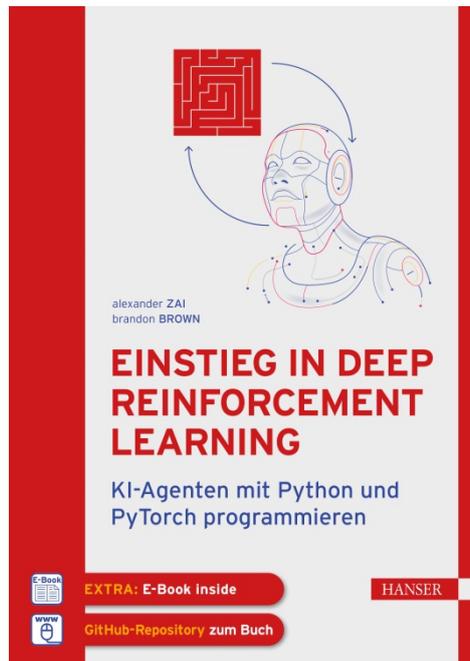


# HANSER



## Leseprobe

zu

## „Einstieg in Deep Reinforcement Learning“

von Alexander Zai und Brandon Brown

Print-ISBN: 978-3-446-45900-7

E-Book-ISBN: 978-3-446-46608-1

E-Pub-ISBN: 978-3-446-46609-8

Weitere Informationen und Bestellungen unter  
<http://www.hanser-fachbuch.de/978-3-446-45900-7>

sowie im Buchhandel

© Carl Hanser Verlag, München

# Inhalt

<b>Vorwort</b> .....	<b>XI</b>
Danksagung .....	XII
Die Autoren .....	XII
 <b>Über dieses Buch</b> .....	 <b>XIII</b>
 <b>Teil I: Grundlagen</b> .....	 <b>1</b>
 <b>1 Was ist Reinforcement Learning?</b> .....	 <b>3</b>
1.1 Das „Tiefe“ beim Deep Reinforcement Learning .....	4
1.2 Reinforcement Learning .....	6
1.3 Dynamische Programmierung versus Monte Carlo .....	9
1.4 Das Reinforcement-Learning-Framework .....	11
1.5 Was kann ich mit Reinforcement Learning anfangen? .....	15
1.6 Warum Deep Reinforcement Learning? .....	17
1.7 Unser didaktisches Werkzeug: String-Diagramme .....	20
1.8 Wie geht es weiter? .....	22
1.9 Zusammenfassung .....	23
 <b>2 Modellierung von Reinforcement-Learning-Problemen: Markov Decision Processes</b> .....	 <b>25</b>
2.1 String-Diagramme und unsere Lehrmethoden .....	25
2.2 Multi-Armed-Bandit-Problem .....	30
2.2.1 Erkundung und Ausnutzung .....	31
2.2.2 Epsilon-greedy-Strategie .....	32
2.2.3 Softmax-Auswahlverfahren .....	37
2.3 Anwendung von Banditen zur Optimierung von Anzeigenplatzierungen .....	40
2.3.1 Kontextabhängige Banditen .....	41
2.3.2 Zustände, Aktionen, Belohnungen .....	42
2.4 Netzwerke mit PyTorch erstellen .....	43
2.4.1 Automatische Differenzierung .....	44
2.4.2 Modelle erstellen .....	44

2.5	Lösen kontextabhängiger Banditen . . . . .	45
2.6	Die Markov-Eigenschaft . . . . .	51
2.7	Vorhersage zukünftiger Belohnungen: Value- und Policy-Funktionen . . . . .	53
2.7.1	Policy-Funktionen. . . . .	54
2.7.2	Optimale Policy. . . . .	55
2.7.3	Wert-Funktionen. . . . .	56
2.8	Zusammenfassung . . . . .	57
<b>3</b>	<b>Vorhersage der besten Zustände und Aktionen:</b>	
	<b>Deep Q-Networks . . . . .</b>	<b>59</b>
3.1	Die Q-Funktion . . . . .	59
3.2	Navigieren mit Q-Learning. . . . .	61
3.2.1	Was ist Q-Learning? . . . . .	62
3.2.2	Gridworld bewältigen. . . . .	63
3.2.3	Hyperparameter . . . . .	65
3.2.4	Diskontierungsfaktor . . . . .	65
3.2.5	Aufbau des Netzwerks . . . . .	66
3.2.6	Einführung in die Gridworld-Spiele-Engine. . . . .	68
3.2.7	Ein neuronales Netz als Q-Funktion. . . . .	71
3.3	Verhinderung katastrophalen Vergessens: Auf Erfahrung basiertes Wiederholungsspiel . . . . .	81
3.3.1	Katastrophales Vergessen . . . . .	81
3.3.2	Auf Erfahrung basiertes Wiederholungsspiel . . . . .	83
3.4	Verbesserung der Stabilität mit einem Target Network . . . . .	87
3.4.1	Lerninstabilität . . . . .	88
3.5	Rückblick . . . . .	93
3.6	Zusammenfassung . . . . .	96
<b>4</b>	<b>Lernen, die beste Policy auszuwählen:</b>	
	<b>Policy-Gradient-Methoden. . . . .</b>	<b>97</b>
4.1	Policy-Funktion mit neuronalen Netzen. . . . .	98
4.1.1	Neuronales Netz als Policy-Funktion . . . . .	98
4.1.2	Stochastischer Policy-Gradient . . . . .	99
4.1.3	Erkundung. . . . .	102
4.2	Verstärkung guter Aktionen: Der Policy-Gradient-Algorithmus . . . . .	102
4.2.1	Definieren eines Ziels . . . . .	103
4.2.2	Verstärkung der Aktionen. . . . .	104
4.2.3	Log-Wahrscheinlichkeit . . . . .	106
4.2.4	Anerkennungszuweisung . . . . .	107
4.3	Arbeiten mit OpenAI Gym . . . . .	108
4.3.1	CartPole . . . . .	110
4.3.2	Die OpenAI Gym-API . . . . .	111
4.4	Der REINFORCE-Algorithmus . . . . .	112

4.4.1	Erstellen des Policy-Netzwerks	112
4.4.2	Interaktion des Agenten mit der Umgebung	113
4.4.3	Das Modell trainieren	114
4.4.4	Die vollständige Trainingsschleife	116
4.4.5	Schlussfolgerung	118
4.5	Zusammenfassung	119
<b>5</b>	<b>Bewältigung komplexerer Probleme mit Actor-Critic-Methoden</b>	<b>121</b>
5.1	Die Kombination von Wert- und Policy-Funktion	123
5.2	Verteiltes Training	128
5.3	Advantage-Actor-Critic	134
5.4	N-step-Actor-Critic	143
5.5	Zusammenfassung	148

## Teil II: Darüber hinaus . . . . . 151

<b>6</b>	<b>Alternative Optimierungsmethoden: Evolutionäre Algorithmen</b>	<b>153</b>
6.1	Ein anderer Ansatz für das Reinforcement Learning	154
6.2	Reinforcement Learning mit Evolutionsstrategien	155
6.2.1	Evolution in der Theorie	155
6.2.2	Entwicklung in der Praxis	159
6.3	Ein genetischer Algorithmus für CartPole	164
6.4	Vor- und Nachteile von evolutionären Algorithmen	170
6.4.1	Evolutionäre Algorithmen erforschen mehr	170
6.4.2	Evolutionäre Algorithmen sind unglaublich testintensiv	171
6.4.3	Simulatoren	172
6.5	Evolutionäre Algorithmen als skalierbare Alternative	172
6.5.1	Skalierung evolutionärer Algorithmen	173
6.5.2	Parallele vs. serielle Verarbeitung	174
6.5.3	Skalierungseffizienz	175
6.5.4	Kommunikation zwischen Knoten	176
6.5.5	Lineare Skalierung	178
6.5.6	Auf Gradienten basierte Ansätze zur Skalierung	178
6.6	Zusammenfassung	179
<b>7</b>	<b>Verteilungs-DQN: Die ganze Geschichte</b>	<b>181</b>
7.1	Was ist falsch an Q-Learning?	182
7.2	Wahrscheinlichkeitsrechnung und Statistik	187
7.2.1	A priori und A posteriori	189
7.2.2	Erwartung und Varianz	190
7.3	Die Bellman-Gleichung	194

7.4	Verteilungs-Q-Learning .....	196
7.4.1	Darstellung einer Wahrscheinlichkeitsverteilung in Python.....	197
7.4.2	Implementierung des Dist-DQN .....	206
7.5	Vergleich von Wahrscheinlichkeitsverteilungen .....	208
7.6	Dist-DQN auf simulierten Daten .....	213
7.7	Verwendung von Verteilungs-Q-Learning zum Spielen von Freeway .....	218
7.8	Zusammenfassung .....	224
<b>8</b>	<b>Von Neugierde getriebene Erkundung.....</b>	<b>225</b>
8.1	Mit prädiktiver Kodierung gegen spärliche Belohnungen vorgehen.....	227
8.2	Vorhersage der inversen Dynamik .....	230
8.3	Implementierung von Super Mario Bros.....	234
8.4	Vorverarbeitung und das Q-Netz.....	236
8.5	Einrichten des Q-Netz und der Policy-Funktion.....	238
8.6	Intrinsisches Neugierde-Modul .....	242
8.7	Alternative intrinsische Belohnungsmechanismen .....	255
8.8	Zusammenfassung .....	258
<b>9</b>	<b>Lernen mit Multi-Agent Reinforcement Learning.....</b>	<b>259</b>
9.1	Von einem zu vielen Agenten .....	259
9.2	Nachbarschafts-Q-Learning .....	264
9.3	Das 1D-Ising-Modell .....	267
9.4	Mean-Field-Q-Learning und das 2D-Ising-Modell .....	278
9.5	Gemischte kooperativ-konkurrierende Spiele .....	288
9.6	Zusammenfassung .....	299
<b>10</b>	<b>Interpretierbares Reinforcement Learning: Aufmerksamkeitsmodelle und relationale Modelle .....</b>	<b>301</b>
10.1	Interpretierbarkeit von Machine Learning mit Aufmerksamkeit und relationalen Verzerrungen .....	302
10.1.1	Invarianz und Äquivarianz .....	304
10.2	Relationale Argumentation mit Aufmerksamkeit .....	306
10.2.1	Aufmerksamkeitsmodelle .....	306
10.2.2	Relationale Argumentation .....	308
10.2.3	Self-Attention-Modelle .....	314
10.3	Implementierung der Self-Attention für MNIST .....	317
10.3.1	Transformiertes MNIST .....	317
10.3.2	Das relationale Modul .....	319
10.3.3	Tensorverjüngungen und Einstein-Notation .....	322
10.3.4	Training des relationalen Moduls.....	326
10.4	Multi-Head Attention und relationales DQN .....	330
10.5	Double Q-Learning .....	338
10.6	Training und Aufmerksamkeitsvisualisierung .....	339

10.6.1	Maximum Entropy Learning	343
10.6.2	Curriculum Learning	344
10.6.3	Visualisierung von Aufmerksamkeitsgewichten	344
10.7	Zusammenfassung	348
<b>11</b>	<b>Abschließend: Rückblick und Fahrplan</b>	<b>351</b>
11.1	Was haben wir gelernt?	351
11.2	Die unergründeten Themen des Deep Reinforcement Learning	353
11.2.1	Priorisiertes auf Erfahrung basiertes Wiederholungsspiel	354
11.2.2	Proximal-Policy-Optimierung (PPO)	354
11.2.3	Hierarchisches Reinforcement Learning und das Options Framework	355
11.2.4	Modellbasierte Planung	356
11.2.5	Monte-Carlo-Baumsuche (MCTS)	357
11.3	Das Ende	358
	<b>Anhang: Mathematik, Deep Learning, PyTorch</b>	<b>359</b>
A.1	Lineare Algebra	359
A.2	Analysis	361
A.3	Deep Learning	366
A.4	PyTorch	367
	<b>Literaturverzeichnis</b>	<b>371</b>
	<b>Stichwortverzeichnis</b>	<b>375</b>

# Vorwort

Deep Reinforcement Learning rückte 2015 ins Rampenlicht, als DeepMind einen Algorithmus entwickelte, der in der Lage ist, eine Reihe von Atari-2600-Spielen besser als der Mensch zu spielen. Die künstliche Intelligenz schien endlich echte Fortschritte zu machen, und wir wollten unseren Teil dazu beitragen.

Wir haben beide einen Hintergrund im Software-Engineering und Interesse an den Neurowissenschaften, und wir interessieren uns schon seit Langem für das breitere Feld der künstlichen Intelligenz (tatsächlich hat einer von uns sein erstes neuronales Netz noch vor der High School in C# geschrieben). Diese frühen Erfahrungen führten zu keinem anhaltenden Interesse, da sie in die Zeit vor der Revolution des Deep Learning um das Jahr 2012 fielen, als die überragende Leistung des Deep Learning deutlich wurde. Aber nachdem wir die erstaunlichen Erfolge des Deep Learning gesehen hatten, wandten wir uns wieder den aufregenden und aufblühenden Bereichen des Deep Learning und dann des Deep Reinforcement Learning zu, und wir beide haben das Machine Learning auf die eine oder andere Weise stärker in unsere berufliche Laufbahn integriert. Alex wechselte in eine Karriere als Machine Learning Engineer und machte sich an wenig bekannten Orten wie Amazon einen Namen, und Brandon begann, Machine Learning in der akademischen neurowissenschaftlichen Forschung einzusetzen. Als wir uns in Deep Reinforcement Learning vertieften, mussten wir uns durch Dutzende von Lehrbüchern und Forschungsartikeln kämpfen, wobei wir uns in fortgeschrittene Mathematik und die Theorie des maschinellen Lernens vertieften. Wir stellten jedoch fest, dass die Grundlagen des Deep Reinforcement Learning durchaus zugänglich sind, wenn man einen Hintergrund im Software-Engineering hat. Die gesamte Mathematik lässt sich leicht in eine Sprache übersetzen, die für jeden Programmierer gut lesbar ist.

Wir begannen, über die Dinge zu bloggen, die wir in der Welt des Machine Learning lernten, und über Projekte, die wir bei unserer Arbeit verwendeten. Am Ende bekamen wir eine ganze Menge positives Feedback, was uns auf die Idee brachte, gemeinsam an diesem Buch zu arbeiten. Wir sind der Meinung, dass die meisten Ressourcen, die es zum Lernen komplexer Dinge gibt, entweder zu einfach sind und die fesselndsten Aspekte des Themas auslassen oder für Menschen ohne fortgeschrittenen mathematischen Hintergrund unzugänglich sind. Mit diesem Buch haben wir uns bemüht, ein für Experten geschriebenes Kompendium in einen Kurs für diejenigen zu übersetzen, die nichts weiter als einen Programmierhintergrund und einige Grundkenntnisse über neuronale Netze haben. Wir wenden einige neuartige Lehrmethoden an, von denen wir glauben, dass sie unser Buch auszeichnen und zu einem viel schnelleren Verständnis führen. Wir fangen bei den Grundlagen an, und am Ende werden Sie innovative Algorithmen implementieren, die von industriellen Forschungsprojekten wie DeepMind und OpenAI sowie von leistungsstarken akademischen Einrichtungen wie dem Berkeley Artificial Intelligence Research (BAIR) Lab und dem University College London entwickelt wurden.

## ■ Danksagung

Dieses Buch hat viel länger gedauert, als wir erwartet hatten, und wir haben unseren Lektorinnen Candace West und Susanna Kline viel zu verdanken. Sie haben uns in jeder Phase des Prozesses geholfen und uns auf Kurs gehalten. Wenn man ein Buch schreibt, muss man viele Details im Auge behalten, und ohne das professionelle und unterstützende Lektorenteam wären wir ins Schwimmen geraten.

Unser Dank gilt auch unseren technischen Redakteuren Marc-Philippe Huget und Al Krinker sowie allen Gutachtern, die sich die Zeit genommen haben, unser Manuskript zu lesen und uns entscheidendes Feedback zu geben. Unser besonderer Dank gilt den Gutachtern Al Rahimi, Ariel Gamiño, Claudio Bernardo Rodriguez, David Krief, Dr. Brett Pennington, Ezra Joel Schroeder, George L. Gaines, Godfred Asamoah, Helmut Hauschild, Ike Okonkwo, Jonathan Wood, Kalyan Reddy, M. Edward (Ed) Borasky, Michael Haller, Nadia Noori, Satyajit Sarangi und Tobias Kaatz. Wir möchten auch allen bei Manning danken, die an diesem Projekt mitgearbeitet haben: Karen Miller (Developmental Editor), Ivan Martinović (Review Editor), Deirdre Hiam (Project Editor), Andy Carroll (Copy Editor) und Jason Everett (Proofreader).

In der heutigen Zeit werden viele Bücher über verschiedene Online-Dienste im Selbstverlag herausgegeben, und diese Option hat uns zunächst gereizt. Nachdem wir jedoch diesen ganzen Prozess durchlaufen haben, können wir den enormen Wert eines professionellen Lektorats erkennen. Insbesondere danken wir dem Copy Editor Andy Carroll für sein aufschlussreiches Feedback, das die Klarheit des Textes wesentlich verbessert hat.

Alex bedankt sich bei seinem PI Jamie, der ihn bereits während seines Grundstudiums an Machine Learning herangeführt hat.

Brandon dankt seiner Frau Xinzhu dafür, dass sie seine langen Nächte am Schreibtisch und seine Abwesenheit von der Familie erduldet und ihm zwei wunderbare Kinder, Isla und Avin, geschenkt hat.

## ■ Die Autoren

ALEX ZAI arbeitete als Chief Technology Officer bei Codesmith, einem immersiven Coding-Bootcamp, wo er weiterhin als Technical Advisor tätig ist, sowie als Software-Ingenieur bei Uber und als Machine Learning Engineer bei Banjo und Amazon. Darüber hinaus wirkt er am Open-Source Deep-Learning-Framework Apache MXNet mit. Er hat zwei Unternehmen mitbegründet, von denen eines durch Y Combinator gefördert wurde.

BRANDON BROWN beschäftigte sich von klein auf mit dem Programmieren und arbeitete während des Studiums als Teilzeit-Software-Ingenieur, entschied sich aber schließlich für eine Karriere in der Medizin; nebenbei arbeitete er als Software-Ingenieur im Bereich der Gesundheitstechnologie. Heute ist er Arzt und verfolgt seine Forschungsinteressen im Bereich der Computational Psychiatry, inspiriert durch Deep Reinforcement Learning.

# 1

## Was ist Reinforcement Learning?



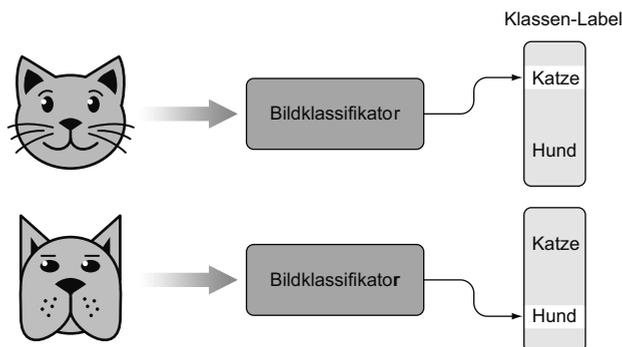
### Dieses Kapitel beinhaltet:

- einen kurzen Überblick über Machine Learning (maschinelles Lernen),
- die Einführung von Reinforcement Learning (bestärkendes Lernen – RL) als Teilbereich,
- das grundlegende Framework (Programmiergerüst) des Reinforcement Learning.

*Computersprachen der Zukunft werden sich mehr mit Zielen und weniger mit vom Programmierer vorgegebenen Prozeduren beschäftigen.*

Marvin Minsky, 1970 ACM-Turing-Vorlesung

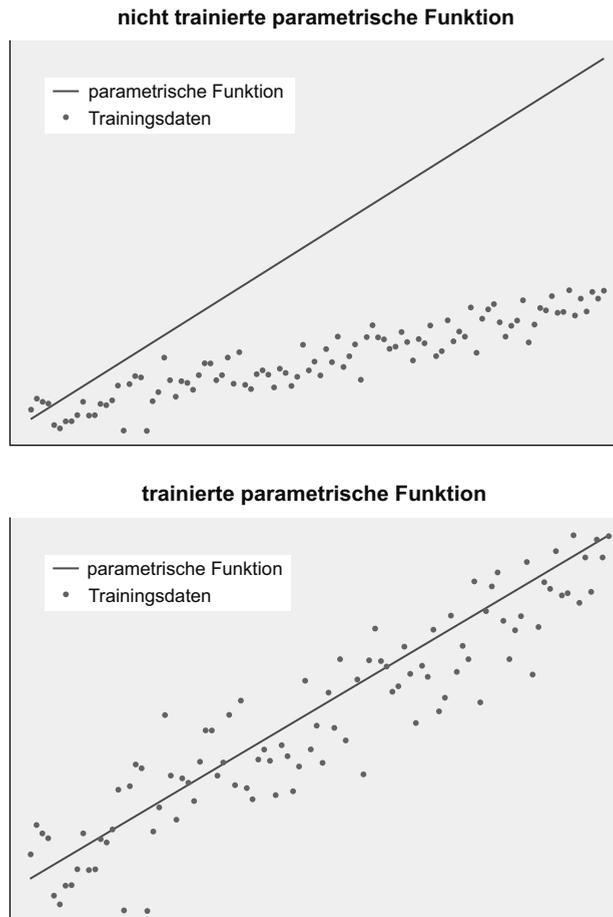
Wenn Sie dieses Buch lesen, sind Sie wahrscheinlich damit vertraut, wie tiefe neuronale Netze für Dinge wie Bildklassifikation oder Vorhersagen verwendet werden (und wenn nicht, lesen Sie einfach weiter; wir haben auch einen Crash-Kurs zu Deep Learning (tiefem Lernen) im Anhang). *Deep Reinforcement Learning* (DRL) ist ein Teilgebiet des Machine Learning, das Deep-Learning-Modelle (d. h. neuronale Netze) für Reinforcement-Learning-(RL)-Aufgaben (siehe Abschnitt 1.2 verwendet. Bei der Bildklassifizierung haben wir eine Menge von Bildern, die einer Reihe von diskreten Kategorien entsprechen, wie z. B. Bilder von verschiedenen Tierarten, und wir möchten, dass ein Machine-Learning-Modell ein Bild interpretiert und die Tierart auf dem Bild klassifiziert (siehe Bild 1.1).



**Bild 1.1** Ein Bildklassifikator ist eine Funktion oder ein Lernalgorithmus, der ein Bild aufnimmt und ein Klassenlabel zurückgibt, das das Bild einer Kategorie oder Klasse zuordnet, die aus einer endlichen Anzahl möglicher Kategorien ausgewählt wurde.

## ■ 1.1 Das „Tiefe“ beim Deep Reinforcement Learning

Deep-Learning-Modelle sind nur eine von vielen Arten von Machine-Learning-Modellen, die wir zur Klassifikation von Bildern verwenden können. Im Allgemeinen brauchen wir nur eine Art Funktion, die ein Bild aufnimmt und ein Klassenlabel zurückgibt (in diesem Fall das Label, das angibt, welche Art von Tier im Bild dargestellt ist), und normalerweise hat diese Funktion einen festen Satz einstellbarer *Parameter* – wir nennen diese Art von Modellen



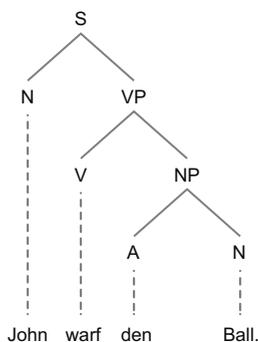
**Bild 1.2** Das vielleicht einfachste Machine-Learning-Modell ist eine lineare Funktion der Form  $f(x) = mx + b$  mit den Parametern  $m$  (die Steigung) und  $b$  (der Achsenabschnitt). Da es einstellbare Parameter hat, nennen wir es eine *parametrische* Funktion oder ein *parametrisches* Modell. Wenn wir einige zweidimensionale Daten haben, können wir mit einem zufällig initialisiertem Satz von Parametern beginnen, wie z. B.  $[m = 3,4, b = 0,3]$ , und dann einen Trainingsalgorithmus verwenden, um die Parameter so zu optimieren, dass sie zu den Trainingsdaten passen, wobei der optimale Satz von Parametern nahe bei  $[m = 2, b = 1]$  liegt.

*parametrische* Modelle. Wir beginnen mit einem parametrischen Modell, dessen Parameter mit Zufallswerten initialisiert werden – dies erzeugt zufällige Klassenlabels für die Eingabebilder. Dann verwenden wir eine *Trainingsprozedur*, um die Parameter so anzupassen, dass die Funktion iterativ immer besser darin wird, die Bilder korrekt zu klassifizieren. Irgendwann werden die Parameter bei einem optimalen Satz von Werten liegen, was bedeutet, dass das Modell bei der Klassifizierungsaufgabe nicht mehr besser werden kann. Parametrische Modelle können auch für die *Regression* verwendet werden, bei der wir versuchen, ein Modell an einen Datensatz anzupassen, damit wir Vorhersagen für ungesehene Daten machen können (Bild 1.2). Ein ausgefeilterer Ansatz könnte sogar noch besser funktionieren, wenn er mehr Parameter oder eine bessere interne Architektur hätte.

Tiefe neuronale Netze sind beliebt, weil sie in vielen Fällen die genauesten parametrischen Machine-Learning-Modelle für eine bestimmte Aufgabe, wie z. B. die Bildklassifikation, sind. Dies ist weitgehend auf die Art und Weise zurückzuführen, wie sie Daten repräsentieren. Tiefe neuronale Netze haben viele Schichten (daher die „Tiefe“), was das Modell dazu veranlasst, geschichtete Darstellungen von Eingabedaten zu lernen. Diese Schichtdarstellung ist eine Form der Kompositionalität, was bedeutet, dass ein komplexes Datenstück als Kombination von elementarerer Komponenten dargestellt wird, und diese Komponenten können weiter in noch einfachere Komponenten zerlegt werden, und so weiter, bis man zu atomaren Einheiten gelangt.

Die menschliche Sprache ist kompositorisch (Bild 1.3). Ein Buch besteht zum Beispiel aus Kapiteln, Kapitel aus Absätzen, Absätze aus Sätzen usw., bis man zu einzelnen Wörtern kommt, die die kleinsten Bedeutungseinheiten darstellen. Doch jede einzelne Ebene vermittelt Bedeutung – ein ganzes Buch soll Bedeutung vermitteln, und seine einzelnen Absätze sollen kleinere Punkte vermitteln.

Tiefe neuronale Netze können ebenfalls eine kompositorische Darstellung von Daten erlernen – sie können beispielsweise ein Bild als die Zusammensetzung primitiver Konturen und Texturen darstellen, die in elementare Formen zusammengesetzt werden, und so weiter, bis man ein vollständiges, komplexes Bild erhält. Diese Fähigkeit, Komplexität mit kompositorischen Darstellungen zu handhaben, macht Deep Learning so wirkungsvoll.

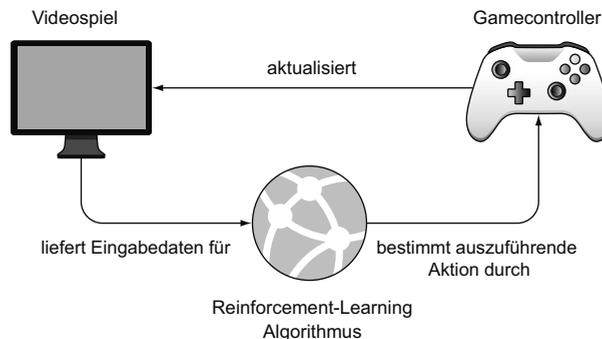


**Bild 1.3** Ein Satz wie „John warf den Ball „ kann in immer einfachere Teile zerlegt werden, bis wir die einzelnen Wörter erhalten. In diesem Fall können wir den Satz (mit S bezeichnet) in ein Nomen (N) und eine Verbalphrase (VP) zerlegen. Die VP kann weiter in ein Verb „warf“ und eine Nominalphrase (NP) zerlegt werden. Die NP kann dann in die einzelnen Wörter „den“ und „Ball“ zerlegt werden.

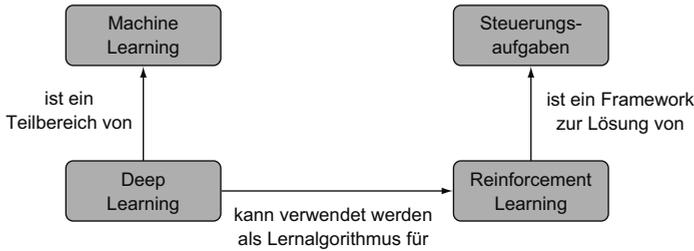
## ■ 1.2 Reinforcement Learning

Es ist wichtig, zwischen Problemen und ihren Lösungen zu unterscheiden oder, mit anderen Worten, zwischen den Aufgaben, die wir lösen wollen, und den Algorithmen, die wir zu ihrer Lösung entwerfen. Deep-Learning-Algorithmen können auf viele Problemtypen und Aufgaben angewendet werden. Bildklassifikations- und Vorhersageaufgaben sind häufige Anwendungen des Deep Learning, da die automatisierte Bildverarbeitung vor dem Deep Learning angesichts der Komplexität der Bilder sehr begrenzt war. Aber es gibt noch viele andere Aufgaben, die wir vielleicht automatisieren möchten, wie zum Beispiel Autofahren oder das Ausbalancieren eines Portfolios von Aktien und anderen Vermögenswerten. Zum Autofahren gehört ein gewisses Maß an Bildverarbeitung, aber noch wichtiger ist, dass der Algorithmus lernen muss, wie er *sich verhalten* muss, und nicht nur klassifizieren oder vorhersagen kann. Diese Probleme, bei denen Entscheidungen getroffen werden müssen oder bestimmte Verhaltensweisen umgesetzt werden müssen, werden kollektiv als *Steuerungsaufgaben* bezeichnet.

*Reinforcement Learning* ist ein generisches Framework für die Darstellung und Lösung von Steuerungsaufgaben, aber innerhalb dieses Rahmens können wir frei wählen, welche Algorithmen wir auf eine bestimmte Steuerungsaufgabe anwenden wollen (Bild 1.4). Deep-Learning-Algorithmen sind dafür prädestiniert, da sie in der Lage sind, komplexe Daten effizient zu verarbeiten. Aus diesem Grund konzentrieren wir uns auf *Deep Reinforcement Learning*, aber vieles von dem, was Sie in diesem Buch lernen werden, ist das allgemeine Reinforcement-Framework für Steuerungsaufgaben (siehe Bild 1.5). Dann werden wir uns ansehen, wie Sie ein geeignetes Deep-Learning-Modell modellieren können, das zum Framework passt und eine Aufgabe löst. Das bedeutet, dass Sie eine Menge über Reinforcement Learning lernen werden, und Sie werden wahrscheinlich auch einiges über Deep Learning lernen, was Sie bisher noch nicht wussten.

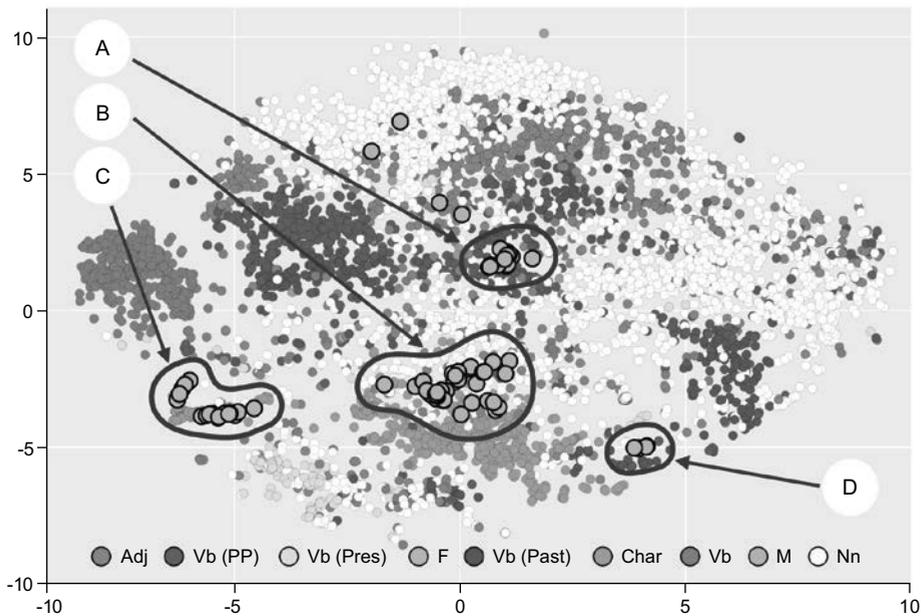


**Bild 1.4** Im Gegensatz zu einem Bildklassifikator interagiert ein Reinforcement-Learning-Algorithmus dynamisch mit Daten. Er konsumiert kontinuierlich Daten und entscheidet, welche Aktionen durchgeführt werden sollen – Aktionen, die die ihm nachfolgend präsentierten Daten verändern. Ein Videospielbildschirm könnte die Eingabedaten für einen RL-Algorithmus darstellen, der dann unter Verwendung des Gamecontrollers entscheidet, welche Aktion zu ergreifen ist, und dies bewirkt eine Aktualisierung des Spiels (z. B. der Spieler bewegt sich oder feuert eine Waffe ab).



**Bild 1.5** Deep Learning ist ein Teilbereich des Machine Learning. Deep-Learning-Algorithmen können zur Unterstützung von RL-Ansätzen zur Lösung von Steuerungsaufgaben verwendet werden.

Eine zusätzliche Komplexität beim Übergang von der Bildverarbeitung zum Bereich der Steuerungsaufgaben bringt das Element der Zeit mit sich. Bei der Bildverarbeitung trainieren wir normalerweise einen Deep-Learning-Algorithmus an einem festen Datensatz von Bildern. Nach einer ausreichenden Menge an Training erhalten wir in der Regel einen Hochleistungsalgorithmus, den wir auf einige neue, ungesehene Bilder anwenden können. Wir können uns den Datensatz als einen „Datenraum“ vorstellen, in dem ähnliche Bilder in diesem abstrakten Raum näher beieinander liegen und unterschiedliche Bilder weiter voneinander entfernt sind (Bild 1.6).



**Bild 1.6** Diese grafische Darstellung von Wörtern in einem 2-D-Raum zeigt jedes Wort als einen farbigen Punkt. Ähnliche Wörter gruppieren sich und unähnliche Wörter liegen weiter auseinander. Daten leben natürlich in einer Art „Raum“, wobei ähnliche Daten näher beieinander leben. Die Labels A, B, C und D weisen auf bestimmte Cluster von Wörtern hin, die eine gemeinsame Semantik haben.

Bei Kontrollaufgaben haben wir in ähnlicher Weise einen Raum von zu verarbeitenden Daten, aber jede Dateneinheit hat auch eine zeitliche Dimension – Daten existieren in Zeit und Raum. Das bedeutet, dass das, was der Algorithmus zu einem bestimmten Zeitpunkt entscheidet, von dem beeinflusst wird, was zu einem früheren Zeitpunkt geschah. Dies ist bei gewöhnlicher Bildklassifizierung und ähnlichen Problemen nicht der Fall. Die Zeit macht die Trainingsaufgabe dynamisch – der Datensatz, auf dem der Algorithmus trainiert, ist nicht unbedingt fixiert, sondern ändert sich aufgrund der Entscheidungen, die der Algorithmus trifft.

Gewöhnliche bildklassifikationsähnliche Aufgaben fallen in die Kategorie des *Supervised Learning* (überwachtes Lernen), da der Algorithmus darauf trainiert wird, Bilder richtig zu klassifizieren, indem er die richtigen Antworten gibt. Der Algorithmus stellt zunächst nach dem Zufallsprinzip Vermutungen an, und er wird iterativ korrigiert, bis er die Features (Merkmale) im Bild lernt, die dem passenden Label entsprechen. Dies setzt voraus, dass wir bereits wissen, was die richtigen Antworten sind, was umständlich sein kann. Wenn Sie einen Deep-Learning-Algorithmus trainieren wollen, um Bilder von verschiedenen Pflanzenarten korrekt zu klassifizieren, müssten Sie mühsam Tausende solcher Bilder erfassen, jedem Bild manuell Klassenlabels zuordnen und die Daten in einem Format aufbereiten, mit dem ein Algorithmus für Machine Learning arbeiten kann, in der Regel in einer Art Matrix.

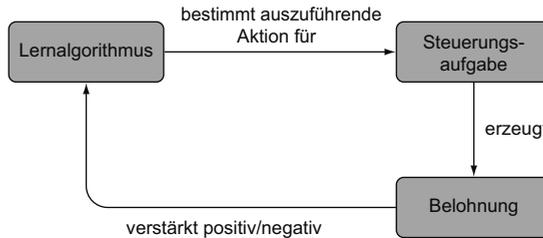
Im Gegensatz dazu wissen wir bei RL nicht bei jedem Schritt genau, was das Richtige ist. Wir müssen nur wissen, was das letztendliche Ziel ist und welche Dinge man vermeiden sollte. Wie bringt man einem Hund einen Trick bei? Man muss ihm Leckerbissen geben. In ähnlicher Weise trainieren wir einen RL-Algorithmus, indem wir ihm einen Anreiz geben, ein hochgestecktes Ziel zu erreichen, und ihn möglicherweise davon abhalten, Dinge zu tun, die wir nicht wollen, dass er sie tut. Im Falle eines selbstfahrenden Autos könnte das hochrangige Ziel sein, „unfallfrei von Ausgangspunkt A aus zu Punkt B zu gelangen“. Wenn er die Aufgabe erfüllt, belohnen wir ihn, und wenn er einen Unfall verursacht, bestrafen wir ihn. Wir würden das alles in einem Simulator machen, statt auf den realen Straßen, sodass wir ihn immer wieder versuchen lassen könnten an der Aufgabe zu scheitern, bis er lernt und belohnt wird.



#### TIPP

In der natürlichen Sprache bedeutet „Belohnung“ immer etwas Positives, während es im Jargon des Reinforcement Learning eine zu optimierende numerische Größe ist. Eine Belohnung kann also positiv oder negativ sein. Wenn sie positiv ist, entspricht sie dem natürlichsprachlichen Gebrauch des Begriffs, wenn sie negativ ist, entspricht sie dem natürlichsprachlichen Wort „Strafe“.

Der Algorithmus hat ein einziges Ziel – die Maximierung seiner Belohnung – und um dieses zu erreichen, muss er mehr elementare Fähigkeiten erlernen, um das Hauptziel zu erreichen. Wir können auch negative Belohnungen liefern, wenn der Algorithmus Dinge tut, die uns nicht gefallen. Da er versucht, seine Belohnung zu maximieren, wird er lernen, Aktionen zu vermeiden, die zu negativen Belohnungen führen. Aus diesem Grund wird es *Reinforcement Learning* genannt: Wir verstärken (*to reinforce*) bestimmte Verhaltensweisen entweder positiv oder negativ durch Belohnungssignale (siehe Bild 1.7). Das ist ganz ähnlich, wie Tiere lernen: Sie lernen, Dinge zu tun, mit denen sie sich gut oder zufrieden fühlen, und Dinge zu vermeiden, die Schmerzen verursachen.



**Bild 1.7** Im RL-Framework entscheidet eine Art Lernalgorithmus, welche Aktionen für eine Steuerungsaufgabe (z. B. das Steuern eines Staubsaugerroboters) durchzuführen sind, und die Aktion führt zu einer positiven oder negativen Belohnung, die diese Aktion positiv oder negativ verstärkt und somit den Lernalgorithmus trainiert.

## ■ 1.3 Dynamische Programmierung versus Monte Carlo

Sie wissen jetzt, dass Sie einen Algorithmus trainieren können, um eine schwierige Aufgabe zu erledigen, indem Sie der Erledigung der Aufgabe eine hohe Belohnung (d. h. positive Verstärkung) zuweisen und Dinge, die wir nicht wollen, negativ bestärken. Lassen Sie uns das konkretisieren. Nehmen wir an, das vorrangige Ziel ist es, einen Staubsaugerroboter so zu trainieren, dass er sich von einem Raum in einem Haus zu seinem Dock, das sich in der Küche befindet, bewegt. Er hat vier Aktionen: nach links, nach rechts, vorwärts und rückwärts gehen. Zu jedem Zeitpunkt muss der Roboter entscheiden, welche dieser vier Aktionen er ausführen soll. Wenn er das Dock erreicht, erhält er eine Belohnung von +100, und wenn er auf seinem Weg an etwas stößt, erhält er eine negative Belohnung von -10. Angenommen, der Roboter verfügt über eine vollständige 3-D-Karte des Hauses und hat die genaue Lage des Docks, aber er weiß immer noch nicht genau, welche Abfolge einfacher Aktionen er ausführen muss, um zum Dock zu gelangen.

Ein Ansatz zur Lösung dieses Problems heißt *dynamische Programmierung* (DP). Er wurde erstmals 1957 von Richard Bellman formuliert. Die dynamische Programmierung sollte besser als *Zielzerlegung* bezeichnet werden, da sie komplexe Probleme löst, indem sie diese in immer kleinere Teilprobleme zerlegt, bis sie zu einem einfachen Teilproblem gelangt, das ohne weitere Informationen gelöst werden kann.

Anstatt zu versuchen, mit einer langen Sequenz primitiver Aktionen zum Dock zu gelangen, kann der Roboter das Problem zunächst in „in diesem Raum bleiben“ versus „diesen Raum verlassen“ zerlegen. Da er über einen vollständigen Plan des Hauses verfügt, weiß er, dass er den Raum verlassen muss, da sich das Dock in der Küche befindet. Er weiß jedoch immer noch nicht, welche Abfolge von Aktionen es ihm erlaubt, den Raum zu verlassen, also gliedert er das Problem weiter auf in „sich auf die Tür zubewegen“ oder „sich von der Tür wegbewegen“. Da sich die Tür näher am Dock befindet und es einen Weg von der Tür zum Dock gibt, weiß der Roboter, dass er sich auf die Tür zubewegen muss, aber auch hier weiß er nicht, mit welcher Abfolge primitiver Aktionen er sich auf die Tür zubewegt.

Schließlich muss er entscheiden, ob er sich nach links, rechts, vorwärts oder rückwärts bewegen soll. Er sieht, dass sich die Tür vor ihm befindet, also bewegt er sich vorwärts. Er hält diesen Prozess aufrecht, bis er den Raum verlässt. Dann muss er noch einige Zielzerlegungen vornehmen, bis er zum Dock gelangt.

Das ist das Wesen der dynamischen Programmierung. Es handelt sich um einen generischen Ansatz zur Lösung bestimmter Arten von Problemen, die sich in Unter- und Teilprobleme zerlegen lassen, und es gibt Anwendungen in vielen Bereichen, darunter Bioinformatik, Wirtschaft und Informatik.

Um die dynamische Programmierung nach Bellman anwenden zu können, müssen wir in der Lage sein, unser Problem in Teilprobleme zu zerlegen, von denen wir wissen, wie sie zu lösen sind. Aber selbst diese scheinbar harmlose Annahme ist in der realen Welt schwer zu verwirklichen. Wie zerlegt man das hochgesteckte Ziel für ein selbstfahrendes Auto, „unfallfrei von Punkt A aus zu Punkt B zu gelangen“, in kleine, unfallfreie Teilprobleme? Lernt ein Kind das Laufen, indem es zuerst die leichteren Teilprobleme löst? In RL, wo wir oft nuancierte Situationen haben, die ein gewisses Zufallsprinzip enthalten, können wir die dynamische Programmierung nicht genau so anwenden, wie Bellman es beschrieben hat. Tatsächlich kann DP als ein Extrem eines Kontinuums von Problemlösungstechniken betrachtet werden, bei dem das andere Ende zufälliges Ausprobieren wäre.

Eine andere Möglichkeit, dieses Lernkontinuum zu betrachten, besteht darin, dass wir in einigen Situationen ein maximales Wissen über die Umgebung haben und in anderen ein minimales Wissen über die Umgebung, und wir müssen in jedem Fall unterschiedliche Strategien anwenden. Wenn Sie die Toilette in Ihrem eigenen Haus benutzen müssen, wissen Sie genau (na ja, zumindest unbewusst), welche Abfolge von Muskelbewegungen Sie von jeder Ausgangsposition aus (d. h. von der dynamischen Programmierung her) zur Toilette bringen wird. Das liegt daran, dass Sie Ihr Haus sehr gut kennen – Sie haben ein mehr oder weniger perfektes *Modell* Ihres Hauses im Kopf. Wenn Sie auf einer Party in einem Haus sind, in dem Sie noch nie zuvor gewesen sind, müssen Sie sich vielleicht lange umschaun, bis Sie die Toilette alleine finden (durch Trial-and-Error), weil Sie kein gutes Modell des Hauses dieser Person haben.

Die Trial-and-Error-Strategie wird im Allgemeinen zu den *Monte-Carlo-Methoden* gezählt. Eine Monte-Carlo-Methode ist im Wesentlichen eine Stichprobe nach dem Zufallsprinzip aus der Umgebung. Bei vielen Problemen der realen Welt haben wir zumindest ein gewisses Wissen über die Umgebungssituation, sodass wir am Ende eine gemischte Strategie aus Trial-and-Error und einer Ausnutzung dessen, was wir bereits über die Umgebung wissen, anwenden, um die einfachen Teilziele direkt zu lösen.

Ein etwas albernes Beispiel für eine gemischte Strategie wäre, wenn man Ihnen die Augen verbindet, Sie an einen unbekannt Ort in Ihrem Haus bringt und Ihnen sagt, Sie sollen das Badezimmer finden, indem Sie Kieselsteine werfen und auf das Geräusch achten. Sie könnten damit beginnen, das übergeordnete Ziel (das Badezimmer zu finden) in ein leichter zugängliches Unterziel zu zerlegen: Finden Sie heraus, in welchem Raum Sie sich gerade befinden. Um dieses Unterziel zu lösen, könnten Sie nach dem Zufallsprinzip ein paar Kieselsteine in zufällige Richtungen werfen und die Größe des Raumes abschätzen, was Ihnen genügend Informationen liefert, um daraus abzuleiten, in welchem Raum Sie sich befinden – sagen wir im Schlafzimmer. Dann müssten Sie zu einem weiteren Unterziel schwenken: zur Tür navigieren, damit Sie den Flur betreten können. Sie würden wieder anfangen, Kieselsteine

zu werfen, aber da Sie sich an die Ergebnisse Ihres letzten nach dem Zufallsprinzip ausgeführten Kieselsteinwurfs erinnern, könnten Sie Ihren Wurf auf weniger sichere Bereiche ausrichten. Durch Iteration dieses Vorgangs könnten Sie schließlich Ihr Badezimmer finden. In diesem Fall würden Sie sowohl die Zielzerlegung der dynamischen Programmierung als auch die Zufallsprinzipien der Monte-Carlo-Methode anwenden.

## ■ 1.4 Das Reinforcement-Learning-Framework

Richard Bellman führte die dynamische Programmierung als eine allgemeine Methode zur Lösung bestimmter Arten von Kontroll- oder Entscheidungsproblemen ein, aber sie nimmt einen der äußersten Punkte des RL-Kontinuums ein. Bellmans wichtigerer Beitrag bestand wohl darin, zur Entwicklung des Standard-Frameworks für RL-Probleme beizutragen. Das RL-Framework ist im Wesentlichen der Kernsatz von Begriffen und Konzepten, in dem jedes RL-Problem formuliert werden kann. Damit steht nicht nur eine standardisierte Sprache für die Kommunikation mit anderen Ingenieuren und Forschern zur Verfügung, sondern wir sind auch gezwungen, unsere Probleme so zu formulieren, dass sie sich einer dynamischen Programmierung – ähnlich der Zerlegung von Problemen – unterwerfen lassen, sodass wir über lokale Unterprobleme hinweg iterativ optimieren und Fortschritte bei der Erreichung des globalen Ziels auf hoher Ebene erzielen können. Glücklicherweise ist das auch ziemlich einfach.

Um das Framework konkret zu veranschaulichen, betrachten wir die Aufgabe des Aufbaus eines RL-Algorithmus, der lernen kann, den Energieverbrauch in einem großen Rechenzentrum zu minimieren. Computer müssen kühl gehalten werden, damit sie gut funktionieren, sodass in großen Rechenzentren erhebliche Kosten durch Kühlsysteme entstehen können. Der schlichte Ansatz, ein Rechenzentrum kühl zu halten, bestünde darin, die Klimaanlage ständig auf einem Niveau zu halten, das dazu führt, dass kein Server jemals zu heiß läuft; dies würde kein ausgefallenes Machine Learning erfordern. Aber das ist ineffizient, und Sie könnten es besser machen, da es unwahrscheinlich ist, dass alle Server im Rechenzentrum zur gleichen Zeit heiß laufen und dass die Auslastung des Rechenzentrums immer auf dem gleichen Niveau ist. Wenn Sie die Kühlung dorthin lenken würden, wo und wann es am wichtigsten ist, könnten Sie dasselbe Ergebnis für weniger Geld erzielen.

Der erste Schritt im Framework ist, Ihr Gesamtziel zu definieren. In diesem Fall besteht unser Gesamtziel darin, die für die Kühlung aufgewendeten Mittel zu minimieren, mit der Einschränkung, dass kein Server in unserem Zentrum eine bestimmte Schwellentemperatur überschreiten darf. Obwohl dies zwei Ziele zu sein scheinen, können wir sie zu einer neuen zusammengesetzten *Zielfunktion* bündeln. Diese Funktion gibt einen Ertrag zurück, der anzeigt, wie weit wir bei der Erreichung der beiden Ziele angesichts der aktuellen Kosten und der Temperaturdaten für die Server vom Ziel abweichen. Die tatsächliche Zahl, die unsere Zielfunktion zurückgibt, ist nicht wichtig; wir wollen sie nur so niedrig wie möglich halten. Daher brauchen wir unseren RL-Algorithmus, um den Ertrag dieser Zielfunktion (Fehler) in Bezug auf einige Eingabedaten zu minimieren, die definitiv die laufenden Kosten und die

Temperaturdaten umfassen, aber auch andere nützliche Kontextinformationen enthalten können, die dem Algorithmus helfen können, die Nutzung des Rechenzentrums vorherzusagen.

Die Eingabedaten werden von der *Umgebung* erzeugt. Im Allgemeinen ist die Umgebung einer RL- (oder Steuerungs-) Aufgabe jeder dynamische Prozess, der Daten erzeugt, die für das Erreichen unseres Ziels relevant sind. Obwohl wir „Umgebung“ als technischen Begriff verwenden, ist er nicht allzu weit von seiner alltäglichen Verwendung abstrahiert. Da Sie selbst ein Beispiel für einen sehr fortschrittlichen RL-Algorithmus sind, befinden Sie sich immer in irgendeiner Umgebung, und Ihre Augen und Ohren nehmen ständig Informationen auf, die von Ihrer Umgebung produziert werden, damit Sie Ihre täglichen Ziele erreichen können. Da die Umgebung ein *dynamischer Prozess* (eine Funktion der Zeit) ist, kann sie einen kontinuierlichen Strom von Daten unterschiedlicher Größe und Art produzieren. Um die Dinge algorithmusfreundlich zu gestalten, müssen wir diese Umgebungsdaten in diskrete Pakete bündeln, die wir den *Zustand* (der Umgebung) nennen, und sie dann in jedem ihrer diskreten Zeitschritte an unseren Algorithmus liefern. Der Zustand spiegelt unser Wissen über die Umgebung zu einem bestimmten Zeitpunkt wider, so wie eine Digitalkamera zu einem bestimmten Zeitpunkt einen einzelnen Schnappschuss einer Szene aufnimmt (und ein konsistent formatiertes Bild erzeugt).

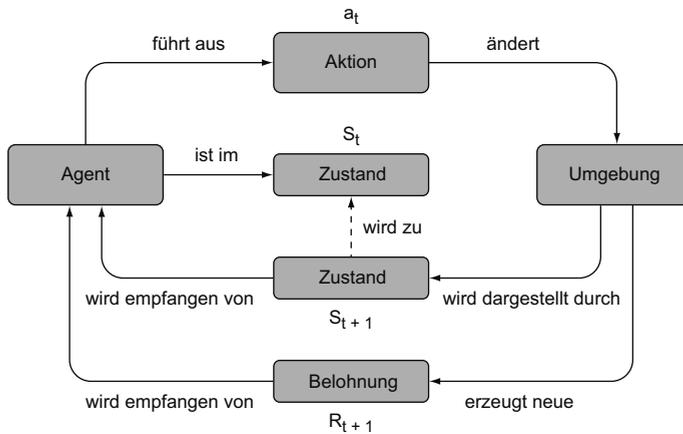
Zusammenfassend lässt sich sagen, dass wir bisher eine Zielfunktion (Minimierung der Kosten durch Optimierung der Temperatur) definiert haben, die eine Funktion des Zustands (aktuelle Kosten, aktuelle Temperaturdaten) der Umgebung (des Rechenzentrums und aller damit verbundenen Prozesse) ist. Der letzte Teil unseres Modells ist der RL-Algorithmus selbst. Dies könnte *jeder* parametrische Algorithmus sein, der aus Daten lernen kann, um eine Zielfunktion zu minimieren oder zu maximieren, indem seine Parameter modifiziert werden. Es muss *kein* Deep-Learning-Algorithmus sein; RL ist ein eigenständiges Gebiet, das von den Belangen eines bestimmten Lernalgorithmus getrennt ist.

Wie wir bereits bemerkt haben, besteht einer der Hauptunterschiede zwischen RL (oder Supervised-Learning-Aufgaben im Allgemeinen) und gewöhnlichem Supervised Learning darin, dass der Algorithmus bei einer Kontrollaufgabe Entscheidungen treffen und Aktionen ausführen muss. Diese Aktionen haben eine kausale Auswirkung auf das, was in der Zukunft geschieht. Eine Aktion zu ergreifen ist ein Schlüsselwort im Framework, und es bedeutet mehr oder weniger das, was man erwarten würde. Jede Aktion ist jedoch das Ergebnis der Analyse des aktuellen Zustands der Umgebung und des Versuchs, auf der Grundlage dieser Informationen die beste Entscheidung zu treffen.

Das letzte Konzept im RL-Framework besteht darin, dass der Algorithmus nach jeder Aktion eine *Belohnung erhält*. Die Belohnung ist ein (lokales) Signal dafür, wie gut der Lernalgorithmus bei der Erreichung des globalen Ziels abschneidet. Die Belohnung kann ein positives Signal sein (d. h. es läuft gut, weitermachen) oder ein negatives Signal (d. h. das nicht tun), auch wenn wir beide Situationen als „Belohnung“ bezeichnen.

Das Belohnungssignal ist das einzige Signal, an dem sich der Lernalgorithmus orientieren muss, während er sich in der Hoffnung auf eine bessere Leistung im nächsten Zustand der Umgebung aktualisiert. In unserem Rechenzentrumsbeispiel könnten wir dem Algorithmus eine Belohnung von +10 (ein willkürlicher Wert) gewähren, wenn seine Aktion den Fehlerwert reduziert. Oder, was vernünftiger ist, wir könnten ihm eine Belohnung gewähren, die proportional dazu ist, wie sehr er den Fehler verringert. Wenn er den Fehler erhöht, würden wir ihm eine negative Belohnung gewähren.

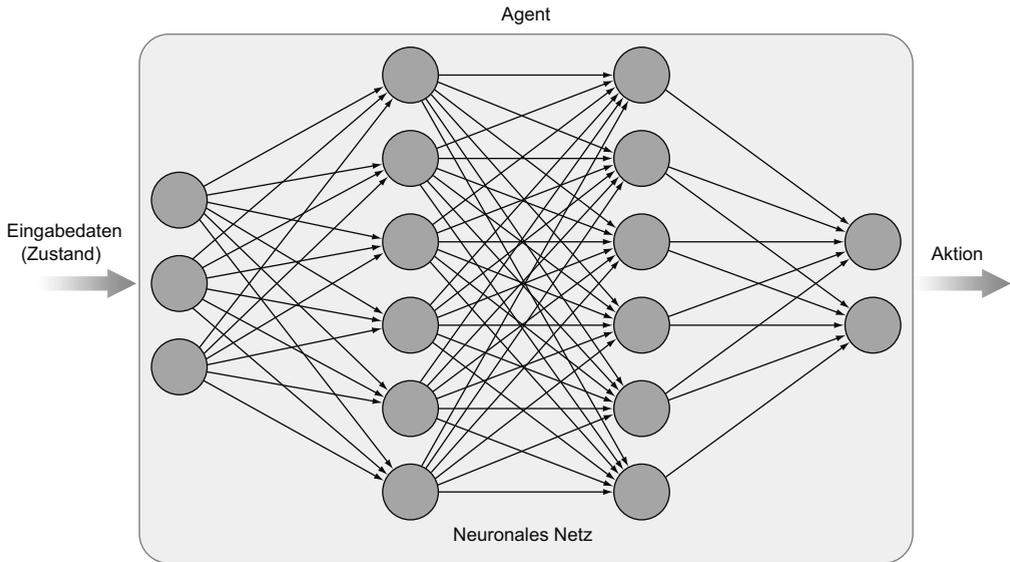
Schließlich sollten wir unserem Lernalgorithmus einen schickeren Namen geben, indem wir ihn *Agent* nennen. Der Agent ist der handlungs- oder entscheidungsorientierte Lernalgorithmus bei jedem RL-Problem. Wir können das alles zusammensetzen, wie in Bild 1.8 gezeigt.



**Bild 1.8** Das Standard-Framework für RL-Algorithmen. Der Agent führt eine Aktion in der Umgebung aus, wie z. B. das Ziehen einer Schachfigur, die dann den Zustand der Umgebung aktualisiert. Für jede Aktion, die er ausführt, erhält er eine Belohnung (z. B. +1 für das Gewinnen der Partie, -1 für das Verlieren der Partie, sonst 0). Der RL-Algorithmus wiederholt diesen Prozess mit dem Ziel, die Belohnungen langfristig zu maximieren, und er lernt schließlich, wie die Umgebung funktioniert.

In unserem Beispiel für ein Rechenzentrum hoffen wir, dass unser Agent lernt, wie wir unsere Kühlungskosten senken können. Wenn wir ihn nicht mit vollständigem Wissen über die Umgebung versorgen können, wird er ein gewisses Maß an Trial-and-Error anwenden müssen. Wenn wir Glück haben, lernt der Agent vielleicht so gut, dass er in einer anderen Umgebung als der, in der er ursprünglich trainiert wurde, eingesetzt werden kann. Da der Agent der Lernende ist, wird er als eine Art Lernalgorithmus implementiert. Und da es sich um ein Buch über *Deep Reinforcement Learning* handelt, werden unsere Agenten unter Verwendung von *Deep-Learning-Algorithmen* (auch bekannt als tiefe *neuronale Netze*, siehe Bild 1.9) implementiert. Aber denken Sie daran, dass es bei RL mehr um die Art des Problems und der Lösung geht als um einen bestimmten Lernalgorithmus, und Sie könnten sicherlich Alternativen zu tiefen neuronalen Netzen verwenden. Tatsächlich werden wir in Kapitel 3 damit beginnen, einen sehr einfachen nicht-neuronalen Netz-Algorithmus zu verwenden, und am Ende des Kapitels werden wir ihn durch ein neuronales Netz ersetzen.

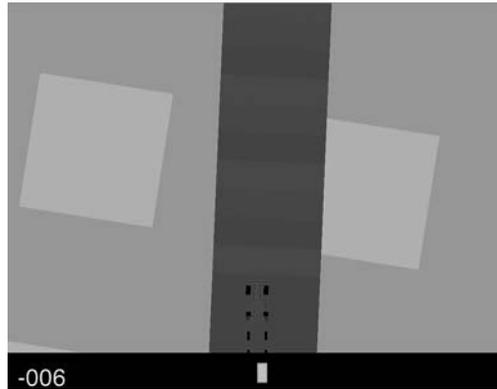
Das einzige Ziel des Agenten besteht darin, seine erwartete Belohnung auf lange Sicht zu maximieren. Er wiederholt einfach diesen Zyklus: die Zustandsinformationen verarbeiten, entscheiden, welche Aktion zu ergreifen ist, sehen, ob er eine Belohnung erhält, den neuen Zustand beobachten, eine weitere Aktion durchführen und so weiter. Wenn wir all dies richtig einrichten, wird der Agent schließlich lernen, seine Umgebung zu verstehen und bei jedem Schritt verlässlich gute Entscheidungen zu treffen. Dieser allgemeine Mechanismus lässt sich auf autonome Fahrzeuge, Chatbots, Robotik, automatisierten Aktienhandel, Gesundheitswesen und vieles mehr anwenden. Einige dieser Anwendungen werden wir im nächsten Abschnitt und an weiteren Stellen im Buch erkunden.



**Bild 1.9** Die Eingabedaten (d. h. der Zustand der Umgebung zu einem bestimmten Zeitpunkt) werden in den Agenten (in diesem Buch als tiefes neuronales Netz implementiert) eingegeben, der diese Daten dann auswertet, um eine Aktion durchzuführen. Der Prozess ist etwas aufwendiger als hier gezeigt, aber die Illustration trifft den Kern.

Die meiste Zeit in diesem Buch werden Sie damit verbringen, zu lernen, wie man Probleme in unserem Standardmodell strukturiert und wie man ausreichend leistungsfähige Lernalgorithmen (Agenten) implementiert, um schwierige Probleme zu lösen. Für diese Beispiele müssen Sie keine Umgebungen konstruieren – Sie müssen sich in bestehende Umgebungen (wie Spiele-Engines oder andere APIs) einklinken. OpenAI hat zum Beispiel eine Python Gym-Bibliothek veröffentlicht, die uns eine Reihe von Umgebungen und eine unkomplizierte Schnittstelle für unseren Lernalgorithmus zur Verfügung stellt, mit dem wir interagieren können. Der Code auf der linken Seite von Bild 1.10 zeigt, wie einfach es ist, eine dieser Umgebungen einzurichten und zu verwenden – ein Autorennspiel benötigt nur fünf Zeilen Code.

```
import gym
env = gym.make('CarRacing-v0')
env.reset()
env.step(action)
env.render()
```



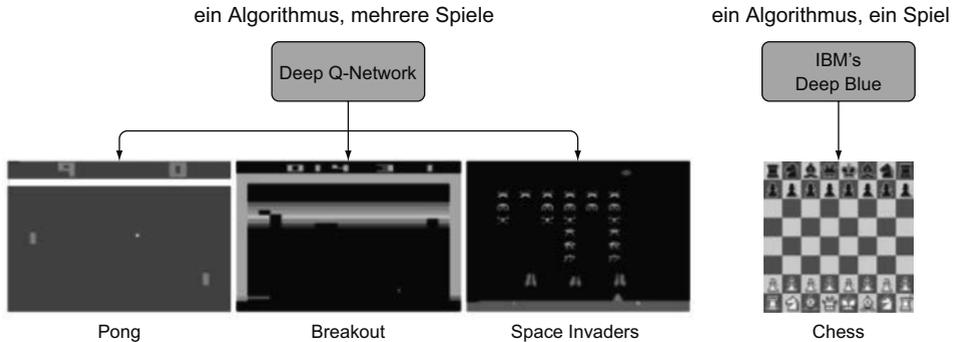
**Bild 1.10** Die OpenAI-Python-Bibliothek wird mit vielen Umgebungen und einer einfach zu bedienenden Schnittstelle für einen Lernalgorithmus geliefert, mit dem man interagieren kann. Mit nur wenigen Zeilen Code haben wir ein Autorennspiel hochgeladen.

## ■ 1.5 Was kann ich mit Reinforcement Learning anfangen?

Wir beginnen dieses Kapitel mit einem Überblick über die Grundlagen gewöhnlicher Algorithmen des Supervised Machine Learning, wie z. B. Bildklassifikatoren, und obwohl die jüngsten Erfolge beim Supervised Machine Learning wichtig und nützlich sind, wird uns Supervised Learning nicht zur Artificial General Intelligence (generelle künstliche Intelligenz – AGI) führen. Letztendlich suchen wir nach Allzweck-Lernmaschinen, die mit minimaler bis gar keiner Beaufsichtigung auf mehrere Probleme angewendet werden können und deren Repertoire an Fähigkeiten domänenübergreifend übertragen werden kann. Große Firmen mit vielen Daten können von Ansätzen des Supervised Learning gewinnbringend profitieren, aber kleinere Firmen und Organisationen haben möglicherweise nicht die Ressourcen, um die Möglichkeiten des Machine Learning auszunutzen. Allzweck-Lernalgorithmen würden das Spielfeld für alle ebnen, und Reinforcement Learning ist derzeit der vielversprechendste Ansatz für solche Algorithmen.

Die RL-Forschung und -Anwendungen sind noch nicht ausgereift, aber es gab in den letzten Jahren viele aufregende Entwicklungen. Die DeepMind-Forschungsgruppe von Google hat einige beeindruckende Ergebnisse vorgelegt und internationale Aufmerksamkeit erregt. Das erste Mal gelang dies 2013 mit einem Algorithmus, der ein Spektrum von Atari-Spielen auf übermenschlichen Leveln spielen konnte. Frühere Versuche, Agenten zur Lösung dieser Spiele zu schaffen, beinhalteten die Feinabstimmung der zugrunde liegenden Algorithmen, um die spezifischen Regeln des Spiels zu verstehen, was oft als *Feature Engineering (Merkmal-Engineering)* bezeichnet wird. Diese Feature-Engineering-Ansätze können für ein bestimmtes Spiel gut funktionieren, aber sie sind nicht dazu geeignet, Wissen oder Fähigkeiten auf ein

neues Spiel oder eine neue Domäne zu übertragen. Der Deep-Q-Network-Algorithmus (DQN) von DeepMind war robust genug, um bei sieben Spielen ohne spielspezifische Anpassungen zu funktionieren (siehe Bild 1.11). Er hatte nicht mehr als die Rohpixel vom Bildschirm als Eingabe und wurde lediglich angewiesen, die Punktzahl zu maximieren, dennoch lernte der Algorithmus über ein menschliches Expertenniveau hinaus zu spielen.



**Bild 1.11** Der DQN-Algorithmus von DeepMind lernte erfolgreich, sieben Atari-Spiele zu spielen, wobei er nur die Rohpixel als Eingabe und die Maximierung der Punktzahl als Ziel hatte. Frühere Algorithmen, wie z. B. IBMs Deep-Blue, mussten für ein bestimmtes Spiel feinabgestimmt werden.

In jüngerer Zeit schlugen die DeepMind-Algorithmen AlphaGo und AlphaZero die weltbesten Spieler beim alten chinesischen Spiel Go. Experten glaubten, dass künstliche Intelligenz mindestens ein weiteres Jahrzehnt lang nicht in der Lage sein würde, Go konkurrenzfähig zu spielen, weil das Spiel Eigenschaften aufweist, die Algorithmen normalerweise nicht gut handhaben können. Die Spieler wissen nicht, welcher Zug am besten ist, und erhalten erst am Ende der Partie Feedback auf ihre Aktionen. Viele professionelle Spieler sahen sich eher als Künstler denn als berechnende Strategen und beschrieben Gewinnzüge als schön oder elegant. Bei über  $10^{170}$  legalen Brettstellungen waren Brute-Force-Algorithmen (mit denen IBMs Deep-Blue-Algorithmus beim Schach gewann) nicht durchführbar. AlphaGo gelang dieses Kunststück vor allem dadurch, dass es Millionen von simulierten Go-Spielen spielte und lernte, welche Aktionen die Belohnungen für ein gutes Spiel maximierten. Ähnlich wie im Atari-Fall hatte AlphaGo nur Zugang zu den Informationen, die auch ein menschlicher Spieler hat: wo sich die Figuren auf dem Brett befanden.

Während Algorithmen, die Spiele besser als Menschen spielen können, bemerkenswert sind, gehen das Versprechen und das Potenzial von RL weit über die Herstellung besserer Spiel-Bots hinaus. DeepMind konnte ein Modell zur Senkung der Kühlungskosten von Googles Rechenzentrum um 40 % erstellen, eine Anwendung, die wir bereits zu einem früheren Zeitpunkt in diesem Kapitel als Beispiel untersucht haben. Autonome Fahrzeuge nutzen RL, um zu lernen, welche Reihe von Aktionen (Beschleunigen, Abbiegen, Bremsen, Signalgebung) dazu führt, dass die Fahrgäste ihr Ziel rechtzeitig erreichen, und um zu lernen, wie Unfälle vermieden werden können. Und Forscher trainieren Roboter so, dass sie Aufgaben wie das Laufenlernen erledigen, ohne explizit komplexe motorische Fähigkeiten zu programmieren.

Viele dieser Beispiele sind große Herausforderungen, wie z. B. das Fahren eines Autos. Man kann eine Lernmaschine nicht einfach durch Trial-and-Error lernen lassen, wie man

ein Auto fährt. Glücklicherweise gibt es immer mehr erfolgreiche Beispiele dafür, dass man Lernmaschinen in harmlosen Simulatoren laufen lässt und sie, sobald sie den Simulator beherrschen, reale Hardware in der realen Welt ausprobieren lässt. Ein Beispiel, das wir in diesem Buch erkunden werden, ist der automatisierte Handel (Algorithmic Trading). Ein beträchtlicher Teil des gesamten Aktienhandels wird von Computern mit wenig bis gar keinem Input durch menschliche Operatoren ausgeführt. Die meisten dieser algorithmischen Händler werden von riesigen Hedgefonds verwaltet, die Milliarden von Dollar verwalten. In den letzten Jahren haben wir jedoch ein zunehmendes Interesse einzelner Händler an der Entwicklung von Handelsalgorithmen beobachten können. So bietet etwa Quantopian eine Plattform, auf der einzelne Benutzer Handelsalgorithmen in Python schreiben und sie in einer sicheren, simulierten Umgebung testen können. Wenn die Algorithmen gut funktionieren, können sie für den Handel mit echtem Geld verwendet werden. Viele Händler haben mit einfacher Heuristik und regelbasierten Algorithmen relativen Erfolg erzielt. Da Aktienmärkte jedoch dynamisch und unvorhersehbar sind, hat ein kontinuierlich lernender RL-Algorithmus den Vorteil, dass er sich in Echtzeit an sich ändernde Marktbedingungen anpassen kann.

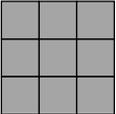
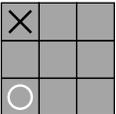
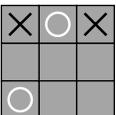
Ein praktisches Problem, das wir in diesem Buch behandeln werden, ist die Platzierung von Werbung. Aus Anzeigen erzielen viele Web-Unternehmen beträchtliche Einnahmen, die oft an die Anzahl der Klicks gebunden sind, die diese Anzeigen erzielen können. Es besteht ein großer Anreiz, Anzeigen dort zu platzieren, wo sie die Klicks maximieren können. Die einzige Möglichkeit, dies zu erreichen, besteht jedoch darin, das Wissen über User zu nutzen, um die am besten geeigneten Anzeigen zu schalten. Im Allgemeinen wissen wir nicht, welche Eigenschaften des Users mit der richtigen Anzeigenauswahl zusammenhängen, aber wir können RL-Techniken einsetzen, um einige Fortschritte zu erzielen. Wenn wir einem RL-Algorithmus einige potenziell nützliche Informationen über den User geben (was wir die Umgebung oder den Zustand der Umgebung nennen würden) und ihm sagen, er solle die Anzeigenklicks maximieren, lernt er, wie er seine Eingabedaten mit seinem Ziel in Verbindung bringen kann, und er lernt schließlich, welche Anzeigen die meisten Klicks von einem bestimmten User erzeugen.

## ■ 1.6 Warum Deep Reinforcement Learning?

Wir haben uns für Reinforcement Learning ausgesprochen, aber warum *Deep* Reinforcement Learning? RL gab es schon lange vor dem populären Aufstieg des Deep Learning. Tatsächlich beinhalteten einige der frühesten Methoden (die wir zu Lernzwecken betrachten werden) nichts anderes als die Speicherung von Erfahrungen in einer Umsetzungstabelle (z. B. einem Python-Wörterbuch) und die Aktualisierung dieser Tabelle bei jeder Iteration des Lernalgorithmus. Die Idee war, den Agenten in der Umgebung herumspielen zu lassen, um zu sehen, was passiert ist, und seine Erfahrungen mit dem Geschehen in einer Art Datenbank zu speichern. Nach einer Weile konnte man auf diese Wissensdatenbank zurückblicken und beobachten, was funktionierte und was nicht – ganz ohne neuronale Netze oder andere ausgefallene Algorithmen.

Für sehr einfache Umgebungen funktioniert das eigentlich recht gut. Zum Beispiel gibt es in Tic-Tac-Toe 255.168 gültige Brettpositionen. Die *Umsetzungstabelle* (auch *Speichertabelle* genannt) würde so viele Einträge haben, die von jedem Zustand auf eine bestimmte Aktion (wie in Bild 1.12 gezeigt) und die beobachtete Belohnung (nicht abgebildet) übertragen werden. Während des Trainings könnte der Algorithmus lernen, welche Bewegung zu günstigeren Positionen führte, und diesen Eintrag in der Speichertabelle aktualisieren.

Spielweisen-Umsetzungstabelle

Schlüssel aktueller Zustand	Wert auszuführende Aktion
	platziere X links oben
	platziere X rechts oben
	platziere X rechts unten

**Bild 1.12** Eine Umsetzungstabelle für Tic-Tac-Toe mit nur drei Einträgen, wobei der „Spieler“ (ein Algorithmus) X spielt. Wenn der Spieler eine Brettstellung mitgeteilt bekommt, diktiert die Umsetzungstabelle den Zug, den er als Nächstes machen soll. Es gibt einen Eintrag für jeden möglichen Zustand in der Partie.

Sobald die Umgebung komplizierter wird, wird die Verwendung einer Speichertabelle schwierig. Zum Beispiel könnte jede Bildschirmkonfiguration eines Videospieles als ein anderer Zustand betrachtet werden (Bild 1.13). Stellen Sie sich vor, Sie versuchen, jede mögliche Kombination von gültigen Pixelwerten, die in einem Videospiel auf dem Bildschirm angezeigt werden, zu speichern! Der DQN-Algorithmus von DeepMind, der Atari spielte, wurde bei jedem



**Bild 1.13** Eine Folge von drei Bildern von Breakout. Die Platzierung des Balls ist in jedem Rahmen leicht unterschiedlich. Wenn Sie eine Umsetzungstabelle verwenden würden, würde dies der Speicherung von drei eindeutigen Einträgen in der Tabelle entsprechen. Eine Umsetzungstabelle wäre unbrauchbar, da es viel zu viele Spielzustände zu speichern gibt.

Schritt mit vier  $84 \times 84$  Graustufenbildern gefüttert, was zu  $256^{28228}$  einzigartigen Spielzuständen führen würde (256 verschiedene Graustufen pro Pixel und  $4 * 84 * 84 = 28228$  Pixel). Diese Zahl ist viel größer als die Anzahl der Atome im beobachtbaren Universum und würde definitiv nicht in den Computerspeicher passen. Und das, nachdem die Bilder verkleinert wurden, um die Größe der ursprünglich  $210 \times 160$  Pixel großen Farbbildern zu reduzieren.

Es ist nicht möglich, jeden möglichen Zustand zu speichern, aber wir könnten versuchen, die Möglichkeiten einzuschränken. Im Spiel Breakout steuern Sie ein Paddel am unteren Bildschirmrand, das sich nach rechts oder links bewegen kann; Ziel des Spiels ist es, den Ball abzulenken und so viele Blöcke am oberen Bildschirmrand zu zerbrechen wie möglich. In diesem Fall könnten wir Einschränkungen definieren, wobei wir uns nur die Zustände ansehen, in denen der Ball zum Schläger zurückkehrt, da unsere Aktionen nicht wichtig sind, während wir auf den Ball am oberen Bildschirmrand warten. Oder wir könnten unsere eigenen Features zur Verfügung stellen – anstatt das Rohbild zu liefern, geben wir einfach die Position des Balles, des Schlägers und der restlichen Blöcke an. Diese Methoden setzen jedoch voraus, dass der Programmierer die dem Spiel zugrunde liegenden Strategien versteht, und sie ließen sich nicht auf andere Umgebungen verallgemeinern.

An dieser Stelle kommt Deep Learning ins Spiel. Ein Deep-Learning-Algorithmus kann lernen, die Details spezifischer Pixelanordnungen zu abstrahieren, und er kann die wichtigen Features eines Zustands lernen. Da ein Deep-Learning-Algorithmus eine endliche Anzahl von Parametern hat, können wir ihn dazu verwenden, jeden möglichen Zustand in etwas zu komprimieren, das wir effizient verarbeiten können, und dann diese neue Darstellung verwenden, um unsere Entscheidungen zu treffen. Durch die Verwendung neuronaler Netze hatte der Atari DQN nur 1792 Parameter (Convolutional Neural Network (CNN, faltendes neuronales Netz) mit  $16 \times 8 \times 8$  Filtern,  $32 \times 4 \times 4$  Filtern und einer 256 Knoten umfassenden, vollständig verbundenen verborgenen Schicht) im Gegensatz zu den  $256^{28228}$  Schlüssel-Wert-Paaren, die zur Speicherung des gesamten Zustandsraums erforderlich wären.

Im Fall des Breakout-Spiels könnte ein tiefes neuronales Netz von sich aus lernen, dieselben High-Level-Features zu erkennen, die ein Programmierer in einer Umsetzungstabelle von Hand entwickeln müsste. Das heißt, es könnte lernen, den Ball, das Paddel, die Blöcke zu „sehen“ und die Richtung des Balles zu erkennen. Das ist ziemlich erstaunlich, wenn man bedenkt, dass er nur Rohdaten in Form von Pixeln erhält. Und noch interessanter ist, dass die gelernten High-Level-Features möglicherweise auf andere Spiele oder Umgebungen übertragbar sind.

Deep Learning ist die geheime Zutat, die all die jüngsten Erfolge in RL möglich macht. Keine andere Klasse von Algorithmen hat eine vergleichbare Darstellungskraft, Effizienz und Flexibilität von tiefen neuronalen Netzen gezeigt. Außerdem sind neuronale Netze eigentlich ziemlich einfach!

## ■ 1.7 Unser didaktisches Werkzeug: String-Diagramme

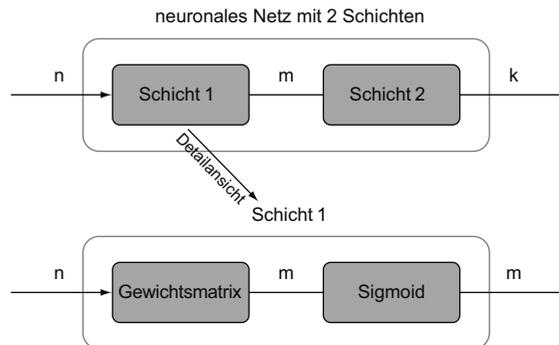
Die grundlegenden Konzepte des RL sind seit Jahrzehnten gut etabliert, aber der Bereich entwickelt sich sehr schnell, so dass jedes einzelne neue Ergebnis bald veraltet sein könnte. Deshalb konzentriert sich dieses Buch auf die Vermittlung von Fähigkeiten, nicht auf Details mit kurzen Halbwertszeiten. Wir behandeln zwar einige neuere Fortschritte auf diesem Gebiet, die sicherlich in nicht allzu ferner Zukunft verdrängt werden, aber wir tun dies nur, um neue Fertigkeiten zu vermitteln, und nicht, weil das spezielle Thema, das wir behandeln, notwendigerweise eine bewährte Technik ist. Wir sind zuversichtlich, dass die Fähigkeiten, die Sie lernen, nicht veraltet sein werden, auch wenn einige unserer Beispiele veraltet sein sollten, und dass Sie darauf vorbereitet sein werden, RL-Probleme noch lange Zeit in Angriff zu nehmen.

Außerdem ist RL ein weites Feld, auf dem es viel zu lernen gibt. Wir können unmöglich hoffen, dass wir in diesem Buch alles davon abdecken können. Unser Ziel ist es nicht, eine erschöpfende RL-Referenz oder ein umfassender Kurs zu sein, sondern Ihnen die Grundlagen von RL zu vermitteln und einige der aufregendsten jüngsten Entwicklungen auf diesem Gebiet zu präsentieren. Wir erwarten, dass Sie in der Lage sein werden, das, was Sie hier gelernt haben, zu übernehmen, um sich in den vielen anderen Bereichen von RL leicht zurechtzufinden. Darüber hinaus haben wir einen Abschnitt in Kapitel 11, der Ihnen einen Überblick über Bereiche gibt, die Sie sich nach der Lektüre dieses Buches vielleicht ansehen möchten.

Dieses Buch ist darauf ausgerichtet, gut, aber auch rigoros zu unterrichten. Reinforcement Learning und Deep Learning sind grundlegend mathematisch. Wenn Sie irgendwelche Forschungsartikel in diesen Bereichen lesen, werden Sie möglicherweise auf ungewohnte mathematische Notationen und Gleichungen stoßen. Die Mathematik ermöglicht es uns, präzise Aussagen darüber zu machen, was wahr ist und wie die Dinge zusammenhängen, und sie bietet rigorose Erklärungen dafür, wie und warum die Dinge funktionieren. Wir könnten RL ohne Mathematik unterrichten und einfach Python verwenden, aber dieser Ansatz würde dazu führen, dass Sie zukünftige Entwicklungen nicht verstehen können.

Wir denken also, dass die Mathematik wichtig ist, aber wie unser Lektor bemerkte, gibt es in der Verlagswelt ein gängiges Sprichwort, das wahrscheinlich einen wahren Kern hat: „Für jede Gleichung im Buch wird die Leserschaft halbiert“. Es gibt einen unvermeidlichen kognitiven Overhead beim Entziffern komplexer mathematischer Gleichungen, es sei denn, man ist ein professioneller Mathematiker, der den ganzen Tag lang Gleichungen liest und schreibt. Angesichts des Wunsches, eine rigorose Darstellung von DRL zu präsentieren, um den Lesern ein erstklassiges Verständnis zu vermitteln, und dennoch so viele Menschen wie möglich zu erreichen, haben wir uns ein unserer Meinung nach sehr charakteristisches Merkmal für dieses Buch ausgedacht. Wie sich herausstellt, sind selbst professionelle Mathematiker der traditionellen mathematischen Notation mit ihrem riesigen Spektrum von Symbolen überdrüssig geworden, und in einem bestimmten Zweig der fortgeschrittenen Mathematik, der *Kategorientheorie*, haben Mathematiker eine rein grafische Sprache entwickelt, die *String-Diagramme* genannt wird. String-Diagramme sehen Flussdiagrammen und Schaltplänen sehr ähnlich, und ihre Bedeutung ist weitgehend intuitiv zu erfassen, wobei sie genauso streng und präzise sind wie traditionelle mathematische Notationen, die weitgehend auf griechischen und lateinischen Symbolen basieren.

Bild 1.14 zeigt ein einfaches Beispiel für ein String-Diagramm, das auf komplexe Art ein neuronales Netz mit zwei Schichten darstellt. Machine Learning (insbesondere Deep Learning) umfasst viele Matrix- und Vektoroperationen, und String-Diagramme eignen sich besonders gut, um diese Art von Operationen grafisch zu beschreiben. String-Diagramme eignen sich auch hervorragend zur Beschreibung komplexer Prozesse, da wir den Prozess auf verschiedenen Abstraktionsebenen beschreiben können. Die obere Tafel von Bild 1.14 zeigt zwei Rechtecke, die die beiden Schichten des neuronalen Netzes darstellen, aber dann können wir in die Schicht 1 „hineinzoomen“ (in den Kasten hineinschauen), um zu sehen, was sie im Detail tut; dies wird in der unteren Tafel von Bild 1.14 gezeigt.



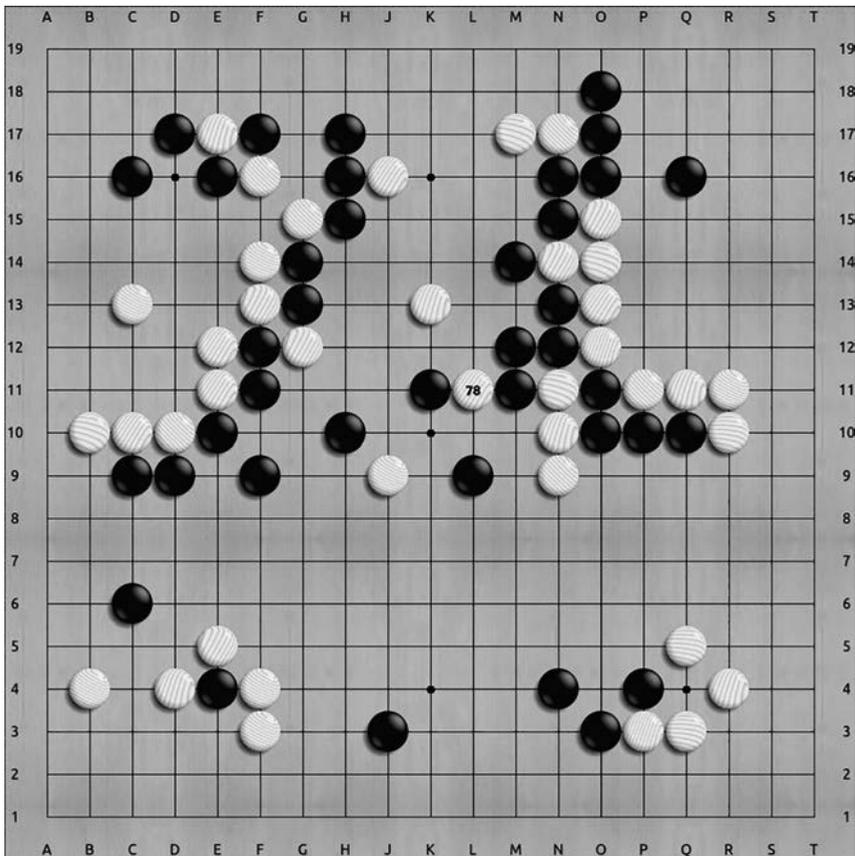
**Bild 1.14** Ein String-Diagramm für ein zweischichtiges neuronales Netz. Von links nach rechts gelesen, stellt das obere String-Diagramm ein neuronales Netz dar, das einen Eingabevektor der Dimension  $n$  annimmt, ihn mit einer Matrix der Dimensionen  $n \times m$  multipliziert und einen Ertrag der Dimension  $m$  zurückgibt. Dann wird die nichtlineare Sigmoid-Aktivierungsfunktion auf jedes Element im  $m$ -dimensionalen Vektor angewendet. Dieser neue Vektor wird dann durch die gleiche Schrittfolge in Schicht 2 geführt, was die endgültige Ausgabe des neuronalen Netzes erzeugt, einen  $k$ -dimensionalen Vektor.

Wir werden im gesamten Buch häufig String-Diagramme zur Vermittlung von komplexen mathematischen Gleichungen bis hin zu den Architekturen tiefer neuronaler Netze verwenden. Wir werden diese grafische Syntax im nächsten Kapitel beschreiben, und wir werden sie im weiteren Verlauf des Buches weiter verfeinern und aufbauen. In einigen Fällen ist diese grafische Notation für das, was wir zu erklären versuchen, übertrieben, sodass wir eine Kombination aus klarer Prosa und Python oder Pseudocode verwenden werden. In den meisten Fällen werden wir auch die traditionelle mathematische Notation verwenden, sodass Sie die zugrunde liegenden mathematischen Konzepte auf die eine oder andere Weise lernen können, je nachdem, was Ihnen am besten zusagt: Diagramme, Code oder normale mathematische Notation.

## ■ 1.8 Wie geht es weiter?

Im nächsten Kapitel tauchen wir direkt in das eigentliche Wesen von RL ein und behandeln viele der Kernbegriffe, wie z. B. den Kompromiss zwischen Erkundung und Ausnutzung, Markov Decision Processes, Wert-Funktionen und Policies (diese Begriffe werden Sie bald verstehen). Doch zunächst werden wir zu Beginn des nächsten Kapitels einige der Lehrmethoden vorstellen, die wir in diesem Buch anwenden werden.

Der Rest des Buches befasst sich mit zentralen DRL-Algorithmen, auf denen ein Großteil der neuesten Forschung aufbaut, beginnend mit Deep Q-Networks, gefolgt von Policy-Gradient-Ansätzen und modellbasierten Algorithmen. Wir werden in erster Linie (das bereits erwähnte) OpenAI's Gym nutzen, um unsere Algorithmen zu trainieren, um nichtlineare Dynamiken zu verstehen, Roboter zu steuern und Spiele zu spielen (Bild 1.15).



**Bild 1.15** Darstellung eines Go-Bretts, das Google DeepMind als Testumfeld für seinen AlphaGo-Algorithmus für Reinforcement Learning verwendete. Der professionelle Go-Spieler Lee Sedol gewann nur eine von fünf Partien. Damit wurde ein Wendepunkt für Reinforcement Learning markiert, da Go lange Zeit als unempfindlich gegenüber der Art von algorithmischer Argumentation galt, der das Schachspiel unterliegt. Quelle: <http://mng.bz/DNX0>

In jedem Kapitel beginnen wir mit einem Hauptproblem oder -projekt, das wir verwenden werden, um die wichtigen Konzepte und Skills für dieses Kapitel zu veranschaulichen. Im weiteren Verlauf jedes Kapitels können wir dem Ausgangsproblem Komplexität oder Nuancen hinzufügen, um einige der Prinzipien zu vertiefen. Zum Beispiel beginnen wir in Kapitel 2 mit dem Problem der Maximierung der Belohnungen an einer Casino-Spielautomatik, und indem wir dieses Problem lösen, werden wir die meisten Grundlagen von RL behandeln. Später fügen wir diesem Problem eine gewisse Komplexität hinzu und ändern die Einstellung von einem Kasino zu einem Unternehmen, das Werbeklicks maximieren muss, was es uns ermöglicht, einige weitere Kernkonzepte darzustellen.

Obwohl dieses Buch für Leser gedacht ist, die bereits Erfahrung mit den Grundlagen des Deep Learning haben, gehen wir davon aus, dass es Ihnen nicht nur unterhaltsame und nützliche RL-Techniken vermittelt, sondern auch Ihre Fähigkeiten zum Deep Learning verfeinert. Um einige der anspruchsvolleren Projekte zu lösen, werden wir die neuesten Entwicklungen im Bereich des Deep Learning einsetzen müssen, wie z. B. Generative Adversarial Networks (GANs, generative gegnerische Netze), evolutionäre Methoden, Meta-Lernen und Transferlernen. Auch dies alles steht im Einklang mit unserer auf Fähigkeiten fokussierten Lehrmethode, sodass die Einzelheiten dieser Fortschritte nicht das Wichtigste sind.

## ■ 1.9 Zusammenfassung

- Reinforcement Learning ist eine Unterklasse des Machine Learning. RL-Algorithmen lernen durch die Maximierung der Belohnung in einer bestimmten Umgebung, und sie sind nützlich, wenn es bei einem Problem darum geht, Entscheidungen zu treffen oder Aktionen durchzuführen. RL-Algorithmen können im Prinzip jedes statistische Lernmodell verwenden, aber es ist effektiver und zunehmend populärer, tiefe neuronale Netze zu verwenden.
- Der Agent steht im Mittelpunkt eines jeden RL-Problems. Er ist der Teil des RL-Algorithmus, der Eingabe verarbeitet, um zu bestimmen, welche Aktion zu ergreifen ist. In diesem Buch konzentrieren wir uns in erster Linie auf Agenten, die als tiefe neuronale Netze implementiert sind.
- Die Umgebung sind die potenziell dynamischen Bedingungen, unter denen der Agent arbeitet. Allgemeiner gesagt, ist die Umgebung der Prozess, der die Eingabedaten für den Agenten erzeugt. Zum Beispiel könnten wir einen Agenten haben, der ein Flugzeug in einem Flugsimulator fliegt, somit wäre der Simulator die Umgebung.
- Der Zustand ist eine Momentaufnahme der Umgebung, zu der der Agent Zugang hat und die er nutzt, um Entscheidungen zu treffen. Die Umgebung besteht oft aus einer Reihe von sich ständig ändernden Bedingungen, aber wir können Proben aus der Umgebung nehmen, und diese Proben zu bestimmten Zeiten sind die Zustandsinformationen der Umgebung, die wir dem Agenten geben.
- Eine Aktion ist eine von einem Agenten getroffene Entscheidung, die eine Veränderung in seiner Umgebung bewirkt. Das Bewegen einer bestimmten Schachfigur ist eine Aktion, ebenso wie das Drücken des Gaspedals in einem Auto.

- Eine Belohnung ist ein positives oder negatives Signal, das einem Agenten von der Umgebung gegeben wird, nachdem er eine Aktion ausgeführt hat. Die Belohnungen sind die einzigen Lernsignale, die dem Agenten gegeben werden. Das Ziel eines RL-Algorithmus (d. h. des Agenten) ist es, die Belohnungen zu maximieren.
- Die allgemeine Pipeline für einen RL-Algorithmus ist eine Schleife, in der der Agent Eingabedaten (den Zustand der Umgebung) empfängt, der Agent diese Daten auswertet und eine Aktion aus einem Satz möglicher Aktionen unter Berücksichtigung seines aktuellen Zustands ausführt, die Aktion die Umgebung verändert und die Umgebung dann ein Belohnungssignal und neue Zustandsinformationen an den Agenten sendet. Dann wiederholt sich der Zyklus. Wenn der Agent als tiefes neuronales Netz implementiert ist, bewertet jede Iteration eine Verlustfunktion auf der Grundlage des Belohnungssignals und führt eine Backpropagation (Rückführung) durch, um die Leistung des Agenten zu verbessern.

# Stichwortverzeichnis

## Symbole

0-Tensor (Skalar) 43  
1D-Ising-Modell 271  
2D-Ising-Modell 277  
@-Operator 213

## A

Abfragen 314  
Absolute (nicht-relationale)  
  Aufmerksamkeitsmodelle 306  
action\_repeats parameter 247  
actions-Array 113  
Actor-Critic-Methoden 121  
  - Kombination von Wert- und Policy-Funktion 123  
  - N-step-Actor-Critic 143  
  - verteiltes Training 128  
  - Vorteile 136  
Actor-Critic-Modell 136, 140  
actor\_loss-Funktion 141  
AddBackward-Funktion 75  
Additive Aufmerksamkeit 334  
add\_spots-Funktion 318  
add\_to\_replay-Funktion 297  
Adjazenzmatrix 312  
Advantage-Actor-Critic 125  
afn-Parameter 273  
Agenten 13, 113  
AGI (Artificial General Intelligence) 15  
Aktionen 42  
  - Berechnung der Wahrscheinlichkeit 114  
Aktion-Wert-Funktion 31, 61  
Algorithmen  
  - dateneffizient 171  
  - evolutionär 153  
AlphaGo-Algorithmus 16, 22, 30, 357, 358  
AlphaZero-Algorithmus 16  
Amazon SageMaker 319  
Anerkennungszuweisung 107

Anzeigenplatzierung mit Banditen 40  
  - Aktionen 42  
  - kontextabhängige Banditen 41  
  - Zustände 42  
A-posteriori-Wahrscheinlichkeitsverteilung 189  
A-priori-Wahrscheinlichkeitsverteilung 189  
  - Varianz 192  
  - Vergleich 208  
  - Verteilung, Berechnung des Erwartungswerts 190  
  - Wahrscheinlichkeitsverteilung, in Python 197  
Äquivarianz 304  
arange-Funktion 39  
argmax-Funktion 36, 282  
Artificial General Intelligence (AGI) 15  
Atari 109, 156, 196, 217, 225  
Atari Freeway 218  
Auf Erfahrung basierter Wiederholungsspiel-Puffer 129  
Auf Erfahrung basiertes Wiederholungsspiel 354  
  - katastrophales Vergessen 81  
  - priorisiertes 354  
Aufmerksamkeit  
  - double Q-Learning 339  
  - Implementierung der Self-Attention für MNIST 317  
  - Einstein-Notation 323  
  - relationale Argumentation mit 306  
  - Aufmerksamkeitsmodelle 306  
  - relationale Argumentation 308  
  - Self-Attention-Modelle 314  
  - Training 339  
  - Curriculum Learning 344  
  - Maximum Entropy Learning 343  
Ausnutzung 31, 171  
Äußeres Produkt 266  
Automatische Differenzierung 44  
AvgPool-Operation 316

## B

Backpropagation 116, 163, 232  
 backward()-Methode 44, 76  
 Bandit  
 - kontextabhängig 41, 45  
 - Multi-Armed-Bandit-Problem 30  
 - Epsilon-greedy-Strategie 32  
 - Erkundung 31  
 - solving, Softmax-Auswahlverfahren 37  
 Bayes'sche Inferenz 189  
 Bellman-Gleichung 194  
 - Verteilung 195  
 Belohnung 42, 60, 107  
 - intrinsische 255  
 - spärliche 226  
 Berechnungsdiagramm 29  
 Bimodale Verteilung 183  
 Boltzmann-Verteilung 282  
 Bootstrapping 125, 135, 146  
 Box2D 109  
 Breakout-Spiel 19, 156

## C

CartPole 109, 115, 118, 135, 137, 139, 142, 164, 174  
 Central Processing Units (CPUs) 130  
 choose\_arm(...)-Methode 47  
 CNNs (Convolutional Neural Networks) 304, 317, 320  
 collections-Bibliothek 237  
 commutativity 304  
 ContextBandit-Klasse 46, 49  
 Convolutional Neural Networks (CNNs) 153, 304  
 CPUs (Central Processing Units) 130, 142  
 CUDA-fähige GPU 319  
 cum\_rewards-Liste 221  
 Curriculum Learning 344

## D

DA2C (verteiltes Advantage-Actor-Critic) 123, 128, 135  
 Dateneffiziente Algorithmen 171  
 Daten, simulierte 213  
 DDQN (Double Deep Q-Network) 338  
 Deduktive Argumentation 303  
 Deep Blue, IBM 16  
 DeepMind 15, 22, 61, 225  
 Deep Q-Netze 238  
 Degenerierte Verteilung 197, 207, 282

Degenerierte Wahrscheinlichkeitsverteilung 99, 197  
 deque 85, 237, 249  
 .detach()-Methode 76, 232, 248  
 Deterministischer Policy-Gradient (DPG) 102  
 Differenzierung 44  
 Diskontierungsfaktor 65  
 Diskrete Verteilung 192, 199, 218  
 display-Methode 69  
 dist\_dqn-Funktion 207  
 Dist-DQN (Verteilungs-Deep-Q-Network) 187, 196, 198, 223  
 - auf simulierten Daten 213  
 - Implementierung 206  
 done-Variable 85, 111, 235, 252  
 double Q-Learning 338  
 downscale\_obs-Funktion 236  
 DP (dynamische Programmierung) 9  
 DPG (deterministic policy gradient) 102  
 DQN (Deep Q-Networks) 93  
 - Q-Learning 61  
 - Q-Learning, Diskontierungsfaktor 65  
 - Q-Learning, Gridworld 63  
 - Q-Learning, Gridworld-Spiele-Engine 68  
 - Q-Learning, Hyperparameter 65  
 - relationale 330  
 - Verbesserung der Stabilität mit einem Target Network 87  
 - Verhinderung katastrophalen Vergessens 81  
 DRL (Deep Reinforcement Learning) 3, 20, 108  
 Dynamik, inverse 230  
 Dynamische Programmierung (DP) 10

## E

Einops-Paket 332, 334  
 Einstein-Notation 322  
 ELU (exponentielle lineare Einheit) 238  
 Empowerment 255  
 Encoder-Funktion 231  
 Encoder-Modell 231  
 Endzustand 85  
 Entropy Learning 343  
 enumerate-Funktion 169  
 env-Objekt 235  
 env.step(action)-Methode 250  
 env-Variable 111  
 Episodische Spiele 66, 104  
 Epsilon-greedy-Ansatz 67  
 Epsilon-greedy-Policy 140, 338, 343  
 Epsilon-greedy-Strategie 32, 171

- Erkundung
  - Implementierung von Super Mario Bros 234
  - von Neugierde getrieben 225
    - alternative intrinsische Belohnungsmechanismen 255
    - ICM 242
    - Policy-Funktion 238
    - prädiktive Kodierung gegen spärliche Belohnungen 227
    - Q-Netz einrichten 238
    - Vorhersage der inversen Dynamik 230
    - Vorverarbeitung 236
- Ertrag 352
- Erwarteter Wert 56
- Erwartungsoperator 192
- Erwartungswert 190
- ES (Evolutionäre Strategien) 173, 178
- evaluate\_population-Funktion 167
- Evolutionäre Algorithmen 153
  - als skalierbare Alternative 172
    - auf Gradienten basierte Ansätze 178
    - lineare Skalierung 178
    - parallele vs. serielle Verarbeitung 174
    - Skalierungseffizienz 175
  - genetischer Algorithmus für CartPole 164
  - in der Praxis 159
  - in der Theorie 155
  - Reinforcement Learning 155
  - Vor- und Nachteile 170
    - testintensiv 171
- Exploration, von Neugierde getrieben, Vorhersage der inversen Dynamik 230
- Exponentielle lineare Einheit (ELU) 238
- Extrinsische Belohnung 228, 243
  
- F
- Feature Engineering 15
- for-Schleife 49, 72, 206
- Forward-Vorhersagemodell 230
  - Fehler 243
- FOV (field of view) 265, 289, 293
- frames\_per\_state-Parameter 247
- Framework 11
- Freeway-Spiel 196, 198, 204, 217
  
- G
- GANs (Generative Adversarial Networks) 142, 252
- Gated Recurrent Unit (GRU) 129, 239
- Gaußsche Normalverteilung 101, 173, 192
- Gegenseitige Information (MI) 256
- Gelernte Verteilungen 215
- Gemischte kooperativ-konkurrierende Spiele 288
- Generative Adversarial Networks (GANs) 142, 252
- Generative Modelle 208
- Genetischer Algorithmus 156, 168
- gen\_params-Funktion 283
- Gesamtertrag 107
- get\_action-Funktion 218
- get\_batch(...)-Methode 241
- get\_best\_arm-Funktion 36, 38
- get\_coords-Funktion 283
- get\_mean\_field-Funktion 292
- .get()-Methode 134
- get\_neighbors-Funktion 291
- get\_reward\_2d-Funktion 283
- get\_reward-Funktion 36
- get\_state()-Methode 46
- get\_substate-Funktion 274
- get\_target\_dist-Funktion 208
- Gewichteter Durchschnitt 190
- Gewichtetes Log-Wahrscheinlichkeitsverhältnis 211
- Glockenkurve 192
- GNN (Graph Neural Network) 303
- Go game 358
- Google Cloud 319
- Google Colab 319
- Go-Spiel 16, 357
- GPUs (Grafikprozessoren) 131, 290
- Gradientenabstieg 163
- Gradientenbasierte Ansätze 178, 179
- Gradientenbasierte Optimierung 240
- Gradientenloser Algorithmus 155
- Grand Theft Auto-Spiel 172
- Graphen 303
- Graph Neural Network (GNN) 303
- Gridworld-Spiel 59, 63, 68, 103, 156, 194, 261, 331, 338, 344, 347, 355
- GRU (Gated Recurrent Unit) 129, 239
- GWagent.att\_map 344
  
- H
- Hierarchisches Reinforcement Learning 355
- Hyperparameter 48, 65, 246, 254
- Hyperthreading 133

## I

ICM (intrinsisches Neugierde-Modul) 234, 242  
 IL-Q (unabhängiges Q-Learning) 260, 261  
 Index, gemeinsamer 322  
 Induktive Argumentation 302  
 Induktive Verzerrungen 302  
 infer\_acts-Funktion 294, 297  
 info-Parameter 111  
 info-Variable 235  
 init\_grid-Funktion 283  
 Inneres Produkt 314, 315  
 Instabilitäten 88  
 Interpretierbarkeit mit Verzerrungen 302  
 Intrinsische Belohnung 228, 243, 255  
 Intrinsisches Neugierde-Modul (ICM) 234, 242  
 Invarianz 304  
 Inverse Dynamik 230  
 Inverses Modell 231  
 Ising-Modell  
 - 1D 267  
 - 2D 278

## J

.join()-Methode 134  
 Jupyter-Notebook 319

## K

Kanten 302  
 Kantenmatrix 312  
 Kategorientheorie 20  
 $k$ -dimensionaler Vektor 21  
 Knoten  
 - Graph Neural Networks 303  
 - Kommunikation zwischen 176  
 Knotenmatrix 312  
 Knotenmerkmalsdimension 325  
 Kodierung, prädiktive 227  
 Kontextabhängige Banditen 41, 45  
 Kontextabhängige Information 41  
 Kooperativ-konkurrierende Spiele 288  
 Kreuzung 159  
 $k$ -Tensor 43  
 Kullback-Leibler-Divergenz 212

## L

Langes Kurzzeitgedächtnis (LSTM) 239  
 LayerNorm-Schichten 320  
 Lerninstabilität 88  
 Lernrate 65  
 linspace-Funktion 201

load\_state\_dict-Methode 90  
 Logarithmen 106, 210  
 log\_softmax-Funktion 137, 326, 332  
 Log-Wahrscheinlichkeiten 106  
 - gewichtet 211  
 lossfn-Funktion 213  
 LR (Wahrscheinlichkeitsverhältnis) 210  
 LSTM (langes Kurzzeitgedächtnis) 239  
 - network 129

## M

MAGent-Spiel 289, 298  
 makeMove-Methode 69, 73  
 Markov Decision Processes 25  
 - kontextabhängige Banditen lösen 45  
 - Markov-Eigenschaft 51  
 - Multi-Arm-Bandit-Problem 30  
 - Ausnutzung 31  
 - Epsilon-greedy-Strategie 33  
 - Netzwerke mit PyTorch erstellen 43  
 - automatische Differenzierung 43  
 - Modelle erstellen 44  
 - Optimierung von Anzeigenplatzierungen mit Banditen  
 - Aktionen 42  
 - Belohnungen 42  
 - kontextabhängige Banditen 41  
 - Zustände 42  
 - Policy-Funktionen 53  
 - String-Diagramme 27  
 - Wert-Funktion 56  
 MARL (Multi-Agent Reinforcement Learning) 264, 267, 270  
 Massenschwerpunkt 190  
 Maßtheorie 188  
 Masterknoten 176  
 matplotlib-Streudiagramm 36  
 Matrix-Multiplikation 322  
 max\_episode\_len-Parameter 247  
 maxlen-Attribut 237, 249  
 MaxPool-Operation 316  
 $m$ -dimensionaler Vektor 21, 29  
 MDP (Markov Decision Process) 51, 104, 123, 148, 352  
 Mean-Field-Näherung 280  
 Mean-Field-Q-Learning 278  
 Merkmale 156  
 MF-Q (Mean-Field-Q-Learning) 259, 280  
 MHDPA (Multi-Head-Skalarprodukt-Aufmerksamkeit) 330

- MI (gegenseitige Information) 256
- MiniGrid-Bibliothek 331, 341
- MiniGrid-DoorKey-Umgebung 332
- min\_progress-Parameter 247
- Mittlere quadratische Abweichung (MQA) 208
- Mittlerer quadratischer Fehler (MSE) 103
- MNIST
  - Einstein-Notation 322
  - Self-Attention für 317
    - relationale Module 324
    - Training des relationalen Moduls 326
- Modell 113
  - relationale Module 327
  - Training 114
    - Berechnung der Wahrscheinlichkeit der Aktion 114
    - Verlustfunktion 115
- Modellbasierte Planung 356
- Modellfreies Lernen 356
- Monte-Carlo-Baumsuche (MCTS) 357
- Monte-Carlo-Methoden 10, 143, 146
- mp.cpu\_count()-Funktion 133
- MSE (mean squared error) 208
- MSE (mittlerer quadratischer Fehler) 103
- MuJoCo 109
- Multi-Agent Reinforcement Learning (MRL) 259, 264
  - 1D-Ising-Modell 267
  - 2D-Ising-Modell 278
  - gemischte kooperativ-konkurrierende Spiele 288
  - Mean-Field-Q-Learning 277
  - Nachbarschafts Q-learning 264
- Multi-Arm-Bandits 33
  - Ausnutzung 31
  - Epsilon-greedy-Strategie 33
  - Erkundung 31
- Multi-Head Attention 330
- Multi-Head-Skalarprodukt-Aufmerksamkeit (MHDPA) 330
- Multiprocessing-Bibliothek 131
- Multithreading 130
- mutate-Funktion 160
- Mutationsrate 166
- MXNet 43
- N**
  - Nachbarschafts-Q-Learning 264
  - Nachrichtenaustausch 325
  - n*-Armed-Bandit-Algorithmus 37, 40
  - Natural Language Processing (NLP) 129
  - n*-dimensionaler Vektor 29
  - Netzwerk
    - Aufbau 66
    - mit langem Kurzzeitgedächtnis (LSTM) 129
    - mit PyTorch erstellen 43
      - automatische Differenzierung 44
  - Neugierde-Modul 233
  - Neuronale Netzschicht 28
  - Neuronales Netz 208
    - als Q-Funktion 72, 98
  - next\_generation-Funktion 167
  - Nichtparametrisches Modell 310
  - Nichtstationäre Probleme 37
  - NLP (Natural Language Processing) 129
  - nn-Modul 44, 71
  - NO-OP (no-operation) 196, 214, 222, 234
  - NPCs (Nicht-Spieler-Charaktere) 259
  - np.expand\_dims(...)-Funktion 271
  - NP (Nominalphrase) 5
  - np.random.choice-Funktion 39
  - N-step-Actor-Critic 143
  - N-step-Lernen 135
  - num\_iter parameter 286
  - Nutzenfunktion 105
- O**
  - obs array 236
  - Ologs (ontologische Logs) 27
  - One-Hot-Encoder 47
  - One-Hot-Vektor 263, 264, 292
  - Online-Training 81
  - OpenAI Gym 14, 108, 196, 331
    - API 111
    - CartPole 110
  - Options Framework 355
  - outcomes-Array 191
- P**
  - Parallelberechnungen 130
  - Parallele Ausführung 174
  - Parametervektor 272
    - abgeflacht 165
  - Parametrische Methoden 310
  - Parametrische Modelle 5, 208, 310
  - params-Wörterbuch 247
  - Partielle Beobachtbarkeit 351
  - PDF (Wahrscheinlichkeitsdichtefunktion) 101
  - PE (Vorhersagefehler) 227, 255, 257
  - PMF (Wahrscheinlichkeitsmassenfunktion) 101

- Policy-Funktion 54, 56
    - einrichten 238
    - mit neuronalen Netzen 98
      - stochastischer Policy-Gradient 99
    - mit Wert-Funktion 125
    - optimale Policy 55
  - Policy-Gradient-Funktion 123
  - Policy-Gradient-Methode 98
    - OpenAI Gym 108
      - CartPole 110
      - OpenAI Gym-API 111
    - Policy-Funktion mit neuronalen Netzen
      - Erkundung 102
      - stochastischer Policy-Gradient 99
    - Policy-Gradient-Algorithmus 108
      - Log-Wahrscheinlichkeit 106
    - REINFORCE-Algorithmus 112
      - Erstellen des Policy-Netzwerks 112
      - Interaktion der Agenten mit der Umgebung 113
      - vollständige Trainingsschleife 116
  - Policy-Netzwerk 97, 108, 112
  - PPO (Proximal-Policy-Optimierung) 255, 354
  - Prädiktive Kodierung 227
  - Pr(A)-Funktion 38
  - pred-Array 113
  - prepare\_images-Funktion 318, 326
  - prepare\_initial\_state(...)-Funktion 249
  - prepare\_multi\_state-Funktion 237
  - prepare\_state-Funktion 237
  - Priorisierte Wiederholung 218
  - probs-Array 33, 191
  - Python, Darstellung einer
    - Wahrscheinlichkeitsverteilung 197
  - Python Gym-Bibliothek 14
  - PyTorch 43
    - automatische Differenzierung 43
    - Modelle erstellen 44
- Q**
- Q-Funktion 31, 56, 59, 71, 194, 197, 261, 272, 275, 338, 352
  - Q-Learning 52, 61
    - Diskontierungsfaktor 65
    - double 338
    - Erwartungswert 181
    - Gridworld 64
    - Gridworld-Spiele-Engine 68
    - Hyperparameter 65
    - Mean-Field 278
      - Nachbarschaft 264
      - neuronales Netz als Q-Funktion 71
  - Quadratische Funktion 132
  - Quantilsregression 223
  - q-Vektor 29
- R**
- random-Modul 193
  - rearrange-Funktion 332, 334
  - recombine-Funktion 160
  - record-Array 35, 39
  - Rectified Linear Unit (ReLU) 29, 44, 47, 66, 74, 242
  - Recurrent Neural Network (RNN) 29, 129, 147, 309
  - reduce-Funktion 332
  - Regression 5
  - Regulierte Modelle 126
  - REINFORCE-Algorithmus 112, 307, 354
    - Modelle trainieren 116
    - vollständige Trainingsschleife 116
  - Reinforcement Learning 8
    - Deep Reinforcement Learning 4, 17
    - dynamische Programmierung versus Monte Carlo 9
    - Framework 11
    - hierarchisches 355
    - Multi-Agent 259
    - String-Diagramme 21
  - Reinforcement von Aktionen 123
  - Rekombination 160
  - Relationale Argumentation 308
  - Relationale DQN 330
  - Relationale Modelle 301, 305
    - double Q-Learning 338
    - Machine Learning, Interpretierbarkeit mit Verzerrungen 302
    - relationale Argumentation mit Aufmerksamkeit 306
      - Aufmerksamkeitsmodelle 306
    - relationales DQN 332
  - Relationale Module 320, 328
  - Relationaler Block 316
  - Rel-DQN 325
  - ReLU (Rectified Linear Unit) 29, 44, 66, 74, 137, 242
  - requires\_grad=True-Argument 44
  - requires\_grad-Attribut 75
  - reset-Methode 111
  - reshape-Methode 266

- resize-Funktion 236
- reward-Methode 69
- RGBA-Wert 312
- RL-Algorithmus 6, 8, 11, 61, 177
- RNN (Recurrent Neural Network) 29, 129, 147, 309
- run\_episode-Funktion 140, 144
- S**
- sample-Methode 111
- SAM (Self-Attention-Modell) 302, 312
- Schaltpläne 27
- Schlüssel 314
- Schlüssel-Abfrage-Multiplikation 316
- Self-Attention 317
  - für MNIST 328
  - Einstein-Notation 323
  - relationale Module 319
  - Tensorverjüngung 322
  - Training des relationalen Moduls 326
  - transformiertes MNIST 317
- Self-Attention-Modell (SAM) 302, 306, 312, 314
  - Self-Attention für MNIST
    - Einstein-Notation 322
    - relationale Module 319
    - Tensorverjüngung 322
- SequenceMatcher-Modul 160
- Serielle Ausführung 174
- Sichtfeld (FOV) 265, 289
- sigma-quadratisch 192
- Simulatoren 172
- Simulierte Daten 217
- Skalar (0-Tensor) 43
- Skalarprodukt 314
- Skalarprodukt-Aufmerksamkeit 334
- Skalierung
  - evolutionäre Algorithmen 173
    - Effizienz 175
  - linear 178
- Softmax-Auswahlverfahren 37
- Softmax-Funktion 38, 47, 113, 239, 281
- Spärliche Belohnung 227
- Speicherpuffer fester Größe 218
- Speichertabelle 18
- Spineigenschaft 268
- square-Funktion 134
- squeeze(...)-Methode 242
- Stabilität 89
- Stapel-Normalisierung (BatchNorm) 321
- .start()-Methode 134
- state1\_hat-Tensor 248
- state2\_hat-Tensor 248
- State-Aktion-Werte 184
- state\_dict()ss-Methode 90
- states-Array 113
- State-Wert-Funktion 56
- Stationäres Problem 37
- Stationäre Umgebung 261
- step()-Methode 45, 111, 235
- Stetige Verteilung 192
- Stetige Wahrscheinlichkeitsverteilung 191
- Steuerungsaufgaben 6
- Stichprobenraum 188
- Stochastischer Policy-Gradient 99
- String-Diagramm 20, 25
- Super Mario Bros game 234
- Supervised Learning 8
- s-Vektor 29
- T**
- tanh-Funktion 273, 278
- Target Network 88
- team\_step-Funktion 297
- Temperatur-Parameter 38
- TensorBoard 29
- Tensoren 43
- TensorFlow 43
- Tensorstufen 43
- Tensorverjüngungen 322
- .terminate()-Methode 134
- test\_model-Funktion 167
- theta-Vektor 207
- Tiefes neuronales Netz 13
- torch.einsum-Funktion 322
- torch.no\_grad()-Methode 75
- torch-Optimierer 115
- train-Funktion 295
- Training 338
  - Curriculum Learning 344
  - Maximum Entropy Learning 343
  - verteiltes Training 128
- Trainingsfunktion 49
- Trainingsprozedur 5
- Transformiertes MNIST 317
- Turnierauswahl 168
- U**
- Übergangswahrscheinlichkeit 54
- Übersetzungsinvarianz 304
- Umgebung 52

- Umsetzungstabelle 17
- unpacked\_params function 164
- .unsqueeze(dim=)-Methode 237
- unsqueeze(...)-Methode 242
- Unterraum-Q-Learning 264
- Unterstützung der Wahrscheinlichkeitsverteilung 197
- update\_dist-Funktion 202, 207
- update\_dist(z, reward)-Funktion 201
- update\_params-Funktion 141, 145
- update\_rate-Funktion 215
- update\_replay-Funktion 341
- use\_extrinsic=False-Funktion 250
- use\_extrinsic=True-Funktion 252
  
- V**
- Varianz 126, 190
- Verjüngungen 322
- Verlustfunktion 44, 106, 115
- Verstärkung der Aktionen 104
- Verteiltes Advantage-Actor-Critic (DA2C) 123, 128
- Verteiltes Rechnen 176
- Verteiltes Training 128
- Verteilungs-Q-Learning 181
  - Atari Freeway spielen 218
  - Bellman-Gleichung 194
  - Implementierung des Dist-DQN 206
  - Vergleich von Wahrscheinlichkeitsverteilungen 208
  - Wahrscheinlichkeiten 187
    - a posteriori 189
    - a priori 189
    - Erwartungswert 190
    - Varianz 190
    - Verteilung in Python 197
- Verzerrung 126, 302
  - Äquivarianz 304
  - Invarianz 304
  
- Visualisierung von Aufmerksamkeitsgewichten 344
- Vorhersagefehler (PE) 227, 255, 257
- Vorverarbeitung 236
- VP (Verbalphrase) 5
  
- W**
- Wahrscheinlichkeiten 187
  - Erwartung 190
- Wahrscheinlichkeitsdichte 191
- Wahrscheinlichkeitsdichtefunktion (PDF) 101
- Wahrscheinlichkeitstheorie 188
- Wahrscheinlichkeitsverhältnis (LR) 210
- Weiche Aufmerksamkeit 307
- Werte 314
- Werteverteilung 195
- Wert-Funktion 54, 56, 60, 124
- Wert-Matrix-Multiplikation 316
- while-Schleife 72, 145, 297
- worker-Funktion 139, 145
- Worker-Knoten 176
  
- X**
- x\_pos key 235
  
- Y**
- y\_correct-Variable 45
- y.detach()-Methode 137
  
- Z**
- Ziel, Definition 103
- Zielfunktion 338
- Zielzerlegung 9
- Zuchtpopulation 158
- Zufallsparameter-Vektoren 158
- Zufallsvariable 192
- Zustand 42, 60, 105, 111
- Zustandsraum 41, 46, 124
- Zustandsvektor 272