



Neuronale Netze und Deep Learning

1 Einbettungen, latenter Raum und Repräsentationen

Beim Deep Learning sind Begriffe wie *Einbettungsvektoren*, *Repräsentationen* und *latenter Raum* gebräuchlich. Was haben diese Konzepte gemeinsam und wie unterscheiden sie sich?

Auch wenn diese drei Begriffe oft synonym verwendet werden, können wir zwischen ihnen feine Unterscheidungen treffen:

- Einbettungsvektoren sind Repräsentationen von Eingabedaten, bei denen ähnliche Elemente nahe beieinanderliegen.
- Latente Vektoren sind Zwischenrepräsentationen von Eingabedaten.
- Repräsentationen sind codierte Versionen der ursprünglichen Eingabedaten.

Die folgenden Abschnitte untersuchen die Beziehung zwischen Einbettungen, latenten Vektoren und Repräsentationen. Außerdem erfahren Sie, wie sie jeweils im Kontext des maschinellen Lernens Informationen codieren.

1.1 Einbettungen

Einbettungsvektoren – kurz *Einbettungen* – codieren relativ hochdimensionale Daten in relativ niedrigdimensionale Vektoren.

Mithilfe von Einbettungsmethoden können wir einen kontinuierlichen dichten (nicht-dünnbesetzten) Vektor aus einer (dünnbesetzten) 1-aus-n-Codierung (englisch One-hot encoding) erzeugen. Die *1-aus-n-Codierung* ist eine Methode, um kategoriale Daten als binäre Vektoren darzustellen, wobei jede Kategorie auf einen Vektor abgebildet wird, der an der Position, die dem Index der Kategorie entspricht, eine 1, und an allen anderen Positionen eine 0 enthält. Damit ist sichergestellt, dass die kategorialen Werte so dargestellt werden, dass bestimmte Algorithmen für maschinelles Lernen sie verarbeiten können. Wenn wir zum Beispiel eine kategoriale Variable Farbe mit den drei Kategorien Rot, Grün und Blau haben, stellt die 1-aus-n-Codierung Rot als [1, 0, 0], Grün als [0, 1, 0] und Blau als [0, 0, 1] dar. Diese 1-aus-n-codierten kategorialen Variablen lassen sich dann in kon-

tinuierliche Einbettungsvektoren abbilden, indem die gelernte Gewichtsmatrix einer Einbettungsschicht oder eines Moduls verwendet wird.

Einbettungsmethoden eignen sich auch für dichte Daten wie Bilder. Zum Beispiel können die letzten Schichten eines Convolutional Neural Networks (CNN) Einbettungsvektoren liefern, wie Abbildung 1–1 veranschaulicht.




Abb. 1–1 Eine Eingabeeinbettung (links) und eine Einbettung von einem neuronalen Netz (rechts)

Um technisch korrekt zu sein, könnten alle Ausgaben der Zwischenschicht eines neuronalen Netzes Einbettungsvektoren liefern. Je nach Trainingsziel kann auch die Ausgabeschicht nützliche Einbettungsvektoren erzeugen. Der Einfachheit halber assoziiert das Convolutional Neural Network in Abbildung 1–1 die vorletzte Schicht mit Einbettungen.

Es ist möglich, dass Einbettungen eine höhere oder niedrigere Anzahl von Dimensionen haben als die ursprüngliche Eingabe. Mithilfe von Einbettungsmethoden für extreme Ausdrücke lassen sich beispielsweise Daten in zweidimensionale dichte und kontinuierliche Darstellungen für Visualisierungszwecke und Clustering-Analysen codieren, wie Abbildung 1–2 zeigt.




Abb. 1–2 Abbildung von Wörtern (links) und Bildern (rechts) auf einen zweidimensionalen Merkmalsraum

Zu den grundlegenden Eigenschaften von Einbettungen gehört, dass sie *Abstand* oder *Ähnlichkeit* codieren. Das bedeutet, dass Einbettungen die Semantik der Daten so erfassen, dass ähnliche Eingaben im Einbettungsraum nahe beieinanderliegen.

Für Leser, die an einer formaleren Erklärung mittels mathematischer Terminologie interessiert sind, sei erwähnt, dass eine Einbettung eine injektive und strukturerhaltende Abbildung zwischen einem Eingaberaum X und dem Einbettungsraum Y ist. Dies impliziert, dass ähnliche Eingaben an nahe beieinanderliegenden Punkten innerhalb des Einbettungsraums liegen, was man als »struktur-erhaltende« Eigenschaft der Einbettung ansehen kann.

1.2 Latenter Raum

Latenter Raum wird in der Regel synonym mit *Einbettungsraum* verwendet, das heißt dem Raum, in den Einbettungsvektoren abgebildet werden.

Ähnliche Elemente können im latenten Raum nahe beieinanderliegen, was jedoch keine strikte Voraussetzung ist. Im weiteren Sinne kann man sich den latenten Raum als jeden Merkmalsraum vorstellen, der Features – oftmals komprimierte Versionen der ursprünglichen Eingabefeatures – enthält. Diese latenten Raumfeatures können von einem neuronalen Netzwerk erlernt werden, beispielsweise einem Autoencoder, der Eingabebilder rekonstruiert, wie Abbildung 1–1 zeigt. Diese latenten Eingabefeatures können von einem neuronalen Netz gelernt werden, beispielsweise von einem Autoencoder, der Eingabebilder rekonstruiert, wie Abbildung 1–3 zeigt.




Abb. 1–3 Ein Autoencoder, der das Eingabebild rekonstruiert

Der Flaschenhals in Abbildung 1–3 repräsentiert eine kleine Zwischenschicht des neuronalen Netzes, die das Eingabebild in eine Repräsentation geringerer Dimensionen codiert. Den Zielraum dieser Abbildung kann man sich als latenten Raum vorstellen. Das Trainingsziel des Autoencoders besteht darin, das Eingabebild zu rekonstruieren, das heißt, den Abstand zwischen den Eingabe- und Ausgabebildern zu minimieren. Um das Trainingsziel zu optimieren, kann der Autoencoder lernen, die codierten Features von ähnlichen Eingaben (zum Beispiel Bilder von Katzen) im latenten Raum nahe nebeneinander zu platzieren, dabei nützliche Einbettungen von Vektoren zu erstellen, wobei ähnliche Eingaben im Einbettungs- (latenten) Raum nahe beieinanderliegen.

1.3 Repräsentation

Eine *Repräsentation* ist eine codierte Form und typischerweise eine Zwischenform einer Eingabe. Zum Beispiel ist ein Einbettungsvektor bzw. Vektor im latenten Raum eine Darstellung der Eingabe, wie oben erläutert. Allerdings können Darstellungen auch mit einfacheren Prozeduren erzeugt werden. Zum Beispiel lassen sich 1-aus-n-codierte Vektoren als Repräsentationen einer Eingabe betrachten, wie bereits oben erwähnt. Allerdings lassen sich Repräsentationen auch durch einfachere Verfahren erzeugen. So werden zum Beispiel 1-aus-n-codierte Vektoren als Repräsentationen einer Eingabe betrachtet.

Der Grundgedanke besteht darin, dass die Repräsentation einige wesentliche Features oder Eigenschaften der ursprünglichen Daten erfasst, um sie weiter analysieren zu können.

1.4 Übungen

1. Angenommen, wir trainieren ein Netz mit fünf konvolutionalen Schichten, gefolgt von drei vollständig verbundenen Schichten, ähnlich dem AlexNet (<https://en.wikipedia.org/wiki/AlexNet>), wie in Abbildung 1–4 veranschaulicht.




Abb. 1–4 Eine Veranschaulichung von AlexNet

Diese vollständig verbundenen Schichten kann man sich als zwei verdeckte Schichten und eine Ausgabeschicht in einem mehrschichtigen Perzeptron vorstellen. Welche Schichten dieses neuronalen Netzes lassen sich nutzen, um nützliche Einbettungen zu erzeugen? Interessierte Leser finden weitere Details zur Architektur und Implementierung von AlexNet in der Originalveröffentlichung von Alex Krizhevsky, Ilya Sutskever und Geoffrey Hinton.

2. Nennen Sie einige Typen von Eingaberepräsentationen, die keine Einbettungen sind.

1.5 Referenzen

- Die Architektur und Implementierung von AlexNet wird ursprünglich in folgendem Paper beschrieben: Alex Krizhevsky, Ilya Sutskever und Geoffrey Hinton, »ImageNet Classification with Deep Convolutional Neural Networks« (2012), <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks>.

2 Selbstüberwachtes Lernen

Was ist selbstüberwachtes Lernen, wann ist es nützlich und wie sehen die Hauptansätze aus, um es zu implementieren?

Selbstüberwachtes Lernen ist eine Vortrainingsprozedur, die es neuronalen Netzen ermöglicht, große, ungelabelte Datensätze in überwachter Art und Weise zu nutzen. Dieses Kapitel vergleicht selbstüberwachtes Lernen mit Transferlernen, einer verwandten Methode zum Vortrainieren von neuronalen Netzen, und erörtert die praktischen Anwendungen von selbstüberwachtem Lernen. Schließlich skizziert es die wichtigsten Kategorien von selbstüberwachtem Lernen.

2.1 Selbstüberwachtes Lernen vs. Transferlernen

Selbstüberwachtes Lernen ist mit dem Transferlernen verwandt, einer Technik, bei der ein Modell, das für eine bestimmte Aufgabe vortrainiert worden ist, als Ausgangspunkt für ein Modell für eine zweite Aufgabe wiederverwendet wird. Nehmen wir zum Beispiel an, dass wir einen Bildklassifikator trainieren wollen, um Vogelarten zu klassifizieren. Beim Transferlernen würden wir ein CNN (Convolutional Neural Network) auf dem ImageNet-Datensatz trainieren, einem großen, gelabelten Bilddatensatz mit vielen verschiedenen Kategorien, einschließlich verschiedener Objekte und Tiere. Nach dem Vortraining mit dem allgemeinen ImageNet-Datensatz wird das trainierte Modell mit dem kleineren, spezifischeren Zieldatensatz trainiert, der die interessierenden Vogelarten enthält. (Oftmals müssen wir nur die klassenspezifische Ausgabeschicht ändern, können ansonsten aber das vortrainierte Netz unverändert übernehmen.)

Abbildung 2–1 veranschaulicht den Ablauf beim Transferlernen.

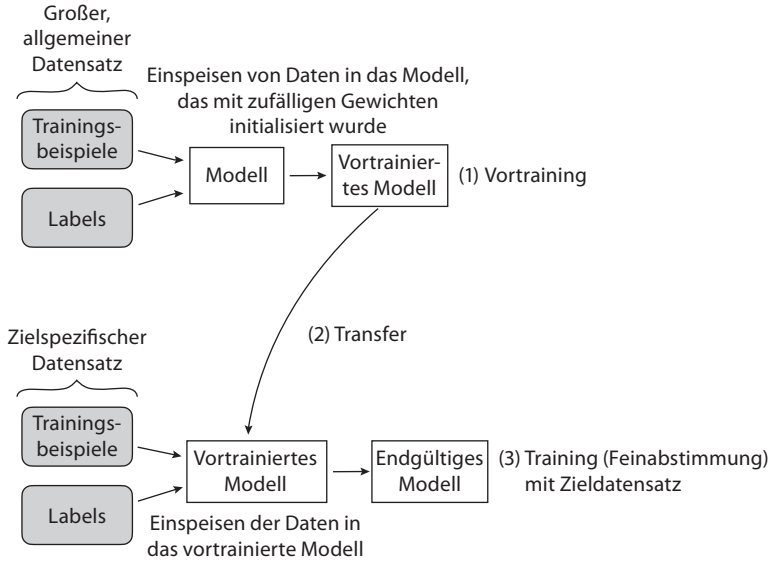


Abb. 2-1 Vortraining mit konventionellem Transferlernen

Selbstüberwachtes Lernen ist ein alternativer Ansatz zum Transferlernen, bei dem das Modell nicht mit gelabelten Daten, sondern mit ungelabelten Daten vortrainiert wird. Wir betrachten einen ungelabelten Datensatz, für den wir keine Label-Informationen haben, und suchen dann nach einer Möglichkeit, Labels aus der Struktur des Datensatzes zu erhalten, um eine Vorhersageaufgabe für das neuronale Netz zu formulieren, wie Abbildung 2-2 zeigt. Diese Aufgaben für das selbstüberwachte Training nennt man auch *Voraufgaben*.

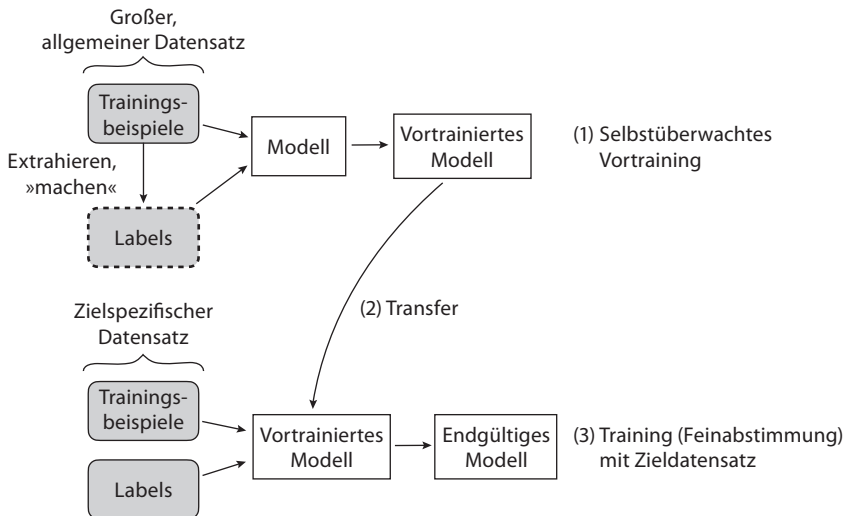


Abb. 2-2 Vortraining mit selbstüberwachtem Lernen

Der Hauptunterschied zwischen Transferlernen und selbstüberwachtem Lernen liegt in der Art und Weise, wie wir die Labels in Schritt 1 der Darstellungen von Abbildung 2–1 und Abbildung 2–2 erhalten. Beim Transferlernen gehen wir davon aus, dass die Labels zusammen mit dem Datensatz bereitgestellt werden. In der Regel werden die Labels manuell von Label-Experten den Daten zugeordnet. Beim selbstüberwachten Lernen lassen sich die Labels direkt aus den Trainingsbeispielen ableiten.

Eine Aufgabe des selbstüberwachten Lernens könnte eine Vorhersage fehlender Wörter im Kontext der Verarbeitung natürlicher Sprache sein. Zum Beispiel können wir bei dem Satz »Draußen ist es schön und sonnig« das Wort »sonnig« ausmaskieren, dem Netz die Eingabe »Draußen ist es schön und [MASKE]« einspeisen und das Netz das fehlende Wort an der Position »[MASKE]« vorhersagen lassen. In ähnlicher Weise könnten wir in einem Computer-Vision-Kontext Bildausschnitte entfernen und das neuronale Netz die Lücken füllen lassen. Dies sind lediglich zwei Beispiele für Aufgaben des selbstüberwachten Lernens; es gibt viele weitere Methoden und Paradigmen für diese Art des Lernens.

Zusammenfassend lässt sich sagen, dass man selbstüberwachtes Lernen bei der Voraufgabe als Repräsentationslernen betrachten kann. Wir können das vorab trainierte Modell verwenden, um es für die Zielaufgabe (auch bekannt als die *Downstream*-Aufgabe) zu optimieren.

2.2 Ungelabelte Daten nutzen

Große Architekturen neuronaler Netze benötigen große Mengen an gelabelten Daten, um eine gute Leistung und Generalisierung zu erzielen. Für viele Problembereiche haben wir jedoch keinen Zugang zu großen, gelabelten Datensätzen. Beim selbstüberwachten Lernen können wir ungelabelte Daten nutzen. Daher ist selbstüberwachtes Lernen beim Arbeiten mit großen neuronalen Netzen und mit einer begrenzten Menge von gelabelten Trainingsdaten höchstwahrscheinlich nützlich.

Transformer-basierte Architekturen, die die Grundlage der LLMs und Vision Transformer bilden, erfordern bekanntermaßen selbstüberwachtes Lernen für das Vortraining, um gute Leistungen zu erzielen.

Für kleine Modelle von neuronalen Netzen wie zum Beispiel mehrschichtige Perzeptrons mit zwei oder drei Schichten wird selbstüberwachtes Lernen in der Regel weder als nützlich noch als notwendig erachtet.

Selbstüberwachtes Lernen ist auch beim herkömmlichen maschinellen Lernen mit nichtparametrischen Modellen wie baumbasierten Random Forests oder Gradient Boosting nicht sinnvoll. Konventionelle baumbasierte Methoden besitzen keine feste Parameterstruktur (im Gegensatz zum Beispiel zu den Gewichtsmatrizen). Daher sind konventionelle baumbasierte Methoden nicht zum Transferlernen fähig und mit selbstüberwachtem Lernen nicht kompatibel.

2.3 Selbstvorhersage und kontrastives selbstüberwachtes Lernen

Es gibt zwei Hauptkategorien des selbstüberwachten Lernens: Selbstvorhersage und kontrastives selbstüberwachtes Lernen. Bei der *Selbstvorhersage*, die in Abbildung 2–3 dargestellt ist, ändern oder verbergen wir normalerweise Teile der Eingabe und trainieren das Modell, um die ursprünglichen Eingaben zu rekonstruieren. Hierfür verwendet man zum Beispiel eine Störungsmaske, die bestimmte Pixel in einem Bild verschleiert.




Abb. 2–3 Selbstvorhersage nach dem Anwenden einer Störungsmaske

Ein klassisches Beispiel ist ein entrauschender Autoencoder, der lernt, Rauschen aus einem Eingabebild zu entfernen. Als Alternative betrachten wir einen maskierten Autoencoder, der die fehlenden Teile eines Bildes rekonstruiert, wie Abbildung 2–4 zeigt.




Abb. 2–4 Ein maskierter Autoencoder, der ein maskiertes Bild rekonstruiert

Methoden zur Selbstvorhersage bei fehlender (maskierter) Eingabe werden häufig auch im Zusammenhang mit der Verarbeitung natürlicher Sprache eingesetzt. Viele generative LLMs, wie zum Beispiel GPT, werden auf eine Vorhersageaufgabe für das nächste Wort trainiert (Kapitel 14 und 17 gehen ausführlicher auf GPT ein). Hier speisen wir das Netz mit Textfragmenten, aus denen es das nächste Wort in der Sequenz vorhersagen muss (wie ich in Kapitel 17 näher erläutern werde).

Beim *kontrastiven selbstüberwachten Lernen* trainieren wir das neuronale Netz, sodass es einen Einbettungsraum lernt, in dem ähnliche Eingaben nahe beieinander und unähnliche Eingaben weit auseinanderliegen. Mit anderen Worten: Wir trainieren das Netz, um Einbettungen zu erzeugen, die den Abstand zwischen

ähnlichen Trainingseingaben minimieren und den Abstand zwischen unähnlichen Trainingsbeispielen maximieren.

Kontrastives Lernen möchte ich nun anhand konkreter Beispiele erörtern. Angenommen, wir haben einen Datensatz, der aus zufälligen Tierbildern besteht. Zunächst zeichnen wir ein zufälliges Bild einer Katze (das Netz kennt das Label nicht, weil wir davon ausgehen, dass der Datensatz ungelabelt ist). Dann wird dieses Katzenbild erweitert, beschädigt oder gestört, indem eine zufällige Rauschschicht hinzugefügt und unterschiedlich beschnitten wird, wie Abbildung 2–5 zeigt.

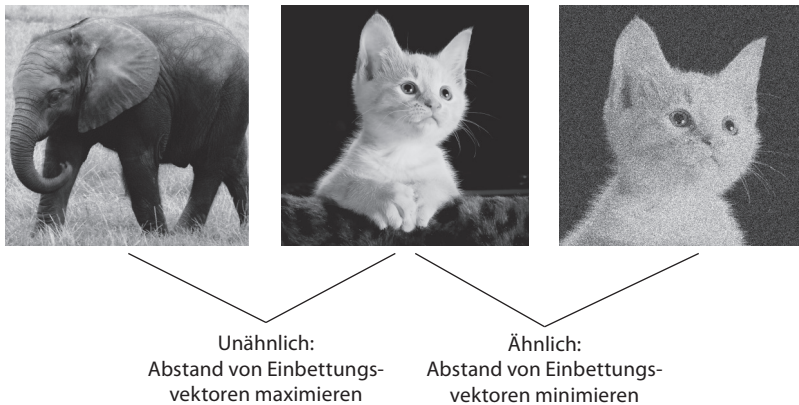


Abb. 2–5 Bildpaare, wie sie beim kontrastiven Lernen auftreten

Das gestörte Katzenbild in dieser Abbildung zeigt immer noch dieselbe Katze, also soll das Netz einen ähnlichen Einbettungsvektor erzeugen. Außerdem betrachten wir ein zufälliges Bild aus der Trainingsmenge (zum Beispiel einen Elefanten, aber auch hier kennt das Netz das Label nicht).

Für das Katzen-Elefanten-Paar soll das Netz unähnliche Einbettungen erzeugen. Auf diese Weise zwingen wir das Netz implizit dazu, den Kerninhalt des Bildes zu erfassen und gleichzeitig gegenüber kleinen Unterschieden und Rauschen einigermaßen agnostisch zu sein. Zum Beispiel ist die einfachste Form eines kontrastiven Verlustes die L_2 -Norm (euklidischer Abstand) zwischen den Einbettungen, die das Modell $M(\cdot)$ erzeugt. Beispielsweise können wir die Modellgewichte aktualisieren, um den Abstand $\|M(\text{cat}) - M(\text{cat?})\|_2$ zu verringern und den Abstand $\|M(\text{cat}) - M(\text{elephant})\|_2$ zu vergrößern.

Abbildung 2–6 fasst das zentrale Konzept des kontrastiven Lernens für das Szenario mit dem gestörten Bild zusammen. Das Modell ist zweimal abgebildet, was als *siamesischer Netzaufbau* bekannt ist. Im Wesentlichen wird dasselbe Modell in zwei Instanzen verwendet: erstens, um die Einbettung für das ursprüngliche Trainingsbeispiel zu generieren, und zweitens, um die Einbettung für die gestörte Version des Beispiels zu erzeugen.

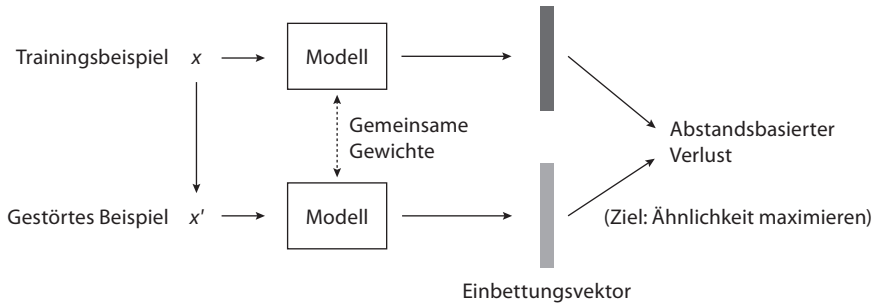


Abb. 2–6 Kontrastives Lernen

Dieses Beispiel skizziert den Grundgedanken des kontrastiven Lernens, von dem es aber viele Untervarianten gibt. Im Großen und Ganzen können wir diese in kontrastive Methoden für *Muster* und kontrastive Methoden für *Dimensionen* kategorisieren. Das Elefanten-Katzen-Beispiel in Abbildung 2–6 veranschaulicht eine beispielhafte kontrastive Methode, bei der wir das Lernen von Einbettungen in den Mittelpunkt stellen und die Abstände zwischen den Trainingspaaren maximieren. Bei *dimensionsbezogenen* kontrastiven Ansätzen konzentrieren wir uns hingegen darauf, nur bestimmte Variablen in den Einbettungsrepräsentationen ähnlicher Trainingspaare nahe beieinander erscheinen zu lassen, während der Abstand anderer maximiert wird.

2.4 Übungen

1. Wie könnte man selbstüberwachtes Lernen auf Videodaten anwenden?
2. Lässt sich selbstüberwachtes Lernen für tabellarische Daten verwenden, die als Zeilen und Spalten dargestellt werden? Wenn ja, wie könnte man dies angehen?

2.5 Referenzen

- Mehr über den ImageNet-Datensatz finden Sie unter: <https://en.wikipedia.org/wiki/ImageNet>.
- Ein Beispiel für eine kontrastive selbstüberwachte Lernmethode: Ting Chen et al., »A Simple Framework for Contrastive Learning of Visual Representations« (2020), <https://arxiv.org/abs/2002.05709>.
- Ein Beispiel für eine dimensionsorientierte kontrastive Methode: Adrien Bardes, Jean Ponce und Yann LeCun, »VICRegL: Self-Supervised Learning of Local Visual Features« (2022), <https://arxiv.org/abs/2210.01571>.
- Wenn Sie vorhaben, selbstüberwachtes Lernen in der Praxis einzusetzen: Randall Balestriero et al., »A Cookbook of Self-Supervised Learning« (2023), <https://arxiv.org/abs/2304.12210>.

- Ein Paper, das eine Methode des Transferlernens und des selbstüberwachten Lernens für relativ kleine mehrschichtige Perzeptrons auf tabellarischen Datensätzen vorschlägt: Dara Bahri et al., »SCARF: Self-Supervised Contrastive Learning Using Random Feature Corruption« (2021), <https://arxiv.org/abs/2106.15147>.
- Ein zweites Paper, das eine derartige Methode vorschlägt: Roman Levin et al., »Transfer Learning with Deep Tabular Models« (2022), <https://arxiv.org/abs/2206.15306>.

Inhaltsverzeichnis

Vorwort	xiii
Danksagungen	xv
Einleitung	xvii

Teil I Neuronale Netze und Deep Learning

1	Einbettungen, latenter Raum und Repräsentationen	3
1.1	Einbettungen	3
1.2	Latenter Raum	5
1.3	Repräsentation	6
1.4	Übungen.	6
1.5	Referenzen	7
2	Selbstüberwachtes Lernen	9
2.1	Selbstüberwachtes Lernen vs. Transferlernen	9
2.2	Ungelabelte Daten nutzen.	11
2.3	Selbstvorhersage und kontrastives selbstüberwachtes Lernen . .	12
2.4	Übungen.	14
2.5	Referenzen	14
3	Few-Shot-Lernen	17
3.1	Datensätze und Terminologie.	17
3.2	Übungen.	20
4	Die Lotterie-Ticket-Hypothese	21
4.1	Das Lotterie-Ticket-Trainingsverfahren	21
4.2	Praktische Konsequenzen und Einschränkungen	22

4.3	Übungen	23
4.4	Referenzen	23
5	Überanpassung mit Daten verringern	25
5.1	Allgemeine Methoden	25
5.2	Übungen	28
5.3	Referenzen	28
6	Überanpassung durch Modellmodifikationen reduzieren	31
6.1	Allgemeine Methoden	31
6.2	Andere Methoden	36
6.3	Eine Regularisierungstechnik auswählen	37
6.4	Übungen	37
6.5	Referenzen	37
7	Multi-GPU-Trainingsparadigmen	39
7.1	Die Trainingsparadigmen	39
7.2	Empfehlungen	43
7.3	Übungen	44
7.4	Referenzen	44
8	Der Erfolg der Transformer	45
8.1	Der Aufmerksamkeitsmechanismus	45
8.2	Vortraining durch selbstüberwachtes Lernen	47
8.3	Große Anzahl von Parametern	47
8.4	Einfache Parallelisierung	48
8.5	Übungen	48
8.6	Referenzen	49
9	Generative KI-Modelle	51
9.1	Generative vs. diskriminative Modellierung	51
9.2	Arten von tiefen generativen Modellen	52
9.3	Empfehlungen	59
9.4	Übungen	60
9.5	Referenzen	60
10	Quellen der Zufälligkeit	61
10.1	Initialisierung der Modellgewichte	61
10.2	Sampling und Shuffling von Datensätzen	62

10.3	Nichtdeterministische Algorithmen	63
10.4	Verschiedene Laufzeitalgorithmen	63
10.5	Hardware und Treiber	64
10.6	Zufälligkeit und generative KI	65
10.7	Übungen.	67
10.8	Referenzen	67

Teil II Computer Vision

11	Die Anzahl der Parameter berechnen	71
11.1	Wie man die Anzahl der Parameter ermittelt	71
11.2	Praktische Anwendungen	75
11.3	Übungen.	75
12	Vollständig verbundene und konvolutionale Schichten	77
12.1	Szenario: Gleiche Größen von Kernel und Eingabe.	78
12.2	Szenario: Kernel-Größe ist 1.	79
12.3	Empfehlungen	79
12.4	Übungen.	80
13	Große Trainingsmengen für Vision Transformer	81
13.1	Induktive Verzerrungen in CNNs.	81
13.2	ViTs können CNNs übertreffen	85
13.3	Induktive Verzerrungen in ViTs	85
13.4	Empfehlungen	87
13.5	Übungen.	87
13.6	Referenzen	87

Teil III Natural Language Processing

14	Die Verteilungshypothese	91
14.1	Word2vec, BERT und GPT	92
14.2	Trifft die Hypothese zu?	93
14.3	Übungen.	94
14.4	Referenzen	94

15	Datenvermehrung für Text	95
15.1	Ersetzen von Synonymen	95
15.2	Löschen von Wörtern	96
15.3	Vertauschen von Wortpositionen	96
15.4	Sätze mischen	97
15.5	Rauschinjektion	97
15.6	Rückübersetzung	98
15.7	Synthetische Daten	98
15.8	Empfehlungen	99
15.9	Übungen	99
15.10	Referenzen	99
16	Selbstaufmerksamkeit	101
16.1	Aufmerksamkeit in RNNs	101
16.2	Der Selbstaufmerksamkeitsmechanismus	103
16.3	Übungen	104
16.4	Referenzen	105
17	Encoder- und Decoder-Transformer	107
17.1	Der ursprüngliche Transformer	107
17.2	Encoder-Decoder-Hybride	112
17.3	Terminologie	112
17.4	Aktuelle Transformer-Modelle	113
17.5	Übungen	114
17.6	Referenzen	114
18	Transformer verwenden und feinabstimmen	117
18.1	Transformer für Klassifizierungsaufgaben verwenden	117
18.2	Kontextbezogenes Lernen, Indizierung und Prompt- Feinabstimmung	120
18.3	Parametereffiziente Feinabstimmung	122
18.4	Reinforcement Learning mit menschlicher Rückmeldung . . .	127
18.5	Vortrainierte Sprachmodelle anpassen	128
18.6	Übungen	128
18.7	Referenzen	129

19	Generative LLMs evaluieren	131
19.1	Bewertungsmetriken für LLMs.	131
19.2	Übungen.	138
19.3	Referenzen	138

Teil IV Produktion und Deployment

20	Zustandsloses und zustandsbehaftetes Training	143
20.1	Zustandsloses (Re-)Training.	143
20.2	Zustandsbehaftetes Training	144
20.3	Übungen.	145
21	Datenzentrierte KI	147
21.1	Datenzentrierte vs. modellzentrierte KI	147
21.2	Empfehlungen	149
21.3	Übungen.	150
21.4	Referenzen	150
22	Inferenz beschleunigen	151
22.1	Parallelisierung.	151
22.2	Vektorisierung	152
22.3	Schleifenkachelung.	153
22.4	Operatorfusion.	154
22.5	Quantisierung	155
22.6	Übungen.	156
22.7	Referenzen	156
23	Datenverteilungsverschiebungen	157
23.1	Kovariatenverschiebung	157
23.2	Labelverschiebung	158
23.3	Konzeptverschiebung	159
23.4	Domänenverschiebung	159
23.5	Arten von Datenverteilungsverschiebungen	160
23.6	Übungen.	161
23.7	Referenzen	161

Teil V Vorhersageperformance und Modellevaluierung

24	Poisson- und ordinale Regression	165
24.1	Übungen	166
25	Konfidenzintervalle	167
25.1	Konfidenzintervalle definieren.	167
25.2	Die Methoden	170
25.3	Empfehlungen	175
25.4	Übungen	175
25.5	Referenzen	175
26	Konfidenzintervalle vs. konforme Vorhersagen	177
26.1	Konfidenzintervalle und Vorhersageintervalle	177
26.2	Vorhersageintervalle und konforme Vorhersagen	178
26.3	Vorhersagebereiche, -intervalle und -mengen.	178
26.4	Konforme Vorhersagen berechnen	179
26.5	Beispiel für eine konforme Vorhersage	180
26.6	Die Vorteile der konformen Vorhersagen	181
26.7	Empfehlungen	182
26.8	Übungen	182
26.9	Referenzen	183
27	Geeignete Metriken	185
27.1	Die Kriterien	185
27.2	Der mittlere quadratische Fehler	186
27.3	Der Kreuzentropieverlust	188
27.4	Übungen	189
28	Das k in der k-fachen Kreuzvalidierung	191
28.1	Kompromisse bei der Auswahl von Werten für k	192
28.2	Geeignete Werte für k bestimmen	194
28.3	Übungen	194
28.4	Referenzen	195
29	Diskordanz zwischen Trainings- und Testdatensatz	197
29.1	Übungen	199

30	Begrenzte gelabelte Daten	201
30.1	Die Modellperformance mit begrenzten gelabelten Daten verbessern	201
30.2	Empfehlungen	210
30.3	Übungen.	211
30.4	Referenzen	212
	Nachwort	213
	Lösungen zu den Übungen	215
	Index	235