

Inhalt

Vorwort	XI
Danksagung	XII
Die Autoren	XII
Über dieses Buch.....	XIII
Teil I: Grundlagen	1
1 Was ist Reinforcement Learning?.....	3
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
2 Modellierung von Reinforcement-Learning-Problemen: Markov Decision Processes	25
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
3	Vorhersage der besten Zustände und Aktionen: Deep Q-Networks	59
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
4	Lernen, die beste Policy auszuwählen: Policy-Gradient-Methoden	97
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
5	Bewältigung komplexerer Probleme mit Actor-Critic-Methoden	121
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	
6	Alternative Optimierungsmethoden:	
	Evolutionäre Algorithmen	153
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
7	Verteilungs-DQN: Die ganze Geschichte	181
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
8	Von Neugierde getriebene Erkundung.....	225
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
9	Lernen mit Multi-Agent Reinforcement Learning.....	259
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
10	Interpretierbares Reinforcement Learning: Aufmerksamkeitsmodelle und relationale Modelle	301
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
11 Abschließend: Rückblick und Fahrplan	351
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
Anhang: Mathematik, Deep Learning, PyTorch	359
A.1 Lineare Algebra	359
A.2 Analysis	361
A.3 Deep Learning	366
A.4 PyTorch	367
Literaturverzeichnis	371
Stichwortverzeichnis	375