

ЛАУРА ГРЕССЕР, ВАН ЛУН КЕНГ

Глубокое обучение с подкреплением

Теория и практика
на языке Python



Санкт-Петербург · Москва · Минск

2022

Краткое содержание

Предисловие	16
Введение.....	18
Благодарности.....	22
Об авторах	23
От издательства	24
Глава 1. Введение в обучение с подкреплением	25

Часть I. Алгоритмы, основанные на стратегиях и полезностях

Глава 2. REINFORCE	52
Глава 3. SARSA.....	81
Глава 4. Глубокие Q-сети.....	112
Глава 5. Улучшение DQN.....	136

Часть II. Комбинированные методы

Глава 6. Метод актора-критика с преимуществом (A2C)	168
Глава 7. Оптимизация ближайшей стратегии.....	198
Глава 8. Методы параллелизации.....	228
Глава 9. Сравнительный анализ алгоритмов.....	239

6 Краткое содержание**Часть III. Практика**

Глава 10. Начало работы с глубоким RL.....	242
Глава 11. SLM Lab.....	274
Глава 12. Архитектура сетей.....	286
Глава 13. Аппаратное обеспечение.....	311

Часть IV. Проектирование сред

Глава 14. Состояния	328
Глава 15. Действия.....	358
Глава 16. Вознаграждения.....	374
Глава 17. Функция переходов.....	383
Заключение	389

Приложения

Приложение А. История глубокого обучения с подкреплением	394
Приложение Б. Примеры сред	397
Список используемых источников	405

Оглавление

Предисловие	16
Введение.....	18
Благодарности.....	22
Об авторах	23
От издательства	24
О научном редакторе русскоязычного издания	24
Глава 1. Введение в обучение с подкреплением	25
1.1. Обучение с подкреплением	25
1.2. Обучение с подкреплением как МППР	31
1.3. Обучаемые функции в обучении с подкреплением.....	35
1.4. Алгоритмы глубокого обучения с подкреплением	37
1.4.1. Алгоритмы, основанные на стратегии	38
1.4.2. Алгоритмы, основанные на полезности	39
1.4.3. Алгоритмы, основанные на модели среды	40
1.4.4. Комбинированные методы	41
1.4.5. Алгоритмы, которые обсуждаются в этой книге.....	42
1.4.6. Алгоритмы по актуальному и отложенному опыту	43
1.4.7. Краткий обзор методов	44
1.5. Глубокое обучение для обучения с подкреплением	44
1.6. Обучение с подкреплением и обучение с учителем	47
1.6.1. Отсутствие оракула.....	47
1.6.2. Разреженность обратной связи.....	48
1.6.3. Генерация данных.....	49
1.7. Резюме	49

**Часть I. Алгоритмы, основанные
на стратегиях и полезностях**

Глава 2. REINFORCE	52
2.1. Стратегия.....	53
2.2. Целевая функция	53
2.3. Градиент стратегии.....	54
2.3.1. Вывод формулы для градиента по стратегиям.....	55
2.4. Выборка методом Монте-Карло.....	58
2.5. Алгоритм REINFORCE.....	59
2.5.1. Усовершенствование метода REINFORCE.....	60
2.6. Реализация REINFORCE.....	61
2.6.1. Минимальная реализация REINFORCE	61
2.6.2. Построение стратегий с помощью PyTorch.....	64
2.6.3. Выборка действий.....	67
2.6.4. Расчет потерь, обусловленных стратегией.....	67
2.6.5. Цикл обучения в REINFORCE.....	68
2.6.6. Класс Memory для хранения примеров при обучении по актуальному опыту	69
2.7. Обучение агента в REINFORCE.....	72
2.8. Результаты экспериментов.....	75
2.8.1. Эксперимент по оценке влияния коэффициента дисконтирования γ	76
2.8.2. Эксперимент по оценке влияния базового значения	78
2.9. Резюме	79
2.10. Рекомендуемая литература.....	80
2.11. Историческая справка	80
Глава 3. SARSA.....	81
3.1. Q-функция и V-функция	82
3.2. Метод временных различий.....	85
3.2.1. Принцип метода временных различий.....	88
3.3. Выбор действий в SARSA	95
3.3.1. Исследование и использование	96
3.4. Алгоритм SARSA	97
3.4.1. Алгоритмы обучения по актуальному опыту.....	98
3.5. Реализация SARSA	99
3.5.1. ϵ -жадная функция выбора действий	99

3.5.2. Расчет Q-функции потерь.....	100
3.5.3. Цикл обучения в SARSA	102
3.5.4. Память для хранения пакетов прецедентов при обучении по актуальному опыту	103
3.6. Обучение агента SARSA.....	105
3.7. Результаты экспериментов.....	108
3.7.1. Эксперимент по определению влияния скорости обучения	108
3.8. Резюме	109
3.9. Рекомендуемая литература	110
3.10. Историческая справка	111
Глава 4. Глубокие Q-сети.....	112
4.1. Настройка Q-функции в DQN	113
4.2. Выбор действий в DQN	115
4.2.1. Стратегия Больцмана	118
4.3. Хранение прецедентов в памяти.....	121
4.4. Алгоритм DQN	122
4.5. Реализация DQN.....	124
4.5.1. Расчет Q-функции потерь.....	124
4.5.2. Цикл обучения DQN.....	125
4.5.3. Память прецедентов	126
4.6. Обучение агента DQN.....	129
4.7. Результаты экспериментов.....	132
4.7.1 Эксперимент по определению влияния архитектуры сети.....	132
4.8. Резюме	134
4.9. Рекомендуемая литература	134
4.10. Историческая справка	135
Глава 5. Улучшение DQN.....	136
5.1. Прогнозные сети	137
5.2. Двойная DQN.....	139
5.3. Приоритизированная память прецедентов	143
5.3.1. Выборка по значимости	145
5.4. Реализация улучшенной DQN.....	146
5.4.1. Инициализация сети.....	147
5.4.2. Расчет Q-функции потерь.....	147
5.4.3. Обновление прогнозной сети	148

10 Оглавление

5.4.4. DQN с прогнозными сетями	149
5.4.5. Двойная DQN	150
5.4.6. Приоритизированная память предшественников.....	150
5.5. Обучение агента DQN играм Atari	156
5.6. Результаты экспериментов.....	161
5.6.1. Эксперимент по оценке применения двойной DQN с PER.....	162
5.7. Резюме	165
5.8. Рекомендуемая литература	165

Часть II. Комбинированные методы

Глава 6. Метод актора-критика с преимуществом (A2C)	168
6.1. Актёр	169
6.2. Критик	169
6.2.1. Функция преимущества	169
6.2.2. Настройка функции преимущества	174
6.3. Алгоритм A2C	175
6.4. Реализация A2C	178
6.4.1. Оценка преимущества.....	178
6.4.2. Расчет функции потерь для полезности и стратегии	181
6.4.3. Цикл обучения актора-критика	181
6.5. Архитектура сети	182
6.6. Обучение агента A2C.....	184
6.6.1. A2C с оценкой преимущества по отдаче за n шагов в Pong	184
6.6.2. A2C с GAE в Pong.....	188
6.6.3. A2C по отдаче за n шагов в BipedalWalker.....	188
6.7. Результаты экспериментов.....	191
6.7.1. Эксперимент по определению влияния отдачи за n шагов	191
6.7.2. Эксперимент по выявлению влияния λ в GAE	193
6.8. Резюме	195
6.9. Рекомендуемая литература	196
6.10. Историческая справка	196
Глава 7. Оптимизация ближайшей стратегии.....	198
7.1. Суррогатная целевая функция.....	199
7.1.1. Падение производительности.....	199
7.1.2. Преобразование целевой функции	201

7.2. Оптимизация ближайшей стратегии	208
7.3. Алгоритм PPO	212
7.4. Реализация PPO	214
7.4.1. Расчет функции потерь для стратегии в PPO	214
7.4.2. Цикл обучения PPO	215
7.5. Обучение агента PPO.....	217
7.5.1. PPO в Pong.....	217
7.5.2. PPO в BipedalWalker.....	220
7.6. Результаты экспериментов.....	223
7.6.1. Эксперимент по определению влияния λ в GAE.....	223
7.6.2. Эксперимент по определению влияния переменной ϵ для усеченной функции потерь	225
7.7. Резюме	226
7.8. Рекомендуемая литература	227
Глава 8. Методы параллелизации.....	228
8.1. Синхронная параллелизация	229
8.2. Асинхронная параллелизация.....	230
8.2.1. Hogwild!.....	232
8.3. Обучение агента A3C.....	234
8.4. Резюме	237
8.5. Рекомендуемая литература	238
Глава 9. Сравнительный анализ алгоритмов.....	239

Часть III. Практика

Глава 10. Начало работы с глубоким RL.....	242
10.1. Приемы проектирования программ	242
10.1.1. Модульное тестирование.....	243
10.1.2. Качество кода	248
10.1.3. Рабочий процесс Git	250
10.2. Рекомендации по отладке.....	252
10.2.1. Признаки жизни.....	253
10.2.2. Диагностирование градиента стратегии.....	254
10.2.3. Диагностирование данных	254
10.2.4. Предварительная обработка	256

12 Оглавление

10.2.5. Память	256
10.2.6. Алгоритмические функции	256
10.2.7. Нейронные сети	257
10.2.8. Упрощение алгоритма	260
10.2.9. Упрощение задачи	260
10.2.10. Гиперпараметры	261
10.2.11. Рабочий процесс в SLM Lab	261
10.3. Практические приемы в играх Atari	263
10.4. Справочник по глубокому обучению с подкреплением	266
10.4.1. Таблицы гиперпараметров	266
10.4.2. Сравнение производительности алгоритмов	269
10.5. Резюме	273
Глава 11. SLM Lab	274
11.1. Алгоритмы, реализованные в SLM Lab	274
11.2. Файл spec	277
11.2.1. Синтаксис поиска в spec	279
11.3. Запуск SLM Lab	282
11.3.1. Команды SLM Lab	283
11.4. Анализ результатов эксперимента	283
11.4.1. Обзор экспериментальных данных	283
11.5. Резюме	285
Глава 12. Архитектура сетей	286
12.1. Виды нейронных сетей	286
12.1.1. Многослойные перцептроны	287
12.1.2. Сверточные нейронные сети	289
12.1.3. Рекуррентные нейронные сети	291
12.2. Рекомендации по выбору семейства сетей	293
12.2.1. Сравнение МППР и частично наблюдаемых МППР	293
12.2.2. Выбор сетей для сред	296
12.3. Net API	300
12.3.1. Выведение размерностей входного и выходного слоев	302
12.3.2. Автоматическое создание сети	304
12.3.3. Шаг обучения	307
12.3.4. Предоставление базовых методов	308
12.4. Резюме	309
12.5. Рекомендуемая литература	309

Глава 13. Аппаратное обеспечение.....	311
13.1. Компьютер	311
13.2. Типы данных	317
13.3. Оптимизация типов данных в RL.....	320
13.4. Выбор аппаратного обеспечения.....	325
13.5. Резюме.....	326

Часть IV. Проектирование сред

Глава 14. Состояния	328
14.1. Примеры состояний.....	328
14.2. Полнота состояния	336
14.3. Сложность состояния	337
14.4. Потеря информации о состоянии.....	343
14.4.1. Преобразование изображений в градации серого	343
14.4.2. Дискретизация.....	344
14.4.3. Конфликты хеширования.....	344
14.4.4. Потери метаинформации.....	345
14.5. Предварительная обработка	348
14.5.1. Стандартизация.....	349
14.5.2. Предварительная обработка изображений.....	351
14.5.3. Предварительная обработка временных данных	353
14.6. Резюме	357
Глава 15. Действия.....	358
15.1. Примеры действий.....	358
15.2. Полнота действий.....	361
15.3. Сложность действий.....	364
15.4. Резюме	369
15.5. Проектирование действий в повседневной жизни	369
Глава 16. Вознаграждения.....	374
16.1. Роль вознаграждений.....	374
16.2. Рекомендации по проектированию вознаграждений	376
16.3. Резюме	382
Глава 17. Функция переходов.....	383
17.1. Проверка осуществимости	383
17.2. Проверка реалистичности	386
17.3. Резюме	388

14 Оглавление

Заключение	389
Воспроизводимость	389
Отрыв от реальности.....	390
Метаобучение и многозадачное обучение	390
Многоагентные задачи.....	391
Эффективность выборки.....	391
Обобщение.....	391
Исследование и структурирование вознаграждений	392

Приложения

Приложение А. История глубокого обучения с подкреплением	394
Приложение Б. Примеры сред	397
Б.1. Дискретные среды.....	398
Б.1.1. CartPole-v0	398
Б.1.2. MountainCar-v0.....	399
Б.1.3. LunarLander-v2.....	400
Б.1.4. PongNoFrameskip-v4	401
Б.1.5. BreakoutNoFrameskip-v4.....	402
Б.2. Непрерывные среды.....	402
Б.2.1. Pendulum-v0	402
Б.2.2. BipedalWalker-v2.....	403
Список используемых источников	405