen Angaben enthalten, die für die späteren Aufgaben wichtig sind. In diesem Fall ist es die Art und Weise, wie die Videosequenzen zusammengeschnitten und mit zusätzlichen Informationen versehen werden. Auch soll die Maschine uns die Relevanz des gezeigten Videoschnitts für die spätere Optimierung des Prozesses vorhersagen. Diese Angaben legen den Grundstein für die Auswahl der benötigten AI-Fähigkeiten.

2. Daten recherchieren

**Beim Erstellen
der Data Journey Map
lohnt sich der Aus-
tausch mit AI-Experten.**

Datentypen und -quellen zusammenzustellen, ist in diesem Szenario schnell gemacht: Wir benötigen nur Videomaterial. Und das produzieren wir selbst. Wir haben die volle Hoheit darüber und können Qualität und Zugang sicherstellen.

Aufwendiger ist die Data Journey Map. Hier schlüsseln wir auf, wie das AI-Modell konkret die Videos auswerten soll. Hier gibt es viele Möglichkeiten. Soll das AI-Modell Nutzerinteraktionen und Bewegungsprofile analysieren? Oder Gestik und Mimik auf Emotionen hin interpretieren? Noch mehr Informationen lassen sich gewinnen, wenn wir Videoinhalte mit anderen Daten verknüpfen, etwa mit dem Flugplan.

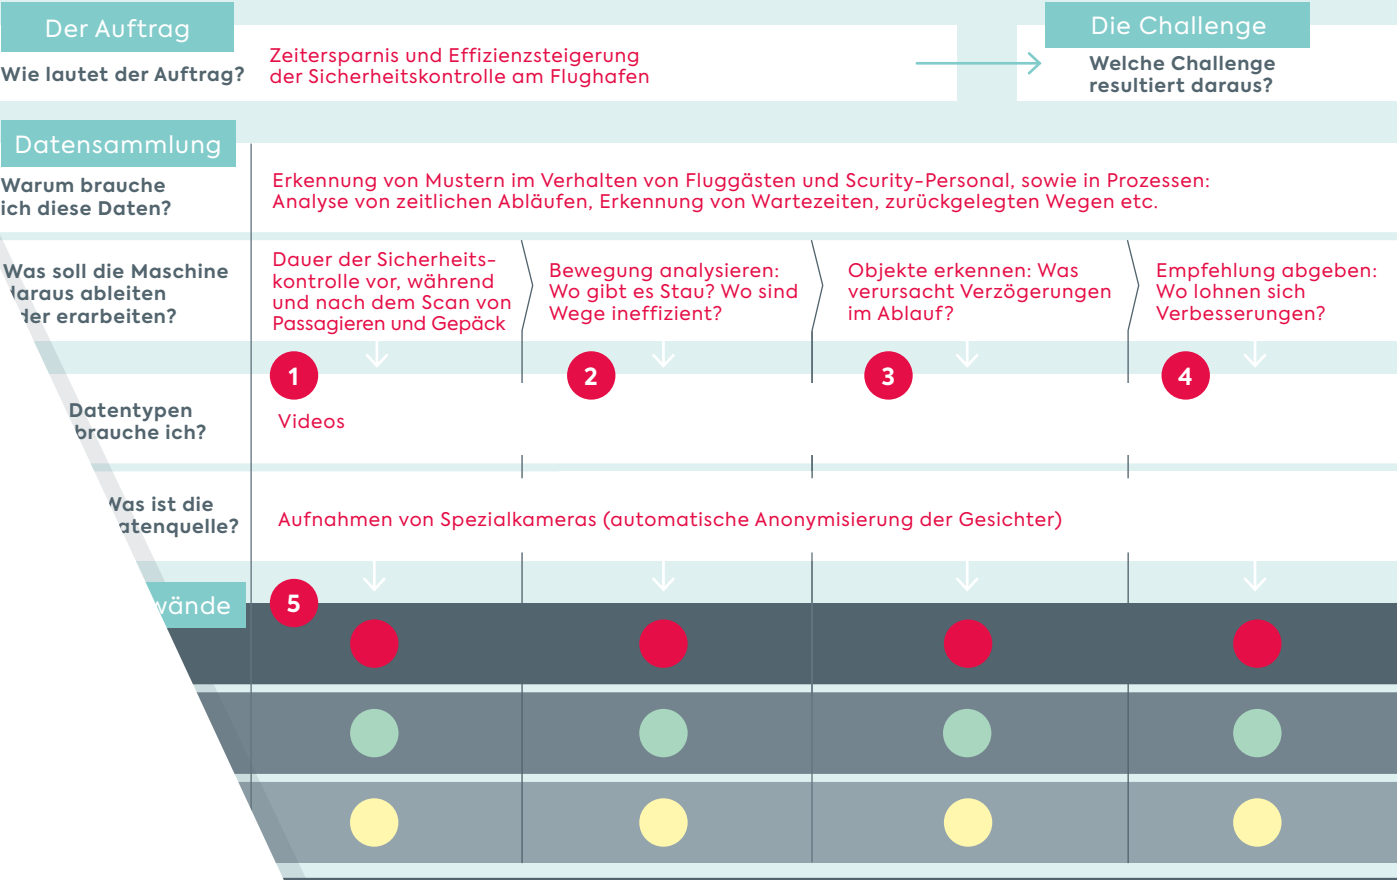
Wir orientieren uns an den Anforderungen aus der Challenge und dem Output und klären, was die Maschine als Erstes lernen und analysieren soll. Diese Ausarbeitung kann auch gemeinsam mit Data Scientists erfolgen, denn nun legen wir grob fest, wie das AI-Modell arbeiten soll.

- 1 Das AI-Modell muss lernen, was ein Security-Prozess ist, also die fünf Schritte der Sicherheitskontrolle unterscheiden können und deren optimale Dauer kennen. Das ist der Bezugsrahmen für das Ziel: Die Passagiere sollen sich so schnell wie möglich vom Eingang durch den Scanner zu ihren gescannten Gepäckstücken bewegen.
- 2 Nun beginnt der Analyseteil: Die Maschine analysiert die Bewegung der Fluggäste durch die Abschnitte der Sicherheitskontrolle und schneidet immer diejenigen Videosequenzen heraus, in denen die Fluggäste besonders schnell waren oder besonders lang gebraucht haben.
- 3 In diesen Sequenzen soll sie alle Objekte markieren, die in einem Prozessschritt für Verzögerungen verantwortlich sind. Das AI-Modell stellt einen Zusammenhang zwischen menschlicher Bewegung und Objekten her.
- 4 Empfehlung abgeben: Als letztes soll das AI-Modell vorhersagen, welche Stellschrauben (Verhalten der Personen, involvierte Objekte, Prozessabläufe) potenziell verändert werden könnten, um den Prozess zu beschleunigen.



Daten recherchieren

Data Journey Map



5 Wie bei jeder Aktion prüfen wir am Ende, ob es unüberwindbare Probleme gibt; diese Prüfpunkte sind während des gesamten Entwicklungsprozesses wichtig, um rechtzeitig die Ausrichtung des Projekts anpassen zu können (siehe «Sicher landen – AI-Projekte sind anders», Seite 260).

In unserem Fall haben wir Glück – außer bei der Aufbereitung und Verarbeitung des Videomaterials hält sich unser Aufwand in Grenzen. Wir können also als Nächstes die benötigten Maschinenfähigkeiten auswählen.



Lernkonzept erstellen Trainingsparameter



Qualitätsniveau des Modells

Einflussfaktoren

Anzahl der erkannten Objekte

Qualität der erkannten Muster

Zusammenhang/Kontext der Muster

1

2

Menschlicher Maßstab

Recherche: 3 Researcher,
1 Monat, Fulltime
= 504 Std.

Insights ableiten (aus ca.
1000 Signalen) = 180 Std.

Opportunity Areas
ableiten = 60 Std.

TOTAL: ca. 750 Std.

Mindestanforderung für Wertgenerierung

80% der Videosequenzen
sind richtig eingeordnet
(Jacke zusammenfalten,
Koffer aufs Band etc.)

Best-of-Sequenzen
(Hunderte Stunden Video
sind auf einige wenige
reduziert)

Erwünschtes Zielmaß


80% der Szenen sind
richtig eingeordnet,
davon sind mindestens
75% zusätzlich nach
Zeitaufwand und
Relevanz richtig
eingeschätzt
(ein Prozess in der
gezeigten Szene hat kurz,
lang, unterschiedlich lang
gedauert)

Mindestvertrauensgrad des Modells

80–90% der gefilterten
Videos haben tatsächlich
etwas mit der
Verbesserung des Ablaufs
zu tun (Menschen
kommen so schnell wie
möglich durch den
Security-Prozess)

Erforderliche Genauigkeit

Trefferquote (Recall)



Genauigkeit (Precision)

3

Argumente

Nur wenn ich später noch Synergieeffekte
schaffen möchte (z.B. Kooperationen mit
Kofferherstellern) und ich daher die
Anwendung mehr als einmal brauche:
Objektkontext und Besonderheiten müssen
dann genauer erkannt werden
(z.B. Kofferlage).



Argumente

Es gibt wenig Varianz in den Szenen

Besonderheiten dürfen wegfallen

Objekte müssen gut erkannt und
zugeordnet werden

Zusammenhänge zwischen Objekten und
Aktionen müssen gut erkannt werden

Keine Wiederverwendung der Anwendung
(Nur einmal für dieses Projekt)

Keine unterschiedlichen Trainingsquellen

3. Lernkonzept erstellen

Aufgabe	AI-Fähigkeit
Analyse: Dauer Security-Prozess	Daten gruppieren, lernen mit vielen Daten
Bewegungsprofile: Staupotential aufdecken	Daten gruppieren, Infos extrahieren
Objekterkennung: Welche Gegenstände halten auf?	Erkenntnisse ergänzen, lernen mit vielen Daten
Empfehlung: Verbesserungspotenziale Prozess	Erkenntnisse ergänzen, Entscheidungs-optimierung

Zuordnung der Aufgaben zu den jeweiligen AI-Fähigkeiten.

Wir benötigen für unsere Research-AI einen ganzen Strauß an AI-Fähigkeiten, um die in der Data Journey Map beschriebenen Aufgaben auszuführen (siehe Tabelle links). Das Machine-Learning-Modell wird mit den ausgewählten AI-Fähigkeiten erstellt und benötigt ein Lernkonzept. Dazu definieren wir die nötigen Parameter.

- 1 Die Einflussfaktoren geben den Rahmen vor, an dem wir Mindestwert, Zielwert und Vertrauensgrad orientieren.
- 2 Ausgehend von der Leistung, die ein Research-Team erbringen kann, definieren wir, was das AI-Modell mindestens leisten soll, damit es einen Mehrwert bringt. In den ausgewählten Videosequenzen müssen die Szenen den **korrekten** Abschnitten im Security-Prozess zugeordnet sein – sonst ist der Teil der Auswertung wertlos. Durch das Kuratieren der Sequenzen darf die **Länge** der gesamten Sequenzsammlung nur noch wenige Stunden betragen – sonst schwindet der Wert ebenfalls. Die Angaben stellen die Relation zum traditionellen Vorgehen her.

Besser wäre es natürlich, wenn das AI-Modell noch mehr liefert, in unserem Fall sollen auch noch die zusätzlichen Angaben möglichst korrekt ausfallen, also die relative Dauer des herausgefilterten Prozessabschnitts und die Interpretation, an welchen Stellen Prozessoptimierung empfohlen wird. Schließlich müssen wir überlegen, wann wir dem Ergebnis vertrauen: Es bringt nichts, wenn irrelevante Sequenzen als relevant für eine Verbesserung eingestuft werden. Die Relevanz von Sequenzen für die Prozessoptimierung, wie das Schuhe zubinden oder das Falten eines Jackets, muss zu 90 Prozent korrekt erkannt werden. Und zwar sowohl, wenn sie wichtig sind, als auch wenn sie für den Prozess keine Rolle spielen.

- 3 Anhand der Evaluationskriterien legen wir fest, wie das AI-Modell trainiert werden soll. Genauigkeit hat Priorität, denn bei allen Aktionen, die das AI-Modell abarbeiten muss, ist es wichtiger, dass die erkannten Objekte, Zuordnungen und Zusammenhänge stimmen. Dieser Vorhersage wollen wir vertrauen, ohne die Daten kontrollieren zu müssen. Wenn nicht alle Besonderheiten erfasst wurden, ist das weniger tragisch. Wir interessieren uns für die Schritte mit dem größten Verbesserungspotenzial.

4. Chancen bewerten

Der Vergleich im «Business Check» hilft Entscheidern, zu verstehen, ob und auf welche Weise sich der Einsatz der AI-Lösung bezahlt macht. Um zu den Werten für den Aufwand der Dauer der Umsetzung zu kommen, hilft die Übersicht im «AI Time Calculator» auf Seite 104 im Kapitel «Einsteigen». Außerdem können bei dieser abschließenden Einschätzung AI-Experten zum Beispiel aus lokalen Netzwerken helfen.

- 1 In diesem Fall benötigen wir kein AI-System, das so umfassend entwickelt wird, dass es einem Einsatz als Kundenprodukt standhält. Nach der Auswertung der Videos hat das System seine Arbeit getan. Uns reicht dafür ein Hackathon. Wir bleiben damit auf Proof-of-Concept-Ebene. Das spart uns eine Menge Zeit und Ressourcen (siehe «Sicher landen – AI-Prozesse sind anders» auf Seite 260).
- 2 Eine Hürde, die typisch für diese Art von Research-Projekten ist: Man weiß vorher nicht, ob die Qualität der Ergebnisse hoch genug ist. Dieses Risiko lässt sich auch durch den Einsatz von AI nicht ausschließen.
- 3 Das geschilderte Projekt eignet sich gut, um erste Erfahrungen mit dem Einsatz von AI-Systemen zu machen. Bei Erfolg bereitet es den Weg zu weiteren Anwendungen – etwa der Analyse anderer Prozesse.

Weil das Video-AI-System als unermüdlicher Beobachter die Abläufe am Flughafen zu hundert Prozent analysieren kann, besteht die Chance auf unerwartete Erkenntnisse. Somit ist das AI-System der konventionellen Methode überlegen.

Zusätzliche Monetarisierung: Eventuell kann das System auch vermarktet werden, und Prozessanalysen an Dritte verkauft werden. Allerdings benötigt das Programm dann deutlich höhere Ressourcen und mehr Training, um zu einem verkaufsfähigen Service entwickelt zu werden. Ob diese bereitgestellt werden ist eine strategische Entscheidung.

Bei der Analyse von Daten mit AI-Systemen kann der Verkauf von Analyseergebnissen die Basis für neue Geschäftsmodelle sein.



Entscheidung treffen Business Check



Kriterien	ohne AI	mit AI
Personal (FTE)	3 Researcher 1 Innovation Strategist 1 Projektleitung	1 ML Engineer 1 DS-Experte 1 Innovation Strategist 1 Projektleitung
1 Zeit	1 Woche Planung 1 Monat Research für tiefgehende Recherche 2 Wochen für die Auswertung bis zu den Opportunity Areas	1 Woche Planung, Maschinentraining und Modellvorbereitung 1 Woche Recherche und Analyse 3 Tage für die Auswertung bis zu den Opportunity Areas
Kosten	Mittel	Mittel
2 Hürden	Wir verpassen wichtige Momente, da nicht alle Augen überall sein können Stichprobe statt Verständnis des Gesamtbildes Expertise nicht im eigenen Unternehmen Möglicherweise keine neuen Erkenntnisse	Expertise nicht im eigenen Unternehmen und teuer Ergebnisqualität nicht vorhersehbar, daher möglicherweise keine neuen Erkenntnisse
3 AI-Potenzial	Erste Erfahrungen mit AI sammeln Big Picture des gesamten Security Prozesses, statt nur einzelner Ausschnitte Monetarisierung der Analysedaten (z. B. Gepäckhersteller, Infrastrukturanbieter) Bei Erfolg: Erweiterung auf andere Prozesse (z. B. Gepäckabfertigung etc.)	



Das Ablegen und Falten der Kleidung sowie die Suche nach Kleingeld und Mobiltelefonen erst direkt am Band stellte sich als das Hauptproblem heraus. Schuhe aus- und anzuziehen, ließ sich gut in den Prozess eingliedern. Neue Stehtrolleys konnten die durchschnittliche Aufenthaltsdauer vor dem Kofferscan deutlich reduzieren.

Was wir gelernt haben ...

1. **Arbeitsschritte können eingespart oder kombiniert werden.** Das Vortasten durch qualitative Recherche fällt weg. Weil ein AI-Modell mühelos tausende Stunden Videomaterial analysieren kann, benötigen wir die Trennung zwischen qualitativer und quantitativer Analyse nicht. Wir werten einfach alles aus, was passiert. Repräsentativer geht es kaum. Um auf Ideen zu kommen, wo sich Schritte kombinieren oder einsparen lassen, lohnt sich der Vergleich zwischen den Stärken von Menschen und Maschinen (siehe «Einsteigen – Value» auf Seite 50) sowie das Studium von Fallstudien zu anderen AI-Lösungen.
2. **Ganzheitliche Analysen ersetzen Stichproben.** Wir sind nicht darauf beschränkt, Momentaufnahmen zu betrachten, wie unsere Researcher es gezwungenermaßen tun. Durch die Maschinenpower können wir nun das Gesamtbild ins Auge fassen und viele ähnliche Situationen gleichzeitig analysieren und vergleichen. Ohne dieses Gesamtbild hätte man womöglich versucht, den Prozess beim Schuhe ausziehen anzupassen, ohne damit je einen Mehrwert zu erzeugen.
3. **Fertige Modelle sparen Zeit.** Für derart konkrete Arbeitsaufträge gibt es möglicherweise auch fertige Dienstleistungen von Unternehmen, die sich sofort oder nur mit wenig Anpassungsaufwand nutzen lassen. Beispiele sind sogenannte Boilerplates von IBM Watson oder Google. Wer aber gerne ausprobieren will, wie sich Maschinenvorhersagen auf Basis von Videomaterial erstellen lassen: die Teachable Machine von Google Experiments ermöglicht das ganz ohne Programmierkenntnisse. Weitere Infos unter: experiments.withgoogle.com/teachable-machine.
4. **Auch Prototypen können Ergebnisse bringen.** Das Beispiel des Flughafens haben Studenten bei einem Projekt im Rahmen eines Hackathons in einer Woche umgesetzt. Wenn wir AI-Hilfe nur intern für ein Einzelprojekt brauchen, reicht oftmals der «Quick-and-Dirty-Ansatz». Wollen wir das AI-Modell zum Bestandteil eines Geschäftsmodells machen, sieht der Fall anders aus. Dann brauchen wir mehr Trainingstiefe, eine andere AI-Infrastruktur und eine Benutzeroberfläche – je nach der Komplexität des Tools und seinem Funktionsumfang können zwischen einem und sechs Monaten Zeit kalkuliert werden (siehe «Sicher landen» auf Seite 242).

3. Persona erstellen

Personas sind wie gut gestaltete Charakterprofile, vergleichbar mit einer Sedcard von Schauspielern.

Vielfältig einsetzbar

Das ewige Mantra der Innovation lautet: «Beachte die Nutzersperspektive.» Es steht im krassen Gegensatz zum genialen Erfinder, der unbeirrt an seiner großen Idee tüftelt. Beide Ansätze eint, dass sie die Lösung eines Problems ins Zentrum stellen. Die Gretchenfrage lautet: Wessen Problem soll gelöst werden? Die Antwort entscheidet oft über Erfolg und Misserfolg von Neuerungen.

Wir knüpfen hier an das vorhergehende Kapitel an, in dem wir mithilfe von Daten neue Erkenntnisse über Nutzerverhalten gesammelt haben. Nun wollen wir wissen, wer eigentlich genau unsere Nutzer sind. Damit Innovatoren beim Entwickeln nicht ihren eigenen Wünschen und Vorlieben folgen, sondern denen der Zielgruppe, erstellen wir Repräsentanten, die sogenannten Personas. In der Antike nutzten Schauspieler aufwendig gestaltete Masken (*persona*), um besser in die Rolle ihrer Charaktere schlüpfen zu können. Heute nutzen wir keine Masken. Stattdessen sind es in der Regel gut gestaltete Charakterprofile, vergleichbar mit einer Sedcard von Schauspielern.

Die Personas helfen, sich besser in typische Kunden hineinzuversetzen. Innovatoren können so ihr Verhalten, ihre Motivationen, Bedürfnisse, Probleme und Wünsche, ihre Produkt- und Wertewelt besser erkennen – und Produkte oder Dienstleistungen entsprechend gut auf deren Bedürfnisse anpassen.

Die Persona ist allerdings nicht nur für Innovatoren nützlich. Sie wird im Marketing genutzt, um Kampagnen besser auf die Zielgruppen zuzuschneiden – im Vertrieb und in der Strategiebeziehungsweise der Geschäftsmodellentwicklung. Im Grunde wird sie immer dort eingesetzt, wo für Entscheidungen eine konkrete Vorstellung vom Kunden notwendig ist.

Das Problem: Es ist sehr aufwendig, diese Personas zu entwickeln. Normalerweise werden quantitative und qualitative Studien durchgeführt, Erkenntnisse abgeleitet und anschließend verschiedene Personas entwickelt. Für ein hochwertiges fundiertes Set können für die erste Erstellung einige Monate Recherche nötig werden.

Personas machen Kudentypologien sichtbar

Leider sind in manchen Branchen die Personas fast schon wieder veraltet, bevor sie überhaupt erstellt sind. Denn eines der Ziele im Umgang mit Personas ist es, zu erkennen, wie sich durch gewisse Marktbewegungen und Trends die Bedürfnisse und das Verhalten einer Zielgruppe verändern. Dieses Anwendungsfeld spiegelt auch eine Umfrage durch das Norman Nielsen Institut wider. Demnach aktualisieren 28 Prozent der Befragten quartalsweise oder öfter ihre Personas, 46 Prozent alle ein bis vier Jahre und 26 Prozent alle fünf Jahre oder später. Vier Gründe für das Anpassen des Personasetts:

1. Das eigene Geschäft oder verwendete Technologien ändern sich, damit wandelt sich auch die angesprochene Zielgruppe.
2. Die Angebote des Wettbewerbs ändern sich und verändern Kundenbedürfnisse.
3. Manchmal wachsen Kunden auch aus einem Angebot heraus, mit dem Alter ändern sich Interessen, nachfolgende Generationen haben manchmal krass geänderte oder sogar gegensätzliche Vorlieben.
4. Äußere Einflüsse, wie die Coronapandemie oder der Klimawandel, ändern die Art und Weise, wie wir leben, und damit auch unsere Wünsche und Vorlieben.

Was liegt also näher, als die enorme Datenfülle, die heute über menschliche Bedürfnisse und Absichten online zur Verfügung steht, zu nutzen, um Kudentypologien automatisiert sichtbar zu machen? Seit Jahren sammeln große und kleine Unternehmen Nutzerdaten auf verschiedenen Plattformen und verknüpfen sie zu Profilen. Meist stecken diese Profile verborgen in den Empfehlungsalgorithmen von Netflix, Facebook, Amazon und vielen anderen Online-Shops.

Doch AI kann inzwischen viel mehr. Die Kunst bei der Suche nach Anwendungsfällen ist es, sich der unterschiedlichen Fähigkeiten maschinellen Lernens bewusst zu werden (siehe Kapitel «Einsteigen – AI Mehrwert» auf Seite 50 und «Sicher landen» auf Seite 242). Die Stärke der lernenden Systeme liegt unter anderem darin, nicht nur Analysen und Prognosen liefern zu können, sondern auch Inhalte zu generieren.

Auf Basis der Daten lassen sich daher dynamische Personas erstellen, deren Elemente von unterschiedlichen AI-Modellen gespeist werden.

So gibt es fertige AI-Modelle, die uns lebensechte Fotos fiktiver Personen generieren können. So sind, während wir dieses Buch schreiben, bereits fast drei Millionen fotorealistische Porträts von nicht existierenden Menschen in der neuen Stockfoto-Datenbank «generated.photos» entstanden.

Textgeneratoren sind in der Lage, aus Daten gut lesbare Zusammenfassungen zu erstellen. Wieder andere Modelle analysieren Verhaltensmuster oder sortieren Konsumenten in bestimmte Kategorien.

Wenn wir also so ein komplexes Problem haben, wie eine Persona, können wir unterschiedliche Fähigkeiten kombinieren. In der Praxis sind das jeweils getrennte AI-Projektabschnitte, deren Resultate in ein gemeinsames Ergebnis münden.

AI ermöglicht es, die Daten in Echtzeit abzufragen. Wir erhalten so immer ein aktuelles Bild des Ist-Zustands. Spätestens hier können Menschen nicht mehr mithalten – und das löst exakt das Problem, das viele Innovatoren haben. Ihre Persona veraltet nicht mehr. Sich ändernde Bedürfnisse lassen sich schnell aktualisieren. Wir nennen das Live-Persona.

Nie da gewesene
Genauigkeit

Da wir aber für das Auswerten von Daten für Personas ohnehin eher Millionen von Datensätze auswerten, lassen sich Bedürfnisse auch mit mehr Genauigkeit und in einer nie da-gewesenen Granularität vorhersagen.

Wir könnten also, wenn wir das brauchen, einer automatisierten Persona auch noch beibringen, in die Kundensegmente hineinzuzoomen. Bedürfnisse könnten auf diese Weise immer genauer erkannt und immer kleinere Nischengruppen aufgedeckt werden. Wenn das für eine spezifische Aufgabe notwendig ist, kann dies bis auf die Ebene einer einzelnen Person geschehen – um zum Beispiel maßgeschneiderte Lernangebote zu erzeugen.

In der Praxis ist das dann wichtig, wenn unterschiedliche Abteilungen im Unternehmen die Persona sinnvoll nutzen wollen. Marketing benötigt größere Segmente für die Entwicklung von Kampagnen, Innovatoren benötigen jedoch ein detaillierteres Bild. Auf diese Weise müssen nicht mehrere Personas für die unterschiedlichen Anwendungsbereiche erstellt werden, sondern nur ein Personasystem.



Was eine gute Persona ausmacht

- Eine Persona muss nachvollziehbar sein (als wäre sie eine echte Person).
- Eine «reale» Darstellung menschlicher Eigenschaften (kein Datenblatt).
- Abgeleitet von echten Insights, abgesichert durch Recherche oder Live-Daten.
- Der in der Persona beschriebene Bedarf muss im Rahmen eines definierten Kontextes stehen (Industriespezifisch, produktspezifisch, oder Ähnliches).
- Eine authentische Persönlichkeit mit individuellen Eigenschaften.
- Sie repräsentiert eine echte Zielgruppe.
- Ergebnisse der Recherche sollten auch angewöhnte und unbewusste Verhaltensweisen aufgreifen – und nicht nur offensichtliches Verhalten und direkt berichtete Tatsachen.
- Keine Stereotypen, die eine irreführende Generalisierung sein können.
- Kein Schwerpunkt auf demografischen Daten – das Verhalten ist wichtiger. Hier kommt es vor allem auf das Datenanalysemodell an und wie das Verhalten daraus abgeleitet wird.

Szenario

Softdrinkhersteller

Für die Getränkebranche spielt das frühe Erkennen von Trends eine wichtige Rolle. Immer öfter etablieren sich Start-ups mit neuen Marken und bedrohen die Marktanteile etablierter Hersteller. Unter diesem Druck steht unser Beispielunternehmen, ein Softdrinkhersteller. Die Folge: Das Unternehmen muss schneller reagieren: auf Bartrends (Zutaten für Mixgetränke), Gesundheitsbewusstsein (zuckerarme oder vitaminhaltige Limonaden), soziale Bedürfnisse (fairer Handel) und mehr. Die Interessen der Zielgruppe ändern sich rapide.

Warum AI?

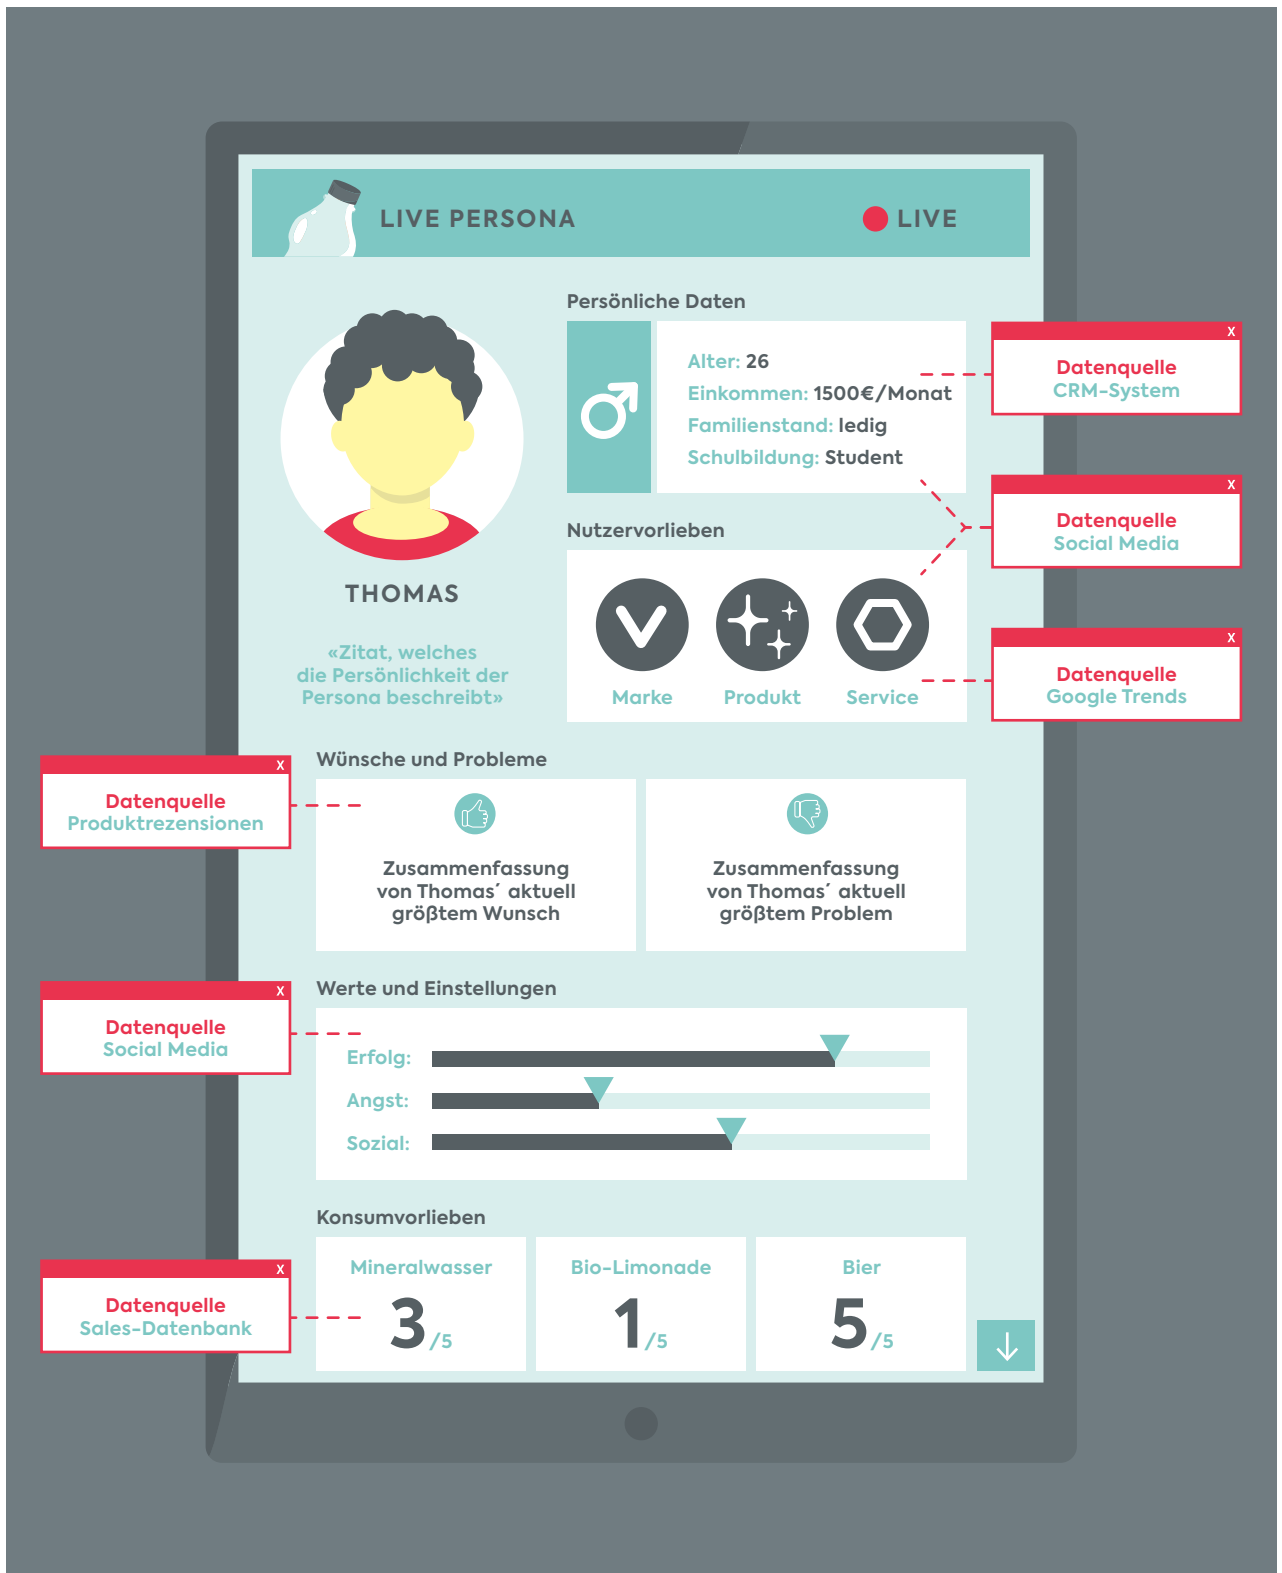
Das Unternehmen setzt seit Jahren Personas ein, um sich ein genaues Bild von der Zielgruppe zu machen. Doch die Mitarbeiter in Marketing und Entwicklung stellen fest, dass die Personas zu schnell veralten. Um dem steigenden Innovationsdruck zu begegnen, muss die Marketingabteilung Mikrotrends schneller erkennen, und das Innovationsteam benötigt für die Produktentwicklung eine klarere Vorstellung der Kundentypologien, die den Mikrotrends folgen. Nur dann kann sie schneller besser passende Produkte entwickeln.

Der AI-Ansatz

Als Antwort auf die Schwierigkeiten im Markt sollen Personas für den Raum Nordamerika künftig automatisch erstellt werden und den Bedürfniswandel der Zielgruppe stets aktuell zeigen. Die Anforderungen an die zu erstellenden Personas sind klar definiert:

1. Eine real wirkende Darstellung menschlicher Eigenschaften, um eine **authentische Persönlichkeit** mit eigenem Charakter zu zeigen.
2. Abgeleitet von **echten Daten**.
3. Sie repräsentiert eine spezifische **Zielgruppe**.
4. Sie deckt **unbewusste Verhaltensweisen** auf.
5. Sie vermeidet **Stereotypen**.

Wir erweitern für diese Aufgabe den Ansatz aus dem Trend-szenario. Dort haben wir User Generated Content als Datenquelle verwendet. Um die vielen Facetten einer Persona darstellen zu können, ergänzen unternehmensinterne Daten den Datenpool aus dem CRM-System und kombinieren diese mit der AI-Fähigkeit, eigene Inhalte, wie Textabschnitte und Fotos, zu erzeugen. Aus den Elementen werden so visuell ansprechende Personas zusammengesetzt.





1. Ziel definieren

AI-Mehrwert



Auftrag

Live Zielgruppenanalyse Nordamerika in Form von Personas für unser Getränke-segment (FMCG)

Erwarteter Mehrwert durch AI

Objektivitätsgewinn (kein Bias bei Recherche und Auswertung).
Zeitersparnis (automatisierte Recherche und Erstellung von Personas).
Qualitätsgewinn (Daten einbeziehen, die manuell nicht nutzbar wären; mehr Daten aus unterschiedlichen Quellen).

Challenge



Wie können wir für unsere internen Anwender datengetriebene Personas kreieren? Sie sollen in unserem schnelllebigsten Marktsegment immer auf dem neuesten Stand sein (Echtzeit), damit wir auf Nachfrageveränderungen schneller mit neuen Produkten reagieren können.

Output



Erkennen



Vorhersagen



Erzeugen



Outputformat

Grafisch aufbereitete Persona-steckbriefe, die mit Echtzeitdaten befüllt werden.



2. Daten recherchieren

Datenquellen



Typ

Quelle

Warum?

A	Sozio-demografische (Kunden)daten	FB, Instagram, CRM-System	Kundenstruktur verstehen, Persona lebendiger machen
B	Interessen, Bedürfnisse aus Suchanfragen	FB, Instagram, Google Trends	Kundenneigungen verstehen, Potenziale finden
C	Probleme, Wünsche, Bewertung: Konkurrenzprodukte	CRM, Amazon Fresh und Instacart Produktbewertungen	Verbesserungspotenziale eigener Produkte finden
D	Profilfotos	generated.photos/faces	Der Persona ein Gesicht geben

Datenprüfung



Priorität

Beschaffung

Technik

A	hoch	niedrig	niedrig
B	hoch	niedrig	niedrig
C	hoch	niedrig	niedrig
D	hoch	niedrig	niedrig

Datenerhebung



Grund für die Datensammlung

Kundenstruktur verstehen	Kundenneigungen verstehen	Potenziale in unseren Produkten finden	Der Persona ein Gesicht geben
--------------------------	---------------------------	--	-------------------------------

Datentypen

Demografische Daten	Interessen, Bedürfnisse durch Surfverhalten	Probleme, Wünsche Bewertung: Konkurrenzprodukte	Profilfotos
---------------------	---	---	-------------

Priorität

Beschaffung

Technik

hoch	hoch	hoch	hoch
niedrig	niedrig	niedrig	niedrig
niedrig	niedrig	niedrig	niedrig



3. Lernkonzept erstellen


Maschinenfähigkeiten		
Aufgabe	Quelle	Fähigkeit
A Erstellung demografischer Personaprofilen	FB, Instagram, CRM-System	Infos extrahieren, Gruppieren, Massendaten
B Personafelder mit Informationen füllen, visualisieren	FB, Instagram, Google Trends	Daten gruppieren, Infos extrahieren
C Relevanz einzelner Produkte für Persona einschätzen	CRM, Amazon Fresh und Instacart Produktbewertungen	Erkenntnisse ergänzen, Lernen mit vielen Daten
D Demografie-basierte Fotos für Profile auswählen	generated.photos/faces	Erkenntnisse ergänzen, Lernen mit vielen Daten



4. Entscheidung treffen

Vorgehensvergleich		
	Ohne AI	Mit AI
Personal	Innovations-, Researchexperten, PL	DS- und ML-Experten, Innovationsexperten, PL
Zeit	3 M Umsetzung für ein Personaset	1 M Vorbereitung 3 M Umsetzung
Kosten	Niedrig – mittel	Mittel – hoch
Hürden	Langsam, kein Update, Bias, Massendaten	Wenig Expertise, hohe Initialkosten, Aufwand
AI-Potenzial	Time-to-Market, Big Picture: Bedürfnisse	

Trainingsparameter	
Menschlicher Maßstab 1 fundiertes Personaprofil pro Woche (ohne Echtzeit-Aktualisierung)	Minimalanforderung Auswertung > 60% aller Social Media und Google Trenddaten; immer noch genauer als Mensch
Erwünschtes Zielmaß Auswertung von 80% aller relevanten Datenquellen, für akkurate Zielgruppendarstellung	Mindestvertrauen > 95% der Daten richtig zugeordnet (Kundensegmente, Neigungen, Werte etc.)

Recall  Precision

Entscheiden	
Ergebnisqualität/ Geschäftswert	<div><div>Nichts wie ran!</div><div>Nur wenn langfristig strategisch relevant</div></div>
Ist es wirklich notwendig?	<div><div>Auf keinen Fall!</div></div>
Risiko/Aufwand	

Eine Persona automatisch erstellen

Eine Persona besteht aus sehr vielen, unterschiedlichen Elementen. Wir werden Bilder erzeugen, demografische Daten und Bedürfnisse analysieren, eine Wertewelt erzeugen sowie typische Produkte und Services darstellen, die die Zielgruppe schätzt, und die uns helfen, uns selbst ein Bild von diesem

Kundenarchetyp zu machen. Interessant ist die Verknüpfung von vielen unterschiedlichen Datentypen zu einem Gesamtbild, das sich zudem noch fortlaufend aktualisieren lässt. Die Menge an zu verknüpfenden Daten macht vor allem die Aufbereitung aufwendig.



Ziel definieren AI Value Map

Der Auftrag

Live-Zielgruppenanalyse Nordamerika in Form von Personas für unser Getränkesegment (FMCG)



Manuelle Projektschritte

Beschreibung

1

Marktforschung
(Zielgruppen eingrenzen)

Qualitative
Recherche
(Anreicherung der
MaFo-Daten)

Quantitative
Recherche
(Quantifizierung
der qualitativen
Erkenntnisse)

Kundensegmente
definieren

Personas erstellen

Typische Pain Points

2

Hoher Zeit- und
Personalaufwand
(wenn selbst
durchgeführt)

Hoher Aufwand,
stichprobenhaft,
Bias, komplexe
Muster unerkannt

Viele Daten,
relevante Fakten
identifizieren

Richtige Abgren-
zung zwischen
Segmenten, Bias,
Zeitaufwand

Schnell veraltet

Geschäftlicher Mehrwert durch AI

Zeitersparnis,
Big-Picture-Blick,
neue Daten-
quellen möglich

Geschwindigkeit,
Objektivität,
latente Wünsche
aufdecken,
Automatisierung

Zeitersparnis,
Big-Picture-Blick,
Datenmassen
verarbeiten

Objektivität
(=Verlässlichkeit),
Ergebnisqualität,
Zeitersparnis

Echtzeit-Anpas-
sung, neue Muster
schneller erkennen,
datengetriebene
Ergebnisse

Hier kann
AI unterstützen:



3



Ziel definieren Challenge Guide



Elemente

Herausforderungen

Manuelle Datenerhebung:
Lange Dauer, wenn nicht extern
einkaufbar

Schnelllebiger Markt, Bedürfnisse
ändern sich schnell

Nutzer/Zielgruppe

Marketing, Vertrieb,
Innovationsabteilung,
Forschung und Entwicklung

Geltungsbereich/ Umfang

Nordamerika

Zeitraumen

Projektdauer:
3 Monate

Analysezeitraum:
Echtzeit

Geschäftlicher Mehrwert durch AI

Zeitgewinn

Echtzeitanalyse

Hohe datengetriebene
Ergebnisqualität


4

Zusammenfassung

Wie können wir für unsere
internen Anwender
datengetriebene Personas
kreieren? Sie sollen in unserem
schnelllebigen Marktsegment
immer auf dem neuesten Stand
sein (Echtzeit), damit wir auf
Nachfrageveränderungen
schneller mit neuen Produkten
reagieren können.

Wie es geht

1. Ziel definieren



So könnte der Output für die AI-Persona skizziert werden.

Dieses Szenario ist insofern anspruchsvoll, weil sowohl viele unterschiedliche Daten als auch viele AI-Fähigkeiten benötigt werden, damit die Einzelschritte des Vorgehens automatisierbar werden.

- 1 Wir nähern uns dem Problem wie üblich, indem wir das Vorgehen in seine **Einzelschritte aufschlüsseln**. Die AI Value Map enthält fünf unterschiedliche Arbeitsschritte. Dabei sind die ersten zwei sehr typisch für Rechercheprojekte: Sie dienen dazu, das Thema erst einmal zu verstehen und einzugrenzen.
- 2 Umfassende Recherchen zu Märkten, Konsumententrends und die richtige Abgrenzung zwischen den einzelnen Kundensegmenten bedeuten immer sehr viel Arbeit. Sie sind geprägt von einem gewissen Unsicherheitsfaktor. Dazu gehören kognitive Verzerrungen (Bias). Sie kosten dazu viel Zeit und Personal.
- 3 Der Mehrwert liegt folglich vor allem in drei Aspekten: **Objektivitätsgewinn** (keine kognitive Verzerrung mehr bei Recherche und Auswertung). **Zeitersparnis** (nach Programmierung des AI-Modells automatisierte Recherche und Erstellung von Personas mit Echtzeitaktualisierung). **Qualitätsgewinn** (Daten einbeziehen, die manuell nicht nutzbar wären; mehr Daten aus unterschiedlichen Quellen).
- 4 Unsere Challenge für das Projekt ist noch recht allgemein gehalten, wie das Template zeigt. Sie definiert nur die Rahmenbedingungen. Wichtig ist, dass der geografische Raum groß genug ist, um viele Daten zu analysieren; die Zielgruppe, Marketing benötigt vielleicht andere Informationen als Entwickler in den Personas, und der Wunsch nach Echtzeitanalyse. Diese stellt besondere Anforderungen an das AI-Modell.

Als **Output** skizzieren wir, wie die Angaben für unsere Persona dargestellt werden sollen. Eine grobe Skizze reicht aus – es geht vor allem um das Darstellungsprinzip. Das ist von Branche zu Branche und Geschäftsmodell zu Geschäftsmodell unterschiedlich.

2. Daten recherchieren

Für die Aktion, Daten zu recherchieren, ist es wichtig zu verstehen, wie Menschen heute ihre Bedürfnisse ausdrücken. Welche Informationen sollen in der Persona enthalten sein, damit die Zielgruppe aus Marketeers und Innovatoren damit arbeiten kann? Wie lässt sich die gewünschte Darstellung der Persona mit Daten untermauern?

Zu Beginn sollten nur wenige Datentypen und Personafelder definiert werden, um die Komplexität nicht zu groß werden zu lassen. Weitere Felder können später hinzugefügt werden. Die Persona des Getränkeherstellers enthält daher zunächst ein Bild, demografische Angaben, einen Abschnitt über Bedürfnisse, eine Wertewelt in Form von Tags sowie eine Ansicht typischer Produkte und Services.

Funktionen von Datentypen

Dafür wird eine Reihe unterschiedlicher Datentypen benötigt. Sie erfüllen unterschiedliche Funktionen:

Soziodemografische Daten: Mit ihrer Hilfe werden die Archetypen eingeteilt.

Suchanfragen nach Produkten, Marken, Services. Sie erlauben es, Trends zu erkennen, diese mit demografischen Daten zu verknüpfen und Nutzervorlieben herauszuarbeiten.

Der **Umsatz** der eigenen Produkte gibt in Verbindung mit soziodemografischen Daten Aufschluss über Konsumvorlieben.

Kundenfeedback ermöglicht das Identifizieren von Problemen und Wünschen in Zusammenhang mit bestimmten Produkten oder Themen.

Social Media Beiträge geben Aufschluss über die Werte und Einstellungen der Zielgruppe.

Als Datenquellen kommt User Generated Content infrage, also ein Mix aus Social Media, Amazon-Fresh-Bewertungen oder Forenbeiträgen. Dazu interne Datenquellen, wie CRM-Systeme, Interne Vertriebsdaten, Kundendienst-Hotline-Mitschnitte und Ähnliches mehr.

Die **Data Checklist** zeigt, wie eine Datenquelle plus ihre Alternative analysiert werden. So entsteht ein Steckbrief, der im Gespräch mit AI-Experten hilft, mögliche Hürden aufzudecken – oder nach weiteren Alternativquellen zu suchen. Die Angaben fließen später in die Data Journey Map ein. Der Datencheck muss für jede Quelle gemacht werden.



Daten recherchieren Data Checklist



Datentyp

Suchanfragen

Warum?

Interesse an bestimmten Produkten, Marken, Services, Themen ermitteln, um die Persona lebendiger wirken zu lassen

Die Basisinformationen

EIGENTÜMER

Wer besitzt sie und Rechte an ihnen?
Welche Stakeholder sind involviert?

Datenquelle

Google Trends

Alphabet Inc (Google)
–

Alternative Datenquelle

Onlineshop Walmart

Walmart
Vertriebsleitung

ZUGANG

Wo befinden sie sich?
Wie ist der Zugang geregelt?
Wie lassen sie sich nutzen?

Google Trends
Frei zugänglich
Inoffizielle API, «pytrends»

Onlineshop-Datenbank
Zustimmung durch Vertrieb
Export aus der Datenbank

KOSTEN

Welche Kosten fallen an?

–

Gegengeschäft, Austausch von Erkenntnissen

Datenqualität

AKTUALITÄT

Wie aktuell sind sie?
Wie häufig werden sie aktualisiert?
Wie oft muss ich darauf zugreifen?

Sehr
Konstante Updates
Konstant (da Echtzeitabfrage)

Sehr, «Datenleichen» möglich
Tägliche Updates
Konstant (da Echtzeitabfrage)

FORMAT

Wie liegen sie vor?
Welche Felder liegen vor?

Strukturiert
Schlüsselwort, Zeitintervall,
Kategorie, Granularität

Strukturiert, Datenbank
Kundensegment, Produktkategorie, Zeitintervall, Umsatz

ZUSTAND

Für Aufgabe und Training vorbereitet?
Datensätze (Aufgabe/Training) komplett?
Wie eindeutig sind sie?
Wie groß ist die Datenmenge?
Wie repräsentativ sind sie?

Ja
Ja
Eindeutig
Minimal, da nur Text
Vollständig repräsentativ

Ja
Evtl. Datenlücken
Eindeutig (Fehler möglich)
N.a. (minimal, da nur Text)
Repräsentativ für Nordamerika

Bewertung

Priorität



Beschaffungsaufwand



Technischer Aufwand



hoch mittel niedrig

3. Lernkonzept erstellen

Für dieses Szenario zeigt der nebenstehende «AI Skill Navigator», welche Fähigkeiten notwendig sind, um die vielen unterschiedlichen Datentypen zu einer Persona zu verarbeiten. Mithilfe der Erklärungen lässt sich nachvollziehen, aus welchem Grund die einzelnen Machine-Learning-Fähigkeiten gebraucht werden.

Auf dieser Basis erstellen wir im nächsten Schritt ein Lernkonzept. In der Praxis kann es sein, dass die Fähigkeiten sich auf zwei oder drei unterschiedliche AI-Modelle verteilen. Dann muss das Lernkonzept entsprechend öfter erstellt werden. Bei der Entscheidung, wie viele und welche Modelle benötigt werden, helfen Experten wie der Machine Learning Engineer. Aber mit der Zeit bekommt man als Innovator auch ein Gefühl für existierende Modelle und Frameworks.

Das Trainingsmodell für die AI-Persona muss angesichts der Datenvielfalt sehr gut darin sein, unterschiedliche Merkmale zu erkennen. Eine extrem hohe Trefferquote (> 90 Prozent) ist nicht so wichtig. Dadurch hält sich der Trainingsaufwand an dieser Stelle auch eher in Grenzen. Eventuell muss das Modell nachtrainiert werden, wenn sich das Marktumfeld ändert und neue Datenquellen oder Personabestandteile erforderlich werden.

Der Hauptaufwand für dieses AI-Modell liegt in der Aufbereitung und anschließenden Interpretation der Trainingsdaten, vor allem, wenn es darum geht, die weniger greifbaren, weichen Faktoren, wie Werte oder Bedürfnisse, zu ermitteln.

Dazu sind Kenntnisse aus Fachgebieten wie Marketing, Soziologie und Psychologie erforderlich. Denn hier sollen aus Daten Werte und Persönlichkeitsmerkmale abgeleitet werden. Für eine Stimmungsanalyse müssen Redewendungen in Social Media Posts zum Beispiel als zustimmend oder ablehnend kategorisiert werden. Erst dann können diese Aussagen für das Training verwendet werden. Um Persönlichkeitsmerkmale zu erkennen, muss daher ein erheblich höherer Aufwand beim Labeln der Aussagen betrieben werden.

Eine andere Möglichkeit besteht darin, Datensätze zu finden, die genau solche Werte bereits enthalten.



Lernkonzept erstellen

AI Skill Navigator



Passende Produkt- und Servicepräferenzen zuordnen, um sie danach zu visualisieren

vorhersagen



Objekte erkennen und klassifizieren
(Auf Bildern Hunde und Katzen auseinanderhalten)



Klassifizierte Daten gruppieren oder sortieren
(Aus Tierbildern Hunde- und Katzenstapel bilden)

Texte analysieren und Teile daraus den verschiedenen Personafelder zuordnen

analysieren etc.)
erkennen)



Informationen extrahieren und Aktionen ableiten
(Wenn Babygeschrei über 100 dB, dann stillen)



Informationen aus Beiträgen extrahieren und in Feldern der Persona zusammenfassen
(Hu



Erfolgversprechendste Schritte für einen Entscheidungsprozess auswählen
(In möglichst wenig Zügen einen Zauberwürfel lösen)

2: Verstehen, kommentieren und generieren



Sprache (Linguistik) und Emotionen verstehen, sowie kommunizieren
(Supportanfrage verstehen und geeignet antworten)

Emotionen in Social-Media-Beiträgen verstehen und sie der Wertewelt und Präferenzen der Persona zuordnen

h
a
ratsantrag)



Inhalte verschiedener Art kombinieren
(Röntgenbild und Diagnose, Deepfake Videos)



Neue Inhalte generieren
(Neue Zeitungsartikel, Webdesigns etc. generieren)

Bestehende interne Daten über Kunden mit neuen Erkenntnissen anreichern



Vorhandenes Wissen mit zusätzlichen Erkenntnissen kombinieren
(Neue Studienerkenntnisse in med. Diagnose einbinden)



Lernen mit vielen Daten
(Autonome Fahrzeuge steuern)

Massendaten aus sehr unterschiedlichen Datenquellen zum Maschinentraining nutzen

erkennen)



Anpassung an veränderliche Bedingungen
(Roboter und Menschen arbeiten zusammen)



Automatisiertes, selbständiges Weiterlernen
(Wettervorhersagen mit Realität abgleichen und künftige Prognosen anpassen)



Anpassung der Personafelder in Echtzeit, sobald wichtige neue Erkenntnisse entstehen

4. Entscheidung treffen

Sehen wir uns an, wie sich das AI-Konzept der Persona im Vergleich zum traditionellen Vorgehen schlägt.

- 1 Im Business Check zeigt sich deutlich: Das Erstellen des AI-Modells benötigt ungefähr so lang und ähnlich viel Personal wie das Erstellen einer klassischen Persona.
- 2 Hinzu kommen hohe Initialkosten für das Aufbereiten der Daten und das Trainieren des Modells.
- 3 Je nachdem, wie erfahren ein Unternehmen mit der Umsetzung von AI-Projekten ist, schlägt womöglich auch noch eine fehlende AI-Expertise negativ zu Buche und gegebenenfalls eine noch fehlende IT-Infrastruktur, die für AI-Projekte geeignet ist.

Mit AI-Experten sollte außerdem diskutiert werden, welchen Aufwand das Nachtrainieren des AI-Modells für die automatische Aktualisierung der Personas bedeutet. Das muss in die Mehrwertüberlegungen einfließen.

- 4 Es ist nur sinnvoll, das Projekt weiterzuentwickeln, wenn das Unternehmen vorhat, Personas dauerhaft und intensiv zu nutzen. Die Vorteile in Form von Zeitersparnis, besseren Produkten und damit einer besseren Positionierung des Unternehmens werden sich erst nach mehrfacher Anwendung zeigen. Dann würde sich auch ein weiterer Vorteil bemerkbar machen: Die intensive Nutzung eines AI-Tools in Innovation und Marketing kann den Boden bereiten, um weitere AI-basierte Werkzeuge entweder selbst zu entwickeln oder als Service den Mitarbeitern zur Verfügung zu stellen.



Entscheidung treffen Business Check



Kriterien	ohne AI	mit AI
1 Personal (FTE)	2–3 Innovations-/Researchexperten Sales, Marketing und R&D Team (Reality Check)	Data Scientist ML Engineer 1 Innovations-/Researchexperten Sales, Marketing und R&D Team (Reality Check)
2 Zeit	3 Monate fulltime Umsetzungszeit für ein Personaset	1 Monat Vorbereitung 3 Monate Umsetzung für laufendes Modell, das sich in Echtzeit aktualisiert
3 Kosten	Niedrig – mittel	Hohe Initialkosten Niedrige bis mäßige Kosten im Regelbetrieb
3 Hürden	Geringere Geschwindigkeit bei Erstellung von Personas Kein schnelles Update möglich Bias bei Recherche Kognitive Grenzen für die Masse an zu durchforstenden Daten	Fehlende AI-Expertise Fehlende IT-Ressourcen Hoher Initialaufwand Eventuell konstantes Nachtrainieren nötig, um Veränderungen im Markt effektiv nachzubilden
4 AI-Potenzial	Wettbewerbsvorteile (Time-to-Market) durch Echtzeitanalyse Kostenersparnis durch gezielte Bedürfnisanalyse am Markt First-of-a-kind-Produkte möglich (Trendsetter werden) Ermittlung potenzieller Neukunden	



Die AI-Persona ermöglicht mittelfristig die Positionierung des Unternehmens als besonders nutzerorientiert. Die Fehlerquote bei Produktentwicklungen kann gesenkt werden, weil die Bedürfnisse der Zielgruppen jederzeit sichtbar sind.

Was wir gelernt haben ...

1. **Die Auswertungslogik beeinflusst die AI-Leistung.**
Wenn aus unstrukturierten Daten, wie Wortbeiträgen in den Social Media und auf Webseiten, Erkenntnisse gewonnen werden sollen, muss definiert werden, nach welchen Begriffen, Phrasen oder Mustern die AI suchen soll. Gegebenenfalls kann für das Erlernen dieser Schlüsselfaktoren ein eigenes AI-Modell trainiert werden. Diese Entwicklung der Auswertungslogik beeinflusst entscheidend, wie das Ergebnis des eigentlichen AI-Modells aussieht.
2. **Datenaufbereitung kann sehr aufwendig sein.**
Je mehr Datenquellen genutzt werden, desto aufwendiger wird die Datenaufbereitung. Es müssen unter Umständen unterschiedliche Schnittstellen geprüft werden, um auf die Daten zugreifen zu können, gegebenenfalls sind auch jeweils eigene Trainings- und Testdatensets notwendig. All dies erhöht den Aufwand.
3. **AI-Modelle können komplexe Prozesse automatisieren.**
Die Kombination aus vielen AI-Fähigkeiten ermöglicht es, komplexe Arbeitsprozesse zu automatisieren, die aus so unterschiedlichen Tätigkeiten, wie Recherche, Analyse und Kreation von Bildern und Texten, bestehen.
4. **Der Trainingsaufwand sinkt mit abnehmender Genauigkeit.**
Wenn ein AI-Modell eher eine hohe Trefferquote benötigt, also viele unterschiedliche Objekte erkennen und interpretieren soll, es aber nicht so sehr auf die extrem hohe Genauigkeit ankommt, ist der Trainingsaufwand erheblich kleiner – sowohl, was die Anzahl der Trainingsdaten angeht, als auch die benötigte Zeit.
5. **Eine AI-Produktionslinie spart viel Zeit.**
Wer häufiger komplexe AI-Modelle entwickeln will, die viele Datentypen mit vielen AI-Fähigkeiten kombinieren oder bei deren Algorithmen viel eigener Entwicklungsaufwand betrieben werden muss, sollte über einen professionellen AI-Produktionsprozess nachdenken. Der Entwicklungsaufwand kann so um bis zu zwei Drittel sinken (siehe «Sicher landen» auf Seite 242).

4. Ideen sichten

In großen Organisationen kommen schnell Tausende von Ideen zusammen.

Ideen auf dem
Prüfstand

Gute Ideen sind der Schlüssel für Neues. Sie gleichen ungeschliffenen Diamanten. Gelingt der richtige Schliff, entsteht ein Brillant. Wenn nicht, endet er vielleicht als gewöhnlicher Splitter auf einem Bohrkopf. Auf der Suche nach lukrativen Ideen bewerten Risikokapitalgeber weltweit zehntausende Gründerideen für neue Produkte und Dienstleistungen. Patente bergen eine Fülle an Erkenntnissen über Wege zur Problemlösung. Und die Zahl der Veröffentlichungen steigt seit Jahren.

Auch innerhalb von Organisationen werden Millionen investiert, um das Wissen der Mitarbeiter für Problemlösungen zu nutzen. Beim Autokonzern VW hatten die Beschäftigten 2018 mehr als 42 000 Ideen eingereicht. Etwa 50 Mitarbeiter kümmern sich dort um die Bearbeitung. Beim Logistikunternehmen DHL sind es 60 000 Vorschläge jährlich.

Im Innovationsmanagement werden Ideen normalerweise in Form von konkreten Kampagnen gesammelt, um die Kreativität der Mitarbeiter in für das Unternehmen sinnvolle Bahnen zu lenken. Diese Kampagnen orientieren sich an den im Rahmen der Unternehmensstrategie definierten Suchfeldern. Das kann für ein Industrieunternehmen, das Ideen für den Umgang mit neuen Technologien sucht, zum Beispiel eine konkrete Herausforderung für 3-D-Druck oder für Blockchain-Anwendungen sein, oder im Fall von Konsumgüterherstellern auch ein Aufruf für innovative, ressourcenschonende Verpackungsideen.

Selbst wenn das Thema auf diese Weise eingegrenzt wird, kommen in großen Organisationen schnell tausend Ideen zusammen. Wenn das Ideenmanagement gut funktioniert und generell eine aufgeschlossene, innovative Kultur existiert, ist die Beteiligungsquote recht hoch.

Die eingereichten Ideen werden in der Regel systematisch in Datenbanken abgespeichert, formal geprüft, an Entscheider oder teure, externe Experten weitergeleitet, bewertet und gegebenenfalls kategorisiert. Umgesetzt wird, was für die jeweilige Organisation den höchsten Nutzen oder Innovationsgrad und die höchsten Erfolgsaussichten verspricht.

Warum ist es schwierig?	Bei dieser Masse an Ideen ist es schwer, den Überblick zu behalten. Gibt es die gleiche Idee mehrfach – aber zu unterschiedlichen Zeiten eingereicht oder anders formuliert? Gibt es Varianten, die gemeinsam vielleicht erst eine gute Idee ausmachen – aber für sich genommen wenig hilfreich sind? Ist eine Idee vielleicht innovativ, aber einfach viel zu früh dran, um bereits einen Wert für das Unternehmen darzustellen? Und wer ist Experte genug, um eine Idee fundiert zu bewerten? In großen Organisationen mit 10 000 oder 100 000 Mitarbeitern ist auch das schwierig.
Was kann AI hier leisten?	AI-basierte Algorithmen sind prädestiniert für die Analyse von Dokumenten. Sie können sortieren, katalogisieren, Zusammenhänge herstellen und Ähnlichkeiten aufdecken. Lauter Eigenschaften, die für die Bewertung und Auswertung von Konzepten hilfreich sind. Werfen wir einen Blick darauf, welche Informationen in eingereichten Ideen verborgen sind, die sich mithilfe von lernenden Algorithmen zusätzlich sichtbar machen lassen: Die oben skizzierten Schwierigkeiten lassen sich mithilfe von AI alle lösen: automatische Expertensuche, Gruppierung nach ähnlichen Lösungsansätzen, Auffinden von doppelten Ideen.
Schwachstellen aufdecken	Darüber hinaus werden in eingereichten Ideen zu internen Verbesserungen immer auch interne, zu verbessernde Abläufe skizziert. Diese Probleme lassen sich automatisch extrahieren und visualisieren. So kann ein digitales Abbild von potenziellen Schwachstellen im Unternehmen erstellt werden.
Talente finden	Im Zusammenhang mit der Bewertung von Ideen können innovative Mitarbeiter für bestimmte Themen identifiziert werden. Ein Vorteil beim Aufbau von Innovationsteams.
Trends erkennen	Werden Ideen über die Zeit analysiert, lassen sich auch hier Trends erkennen – sowohl zu eingesetzten Lösungstechniken als auch zu bestimmten Problemen.
Ideen bewerten	Sogar die Bewertung von Ideen ist möglich – wie das funktioniert, zeigen wir im folgenden Szenario.

Szenario

Ideenwettbewerb

Bei einer Masse von Ideen sucht man die Nadel im Heuhaufen – wirklich sinnvolle innovative Ideen.

Warum AI?

Eine große internationale Organisation sucht nach innovativen Lösungen, um dem Klimawandel zu begegnen. In einem Ideenwettbewerb sollen Ideen für die Entwicklung «nachhaltiger Städte» gesammelt werden, dem Nachhaltigkeitsziel 11 aus dem Katalog der globalen Nachhaltigkeitsziele der Vereinten Nationen (Sustainable Development Goals, SDG). Die Organisatoren haben sich entschieden, dafür eine offene Plattform zu wählen und die Aufgabe weltweit als Ideenwettbewerb auszuschreiben. Der Crowd-Innovation-Ansatz soll helfen, möglichst viele und unterschiedliche Ideen zu erzeugen.

In dem Ideenwettbewerb werden über 10 000 Vorschläge erwartet. Den Ideen sollen Kategorien, wie Luftqualität, Sicherheit, Nachhaltigkeit, Mobilität, Inklusivität und viele weitere, zugeordnet werden. Die Organisatoren stehen jedoch vor dem Problem, dass die große Menge kaum zu bewältigen ist. Wenn Experten über 10 000 Ideen bewerten sollen, ist es naheliegend, dass innovative Ansätze übersehen werden – man sucht die Nadel im Heuhaufen. Man steht außerdem vor der Herausforderung, mit Doppelungen umgehen sowie unterschiedliche kulturelle Hintergründe und Realitäten aus aller Welt objektiv beurteilen zu müssen.

Der AI-Ansatz

In diesem Fall soll eine der Stärken Künstlicher Intelligenz, das Erkennen von Mustern, ausgespielt werden. Die Experten bewerten nur 500 Ideen. Danach übernehmen die Algorithmen. Sie sollen in zwei Stufen arbeiten. Natürlich können sie keine Texte lesen und wirklich verstehen. Sie können aber durch das verwendete ML-Modell den individuellen Fingerabdruck einer Ideenbeschreibung analysieren. Im zweiten Schritt sollen die Expertenbewertungen mit dem Fingerabdruck der Ideenbeschreibungen verglichen werden. Durch das Training mit den 500 Bewertungen lernt das AI-Modell, welches Ideenmuster für einen hoch bewerteten Ansatz steht. Das implizite Expertenwissen für diesen Anwendungsfall wird so in den Algorithmus übertragen.

Das Beispiel zeigt, dass mithilfe von AI-Modellen auch sehr viele unstrukturierte Daten handhabbar gemacht werden können. Besonders interessant ist, dass die Expertise einer Expertenjury für ein Thema einem Algorithmus vermittelt werden kann, sofern genügend Trainingsdaten vorliegen.



IDEENWETTBEWERB

Die Entwicklung von nachhaltigen Städten

DER ABLAUF

Start des Ideenwettbewerbs



10000

Ideen werden von den Teilnehmern eingereicht

Beschreibungstexte

Idee

Idee

Idee

Idee

1

Das AI-Maschinentraining



500

Ideen werden durch Experten bewertet

AI-Modell:
Es lernt, wie Experten zu bewerten

2

Analyse der Ideen

Schritt 1:
Die AI analysiert den Fingerabdruck der Beschreibungstexte

Idee

Idee

Schritt 2:
Die Ideen werden nach ähnlichen Fingerabdrücken gruppiert

Bewertung der Ideen

AI-Modell:
Es erkennt, welche Merkmale zu einer hohen Bewertung führen

Idee

Idee




4



1. Ziel definieren

AI-Mehrwert



Auftrag

Identifikation der besten Ideen und deren Merkmale aus unserem internationalen Crowd-Innovationswettbewerb zum Thema: Nachhaltige Städte (SDG 11).


Erwarteter Mehrwert durch AI

Latente Muster und Ideenmerkmale in großen Datenmassen (ca. 10 000 Ideen) aufdecken
Zeitgewinn, Kosteneinsparung und Skalierung




2. Daten recherchieren

Datenquellen




	Typ	Quelle	Warum?
A	Ideenbeschreibung in Textform	Plattform Ideenwettbewerb	Latente Merkmale aus Ideen ableiten
B	Experten- und Nutzerbewertung aller Ideen	Plattform Ideenwettbewerb	Lernen, welche Ideen, warum gut bewertet wurden
C			
D			













Challenge




Wie können wir in einer Masse von eingereichten Ideen automatisiert latente Merkmale aufdecken und deren Einfluss auf hohe Experten- und Nutzerbewertungen ermitteln, um so die vielversprechendsten Lösungsansätze für die weitere Betrachtung innerhalb unserer Produkt- oder Serviceentwicklungsprozesse auszuwählen?


Datenprüfung





	Priorität	Beschaffung	Technik
A	hoch 	niedrig 	mittel 
B	hoch 	niedrig 	niedrig 
C			
D			

Output






Erkennen 




Vorhersagen 

Erzeugen 


Outputformat

Visuelle Ideencluster, die jeweils die wichtigsten Ideenmerkmale und deren Einfluss auf eine hohe Gesamtbewertung in Prozent anzeigen.





Datenerhebung















Grund für die Datensammlung

Latente Merkmale aus Ideen ableiten	Lernen, welche Ideen, warum gut bewertet wurden		
-------------------------------------	---	--	--

Datentypen

Ideen in Textform	Experten und Nutzerbewertung		
-------------------	------------------------------	--	--

Priorität				
Beschaffung				
Technik				



3. Lernkonzept erstellen

Maschinenfähigkeiten		
Aufgabe	Quelle	Fähigkeit
A Ideenmerkmale identifizieren, klassifizieren	Plattform Ideenwettbewerb	Klassifizieren, Gruppieren, Semantikextraktion
B Zusammenhänge: Merkmale und Bewertungen	Plattform Ideenwettbewerb	Inhaltskombination, Vorhersagen, Auto-Weiterlernen
C		
D		



4. Entscheidung treffen

Vorgehensvergleich		
	Ohne AI	Mit AI
Personal	1 PL, 10 SDG Experten, 2 Innovationsexperten	1PL, 5 SDG Experten, Innovationsexperte, DS
Zeit	6 Wochen Wettbewerb 10 W. Expertenwertung	6 Wochen Wettbewerb 2 Wochen AI Projekt
Kosten	Mittel – hoch	Gering – mittel
Hürden	Zeit und Kosten, Muster in Datenmassen	Einreichungsqualität, viel Datenaufbereitung
AI-Potenzial	Wiederverwendbarkeit Modell, zukünftiger Expertenverzicht (Kosten- und Zeitersparnis)	

Trainingsparameter	
Menschlicher Maßstab 500 Ideen in 1 Woche von 5 Experten bewertet. Erkennen typischer Merkmale einer Idee	Minimalanforderung Mindestens 20 Merkmale klassifizieren; 70% der Ideen auf Merkmalbasis richtig bewerten
Erwünschtes Zielmaß Alle Ideen klassifizieren und clustern, 70% der Ideen auf Merkmalbasis richtig bewerten	Mindestvertrauen 90% der Merkmale haben Einfluss auf eine hohe Bewertung; 85% richtige Vorhersagen
<div><div></div><div></div><div></div><div></div><div></div></div> <div>Recall ————— Precision</div>	

Entscheiden	
Ergebnisqualität/ Geschäftswert	Nichts wie ran!
	Nur wenn lang- fristig strategisch relevant
Ist es wirklich notwendig?	Auf keinen Fall!
Risiko/Aufwand	

Ideenwettbewerb: Nachhaltige Städte

Der AI Planner zeigt die Kernparameter für die automatische Bewertung von 10 000 Ideen aus einem globalen Ideenwettbewerb. Das Konzept: Zunächst identifiziert das AI-Modell aus den Ideenbewertungen typische Merkmale. Anhand von 500 Expertenbewertungen lernt

das Modell anschließend, welche Ideenmerkmale wahrscheinlich zu einer guten Bewertung führen. Auf Basis dieses Wissens kann das AI-Modell anschließend die restlichen Ideen selbständig bewerten – im Optimalfall so gut wie menschliche Experten.



Ziel definieren AI Value Map

Der Auftrag

Identifikation der besten Ideen und deren Merkmale aus internationalem Crowd-Innovationswettbewerb: Nachhaltige Städte (SDG 11)



Manuelle Projektschritte

Beschreibung

1

Ideenwettbewerb durchführen

Bewertung durch
Expertenjury
und Vorauswahl
der besten Ideen

Auswahl der besten
Ideen, die
weiter ausgear-
beitet werden

Typische Pain Points

2

TN-Engagement
sinkt schnell,
Mehrfacheinrei-
chungen, Ideen
off-topic

Zeit- und Kosten-
aufwand, Bias,
Auswahl der «rich-
tigen» Ideen aus
Datenmassen

Kognitive Grenzen
bei der Muster-
erkennung in
Datenmassen

Geschäftlicher Mehrwert durch AI

–

Keine teuren
Experten mehr
nötig, Zeitgewinn
bei Auswertung,
latente Muster

Latente Muster,
akkurater
Vorhersagen
(Qualitätsgewinn),
Dauerbetrieb

Hier kann
AI unterstützen:



3



Ziel definieren Challenge Guide

4



Elemente

Herausforderungen

Hoher Kosten- und Zeitaufwand

Kultureller Bias

Identifikation der vielversprechendsten
Lösungen in Massendaten

Nutzer/Zielgruppe

10 000 Wettbewerbsteilnehmer
weltweit

Entwicklungsteam

Geltungsbereich/ Umfang

Weltweit

Zeitraumen

Wettbewerbsdauer:
6 Wochen

Gesamtprojektdauer:
3 Monate

Geschäftlicher Mehrwert durch AI


Automatisierte Ableitung
latenter Merkmale aus
Lösungen,
Zusammenhänge zwi-
schen Merkmalen und
Lösungserfolg erkennen.

Zusammenfassung

Wie können wir in einer Masse
von eingereichten Ideen
automatisiert latente
Merkmale aufdecken und
deren Einfluss auf hohe
Expertenbewertungen
ermitteln, um so die
vielversprechendsten
Lösungsansätze für die weitere
Betrachtung innerhalb unserer
Produkt- oder Service-
entwicklungsprozesse
auszuwählen?

Wie es geht

1. Ziel definieren



Die schematische Output-Darstellung zeigt, dass spezifische Merkmale in den Ideenbeschreibungen identifiziert werden sollen.

Crowd-Innovation-Wettbewerbe, richtig durchgeführt, sind ein sehr gutes Mittel, um schnell eine große Bandbreite qualitativ hochwertiger Ideen zu bekommen.

- 1 Der klassische Ablauf ist in der «AI Value Map» skizziert. Zunächst läuft der Wettbewerb sechs Wochen, um möglichst vielen Teilnehmern die Abgabe der Ideen zu ermöglichen. Eine Jury bewertet die Ideen und wählt die besten aus. Anschließend bekommt die Community die Gelegenheit, diese Auswahl ebenfalls zu bewerten. Aus diesen Bewertungen werden zum Schluss die besten Ideen ermittelt, die umgesetzt werden sollen.
- 2 Dabei gibt es typische Fehler: Neben formal fehlerhaften Ideenbeiträgen gibt es Doubletten, ähnliche Idee, die Experten sind, je nach ihren Wissensschwerpunkten immer in gewisser Weise voreingenommen, und der Mensch kommt bei Tausenden von zu bewertenden Ideen an kognitive Grenzen. Die Auswahl ist letztlich sehr schwer – vor allem bei einem solch komplexen Thema wie nachhaltige Städte.
- 3 Der Mehrwert liegt ganz klar in der objektiven Bewertung (Experten haben immer ihren persönlichen, auf Erfahrung basierenden Blickwinkel) und im Zeitgewinn – die Maschine wird nicht müde, sondern arbeitet sich fleißig durch alle eingereichten Ideen.
- 4 Der «Challenge Guide» zeigt den Projektumfang noch einmal im Überblick. In drei Monaten wollen wir nicht nur den Ideenwettbewerb durchgeführt, sondern auch ein solides AI-Modell aufgebaut haben, dass wir in zukünftigen Wettbewerben nutzen können. Nach drei Monaten wollen die Organisatoren die besten Ideen präsentieren. Anschließend kann sich das Entwicklerteam an die Ausarbeitung und Umsetzung der Ideen für die nachhaltige Stadt der Zukunft machen.

Die Analyseergebnisse werden als Ideencluster dargestellt (siehe Output-Grafik links). Jedes Cluster enthält als Zusatzinformationen die jeweils wichtigsten Ideenmerkmale und deren Einfluss auf eine hohe Gesamtbewertung in Prozent. So können die Entwickler besonders gut bewertete Ideenmerkmale bevorzugen oder sogar neu miteinander kombinieren.



Daten recherchieren

Datenquellen



1

A

Datentyp

Ideen-
beschreibung in Textform
Warum?

Latente Merkmale aus Ideen
ableiten

Datenquelle

Ideenwettbewerb-
Plattform

2

B

Datentyp

Expertenbewertungen
Warum?

Lernen, welche Ideen, warum
gut bewertet wurden

Datenquelle

Ideenwettbewerb-
Plattform

C

Datentyp

Warum?

Datenquelle

D

Datentyp

Warum?

Datenquelle

i

Was passiert, wenn Ideen Skizzen enthalten?

In diesem Szenario gehen wir davon aus, dass die Ideen mit Text beschrieben werden. Sollen auch technische Zeichnungen, Bilder, Handskizzen ausgewertet werden, wird die Komplexität beträchtlich erhöht. Andere AI-Fähigkeiten müssen eingesetzt und trainiert werden. Das Training dauert dann länger und eventuell auch die Aufbereitung der Daten. Das Problem ließe sich zum Beispiel lösen, indem die AI Ideen auf der Basis der Beschreibungen auswählt – und im Anschluss nur die relevanten Bilddaten von Hand beurteilt werden.

2. Daten recherchieren

AI-Modelle helfen uns, latente Merkmale in Texten zu identifizieren.

Auch wenn die Aufgabe, 10 000 Ideen automatisch auf ihren Innovationsgrad bewerten zu lassen, zunächst komplex erscheint: Die Datenlage ist in diesem Fall sehr übersichtlich.

1

Es gibt zwei Datentypen: Ideenbeschreibungen und Bewertungen. Beide stammen aus derselben Quelle, der Ideenmanagementplattform für den Wettbewerb. Die eingereichten Ideen müssen formalen Kriterien entsprechen. Es gibt einen Ideentitel, eine Beschreibung, die bestimmte inhaltliche Vorgaben erfüllen muss, und Kategorien, in welche die Idee eingeordnet wird. Jeder Wettbewerbsbeitrag enthält also eine Reihe von Kategorien. Das sind die strukturierten Datenbestandteile einer Einsendung. Interessant für die Auswertung ist jedoch der unstrukturierte Teil, die Beschreibung der Idee. Sie enthält sogenannte latente Merkmale, die sich auf Themen, wie Luftqualität, Sicherheit, Nachhaltigkeit oder Inklusivität, beziehen können. Das sind Begriffe, die den Kontext der Idee bilden.

2

Der Datentyp B, die «Expertenbewertungen», enthält ebenfalls mehrere Merkmale. Das sind Noten für verschiedene Kategorien, wie Innovationsgrad, Passung für das Thema «Nachhaltige Stadt» sowie deren Unterthemen und Umsetzbarkeit.

Für ein AI-Projekt ist es entscheidend, sich über die Gründe für einen bestimmten Datentyp klar zu werden. In diesem Szenario soll die AI zwei Dinge tun:

Die **latenten Merkmale** in der Fülle der rund 10 000 Einsendungen herausarbeiten.


Ideen annähernd so **akkurat einschätzen und bewerten**, wie ein Experte (dafür aber immer gleich und objektiv).

Diese Analyse der AI-Aktivitäten sollte im Zusammenspiel mit der Ausarbeitung der benötigten Datentypen geschehen. Wir fragen uns: Was soll die Maschine eigentlich für uns tun? In der Data Journey Map folgen diese beiden Aktivitäten einfach aufeinander. Das ist in diesem Fall eine leichte Übung. Sehen wir uns die nötigen Fähigkeiten für die erste Aufgabe an: «Latente Merkmale erkennen».

3. Lernkonzept erstellen

- 1 Um die latenten Merkmale im Beschreibungstext zu finden, muss der Algorithmus Text verarbeiten können. Dazu dient die Fähigkeit: «Sprache verstehen». Kombiniert mit «Text semantisch und im Kontext verstehen» erhält das AI-Modell die Basis, um später die Merkmale zu identifizieren. Weil 10 000 Ideen verarbeitet werden sollen, wird noch die Lernfähigkeit, «Lernen mit vielen Daten», ausgewählt.
- 2 Dieser Schritt befähigt das AI-Modell, Muster zu erkennen. Damit werden die latenten Merkmale in den 10 000 Ideenbeschreibungen identifiziert.
- 3 Ein latentes Merkmal einer Idee könnte zum Beispiel «geringere Reibung» sein. Das Merkmal findet sich bei Ideen für Cityroller, Ideen für Fahrräder und Ideen für Stromabnehmer bei U-Bahnen. Dieses Merkmal soll beim Klassifizieren mit der von den Veranstaltern vorgegebenen Kategorie «Mobilität» versehen werden. Auf diese Weise werden alle Merkmale klassifiziert. Ideen mit einem ähnlichen Mix latenter Merkmale (also ihrem charakteristischen Fingerabdruck) werden zu einer Gruppe zusammengefasst.

Bei der zweiten Aufgabe wird der charakteristische Fingerabdruck einer Idee mit den Expertenbewertungen kombiniert. Das Modul überträgt das implizite Wissen der Experten auf den AI-Algorithmus.
- 4 Das AI-Modell stellt Zusammenhänge zwischen Ideenmerkmalen und Expertenbewertungen her.
- 5 Werden neue Ideen eingereicht, können sie auch nachträglich in die Analyse einfließen und bewertet werden.



Lernkonzept erstellen AI Skill Navigator



1: Erkennen, analysieren und vorhersagen



Objekte erkennen
und klassifizieren
(Auf Bildern Hunde und Katzen auseinanderhalten.)



3
Klassifizierte Daten
gruppieren oder sortieren
(Aus Tierbildern Hunde- und Katzenstapel bilden)

Klassifizierte Ideen nach
ihren Merkmalen clustern

analysieren
etc.)
erkennen)



2

Informationen extrahieren
und Aktionen ableiten
(Wenn Babygeschrei über 100dB, dann stillen.)



Latente Merkmale in Ideen identifizieren



Erfolgversprechendste Schritte für einen
Entscheidungsprozess auswählen
(In möglichst wenig Zügen einen Zauberwürfel lösen)

2: Verstehen, kommentieren und generieren



1
Sprache (Linguistik) und Emotionen
verstehen, sowie kommunizieren
(Supportanfrage verstehen und geeignet antworten)



Ideenbeschreibungen inhaltlich verstehen



Text, Bild und Video semantisch
und im Kontext verstehen
(Person kniet vor einer anderen = Heiratsantrag)



Ideenbeschreibungen und Merkmale
inhaltlich in den Kontext einordnen

Ideenmerkmale zur Mustererkennung mit
Bewertungsergebnissen kombinieren



4
Vorhandenes Wissen mit zusätzlichen
Erkenntnissen kombinieren
(Neue Studienerkenntnisse in med. Diagnose einbinden)



Anpassung an
veränderliche Bedingungen
(Roboter und Menschen arbeiten zusammen)



1
Lernen mit
vielen Daten
(Autonome Fahrzeuge steuern)



5
Automatisiertes,
selbständiges Weiterlernen
(Wettervorhersagen mit Realität abgleichen und
künftige Prognosen anpassen)

Aus 10 000 Ideen wichtige
Merkmale extrahieren

erkennen)

Neue Ideen in die Analyse einfließen lassen

Die Experten haben 500 Ideen bewertet. Das in diesen Bewertungen enthaltene Wissen soll nun dem AI-Modell durch Training beigebracht werden.

1

Welche Einflussfaktoren müssen wir betrachten, damit wir im nächsten Schritt die Qualität des Ergebnisses definieren können? Wie das aussehen kann, zeigt der erste Abschnitt im Template rechts. Wenn die latenten Merkmale ermittelt werden, müssen sie so trennscharf sein, dass sie eine verlässliche Bewertung durch die AI ermöglichen. Das gilt ebenso für die Qualität der Generalisierung. Außerdem soll das AI-Modell reibungslos mit der Menge der zu analysierenden Ideen klarkommen und das in kurzer Zeit. Schließlich muss die Vorhersagequalität des AI-Modells betrachtet werden. Das ist die Wahrscheinlichkeit, dass eine AI-Bewertung annähernd so gut ist wie eine Expertenbewertung.

2

Nach dieser Vorarbeit lassen sich vier Qualitätskriterien definieren. Was die Experten beim Bewerten inhaltlich leisten, ist der Ausgangspunkt. Die beiden mittleren Boxen definieren den Rahmen, innerhalb dessen die AI-Leistung den Nutzern einen Mehrwert bringt: Das AI-System muss «latente Merkmale» finden, die Ideen charakterisieren. Es sollen möglichst alle Merkmale gefunden werden. Beim Training lernt die AI, welche der Merkmale für gute Bewertungen sorgen. Auf Basis dieser «relevanten Merkmale» soll sie zwischen 70 und 95 Prozent der Ideen bewerten. Damit wir dem AI-System vertrauen können, wird festgelegt: Die AI muss sich zu 95 Prozent sicher sein, dass die Ideen korrekt analysiert sind. Sie muss zu mindestens 90 Prozent sicher sein, dass ein relevantes Merkmal eine hohe Bewertung verursacht. Und sie darf ein Ideencluster erst präsentieren, wenn sie zu mindestens 85 Prozent sicher ist, dass die Bewertungen annähernd der Qualität eines menschlichen Experten entsprechen.

3

In den 10 000 Bewertungen stecken viele Merkmale. Daher kommt es auf die Fähigkeit zur Generalisierung an. Ideenbeschreibungen sind sehr unterschiedlich, manchmal schlecht formuliert oder missverständlich. Das AI-Modell muss diese Unzulänglichkeiten tolerieren können. Daher wird das Modell mit dem Schwerpunkt «Recall» trainiert.



Lernkonzept erstellen Trainingsparameter



Qualitätsniveau des Modells

1

Einflussfaktoren

- Qualität der Identifikation und Klassifizierung der latenten Merkmale
- Qualität der Generalisierung (Merkmale über verschiedene Ideen hinweg zuordnen)
- Menge der analysierten Ideen
- Vorhersagequalität bei der Bewertung neuer Ideen auf Basis der Merkmale

Menschlicher Maßstab

- In 1 Woche bewerten 5 Experten ca. 500 Ideen
- Experten erkennen typische Merkmale einer Idee
- Experten bewerten Ideen auf Basis der erkannten Merkmale

Mindestanforderung für Wertgenerierung

- Latente Merkmale in den analysierten 10 000 Ideen identifizieren und diese danach clustern
- 70% aller Ideen auf Basis der relevanten Merkmale bewerten
- Nur die besten Ideencluster präsentieren

2

Erwünschtes Zielmaß

- Alle, auch seltene latente Merkmale in den analysierten Ideen identifizieren und diese danach clustern
- 95% aller Ideen auf Basis der relevanten Merkmale bewerten
- Nur die besten Ideencluster präsentieren


Mindestvertrauensgrad des Modells

- Ideen sind korrekt analysiert: > 95%
- Relevantes Merkmal ist für hohe Bewertung verantwortlich: > 90%
- Bewertungen sind ähnlich genau wie vom Experten: > 85%

Schwerpunkt des Trainings

Trefferquote (Recall)

Genauigkeit (Precision)



Argumente

- Soll sehr unterschiedliche Merkmale in Ideen klassifizieren
- Findet identifizierte Merkmale zuverlässig in unterschiedlichen Ideen
- Qualität der Einreichungen sehr unterschiedlich (nicht immer sauberes Englisch, nicht immer verständliche Sätze und Ideenbeschreibungen, unvollständige Beschreibungen)

3



Argumente

- Gute Vorhersagequalität, da nicht noch mal nachkontrolliert werden soll, ob die Merkmale tatsächlich für die gute Bewertung verantwortlich sind

4. Entscheidung treffen

Wir müssen uns entscheiden, ob wir ein Modell nur einmalig nutzen oder es weiterhin eingesetzt werden soll: Das bestimmt den Trainingsaufwand.

- 1 Für die Organisatoren des Ideenwettbewerbs ist der Einsatz der AI ein klarer Fall. Der «Business Check» zeigt ganz deutlich: Trotz der erst noch durchzuführenden Trainings der AI-Modelle ist die geplante Bewertung der Ideen im vorgegebenen Zeitrahmen möglich und schneller, als menschliche Experten es jemals könnten.

Weil das AI-Modell nur für den konkreten Ideenwettbewerb benötigt wird, fallen viele aufwendige Schritte weg (Skalierbarkeit, Sicherheitsaspekte, Benutzeroberfläche). Die Umsetzung ist in etwa einer Woche möglich (wenn man auf bestehende Modelle zurückgreifen kann) im Gegensatz zu acht bis zehn Wochen ohne AI.

- 2 Die Kosten sind aufgrund der kurzen Projektdauer vergleichsweise gering – im Gegensatz zu der langen Zeit, die die Experten bräuchten, um die gesamte Datenmenge zu sichten. Arbeiten die Experten ehrenamtlich, würde sich der Aspekt Kosten zugunsten der manuellen Arbeit verschieben.

- 3 Hier steckt der Teufel im Detail. Denn erst eine genauere Analyse der Daten zeigt, wie aufwendig die Aufbereitung tatsächlich ist. Wenn sich die Teilnehmer nur ungefähr an die inhaltlichen Vorgaben gehalten haben, müssen unter Umständen diese Ungenauigkeiten in den Ideenbeschreibungen von Datenwissenschaftlern korrigiert werden. Das kann sowohl die Dauer als auch die Kosten ungünstig beeinflussen. Um das zu vermeiden, kann im Vorfeld das Formular für die Einreichung so definiert werden (Mindestzeichenzahl, Pflichtfelder), dass möglichst wenig ungenaue Ideenbeschreibungen möglich werden.

- 4 Neben dem enormen Zeitgewinn für den ersten Einsatz besteht die Möglichkeit, die Anwendung weiter auszubauen und sie dann künftig mehrfach zu verwenden. Auf diese Weise amortisieren sich die Initialkosten besser und die Verantwortlichen sammeln weitere Erfahrungen im Umgang mit AI-Projekten. Bei künftigen Ideenwettbewerben muss die Maschine nur noch neu lernen, andere Arten von Ideenmerkmalen zu erkennen und zu bewerten.



Entscheidungen treffen Business Check



Kriterien	ohne AI	mit AI
1 Personal (FTE)	1 Projektleiter 2 Innovationsexperten 10 SDG 11-Experten zur Ideenbewertung	1 Projektleiter 1 Innovationsexpertin 5 SDG 11-Experten für Bewertung und Training 2 Data Scientists
2 Zeit	6 Wochen Wettbewerb (ca. 10 000 Ideen) 8–10 Wochen Auswertung durch Experten	6 Wochen Wettbewerb (ca. 10 000 Ideen) 1 Woche AI-Projekt (+ Vorbereitungszeit)
3 Kosten	Mittel – hoch (sehr lange Auswertung und viele Experten beteiligt)	Gering – mittel (abhängig vom benötigten Datenaufbereitungsaufwand)
3 Hürden	zeitlicher Aufwand Kostenaufwand Mustererkennung unmöglich bei solch großer Ideenanzahl	Qualität der Einreichungen sehr unterschiedlich (ggf. Datennachbereitung nötig) möglicherweise hohe Kosten für Datenaufbereitung
4 AI-Potenzial	Modell lässt sich zukünftig für weitere Wettbewerbe einsetzen Wenn gute Vorhersageleistung, kann in Zukunft auf Experten verzichtet werden (Kosten und Zeitersparnis) Bisher unbekannte Lösungsmerkmale und Lösungszusammenhänge aufdecken (und so die Welt retten)	



*10 000 Ideen in einer Woche in Expertenqualität
bewertet, inklusive Modellentwicklung,
Training und Testen. Dafür würde
eine Expertenjury zehn
Wochen arbeiten.*

Was wir gelernt haben ...

1. **Eine überwältigende Aufgabe kann für AI leicht sein.**
Für Menschen ist es eine sehr große Hürde, eine Menge von 10 000 Dokumenten zu sichten, zu verstehen und zu beurteilen. Für ein AI-System ist das eine Kleinigkeit. Das Prinzip der Analyse ist übertragbar auf viele andere Dokumentarten – und wird in der Praxis für Gesetzestexte und deren Auslegung, Patentschriften, Diagnoseberichte und vieles mehr angewandt. Hier unterstützt AI den Menschen auf perfekte Weise.
2. **Partnerschaften mit Netzwerken senken die Eintrittshürde.**
Wer sich mit AI beschäftigen will, findet im Umfeld großer Städte meist lokale Initiativen, die mit Rat und Tat zur Seite stehen. Der Kontakt mit solchen Netzwerken kann die Umsetzung eines ersten AI-Projekts enorm erleichtern. Auch Universitäten erweisen sich als wertvolle Anlaufstellen, um sich in ersten Projekten dem Thema AI zu nähern. Unser Szenario bietet sich perfekt als Forschungsprojekt an einer Hochschule an. Während Studierende motiviert sind, an realen Herausforderungen zu arbeiten, profitieren Unternehmen oder Organisationen von deutlich reduzierten Kosten und lernen außerdem den Umgang mit AI-Projekten.
3. **Man muss nicht alles selber machen.**
Unser Beispiel zeigt perfekt, was sich mit bereits am Markt erhältlichen fertigen Algorithmen und Modellen umsetzen lässt. Für beide Aufgaben – das Identifizieren von latenten Merkmalen sowie das Erkennen von statistischen Korrelationen zwischen Merkmalen und hohen Bewertungen – gibt es Frameworks, die sich teilweise sogar kostenfrei nutzen lassen. Viele Aufgaben mit AI lassen sich heutzutage mit vorhandenen Tools umsetzen, das Erstellen eigener Modelle ist für Standardaufgaben nicht mehr nötig. AI-Experten haben in der Regel einen guten Überblick darüber, was derzeit verfügbar ist.

5. Designs entwickeln

Design ist aufgrund nahezu unbegrenzter Gestaltungsmöglichkeiten ein äußerst komplexer Vorgang.

Das Problem

Computerunterstützung beim Design gibt es, seit die Rechner leistungsstark genug sind, grafische Darstellungen zu ermöglichen.

Dabei ist Design hier im weiteren Sinne gemeint. Es geht nicht nur um die ästhetische Gestaltung, sondern vielmehr um die logische Konzeption von Produkten und Dienstleistungen. Beim Design spielen neben ästhetischen auch funktionelle Kriterien eine Rolle: Ist die Konstruktion effizient? Bei einem Computercode äußert sich die Effizienz in Programmen, die sparsam oder verschwenderisch mit Rechenleistung umgehen. Bei medizinischen Wirkstoffen – sehr schön zu beobachten bei der Entwicklung von Covid-19-Impfstoffen – zeigt sich die Effizienz in einer mittelmäßigen oder sehr guten Wirkung. Ein Stuhl kann mit viel Materialeinsatz weniger stabil und bequem sein als ein äußerst filigran gestaltetes Exemplar.

Design ist aufgrund nahezu unbegrenzter Gestaltungsmöglichkeiten ein äußerst komplexer Vorgang. Wenn wir neben Aussehen und Funktionalität noch die Auswirkungen auf Umwelt und Mensch berücksichtigen wollen, erhöht sich die Komplexität noch mehr.

An diesem Punkt wird es für Innovatoren und Designer zu einer herausfordernden Aufgabe, die vielen Wechselwirkungen in ihren Gestaltungsentwürfen zu berücksichtigen. Ein bestimmtes Material mag einen besonders wertigen optischen Eindruck machen, lässt sich aber schlecht recyceln.

Komfortfunktionen, wie Heizung, elektrische Höhenverstellung oder Massagefunktion, steigern zwar den Komfort eines Autofahrers, erhöhen dadurch aber Gewicht, Teilezahl und Komplexität der Konstruktion eines Fahrzeugsitzes.

Designer sind darauf trainiert, solche komplexen Herausforderungen zu bewältigen – mit Neugier, Kreativität und Mut.

Nur was ist, wenn diese Aufgaben die kognitiven Fähigkeiten eines Menschen um ein Vielfaches übersteigen?

Wenn das, was wir heute lernen, morgen schon wieder überholt ist? Wie kann ein Innovator bei der Entwicklung seiner Produkte und Services dem enormen Tempo und den Anforderungen an Umweltschutz, sozialer Verantwortung und Wirtschaftlichkeit gerecht werden?

Wie AI helfen kann

Computer helfen Entwicklern weltweit bei unterschiedlichen Aufgaben in der Kreation von neuen Produkten. Seit AI-Algorithmen entwickelt und verfeinert wurden, die auch in der Lage sind, Neues zu schaffen, beschleunigt sich diese Entwicklung.

So hat der Designer Philippe Starck gemeinsam mit dem Unternehmen Autodesk einen Stuhl mithilfe eines AI-Modells entworfen. Ein filigranes Exemplar. Der «A. I. Chair». Das Modell lernte von Starcks früheren Entwürfen und berücksichtigte, dass der Stuhl im Spritzgussverfahren hergestellt werden soll und dass das Material mindestens sechs bis acht Millimeter dick sein muss, damit er nicht unter dem Gewicht eines Menschen zusammenbricht.

**Menschliche
Vorstellungskraft
kombiniert mit
technischer
Umsetzbarkeit.**

Die Zusammenarbeit von Mensch und Maschine kombiniert menschliche Vorstellungskraft von Ästhetik mit technischer Umsetzbarkeit. Das Produkt kam am Ende mit einem Minimum an recyceltem Plastik aus und war dennoch stabil und ästhetisch.

Dieses Zusammenspiel von Mensch und Maschine in der Konzeption und Produktion von Innovationen funktioniert auf vielen Ebenen. Besonders interessant ist es, dass sehr unterschiedliche Daten, wie zum Beispiel die Bewertung bestehender Produkte durch Kunden und Experten, Vertriebsdaten, Gewinnmargen, Materialeigenschaften, Umweltverträglichkeit und vieles mehr, direkt in ein neues Design einfließen können.

Das Revolutionäre daran: Mehrere Schritte eines klassischen Innovations- und Designprozesses können mit AI-Modellen zu einem Arbeitsgang kombiniert werden.

Mensch: Die Recherche von Nutzerbedürfnissen auf der Basis von Bewertungen, Kommentaren und Expertenmeinungen bilden das Element der Kundenperspektive ab, den Faktor Mensch.

Technik: Die Informationen über Materialeigenschaften, Zusammensetzung existierender Produkte, Produktionsparameter schaffen die Grundlage für technische Entwicklung von Prototypen.

Geschäft: Vertriebsdaten, Materialkosten und andere Kennzahlen steuern die Geschäftsperspektive bei.

Der Dreiklang aus Machbarkeit, Wünschbarkeit und Umsetzbarkeit kann auf diese Weise von der Maschine abgebildet werden.

Gefüttert mit dieser Datenvielfalt kann ein gut trainiertes ML-Modell fertige Entwürfe oder Prototypen herstellen, zum Beispiel eine optimierte Produktionsstraße, eine Rezeptur für einen Whisky oder ein Autodesign.

Für den Innovationsprozess selbst bedeutet das: Es lassen sich Phasen wie Beobachten und Verstehen oder Ideenentwicklung bis zum ersten Prototyp, mit Maschinenhilfe unterstützen oder sogar automatisieren. Dieser Punkt ist für das Verständnis, wie der Einsatz von AI auch Prozesse und die Organisation von Arbeit im Unternehmen verändern kann, sehr wichtig. Bisher getrennte Arbeitsschritte, vor allem aus Analyse und Produktion, können durch AI zu einem Schritt verschmolzen werden.

AI für die Entwicklung von Produkt- oder Servicekonzepten kann einen hohen Mehrwert liefern, da AI Entwickler in ihrer Arbeit unterstützt. Das am Anfang dieses Kapitels erwähnte Beispiel von Alpha Fold zeigt das eindrücklich. Ohne den Einsatz von AI können die Strukturen von Proteinen, zum Beispiel bei Viren, nur sehr langwierig ermittelt werden – diese Strukturen aber sind die Basis für die Entwicklung von Impfstoffen.

Für die Suche nach Anwendungsfeldern im Entwicklungsprozess muss überlegt werden, welche komplexen Zusammen-

Bisher getrennte Arbeitsschritte vor allem aus Analyse und Produktion werden zu einem verschmolzen.

hänge in das Design integriert werden sollen: Sind es vor allem ökologische Aspekte oder eine besonders komplexe Herstellung, wie zum Beispiel bei einem Auto? Geht es vorwiegend um betriebswirtschaftliche Aspekte, muss es also möglichst billig zu produzieren sein? Oder soll AI helfen, unkonventionelle Lösungen für ein Problem zu finden – wie das zum Beispiel bei der Suche nach der optimalen Konfiguration des Plasmas von Fusionsreaktoren der Fall war? Der «Optometrist-Algorithmus» half den Entwicklern, eine Plasmakonfiguration zu finden, bei der erstmals mehr Energie erzeugt wurde, als für das Zünden des Plasmas nötig war.

Die Beispiele zeigen, wie sich die Rolle des Designers, Entwicklers oder Innovators zukünftig verändern wird:

Der Designer wird zum Kurator von Ideen.

1. Die **schnelle Entwicklung** vieler Varianten, die spezifischen Anforderungen gerecht werden, das Generieren einer Vielzahl von ungeahnten Lösungen wird einfacher und schneller.
2. Der Designer wird sich sehr bald **nicht mehr mit Fleißaufgaben**, wie dem Herumschieben von Pixeln, dem Freistellen von Menschen auf Fotos oder der hundertsten Anpassung des 3-D-Entwurfs beschäftigen müssen, weil es überraschende neue Anforderungen aus dem Engineering gibt.
3. Er wird zum **Kurator der Ideen** und versteht die Aufgabe, er kennt das Ziel, die Anforderungen der involvierten Stakeholder und die Strategie des Unternehmens, um auf Basis all dieser Aspekte fundierte Entscheidungen treffen zu können.
4. Er wird sich auf das konzentrieren, was Innovatoren am besten können, auf die menschlichsten aller menschlichen Fähigkeiten: **Empathie zu Menschen** aufzubauen, kreativ Probleme zu lösen oder den Status quo zu hinterfragen, um weiterhin die Veränderung der Welt voranzutreiben.

Szenario

Maschinendesigner

Warum AI?

Ein sehr komplexes Szenario: Ein Design-Konfigurator soll die Hauptrolle bei der Entwicklung von Autokarosserien übernehmen. Er soll das Designteam eines Autoherstellers unterstützen, um die perfekte Form für neue Automodelle zu finden.

Das Schwierige an der Erstellung eines Autodesigns ist die Komplexität des Produkts. Von den ersten Handskizzen über Autostudien, die auf den großen Autoshown gezeigt werden, bis zum Serienmodell vergehen Jahre der Entwicklung. Im Design müssen nicht nur Aspekte, wie Luftwiderstand, Fußgängerschutz oder Spaltmaße an Türen, berücksichtigt werden, es spielen auch ästhetische Aspekte eine sehr wichtige Rolle – Emotion verkauft.

Normalerweise ist das Zusammenspiel von technischer und formaler Entwicklung ein konstantes Pingpong zwischen Vorgaben aus dem Engineering und dem Kampf um die schnittigste Linienführung.

Nur wenige erfahrene Autodesigner können alle Anforderungen in konforme Designs übersetzen. Das Designteam fragt sich also, wie es sich mehr auf den Kreativprozess und die Formalgestaltung konzentrieren kann, ohne sich sorgen zu müssen, dass dabei wichtige Anforderungen und Auflagen an das Design missachtet werden.

Der AI-Ansatz

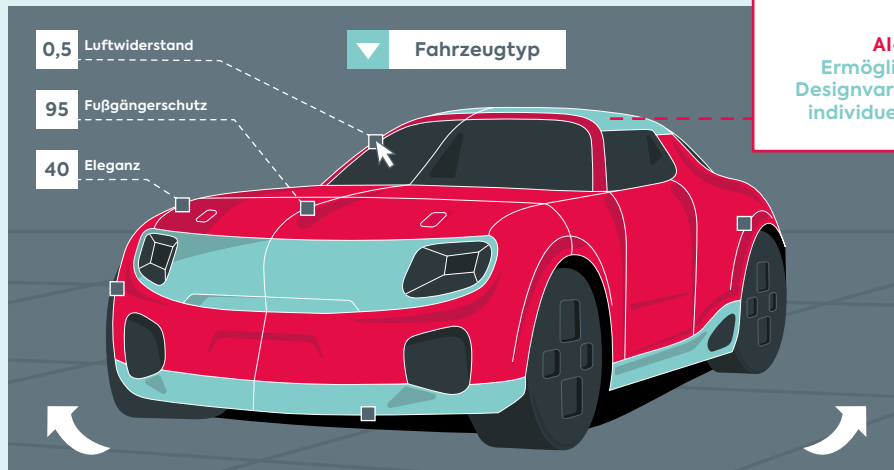
In diesem Szenario steht die Fähigkeit von Algorithmen, neue Inhalte zu kreieren, im Vordergrund. Das AI-Modell soll wichtige technische Anforderungen aus dem Engineering, bekannte Kundenpräferenzen aus dem Vertrieb oder vorgegebene Budgets der Controller berücksichtigen und auf Basis dieser Vorgaben Autodesigns vorschlagen. Das Designteam kann die maschinellen Entwürfe auf die ästhetischen Aspekte hin überprüfen und kuratieren. Daraus kann neue Inspiration entstehen oder eine grobe «3-D-Skizze», die gleich mit Modelleuren in Tonmodelle übertragen werden kann.

Ohne den Menschen geht es nicht: Denn auch die beste AI-Anwendung ersetzt nicht die Beurteilung eines Designs im physischen Raum – wo Licht und Schatten ein Design zum Leben erwecken.

AUTODESIGN-KONFIGURATOR

X

3-D-Vorschau




AI-Modell:
Ermöglicht Echtzeit-
Designvarianten auf Basis
individueller Parameter

Basisparameter




AI-Modell:
Erstellt Design-
varianten auf Basis
der gelernten 3-D-Daten

Designparameter



AI-Modell:
Über Schieberegler können
Designparameter individuell
angepasst werden

Vorgegebene Parameter



AI-Modell:
Vorgaben werden in jedem
Design automatisch
berücksichtigt

Letzte Designs





1. Ziel definieren

AI-Mehrwert



Auftrag

Das Designteam sucht neue Möglichkeiten, Autodesigns schneller zu entwickeln, ohne wichtige Anforderungen zu vergessen

Erwarteter Mehrwert durch AI

Zeitgewinn: Designvarianten entstehen auf Knopfdruck
Qualität: Vorgeschlagene Designs berücksichtigen automatisch Anforderungsparameter, wie Umweltaspekte, Sicherheit, Kundenbedürfnisse.
Aktualität: Neue Anforderungen lassen sich schnell im AI-Modell verankern.

Challenge



Wie können wir unserem Designteam eine neuartige Möglichkeit geben, Autodesigns zu entwickeln. Dabei sollen automatisch eine Vielzahl von Vorgaben berücksichtigt werden, wie Kundenbedürfnisse, Umweltauflagen, Sicherheit sowie technische Machbarkeit.

Output



Erkennen



Vorhersagen




Erzeugen



Outputformat

Design-Konfigurator, der auf Basis der vorgegebenen Anforderungen und Parameter Designvorschläge macht



2. Daten recherchieren

Datenquellen



Typ

Quelle

Warum?

A	Konstruktionsanforderungen	Engineering Datenbank	Anforderungen an Design lernen
B	Marktdaten	CRM, Salesforce	Anforderungen der Kunden lernen
C	Interne Autodesigns	CAD-Modelle aus Entwicklung	Basis für Designvorschläge
D	Externe Autodesigns	CAD Modelle aus dem Internet	«Inspiration» für ganz neue Designs

Datenprüfung



Priorität

Beschaffung

Technik

A	hoch ●	niedrig ●	niedrig ●
B	hoch ●	niedrig ●	niedrig ●
C	hoch ●	niedrig ●	niedrig ●
D	mittel ●	mittel ●	mittel ●

Datenerhebung



Grund für die Datensammlung

Anforderung Konstruktion abfragbar machen
Anforderung Kunden vermitteln
Basis für Training zur Gestaltung von Designs
Firmeninterne Designs lernen

Datentypen

Anforderung Konstruktion
Marktdaten
Interne 3-D-Autodesigns
Externe 3-D-Autodesigns

Priorität

Beschaffung

Technik

●	●	●	●
●	●	●	●
●	●	●	●



3. Lernkonzept erstellen

Maschinenfähigkeiten		
Aufgabe	Quelle	Fähigkeit
A Design und Eigenschaften in Beziehung setzen	Engineering Datenbank	Infos extrahieren, Daten gruppieren, Wissen kombinieren
B Designvorlieben der Kunden lernen	CRM, Salesforce	Infos extrahieren, Daten gruppieren, Wissen kombinieren
C Designs auf Anforderungen anpassen lernen	CAD Modelle aus Entwicklung	Infos extrahieren, Inhalte kombinieren, Inhalte generieren
D Unbekannte Designparameter lernen	CAD Modelle aus dem Internet	Infos extrahieren, Inhalte kombinieren, Inhalte generieren



4. Entscheidung treffen

Vorgehensvergleich		
	Ohne AI	Mit AI
Personal	ca. 30 FTE, 1 Projektleiterin	ML- & DS-Experten, 3 FTE, 1 Projektleiter
Zeit	1–2 J. für frühe Designphasen	PoC: 4 M, Launch: 2 J., 3 M für erstes Design
Kosten	Hoch	Hoch (Initial) Niedrig (Weiterentw.)
Hürden	Lange Entwicklungszeit; F&E personalintensiv	Wenig AI-Expertise, Geringe Akzeptanz
AI-Potenzial	Zeit- und Kostenersparnis, zielgenauere Designs, ganz neue Kompositionen.	


Trainingsparameter	
Menschlicher Maßstab Täglich 200 2-D-Skizzen, ein 3-D-Modell basierend auf groben Anforderungen	Minimalanforderung Echtzeit-3-D-Modelle mit grundlegenden Markenelementen; Basisanforderungen berücksichtigt
Erwünschtes Zielmaß Wichtigste Designanforderungen zu 80% in jedem generierten Design berücksichtigt	Mindestvertrauen 90% der wichtigen Markenmerkmale erkennbar; Priorisierung wichtiger Parameter
Recall	Precision

Entscheiden	
Ergebnisqualität / Geschäftswert	Nichts wie ran!
	Nur wenn lang-fristig strategisch relevant
Ist es wirklich notwendig?	Auf keinen Fall!
Risiko/Aufwand	

Maschinendesigner im Überblick

Dieses Beispiel zeigt, dass AI-Modelle auch kreativ sein können. Der Zufall, nachdem neue Entwürfe generiert werden, wird gelenkt durch die Eingabe von Rahmenbedingungen: Vertriebsdaten, Kundenpräferenzen, Sicherheitsfragen und vielem mehr. Interessant sind weniger der Mehrwert oder die Challenge, sondern vor allem die AI-Fähigkeiten

und die Trainingsparameter, denn sie entscheiden über den Grad der Kreativität und das Ausmaß an Inspiration, die die Modelle liefern können. Wichtig ist bei einem so komplexen Projekt der Vergleich der Vorgehensweisen. Nur so lässt sich abschätzen, ob sich bis zu zwei Jahre Entwicklungsaufwand lohnen – danach stehen um 1 bis 1,5 Jahre reduzierte Designentwicklungszeiten in Aussicht.



Ziel definieren AI Value Map

Der Auftrag

Das Designteam sucht neue Möglichkeiten, Autodesigns schneller zu entwickeln, ohne dabei wichtige Anforderungen zu vergessen



Manuelle Projektschritte

Beschreibung

1

Sammeln aller Entwicklungsanforderungen der Departments

Sortieren und Priorisieren der Parameter/Anforderungen

Überführung in konkrete Designanforderungen und Briefings

Designvorschläge machen

Designvorschläge auswählen

Typische Pain Points

Aktuelle Infos nicht immer verfügbar;
Datenqualität nicht ausreichend

Zeitaufwand, Datenmassen, Komplexe Abhängigkeiten in Anforderungen.

Widersprüchliche Faktoren vereinen; «Featuritis»; Anforderungen ändern sich häufig

Viele Ressourcen; Designoptionen unbegrenzt; Bias Designer; Anpassungsaufwand

Bias bei der Auswahl

Geschäftlicher Mehrwert durch AI

2

Zeitersparnis, Automatisierte Datenerhebung über Firmengrenzen hinaus

Geschwindigkeit, Objektivität: Prio, latente Wünsche aufdecken, Automatisierung

Zeitersparnis; Aktualität: Auto-Anpassung an neue Anforderungen

Zeitersparnis, Designvarianten auf Basis von Anforderungen; Anpassungsfähigkeit

Objektivität der Ergebnisauswahl auf Basis von klaren Kriterien

Hier kann AI unterstützen:



Ziel definieren Output



Die Aktion



Erkennen




Vorhersagen



Erzeugen

Das Format

Interaktiver Design-Konfigurator, der auf Basis der vorgegebenen Anforderungen und Parameter Designvorschläge macht



3

Wie es geht

1. Ziel definieren

Der Ausgangspunkt ist im Designteam die Erkenntnis, dass es zu lange dauert, neue Autodesigns fertigzustellen. Hinzu kommt die Schwierigkeit, die Designs auf immer neue Anforderungen, zum Beispiel seitens der Ingenieure, anzupassen. Angesichts neuer technischer Möglichkeiten sucht das Team einen Weg, den Prozess zu beschleunigen. Der Auftrag lautet: «Das Designteam sucht neue Möglichkeiten, Autodesigns schneller zu entwickeln, ohne dabei wichtige Anforderungen zu vergessen.»

- 1 Die AI Value Map zeigt, wie der Designprozess prinzipiell aussieht. Auffällig ist, dass sich nur zwei Schritte tatsächlich mit Gewinn automatisieren lassen: das Überführen der Anforderungen (Nachhaltigkeit, Fußgängerschutz etc.) in Designvorgaben und das Ausarbeiten von Designvorschlägen.
- 2 Ein gutes AI-Modell brächte vor allem sehr große Zeitvorteile und einen Weg, die Komplexität der vielen Anforderungen und ihrer Auswirkungen auf das Design zu reduzieren.
- 3 Das Designteam stellt sich auf der Basis der Mehrwert-Überlegungen einen Konfigurator vor, der auf Knopfdruck Designvorschläge liefert. Die wichtigsten Konstruktionsparameter sollen mit Schieberegler eingestellt werden: Das können Markenparameter sein, wie Emotionen (BMW betont die Freude am Fahren, Volvo eher Sicherheit). Dazu gehören aber auch technische Werte, wie der Luftwiderstand oder der Fußgängerschutz. Ein angezeigter Designentwurf soll sich mithilfe der Schieberegler verändern lassen. Auf diese Weise kann das Designteam den Einfluss von Parametern auf das Design live beobachten. So weit ist das Ziel definiert. Wie geht es weiter?



Daten recherchieren

Datenquellen



A

Datentyp

Parameter, wie CW-Werte, Verbrauch

Warum?

Anforderungen an Design lernen

Datenquelle

Engineering Datenbank (Material, Teilebezeichnungen)

B

Datentyp

Marktdaten

Warum?

Anforderungen der Kunden lernen

Datenquelle

CRM, Salesforce (Vertrieb, Marketing, Market Intelligence)

C

Datentyp

Interne 3-D-Autodesigns

Warum?

Lernen, wie Autos dieser Marke gestaltet werden

Datenquelle

CAD-Modelle aus der Entwicklungsabteilung

D

Datentyp

Externe 3-D-Autodesigns

Warum?

Inspiration für neue Designs

Datenquelle

CAD-Modelle aus dem Internet



Wo gibt es Autodesigns?

Es gibt zahlreiche 3-D-Modell-Datensammlungen im Internet. Darunter befinden sich auch 3-D-Automodelle. Aber Achtung: Die Autoindustrie steckt außergewöhnlich viel Aufwand in die Qualität der Oberflächen in ihren 3-D-Modellen. Dieses Niveau wird von öffentlich verfügbaren Designs nicht erreicht. Wer diese Daten verwenden will, muss erheblichen Aufwand in deren Aufbereitung stecken. Beispielsweise sind Flächen nicht sauber geschlossen, verlaufen unschön oder Kanten stoßen nicht sauber aufeinander. Dafür wäre ein eigenes Data-Science-Projekt nötig.

2. Daten recherchieren

Wichtig sind zunächst diejenigen Daten, die die Parameter und Anforderungen definieren. Aus Daten soll die AI lernen, was windschnittig bedeutet (CW-Wert) oder wie die Formsprache der Marke aussieht.

Vereinfacht dargestellt, benötigt das AI-Modell vier Datentypen:

1. **Konstruktionsparameter:** Das sind zum Beispiel Daten zu CW-Wert, Verbrauch, Karosseriefestigkeit, Gewicht, Preis.
2. **Marktparameter:** Dazu gehören Verkaufszahlen, Marktforschung, Markenwahrnehmung.
3. **Interne 3-D-Modelle von Autodesigns unserer Marke:** Sie enthalten unter anderem die Teile und deren Bezeichnung (Teilenummern, Plattform ...).
4. **Externe 3-D-Modelle, markenfremd:** Gemeint sind Entwürfe von Designplattformen im Internet oder von Partnerunternehmen.

Diese Daten liefern uns die Informationen, die das AI-Modell benötigt, um passende Designs zu erstellen. Dabei sorgen die Konstruktionsparameter dafür, dass das Design machbar ist, die Marktparameter integrieren die Kundenperspektive. Die 3-D-Modelle werden genutzt, damit das AI-Modell lernen kann, wie ein Auto konstruiert ist. Die markenfremden Designs dienen der Maschine dabei als «Inspirationsgrundlage» über die Grenzen der eigenen Marke hinweg.

Projekte dieser Komplexität erfordern viel Wissen über die möglichen Datenquellen im Unternehmen. In so einem Fall ist das Gespräch mit einem Datenwissenschaftler oder einer Datenwissenschaftlerin Pflicht. Sie wissen in der Regel, welche Datenquellen sich im Unternehmen finden lassen – oder können diese Informationen besorgen, sie kennen schließlich auch die Anforderungen, die AI-Modelle an die Datenquellen stellen. So gehen die Suche der Datenquellen und die erste Bewertung der Datenqualität Hand in Hand.

In der Data Journey Map werden alle diese Informationen zusammengeführt, um als Gesprächsbasis für die internen Stakeholder zu dienen – somit ist auf einen Blick zu sehen, bei welchen Datenquellen höhere Aufwände zu erwarten sind.

3. Lernkonzept erstellen

3-D-Entwürfe aus der Maschine: Diesen Job übernehmen sogenannte «Generative Adversarial Networks».

Für den Design-Konfigurator stehen große Datensätze aus ganz unterschiedlichen Bereichen zur Verfügung. Nun muss das Fähigkeitsenset definiert werden, damit ein Machine Learning Engineer entscheiden kann, welches AI-Modell geeignet ist oder ob ein eigenes erstellt werden muss.

- 1 Zunächst lernt das AI-Modell, wie ein Auto zusammengesetzt ist, was ein Kotflügel ist, wie er aussieht und an welche Stelle er gehört. Dazu dienen die 3-D-Daten von Karosserieteilen, die mit einer Vielzahl an Metainformationen versehen sind. Diese kann das AI-Modell für das Training verwenden.
- 2 Um zu wissen, wie Designs der Unternehmensmarke aussehen sollen, benötigt das AI-Modell eine Vorlage. Dazu dienen 3-D-Daten aller Automodelle des Unternehmens seit dem Jahr 2000. Anhand dieser Daten kann das AI-Modell die typische Formensprache der Marke sowie Unterschiede zwischen verschiedenen Autotypen, wie Kleinwagen, Limousine oder Kombi, erkennen. Dieser ziemlich große Datensatz erfordert die Fähigkeit zum «Lernen mit vielen Daten».
- 3 «Neue Inhalte generieren» sorgt dafür, dass die AI aus den vorhandenen Daten neue dreidimensionale Entwürfe erschafft. Diesen Job übernehmen sogenannte «Generative Adversarial Networks». Damit die Designs sich an konkreten Anforderungen orientieren, muss das AI-Modell «Inhalte verschiedener Art kombinieren» können: mit Konstruktions- und Marktdaten. Um diese Daten in einem Design zu berücksichtigen, muss es außerdem «Zielwerte vorhersagen» können. Das AI-Modell schätzt anhand der Daten ab, welches Design besonders windschlüpfrig oder für Fußgänger in Unfallsituationen besonders ungefährlich ist. Sollen nach dem abgeschlossenen Training weitere 3-D-Modelle zur Inspiration hinzugefügt werden, muss das AI-Modell «Automatisiert weiterlernen» können.
- 4 Die «Anpassung an veränderliche Bedingungen» ermöglicht es schließlich, ein Design per Schieberegler zu verändern, um zum Beispiel die sportliche Anmutung zu variieren.



Lernkonzept erstellen AI Skill Navigator



1: Erkennen, analysieren und vorhersagen



Objekte erkennen
und klassifizieren
(Auf Bildern Hunde und Katzen auseinanderhalten)



1
Klassifizierte Daten
gruppieren oder sortieren
(Aus Tierbildern Hunde- und Katzenstapel bilden)

Alle getaggten Autoteile
in Gruppen vergleichbar machen

analysieren
etc.)
erkennen)



Informationen extrahieren
und Aktionen ableiten
(Wenn Babygeschrei über 100dB, dann stillen)



3
Zielwerte oder Ereignisse
schätzen und vorhersagen
(Hurrikan mit Tempo X erreicht Florida in Y)



Er
(In mög

Designs an neue Anforderungen anpassen

2: Verstehen, kommentieren und generieren

Designdaten mit Anforderungen verknüpfen

tionen
ren
et antworten)



Neue Designs erstellen

h
r
ratsantrag)



3
Inhalte verschiedener
Art kombinieren
(Röntgenbild und Diagnose, Deepfake Videos)

Neue Inhalte
generieren
(Neue Zeitungsartikel, Webdesigns etc. generieren)

Neue Designanforderungen einfließen lassen



3
Vorhandenes Wissen mit zusätzlichen
Erkenntnissen kombinieren
(Neue Studienerkenntnisse in med. Diagnose einbinden)



2
Lernen mit
vielen Daten
(Autonome Fahrzeuge steuern)

Unsere Autodesigns seit
2000 in das Modell einbeziehen

erkennen)



4
Anpassung an
veränderliche Bedingungen
(Roboter und Menschen arbeiten zusammen)



3
Automatisiertes,
selbständiges Weiterlernen
(Wettervorhersagen mit Realität abgleichen und
künftige Prognosen anpassen)



Interaktive Kontrolle der Designs über
User Interface

Neue Designs als Inspiration für
weitere Varianten

Mithilfe der sehr unterschiedlichen Datentypen und eines umfassenden Fähigkeitensets kann das AI-Modell so trainiert werden, dass es Autodesigns erstellt, die die gewünschten Parameter, wie Sicherheit, Markenversprechen oder Kosten, automatisch zu einem bestimmten Prozentsatz einhält.

Trainingskriterien

Um dies zu erreichen, müssen die Qualitätskriterien für das Training entsprechend ausgearbeitet werden.

- 1 Die von dem AI-Modell kreierten Designs werden von mehreren Faktoren beeinflusst: Die durch die Daten vorgegebenen Anforderungen, die für das Training verwendeten Designs und die Integration der Anforderungen in das Design.
- 2 Was das Designteam leistet, dient als Ausgangspunkt. Es müssen zum Beispiel zahlreiche Skizzen angefertigt und in 2-D beziehungsweise 3-D visualisiert werden, bevor ein Tonmodell entsteht. Diese Schritte versuchen wir durch unser Modell teilweise zusammenzufassen. Die beiden mittleren Boxen definieren den Rahmen innerhalb dessen die AI-Leistung den Nutzern einen Mehrwert bringt: Für dieses Szenario soll das AI-Modell mindestens die Markenwerte berücksichtigen, optimalerweise werden jedoch auch technische Parameter in hohem Maße (zu 80 Prozent) berücksichtigt. Damit wir dem AI-System vertrauen, wird festgelegt: Die AI muss sich zu 90 Prozent sicher sein, dass im errechneten Entwurf die wichtigsten Merkmale der Marke erkennbar und die wichtigsten Anforderungen enthalten sind. Für das Feintuning könnte noch vorgegeben werden, dass bestimmte Merkmale eine höhere Toleranz haben dürfen. Dafür würde der Mindestvertrauensgrad für diese Parameter erhöht werden – und für andere abgesenkt.
- 3 Einerseits muss das AI-Modell eine hohe Genauigkeit erreichen, damit die Designs der Markensprache entsprechen. Doch die Chance für interessante Neuentdeckungen ist nur durch gezielte «Ungenauigkeit» möglich. Daher wird ein hohes Mindestvertrauensmaß mit dem Schwerpunkt auf «Recall» kombiniert. Das ermöglicht es, interne Markendesigns sehr frei zu interpretieren – ihnen gewissermaßen einen Schuss Ferrari oder eine Prise Volvo zu geben.

Die Chance auf ungewöhnliche Designs steigt durch gezielte «Ungenauigkeiten» beim Training des AI-Modells.



Lernkonzept erstellen Trainingsparameter



Qualitätsniveau des Modells

1

Einflussfaktoren

Anzahl gelernter Anforderungen

Anzahl gelernter Designs

Integration der Anforderungen in das Design

Menschlicher Maßstab

Pro Designer:
200x 2-D-Skizzen/1 T.
1 x 2-D-Visualisierung/1 T.
1 x grobes 3-D-Modell/1 T.
(zzgl. 3-D-Modelleur)
1 x 1:5–1:4 Tonmodell/3 T.
(zzgl. Clay-Modelleur)

Frühe Designs basieren
nur grob auf echten
Anforderungen

Mindestanforderung für Wertgenerierung

Echtzeit-3-D-Modelle
mit markenspezifischen
Designelementen

Basisanforderungen an
Design wie CW-Wert,
Insassen- und
Fußgängerschutz, sowie
Kundenpräferenzen
werden berücksichtigt

2

Erwünschtes Zielmaß

Die wichtigsten
Parameter, wie Sicherheit
und CW-Wert sind in
jedem Design zu
80% berücksichtigt
(je höher der Wert,
desto höher der
Trainingsaufwand)

Mindestvertrauensgrad des Modells


90% der wichtigsten
Merkmale unserer Marke
sind klar im Design
erkennbar und basieren
auf den wichtigsten
Anforderungen

Priorisierung wichtiger
vorgegebener Parameter
(wie Aerodynamik,
Sicherheit etc) im Design

Erforderliche Genauigkeit

Trefferquote (Recall)

Genauigkeit (Precision)



Argumente

Modell muss verschiedene Designs
miteinander vermischen (interpretieren)

Daten in unterschiedlicher Qualität

Design lässt Ungenauigkeiten zu, vor allem
wenn Designs als Inspirationsquelle dienen

Keine produktionsfertigen Designs erwartet

Trainingsgeschwindigkeit wird erhöht und
Trainingsaufwand verringert, da Modell nicht
so genau sein muss

3



Argumente

Marken- und Designidentität muss klar
erkennbar sein

Design und Konstruktion müssen gewissen
festgelegten Regeln folgen (4 Räder unten,
Kühlergrill vorne etc.)

Anforderungen, wie Aerodynamik,
Fußgängerschutz etc., müssen zuverlässig
berücksichtigt werden, um Wert zu gene-
rieren (das können Designer in frühen
Designphasen nur bedingt und nur mit sehr
viel Erfahrung)

4. Entscheidung treffen

Die Angst, von einer Maschine ersetzt zu werden, kann die Akzeptanz eines AI-Systems im Team stark reduzieren.

Diese AI-Anwendung stellt hohe Anforderungen an die Benutzeroberfläche und die technische Performance.

- 1 Der Vergleich zeigt, dass ein bis zwei Jahre Zeit einkalkuliert werden müssen, bevor die Anwendung im Designteam genutzt werden kann. Auch der personelle Faktor ist nicht zu unterschätzen. Demgegenüber steht jedoch die auf bis zu einem Zehntel reduzierte Zeit für das Erstellen neuer Designs im Vergleich zum klassischen Vorgehen.
- 2 Die Kosten sind in diesem Fall eher nicht der limitierende Faktor. Die Entwicklung eines neuen Designs ist sehr teuer. Dagegen fällt selbst ein hoher Betrag für die Entwicklung der AI-Anwendung nicht so sehr ins Gewicht. Die Instandhaltung und Weiterentwicklung muss jedoch im Blick behalten werden – auch das kostet einiges an Budget. Sind keine AI-Experten im Haus, erhöht dies die Kosten zusätzlich.
- 3 Eine so umwälzende AI-Anwendung birgt verschiedene Risiken. Die Angst, von einer Maschine ersetzt zu werden, kann die Akzeptanz des AI-Systems im Designteam stark reduzieren. Das gilt auch für den Betriebsrat. Diese Sorgen müssen ernst genommen werden und gehören zum notwendigen Change Management bei der Einführung von AI-Anwendungen (siehe «Sicher landen» auf Seite 242). Schließlich muss klar sein: Die Leistung der AI endet beim 3-D-Modell. Die Handarbeit am Tonmodell lässt sich nie ganz ersetzen.
- 4 Wir fassen zusammen: Das Potenzial, schneller und präziser technische und betriebswirtschaftliche Faktoren im Design zu berücksichtigen, ist deutlich. Die Technik bietet die Chance, der Schnellebigkeit auf dem Markt zu begegnen sowie die Entwicklungszeiten zu reduzieren. Das führt zu erheblichen Kostensenkungen. Außerdem besteht die Aussicht, Subjektivität bei der Entscheidungsfindung auch im Designbereich zu reduzieren. Weil das Projekt umfassende Veränderungen mit sich bringt, würde sich nur dafür entschieden werden, wenn es strategisch relevant ist.



Entscheidung treffen Business Check



Kriterien	ohne AI	mit AI
1 Personal (FTE)	ca. 20 Exterieur-Designer pro Modell 1–3 3-D-Modelleure 1–3 Clay-Modelleure 1 Projektleiterin 1 Designmanager 1 Engineering PL (pro Thema) Sales-, Marketingverantwortliche etc.	ML- Experten DS-Experten 1 Designmanager 1 Projektleiter 1–2 Exterieur-Designer 1 Engineering PL (pro Thema) Sales-, Marketingverantwortliche etc.
Zeit	1–2 Jahre für die frühen Designphasen in der Vorentwicklung	4 Monate für einen ersten PoC Bis zu 2 Jahre für die Umsetzung einer fertigen Endnutzer-Software Angestrebte Zeitersparnis: netto Designzeit statt 2 Jahre auf 2–3 Monate reduzieren
2 Kosten	F&E (inkl. Design) machen ein Drittel der Gesamtentwicklungskosten eines Autos aus Hohe Entwicklungskosten (pro neuem Modell können das bis zu 1 Milliarde Euro sein)	Hohe Initialkosten vom PoC bis zur Serie Niedrige bis mittlere Kosten in der Weiterentwicklung und Instandhaltung des Modells
3 Hürden	Lange Entwicklungszyklen verhindern die Anpassung an den schnelllebigen Markt Wachsende Produktpalette = steigende Entwicklungs- und Personalkosten Subjektivität beeinflusst Design- und Entwicklungsentscheidungen	Geringe Akzeptanz beim Designteam (Angst, ersetzt zu werden, oder dass Kompetenz untergraben wird) Geringe Akzeptanz bei Betriebsrat Wenig AI-Kompetenz 3-D-Modelle können maßstabsgetreue Tonmodelle bis heute nicht ersetzen
4 AI-Potenzial	Anforderungen, wie Aerodynamik etc., werden zu Beginn der formalen Entwicklung zuverlässig berücksichtigt und müssen nicht mehr konstant angepasst werden Zeit- und Kostenersparnis Leichte Anpassbarkeit auf neue Produktreihen	



*Der Design-Konfigurator bietet die Chance, die
Zeit für das Erstellen eines neuen Autodesigns
um den Faktor Zehn zu reduzieren.
Das rechtfertigt die anfänglich
hohen Investitionen.*

Was wir gelernt haben ...

- 1. AI-Modelle können auch gewollt ungenau arbeiten.**
Der interessante Twist beim Training dieser Anwendung ist, dass einem AI-Modell bewusst Abweichungen gestattet werden. Dadurch entstehen neue Ideen, die für die Designer in unserem Szenario als Inspiration dienen können. Der Vorteil: Die neuen Ideen enthalten bereits die technischen und betriebswirtschaftlichen Vorgaben.
- 2. Eine neue Technologie erzeugt Ängste.** Der Faktor Angst vor dem Verlust des Arbeitsplatzes ist ein ständiger Begleiter bei der Einführung neuer Technologien. Vor allem das Erledigen kreativer Arbeit durch Maschinen führt bei den betroffenen Berufsgruppen möglicherweise zu Widerstand. Es ist für die Akzeptanz dieser Systeme entscheidend, bei der Planung die Kombination aus menschlichen und maschinellen Stärken zu berücksichtigen. Welche menschlichen Stärken können mit maschineller Hilfe unterstützt werden? Wo können Aufgaben durch Maschinen übernommen werden, die unter Umständen sogar eher eintönig und belastend sind?
- 3. Künstliche Intelligenz kann Neues schaffen.** Ein AI-Modell kann prinzipiell jegliche kreative Leistung imitieren und auch ungewöhnliche neue Variationen schaffen. Eindrucksvolle Beispiele sind lebensechte Fotos von Menschen, die es gar nicht gibt. Das funktioniert auch mit Landschaften, 3-D-Modellen, Lebensmittelrezepturen oder Molekülbausteinen. Allerdings sind die Ergebnisse eben nie zu hundert Prozent perfekt ... aber das sind wir Menschen ja auch nicht.

6. Tests durchführen

Der Zwilling der Kreativität beim Innovieren ist die Unsicherheit. Wir haben eine Idee – aber zweifeln, ob sie beim Kunden auf Interesse stößt. Wir entwickeln ein Konzept und daraus einen Prototyp – doch ob die aus Sicht der Erfinder brillante Lösung auch tatsächlich das Problem des Kunden löst, ist zunächst unbekannt.

Es sind Hypothesen, und der beste Weg, eine Hypothese zu überprüfen, ist das Experiment. Wir haben in den ersten beiden Abschnitten gesehen, wie wir AI-Modelle nutzen, um Bedürfnissen von Nutzern auf die Spur kommen, oder wie wir am Flughafen die Hindernisse einer flüssigen Sicherheitskontrolle ohne allzu lange Wartezeiten aufdecken können. Wir können diese Techniken ebenso einsetzen, um zu verifizieren, ob ein Trend, ein Bedarf oder ein Problem, das wir ahnen, tatsächlich existiert.

1. Während wir innovieren, befassen wir uns in der Regel mit vier grundsätzlichen Fragen:
2. Existiert das **Problem** beim Kunden tatsächlich?
3. Löst meine **Idee** das Problem des Kunden, hat sie einen Nutzen? Wird meine Idee auf dem **Markt** erfolgreich, funktioniert das Geschäftsmodell?
4. Funktioniert meine **Lösung** technisch?

Zu allen vier Fragen haben wir am Anfang nur Hypothesen, unsere eigenen Glaubenssätze, die zunächst nur auf unserer Erfahrung beruhen.

Um zu validieren, dass unsere Annahmen in die richtige Richtung gehen, führen wir Experimente durch.

Hypothesen verifizieren

Um zu validieren, dass unsere Annahmen in die richtige Richtung gehen, führen wir Experimente durch. In den vergangenen Jahrzehnten haben sich dafür eine ganze Menge unterschiedlicher Verfahren etabliert.

Das einfachste Verfahren funktioniert vollkommen analog: Wir fragen unsere Kunden persönlich, setzen ihnen unsere Lösung vor, beobachten sie beim Ausprobieren und dokumentieren, was wir erleben. Wir können so mit relativ wenig Aufwand Hypothesen oder erste Produktvarianten verifizieren – oder falsifizieren.

Oder wir fragen unsere Kunden online. Dazu eignen sich zum Beispiel Landingpages mit Produkt-Dummys und unterschiedlichen Preismodellen, bei denen gemessen wird, welche Variante am besten ankommt. Oder es werden unterschiedliche Versionen eines Angebots den Besuchern per Zufall gezeigt (A/B-Tests). Die Auswertung gibt Aufschluss, welche Version am besten ankommt.

Prototypen testen

Prototypen können natürlich auch aktiv getestet werden. Dazu gibt es zahlreiche Angebote von Dienstleistern, die Testgruppen mit allen erdenklichen Nutzertypen rekrutieren. Diese probieren die Prototypen aus und geben ihr Feedback ab.

Schließlich können erste Produktversionen bereits verkauft oder angezahlt werden. So ging zum Beispiel Dropbox vor oder auch Amazon mit dem ersten smarten Lautsprecher mit Alexa-Funktion. Beide Angebote existierten nur als Webseite. Auch diese Informationen geben Aufschluss über mögliche Größenordnungen beim Markteintritt.

Das Problem

Hier haben wir, ähnlich wie bei der Marktforschung, mit Verzerrungen zu kämpfen. Bei Kundeninterviews klafft oft eine Lücke zwischen dem, was Kunden sagen, und dem, wie sie sich später verhalten, wenn es darum geht, Geld auszugeben. Technische Produkte haben heute eine enorme Komplexität – Tests sind daher sehr aufwendig. Und schließlich gibt es hohe Ansprüche an die Bedienbarkeit. Auch sie muss immer besser getestet werden. Die letzten beiden Punkte gelten in besonderem Maße für Softwareprodukte. Deren Qualität hängt nicht nur vom fehlerfreien und effizienten Programmcode ab, sondern auch von der richtigen Balance der Funktionen und der möglichst intuitiven Benutzbarkeit.

Wie AI helfen kann

Wir sehen derzeit vor allem in der Softwarebranche, dass mehr und mehr Testszenarien mithilfe von AI-Modellen unterstützt werden. So wird die Bedienbarkeit und Funktion von Websites, Apps und Computerprogrammen mehr und mehr von automatischer Testsoftware unterstützt. Gemessen wird zum Beispiel, wie viel mehr gekauft wird, wenn ein Button an anderer Stelle steht, einen anderen Text enthält oder eine andere Farbe hat.

Für Tester sind automatische Helfer extrem wichtig, weil die Arbeitszyklen immer kürzer werden.

Auch die Funktion selbst kann automatisiert getestet werden. AI-basierte Prüfprogramme können ähnlich wie bei Programmen, die den Stil von Texten korrigieren, unterschiedliche Arten von Fehlern im Programmcode finden, markieren und Änderungsvorschläge machen. Für die Tester sind diese automatischen Helfer extrem wichtig, weil sich in der Softwareentwicklung das agile Arbeiten mit sehr kurzen Arbeitszyklen stark durchgesetzt hat. Im Idealfall bekommt man so schon nützliche Hinweise während des Designs oder der Programmierung. Diese Arbeitsweise ist nur noch mithilfe von AI-Anwendungen möglich. Wo es früher allenfalls jährlich eine neue Programmversion gab, werden heute oft wöchentlich neue Versionen veröffentlicht.

Dauertests

In der Industrie hat sich eine andere Art des Testens etabliert. Unter dem Stichwort «Predictive Maintenance» existieren eine Vielzahl von Dauertests: So werden zum Beispiel die Betriebsdaten von Flugzeugturbinen von Sensoren aufgezeichnet. Ein AI-System überprüft die Muster in diesen Daten kontinuierlich auf Abweichungen. Treten Anomalien auf, leitet das System eine Aktion ein – es informiert Techniker oder reduziert zum Beispiel die maximal mögliche Leistung.

Auch beim Testen von Produkten mit Testpersonen hilft mittlerweile der Einsatz von Hightech. So forschen Wissenschaftler daran, aus der Messung von Gehirnströmen den emotionalen Zustand eines Menschen abzuleiten. Eine praktische Anwendung ist das Testen der unbewussten Emotionen auf die Präsentation von Produkt- und Serviceideen.

Ökonomie des Geschmacks

Eine andere Anwendung erlaubt das Testen von Geschmacksrichtungen für die industrielle Produktion von Nahrungsmitteln. Hier werden weltweite Geschmacksmuster von Zielgruppen in einer App dokumentiert. Die AI kann daraus ableiten, welche anderen Geschmacksvorlieben diese Gruppen auch noch haben. Die Tester können diese Datenbasis nutzen, um ihre Produkte besser an diese Wünsche anzupassen. Und sie können auf die aufwendigen Fokusgruppentests verzichten, weil die Präferenzen der Zielgruppe im Algorithmus abgespeichert sind. Wichtig ist das für Unternehmen, die ihre Marken auf globalen Märkten vertreiben und an lokale Geschmacksvorlieben anpassen müssen.

Wir sehen an diesen Beispielen, dass die Grenzen zwischen Nutzeranalyse, Personaentwicklung, Design und Testen durch den Einsatz von AI zunehmend verschwimmen. Innovation als kreativer Prozess lässt sich mit dem Einsatz von lernenden Maschinen außergewöhnlich gut automatisieren und verbessern. Was zunächst als Nachteil der AI (keine Intuition, ohne gut aufbereitete Daten weiß sie nichts) empfunden werden kann, stellt sich bei genauerer Betrachtung oft als unschätzbare Vorteil heraus: Ein Designvorschlag oder ein Test basiert grundsätzlich auf Nutzerdaten.

Echtes Nutzerverhalten

Damit ist die Grundforderung modernen Designs – nämlich die Kundenperspektive – einem AI-Design immer schon eingeschrieben. Weil AI keine Intuition und keinen eigenen Willen besitzt, muss sie sich auf Nutzerdaten stützen. Das können Gehirnströme, Geschmacksvorlieben oder Klickverhalten sein, Posts in den Social Media, Expertenbewertungen oder Absatzzahlen aus der Buchhaltung. Alle diese Daten spiegeln immer echtes Nutzerverhalten wider oder auch Einschätzungen, was von Nutzern als gute Qualität empfunden wird.

Szenario

Der App-Tester

Apps sind heute erste Wahl bei neuen digitalen Anwendungen. Viele Menschen besitzen gar keinen Computer mehr, sondern nutzen vorwiegend Smartphone oder Tablet.

Statt eine physische Tastatur zu benutzen, wird mithilfe einer virtuellen Tastatur auf dem Touchscreen mit dem Finger getippt und mit mehreren Fingern Gesten ausgeführt.

Weil die richtige Geste nicht immer intuitiv ersichtlich ist, werden häufig kleine Erklärsequenzen angezeigt, wenn eine App zum ersten Mal benutzt wird – vermutlich eine der am meisten übersprungenen Funktionen.

Warum AI?

Besser wäre es, zu wissen, was Nutzer erwarten, bevor Bedienelemente in einer App gestaltet werden. Die begrenzte Bildschirmfläche bietet nur wenige Möglichkeiten, um Erklärungen oder Bedienhilfen anzuzeigen. Also müssen Entwickler wissen, wie das intuitive Verhalten der Nutzer aussieht.

Wann **tippen** sie mit dem Finger auf ein Bild?

Wann erwarten sie, dass **eine Aktion folgt**, wenn sie eine Textpassage sehen?

Welche Farbe oder Button-Form lädt **zum Klicken** ein?

Der AI-Ansatz

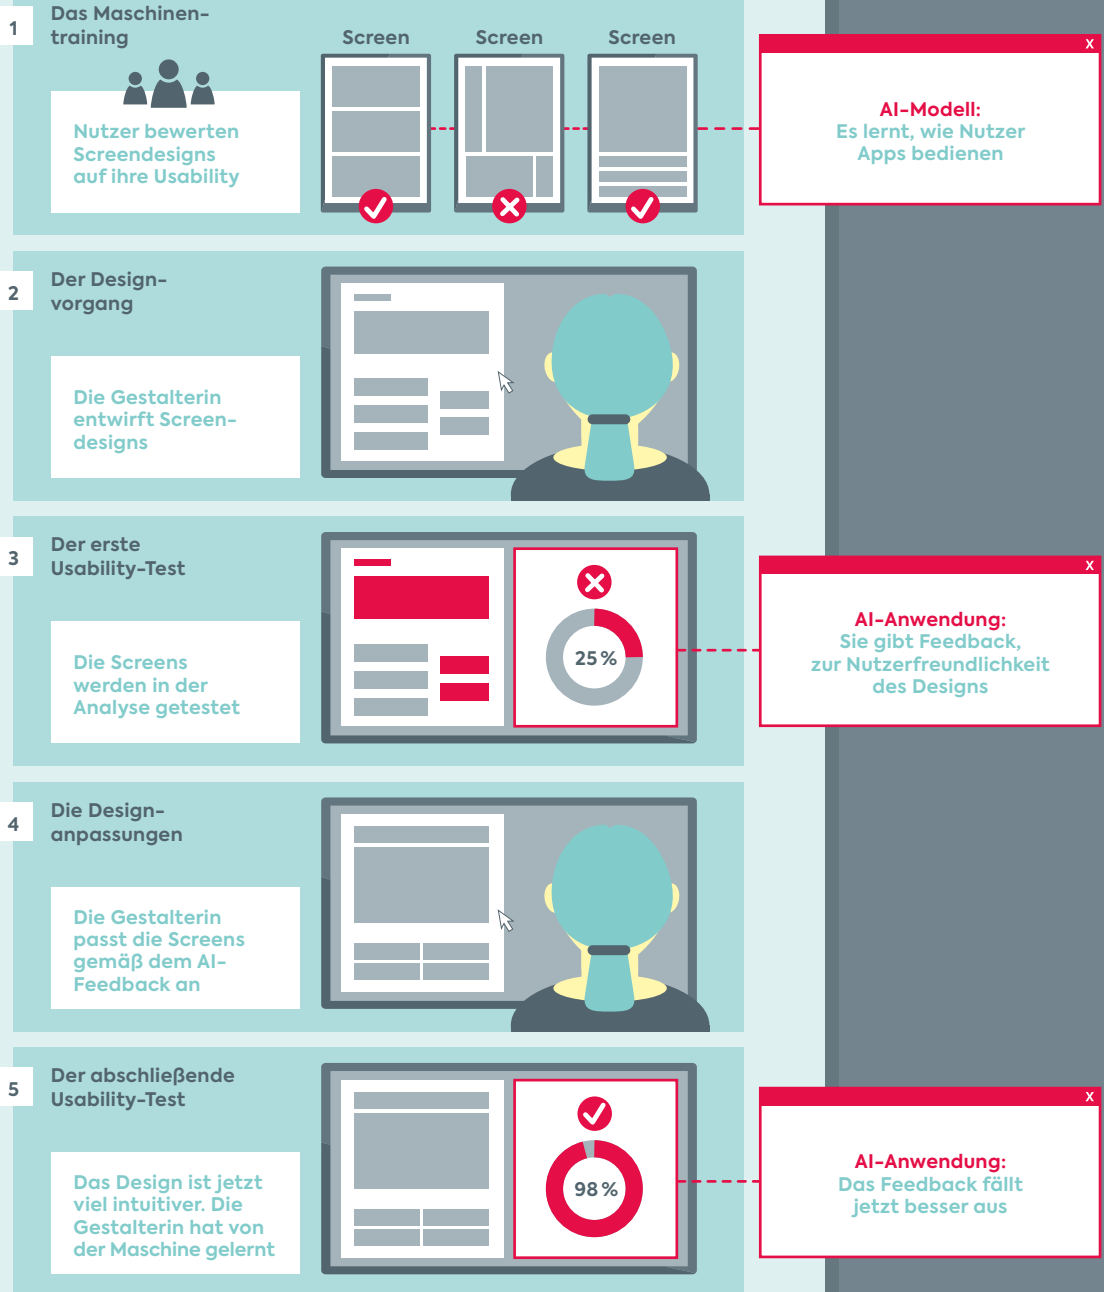
Für unser Entwicklerteam wollen wir ein Programm, dass uns anzeigt, wie Nutzer auf unsere Designs von Bedienelementen, wie Buttons und Links, oder Inhalte, wie Bilder und vieles mehr, reagieren.

Die Vorhersage des menschlichen Verhaltens soll unseren Gestaltern und Entwicklern helfen, wichtige Aspekte der Benutzerfreundlichkeit ihrer Apps zu verstehen, ohne aufwendige Nutzertests durchführen zu müssen. So können Designs direkt an das Feedback angepasst werden – lange Iterationszyklen entfallen.

In diesem von einem Google-Team erdachten Ansatz wird außerdem Crowdsourcing angewandt, um Trainingsdaten zu labeln (Details siehe arxiv.org/abs/1902.11247). Auf diese Weise lässt sich beispielsweise das typische Verhalten einer Zielgruppe von einem AI-Modell erlernen. In diesem Fall ist es das Tippverhalten bei der Nutzung von Apps.



AUTOMATISIERTES UI-USABILITY TESTING





1. Ziel definieren

AI-Mehrwert

Auftrag

Herausfinden, wie Nutzer mit unserem digitalen User Interface interagieren, ohne aufwendige Nutzertests durchzuführen.

Erwarteter Mehrwert durch AI

- Kontinuierliches Testen in Echtzeit, ohne Testnutzer (Zeit- und Kostenersparnis)
- Testen parallel zu Designanpassungen (kürzere Iterationszyklen)
- Testen über verschiedene Apps hinweg

Challenge


Wie können wir unserem UX-Team ein digitales Testwerkzeug zur Verfügung stellen, das ermöglicht, in Echtzeit neue UX-Designs auf Usability (Tappability, Affordance) zu testen und vorherzusagen, welche Teile des Interfaces interaktiv (antippbar) sind und welche nicht, ohne auf zeit- und kostenintensive menschliche Nutzerstudien zurückgreifen zu müssen?

Output

Erkennen ☐ Vorhersagen ☒ Erzeugen ☐

Outputformat

Test-Applikation, in die unsere Designer aktuelle UI-Designs und deren dahinterliegende Interaktionsstruktur reinladen können, um in Echtzeit zu überprüfen, wo ein Mensch theoretisch bei der Nutzung der Screens draufklicken würde und wo nicht.

 Screendesign



2. Daten recherchieren

Datenquellen

Typ	Quelle	Warum?
A Verschiedene App Screendesigns	Rico Dataset (University of Illinois)	Designstile und Interface-Konzepte lernen
B UI Interaktionsstruktur pro Screen	Rico Dataset (University of Illinois)	Lernen welche Screenbereiche tippbar sind
C Crowd-gelabelte tippbare Screenbereiche	Selbsterstelltes Datenset durch Crowdsourcing	Menschliche Einschätzung der Klickbarkeit lernen
D		

Datenprüfung

	Priorität	Beschaffung	Technik
A	hoch <input checked="" type="radio"/>	niedrig <input checked="" type="radio"/>	niedrig <input checked="" type="radio"/>
B	hoch <input checked="" type="radio"/>	niedrig <input checked="" type="radio"/>	niedrig <input checked="" type="radio"/>
C	hoch <input checked="" type="radio"/>	mittel <input checked="" type="radio"/>	niedrig <input checked="" type="radio"/>
D	hoch <input type="radio"/>	hoch <input type="radio"/>	hoch <input type="radio"/>

Datenerhebung

Grund für die Datensammlung

- Designstile und Interface-Konzepte lernen
- Menschen-schätzung: «klickbar ja/nein»
- Tippbarkeit Screenbereiche lernen

Daten-typen

App Screen-designs	Crowd-gelabelte Screen-bereiche	Struktur: UI Interaktion pro Screen	
--------------------	---------------------------------	-------------------------------------	--

Priorität ☒ ☒ ☒ ☐

Beschaffung ☒ ☒ ☒ ☐

Technik ☒ ☒ ☒ ☐



3. Lernkonzept erstellen

Maschinenfähigkeiten		
Aufgabe	Quelle	Fähigkeit
A Screendesign und UI-Elemente verstehen	«Rico Dataset» (University of Illinois)	Infos extrahieren, Kombi Inhalte, Wenig Daten
B Vergleich: Echte Klickbarkeit und Crowd-Labels	«Rico Dataset» (University of Illinois)	Infos extrahieren, Kombi Inhalte, Wenig Daten
C Simulation Usability Test: Von Crowd lernen	Selbsterstelltes Datenset durch Crowdsourcing	Objekte erkennen, Kombi Inhalte, Wenig Daten
D		



4. Entscheidung treffen

Vorgehensvergleich		
	Ohne AI	Mit AI
Personal	2 Researcher, 1 Designer, 1 PL	1 DS- und 1 ML-Experte, 1 Designer, 1 PL
Zeit	2 W Vorbereitung, 1+1 W Test und Iteration	1 W Vorbereitung, 1 W Training und Tweaks
Kosten	Mittel – hoch	Mittel
Hürden	Hoher zeitlicher Aufwand, hohe Kosten	Wenig Expertise
AI-Potenzial	Keine Userstest mehr nötig (Kosten- und Zeitersparnis), schnellere Iterationszyklen	

Trainingsparameter	
Menschlicher Maßstab 39% nicht klickbar und als klickbar gekennzeichnet, 10% klickbar als nicht klickbar gekennzeichnet	Minimalanforderung 80% der UI-Elemente korrekt und konsistent ermitteln, die User als tippbar wahrnehmen
Erwünschtes Zielmaß > 95% der UI-Elemente korrekt und konsistent ermitteln, die User als tippbar wahrnehmen	Mindestvertrauen > 95% Vorhersagen entsprechen menschlicher Beurteilung, weil keine Nachkontrolle erwünscht

Recall ————— Precision

Entscheiden	
Ergebnisqualität/ Geschäftswert	Nichts wie ran!
	Nur wenn lang-fristig strategisch relevant
Ist es wirklich notwendig?	Auf keinen Fall!
Risiko/Aufwand	

Nutzerfreundlichkeit vorhersagen

Das Testen, ob die Seiten einer App nutzerfreundlich gestaltet sind, kann ein aufwendiger Prozess sein. Eine recht einfache AI-Anwendung kann mit wenig Training lernen, sich wie typische App-Anwender verhalten. Der Trick ist, dass die Dienste von sogenannten Clickworkern genutzt werden.

Sie bewerten typische Designelemente in einer App daraufhin, ob sie klickbar sind oder nicht. 20 000 Elemente werden auf diese Weise gelabelt – und sind damit von einem AI-Modell nutzbar. Diese Datenbasis nutzt das hier vorgestellte Modell für das Training.



Ziel definieren AI Value Map

Der Auftrag

Herausfinden, wie Nutzer mit unserem digitalen User Interface interagieren, ohne aufwendige Nutzertests durchzuführen



Manuelle Projektschritte

Beschreibung

Usability-Tests vorbereiten: Screenflows erstellen, Recruiting

Tests durchführen

Designiteration auf Basis der Insights

Erneutes Testen

Typische Pain Points

Hoher Designreifeegrad nötig, Testprovider teuer, Incentives für Testnutzer

Kosten- und Zeitaufwand; Projektstillstand während Tests, eine App pro Test

Hoher Zeitaufwand, begrenzte Anpassung pro Iteration

Kosten- und Zeitaufwand, Projektstillstand während Tests, eine App pro Test

Geschäftlicher Mehrwert durch AI

Kostenersparnis durch Automatisierung

Zeitersparnis, keine Idle-Time, verschiedene Apps gleichzeitig testen

Zeitersparnis, Lernkurve für Entwickler, neue Designansätze finden (USP)

Zeitersparnis; keine Idle-Time, verschiedene Apps gleichzeitig testen

Hier kann AI unterstützen:



Ziel definieren Challenge Guide



Elemente

Herausforderungen

Hoher Kosten- und Zeitaufwand. Begrenzte Anpassungsmöglichkeiten pro Iterationszyklus, Entwicklungsstillstand während Testphasen

Nutzer/Zielgruppe

Marketing, Vertrieb, Innovationsabteilung, Forschung und Entwicklung

Geltungsbereich/ Umfang

Alle Apps unseres Unternehmens

Zeiträumen

Projektdauer: 2 Monate

2

Geschäftlicher Mehrwert durch AI

Usability Testing neuer Designs in Echtzeit, Verzicht auf menschliche Testnutzer, kein Leerlauf im UX-Team

Zusammenfassung

Wie können wir unserem UX-Team ein digitales Testwerkzeug zur Verfügung stellen, das ermöglicht, in Echtzeit neue UX-Designs auf Usability (Tappability, Affordance) zu testen und vorherzusagen, welche Teile des Interfaces interaktiv (antippbar) sind und welche nicht, ohne auf zeit- und kostenintensive menschliche Nutzerstudien zurückgreifen zu müssen?

Wie es geht

1. Ziel definieren

Tipptbar oder nicht tipptbar, das ist hier die Frage.


Die schöne Erkenntnis in diesem Szenario ist, dass der Weg zu einer gewinnbringenden Anwendung oft weniger komplex ist, als man anfangs annehmen könnte.

1

Bei der Analyse der manuellen Projektschritte wird schnell deutlich, dass AI einen enormen Mehrwert bringen kann, wenn es darum geht, aufwendige Iterationszyklen zwischen Design und Testen abzukürzen. Denn während der Testphasen von Apps vergehen manchmal Tage, in denen Entwickler und Designer nicht voll ausgelastet werden. Dieser Leerlauf kostet Geld.

Nach jedem Nutzertest vergeht Zeit, um die Testergebnisse in verbesserte Designs zu übersetzen. Um die Auswirkungen einzelner Designanpassungen besser nachvollziehen und vergleichen zu können, enthalten diese oft eher kleine Änderungen. Aber auch diese müssen wieder mit echten Nutzern überprüft werden. Ein AI-Modell bietet eine wertvolle Abkürzung, wenn wir statt Tagen nur noch Sekunden oder Minuten für die Analyse der Benutzerfreundlichkeit eines Designs benötigen.

Direktes Feedback durch AI hat einen schönen Nebeneffekt: Es inspiriert Designer und Entwickler grundsätzlich, über ihre Gestaltungsprinzipien nachzudenken und ganz neue Designansätze zu finden, die Nutzern ihrer digitalen Produkte in Form von Bedienkomfort zugute kommen.



Die Output-Darstellung zeigt, wie das visuelle Feedback aussehen soll.

2

Der Mehrwert ergibt sich also vor allem aus drei Aspekten: **Zeitersparnis** (kürzere Iterationszyklen = mehr Produktivität). **Kostenersparnis** (eine Vielzahl von Apps, Designs und Interaktionskonzepten können ohne Testnutzer analysiert werden). **Ressourcenauslastung** (Designer müssen nicht auf Testergebnisse warten, bevor sie Anpassungen vornehmen können).

Der Output soll aus einer Testapplikation bestehen, in die Designer ihre Screendesigns und deren dahinterliegende Interaktionsstruktur importieren können. Dort können sie in Echtzeit überprüfen, ob die geplanten interaktiven Elemente der Benutzeroberfläche von Menschen wie beabsichtigt wahrgenommen und angetippt würden.

2. Daten recherchieren

Zu Illustrationszwecken haben wir unsere Data Checklist ausnahmsweise etwas angepasst. Dadurch können wir besser darstellen, wo die Unterschiede zwischen Trainings- und Testdatenquellen liegen. Die normalerweise im Template gezeigten Alternativen zu den genannten Quellen wären zum Beispiel Ergebnisse von A/B-Tests oder Nutzerbeobachtungen per Video.

1

Um dem AI-Modell beizubringen, wie Menschen die Interaktivität eines Screendesigns intuitiv einschätzen, sind drei verschiedene Datentypen notwendig. Sie ermöglichen jeweils unterschiedliche Lernaspekte:

Verschiedene **Screendesigns** unterschiedlicher Apps (verschiedene Designstile und Screenstrukturen lernen).

Interaktionsstrukturen jedes Screens (lernen, welche Elemente der abgebildeten Designs tatsächlich antippbar sind). Dieser Datentyp wird für die Testdaten verwendet.

Crowd-gelabelte tippbare **Screenbereiche** (lernen, wie Menschen die Screen-Interaktivität einschätzen).

Die ersten zwei Datentypen lassen sich einfach aus dem kostenlos zur Verfügung stehenden Rico Dataset der Universität Illinois nehmen. Es enthält über 66 000 einzigartige UI-Screens sowie deren Interaktionsstruktur.

Die dritte Datenquelle muss noch aufbereitet werden. Dazu werden aus dem Rico Dataset 3500 Screens und deren hinterlegte Interaktionsstruktur mit circa 20 000 Datenpunkten (klickbare oder nicht klickbare Screenelemente) ausgewählt. Diese werden von Crowdworkern gelabelt. Das heißt, diese bezeichnen jedes Screenelement als klickbar oder nicht klickbar. Anhand dieser einfachen Information kann das AI-Modell lernen, wie Nutzer Screenelemente anklicken würden. So entsteht ein umfangreicher Trainingsdatensatz.

2

Das Rico Dataset ist bereits für maschinelles Lernen vorbereitet und kostenlos verfügbar. Hier ist der Aufwand für Beschaffung und technische Aufbereitung gering. Die Screen-elemente für das Crowdsourcing müssen dagegen so vorbereitet werden, dass sie in Crowdsourcing-Plattformen, wie Amazon Mechanical Turk, verarbeitbar sind. Der Beschaffungsaufwand ist daher eher als mittel einzustufen.



Daten recherchieren Data Checklist



Datentyp

Datentyp B: UI-Interaktionsstruktur pro Screen
Datentyp C: Crowd-gelabelte Screenbereiche

Warum?

Datentyp B: lernen welche Screenbereiche tippbar sind
Datentyp C: menschliche Einschätzung der Klickbarkeit lernen

Die Basisinformationen

EIGENTÜMER

Wer besitzt sie und Rechte an ihnen?
Welche Stakeholder sind involviert?

ZUGANG

Wo befinden sie sich?
Wie ist der Zugang geregelt?
Wie lassen sie sich nutzen?

KOSTEN

Welche Kosten fallen an?

Trainingsdatenquelle

Crowd-erstelltes Datenset

Unser Unternehmen
Keine

Amazon Mechanical Turk (AMT)
Verfügbar nach Beauftragung
Web API

Ca. 500 \$ bei circa 20 000 zu
verarbeitbaren Datenpunkten

Testdatenquelle

Rico Dataset

University of Illinois
Keine

Download auf Projektwebsite
Frei zugänglich
Download der Datenset-Teile

Keine

Datenqualität

AKTUALITÄT

Wie aktuell sind sie?
Wie häufig werden sie aktualisiert?
Wie oft muss ich darauf zugreifen?

Sehr, weil von uns erzeugt
Gar nicht (einmalig erstellt)
Einmalig für Maschinentraining

2017
K. A. (derzeit nicht geplant)
Einmalig für meine Anwendung

FORMAT

Wie liegen sie vor?
Welche Felder liegen vor?

Strukturiert, Bildformat (PNG)
und Datenbankformat (JSON)
Bezeichnungen für UI Elemente

Strukturiert, Datenbank (JSON)
Bezeichnungen für UI Elemente
(z. B. «Klickbar: ja/nein»)

ZUSTAND

Für Aufgabe und Training vorbereitet?
Datensätze (Aufgabe/Training) komplett?
Wie eindeutig sind sie?
Wie groß ist die Datenmenge?
Wie repräsentativ sind sie?

Ja, wichtig für Crowdsourcing
Nach Labelling durch AMT, ja
Sehr, Datenset von uns erstellt
ca. 1 GB
Sehr, da sehr diverses Datenset
inkl. noch gültigen Designtrends

Ja
Ja
Sehr, Datenset für ML erstellt
ca. 6 GB
Sehr, da sehr diverses Datenset,
inkl. gültigen Designtrends

Bewertung

Priorität



Beschaffungsaufwand



Technischer Aufwand



hoch



mittel



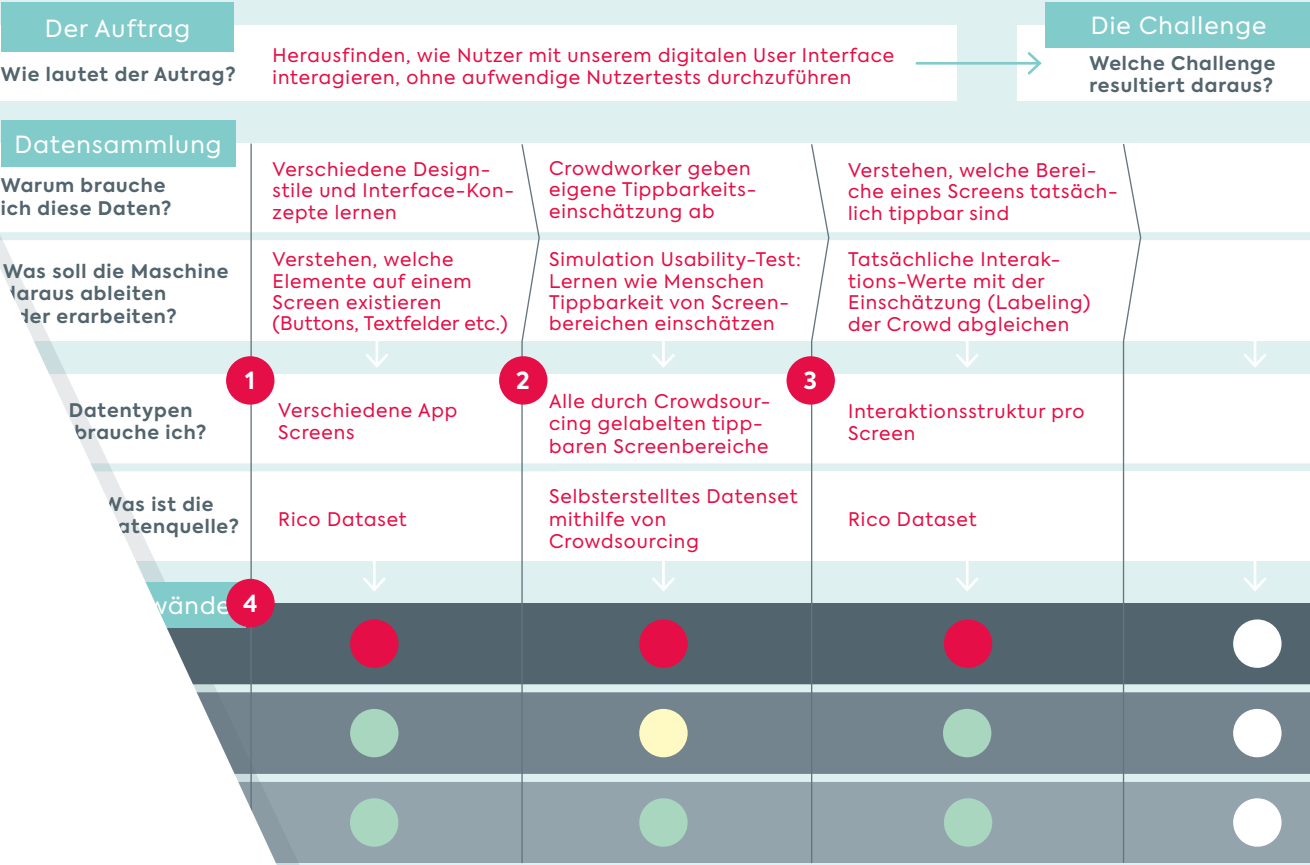
niedrig

Die drei Datentypen müssen nun sortiert werden. Welche Daten muss die Maschine nacheinander auf welche Weise verarbeiten, damit sie uns in der gleichen Qualität wie ein Mensch Feedback zu unseren Screendesigns liefern kann?

- 1 Zunächst muss die Maschine lernen, Screendesigns und die darin enthaltenen Elemente zu verarbeiten. Je mehr Screens sie gesehen hat, desto einfacher fällt es ihr nachher, neue Designs zu interpretieren, die sie noch nie gesehen hat. Die dafür benötigten Daten erhält sie aus dem Rico Dataset.
- 2 Der folgende Schritt ist entscheidend für die gesuchte Test-Anwendung: Crowdworker bewerten die 20 000 markierten Bereiche der 3500 Screendesigns nach Klickbarkeit. Damit wird ein Usability-Test simuliert. So lernt unser Modell später im Training, wie Menschen Screens auf Interaktivität einschätzen, und kann diese Einschätzung in bisher unbekannten Designs vorhersagen/nachahmen.
- 3 Um richtig vorhersagen zu können, wie Menschen im neuen Screendesigns klicken, muss unser Modell lernen, wie akkurat die Crowdworker tatsächlich klickbare Screelemente bewertet haben. Dazu werden die 20 000 durch Menschen markierten Datenpunkte aus der simulierten Usability-Studie mit der tatsächlichen Interaktionsstruktur des Rico Dataset verglichen.
- 4 Wie die Data Checklist zeigt, bereitet die Datenaufbereitung bei dem geplanten Vorhaben keine allzu hohen Aufwände. Passende Modelle und Daten sind entweder verfügbar oder können mit mittlerem Aufwand innerhalb der vorgegebenen Projektdauer von zwei Monaten angepasst werden.



Daten recherchieren
Data Journey Map



3. Lernkonzept erstellen

Die Ausgangsfrage unseres Szenarios war, wie gut Menschen den tatsächlich klickbaren Zustand eines Elements wahrnehmen, der von Entwicklern vorgegeben wurde.

- 1 Die Qualität des Modells hängt davon ab, wie genau es das Verhalten der Crowdworker simuliert. Als Maßstab stehen zwei Werte zur Verfügung: In der Interaktionsstruktur der Rico-Daten ist für jedes Element definiert, ob es klickbar ist oder nicht. Demgegenüber stehen die Werte, wie die Crowd die Elemente tatsächlich angeklickt hat.
- 2 Der Abgleich von Interaktionsstruktur und Einschätzung der Crowdworker ergibt, dass es teils erhebliche Abweichungen zwischen als klickbar wahrgenommenen und tatsächlich klickbaren Elementen gibt – eine Wahrnehmungsverzerrung, die auf unterschiedlich intuitive Screendesigns zurückzuführen ist und in unserem Modell enthalten sein muss, wenn es Screendesigns wie ein Mensch bewerten soll. In diesem Fall wird der menschliche Bias also bewusst genutzt.
- 3 Um menschliche User-Tests zukünftig zu vermeiden, sollte das Modell mindestens 80 Prozent, idealerweise mehr als 95 Prozent der UI-Elemente wie ein Mensch einschätzen können. Das Ziel ist es außerdem, dass sich das fertige Testprogramm schnell auf neue Designstile einstellen kann.
- 4 Die Designer in unserem Szenario wollen sich darauf verlassen, dass die Einschätzung der Maschine tatsächlich der menschlichen Wahrnehmung entspricht. Das AI-Modell darf also erst eine Einschätzung über ein neues Design geben, wenn es sich zu mehr als 95 Prozent sicher ist, dass die Vorhersage dieses Kriterium erfüllt.
- 5 Die Test-App soll unterschiedliche Screendesigns und Elemente erkennen. Dafür wird der Schwerpunkt des Trainings auf «Recall» gesetzt. Aber: Zusätzlich ist eine hohe Vorhersagegenauigkeit wichtig, also «Precision». Hier muss gewichtet werden, welcher Aspekt dominieren soll. In diesem Fall verschiebt sich der Schwerpunkt in Richtung «Precision», obwohl sehr vielfältige Elemente erkannt werden sollen.



Lernkonzept erstellen Trainingsparameter



Qualitätsniveau des Modells

1

Einflussfaktoren

Genauigkeit in der Vorhersage, ob Benutzer ein UI-Element als antippbar wahrnehmen würde

Tatsächliche Antippbarkeit eines UI-Elements

2

Menschlicher Maßstab

Nicht klickbare Elemente in 39 % der Fälle als «klickbar» gekennzeichnet

Klickbare Elemente in 10 % der Fälle als «nicht klickbar» gekennzeichnet

Einschätzung ist unter Testpersonen inkonsistent, sie ist abhängig von Erfahrung und Technikaffinität

Mindestanforderung für Wertgenerierung

80 % der UI-Elemente korrekt und konsistent ermitteln, die Benutzer als tippbar wahrnehmen würden

(Um menschliche User-Tests zu vermeiden)

3

Erwünschtes Zielmaß

> 95 % der UI-Elemente korrekt ermitteln, die Benutzer als tippbar wahrnehmen würden

Schnelles Adaptieren auf neue Interface-Designstile

4

Mindestvertrauensgrad des Modells

> 95 % der präsentierten Voraussagen stimmen, weil mein Designer sich auf die Aussage verlassen können soll, dass die Maschine in der gleichen Genauigkeit wie ein Mensch einschätzt, ob UI-Elemente klickbar sind oder nicht

Schwerpunkt des Trainings

Trefferquote (Recall)

Genauigkeit (Precision)



Argumente

Modell soll auf neue Screens verschiedener Apps ebenfalls gute Vorhersagen treffen

Viele verschiedene Arten von Screens einschätzen können

Anwendung auf gleiche Apps unter verschiedenen Operating Systems

5



Argumente

Hohe Genauigkeit bei der Vorhersage, wie Menschen UI-Elemente einschätzen, damit Designer Feedback einarbeiten können

Kein selbstlernendes Modell (neue Designs werden manuell angelernt, dafür nur wenige Daten nötig)

Stabile Daten (neue Designstile und -trends kommen alle paar Jahre, nicht Wochen)

Wenn ich das Tool nur intern nutzen möchte (nur nach meinem Design Guide), soll es meine Designs sehr zuverlässig bewerten

4. Entscheidung treffen

Ziel der AI-Anwendung: Die Designer und UX-Entwickler sollen am Ende durch das Feedback der Maschine lernen, ihr Interfacedesign intuitiver zu gestalten.

- 1 Der Business Check zeigt: Die Entwicklung kostet weniger Zeit und ähnlich viel Personal wie das Durchführen eines manuellen Testzyklus.
- 2 Die Kosten sind im Vergleich zum manuellen Testen ebenfalls niedrig.
- 3 Die AI-Anwendung kommt nicht ohne kontinuierliche Wartung aus. Neue Designstile und -trends müssen nachtrainiert werden. Das sind Aufwände, die bei der Entscheidung für oder gegen AI mit berücksichtigt werden müssen. Fehlt die AI-Expertise, lässt sich das Modell mit Partnerhilfe relativ einfach umsetzen. Dann steigt jedoch der Aufwand entweder an Kosten oder an investierter Zeit.
- 4 Die Chancen stehen gut, dass sich das Entwickeln der AI-Anwendung sehr schnell amortisiert, sofern regelmäßig aufwendige Usability-Tests gemacht werden. Die Iterationszyklen lassen sich um ein Vielfaches verkürzen, Nutzertests sind nur noch selten nötig, und die Designer können durch das kontinuierliche und schnelle Feedback besser lernen, welche Designprinzipien von den Nutzern akzeptiert werden.



Entscheidung treffen Business Check



Kriterien	ohne AI	mit AI
1 Personal (FTE)	2 Researcher (Auswertung der Tests) 1 Designer (schätzt Erkenntnisse aus Test ein und iteriert seine Designvorschläge) 1 Projektleiterin	1 Data Scientist 1 Machine Learning Engineer 1 Designer (schätzt Usability und Nutzwert der ML-Anwendung ein) 1 Projektleiterin
Zeit	Test-Vorbereitung: 2 Wochen Test-Durchführung: 1 Woche Test-Wiederholung nach Designiteration: 1 Woche (Iterationszahl hängt vom Projektmanagement und Budget ab)	Vorbereitung: 1 Woche Training und Tweaking des Modells: 1 Woche Weiterentwicklung bis zur Endnutzerapp: 1 Monat
2 Kosten	Hoch	Niedrige bis mittlere Initialkosten Niedrige bis mäßige Kosten im Regelbetrieb
3 Hürden	Hoher Zeitaufwand und dadurch langsame Iterationszyklen, häufige Wiederholung bei neuen Apps oder größeren Updates, Hohe Kosten, bei Usability-Tests oft nur Fokus auf eine App pro Test	Fehlende AI-Expertise Nachtrainieren notwendig, wenn neue für uns relevante Designstile und -trends aufkommen
4 AI-Potenzial	Keine Nutzertests mehr nötig (Zeit- und Kostenersparnis) Schnellere Iterationszyklen Direktes verlässliches Feedback für Designer Durch die Lernkurve der Designer können wir neue Design-Prinzipien am Markt etablieren: Trendsetter/USP, First-Mover sein Einfache Übertragbarkeit des Modells auf neue Apps und Interfaces	



Die Test-App hat von Menschen gelernt, wie sich Nutzer verhalten. Nun werden die Rollen getauscht: Die Designer lernen von der Maschine, wie sie nutzerfreundlich gestalten.

Was wir gelernt haben ...

1. **Wenig Daten, große Wirkung.** Die Crowdworker unseres Szenarios haben 3500 Screens bewertet. Was erst mal nach viel klingt, ist für die Maschine ein Kinderspiel. Diese Anzahl hat ausgereicht, um ihr beizubringen, mit einer menschenähnlichen Wahrnehmungsgenauigkeit neue Screendesigns einzuschätzen. Zum Vergleich: Das hier verwendete Rico Data-set ist mit über 66 000 Screens plus Zusatzdaten riesig. Hier wurden mit hohem Aufwand saubere Massendaten erstellt. AI-Experten können die ungefähr benötigte Datenmenge recht leicht bestimmen, wenn der Einsatzzweck klar formuliert ist.
2. **Bias lässt sich bewusst nutzen.** Bei einem Blick in die Medien entsteht oft der Eindruck, dass ein AI-Bias grundsätzlich etwas Schlechtes ist. Man kann ihn jedoch auch nutzen, um einem AI-Modell beizubringen, typisch menschliches Verhalten zu simulieren. Nutzertests werden dadurch erheblich vereinfacht.
3. **AI-Modelle können nur einen Trainingsschwerpunkt haben.** In manchen Fällen ist es nicht so einfach, zu entscheiden ob der Trainingsschwerpunkt eher beim Generalisten oder eher beim Spezialisten liegen sollte. Dann hilft es, schrittweise vorzugehen: Soll die Test-App verschiedenste Screens erkennen? Die Antwort lautet: ja. Nötiges Training: Generalist (Recall). Müssen die Erkenntnisse in den Screens exakt gefunden werden? Antwort: ja. Nötiges Training: Spezialist (Precision). Nun muss gewichtet werden. Was ist wichtiger? Alle Screens erkennen (auch neue) oder eher die Funde möglichst korrekt interpretieren?



AI-Design erlaubt es Kreativen, sich auf ihre genuinen Aufgaben zu konzentrieren. Der Mensch bringt die Emotion ins Spiel.

Tim Cook, CEO Apple

Fazit

Geschafft. Wir sind gesprungen.

Es ist Zeit, den Innovationsprozess selbst ins Maschinenzeitalter zu bringen.

Wir haben gelernt, sehr unterschiedliche AI-Anwendungen mithilfe des AI Planners zu konzipieren. Wir wissen nun, dass Hackathons eine Alternative zum aufwendigen Projekt sein können, wie wir Crowdsourcing effektiv zur Datengewinnung einsetzen können und was es bedeutet, Trainings- und Testdaten aufzubereiten.

Wir haben gelernt, dass der Einsatz von Künstlicher Intelligenz die Grenzen zwischen Nutzeranalyse, Personaentwicklung, Design und Testen zunehmend verschwimmen lässt. Innovation als kreativer Prozess lässt sich mit dem Einsatz von lernenden Maschinen sogar außergewöhnlich gut automatisieren und verbessern.

Es gibt viel zu tun, für Innovatoren und Designer. Doch AI kann wirkungsvoll unterstützen. Das menschliche Gehirn ist nicht länger der einzige Ort, an dem schöpferische Prozesse ablaufen. Designer werden zu Dirigenten. Oder wie es Tim Cook, CEO von Apple, formuliert: «AI-Design erlaubt es Kreativen, sich auf ihre genuinen Aufgaben zu konzentrieren. Der Mensch bringt die Emotion ins Spiel.»

Nun ist es Zeit, sich auf die Landung zu konzentrieren. Aus einem AI-Konzept soll eine stabile, gut verwendbare AI-Anwendung werden. Je nach angestrebtem Ziel gibt es eine Menge zu beachten. Wie ein AI-Entwicklungsprozess genau läuft, ab wann es nötig ist, eine AI-Strategie zu entwickeln, was es mit der Ethik auf sich hat, und welche Elemente eine AI-Governance enthalten soll, ist Gegenstand des nächsten Kapitels «Sicher landen».

Sicher landen

Wie Sie AI im
Unternehmen
skalieren





1. Intro

«Ladies and Gentlemen, prepare for landing.» Unser Fallschirmsprung ist fast zu Ende. Wir haben gelernt, zu springen und unser Equipment zu bedienen. Nun müssen wir nur noch lernen, sicher zu landen.

Was wir bisher über die Entwicklung von AI-Konzepten erfahren haben, führt uns in der Regel bis zu einem Prototyp und später zu einem Proof of Concept. Doch damit ist die Reise nicht zu Ende. AI-Projekte sind grundsätzlich auch Innovationsprojekte. Und aus unserer zehnjährigen Erfahrung mit Innovation und dem Design von Produkten und Dienstleistungen wissen wir, wie viel Arbeit nach der Idee und dem Proof of Concept auf dem Weg zum Produkt noch folgt.

In diesem Kapitel wird es darum gehen, zu verstehen, was es bedeutet, die Grundlagen für Innovation im Unternehmen zu schaffen, sie zu entwickeln und zu einem wertschöpfenden Produkt auszuarbeiten.

Unterscheidung zwischen AI und IT

AI-Projekte stellen aber noch weitere Anforderungen. Häufig werden sie mit IT-Projekten gleichgesetzt – doch die Erfahrung zeigt: AI-Projekte sind in vielerlei Hinsicht anders. Daher zeigen wir, welche Elemente für die Umsetzung von AI-Projekten notwendig sind, und was darüber hinaus unternommen werden muss, wenn das Management Künstliche Intelligenz nicht nur für ein bestimmtes Produkt einsetzen, sondern grundsätzlich in seiner DNA verankern will. Die Führung bereitet damit den Boden für die Transformation zum datengetriebenen Unternehmen – was zu messbar größerem wirtschaftlichem Erfolg führt. Der AI Planner wird uns hier durch die verschiedenen Phasen als Werkzeug und Dokumentation begleiten.

Was ist ein Proof of Concept?

Nach erfolgreichem Studium an der Ostküste der USA zog es die beiden Freunde Joe und Brian 2007 ins Silicon Valley nach San Francisco. Typisch für die Gegend wurde ihnen die Miete ihrer 3-Zimmer-Wohnung kurzfristig um 25 Prozent erhöht und sie waren gezwungen, nach zusätzlichen Geldquellen zu suchen. Die Idee: San Francisco ist auch als Konferenzstadt bekannt und entsprechend sind die Hotels notorisch ausgebucht. Diesen Umstand wollten die beiden nutzen. Sie boten Konferenzbesuchern einen Schlafplatz in ihrer Wohnung an.

Ein Proof of Concept belegt das Funktionieren einer Idee.

Sie erstellten eine Webseite, nannten ihr Angebot: «Air Bed and Breakfast», schrieben einige lokale Blogs mit der Bitte um Werbung an, und innerhalb eines Tages hatten sie drei Buchungen. Am folgenden Wochenende verdienten sie 1000 US-Dollar.

Dieses einfache Angebot und der Verkaufserfolg ist ein klassischer Beleg für das Funktionieren einer Idee, ein Proof of Concept (PoC). Es belegt die Hypothese, dass man online fremden Menschen sein freies Bett vermieten kann. Der PoC war ein voller Erfolg. Er erfüllte drei Eigenschaften:

Die **Akzeptanz der Anwender**: Gäste waren bereit, auf einer Luftmatratze in einer fremden Wohnung zu schlafen und dafür Geld zu bezahlen.

Die **Validierung der wichtigsten Anforderungen**: Interessenten konnten übers Web rekrutiert und Gäste über die Webseite verbindlich gewonnen werden.

Und es diente als **Entscheidungsgrundlage** zur Weiterentwicklung der Plattform und überzeugte ihren dritten Co-Gründer Nathan Blecharczyk, ebenfalls mitzumachen.

Jetzt fängt die
Arbeit erst richtig an

Doch auf den ersten Erfolg folgten zwei Jahre der Ernüchterung. Weiterentwicklungen skalierten nicht oder führten ins Leere. Die Suche nach Investoren blieb erfolglos. Denn um einen PoC zu einem marktfähigen Produkt zu skalieren, braucht es mehr als eine gute Idee, Mut und Schweiß. In der Regel fängt die Arbeit an diesem Punkt erst richtig an. Mit Sequoia Capital fanden die drei 2009 endlich einen ersten kompetenten Investor, der ihnen zu relevantem Business Know-how sowie Kapital für die erfolgreiche Skalierung verhalf.

Die Erfolgsgeschichte von Airbnb zeigt, wie wichtig das Verständnis der Skalierung von Innovationen ist. Grundsätzlich verläuft dieser Prozess in drei Phasen. Dabei spielt die Entwicklung der Idee nur eine kleine Rolle. Viele weitere Aspekte berühren Themen wie Strategie, Organisation und Management und handeln nur sekundär von Innovation. Erst wer in der Lage ist, alle Aspekte erfolgreich zu berücksichtigen, bereitet den Boden für erfolgreiche neue Produkte und Services.

Wie Innovationen skaliert werden – drei Phasen für den Erfolg

1. Innovation meets Strategy meets Change Management

Innovationen benötigen solide und vorausschauende Vorbereitung, um nachhaltig erfolgreich zu sein. Denn wenn Neues erarbeitet wird und der Ausgang einer Unternehmung ungewiss ist, brauchen Menschen eine andere Umgebung, als wenn es um vorhersehbare, erprobte Abläufe geht.

Der wohl wichtigste Schritt ist, das eigene Topmanagement ins Boot zu holen. Denn bis zum erfolgreichen Produkt oder zur Umsetzung ist es ein weiter und steiniger Weg. Da hilft ein starker Fürsprecher, der in besonderen Situationen die richtigen Hebel in Bewegung setzt, Ausnahmen ermöglicht und für breite Akzeptanz sorgt. In unseren Projekten hat es sich bewährt, den Bereichsvorstand oder die verantwortliche Geschäftsführung als Sponsor frühzeitig für das Projekt zu gewinnen und in wichtigen Momenten konkret, zum Beispiel in Workshops, einzubeziehen.

Die Geschäftsführung integrieren

Je mehr das Innovationsthema die Unternehmensstrategie unterstützt, desto höher ist die Akzeptanz bei der Geschäftsführung. Neue Erkenntnisse sollten immer wieder mit der Strategie abgeglichen werden. Die Argumente für ein Innovationsprojekt sollten die wichtigsten Fragen beantworten: Auf welche Weise unterstützt das Innovationsthema eines oder mehrere der Unternehmensziele, und wie lange wird es dauern, bis sich sichtbare Ergebnisse einstellen?

Innovationen benötigen eine höhere Bereitschaft, Risiken einzugehen.

Innovationen benötigen eine höhere Risikobereitschaft. Das Risiko eines Fehlschlags ist selbst bei Verbesserungs- oder Anpassungsinnovationen höher als bei anderen Projekten. Das heißt, dass der Ausgang häufig ungewiss, ein Gewinn auf das investierte Kapital auch nicht garantiert ist. Die Höhe des Risikos hängt neben der Unternehmenskultur etwa auch davon ab, ob das Projekt eher Forschungscharakter hat oder aufgrund der Wettbewerbssituation als Schlüssel zur Zukunftssicherung gilt. Wir arbeiten dazu qualitative und quantitative Risikofaktoren für das jeweilige Innovationsthema heraus und bewerten sie nach Eintrittswahrscheinlichkeit und Ausmaß.

Der Nutzen für den Kunden muss immer wieder geprüft werden.

Transparente
Kommunikation

Die Wahrscheinlichkeit eines Erfolgs lässt sich messbar erhöhen, wenn während des gesamten Prozesses der Kundennutzen berücksichtigt wird. Denn eine Innovation ist erst dann erfolgreich, wenn sie von den Anwendern akzeptiert respektive angenommen wird. Wir kennen alle Geschichten, wie die der Firma Kodak, die in der Entwicklung der Digitalkamera technologisch führend war, den wahren Wert des Kundennutzen allerdings nicht erkannte. Oder erst jüngst die Ignoranz der deutschen Automobilindustrie gegenüber Tesla, das das Erlebnis des Autofahrens für die Nutzer neu definiert hat. Deshalb ist es so wichtig, in iterativen Schritten mithilfe immer neuer Prototypen den Nutzen der Innovation bei den Kunden zu überprüfen. Mit jedem Test gewinnen wir noch mehr wichtige Einsichten, die zeigen, welche Richtung die Entwicklung nehmen muss.

Neues erzeugt oft Widerstand in der eigenen Organisation. Dieser Faktor darf nicht unterschätzt werden. Wir plädieren daher für ein internes Innovationsmarketing. Je früher über die Innovation in den relevanten Unternehmensbereichen transparent berichtet wird, desto mehr bereiten wir den Boden vor, um mögliche Veränderungen im Unternehmen anstoßen zu können. Denn egal wie klein oder groß eine Innovation ist, erfolgreich umgesetzt ist sie der Anfang einer größeren Veränderung. Und Veränderung schürt immer auch Angst und Verunsicherung. Daher sollte sie als interner Change-Management-Prozess betrachtet werden.

2. Value Creation needs Resources needs Entrepreneurship

In dieser Phase wird der eigentliche Wert des Produkts oder der Dienstleistung entwickelt. Wir sehen sie als Herzstück einer jeden Innovation. Hohe Leistungsbereitschaft, intensive Auseinandersetzungen und schnelle Iterationen zwischen Ideenentwicklung und Validierung prägen die Arbeitsweise. Aus Erfahrung wissen wir, dass die klassische Hierarchie in Unternehmen für die Umsetzung von Neuem zu langsam ist. Damit die Entwicklung zum PoC funktioniert, muss die Organisation für die Innovationsbereiche entsprechend angepasst werden.

Innovationsteams brauchen Autonomie und Eigenverantwortung. Die Projektspensoren müssen beim Aufbau von Innovationsaktivitäten darauf achten, den entsprechenden Freiraum in der Organisation zu schaffen. Das kann etwa durch den Aufbau eigener Innovationslabore, Acceleratoren oder Hubs geschehen. Hier gibt es keine allgemeingültige Blaupause. Wichtig ist, dass die Innovationsteams dort Zeit, Ort und feste Mitstreiter vorfinden, um sich unabhängig vom Tagesgeschäft dem einen Innovationsziel widmen zu können.

Innovatoren brauchen Zugang zu wertvollen firmeninternen Ressourcen und einen unbürokratischen Zugriff auf externe Dienstleistungen. Wie häufig sahen wir das Momentum einer genialen Idee verloren gehen, weil Lokalfürsten ihr Wissen selbst kontrollieren wollten oder bei kurzfristiger Zuarbeit eines externen Spezialisten zuerst eine neue Lieferantennummer über den Einkauf erstellt werden musste. Ressourcen sind das Schmiermittel der Wertschöpfung.

Neue Regeln definieren

Radikale Innovationen brauchen aus unserer Erfahrung oft neue Spielregeln. Wer sich aufmacht, radikale Innovationen zu erschaffen, muss auch den Mut haben, das existierende Geschäft zu kannibalisieren, neue Kennzahlen zu etablieren oder die Befehlsketten für mehr Tempo zu entschlacken.

Innovation braucht Entrepreneur, denn nicht jeder taugt für Arbeiten unter Unsicherheit. In unseren Projekten erkennen wir immer wieder, wie wichtig die Fähigkeit von Teammitgliedern ist, Dinge gegen Widerstände auch selbständig zum Abschluss zu bringen. Es erfordert Mut und Kreativität, alleine einen Teil der Strecke zu gehen sowie Mittel und Wege zu finden, Hindernisse aus dem Weg zu räumen oder zu umgehen.

Innovation braucht Entrepreneur

Bei diesen Menschen schürt die Möglichkeit des Scheiterns keine Angst vor dem Versagen, sondern ist Grundlage für das Erweitern der eigenen Fähigkeiten – und die Basis für bessere künftige Projekte.

Erfolgreiche Innovation benötigt auch gute Logistik, Marketing, Kundensupport.

3. Value Capture is looking for Talent is looking for Speed

Wir haben unseren Prototyp getestet, den Proof of Concept erbracht – nun wird es ernst. Es soll ein massentaugliches Produkt oder eine skalierbare Dienstleistung entstehen. Die Innovation wird für das Unternehmen kommerzialisiert. Häufig scheitern Innovationen in dieser Phase. Während dem sogenannten Frontend of Innovation, also der Zeit von Idee bis Proof of Concept viel Raum gegeben wird, wird der Aufwand und Bedarf an Expertise im Backend of Innovation, der Umsetzung ins tägliche Geschäft bei entsprechender Skalierung, oft massiv unterschätzt.

Unternehmen, die das Backend of Innovation zu wenig beachten, setzen den Geschäftserfolg aufs Spiel. Ende 2017 hatten wir eine digitale Plattform mit einem internetfähigen Endgerät für einen Zulieferer des Lebensmitteleinzelhandels entwickelt. Die ersten Konsumententests waren ein gigantischer Erfolg. Doch die Geschäftsführung wollte auf Nummer sicher gehen und orderte für die Markteinführung nur einige zehntausend Geräte. Im Frühjahr 2018 waren innerhalb von zwei Stunden alle Geräte ausverkauft und die Sozialen Medien voller verärgelter Kunden, die keine Chance auf das massiv beworbene Produkt hatten.

Die Gefahren des Erfolgs

Der Erfolg traf unseren Kunden und seinen Hersteller in China völlig unerwartet und unvorbereitet. Eine Produktionsstraße für eine komplexe Innovation mit der nun ersichtlichen Kapazität aufzubauen erfordert viele Monate Vorarbeit. Selbst als zum Weihnachtsgeschäft desselben Jahres die nächste Charge geliefert wurde, reichte diese bei weitem nicht aus, um den Bedarf zu decken. Es dauerte nochmals mehr als 12 Monate, bis die Lieferkapazitäten ausreichten. Zeit, in denen sich Wettbewerber in Position bringen konnten.

Das Beispiel zeigt: Unternehmen haben viel mehr Angst, erfolglos zu sein, als sich auf die Gefahren eines enormen Erfolgs vorzubereiten. Deshalb empfehlen wir den Unternehmen bei jedem Projekt, bevor es zum Markteintritt kommt, zu prüfen, wie gut sie auf Erfolg vorbereitet sind. Wie schnell und in welchem Maße können die Produktion, die Logistik, die E-Commerce-Plattform oder der Kundendienst skalieren?

Neue Märkte erfordern häufig neue Kompetenzen. In einem anderen Projekt beauftragte uns ein weltweit agierendes Unternehmen, das Produkte für professionelle Handwerker vertreibt, ein neues Kundensegment zu erschließen. Unter Nutzung seiner Kerntechnologie sollte eine Innovation für die Kosmetikindustrie entstehen.

Der Prototyp war entwickelt, und die Tests mit Verbraucherinnen waren so aussagekräftig, dass die Mitarbeiter im Unternehmen regelrecht euphorisch reagierten. Das Unternehmen beherrschte alle Bereiche für eine skalierbare Massenproduktion, Qualitätssicherung und Logistik inklusive.

Neue Konzepte

Doch da es sich um ein Produkt für ein völlig neues Markt- und Kundensegment handelte, fehlte ihnen der Zugang und die Erfahrung, um es dort platzieren zu können. Zuerst versuchten sie, Vertriebspartner zu gewinnen. Sie suchten bekannte Markenartikelhersteller als Partner. Doch es fehlte ihnen an fachlicher Kompetenz. Schließlich gestanden sie sich ein: Unter dem bestehenden Dach würde diese Innovation kein Erfolg werden. Sie gründeten ein Corporate Start-up, stellten die erforderlichen Spezialisten ein und konnten unter der Führung des ehemaligen Projektleiters ein erfolgreiches Unternehmen aufbauen.

Größere Innovationsprojekte sollten von Anfang an systemisch betrachtet werden. Insbesondere, wenn neue Märkte, Kundengruppen oder Kerntechnologien erschlossen werden sollen, muss die gesamte Unternehmung sich mitentwickeln und neue Kompetenzen aufbauen können. Alternativ sollte frühzeitig über ein eigenes Start-up nachgedacht werden.

Innovative digitale Funktionen rechtzeitig planen und vorbereiten.

Digitalisierung erfordert rapide Weiterentwicklung. Für einen Freizeitartikelhersteller entwickelten wir ein internetfähiges Sportgerät. Es sollte durch kostenpflichtige Online-Dienstleistungen auch nach dem Verkauf des Gerätes Umsätze ermöglichen. Um die Organisation vor dem Marktstart nicht zu überlasten, entschied sich das Management, die anspruchsvollen Web-basierten Funktionen erst nach dem Marktstart fertigzustellen.

Digitale Produkte benötigen schnellere Innovationszyklen.

Die Sportgeräte verkauften sich wie erhofft. Doch als einige Monate später die Web-basierten Zusatzfunktionen freigeschaltet wurden, hatten viele Kunden die Wlan-Funktion am Gerät ausgeschaltet. In einer aufwendigen Kampagne mussten die Kunden dazu bewegt werden, die neuen Funktionen an Ihrem Gerät auszuprobieren. Damit rückten die neuen Erlösströme in weite Ferne.

Digitale Projekte gehorchen einem deutlich schnelleren Takt. Innovative digitale Funktionen sollten vor der Produkteinführung geplant und vorbereitet sein. Sie benötigen zudem kontinuierliche Weiterentwicklung, also schnelle Innovationszyklen, um ihr eigentliches Potenzial auszuschöpfen.



Vielfältiges Wissen

Die Beispiele zeigen, die Umsetzung und Skalierung von einem PoC zur Innovation erfordert von Menschen und Organisationen in den einzelnen Phasen sehr unterschiedliche Talente und Eigenschaften. Nicht nur Lieferketten und Industriestandards müssen beherrscht werden, auch der Vertrieb muss das geeignete Wissen und das relevante Netzwerk haben.

2. Ziele für AI definieren

Daten sind die
Grundlage für
Entscheidungen

Google (Alphabet) ist mit 1000 Milliarden US-Dollar höher kapitalisiert als alle deutschen Unternehmen im Leitindex DAX zusammen – und mehr als siebenmal mehr wert als das Schwergewicht SAP mit 135 Milliarden. Google stellt jedoch seine Produkte, wie die Suche, Google Maps sowie das mobile Betriebssystem Android, kostenlos zur Verfügung. Wie ist das möglich? Das funktioniert, weil das Geschäftsmodell nicht auf Produkten, sondern auf Daten basiert. Produkte sind hier nur das Mittel zum Zweck, um Daten generieren zu können.

Durch tiefe Kenntnisse über die Nutzung seiner Dienste verkauft Google Werbung, die sich präziser an die gewünschten Zielgruppen richtet, als das Print- oder TV-Medien leisten können. Verkehrsvorhersagen und Staunachrichten werden an Hersteller von Navigationssystemen verkauft, die es selbst versäumt haben, solche Daten in ihren Geräten zu sammeln und aufzubereiten. Durch Bewegungs- und Sprachdaten werden im Hintergrund AI-Anwendungen mit Daten versorgt, um etwa Personas mit hoher Präzision zu erstellen oder Sprachmodelle für ChatBots zu trainieren.

Google ist ein datengetriebenes Unternehmen. Das Geschäftsmodell basiert auf Daten. Die Unternehmensentscheidungen basieren auf präzisen Daten und Vorhersagen, selbst über Bewerbungen und Jobchancen entscheidet ein AI-System mit.

So weit sind wir noch nicht. Wir wollen erst einmal sicher landen. Im Kapitel «Springen» haben wir gelernt, wie wir den AI Planner differenziert anwenden und entsprechende AI-Konzepte entwickeln können. Nun kommt der nächste Schritt. Wir schauen uns an, wie aus AI-Konzepten echte Anwendungen, Produkte oder Dienstleistungen werden. Dazu müssen wir einige sehr unterschiedliche Aspekte betrachten. Wir lernen, wie ein Unternehmen Schritt für Schritt AI-ready wird. Dazu gehören Themen, wie der richtige Umgang mit Daten, der besondere Ablauf von AI-Projekten, die Suche nach Partnern und die geeigneten Rahmenbedingungen für den Einsatz von Künstlicher Intelligenz. Auch Fragen der Ethik und der Expertise sowie die Organisationsform müssen berücksichtigt werden. Wer all dies beachtet, hat die Chance, sich wie Google zu einem datengetriebenen Unternehmen zu entwickeln.

Anwendungsfälle für AI identifizieren

Ähnlichkeiten in Daten finden

Jede Maschine von John Deere weiß heute, wann sie gepflügt hat, wann gedüngt wurde und wie viel Dünger verwendet wurde.

Konkrete Anwendungsfälle für den Einsatz von AI ausfindig zu machen, fällt den meisten Unternehmen nicht schwer. Mangels Erfahrung passieren aber häufig viele Fehler. Manche Ideen beruhen auf Wunschdenken, die notwendige Datenbasis existiert nicht oder neue Möglichkeiten der AI werden missachtet. Ein häufiger Fallstrick ist es außerdem, Abläufe einfach nur schneller machen zu wollen. Die notwendige grundsätzliche Betrachtung der Mensch-Maschine-Interaktion wird in den meisten Unternehmen vernachlässigt.

Wer nach Anwendungsfällen sucht, sollte im Blick behalten, dass AI-Modelle nicht darauf beschränkt sind, sich wiederholende Aufgaben zu übernehmen, um den Menschen zu entlasten. Die neue Technologie ermöglicht es auch, genauere Entscheidungen zu treffen; ihre Stärke liegt dabei in der Fähigkeit zu Vorhersagen, Klassifizierungen und Clusteranalysen, also dem Auffinden von Ähnlichkeiten in Daten. So sind Anwendungen möglich, die für den Menschen kognitiv nicht leistbar sind, zum Beispiel Tausende von Bildern oder Stunden von Videomaterial durchforsten oder Krankheiten in den Tonaufnahmen von hustenden Menschen erkennen.

Projektverantwortliche sollten immer die ganze Palette der Machine-Learning-Fähigkeiten im Blick behalten (siehe «AI Skill Navigator», Seite 90). Auch die Analyse existierender Fallbeispiele hilft, die Vorstellungskraft für potenzielle Anwendungsgebiete zu trainieren. Denn die Möglichkeiten der schnellen Wiederholung von Vorgängen, der Prognose und Mustererkennung in Daten sowie die enorm hohe Analysegeschwindigkeit ermöglichen sehr leistungsstarke und oft unkonventionelle Lösungsansätze für Probleme.

Welches Potenzial darin liegt, zeigt die Geschichte des US-amerikanischen Traktorherstellers John Deere. Dessen Mitarbeiter haben sehr früh schon überlegt, wie digitale Technik landwirtschaftliche Maschinen verbessern könnte. Anstatt auf herkömmliche Fälle in der Produktion oder Prozessautomatisierung zu setzen, hat man den Traktoren Sensoren hinzugefügt. Jede Maschine von John Deere weiß heute, wann sie gepflügt hat, wann gedüngt wurde und wie viel Dünger und Pflanzenschutzmittel an welchem Ort verwendet wurde. Die Landwirte können weitere Informationen hinzufügen,

zum Beispiel, welche Getreidesorte sie gerade ausbringen. Die Sensoren messen auch die Bodenbeschaffenheit oder den Zustand der Pflanzen und verknüpfen diese Daten mit Informationen zu Wetter und Fruchtfolge sowie mit einer landwirtschaftlichen Wissensdatenbank.

Ein neues Geschäftsmodell

Die Landwirte haben dadurch erhebliche Vorteile: Durch die Steuerung und Auswertung mithilfe lernender Algorithmen können sie den Einsatz von Pflanzenschutzmitteln reduzieren, das Wachstum der Pflanzen in Abhängigkeit vom Wetter genauer unterstützen und so den Ertrag erhöhen. Der Mehrwert für das Unternehmen wird dabei auf unterschiedlichen Ebenen erzielt:

John Deere änderte das **Geschäftsmodell** vom Verkauf von Maschinen hin zum Verkauf von kontinuierlichen Leistungen.

Der Kunde bezahlt für diese **Leistungen**, weil ihm das hilft, seinerseits Kosten für Dünger, Pflanzenschutzmittel und Wasser zu reduzieren.

Der Einsatz von AI-Modellen für automatisierte **Entscheidungen** kann daher dazu führen, dass sich Geschäftsmodelle verändern.

Im Zentrum einer Vision für das, was sich mit AI im Unternehmen erreichen lässt, steht die Grunderkenntnis, dass Daten als Rohstoff zu betrachten sind. Dieser Rohstoff kann zu unterschiedlichen Ergebnissen führen. Dazu teilen wir das Potenzial von Künstlicher Intelligenz in drei Kategorien ein.

1. **Optimierung (schneller): Ein bestehender Prozess wird durch Einsatz von Technologie verbessert. Das geschieht in der Regel durch Analysen, Frühwarnsysteme und Automatisierung.** Dank RFID-Technologie und Analytics-Modellen bei Walmart können Lieferkettenmanager die Produktgruppen identifizieren, die am meisten Kosten verursachen, und anhand von Korrelationsanalysen präzise den Bedarf planen und Materialflüsse steuern. Auch die Planung der Warenströme anhand von saisonalen Daten ist automatisiert, und so entscheidet ein AI-System, was morgen oder nächste Woche in den Regalen stehen muss. Dabei werden sogar

AI hat das Potenzial, Bestehendes zu verbessern, es zu ersetzen oder gänzlich neue Wege für eine Lösung zu finden.

Wertschöpfung mit AI bedeutet: Menschen bekommen Werkzeuge an die Hand, die kognitive Fähigkeiten simulieren.

Kurzzeitdaten, wie Wetter oder besondere Events, zum Beispiel Footballspiele, beachtet. Für die Kunden ist das ein großer Vorteil, denn sie können sich darauf verlassen, die gewünschten Waren zu bekommen – selbst im Einkaufstrubel vor Thanksgiving oder Weihnachten.

2. **Transformation (anders): Etwas bereits Existierendes wird durch den Einsatz von neuer Technologie ersetzt (E-Mail statt Fax, PDF statt Brief, Chatbot statt Callcenter oder eben AI-gesteuerte Roboter statt Menschen).** Magna Steyr ist durch die konsequente Entwicklung einer Datenstrategie für Produktion und Logistik der erste Fahrzeugauftragsfertiger, der eine breite Palette von Antriebstechnologien in einem Werk fertigt. Vom konventionellen Antrieb über Plug-in-Hybrid bis zum rein elektrischen Fahrzeug – zum Teil auf der selben Produktionslinie und auch für verschiedene Hersteller. Auftragsvorbereitung und Produktion sind durch Robotik und Einsatz von AI hochautomatisiert, und Magna Steyr erreicht so einen einzigartigen Kosten- und Wettbewerbsvorteil.
3. **Innovation (neu): Einen völlig neuen Ansatz wählen, um Ziele oder Wettbewerbsvorteile zu erreichen.** Der Lehrstuhl für Embedded Intelligence for Health Care an der Universität Augsburg forscht an der sensor- und wissensbasierten Begleitung und Überprüfung aller gesundheitsrelevanten Parameter bei sportlichen Aktivitäten. Mit der Pandemie hat sich dieses Forschungsfeld verändert. Neues Ziel: Eine Anwendung für Jedermann auf der Basis der Smartphone-Technologie zu entwickeln, um eine Covid-19-Infektion berührungslos, in Echtzeit und sogar auf Distanz zu erkennen. Aufwendige Abstrichuntersuchungen im Labor werden durch Stimmanalyse ersetzt.

Diese drei Kategorien sollten immer berücksichtigt werden, wenn über die mögliche Wertschöpfung durch AI im geschäftlichen Kontext nachgedacht wird. Im Mittelpunkt steht dabei die Interaktion von Menschen mit Werkzeugen, die kognitive Fähigkeiten simulieren und dabei unterstützen, Entscheidungen zu treffen oder dabei autark agieren.

Jedes Unternehmen beginnt seinen Weg in die AI-Welt anders.

Die folgenden Abschnitte dienen einem besseren Verständnis der Grundlagen und praktikable Vorgehensweisen, der sinnvollen Methoden und einfachen Instrumente, um den Einsatz von AI zu bewältigen. Wie weit Unternehmen beim Einsatz von AI gehen, ist sehr unterschiedlich. Man kann mit vergleichsweise geringem Aufwand einzelne Produkte verbessern oder interne Aufgaben automatisieren, wie zum Beispiel das Übersetzen von Texten. Dafür ist keine AI-Strategie notwendig. Es können größere Projekte mithilfe von AI-Modellen umgesetzt werden. Dafür sind vielleicht bereits Partner nötig oder das Einstellen qualifizierter Mitarbeiter. Oder das Unternehmen soll grundsätzlich auf breiter Ebene AI einsetzen – dann müssen viele unterschiedliche Aspekte betrachtet werden – von der Governance über Fragen der Ethik bis zur Umorganisation des Unternehmens.

Klein anfangen

Alle Elemente zusammengekommen weisen den Weg zur Verankerung einer AI-Strategie in einem datengetriebenen Unternehmen. Dabei haben wir versucht, so viele Schritte und Fallstricke wie möglich zu betrachten – trotzdem darf man das Kapitel nicht als Schritt-für-Schritt-Anleitung sehen. Jedes Unternehmen beginnt seinen Weg in die AI-Welt anders und mit anderen Voraussetzungen. Die klare Empfehlung ist, klein anzufangen, um Erfahrungen zu sammeln, und dann über das weitere Vorgehen zu entscheiden.

3. Daten richtig nutzen

Daten prüfen oder beschaffen

Mithilfe des AI Skill Navigators haben wir in der Data Journey Map unsere Datenquellen mit den passenden Maschinenfähigkeiten in Verbindung gebracht. Erst diese Verknüpfung ermöglicht es, die benötigten Informationen aus den Daten zu gewinnen. In der AI-Sprache wird es «Datenmodell» genannt.

Daten sind die Grundlage jeder AI-Anwendung. Wie umfassend sich ein Projektteam damit beschäftigt, hängt davon ab, wie erfahren es ist – und welche Ziele mit dem Einsatz von AI im Unternehmen verfolgt werden. Im ersten Projekt wird die Datenaufbereitung oder -generierung erst einmal nur für diese eine Aufgabe durchgeführt, um daraus zu lernen. Macht man weiter mit AI, benötigt man eine Datenstrategie – dafür bereitet dieser Abschnitt vor.

Trainieren können wir ein AI-Modell erst, wenn genügend Daten in ausreichender Qualität vorliegen. Die Datenerhebung ist nicht trivial, da Daten durch verschiedene Systeme in vielfältiger Weise abgelegt werden und man manche Systeme, beispielsweise ältere Produktionsanlagen, erst einmal dazu befähigen muss, Daten zu senden, etwa durch das Nachrüsten mit Sensoren.

Auch wenn ein Projektteam oder Unternehmen bereits über die notwendigen Daten verfügt, heißt es nicht, dass das Datenproblem gelöst ist. Oft liegen die Daten der verschiedenen Systeme ungeordnet vor und sind verteilt auf den Computern einzelner Mitarbeiter, auf Servern von Abteilungen oder Geschäftspartnern.

Interne Recherche

Damit Daten grundsätzlich von AI-Modellen genutzt werden können, müssen wir klären, welche Datenquellen dem Unternehmen zur Verfügung stehen, wie die Datenquellen angezapft werden können, wie sich unterschiedliche Daten zusammenführen und wie sich die Daten bereinigen lassen. Wichtig ist, vorher zu definieren, welche Ziele des Projekts oder des Unternehmens durch das Sammeln von Daten erreicht werden sollen.

Data-Science-Projekte versus Machine- Learning-Projekte

Daher definieren wir für unser erstes Projekt zunächst die Art der AI-Nutzung. Sollen relevantes Wissen und wichtige Erkenntnisse aus Daten extrahiert und interpretiert werden, um zum Beispiel eine medizinische Diagnose zu erstellen, sprechen wir von Data Science. Geht es dagegen darum, dass ein Computer etwas lernt, ohne es einprogrammiert zu bekommen, wie ein autonom handelnder Roboter oder ein autonomes Auto, sprechen wir von Machine Learning.

Beide Disziplinen gehen Hand in Hand. Die Ergebnisse sind sehr unterschiedlich, und es werden unterschiedliche Fähigkeiten gebraucht (siehe «Menschen und Organisation» auf Seite 291). Data-Science-Projekte generieren in der Regel Informationen in Form von Berichten, statistischen Grafiken oder Heatmaps zur Visualisierung von Daten, aus denen Erkenntnisse oder Entscheidungen abgeleitet werden. Machine-Learning-Projekte dagegen enthalten in der Regel eine Software als Ergebnis. Sie kann eine Entscheidung treffen oder eine Empfehlung abgeben.

Zusammenhänge aufdecken

Ein Beispiel: Analysiert man Hauspreise verschiedener Regionen, deckt ein Data-Science-Projekt bereits existierende Zusammenhänge auf: Dass Häuser mit drei Schlafzimmern teurer sind als Häuser mit zwei Schlafzimmern bei gleicher Fläche und dass das entscheidende Kaufargument bei Häusern mit drei Zimmern ein Tiefgaragenplatz, bei zwei Zimmern aber die Erreichbarkeit öffentlicher Verkehrsmittel zu Fuß ist.

Prognosen erstellen

Dagegen liefert ein ML-Tool eine Prognose. Basierend auf Angaben zu Fläche, Anzahl der Schlafzimmer, Anzahl der Badezimmer und ob das Haus in den vergangenen drei Jahren renoviert wurde, hat es gelernt, abzuschätzen wie viel das Haus wert ist und wie sich dieser Wert entwickeln wird.

Rückblick 1: Schulbeispiel

Für unser Schulbeispiel aus dem Kapitel «Einsteigen» beginnen wir mit einem Data-Science-Projekt, da wir nicht die Unfallquote und -wahrscheinlichkeit berechnen wollen, sondern erst zeigen müssen, dass es vor Schulen (Adresse und Umkreis) zu bestimmten Zeiten (Datum und Zeit mit Berücksichtigung von Ferienzeiten der Bundesländer) zu Staus kommt (Verkehrsdaten) und zu Unfällen (Unfallberichte). Selbst Wetter- oder Saisondaten (Regen, Winter) könnte man noch betrachten.

Die Verbindung zwischen den Variablen (Korrelation) belegen wir durch statistische Wahrscheinlichkeiten (keine Unfälle in Ferienzeiten) oder wir widerlegen eine in die Irre führende Kausalität (also eine zufällige Verbindung der Variablen) durch das Herausfiltern von Aussagen zum Schulweg in den Unfallberichten und Meldungen. Machine Learning benötigen wir hier eventuell, um den Prozess des Auslesens von Unfallberichten zu automatisieren.

Daten verwalten

Sowohl Data Lake als auch Data Warehouse sind etablierte Begriffe, wenn es um das Speichern von Big Data geht. Wir benötigen in der Regel ein grundlegendes Verständnis ihrer Funktionsweise. Im Abschnitt «AI als Strategie» auf Seite 300 gehen wir dann etwas mehr in die Tiefe.

Big Data bezeichnet allgemein das Zusammenführen von großen Datenmengen. Daten existieren an vielen unterschiedlichen Orten und unterscheiden sich durch ihre Größe, Komplexität, Schnelllebigkeit und Strukturierung. All diese Daten werden durch Beschreibungen miteinander in Beziehung gesetzt, damit sie für eine Abfrage überhaupt erst sichtbar werden. Sobald der Zugriff auf große Datenmengen auf diese Weise systematisiert ist, entsteht ein Data Lake oder ein Data Warehouse, das hängt davon ab, wie umfassend die Katalogisierung durchgeführt wird.

Data Lake

Ein Data Lake ist ein großer Pool mit Rohdaten (zum Beispiel Bilder ohne Tags), für die noch nicht festgelegt ist wie sie verwendet werden sollen. Vergleichbar ist das mit einem automatisierten Warenlager. Dort werden die Pakete so abgelegt, dass sie schnell verfügbar sind und möglichst wenig Platz verschwendet wird. Der Vorteil: Hier kann alles abgelegt werden, was noch keinen klaren Zweck hat und unstrukturiert vorliegt – zum Beispiel Videos.

Ein Data Warehouse organisiert Daten wie ein Supermarkt: Sauber nach Kategorien.

Data Warehouse

Bei einem Data Warehouse werden Daten organisiert und gefiltert (zum Beispiel Bilder mit Metadaten, wie Aufnahmeort, Kategorie, Beschreibung). Sie sind bereits für einen bestimmten Zweck verarbeitet worden. Sie entsprechen eher einem Supermarktregal, wo klar nach Backwaren und Gemüsekonserven sortiert wird.

Beide dienen unterschiedlichen Zwecken und brauchen unterschiedliche Spezialisten (siehe Abschnitt «Menschen und Organisation» auf Seite 291), um sie richtig einzusetzen. Für manche Unternehmen eignet sich eher ein Data Lake, wenn zum Beispiel viele unstrukturierte Daten aufbereitet werden müssen. Für andere dagegen passt ein Data Warehouse, wenn es darum geht, bereits gefilterte, strukturierte Daten weiterzuverarbeiten. Beides lässt sich natürlich auch gemeinsam nutzen, wo das sinnvoll ist.

Rückblick 2: Schulbeispiel

Für unser Schulbeispiel würden wir einen «Mini» Data Lake generieren. Denn wir haben eine Menge unstrukturierter Daten, wie zum Beispiel Unfallberichte, und wir müssen ein AI-Modell trainieren, damit es die benötigten Aussagen filtert. Die AI-Fähigkeiten haben wir im «AI Skill Navigator» definiert, in der Projektphase entwickelt ein Data Analyst das passende Modell (siehe «AI-Projekte sind anders» auf Seite 260).

Um spezifische Informationen aus Datensätzen zu gewinnen, gibt es unterschiedliche Möglichkeiten. Mithilfe sogenannter Kategorieklassifizierungsmodelle kann ein Data Analyst zum Beispiel die Quellen der Daten einordnen, diese nach Erkenntnissen durchsuchen und sortieren.

Um konkrete Sätze oder Satzabschnitte («vor der ... Schule») zum Beispiel aus Unfallberichten zu identifizieren und zu katalogisieren, wird ein weiteres AI-Modell benötigt (Entitätsextraktion). Es wandelt unstrukturierte Daten in maschinenlesbare Daten um. Auf diese Weise können sie mit anderen strukturierten Daten, wie zum Beispiel einer Postleitzahl als Angabe für einen Ort, verknüpft werden.

Beide Modelle werden auch genutzt, um Daten zu «taggen» und zu bereinigen, also auf Vollständigkeit, Duplikate, Besonderheiten oder auch unnötigen Ballast zu prüfen.



Die Basis für das Fachgespräch

Die Vorbereitungen aus der Data Journey Map und dem Skill Navigator helfen, die konkreten Aufgaben mit einem Data Analysten zu besprechen. Hat man in seinem Unternehmen noch keinen Data Analysten oder ML Engineer, nutzt man seinen «Sprungtrainer», um hier sicher zu landen. Dies kann ein Partnerunternehmen oder Netzwerk sein, wie im Abschnitt «Partner» auf Seite 272 beschrieben. Das gleiche gilt für Entwicklungswerkzeuge, bestehende Datenmodelle oder Betriebskonzepte.

4. AI-Projekte sind anders

Wie AI-Systeme zu Lösungen kommen, bleibt oft im Verborgenen.

Daten über Daten

In der Nacht des 18. März 2018 schob Elaine Herzberg ihr mit Gepäck beladenes Fahrrad über die vierspurige Mill Avenue in Tempe, Arizona. Sie trug ein schwarzes Oberteil und überquerte die nur spärlich befahrene Straße abseits des Zebrastreifens. In diesem Augenblick näherte sich ein Wagen, gesteuert von einem Computer. Die Algorithmen des selbstfahrenden Testautos von Uber, das genau auf Herzberg zu fuhr, konnten ihre Silhouette nicht genau identifizieren. Der Wagen überfuhr die 49-jährige ungebremst.

Hätte der Wagen gebremst, hätte vermutlich nie jemand gefragt, wie die Algorithmen des autonomen Fahrzeugs zu ihrem Ergebnis gekommen waren. So aber drängen sich zahlreiche Fragen förmlich auf. Warum wird nicht bei jeder Art von Objekt gebremst? Wurde das farblich und von der Form ungewöhnliche Objekt als Hintergrunderscheinung klassifiziert? Das Problem ist: Man weiß es nicht.

Denn moderne Machine-Learning-Algorithmen gleichen einer Blackbox. Sie folgen nicht mehr vorgegebenen Regeln, wie konventionelle Computerprogramme. Stattdessen erzeugen sie selbständig aus Daten ein komplexes Entscheidungsmodell. Wie das Modell konkret aussieht, kann der Mensch allenfalls indirekt beeinflussen. Der Mensch kann es mit Daten anlernen und mit anderen Daten testen, ob die Entscheidungen richtig sind. Sind sie es nicht, wird der Lernprozess mit neuen Daten fortgesetzt. Wie der Lösungsweg zustande kommt, bleibt dabei im Verborgenen. Umfangreiche Projekte benötigen sehr viele dieser Kontrollschleifen. Manche AI-Projekte, dazu zählt das autonome Fahren, benötigen so unfassbar viele Daten, dass nach Millionen gefahrener Kilometer immer noch neue, unvorhergesehene Situationen auftreten. Fehlentscheidungen sind die Folge.

Der Fall Herzberg zeigt, dass AI-Projekte anders als konventionelle IT-Projekte sind. Um das besser verstehen zu können, müssen wir hinter die Kulissen einer AI schauen. Im Wesentlichen unterscheiden sich AI-Projekte in den folgenden Aspekten:

Hinter den Kulissen

Weil AI-Modelle autark lernen und entscheiden können, sind Ergebnisse schlechter planbar als bei anderen Projekten.

1. **Ohne gute Daten kein Lernen:** Daten für AI-Projekte müssen eindeutig sein und in guter Qualität vorliegen oder sogar erst generiert werden. Wie hoch die Datenqualität tatsächlich ist, ist bei der Projektidee oder Planung meistens noch unbekannt.
2. **AI-Modelle können selbständig entscheiden:** AI-Anwendungen ziehen ihre Rückschlüsse aus Daten selbst, ähnlich wie der Mensch. Auf Basis der gelernten Daten werden Entscheidungen getroffen. Das Ergebnis der Entscheidung ist sichtbar, die Grundlage der Entscheidung hingegen bleibt im Verborgenen. Das wird auch als «Blackbox-Effekt» bezeichnet.
3. **AI-Algorithmen können sich selbst weiterentwickeln:** Programme lernen durch neue Daten ständig weiter – das heißt, das Ergebnis ändert sich, sie passen sich selbständig an – auch diese Entwicklung bleibt im Verborgenen und erfordert eine besondere Updatestrategie.
4. **Konsequenzen sind häufig nicht konkret vorhersehbar:** Da die Entscheidungswege einer AI nicht transparent sind und durch neue Daten verändert werden können, benötigt es eine besonders gute Qualitätskontrolle und bei selbstlernenden Systemen ein Risikomanagement. Maschinen können ansonsten in vorhandenen Daten versteckte Vorurteile übernehmen und zum Beispiel nur weiße Männer zu Vorstellungsgesprächen einladen.
5. **Die Dauer eines AI-Projekts kann ungewiss sein:** Während es in jedem IT-Projekt Gründe für Verzögerungen geben kann, ist die Dauer und Leistung von AI-Projekten in der Regel nur schwer vorhersagbar. Dies ist immer dann so, wenn man nicht auf etablierte Algorithmen, Modelle oder Datensätze zurückgreifen kann und gilt im Besonderen für selbstlernende Modelle.
6. Traditionellen IT-Projekten mangelt es an **Akzeptanz bei den Nutzern**, wenn die neue Software deren Arbeitsweise ändert, liebgewonnene Gewohnheiten über den Haufen wirft, zu

langsam oder schlecht bedienbar ist. Das ist bei AI-Projekten nicht anders. Aber: Hier leidet die Akzeptanz auch, wenn die AI zu gut funktioniert. Entscheidungen einer Maschine zu akzeptieren, fällt Menschen schwer. Die Mensch-Maschine-Interaktion darf daher nicht zu sehr vermenschlicht werden, und durch eine zu gut funktionierende Automatisierung fühlen sich Mitarbeiter irrational bedroht (diese Besonderheit von AI-Systemen wird auch als «Uncanny Valley» bezeichnet).

Vom AI Planner zum Konzept

Die aufgeführten Besonderheiten führen dazu, dass AI-Projekte in manchen Punkten anders umgesetzt werden müssen, als es Manager und Projektleiter von IT-Projekten gewohnt sind. Die Arbeit mit dem AI Planner liefert uns als Ergebnis ein Konzept. Dieses gibt uns eine erste Orientierung über Inhalte, wie das Daten- und Lernmodell sowie den Mehrwert. Dann beginnt die eigentliche Arbeit. Um mit den Besonderheiten von AI-Anwendungen umzugehen, planen wir das Projekt in iterativen Schritten und mit sogenannten Stopp-Punkten. An diesen Stellen überprüfen wir, ob der erwartete Mehrwert sich noch bestätigt, und entscheiden, ob das Projekt fortgesetzt wird.

Ein beispielhafter Projektablauf

Wie ein Projekt konkret ablaufen könnte und welche Prüf- oder Stopp-Punkte es gibt, haben wir anhand unseres Schulbeispiels gezeigt. Kurzer Blick zurück: AI soll in diesem Fall unserem Designteam helfen, ein Fahrzeugdesign für ein autonomes Schulshuttle in kürzerer Zeit und zielgerichteter zu entwickeln. Dabei könnte ihnen beispielsweise ein 3-D-Auto-design-Konfigurator helfen. Unser Ausgangspunkt ist das AI-Konzept, das wir mit dem AI Planner ausgearbeitet haben. Wir haben bereits die Idee entwickelt, Datenquellen identifiziert und in eine Data Checklist überführt; wir haben die unserer Idee entsprechenden AI Fähigkeiten im «AI Skill Navigator» zugeordnet und die Mindestleistung des Modelles definiert, damit die Anwendung einen Mehrwert bringt. Das Ergebnis des AI Planners liefert die Grundlage für die Entscheidung, einen Prototyp zu entwickeln. Dieser Schritt folgt bei AI-Projekten grundsätzlich auf das Konzept.

Phase 1: Prototyp

Ziel des Prototyps ist, die Voraussetzungen des Projekts möglichst genau zu klären und Fragen gezielt beantworten zu können. Vor allem muss das konkrete Ziel definiert und die Datenqualität genauer untersucht werden. Teure Arbeiten, wie die Programmierung oder das Anlernen eines AI-Modells, sollten in dieser Phase noch vermieden werden. Jeder Arbeitsschritt in die falsche Richtung kostet viel Geld. Der Prototyp hilft, die richtige Richtung zu finden und prinzipiell zu klären, ob die Anwendung tatsächlich den erhofften Nutzen erbringen kann und mit den verfügbaren Daten herstellbar ist.

Für unsere Projektidee des Autodesign-Konfigurators werden die in der Data Journey Map besprochenen Abläufe mit Data-Analysten besprochen.

**Erst das Ziel definieren,
dann die Datenqualität
analysieren.**

Es lohnt sich, die Vorstellung vom Output der AI bereits jetzt mithilfe eines User-Experience-Experten für das Design von Benutzeroberflächen genauer auszuarbeiten (UX-Designer – siehe auch «Menschen und Organisation» auf Seite 291). Das Ergebnis zeigt genau, wie die späteren Nutzer mit dem Programm umgehen, und welches Ergebnis sie erwarten. Das könnten 3-D-Darstellungen sein, deren Design die Autodesigner mit Schiebereglern verändern können. Dazu zeigt es relevante Fahrzeugdaten, wie zum Beispiel den Strömungswiderstand (CW-Wert), für die jeweilige Konfiguration an.

Die Daten-Analysten können auf dieser Basis die Veränderung der Schieberegler in einem Logikdiagramm den entsprechenden Datenquellen zuordnen. Wichtige Parameter, wie ein bestimmter Strömungswiderstand (CW-Wert), würden die Analysten ebenso beachten. Der Wert würde dafür sorgen, dass das Design nicht zu eckig wird.

Da im Unternehmen bereits umfangreiche Konstruktionsdaten bis hin zu 3-D-Modellen vorhanden und sie auch detailliert aufbereitet sind, schätzen die Data Analysten die Datenqualität als sehr gut ein und geben grünes Licht für den nächsten Schritt: die Nutzung durch AI-Modelle. Zusätzliche Daten müssen nicht generiert werden.

Das Nutzungskonzept des UX-Experten und das Logikdiagramm des Data Analysten liefern nun die Basis für den letzten Schritt des Prototyps: die Einschätzung der Machbarkeit durch Machine Learning Engineers.

Machbarkeit analysieren

Der Prototyp existiert bisher nur als visualisierte Vorlage, als Logikdiagramm und als Prüfung durch einen Machine-Learning-Experten. Mit relativ geringem Zeit- und Kostenaufwand können wir auf diese Weise erkennen, ob die Anwendung machbar ist, und können nun Projektumfang und Dauer deutlich besser einschätzen als noch in der Konzeptphase. Der ML Engineer kann sogar eine erste Prognose abgeben, ob auf bestehende AI-Modelle auf dem Markt zurückgegriffen werden kann. Das wird dann im nächsten Schritt verifiziert.

Der fertige Prototyp ist also der erste kritische Stopp-Punkt. In unserem Fall ist ein AI-Modell aus vorhandenen und qualitativen Daten möglich, das Team schätzt den Aufwand für einen Proof of Concept auf zwei Monate. Die Stakeholder geben die Proof-of-Concept-Phase frei.

AI-Entwicklung benötigt Iteration. An Prüfpunkten wird hinterfragt: Sind wir auf dem richtigen Weg? Machen wir weiter oder ändern wir die Richtung?

Phase 2: Proof of Concept (PoC)

Auch die PoC-Phase beginnt nicht gleich mit der Programmierung oder dem Trainieren eines AI-Modells. In dieser Phase prüfen wir, ob es fertige AI-Modelle gibt, die wir für unsere Zwecke nutzen können, ob wir sie erweitern oder ob sie sogar neu erstellt werden müssen. Außerdem müssen wir uns Gedanken über Aspekte, wie den Grad der Autonomie und die Fehlertoleranz machen. Das heißt, es wird definiert, ob die Anwendung selbst weiterlernen soll, ob die Entscheidungswege transparent sein müssen, ob Besonderheiten in der Benutzerakzeptanz Beachtung finden müssen und in welcher Form mit Fehlern im Algorithmus umgegangen werden muss. Gehen wir es an.

Welches AI-Modell ist das richtige?

Für einen Proof of Concept nutzen Machine-Learning-Experten eine abgespeckte Version der echten Daten und testen den geplanten Ansatz zunächst mit schon existierenden Machine-Learning-Modellen (siehe «Einsteigen – Lernkonzept erstellen» auf Seite 84).

Für Aufgaben, wie die Klassifikation von Produktbildern, das Vorlesen von Texten, das Transkribieren von Sprache, aber auch das Manipulieren von 3-D-Darstellungen, gibt es verfügbare AI-Modelle. Und Jahr für Jahr kommen mehr solcher fertigen Modelle (sogenannte Boilerplates) hinzu. Inzwischen muss nicht einmal mehr eigene AI-Hardwaretechnologie gekauft werden – all dies lässt sich in der Cloud buchen.


Wie autonom darf das AI-Modell entscheiden?

Beim Design von AI-Systemen müssen wir uns um das Zusammenspiel zwischen Mensch und Maschine Gedanken machen – wie viel entscheidet die Maschine selbst, und wie wird der Mensch dabei eingebunden? Einen ersten Anhaltspunkt gibt es in der Betrachtung der «Super Powers», also der kognitiven Ausprägungen und Unterschiede zwischen Mensch und Maschine (siehe «Einsteigen – AI-Mehrwert» auf Seite 50). Die dort aufgelisteten «Super Powers» helfen uns, eine erste Einstufung vorzunehmen und zu entscheiden, wo es sinnvoller ist, den Schwerpunkt auf die Fähigkeiten des Menschen und wo auf die Maschine zu legen.

Stufen der Automation

Das Schema ordnet das Zusammenspiel zwischen Mensch und Maschine nach dem Grad der maschinellen Autonomie.

Für den Grad der Autonomie gibt es in der AI-Welt eine Einordnung in «Stufen der Automation». Jede einzelne Stufe der



Automation beschreibt, wie genau eine Aufgabe zwischen Mensch und Maschine aufgeteilt würde. Die Kombination relativer kognitiver Stärken des Menschen mit der von Maschinen führt so zur besten Art der Automation des Entscheidens. Dies hilft, kognitive Fehlschlüsse zu vermeiden, wie sie durch vorschnelles Denken oder Vorprägungen (Bias) jedem passieren können.

Transparenz

Menschen tun sich schwer, Entscheidungen einer AI zu akzeptieren, wenn sie diese nicht nachvollziehen können. Je mehr Vertrauen zu einer Anwendung notwendig ist, also je wichtiger und autonomer die Entscheidungen sind, desto transparenter muss die Anwendung werden. Je mehr Kontrolle der Mensch über den Arbeitsfluss hat – wenn die AI also eher assistiert –, desto weniger wichtig wird die Transparenz.

In unserer Designanwendung wird im Workshop definiert, dass die Entscheidungswege des Modells nicht transparent sein müssen, da diese durch die Schieberegler verändert und vom Designer jeweils im Ergebnis überprüft werden können. Transparent dargestellt werden sollen die Ergebnisse der technischen Werte, wie der CW-Wert und seine wichtigsten Berechnungsparameter. Dies hilft dem Designer, an den richtigen Stellschrauben zu drehen.

Akzeptanz

Nur wenn Menschen darauf vertrauen können, dass die Entscheidungen und Ergebnisse von AI-Systemen gut und verlässlich sind, bauen sie Vertrauen auf und nutzen die entsprechenden Produkte und Dienste. Kein Mensch würde sein Schicksal selbstfahrenden Autos oder kollaborativen Robotern anvertrauen, wenn deren Algorithmen intransparente und mitunter sogar falsche Entscheidungen fällen, oder es keine Möglichkeit gibt, sie vorher zu prüfen. Transparenz führt zu Vertrauen bei den Benutzern.

Transparenz führt zu Vertrauen bei den Nutzern.

Wie in herkömmlichen Produkten muss die Frage der Akzeptanz auch von den Produktdesignern, also Service/UI/UX, beachtet werden. Vor allem in der Mensch-Maschine-Interaktion ist das ein besonders wichtiger Aspekt.

Schließlich spielt auch die Akzeptanz durch Automatisierung eine Rolle. Je höher der Automatisierungsgrad, desto eher sehen Mitarbeiter in der AI einen Konkurrenten um den Arbeitsplatz. Mitarbeiter könnten es unterlassen, die Anwendung zu nutzen oder selbstlernende Systeme sogar manipulieren. Hierfür sind klare Ziele und eine transparente Kommunikation notwendig.

Wie autonom soll das
AI-Modell lernen?

AI-Systeme sind grundsätzlich in der Lage, ständig weiterzulernen. Das ist etwas sehr Positives, es definiert ein AI-System. Diese Stärke kann es voll ausspielen, weil Datenbestände heutzutage immer schneller aktualisiert werden. Im Wechselspiel mit den Daten lernen Algorithmen permanent dazu und erlauben immer genauere Ergebnisse. Das AI-System passt sich an – an die Daten oder auch an den Benutzer.

Neue Daten,
neues Lernen

Die Übergänge sind fließend. Neue Daten können kontinuierlich oder stufenweise zum Lernen genutzt werden. Manchmal kann es wichtig sein, dass die Ergebnisse des Lernprozesses erst überprüft werden, bevor die Nutzer von ihnen profitieren können.

**Sollen selbstlernende
Modelle Kontroll-
funktionen enthalten,
verlängert sich die
Projektdauer.**

Ob und wie ein AI-Modell sich weiterentwickeln soll, wird von der Art der Anwendung bestimmt und vom ML Engineer entsprechend umgesetzt.

Die Nachteile: Eine Kontrolle über ein selbstlernendes Modell zu implementieren, wird die Projektdauer auf alle Fälle verlängern. Zudem müsste erst definiert werden, wie neue Daten und Rückmeldungen zurückfließen, um den Algorithmus anzupassen.

Wie viele Fehler darf
die AI machen?

Auch AI-Modelle machen Fehler – sie macht im besten Fall zwar weniger Fehler als der Mensch, aber sie ist nicht unfehlbar. Im Gegenteil: Algorithmen nähern sich ja dem Entscheidungsprozess des Menschen an und sind abhängig von Daten und Annahmen. AI ist kein festgeschriebener Code mehr, sie verändert sich. Die Fehlertoleranz ist daher ein sehr wichtiger Aspekt im AI-Design – umso wichtiger, je höher der Automatisierungsgrad ist.

Der AI Planner begleitet die Entwickler und dient der fortwährenden Dokumentation der gewählten Parameter.

Ergebnis des PoC

Mithilfe des AI Planners wurden im PoC die wichtigsten Fragen zum Umgang mit der AI-Anwendung und zur Implementierung des Modells geklärt. Der Machine Learning Engineer hat Testdaten mit dem Modell trainiert und eine klare Abschätzung von Projektdauer und Umfang abgegeben. Ebenso sind an dieser Stelle auch alle Fragen zu Datenzugriff, Datensicherheit und Datenschutz beantwortbar. Diese Informationen sollten mit den entsprechenden Fachabteilungen oder Personen besprochen und gegebenenfalls in der Data Checklist aktualisiert werden.

Für unsere Designanwendung können wir nur teilweise auf bestehende AI-Modelle zurückgreifen. Zusätzlich muss das Modell lernen, wie das Modifizieren eines Fahrzeugs mit anderen Designs funktioniert und wie es den CW-Wert direkt im Design berechnen kann. Es wurde auch geprüft, ob die Mitarbeiter nur den Zugriff auf Daten erhalten, den sie in der zu den Daten gehörenden Anwendung auch haben. Externe Zugriffe sind nicht möglich, daher ist kein gesondertes Sicherheitsdesign notwendig, und persönliche Daten, die den Datenschutz betreffen, werden nicht verarbeitet.

Wir haben den Grad der Autonomie geklärt. Unsere Designanwendung lernt nicht selbstständig weiter, sie erhält nur in definierten Zyklen neue Daten, also ein aktualisiertes Fahrzeugmodell oder CW-Wert-Messungen. Entscheidungen sind nicht automatisiert, sondern werden im Wechselspiel mit den Designern getroffen. Ein selbstlernendes Modell wurde, zumindest im ersten Release, auch ausgeschlossen.

Fehler im Auge behalten

All dies ist positiv für den Umgang mit Fehlern in der AI-Anwendung. Mögliche Fehlerquellen könnten noch in den Daten verborgen sein oder dem Modell unterlaufen, etwa indem es den CW-Wert nach Änderung der Form falsch berechnet. Solche Fehler können in einer späteren Phase entdeckt und behoben werden. Es muss aber sichergestellt sein, dass die Berichtigung an die AI zurückfließen kann – dafür ist eine iterative Arbeitsweise entscheidend.

Das Projekt freigeben

Der PoC kann den Stakeholdern zur Entscheidung der Projektfreigabe vorgestellt werden. Dabei lautet die Schätzung für den Aufwand, dass ein Minimum Viable Product (MVP) sechs Monate und eine Produktentwicklung zwei Jahre dauern wird. Da es eine strategische Anwendung ist, wird sie trotz Aufwand, Kosten und Zeit freigegeben.

Ein weiterer Prüfpunkt liegt hinter uns.

Hinweis: Nicht immer muss man all diesen Schritten in dieser Ausführlichkeit folgen. Hier geht es ja um eine Anwendung für Endanwender. Ein neuronales Netz zur Datenauswertung von Adressen und Unfallberichten, wie in dem Schulbeispiel, hätte bereits im Proof of Concept ein konkretes Ergebnis geliefert – und damit das Endergebnis bereits erreicht. Nach der Auswertung der Daten würde so ein System nicht mehr benötigt.

Nachdem der PoC steht, kehren wir zur wirtschaftlichen Seite unseres Projekts zurück.

Phase 3: Minimum Viable Product

In dem Stakeholder Meeting zur Projektentscheidung werden nun weitere entscheidende Fragen diskutiert. Natürlich in erster Linie die zu erwartende Projektdauer und die Kosten im Vergleich zu den erwartenden Vorteilen der Anwendung.

Das Minimum Viable Produkt baut dabei auf dem PoC auf. Zwingend notwendige Produktteile werden zusätzlich implementiert. Beispielsweise hat das PoC, um den Aufwand möglichst gering zu halten, nur ein gezeichnetes oder rudimentäres User Interface (UI). Dies kann für das MVP nun weiter ausgearbeitet werden.

Die nächsten Schritte zum Produkt

Geht es an die konkrete Umsetzung der AI, müssen die grundsätzlichen Regeln der Skalierung von Innovationen beachtet werden, wie wir das am Anfang des Kapitels beschrieben haben. Die Verantwortlichen im Unternehmen müssen entscheiden, ob sie eine eigene AI-Infrastruktur aufbauen oder die Dienste von Cloud-Anbietern in Anspruch nehmen wollen.

Unternehmen mit wenig Erfahrung in Entwicklung von AI-Modellen und maschinellem Lernen sollten, sofern möglich, mit einem Projekt aus den Cloud-Angeboten beginnen und darauf achten, dass die Anwendung später auch im eigenen Rechenzentrum laufen kann.

Amazon Web Services bieten hierfür Plug-and-Play-Dienste an. Wer komplexere Modelle benötigt, findet bei IBM Watson oder Google Cloud vortrainierte Modelle und auch Trainingsdaten selbst. Mit steigenden Ansprüchen können in der Folge unternehmenseigene Systeme aufgebaut werden (siehe «AI als Strategie» auf Seite 300).

Partnerwahl

Gleiches gilt für die notwendigen Ressourcen und Skills. Wenn man diese nicht bereits im Haus hat oder erst aufbauen muss, kann man sich für das erste Projekt (oder sogar schon für den PoC) einen Technologiepartner ins Haus holen, um Erfahrungen zu sammeln und einen Wissenstransfer zu erreichen (siehe «Partner finden» auf Seite 272).

Selber machen oder machen lassen?

Der PoC hat die Entscheidung vorbereitet, ob man auf bestehende AI-Anwendungen oder verfügbaren AI-Modellen aufbauen will oder diese selbst erstellen muss oder will.

Wer sich für «Make» entscheidet, sollte bei der Entwicklung im Besonderen auf die Qualitätssicherung des AI-Modells achten. Im MVP muss jetzt auch die Skalierung beachtet werden. Diese ist stark abhängig von der Anzahl der Benutzer, der Änderungsfrequenz der Daten, dem Selbstlernen und der Frage, wie autonom das System Entscheidungen trifft. Getestet werden kann dies mit Frameworks wie Tensor Flow oder direkt in den Boilerplates der AI-Anbieter.

**Beim MVP werden
wegweisende
Entscheidungen
für das spätere
Produkt getroffen.**

Eventuell sollte man überlegen, ob man das autonome Entscheiden und Selbstlernen im MVP bereits benötigt. Falls nicht hat man Zeit, die Performance des Modells zu justieren, nachdem alle anderen Parameter bereits funktionieren.

Es ist so weit – wenn die Stakeholder sich für das System entscheiden, können wir unseren ersten AI-MVP bauen. Die wörtliche Übersetzung von «Minimal Viable Product» ist «minimal überlebensfähiges Produkt». Es ist die erste minimal

funktionsfähige Iteration eines Produkts, mit der man richtig arbeiten kann. Ab diesem Punkt ist der Weg zur fertigen Version 1 wieder «normales Projektmanagement».

Neue Möglichkeiten

Mit Abschluss des ersten AI-Projekts stehen Unternehmen alle Wege offen. Grundsätzlich bietet es die Chance, das Produkt kontinuierlich weiterzuentwickeln. Erfahrungsgemäß ergeben sich ab dem Zeitpunkt, an dem eine Anwendung genutzt wird, immer neue Möglichkeiten, das Produkt oder den Service weiter auszubauen.



Der richtige Zeitpunkt für eine AI-Strategie

Es entsteht immer mehr Wissen und Erfahrung im Umgang mit Künstlicher Intelligenz im Unternehmen. Früher oder später sollte sich das Management mit der Frage befassen, inwieweit AI zu einem integrierten Bestandteil der Unternehmensprozesse wird. Spätestens dann ist es an der Zeit, eine umfassende AI-Strategie zu entwickeln. Dazu gehören Aspekte, wie die Governance von AI-Projekten, Fragen der Ethik und die Umstrukturierung der Unternehmensorganisation.

5. Partner finden

Methodische Partner

AI-Projekte sind anders als gewöhnliche IT-Projekte. Sie benötigen andere, oft im Unternehmen nicht vorhandene Fähigkeiten, andere IT-Spezialisten, spezielle Kenntnisse im Umgang mit Daten, Erfahrung in der Berechnung des Geschäftsmodells und vieles mehr.

In vielen Fällen stehen Unternehmen noch ganz am Anfang. Sie wissen nicht, ob sie sich mit dem Thema Künstliche Intelligenz befassen, geschweige denn, wo sie starten sollen. An diesem Punkt benötigen die Entscheider vor allem Wissen und Orientierung, eine Art Lotse, der sie durch neue Gewässer führt. Das hilft ihnen, zu verstehen, worin das Potenzial der neuen Technologie für neue Geschäftsmodelle und der Zusatznutzen für die Kunden bestehen könnte. Orientierung bedeutet nicht nur, sich auf der methodischen und konzeptionellen Ebene Rat zu suchen. Wir haben in den vorigen Kapiteln bereits gesehen, dass es nicht so einfach ist, aus einem AI-Konzept ein MVP zu entwickeln. Partner können helfen, den Weg zur eigenen AI-Expertise deutlich abzukürzen. Dabei gibt es eine große Zahl unterschiedlicher Möglichkeiten.

AI-Projekte benötigen mehr als konventionelle IT-Projekte die Kundenperspektive und die Kooperation sehr unterschiedlicher Experten. Die Bedürfnisse der Nutzer entscheiden in deutlich höherem Ausmaß darüber, wie ein AI-Modell entwickelt wird, als es bei der reinen Programmierung der Fall wäre. Einmal müssen die AI-Experten verstehen, wie Wissensarbeiter mit Dokumenten umgehen, und gezielte Unterstützung anbieten – in einem anderen Fall kann diese Unterstützung ganz anders aussehen. Dann soll das AI-Modell einen Designer dabei unterstützen, ein Autodesign in schnellerer Zeit umzusetzen und dabei zugleich lernen, wie der Chefdesigner denkt.

Den richtigen
Anwendungsfall finden

Erfahrungsgemäß haben Entscheider im Unternehmen häufig Schwierigkeiten mit diesem sehr viel breiteren Spektrum an Einsatzmöglichkeiten. AI-Technologien haben das Potenzial, ganz neue Geschäftsmodelle und neue Wege der Unterstützung zu ermöglichen. Häufig folgen unerfahrene Anwender jedoch dem Reflex, herkömmlichen Zielen zu folgen und die

Methodische Unterstützung hilft dabei, die Komplexität zu bewältigen.

Facilitatoren als Begleiter

Effizienz in einzelnen Prozessen noch ein wenig zu verbessern oder Kosten einzusparen. Die Suche nach einem passenden Anwendungsfall benötigt Offenheit und Kreativität. Es passiert nicht selten, dass ein potenziell attraktives Anwendungskonzept zu den Akten gelegt wird, weil es am methodischen Rüstzeug für die Ausarbeitung fehlt. Oder es wird kein Geschäftsmodell daraus, da nicht nur die Einsatzideen, sondern auch die Berechnungsgrundlagen fehlen.

Daher ist es für AI-Projekte essenziell wichtig, alle Beteiligten, zum Beispiel auch aus Abteilungen wie dem Vertrieb oder der Unternehmensstrategie, zusammenzubringen und die Anwendungsfälle interdisziplinär und ergebnisoffen zu gestalten (siehe auch Abschnitt «Menschen und Organisation» auf Seite 291). Hier lohnt es sich, methodische Unterstützung, zum Beispiel aus dem Innovationsmanagement, zu suchen. Gemeinsam mit geschulten internen Methodikexperten kann etwa ein Anwendungsfall iterativ mithilfe des Design Thinking ausgearbeitet werden. Die Organisatoren sorgen in der Regel dafür, dass unterschiedliche Experten in einem Team gemeinsam an Anwendungsideen arbeiten.

Ansonsten besteht die Gefahr, einen möglichen Anwendungsfall (meist Use Case genannt) zu schnell zu verwerfen, bevor die Beteiligten überhaupt die Chance hatten, auf neuen Ideen zu kommen.

Methodikexperten helfen also bei der Analyse der unternehmenseigenen Möglichkeiten, die dann von den einzelnen Geschäftsprozessen ausgehend auf konkrete Szenarien übertragen werden. Neue Einsatzszenarien kommen meistens durch intensive Workshops im Rahmen des Digital Innovation Managements ins Unternehmen.

Netzwerke nutzen

Der interdisziplinäre Ansatz von AI-Projekten macht an Grenzen von Abteilungen nicht halt. Ein AI-Team kann aus Data Scientists, ML Engineers, Programmierern, Mathematikern, Statistikern, Designern, Personal aus den Fachbereichen und weiteren Stakeholdern bestehen (siehe Abschnitt «Briefing – Faktor Mensch» auf Seite 34). Ganz schön viel für den Anfang. Und teuer. Wer also mehr will als nur erste Erfahrungen

sammeln, kann sich alternativ Hilfe bei Partnern suchen und sich ein Netzwerk aufbauen.

Anlaufstellen sind hier die AI- oder Branchen-Netzwerke, die es mittlerweile in vielen Regionen gibt. In diesen organisieren sich Agenturen zur Ideenfindung, Universitäten zur Unterstützung von kleinen Prototypen oder Proof of Concepts, Start-ups, die passende fertige Anwendungsteile anbieten, bis hin zu Partnern für komplexe Lösungen wie zum Beispiel in der Robotik.

So kann man sein eigenes Netzwerk Schritt für Schritt entwickeln und geeignete Partner oder Technologien auswählen. Ein weiterer Vorteil: Viele der genannten Organisationen pflegen ihrerseits Netzwerke und ermöglichen sehr schnell weiterführende Kontakte.

Selbst sehr erfahrene Organisationen, wie das Fraunhofer-Institut für Optik und Feinmechanik, setzen auf die Arbeit in Netzwerken. Das von diesem Institut geleitete Open Innovation Projekt 3Dsensation soll eine effiziente Interaktion zwischen Mensch, Maschine und Umwelt entwickeln. Dazu stehen Forschungsinfrastrukturlabore, wie das Human Centered Design Lab (HCD), Virtual und Augmented Reality und ein Robo-Lab im Netzwerk zur Verfügung. Für die experimentelle Nachbildung von Anwendungsszenarien bieten sich Nachwuchswissenschaftler zur Erforschung und Erprobung Künstlicher Intelligenz an. Da das ganze Projekt auf Open Innovation basiert, stehen alle Ergebnisse auch allen Netzwerkmitgliedern zur Verfügung. So kann auch schnell auf aktuelle Entwicklungen reagiert werden.

Einfacher kann man seine Reise in eine AI-Welt kaum beginnen – selbst wenn man noch keine eigene AI-Strategie entwickelt hat.

Wie für jedes andere Problem gibt es für AI-Anwendungen auch Berater und Entwickler, die das Ausarbeiten von AI-Projekten übernehmen. Zudem können Unternehmen oft auf bereits existierende Anwendungsbeispiele, bekannte Algorithmen und etablierte Modelle zurückgreifen, um die

**Netzwerke machen
Entwicklungen
transparenter und
ermöglichen schnelles
Reagieren.**

Partner bei der
Lösungssuche

eigenen Lösungen umzusetzen. Die mit den methodischen Partnern gefundenen neuen Ideen und Möglichkeiten erfordern auch neue Machine-Learning-Modelle oder ganz eigene Anwendungen.

Um entscheiden zu können, welche Wege beschritten werden sollen, müssen die verschiedenen Spielarten Künstlicher Intelligenz, deren technologische Möglichkeiten und Implikationen sowie deren Betriebsmodelle evaluiert werden. So lassen sich Erwartungen, nötige Investitionen, Risiken und gesetzliche Bestimmungen vorab bestimmen und austarieren. Um hier fundierte Entscheidungen zu treffen, benötigt man eine AI-Strategie und einen nicht unerheblichen Wissensaufbau. Unterstützen können digitale Unternehmensberatungen und spezialisierte IT-Firmen.



Technologiepartner

Von der Bürosoftware bis zur Künstlichen Intelligenz kann heute nahezu jede IT-Lösung in der Cloud gespeichert und betrieben werden – und entsprechend viele Dienstleister gibt es hier. Vorher muss man aber entscheiden, ob man bestehende Lösungen kaufen oder eigene entwickeln will (build or buy) und ob man überhaupt in die Cloud will – oder darf. Diese Evaluierung hat man im Idealfall mit seinem Lösungspartner bereits geklärt und in seiner AI-Strategie verankert. Wer aber nicht alles selbst bauen möchte oder muss, kann auf eine Vielfalt von Technologiepartnern zugreifen. Von der Bereitstellung von Open-Source-Lösungen über spezifische Schnittstellen (APIs) für das Maschinentraining bis hin zu fertigen AI-Anwendungen.

Fertige Cloud-Lösungen und AI-Modelle senken die Einstiegshürde.

Amazon Web Services, IBM Watson oder Google Cloud stellen hier sowohl Rechenkapazitäten als auch fertige AI-Modelle (sogenannte Boilerplates), spezifische Frameworks für neuronale Netze, wie Tensor Flow oder APIs, für Anwendungen, wie Watson Assistant, zur Verfügung, um zum Beispiel Chatbot-Konversationen zu ermöglichen.

Aber auch Daten oder Trainingsdaten können von Partnern kommen. In unserem Toolbook und dem Schulbeispiel haben wir Verkehrsdaten von Google Maps, öffentlich verfügbare Daten, wie Schuladressen, sowie spezifisch angefragte Daten,

wie Unfallberichte, verwendet. Oftmals gibt es auch hierfür öffentlich verfügbare Datensätze zum Beispiel mit vorklassifizierten Bildern (deepai.org oder image-net.org).

Auch ganz fertige AI-Anwendungen kann man aus der Cloud beziehen oder auf AI basierende Schnittstellen zur IT-Automatisierung oder Robotic Process Automation zurückgreifen. Hier schließt man eigene Anwendungen einfach an und kann so wiederkehrende und zeitraubende Aufgaben von einer AI erledigen lassen.



Datenspezialisten

Ohne gute Daten funktionieren AI-Modelle nicht besonders gut. Wer eine möglichst objektive AI zur Entscheidungsfindung möchte, muss für objektive Daten sorgen. Wer Trends in Echtzeit analysieren möchte, muss auswertbare und nicht redundante Nutzungsdaten auch in Echtzeit zur Verfügung stellen. Oftmals sind es sogar die Daten selbst, die man für ein neues Geschäftsmodell nutzen möchte. Hier gilt es also, diese Daten zu besorgen, aufzubereiten und den AI-Projekten zur Verfügung zu stellen. Nicht selten beginnt AI daher mit einem Big-Data-Projekt und der Implementierung eines sogenannten Data Lakes, das sind große zentrale Datenspeicher, in denen sowohl strukturierte als auch unstrukturierte Daten in ihrem Rohformat abgespeichert werden können. Daher haben sich auf dem Gebiet der Datenaufbereitung viele Spezialisten etabliert, von den großen Unternehmensberatungen, über zahlreiche Start-ups bis hin zu OpenSource-Projekten, wie Apache Hadoop, um große Datenmengen auf verteilten Systemen in hoher Geschwindigkeit überhaupt verarbeiten zu können.



Schlüsselfertige Angebote

Natürlich gibt es auch die Möglichkeit, sich die Auseinandersetzung mit den vielen Details zu ersparen. Der Griff zum Rundum-sorglos-Paket empfiehlt sich dann, wenn man entweder keine Möglichkeiten hat, auf ein Netzwerk zuzugreifen oder einer AI-Initiative beizutreten – oder wenn klar ist, dass man eine umfassende und tiefe AI-Strategie entwickeln muss und noch nicht das erforderliche Wissen aufgebaut hat.

Rundum sorglos

Entscheiden muss man hier, ob man nur einen großen AI-Hersteller, wie IBM AI Services, nutzt und auch dessen Beratungsdienste – die oft sehr gut integriert sind – oder eine unabhängige Beratung für einen sogenannten Best-of-Breed-Ansatz. Damit ist gemeint, dass die besten Lösungen verschiedener Anbieter analysiert und die zum eigenen Unternehmen passenden Angebote ausgewählt werden. Die erweiterten, anbieterunabhängigen Möglichkeiten bezahlt man aber oft mit deutlich höheren Aufwänden für eine Integration.



Die richtigen Partner auswählen

Partnerschaften sind in der AI-Welt unverzichtbar. Beginnen sollte man mit Workshops, um herauszufinden, was genau man von diesen Partnern erwartet, oder bestehende Initiativen und Netzwerke nutzen. Am Ende werden das technologische Wissen, die Innovationsfähigkeit, die gute Zusammenarbeit und das Vertrauen ausschlaggebend für die Partnerwahl sein. Ob mit oder ohne Partner müssen die definierten Lösungen jetzt entwickelt, die Infrastruktur bereitgestellt und auf Skalierung hin optimiert werden. Selbst wenn man das Ressourcenproblem selbst lösen kann, bleibt die Herausforderung, den richtigen Mix an Fähigkeiten im eigenen Unternehmen zu finden.

6. Governance

Eine unkontrollierte Einführung von AI führt zur Verschwendung von Ressourcen.

Verbindliche
Regeln helfen

Keine AI-Strategie zu haben, bedeutet nicht zwingend, dass AI im Unternehmen nicht genutzt wird. Ganz häufig legen Pioniere in einer Organisation mit einer neuen Technologie los. Vielleicht beschäftigen sie Werkstudenten beim Anlernen von neuronalen Netzen, und andere Abteilungen greifen auf kostenpflichtige AI-Dienste zu, die eigentlich das Gleiche bieten. Das geschieht, wenn AI aus unterschiedlichen Gründen genutzt und aus unterschiedlichen Budgets bezahlt wird.

Zum Problem werden derartige Pioniertaten, wenn sie sich häufen und zur Regel werden. Dann beginnt ihr Vorteil ins Gegenteil umzuschlagen. Synergien werden nicht genutzt. Einige Beispiele: Das neuronale Netz mit dem Werkstudenten kommt nie ans Fliegen, da es zwar technisch einwandfrei ist, aber Datenschutz- und Ethikaspekte außer Acht gelassen wurden. Die Anwendung in der Produktion hat die im Unternehmen vorhandenen Daten nicht aufbereitet und daher ist das System nicht einsetzbar. Die Cloud-Anwendung im Marketing wird nach mühsamem Anlernen wieder stillgelegt, weil das Unternehmen noch keine Cloud-Strategie definiert hat und das neue AI-Werkzeug für IT-Automatisierung durch den Betriebsrat vorerst gestoppt wurde.

Diese Szenarien zeigen, dass eine unkontrollierte Einführung von AI zu Geldverschwendung führt, da Ressourcen für die falschen Prioritäten eingesetzt und neue Möglichkeiten und Chancen gar nicht betrachtet werden. Die effiziente Nutzung von Ressourcen und die Überwachung von Ergebnissen erfordert das gemeinsame Engagement aller Unternehmensdisziplinen. Es ist also wichtig, ab einem bestimmten Punkt zentral die Fäden in die Hand zu nehmen und verbindliche Regeln für den Einsatz von Künstlicher Intelligenz zu definieren. Diese sogenannte Governance sorgt dafür, dass Investitionen nicht ins Leere laufen und die neue Technologie effizient, nachhaltig und nach ethischen Maßstäben genutzt wird. Die folgenden Elemente sollten dabei mindestens berücksichtigt werden.

Die sechs Elemente der AI-Governance

Der Kodex definiert Ziele und Grenzen für den Einsatz von Künstlicher Intelligenz.

1. Eine gemeinsame Verständnisgrundlage schaffen

Die Begrifflichkeiten rund um AI sind bis heute nicht eindeutig formuliert und werden oft vermischt oder missverständlich benutzt. Dies beginnt bei dem Begriff «Künstliche Intelligenz» selbst. Manche verstehen darunter maschinelles Lernen, technikaffine Mitarbeiter bezeichnen so neuronale Netze, das Management hingegen jede Form von Büroautomatisierung. Es sollte klar sein, was genau mit einem Anwendungsfall, einer Anwendung, mit Maschinenlernen, einem Algorithmus oder einem Modell gemeint ist. Auch die Abstufungen zwischen Prototyp, Proof of Concept und Minimal Viable Product sollten geklärt sein. Wird eine AI-Strategie festgelegt, muss auch definiert werden, was genau unter Schlagworten wie «Datengetriebenes Unternehmen», verstanden wird.

2. Einen Kodex erarbeiten

Neben einer gemeinsamen Sprache benötigt ein Unternehmen einen gemeinsamen Kodex. Dieser definiert die Ziele und Grenzen für den Einsatz Künstlicher Intelligenz. Der Kodex betrifft daher viele verwaltende Bereiche des Unternehmens und wird in der Regel gemeinsam mit Betriebsrat und Personalabteilung ausgearbeitet. Zunächst wird definiert, was das Unternehmen mithilfe von AI-Technologien erreichen will. Dazu zählen zum Beispiel ein automatisierter Kundenservice, individuelle Risikoberechnung bei der Kreditvergabe oder ein autonom agierender Algorithmus für das Wertpapiergeschäft. Letztlich sollen die AI-Bestrebungen der Organisationsbereiche mit den strategischen Unternehmenszielen in Einklang stehen. Weitere Elemente sind konkrete Regeln für Datenschutz und Ethik (siehe Abschnitt «AI und Ethik» auf Seite 284). Diese Regeln werden umso wichtiger, je autonomer AI-Systeme entscheiden sollen.

Der Kodex sollte außerdem regeln, in welchen Bereichen des Unternehmens eine Automatisierung sinnvoll ist und wie weit sie gehen soll. Schließlich müssen dazu auch, zumindest für interne Anwendungen, Rahmenvereinbarungen mit der Personalabteilung und dem Betriebsrat getroffen werden.

Das Kontrolldesign der AI-Projekte benötigt Experten aller Geschäftsbereiche.

3. Kontrolle sicherstellen

Der Handlungsrahmen sollte den gesamten AI-Entwicklungsprozess abdecken. Am wichtigsten und effektivsten sind Kontrollpunkte in der Entwurfs- und Implementierungsphase. So werden frühzeitig Probleme und Verbesserungspotenziale erkannt und Ressourcen effektiv eingesetzt.

Dazu gehören Regeln, welche Stakeholder, wie zum Beispiel Management, Datenschützer, Betriebsrat, Personalabteilung, an welchen Prüfpunkten eines AI-Projekts (siehe «AI-Projekte sind anders» auf Seite 260) entscheiden und Vorgaben machen. Auf diese Weise werden starke Verzögerungen durch Meinungsverschiedenheiten zwischen Entscheidern, Befindlichkeiten beim Zugriff auf Daten, Bedenken durch Datenschutzbeauftragte oder die langwierige Prüfung einer eigentlich bereits einsatzfähigen Anwendung durch die Personalabteilung oder den Betriebsrat verhindert. Wird dies nicht verbindlich geregelt, kommt es schnell zu einem Kampf der Entscheider – zwischen CEO, CIO, CDO (Digital Officer) oder CMO (Marketing) sowie mit Fachleuten wie Betriebsrat und Personalchef.

Das Kontrolldesign der AI-Projekte verlangt zudem erheblichen Input von Experten aller Geschäftsbereiche, wie Spezialisten der Sicherheitstechnik, Datenschützer, Data Scientists oder auch Rechtsberater. Dies wird umso wichtiger, wenn wir Anwendungen mit weitgehender oder völliger Autonomie anstreben.

4. Regeln für die AI-Innovation

Damit im Unternehmen nicht jede Abteilungsleitung macht, was sie für richtig hält, müssen Spielregeln für die Entwicklung neuer AI-Projekte definiert werden. Sie umfassen etwa die Frage der Prioritäten: Was wird zuerst gemacht? Ist die interne AI-Anwendung für die Verbesserung eines Prozesses wichtig? Oder betreffen sie eher das zusätzliche Produktfeature, das aus einem Produkt einen Service macht? Dabei sollten Ideen nicht zu früh abgelehnt werden. Ab einem gewissen Zeitpunkt sollten sie nach vorhandenen Ressourcen, Budget, Risiko und Potenzial priorisiert werden. So wird verhindert, dass zu viele Möglichkeiten auf einmal verfolgt

Die Gestaltung von AI-Anwendungen hat großen Einfluss auf deren Akzeptanz.

werden, die um das selbe Budget und die selben Ressourcen konkurrieren. Diese Konkurrenzsituation würde wieder zu einem Kampf der Entscheider führen.

Es hat sich außerdem in der Praxis bewährt, alle im Unternehmen verfügbaren Anwendungen oder Ideen zentral zu dokumentieren (zum Beispiel mithilfe eines Dashboards). Dort werden alle Initiativen und Anwendungen auf einfache Weise katalogisiert und ihr Reifegrad angezeigt. Das hilft, Doppelarbeiten sowie einzelne, isolierte Initiativen zu vermeiden sowie Budgets zu bündeln. Wer mit einer eigenen Anwendung starten muss oder möchte, könnte auch erfahrene Kollegen als Mentor an die Seite gestellt bekommen. Vor allem bei ganz neuen Anwendungen und in Innovationsbereichen ist dies sehr effektiv.

Zu guter Letzt sollte geregelt werden, wie beim Design von AI-Anwendungen vorgegangen wird. Vor allem die Gestaltung von Mensch-Maschine-Interaktionen hat großen Einfluss auf die Akzeptanz von AI-Systemen – und entscheidet über Erfolg oder Misserfolg eines Projekts. Hält AI Einzug in die Unternehmensstrategie und damit in viele Unternehmensbereiche, sollte ein AI-Portfolio entwickelt werden. (siehe auch «Menschen und Organisation» auf Seite 291).

5. Den Wissensaustausch garantieren

AI-Projekte sind in besonderem Maße auf die Kooperation zwischen unterschiedlichen Fachabteilungen angewiesen. Das ist ein wesentlicher Erfolgsfaktor und sollte ebenfalls im Rahmen der Governance definiert werden. Silodenken und das Hüten von Wissen haben hier ebenso wenig Platz wie versäumtes Lernen aus Fehlern.

Geregelt werden sollte im Unternehmen zum Beispiel auch die Art und Weise des Austauschs. Dies kann geschehen, indem beispielsweise temporäre, interdisziplinäre Teams gebildet werden, Design-Thinking-Methoden verwendet oder ähnliche interaktive und iterative Arbeitsweisen vorgegeben werden. Auf diese Weise wird die Kooperation innerhalb des Unternehmens aktiv gefördert. Dazu zählen auch der Umgang mit externen Partnern und die Frage, wie umfassend die

zahlreichen Erkenntnisse aus Projekten für die Information der Mitarbeiter und Partner veröffentlicht werden.

Dies muss nicht zwingend in Form einer Dokumentation passieren. Die Erkenntnisse können auch einem Expertennetzwerk zur Verfügung gestellt oder in regelmäßigen Meet-ups vorgestellt werden. Es ist außerdem empfehlenswert, einen solchen Austausch auch über Unternehmensgrenzen hinaus zu ermöglichen (siehe «Partner finden» auf Seite 272). Konkret nutzbare Erkenntnisse, wie Best Practices, sollten allerdings formalisiert werden, sodass sie möglichst schnell übergreifend im Unternehmen genutzt werden können.

Die effiziente Nutzung von Ressourcen und die Überwachung von Ergebnissen erfordert das gemeinsame Engagement aller Unternehmensdisziplinen.

6. Technologiestandards definieren

Je flächendeckender AI im Unternehmen Einzug hält, desto wichtiger ist es, Synergien zu nutzen. Das gilt dann nicht nur für die Anwendungsbereiche und Fachabteilungen, sondern später auch für die Entwicklungswerkzeuge, AI-Modelle und Frameworks, für Testverfahren, standardisierte Betriebsmodelle und die IT-Infrastruktur. Diese Elemente bezeichnet man als «Technologie-Stacks». Für die ersten Projekte kann es noch von Vorteil sein, verschiedene Werkzeuge auszuprobieren oder verschiedene Vorgehensweisen in der Entwicklung zu testen und auch unterschiedliche Betriebsmodelle sind noch handhabbar. Dies dient dazu, Erfahrungen zu sammeln. Früher oder später müssen aber Standards festgelegt werden. Diese Vorgehensweise hilft, sich nicht zu früh auf bestehenden IT-Technologien festzulegen, die sich dann später als ungeeignet herausstellen können.

Dies gilt aber auch für die Datensammlung und Nutzung. Für jede AI-Idee, die mit dem AI Planner durchgespielt wird, sollte die gewünschte Datennutzung katalogisiert werden, selbst

Für jede Idee, die mit dem AI Planner durchgespielt wird, sollte die gewünschte Datennutzung katalogisiert werden.

wenn die Idee nicht umgesetzt wird. So erhält man eine klare Übersicht über die Datenanforderungen und kann eine Datenstrategie erstellen oder genauer spezifizieren.

Auf Technologie-Stack und Datennutzung gehen wir im Abschnitt «AI als Strategie» auf Seite 300 detaillierter ein.



Erste Gehversuche

Alle diese Regeln zusammengekommen helfen, den strategischen Einsatz von AI in einem Unternehmen zu steuern und zu kontrollieren. Wie gesagt: Bei den ersten Gehversuchen ist dies alles nicht notwendig. Je stärker die neue Technologie jedoch das Handeln in der Organisation bestimmt, desto wichtiger ist es, Teilaspekte dieses Governance-Katalogs auszuarbeiten. Je weiter das Unternehmen auf dem Weg zum datengetriebenen Unternehmen voranschreitet, desto wichtiger wird die Governance.

7. Ethik

Gerade weil AI-Systeme Fehler machen können, gehören ethische Abwägungen zum Standardprozedere bei der Entwicklung.

Ethische Standards für AI

Erstmals in der Geschichte der Menschheit stehen wir an einem Punkt, bei dem Entscheidungen nicht an andere Menschen, sondern an selbstlernende Systeme übertragen werden können. Das ist ein gravierender Einschnitt und erfordert besondere Aufmerksamkeit.

Eine AI kann in kürzester Zeit Tausende Studien und Diagnosen durchforsten und mit einem bestehenden Krankheitsbild vergleichen. Was aber ist, wenn sie sich irrt und daraufhin falsche Medikamente verabreicht werden?

Eine AI trifft die Vorauswahl der Bewerber für die Personalabteilung und bestimmt damit, wer im Unternehmen einen Job bekommt – und wer nicht. Was ist, wenn sie Menschen mit Behinderungen, anderer Hautfarbe oder Frauen benachteiligt? Nicht, weil der Mensch das aktiv vorgegeben hätte – sondern weil die Daten der Vergangenheit so aussehen und die Maschine dann «denkt», Hautfarbe und Geschlecht seien wichtige Kriterien?

Eine AI entscheidet, wer am Flughafen sein Gepäck öffnen muss, oder gar, wer einreisen darf. Nach welchen Kriterien bestimmt sie das? Und dürfen wir so weit gehen?

Die Einsatzzwecke für AI sind vielfältig. Technisch wird immer mehr machbar, technische Systeme werden immer autonomer. Doch die Konsequenzen trägt der Mensch. Der Grad an Selbstständigkeit kann im schlimmsten Fall Existenznöte oder gar den Tod von Menschen verursachen. Daher ist es unumgänglich, bei der Entwicklung einer AI neben handwerklichen Aspekten auch moralische Fragen zu klären. Das ist die Aufgabe der Ethik. Welche Aspekte dabei abgedeckt und wie eine ethische AI bewertet und gekennzeichnet werden kann, klären wir in diesem Kapitel.

Die Debatte um ethische Leitlinien ist inzwischen recht weit fortgeschritten. 2020 haben sehr viele Unternehmen entsprechende Erklärungen, AI-Chartas oder Selbstverpflichtungen veröffentlicht. Die Deutsche Telekom fasst diese Aktivitäten unter dem Dach der Compliance-Abteilung zusammen und hat 2019 ihre «Digital Ethics Guidelines on AI» veröffentlicht. IBM

Je autonomer die Maschine, desto gründlicher müssen ethische Prinzipien in ihren Code integriert werden.

hat 2015 die Position der AI Ethics Global Leaders geschaffen und seine Grundsätze in der Publikation «Everyday Ethics for Artificial Intelligence» publiziert (ibm.biz/everydayethics). Die EU hat 2019 ihre «Ethics guidelines for trustworthy AI» (<https://ec.europa.eu/digital-single-market/en/news/ethics-guidelines-trustworthy-ai>) vorgestellt. Es gibt Gespräche zwischen Technologieunternehmen über eine sogenannte «Allianz für Digitale Ethik», und die Bundesregierung arbeitet im Rahmen der Daten-Ethik-Kommission und der Initiative D21 (AG Ethik) an diesem Thema.

Grundsätzlich müssen wir uns bei der Frage nach ethischen Standards noch einmal vergegenwärtigen, was beim Einsatz von AI tatsächlich passiert. Moralische Prinzipien gehören fest zu unseren Denkprozessen, unabhängig davon, ob wir uns danach richten oder nicht. Meistens ist uns bewusst, dass wir moralische Regeln verletzen. Je mehr wir kognitive Fähigkeiten von Maschinen einsetzen und je mehr Entscheidungen wir der Maschine überlassen, desto gründlicher müssen wir ethische Prinzipien in die Arbeit der Maschine integrieren. Ist dies nicht möglich, muss man überlegen, wie man den Menschen an der Entscheidung oder Prüfung beteiligt. Dazu dienen ethische Grundsätze. Sie sind die Basis dafür, dass der Maschine «moralisches Handeln» beigebracht werden kann.

Vier Grundsätze

Was macht eine vertrauenswürdige AI aus? Laut einem Grundsatzpapier der EU soll sie vier Grundsätze auf Basis der Grundrechte berücksichtigen: Menschen sollen bei der Nutzung von AI jederzeit ihre Autonomie wahren können, die AI soll unabsichtlich keinen Schaden verursachen können, ihre Aktionen sollen fair und sie sollen erklärbar sein.

Daraus ergeben sich für Organisationen, die AI-Systeme entwickeln, eine Reihe von Kriterien. Sie sollten im Rahmen der Entwicklung und des Betriebs berücksichtigt werden und sind Teil der AI-Governance (siehe Seite 278).

Vorrang menschlichen Handelns und menschlicher Aufsicht

Das bedeutet, dass die Benutzer zum Beispiel in der Lage sein müssen, informierte Entscheidungen in Bezug auf AI-Systeme zu treffen, sie müssen sich also auch bewusst dagegen entscheiden können. Eine Manipulation durch Algorithmen wäre demnach unethisch. Daher ist menschliche Aufsicht in manchen Bereichen wichtig. Bei Anwendungen für Bewerbungsprozesse könnte eine unabhängige Instanz die Entscheidungen eines lernenden Systems bewerten und ein Gütesiegel oder Zertifikat ausstellen.

Technische Robustheit und Sicherheit

Wenn ein Tesla ein stehendes Fahrzeug nicht erkennt und ungebremsst auffährt, handelt es sich um ein Beispiel für unbeabsichtigte und unerwartete Schäden, die beim Einsatz von autonomen Systemen geschehen können. Deshalb sind die Fahrer verpflichtet, jederzeit aufmerksam zu bleiben. Die Verantwortlichen müssen bei der Entwicklung überlegen, wie Sicherheitsmechanismen konkret aussehen sollen.

Datenschutz und Datenqualitätsmanagement

Zum Einen geht es hier darum, dass beim Verwenden von Daten die Privatsphäre beachtet wird, ein Algorithmus zum Beispiel nicht die ausgewerteten Daten nutzt, um zu diskriminieren. Zum anderen geht es aber auch darum, dass Daten nicht unabsichtlich sozial bedingte Verzerrungen, Ungenauigkeiten, Fehler und andere Mängel enthalten.

Die verwendeten Algorithmen, Daten und Prozesse sollten dokumentiert werden, damit die Entscheidungen von Maschinen später nachvollzogen werden können.

Datenschutz gilt nach Artikel 13 der DSGVO auch bei «einer automatisierten Entscheidungsfindung», bei der betroffene Personen Anspruch auf «aussagekräftige Informationen über die involvierte Logik sowie die Tragweite und die angestrebten Auswirkungen» haben. Hersteller sind also verpflichtet, Auskunft über die verwendeten Daten zu geben, diese datensparsam nach Notwendigkeit zu speichern und auf Verlangen zu löschen. Sie können sich dabei nicht auf den Black-Box-Effekt der AI berufen.

**Maschinen dürfen
sich nicht als
Menschen ausgeben.**

Transparenz

Menschen sollen nachvollziehen können, welche Datensätze und Prozesse zu einer Entscheidung für ein AI-System geführt haben. Dazu gehören auch die verwendeten Algorithmen. Sie sollen dokumentiert werden (zum Beispiel mithilfe eines Frameworks wie es unser AI Planner darstellt).

Wie beschrieben sollen nicht nur die technischen Prozesse, sondern auch die Entscheidung für bestimmte Anwendungsbereiche von AI erklärt werden können. Die technische Erklärbarkeit setzt voraus, dass die von einem AI-System getroffenen Entscheidungen vom Menschen verstanden und rückverfolgt werden können. Dieser Anspruch hat unter Umständen gravierende Konsequenzen in der Praxis. In einem Projekt kann es dann passieren, dass Kompromisse zwischen einer verbesserten Erklärbarkeit eines Systems (was die Präzision beeinträchtigen kann) und mehr Präzision (auf Kosten der Erklärbarkeit) eingegangen werden.

Schließlich gehört zur Transparenz auch, dass AI-Systeme gegenüber den Nutzern nicht als Menschen auftreten dürfen (bei Systemen wie Google Duplex, die Menschen zum Beispiel beim Reservieren eines Friseurtermins perfekt imitieren können, wird das sehr wichtig. Google Duplex stellt sich nun bei jedem Anruf selbst als Chatbot vor).

Vielfalt, Nichtdiskriminierung und Fairness

Dieser Abschnitt hängt eng mit dem Aspekt der Datenqualität zusammen. Es geht darum, unbeabsichtigte Verzerrungen zu vermeiden, die entstehen, wenn zum Beispiel historische Daten verwendet werden oder der unlautere Wettbewerb durch den Einsatz von Algorithmen verhindern werden soll. Es geht aber auch darum, dass die Richtlinien der Governance selbst den Ansprüchen von Inklusion und Vielfalt genügen und dementsprechend so ausgearbeitet sind, dass Diskriminierung vermieden, Barrierefreiheit ermöglicht und die Beteiligung von Interessenträgern gewährleistet wird.

Gesellschaftliches und ökologisches Wohlergehen

Moralisches Handeln bedeutet auch, Rücksicht auf unsere Umwelt zu nehmen und sich der Konsequenzen von technischen Systemen auf unsere Lebensbedingungen schon bei der Planung bewusst zu werden. Das betrifft nicht nur mögliche Schäden. Viele Umweltprobleme, wie der Ausstoß von Schadstoffen, die Verteilung von Lebensmitteln oder der gezielte Einsatz von Ressourcen, wie Wasser oder Dünger, sind durch Daten und Algorithmen lösbar. Allerdings benötigt der Einsatz von AI zum Teil erhebliche Mengen an Energie. Wo immer möglich, sollte auch der Parameter «Nachhaltigkeit» in unseren Entscheidungen eine wichtige Rolle spielen. Ebenso sollten Auswirkungen auf das körperliche und geistige Wohlergehen der Menschen sowie auf die Gesellschaft und die Demokratie berücksichtigt werden.

Rechenschaftspflicht

Damit ist nicht gemeint, dass immer gleich Informationen über Geschäftsmodell und geistiges Eigentum veröffentlicht werden müssen. Die Rechenschaftspflicht ist wieder eng mit der Governance verbunden – das Integrieren von internen oder sogar externen Kontrollen in die Entwicklungsprozesse erhöht das Vertrauen in AI-Systeme. Dazu gehören auch Prozessschritte, wie zum Beispiel die Folgenabschätzung von AI-Handlungen.

Diese Auszüge aus dem Kriterienkatalog der EU zeigen die Komplexität des Themas. Je nach Unternehmenssituation und Zielen, die mit dem Einsatz von AI-Systemen verfolgt werden, fallen die Schwerpunkte der jeweiligen ethischen Governance-Kriterien unterschiedlich aus.

Wie kann man Ethik im AI-Design verankern?

Für Ethik in AI und Algorithmen gibt es inzwischen einige Kriterienkataloge. Je nach Einsatzzweck ist es mehr oder weniger komplex, zu beurteilen, wie notwendig ethische Standards in den eigenen Anwendungen sind – oder wie sie genau ausgestaltet sein müssen.

**Bewertungs-
systeme helfen,
die ethische
Qualität von
AI-Systemen
zu beurteilen.**

Das einfachste Modell ist eine Risikomatrix, die ursprünglich von der AI-Forscherin Katharina Zweig entwickelt und inzwischen auch von der Datenethikkommission der Bundesregierung aufgegriffen wurde. Diese Matrix ist ein zweidimensionales Modell für die Klassifizierung der verschiedenen Anwendungskontexte von AI-Systemen. Die abgestufte Bewertung der Kritikalität automatisierter Entscheidungssysteme in Abhängigkeit vom Einsatzbereich der AI beugt durch die Transparenz und Risikobewertung zudem der Möglichkeit einer Über- oder Unterregulierung vor.

Desweiteren steht ein detailliertes AI-Ethik-Label zur Verfügung, das dem Energieeffizienzlabel nachempfunden ist und so auf einen Blick Orientierung und kompakte Informationen zu den ethisch relevanten Eigenschaften eines AI-Systems bietet. Eine solche Kennzeichnung bietet auch Entwicklern Klarheit, die versuchen, ethisch einwandfreie AI-Systeme zu schaffen, und erhöht zugleich die Transparenz und Vergleichbarkeit von Produkten für die Nutzer. Darüber hinaus schafft solch ein detailliertes und aussagekräftiges Label Markttransparenz sowohl in B2C- als auch B2B-Kontexten.

Das WKIO-Modell (Werte, Kriterien, Indikatoren und Observablen, engl.: VCIO) dient als Ansatz für die Konkretisierung und Messbarmachung der in den Vorgaben zum AI-Ethik-Label aufgeführten Werte. Die Methode hilft dabei, ethische Prinzipien umsetzbar, vergleichbar und messbar zu machen. Dabei werden den Werten zu bestimmende (variable) Kriterien zugeordnet, deren Bewertung anhand von Indikatoren und Observablen (messbar) erfolgt und so den Grad der jeweiligen Werterfüllung anzeigt. Werte werden so differenziert betrachtet und bewertet und müssen nicht absolut bestimmt werden. Das Modell lässt Raum für eine Differenzierung der AI-Systeme in ihren verschiedenen Anwendungskontexten. Mehr Informationen dazu unter www.ai-ethics-impact.org.

Vertrauen in AI als Wettbewerbsfaktor

Auch wenn Governance im Allgemeinen und Ethik im Besonderen zunächst als sehr großer Aufwand erscheinen: Eine konsequente Einhaltung dieser Kriterien sollte als Investition in die Zukunft betrachtet werden. Denn sie helfen nicht nur, unbeabsichtigt künftige Schäden zu vermeiden, sondern erhöhen auch das Vertrauen der Nutzer in die AI-Systeme.

Das ist dringend notwendig, denn bei den Nutzern sprechen sich die Unzulänglichkeiten von AI-Systemen schnell herum. Eine Studie des Beratungsunternehmens Capgemini unter 2900 Konsumenten und 900 Führungskräften im Jahr 2020 zeigt, dass fast jeder zweite Kunde negative AI-Erfahrungen mit Freunden und Verwandten teilt und sie dazu anhält, nicht mit den entsprechenden Unternehmen in Kontakt zu treten. 22 Prozent der befragten Unternehmen wurden seit 1997 von Kunden damit konfrontiert, dass AI-basierte Entscheidungen angezweifelt wurden, oder gefordert wurde, den Weg der Entscheidungsfindung offenzulegen. Und jedes zweite der befragten Unternehmen musste seine von AIs genutzten Datensätze von Gerichten auf Vorurteile prüfen lassen.



Ist Ethik Chefsache?

Klares Nein. Auch Mitarbeiter können auf unethische Weise durch AI Probleme lösen. Antworten auf ethische Fragen müssen ein Teil der Firmenphilosophie sein und speziell für AI im Anwendungsdesign berücksichtigt werden. Daraus wird klar, dass Unternehmen, die eine AI-Strategie entwickeln, sich um ethische Standards kümmern müssen. Denn Technologie selbst hat keine Ethik – weder im Guten noch im Schlechten. Unser Bestreben muss es sein, eine Balance zwischen Mensch und Maschine zu ermöglichen, sodass durch eine Art »assistierten Entscheidens« ethische und gute Resultate erzielt werden. In jedem Fall ist das Zusammenspiel von Mensch und Maschine dem jeweils Einzelnen überlegen. Wir müssen lernen, beide zusammenarbeiten zu lassen oder gar voneinander zu lernen.

8. Menschen und Organisation

Nicht nur ein Mangel an Erfahrung und Vorstellungsvermögen steht dem Einsatz von AI-Systemen entgegen. Häufig hemmen auch herkömmliche Denkmuster und Arbeitsweisen den Erfolg. Unternehmen schaffen es nicht, ihre AI-Initiativen zu skalieren, trotz teilweise hoher Investitionen in Dateninfrastrukturen, AI-Softwaretools, Datenexpertise und eigene Modellentwicklungen. Das liegt hauptsächlich daran, dass versäumt wurde, organisatorische und kulturelle Hindernisse aus dem Weg zu räumen.

Soll beispielsweise der Kundenservice über den Internetauftritt automatisiert werden, und die Servicemitarbeiter werden über ihre zukünftige Rolle im Unternehmen im Unklaren gelassen, wird das Projekt auf starke Widerstände stoßen. Die Automatisierung bringt dem Unternehmen eine höhere Wettbewerbsfähigkeit, und die Mitarbeiter können sich intensiver um spezielle Kundensituationen kümmern, die nicht automatisiert werden können. Ein Gewinn für Mitarbeiter, Kunden und Unternehmen. Im Unternehmen muss also vermittelt werden, wie dringlich die AI-Initiativen sind und welchen Nutzen sie allen bringen. Es ist wichtig, dass mindestens genauso viel in die Akzeptanz wie in die Technologie investiert wird.

AI skaliert zudem am besten, wenn sie organisationsübergreifend genutzt wird. Statt punktuell einzelne Prozesse im Kundenservice zu verbessern, sollte man die ganze Customer Journey betrachten. Letztlich werden Daten über den ganzen Prozess generiert und genutzt. So können Synergien geschaffen werden. AI kann die größte Wirkung entfalten, wenn sie von funktionsübergreifenden Teams entwickelt wird, in denen unterschiedliche Fähigkeiten und Perspektiven zusammenkommen.

Die Organisation muss auf den Einsatz von AI vorbereitet werden. Durch Kommunikation, Information und Integration.

Essenziell ist daher die Weiterentwicklung der Unternehmenskultur, damit sie auf den Einsatz der datengetriebenen Technologie optimal vorbereitet ist, sowie einer Organisationsstruktur, die die Nutzung von AI effektiv vorwärtsbringt. Das bedeutet, nicht nur die IT auf den Einsatz von AI vorzubereiten, sondern auch in den Fachbereichen ein Bewusstsein und die Befähigung zu etablieren, was mit AI möglich sein wird – und dabei die Mitarbeiter eng einzubinden.

«Wirksam werden AI-Initiativen [erst], wenn sie als Bereicherung oder zumindest als Erweiterung verstanden werden. Dieses Verständnis für Veränderung herzustellen, ist deshalb zentrale Aufgabe der Kommunikation, um die Akzeptanz für die Veränderung im Unternehmen bei den Mitarbeitern herzustellen.» –Oliver Lindner (Continental)

Service-Design-Teams etablieren

Gemeinsam Ideen spinnen, schnell einen Experten für ein Thema finden oder die Erkenntnisse des Kollegen aufgreifen: All das ist einfach, wenn sich alle kennen und die Wege kurz sind – also in kleineren Unternehmen. Die meisten Unternehmen aber arbeiten in ihren Bereichssilos.

Wenn ein Unternehmen aber AI nicht nur punktuell nutzen und nachhaltig die Benutzer und Kunden im Blick behalten möchte, muss die Organisation darauf vorbereitet werden.

Hierfür sollten AI-Service-Design-Teams etabliert werden. Diese helfen den Fachabteilungen, zu definieren, welche Problemstellung es ganz konkret zu lösen gibt, und sich einen Eindruck zu verschaffen, wie man dies durch Daten und Automatisierung lösen kann. Dabei wird betrachtet, ob die Prozesse erst verändert werden sollen, bevor man sie automatisiert (Achtung: Shit in – shit out). Innerhalb dieses iterativen Prozesses wird klar herausgearbeitet, welches Potenzial die AI-Anwendung bietet. Selbst wenn der Business Case an diesem Punkt noch nicht berechnet werden kann, muss der Mehrwert einer AI-Initiative klar werden.

Den Mehrwert
definieren

Durch die tiefe Einbindung in die Organisation des Service-Design-Teams, aber auch durch interdisziplinäre Service-Design-Workshops, können schnell Synergien gefunden werden. So kann ein Algorithmus, der den Wartungsbedarf einer Produktionsmaschine vorhersagt, gleichzeitig auch die Arbeitsabläufe zur Instandhaltung optimieren.

Synergien finden

Von Anfang an dabei sind Designer, denn das wichtigste Resultat ist die Akzeptanz der Endanwender. Diese beruht nicht nur auf Funktionen, sondern auch auf geeigneter und intuitiver Nutzung und auf Vertrauen gegenüber dem AI-System.

**Spezialisten für
Prozesse helfen den
Fachabteilungen,
das Potenzial von
AI zu ermitteln.**

Zudem erfordert AI ein gewisses Maß an Experimentierfreude. Oftmals gelingen die ersten Iterationen nicht wie geplant. In diesem Fall ist es wichtig, aus den Iterationen und Pilotprojekten übergreifend in der Organisation zu lernen. Je besser verankert der Wissensaustausch in der Organisation ist, desto mehr kann man seine zukünftigen Entscheidungen auf Daten stützen, anstatt ausschließlich auf Expertise und Erfahrungen.

Alle Beteiligten sollten das gleiche Verständnis für die Projektanforderungen entwickeln.

Kommunikation zur Regel machen

Um Mitarbeiter an Bord zu holen, muss innerhalb des Unternehmens über die Dringlichkeit von AI-Initiativen kommuniziert werden und diese an einem gemeinsamen Ziel ausgerichtet sein. Mitarbeiter müssen verstehen, warum AI so wichtig für das Geschäft ist und wo ihr eigener Platz in der neuen, AI-orientierten Kultur sein wird. Vor allem brauchen sie die Bestätigung, dass die Technologien ihre Aufgaben erweitern werden, anstatt sie einzuschränken oder ganz verschwinden zu lassen.

Vertrauen schaffen

Service-Design-Teams binden Mitarbeiter daher nicht nur bei der Ideenfindung ein, sondern auch in den ganzen Designprozess. So wird die Anwendung nachhaltig am Benutzer ausgerichtet, und die Mitarbeiter haben das letzte Wort über die Gestaltung des UI/UX – aber auch über den Grad der Automatisierung oder die erforderliche Transparenz der maschinellen Entscheidung. Das schafft Vertrauen und führt zu einer optimalen Mensch-Maschine-Interaktion und zu einer erfolgreichen Nutzung der AI-Anwendung.

Verständnis entwickeln

Service-Design-Teams nehmen damit eine Schlüsselrolle ein und sind eine Art Übersetzungsscharnier zwischen Data Engineers, Data Scientists, Management Stakeholdern, IT und Mitarbeitern aus den Fachbereichen. Diese «Übersetzer» helfen sicherzustellen, dass alle Beteiligten das gleiche Verständnis entwickeln, dass die AI-Anwendungen tatsächlich den Geschäftsanforderungen entsprechen und die Akzeptanz zur Einführung hergestellt wird.

Um die Mitarbeiter selbst noch optimaler auf den Einsatz von AI vorzubereiten, sollten auch unternehmensspezifische

Qualifikationen – gestaffelt nach vorhandener Wissenstiefe – angeboten werden. Auch Qualifikationen in die Zukunft schaffen Vertrauen und damit Akzeptanz.

Die «AI-Grundlagen» sollen eine grundlegende Basis dafür sein, den Mitarbeiter auf den Themenkomplex vorzubereiten. Neue Perspektiven und Arbeitsweisen sollen eingeführt und deren Zusammenhänge erläutert werden. Dies hilft, die Unternehmensstrategie einzuordnen und mit dem Service-Design-Team Anwendungspotenziale zu identifizieren.

Die Qualifikation zum AI-Praktiker bereitet direkt für die Nutzung von AI-Anwendungen am Arbeitsplatz vor. Der Mitarbeiter vertieft die Kenntnisse aus den AI-Grundlagen und wird praktisch, bei der Einführung eines AI-basierten Systems, auf die Nutzung geschult.

Die Mitarbeiter müssen auf die Arbeit mit AI vorbereitet werden: durch Schulungen und praktische Übungen.

Den Ideenfluss organisieren

Da wir unser Unternehmen auf den weiten Einsatz von AI vorbereiten, sollte spätestens ab hier ein AI-Portfolio an Initiativen entwickelt werden und in die AI-Governance einfließen. In «AI-Governance – Regeln für die AI-Innovation» Seite 280 wurde ein Dashboard vorgeschlagen, um ein solches Portfolio sichtbar zu machen.

Projekte priorisieren

Projekte sollten auf Basis der AI-Reife und des Innovations tempos der Geschäftsbereiche und der Komplexität der Anwendungen oder des Schwierigkeitsgrads der Umsetzung priorisiert werden. Eine reine Betrachtung nach schnellen oder hohen Gewinnen ist nicht zielführend, da dies schnell umsetzbare und sinnvolle Optimierungsinitiativen behindern würde, selbst wenn diese parallel zu anderen Projekten leistbar wären. Ein Portfolio sollte für mehrere Jahre aufgebaut werden, aber dynamisch anpassbar sein, wenn sich die Bedingungen oder die Strategie ändern. Für eine bessere Beurteilung der Initiativen kann es sinnvoll sein, möglichst viele zumindest bis zur Reife eines Prototypen zu entwickeln.

Verschiedene Blickwinkel

In dem Portfolio sollten auch die Initiativen aus verschiedenen Blickwinkeln gezeigt werden, um Synergien nutzen oder

Mikroinitiativen über weitere Teile einer Wertschöpfungskette bündeln zu können. So fällt es leicht, die betrieblichen Veränderungen zu überblicken, die die neuen Anwendungen möglicherweise erfordern.

Jede Initiative im Portfolio sollte einen zugewiesenen Product Owner besitzen. Dies kann, je nach Anwendungsfall und Herkunft der AI-Initiative, ein Innovator, Data Analyst, Fachexperte oder sogar ein Endanwender sein. Der Product Owner treibt das Projekt an, vertritt es und stellt sicher, dass die Geschäftseinheiten, aus denen die jeweiligen Initiativen kommen, auch für den Projekterfolg selbst verantwortlich sind. Der Product Owner sollte ein Projekt von Anfang bis Ende begleiten, selbst wenn es mehrere Unternehmensteile überspannt.

Komplexere Projekte verteilen diese Rolle auf einen Navigator und einen Piloten. Der Navigator kümmert sich um die Zielsetzungen und Stakeholder, also die Richtung des Projekts, der Pilot um die Umsetzung und Expertise. Navigator und Piloten können ihre sich ergänzenden Rollen zwischen Projektabschnitten tauschen, um nicht «betriebsblind» zu werden.

Interdisziplinäre Arbeit ist ein wichtiger Schlüssel für den Erfolg.

Budgets fixieren

Die Organisation auf den Wandel vorbereiten

Die Einführung von AI verlangt der Unternehmensorganisation einiges ab. Führungskräfte müssen sich, ebenso wie Mitarbeiter, von vielen bisher gültigen Wahrheiten oder Vorstellungen verabschieden.

Wir sind bereits auf das übergreifende Arbeiten zwischen Unternehmensteilen im Sinne von »Silos« eingegangen. In letzter Konsequenz bedeutet dies aber auch, die Budgets zu flexibilisieren. Unternehmen, die Budgets ausschließlich über die Funktion oder den Geschäftsbereich zuweisen, werden sich schwertun, interdisziplinäre, agile Teams einzurichten oder Anwendungen über die ganze Wertschöpfungskette zu implementieren.

Aufgaben flexibilisieren

Schlüsselaufgaben – wie das Bestimmen des Ziels für AI-Projekte, das Analysieren der Probleme, die sie lösen sollen, die Erstellung der Algorithmen, das Entwickeln der Tools, ihr Test mit den Endanwendern, das Organisieren der Umstellung und

das Einrichten der unterstützenden IT-Infrastruktur – berühren ebenfalls viele Unternehmensteile. Wenn für jedes AI-Projekt lange Managementverhandlungen notwendig werden, um zu entscheiden, welcher Mitarbeiter mit wie viel Zeit welches Projekt unterstützen darf, werden die Projekte oftmals gar nicht starten oder sehr stark verzögert.

Vorläufigkeit akzeptieren

Auch müssen sich Führungskräfte von der Vorstellung verabschieden, eine Idee müsse voll ausgereift und vollständig durchgerechnet sein, bevor sie entwickelt werden und zum Einsatz kommt. Bei der ersten Iteration verfügen AI-Anwendungen selten über alle gewünschten Funktionen. Eine Versuch-und-Irrtum-Mentalität bewertet Fehler als eine Quelle neuer Entdeckungen und verringert die Angst vorm Scheitern. Feedback von den ersten Nutzern kann in die nächste Version einfließen. So werden kleinere Ungereimtheiten ausgemerzt, bevor sie sich zu kostspieligen Problemen auswachsen. Das beschleunigt die Entwicklung und versetzt kleine AI-Teams in die Lage, innerhalb von Wochen statt von Monaten Produkte in einer funktionsfähigen Basisversion zu entwickeln.

Die skalierbare AI-Organisation

Erfolgreiche AI-Unternehmen lösen diese Anforderungen durch den sogenannten Hub-Spoke-Ansatz oder ein «Center für AI-Excellence». Mit deutlicher Absicht wird nicht versucht, alle Kompetenzen in einem Bereich, etwa der IT, zu bündeln oder in die Unternehmenshierarchie einzupassen. Es ist wenig sinnvoll, ein starres Modell gegen ein neues starres Modell auszutauschen. Ebenso sollte der Versuch vermieden werden, den Hub oder das AI Center als Cost Center zu betrachten und auf Basis von Gewinnen durch die AI-Anwendungen zu finanzieren. Der Erfolg der Anwendungen sollte durch sorgfältige Planung und Herantasten sichergestellt werden.

Der Hub- Spoke-Ansatz

Der Unterschied zwischen dem Hub-Spoke-Ansatz und dem Center für AI-Exzellenz ist lediglich, dass beim Hub-Spoke-Prinzip tatsächlich eine Rolle geschaffen wird, etwa ein Chief AI Officer, sowie eine kleine Einheit im Hub, die die wichtigsten Funktionen in ständiger Position vertritt – zum Beispiel die Überwachung und Durchsetzung der AI-Governance. Ein Center für AI-Exzellenz führt genau die gleichen Aufgaben durch, ist aber nur eine virtuelle Einheit oder ein Gremium.

Die Kooperation über Silos hinweg fördert die Kompetenz und verhindert Konkurrenz.

In beiden Fällen kommen Vertreter aus verschiedenen Bereichen zusammen und bündeln Kompetenzen, Befugnisse und Budgets für die AI-Strategie. So soll ein Konkurrenzkampf im Unternehmen verhindert und Rollen und Verantwortlichkeiten im Einzelnen festgelegt werden.

Die Funktion des Hubs umfasst:

Budget für die Initiativen und Prototypen bereitstellen,
AI-Expertise (Data Analysts, ML Engineers, Visualisierungsexperten ...),
Service Design,
Governance (Priorisierung, Synergien ...),
Datensteuerung und Zugriffe,
Wissensaustausch und Best Practices,
Zusammenarbeit mit Partnern,
AI-Infrastruktur und Werkzeuge.

Die Spokes sind die einzelnen Geschäftseinheiten, denen die AI-Anwendungsfälle zugeordnet sind. Bei übergreifenden Anwendungen können auch mehrere Spokes beteiligt sein. Die Spokes umfassen folgende Punkte:

Product Owner,
Fachexpertise,
Projektverantwortlicher,
Budgets für Umsetzungen nach Prototyp oder PoC-Phase,
Neugestaltung der Prozesse oder Workflows,
Überwachung der Auswirkung des AI-Einsatzes,
Benutzertests,
Endbenutzerschulungen.

AI-Taskforce

Die AI-Taskforces oder -Teams werden normalerweise am Beginn einer jeden Initiative zusammengestellt und beinhalten anfänglich mindestens einen Product Owner, Übersetzer, Data Scientist, Designer und Fachexperten. Die Zuordnung erfolgt dabei nach Bedarf, was bedeutet, dass sie allmählich entwickelt und nicht auf einen Schlag eingerichtet werden sollte.

Weitere typische Rollen, die von Anfang an oder später mit der Taskforce arbeiten:

Mitarbeiter mit strategischer Ausrichtung und theoretischem Fundament betrachten das Projekt unter den Aspekten Innovation, Serviceorientierung und Prozessorientierung.

Innovatoren übernehmen innerhalb der Gruppe den Job der Trendsetzer, die nahe am Markt neue Ideen aufgreifen und mit idealistischer Motivation das Projektteam fördern und fordern.

Techniker werden nach wie vor Spezialisten der Umsetzung sein und mit technologischem Know-how und Fragen bei der Umsetzbarkeit das Team unterstützen.

Einkäufer und Controller unterstützen das Team mit ihrem Expertenwissen über die Wirtschaftlichkeit und in finanziellen Aspekten.

Human-Resource-Manager und Betriebsräte bringen die Perspektive der Mitarbeiter ein und können eine Gesamtperspektive in der Personalentwicklung abschätzen.

Netzwerke aus AI-Experten

Je mehr Geschäftsfunktionen, Geschäftslinien oder Bereiche von den AI-Tools unterstützt werden sollen, desto größer ist die Notwendigkeit, Netzwerke aus AI-Experten aufzubauen.

Der frühzeitig hohe Ausbildungsstand der Fachkräfte und Mitarbeiter hat häufig einen überdimensionalen Einfluss auf eine erfolgreiche Umsetzung. Dafür richten manche Unternehmen eigene AI-Akademien ein und bieten Diskussionen über die Auswirkungen auf die Rolle der Mitarbeiter sowie über Hindernisse bei der Einführung und über die Fachkräfteentwicklung oder Mitarbeitercoaching an.

Je höher der Ausbildungsstand der Fachkräfte und Führungskräfte, desto besser lässt sich abschätzen, ob die jeweiligen Fachexperten während der Projektphasen immer noch die Anforderungen ihrer Geschäftseinheiten, Funktionen und Bereiche erfüllen können und desto einfacher fällt den Mitarbeitern ihre Doppelrolle.

Sämtliche Schritte, die die Skalierung der Künstlichen Intelligenz vorantreiben, verstärken sich gegenseitig. Der Schritt von funktionalen zu interdisziplinären Teams bringt zu Beginn unterschiedliche Fähigkeiten und Sichtweisen zusammen sowie den Benutzerinput, der nötig ist, um effektive Tools zu entwickeln. Mit der Zeit übernehmen die Mitarbeiter im gesamten Unternehmen neue Formen der Zusammenarbeit. Je enger sie mit Kollegen in anderen Funktionen und Bereichen zusammenarbeiten, desto größer ist die Dimensionen, in denen die

Mitarbeiter allmählich denken – sie bewegen sich dabei von dem Versuch, einzelne Probleme zu lösen, dahin, dass sie vollkommen neue Geschäfts- und Organisationsprogramme entwerfen.

Das Innovationstempo nimmt Fahrt auf, wenn auch die anderen im Unternehmen allmählich den Ansatz des Lernens aus Erfahrung übernehmen, der die Pilotprojekte erfolgreich vorangetrieben hat. Während sich die AI-Tools im gesamten Unternehmen ausbreiten, werden diejenigen, die am nächsten am Geschehen sind, immer mehr befähigt, selbst Entscheidungen zu treffen, die zuvor bei ihren Vorgesetzten lagen.

Mitarbeitern vertrauen

Je mehr wir überlegen, ob wir Vorgänge im Unternehmen automatisieren, und uns auch darüber Gedanken machen, wie kreative oder sogenannte Wissensarbeit von Maschinen übernommen werden kann, desto mehr müssen wir uns über unsere Verantwortung den Mitarbeitern gegenüber Gedanken machen. Die alte Idee, dass ein Unternehmen einem Mitarbeiter einen lebenslangen Arbeitsplatz garantiert, muss in gewisser Weise eine Renaissance erfahren. Es muss ein Vertrauensverhältnis entwickelt werden, das die Selbstabschaffung von Jobs ermöglicht – und zugleich die Weiterentwicklung der Mitarbeiterfähigkeiten im Zusammenhang mit der technologischen Entwicklung des Unternehmens möglich macht. Mit diesem Gedanken bewegen wir uns in die nächste Phase, nämlich den Übergang zum vollständig datengetriebenen Unternehmen.



Datengetriebene Unternehmen sind im Vorteil

Unternehmen, denen es besonders gut gelingt, Künstliche Intelligenz in allen Bereichen zu implementieren, befinden sich deutlich im Vorteil in einer Welt, in der Menschen und Maschinen, die zusammenarbeiten, nicht nur den Menschen, sondern auch den Maschinen, die für sich allein arbeiten, überlegen sind.

9. AI als Strategie

**Die Welt wird
maschinenlesbar.**

**Veränderungen
werden messbar**

Seit vielen Jahren werden Daten als «das neue Öl» bezeichnet. Dennoch wird die Bedeutung von Daten für ein Unternehmen weiterhin unterschätzt. In der Regel werden sie lediglich als Stoff für Analysen und zur Effizienzsteigerung, manchmal noch ansatzweise für neue Geschäftsmodelle gesehen.

Nun haben wir in den vergangenen Kapiteln gelernt, dass Daten viel umfassender genutzt werden können. Wir sind nun in der Lage, die Welt maschinenlesbar zu machen. Wir erzeugen benötigte Daten selbst. Wir können beliebige Vorgänge kontinuierlich erfassen und auswerten. Mit AI-Algorithmen können wir sehr präzise Vorhersagen treffen und automatisiert Entscheidungen treffen lassen. Damit ist aber nicht das Ende erreicht. Denn wann immer sich die Welt verändert, die Algorithmen lernen Veränderungen mit, und passen ihre Entscheidungen an.

Wir sehen das heute an so banalen Beispielen, wie Tankstellen, deren Preise jeweils die aktuelle Nachfrage widerspiegeln. Auch in Supermärkten und Online-Shops werden teilweise nachfragebedingt die Preise angepasst.

Egal, ob uns AI-Systeme bei Entscheidungen für den nächsten Wareneinkauf, den Personaleinsatz oder bei strategischen Fragen beraten – sie sind in der Lage, die auf der Basis des aktuellen Zustands der Welt zu tun. Das ist das eigentlich Revolutionäre. Die nächste Stufe der Unternehmensorganisation ist in der Lage, sich an Veränderungen anzupassen, sobald sie messbar sind. Einen Trend zur Digitalisierung zu ignorieren, wie es Kodak beim Übergang von der analogen zur digitalen Fotografie getan hat, wäre nicht mehr so ohne weiteres möglich.

Was das für den Unternehmenserfolg bedeutet, zeigen die Beispiele von Facebook, Google, Airbnb und Co. Sie gehören zu den ersten Vertretern der neuen Generation von Unternehmen, die Künstliche Intelligenz nicht punktuell nutzen, sondern zur Firmenstrategie erhoben haben. Damit sind sie sehr erfolgreich. Sie erzielen 22 Prozent mehr Gewinn und pro Mitarbeiter 70 Prozent mehr Umsatz als ihre Wettbewerber. Datengetriebene Unternehmen schneiden bei Kennzahlen zu Kundenbindung, Betriebseffizienz und Kosteneinsparungen

um 30 bis 90 Prozent besser ab. Zudem erzielen sie durch neue Produkte und Dienstleistungen eine 19-prozentige und damit um sieben Prozentpunkte höhere Umsatzsteigerung als andere Unternehmen.

Daten gestalten die Zukunft

Der entscheidende Unterschied zum traditionellen Unternehmen besteht darin, dass diese ihre Daten, wenn überhaupt, deskriptiv und diagnostisch nutzen – und somit ausschließlich reaktiv. Datengetriebene Unternehmen gestalten jedoch ihre Zukunft auf der Basis von Daten. Sie haben keine Geschäftsstrategie, die Daten und AI nutzt, denn AI und Daten sind selbst die Geschäftsstrategie. Sie unterstützen die traditionellen Produkte durch Mehrwerte, zusätzliche Einnahmequellen und eine bessere Wettbewerbsfähigkeit – und schaffen ganz eigene Wertschöpfungsmodelle.

Was Entscheider
wissen müssen

Um das volle Potenzial von Daten ausschöpfen zu können, müssen Entscheider in einigen Bereichen umdenken. Sie müssen lernen, das Wesen von AI zu verstehen und sich mit den Besonderheiten von AI-Projekten beschäftigen. Sie müssen den möglichen Nutzen der AI für ihr Unternehmen erkennen können, den Einsatz konzipieren und die Einführung mit Verantwortung und Weitsicht begleiten. Sie müssen in der Lage sein, Investitionsvorschläge zu beurteilen oder die Tragweite einer strategischen Neuausrichtung mithilfe von AI in vollem Umfang zu erfassen.

**Datengetriebene
Unternehmen müssen
risikofreudiger und
agiler sein.**

Sich an neue Situationen und Chancen heranzutasten, wird zum Normalzustand. AI-getriebene Unternehmen müssen risikofreudiger und agiler sein. Dazu gehört es, Organisationsänderungen umzusetzen und die bisher dominierende prozessorientierte Arbeitsweise zunehmend durch eine datengetriebene abzulösen.

Besser urteilen

Wird AI auf breiter Basis angenommen, erweitern die Mitarbeiter aller Hierarchieebenen durch die Empfehlungen der Algorithmen ihr eigenes Urteilsvermögen und Gespür. So gelangen sie zu besseren Lösungen, als Menschen oder Maschinen sie allein jeweils finden könnten. Doch damit dieser Ansatz funktioniert, müssen Mitarbeiter auf allen Ebenen den Vorschlägen der Algorithmen trauen und sich bestärkt

Die nächste Stufe zünden

fühlen, selbst Entscheidungen zu treffen. Der traditionelle Top-down-Ansatz ist damit weitgehend überholt. Denn mithilfe der AI-Werkzeuge werden Mitarbeiter bessere Entscheidungen treffen können als je zuvor.

Damit ein Unternehmen diese Vorteile nutzen kann, muss der Entwicklungsprozess von AI-Tools professioneller werden. Es darf nicht mehr für jedes einzelne AI-Projekt der richtige Weg zur Umsetzung durch die Instanzen einer Organisation gesucht werden müssen. Das würde zu lange dauern, zu viele Ressourcen verschlingen und unnötige Reibung verursachen.

Stattdessen ist nun der Zeitpunkt gekommen, eine interne AI-Fabrik aufzubauen. Eine solche Fabrik besteht aus mehreren Komponenten, beginnend mit einer entsprechenden Infrastruktur, einem systematischen Prozess, um Ideen zu Projekten zu entwickeln, und einer neutralen, faktenbasierten Prüfung jeder einzelnen Idee.

Datenstandards

Der Weg zum datengetriebenen Unternehmen benötigt einen sehr professionellen Umgang mit Daten. Eines ist klar: Daten sind flüchtig. Manche Daten haben eine lange Lebensdauer, andere, wie zum Beispiel der Input von Sensoren, ändern sich in Echtzeit. Daten müssen immerwährend ergänzt oder generiert werden. Dazu müssen Standards für die Weiterverarbeitung eingehalten werden, wie zum Beispiel CRISP (Cross Industry Standard Process for Data Mining). Damit werden Datenbestände nach Mustern, Trends und Zusammenhängen katalogisiert und standardisiert abfragbar.

Auf diese Weise können neue Erkenntnisse und Daten kontinuierlich in den nächsten Lernzyklus eines AI-Modells integriert werden. Ein Lernzyklus kann ständig stattfinden, und damit ändert sich auch der Algorithmus selbständig. Die Entwickler von AI-Systemen müssen diese Besonderheit in ihrem Design berücksichtigen, ein Konzept, das als «Virtuous Cycle of AI» beschrieben wird – auch «Schwungradeffekt» genannt. Durch neue Daten und Feedback wird der Algorithmus immer genauer oder passt sich stetig neuen Gegebenheiten an. Das

Produkt verbessert sich automatisch, es wird für mehr Kunden interessant – der Erfolg potenziert sich.

Der Technikturbo

Wer AI-Systeme als Standardwerkzeug überall im Unternehmen einsetzt, muss sich bewusst sein, dass sie einen ziemlichen Hunger nach Ressourcen, wie Rechenleistung, entwickeln können. Die zugrundeliegende Technik muss bei Bedarf extrem skaliert werden können. Unternehmen benötigen daher eine standardisierte AI-Infrastruktur mit speziell entwickelter, leistungstarker Hardware und Software. Um sie sinnvoll im Unternehmen einzusetzen, gibt es bereits sogenannte Architekturframeworks, wie TOGAF, die dem iterativen Charakter der AI-Entwicklung Rechnung tragen und die Bedürfnisse von Geschäftsmodell, Anwendungsentwicklung, Datenarchitektur und Technologie berücksichtigen. Sie sollte sich zudem für neue Anwendungen auf Knopfdruck erweitern lassen. Erst wenn diese Voraussetzungen erfüllt sind, lässt sich die Leistungsfähigkeit eines AI-Modells zuverlässig vorhersagen.

Die AI-Pipeline ist die Basis für die systematische Produktion von AI-Systemen.

Die Produktionslinie

Damit die für die Entwicklung zum datengetriebenen Unternehmen notwendigen Initiativen entstehen, muss für eine systematische Produktion gesorgt werden. Die Basis dafür ist die AI-Pipeline. Sie entwickelt den Gedanken des AI-Portfolios weiter. Der entscheidende Unterschied ist: Ein AI-Portfolio ordnet Projekte nach verfügbaren Ressourcen und Prioritäten. Die AI-Pipeline kehrt dieses Prinzip um. Sie hat also strategischen Charakter. Denn datengetriebene Unternehmen möchten mit ihren Vorteilen nicht warten, bis eine Ressource zur Verfügung steht. Initiiert und gepflegt wird die Pipeline vom AI-Hub (siehe «Mensch und Organisation» auf Seite 291).

Praktisch sieht das so aus: Sogenannte Scouts halten kontinuierlich den Kontakt zu den Fachabteilungen, um mögliche Anwendungsfälle für AI-Projekte zu finden und die AI-Pipeline aufzubauen. Die Ideen werden in einer Art AI-Accelerator entwickelt – einem formalisierten Vorgehen von der ersten Idee bis zum Prototypen –, der einer Stakeholdergruppe vorgestellt wird. In manchen Unternehmen geschieht dies

wöchentlich. Wird das Projekt zugelassen, erhält es eine Priorität und ein Zieldatum – die Ressourcen dafür werden zugeteilt oder generiert. Es werden also zum Beispiel bei Bedarf auch Mitarbeiter ausgebildet oder eingestellt. Hier gilt der Grundsatz: Projekte warten nicht auf Ressourcen.

Für die schnelle und bestmögliche Umsetzung haben sich dabei Techniken wie Hackathons bewährt. So beginnt zum Beispiel jede Proof-of-Concept-Phase mit einem Wettbewerb um den besten Ansatz. Alle Ergebnisse daraus fließen zurück in den Wissensaustausch – alles könnte zu einem späteren Zeitpunkt wichtig werden, selbst die für diese Anwendung unterlegenen Ansätze.

Im Anpassungswettlauf

Damit die Vorteile des datengetriebenen Entscheidens möglichst schnell sichtbar werden, sollte jeder Unternehmensteil kontinuierlich nach Verbesserung der Prozesse streben. Auf diese Weise wird es mehr und mehr möglich, Entscheidungen und Abläufe auf der Grundlage von Daten zu treffen, anstatt auf der Basis von Bauchgefühl und Prozessbeschreibungen.

Möglichkeiten gibt es viele: Automatisierter Kundensupport, AI-gesteuerte Bewerbungs- und Rekrutierungsprozesse, Einsatzplanungen von Servicetechnikern in Echtzeit oder das interne Wissensmanagement. Der Mensch wird jeweils von Routine entlastet und übernimmt vor allem die Aufgaben, die den typischen menschlichen Stärken am besten entsprechen: das schwierige Kundengespräch, die Beurteilung von Sonderfällen und das stete Hinterfragen, ob die Maschine etwas nicht bedacht hat oder der Entscheidungsweg unklar geblieben ist. Der Mensch bleibt die letzte Instanz.

Der Erfolg von datengetriebenen Unternehmen hängt auch damit zusammen, dass es dort eine Kultur der Veränderung gibt, die von jeder Person gelebt wird. Mitarbeiter bei Google oder Amazon erhalten Prämien, wenn sie ihren Arbeitsplatz automatisieren oder abschaffen (beziehungsweise die Ideen dazu liefern). Sie müssen keine Angst davor haben, denn sie dürfen über den Grad der Automatisierung mitbestimmen und es wird ihnen ein ebenbürtiger Job garantiert. So beginnen

Mitarbeiter nicht selten im Marketing und arbeiten später daran, eine AI mit Marketingideen anzulernen, um gezielte und individuelle Marketingbotschaften generieren zu können.

Eine AI-Pipeline ist nur so gut wie die kritische Prüfung der Ideen, die von Scouts im Unternehmen eingesammelt werden. Diese Due Diligence überprüft AI-Projektideen systematisch darauf, ob sie die Unternehmensziele, ethischen Werte und vieles mehr erfüllen. Wir haben eine Liste mit Fragen zusammengestellt, die helfen, die wunden Punkte offen zu legen.

Fragen-set: Due Diligence

Das Set hilft bei der kritischen Bewertung von AI-Projekten.

Für den Prototyp

- Wie hilft die Anwendung, Unternehmensziele (besser) zu erreichen?
- Welche Aufwände stehen welchem Potenzial gegenüber?
- Wie werden die Machbarkeit und Dauer des Projekts eingeschätzt?
- Was benötigt die Anwendung für ihre Benutzerakzeptanz?
- Gibt es Grenzen, die beachtet werden müssen?
- Besteht der Wettbewerbsvorteil nach Ende des Projekts noch?
- Wie einfach/schwer ist die Anwendung von Mitbewerbern kopierbar?
- Warum kann keine fertige AI-Lösung aus dem Markt verwendet werden?
- Wo liegen die Stopp-Punkte für einen frühen Abbruch (fail early)?
- Was lernen wir aus der Anwendung, wenn wir scheitern?

Nach dem Proof of Concept

- Wie wird die Leistung des Modells eingeschätzt?
- Welche Kapazitäten und Skills werden notwendig?
- Ist das MVP bereits für Endnutzer einsetzbar?
- Wie fehlertolerant ist die Anwendung und wie ist der Umgang mit Fehlern?
- Wie ist die Governance des Projekts sichergestellt?



Manche Leute nennen es Künstliche
Intelligenz. Aber in Wirklichkeit wird diese
Technologie uns selbst verbessern.

Ginni Rometty



Fazit

Alle diese Komponenten der AI-Fabrik beschleunigen Projekte. Das klingt aufwendig und teuer. Und es wird oft argumentiert, dass die Techkonzerne aus dem Silicon Valley sich die beschriebene Vorgehensweise leisten könnten, da sie viel Kapital zur Verfügung haben. Die Wahrheit ist: Sie haben viel Kapital, weil sie so vorgehen.

Der Vorteil der AI-Fabrik: Es gibt keine kräftezehrenden Managementkämpfe um Ressourcen mehr. Es werden viele Ideen nach Wert statt nach Popularität gefiltert. Es gibt schnelle Prototypen und damit einen schnellen Beweis der Machbarkeit. Einmal gemachte Erfahrungen, erarbeitetes Wissen und AI-Modelle werden kontinuierlich weiterverwendet und nach dem immer gleichen Prinzip durch die Produktionslinie umgesetzt. Erfahrungsgemäß lassen sich die Projektzeiten auf diese Weise häufig um die Hälfte bis zu zwei Drittel reduzieren.

Der Weg zum datengetriebenen Unternehmen ist ein Prozess, der sich über Jahre hinzieht und für den grundsätzlich alle Elemente des Kapitels «Sicher landen» notwendig sind.

Doch das Wichtigste ist, überhaupt erst einmal Erfahrungen mit Künstlicher Intelligenz zu sammeln, und dafür ist keine übergeordnete Strategie notwendig. Für die ersten Gehversuche reicht es, sich die Aspekte herauszupicken, die in der jeweiligen Situation brauchbar erscheinen. Anhand kleiner Projekte, einem Netzwerk und dem in diesem Buch vorgestellten AI Planner ist es vergleichsweise einfach, die erste Hürde im Umgang mit dem Unbekannten zu nehmen.

Die Autoren

Alessandro Brandolisio (links) ist Industriedesigner, Innovationsstrategie und Start-up-Gründer. Seit zehn Jahren entwickelt er innovative Produkte, Services und Geschäftsmodelle für Kunden wie Intel, Deutsche Telekom und das MIT. Seine Stationen in vielen Unternehmen in Europa und im Silicon Valley prägten seine Überzeugung, dass bahnbrechende Innovation nur gelingt, wenn die Stärken von Mensch und Maschine kombiniert werden.

Karel J. Golta (Mitte) begleitet seit den 1990er-Jahren die Umsetzung von Zukunftstechnologien. Auf Grundlage dieser Erfahrungen gründete der Innovationsexperte und Designer die Unternehmen *INDEED Innovation*, *Simplexion* und *TOI – Tools of Innovators*.

Sie unterstützen Kunden dabei, komplette Geschäftsmodelle zu entwickeln, IoT-Produkte umzusetzen und die Innovationsfähigkeit von Unternehmen zu aktivieren. Der Entrepreneur weiß: Für eine nachhaltige und bessere Zukunft brauchen wir viel mehr innovationsfähige Mitarbeiter.

Michael Leitl (rechts) ist Innovationsexperte in Theorie und Praxis. Der Chemie-Ingenieur gründete Start-ups und arbeitete als Wirtschaftsredakteur unter anderem beim *Harvard Business Manager*. 15 Jahre betreute er die Themenbereiche Digitalisierung und Innovation und arbeitete mit am Aufbau des Innovationsmanagements des Spiegel-Verlags. Für ihn gehört Innovationsfähigkeit zum Einmaleins des 21. Jahrhunderts.



Die Entstehung

Wir erinnern uns noch gut: Wir liebten unsere Design-Thinking-Workshops, waren stolz auf Tausende beschriebene Post-its und freuten uns über die Produkt- und Servicekonzepte, die in kurzer Zeit entstanden. Die Methode war der letzte Schrei und eroberte die Chefetagen – obwohl sie bereits in den 1980er-Jahren erfunden worden war.

Parallel zum Siegeszug der vielen agilen Methoden entwickelte sich die Welt außerhalb der Innovations-Community weiter. Prozesse wurden digitalisiert: In der Produktion, im Marketing, im Vertrieb, im Einkauf. Nur wir Innovatoren klebten weiter Post-its. Abgesehen von digitalen Ideenmanagementplattformen tat sich nicht viel am Frontend of Innovation.

Das war vor 2018. In diesem Jahr änderte sich langsam, aber kontinuierlich das Klima. Beim Innovation Roundtable Summit in Kopenhagen berichteten wir von unseren Rechercheergebnissen: Die Innovationsfähigkeit in den Unternehmen sinkt seit Jahren, trotz Digitalisierung und New Work. In der anschließenden Diskussion kamen die Zuschauer auf uns zu und berichteten von ähnlichen Erfahrungen. Die von ihnen verwendeten Methoden wurden der Komplexität ihrer Herausforderungen nicht mehr gerecht. Design Thinking ist eben nicht immer die adäquate Lösung. Die Frage lautete also: What's the next big thing? Wie kann Innovation modernisiert werden?

Um das herauszufinden, taten wir, was Innovatoren immer tun: Wir betrachteten die Bedürfnisse der Nutzer. Was macht uns und anderen

Innovatoren am meisten Arbeit und Mühe? Aus der Menge der identifizierten Pain Points nur ein Beispiel. Beim Aufdecken von Erkenntnissen aus Kundeninterviews müssen oft Tausende Signale von Hand ausgewertet werden. Diesem Job würden wir keine Träne nachweinen.

Was wäre, wenn wir solche Aufgaben komplett automatisieren oder gar überflüssig machen könnten? Wenn von der Trendrecherche bis zur Prototypentwicklung der gesamte Ablauf im Computer stattfinden würde? Wenn Algorithmen nicht nur Texte übersetzen, sondern Designs entwickeln würden?

Das wäre er: der nächste Entwicklungssprung in der Innovationsarbeit.

Wir haben uns an die Arbeit gemacht – und dieses Buch ist das Ergebnis. Eine allgemeinverständliche Anleitung, mit der auch Macher, Entscheider und Innovatoren AI-Konzepte entwickeln können – ohne Programmierkenntnisse haben zu müssen.

Das Ergebnis unserer Arbeit wollen wir nun allen zur Verfügung stellen. Mit dem vorliegenden Framework bekommt das Entwickeln von AI-Konzepten dieselbe Leichtigkeit wie beim spielerischen Umgang mit den Elementen neuer Geschäftsmodelle.

Wir wollen Menschen ermutigen, sich dem Thema Künstliche Intelligenz zu nähern, eigene Erfahrungen zu sammeln und das Potenzial für ihre Unternehmung zu erschließen. Für eine nachhaltige, bessere Zukunft.

Das Netzwerk

Für die Entwicklung des AI Planners und der Anleitungen haben wir intensiv mit **Ralph Siepmann** zusammengearbeitet. Er vereint fundierte Kenntnis für kollaborative Arbeitsabläufe im Unternehmen mit fundierten AI-Kenntnissen aus seiner über 20-jährigen Arbeit bei IBM, unter anderem im Bereich «Watson Cognitive Collaboration». Aktuell arbeitet er als Digital Workplace & Collaboration Consultant bei dem IT-Dienstleister edcom GmbH in München.

Beim Sparring haben uns viele Experten geholfen. Unser Dank gilt: **Oliver Lindner** von Continental, er brachte den Gedanken an ein Buch ins Spiel. **Maurice Conti**, damals AI-Experte bei der europäischen Moonshot-Fabrik Alpha, half uns mit seinen kritischen Fragen, den Mehrwert von AI für Innovation klar herauszuarbeiten. **Christian Mio Loclair** und **Thomas Johann Lorenz** vom kreativen AI-Labor Waltz Binaire waren eine wertvolle Hilfe bei der Ausarbeitung des AI Planners. Die AI-Designer **Mike Brandt** und **Jonas Wenke** von 33A inspirierten uns mit Ihrer Art, komplexe Inhalte verständlich darzustellen.



Danke

Für unendlich viele leckere Kaffees, seelische
und moralische Unterstützung: Maria Negrão, Andrea Reidl.

Unseren Kolleginnen und Kollegen Maria Krüger,
Johanna Joppien, Min Joo Cho und Sam Swift, die immer
ein offenes Ohr für Fragen und Feedback hatten.

Unserem unermüdlichen Grafiker Max Glimm
(www.maxglimm.de).





Zum Ausgleich für die entstandene CO₂-Emission bei der Produktion dieses Buches unterstützen wir die Erhaltung und Wiederaufforstung des Kibale-Nationalparks in Uganda. Das Projekt trägt zum Klimaschutz bei, indem die Bäume bei der Fotosynthese Kohlenstoff aus der Luft binden, es schützt die Biodiversität des tropischen Waldes und sichert 260 Arbeitsplätze.

Bibliografische Information der Deutschen Nationalbibliothek
Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

Das Werk einschließlich aller seiner Teile ist urheberrechtlich geschützt. Jede Verwertung ist ohne Zustimmung des Verlages unzulässig. Das gilt insbesondere für Vervielfältigungen, Übersetzungen, Mikroverfilmungen und die Einspeicherung und Verarbeitung in elektronischen Systemen.

Der Verlag weist ausdrücklich darauf hin, dass er, sofern dieses Buch externe Links enthält, diese nur bis zum Zeitpunkt der Buchveröffentlichung einsehen konnte. Auf spätere Veränderungen hat der Verlag keinerlei Einfluss. Eine Haftung des Verlags ist daher ausgeschlossen.

Copyright © 2021 Murmann Publishers GmbH, Hamburg

Editorial Design: Christoph Schulz-Hamparian, Stuttgart
Grafik: Max Glimm, Hamburg (www.maxglimm.de)
Druck und Bindung: Optimal Media GmbH, Röbel/Müritz
Printed in Germany

ISBN 978-3-86774-648-9

Besuchen Sie uns im Internet: www.murmann-verlag.de
Ihre Meinung zu diesem Buch interessiert uns!
Zuschriften bitte an info@murmann-publishers.de
Den Newsletter des Murmann Verlages können Sie anfordern unter newsletter@murmann-publishers.de