

Оглавление

Предисловие.....	17
Вступление	19
Благодарности	27
Хобсон Лейн.....	29
Ханнес Макс Хапке	29
Коул Ховард	29
Об этой книге	30
Дорожная карта	30
Что вы найдете в книге	31
О коде	32
Дискуссионный форум liveBook.....	32
Об авторах	33
Об иллюстрации на обложке	34
От издательства	34

Часть I. Машины для обработки слов

Глава 1. Знакомство с технологией NLP.....	37
1.1. Естественный язык в сравнении с языком программирования	38
1.2. Волшебство	39
1.2.1. Машины, которые общаются	40
1.2.2. Математика.....	40
1.3. Практическое применение.....	42
1.4. Язык глазами компьютера	44
1.4.1. Язык замков.....	45
1.4.2. Регулярные выражения.....	46

8 Оглавление

1.4.3. Простой чат-бот	48
1.4.4. Другой вариант	52
1.5. Краткая экскурсия по гиперпространству	56
1.6. Порядок слов и грамматика	58
1.7. Конвейер чат-бота на естественном языке	59
1.8. Углубленная обработка	62
1.9. IQ естественного языка	65
Резюме	67
 Глава 2. Составление словаря: токенизация слов.....	68
2.1. Непростые задачи: обзор стемминга	70
2.2. Построение словаря с помощью токенизатора.....	71
2.2.1. Скалярное произведение	80
2.2.2. Измерение пересечений мультимножеств слов	81
2.2.3. Улучшение токенов.....	82
2.2.4. Расширяем словарь n-граммами.....	87
2.2.5. Нормализация словаря	94
2.3. Тональность	103
2.3.1. VADER — анализатор тональности на основе правил	104
2.3.2. Наивный байесовский классификатор	106
Резюме	110
 Глава 3. Арифметика слов: векторы TF-IDF	111
3.1. Мультимножество слов.....	113
3.2. Векторизация	118
3.2.1. Векторные пространства	120
3.3. Закон Ципфа	126
3.4. Тематическое моделирование	129
3.4.1. Возвращаемся к закону Ципфа.....	132
3.4.2. Ранжирование по релевантности	133
3.4.3. Инструменты.....	136
3.4.4. Альтернативы	137
3.4.5. Okapi BM25	138
3.4.6. Что дальше?	139
Резюме	139
 Глава 4. Поиск смысла слов по их частотностям: семантический анализ	140
4.1. От частотностей слов до оценок тем	142
4.1.1. Векторы TF-IDF и лемматизация	142
4.1.2. Векторы тем.....	143

4.1.3. Мысленный эксперимент	144
4.1.4. Алгоритм оценки тем	149
4.1.5. LDA-классификатор	150
4.2. Латентно-семантический анализ	155
4.2.1. Воплощаем мысленный эксперимент на практике	158
4.3. Сингулярное разложение	160
4.3.1. U — левые сингулярные векторы	162
4.3.2. S — сингулярные значения	163
4.3.3. V^T — правые сингулярные векторы	164
4.3.4. Ориентация SVD-матрицы	165
4.3.5. Усечение тем	166
4.4. Метод главных компонент	168
4.4.1. PCA на трехмерных векторах	170
4.4.2. Хватит возиться с лошадьми, возвращаемся к NLP	171
4.4.3. Применение PCA для семантического анализа СМС	174
4.4.4. Применение усеченного SVD для семантического анализа СМС	176
4.4.5. Насколько хорошо LSA классифицирует спам	177
4.5. Латентное размещение Дирихле	180
4.5.1. Основная идея LDiA	181
4.5.2. Тематическая модель LDiA для СМС	183
4.5.3. LDiA + LDA = классификатор спама	186
4.5.4. Более честное сравнение: 32 темы LDiA	188
4.6. Расстояние и подобие	190
4.7. Стиринг и обратная связь	192
4.7.1. Линейный дискриминантный анализ	194
4.8. Мощь векторов тем	195
4.8.1. Семантический поиск	197
4.8.2. Дальнейшие усовершенствования	200
Резюме	200

Часть II. Более глубокое обучение: нейронные сети

Глава 5. Первые шаги в нейронных сетях: перцептроны и метод обратного распространения ошибки	203
5.1. Нейронные сети, список ингредиентов	204
5.1.1. Перцептрон	205
5.1.2. Числовой перцептрон	205
5.1.3. Коротко про смещение	206
5.1.4. Айда кататься на лыжах — поверхность ошибок	221

10 Оглавление

5.1.5. С подъемника — на склон	222
5.1.6. Проведем небольшую реорганизацию	223
5.1.7. Keras: нейронные сети на Python	224
5.1.8. Вперед и вглубь	228
5.1.9. Нормализация: «стильный» входной сигнал	228
Резюме	229
Глава 6. Умозаключения на основе векторов слов (Word2vec).....	230
6.1. Семантические запросы и аналогии.....	231
6.1.1. Вопросы на аналогию	232
6.2. Векторы слов.....	233
6.2.1. Векторные умозаключения	237
6.2.2. Вычисление представлений Word2vec	240
6.2.3. Использование модуля gensim.word2vec	250
6.2.4. Как сгенерировать свои собственные представления векторов слов	252
6.2.5. Word2vec по сравнению с GloVe (моделью глобальных векторов)	255
6.2.6. FastText.....	256
6.2.7. Word2vec по сравнению с LSA	257
6.2.8. Визуализация связей между словами	258
6.2.9. Искусственные слова	264
6.2.10. Определение сходства документов с помощью Doc2vec	266
Резюме	268
Глава 7. Сверточные нейронные сети.....	269
7.1. Усвоение смысла	271
7.2. Инструментарий	272
7.3. Сверточные нейронные сети	273
7.3.1. Стандартные блоки	274
7.3.2. Размер шага (свертки)	275
7.3.3. Формирование фильтров	276
7.3.4. Дополнение	278
7.3.5. Обучение	279
7.4. Окна и правда узкие	280
7.4.1. Реализация на Keras: подготовка данных	282
7.4.2. Архитектура сверточной нейронной сети	288
7.4.3. Субдискретизация	288
7.4.4. Дропаут	291
7.4.5. Вишненка на торте	292

7.4.6. Приступаем к обучению	294
7.4.7. Применение модели в конвейере	296
7.4.8. Что дальше?	297
Резюме	299
Глава 8. Нейронные сети с обратной связью: рекуррентные нейронные сети.....	300
8.1. Запоминание в нейронных сетях	303
8.1.1. Обратное распространение ошибки во времени	308
8.1.2. Когда что обновлять	311
8.1.3. Краткое резюме	313
8.1.4. Всегда есть какой-нибудь подвох	313
8.1.5. Рекуррентные нейронные сети и Keras	314
8.2. Собираем все вместе	318
8.3. Приступим к изучению прошлого	321
8.4. Гиперпараметры	321
8.5. Предсказание	324
8.5.1. Сохранение состояния	325
8.5.2. И в другую сторону	326
8.5.3. Что это такое?	327
Резюме	328
Глава 9. Эффективное сохранение информации с помощью сетей с долгой краткосрочной памятью	329
9.1. Долгая краткосрочная память	330
9.1.1. Обратное распространение ошибки во времени	341
9.1.2. А как же проверка на практике?	343
9.1.3. «Грязные» данные	345
9.1.4. Возвращаемся к «грязным» данным	348
9.1.5. Работать со словами сложно. С отдельными буквами — проще	349
9.1.6. Моя очередь говорить	354
9.1.7. Моя очередь говорить понятнее	357
9.1.8. Мы научились, как говорить, но не что говорить	365
9.1.9. Другие виды памяти	365
9.1.10. Углубляемся	366
Резюме	368
Глава 10. Модели sequence-to-sequence и механизм внимания	369
10.1. Архитектура типа «кодировщик — декодировщик»	370
10.1.1. Декодирование вектора идеи	371
10.1.2. Знакомо, правда?	374

12 Оглавление

10.1.3. Диалог с помощью sequence-to-sequence	375
10.1.4. Обзор LSTM.....	376
10.2. Компонуем конвейер sequence-to-sequence	377
10.2.1. Подготавливаем набор данных для обучения модели sequence-to-sequence	378
10.2.2. Модель sequence-to-sequence в Keras.....	379
10.2.3. Кодировщик последовательностей.....	380
10.2.4. Декодировщик идеи	382
10.2.5. Формируем сеть sequence-to-sequence	383
10.3. Обучение сети sequence-to-sequence	384
10.3.1. Генерация выходных последовательностей.....	385
10.4. Создание чат-бота с помощью сетей sequence-to-sequence.....	386
10.4.1. Подготовка корпуса для обучения.....	386
10.4.2. Формирование словаря символов.....	388
10.4.3. Генерируем унитарные тренировочные наборы данных	388
10.4.4. Обучение нашего чат-бота sequence-to-sequence	389
10.4.5. Формируем модель для генерации последовательностей	390
10.4.6. Предсказание последовательности	391
10.4.7. Генерация ответа.....	391
10.4.8. Общаемся с нашим чат-ботом	392
10.5. Усовершенствования	393
10.5.1. Упрощаем обучение с помощью группирования данных.....	393
10.5.2. Механизм внимания	394
10.6. На практике	396
Резюме	398

Часть III. Поговорим серьезно. Реальные задачи NLP

Глава 11. Выделение информации: выделение поименованных сущностей и формирование ответов на вопросы.....	401
11.1. Поименованные сущности и отношения.....	401
11.1.1. База знаний	402
11.1.2. Выделение информации.....	405
11.2. Регулярные паттерны	405
11.2.1. Регулярные выражения.....	407
11.2.2. Выделение информации и признаков при машинном обучении	407
11.3. Заслуживающая выделения информация	409
11.3.1. Выделение GPS-координат	409
11.3.2. Выделение дат.....	410

11.4. Выделение взаимосвязей (отношений)	415
11.4.1. Частеречная (POS) разметка	416
11.4.2. Нормализация имен сущностей	420
11.4.3. Нормализация и выделение отношений	421
11.4.4. Паттерны слов	421
11.4.5. Сегментация	422
11.4.6. Почему не получится разбить по ('.!?')	424
11.4.7. Сегментация предложений с помощью регулярных выражений.....	425
11.5. На практике	427
Резюме	428
Глава 12. Начинаем общаться: диалоговые системы	429
12.1. Языковые навыки	430
12.1.1. Современные подходы	432
12.1.2. Гибридный подход	438
12.2. Подход сопоставления с паттернами	439
12.2.1. Сопоставляющий с паттернами чат-бот на основе AIML	440
12.2.2. Сетевое представление сопоставления с паттерном.....	447
12.3. Заземление	448
12.4. Информационный поиск	450
12.4.1. Проблема контекста.....	451
12.4.2. Пример чат-бота на основе информационного поиска.....	453
12.4.3. Чат-бот на основе поиска.....	456
12.5. Порождающие модели.....	459
12.5.1. Разговор в чате про nlpia	459
12.5.2. Достоинства и недостатки каждого из подходов	462
12.6. Подключаем привод на четыре колеса	462
12.6.1. Will — залог нашего успеха	463
12.7. Процесс проектирования	464
12.8. Маленькие хитрости	467
12.8.1. Задавайте вопросы с предсказуемыми ответами	467
12.8.2. Развлекайте пользователей	467
12.8.3. Если все остальное не дает результата — ищите!	468
12.8.4. Стремитесь к популярности	468
12.8.5. Объединяйте людей.....	468
12.8.6. Проявляйте эмоции.....	469
12.9. На практике	469
Резюме	470

Глава 13. Масштабирование: оптимизация, распараллеливание и обработка по батчам	471
13.1. Слишком много хорошего (данных)	472
13.2. Оптимизация алгоритмов NLP.....	472
13.2.1. Индексация.....	473
13.2.2. Продвинутая индексация	475
13.2.3. Продвинутая индексация с помощью пакета Annoy	477
13.2.4. Зачем вообще использовать приближенные индексы.....	481
13.2.5. Решение проблемы индексации: дискретизация.....	482
13.3. Алгоритмы с постоянным расходом RAM.....	483
13.3.1. gensim	484
13.3.2. Вычисления на графах.....	485
13.4. Распараллеливание вычислений NLP	486
13.4.1. Обучение моделей NLP на GPU.....	486
13.4.2. Арендовать или покупать?	487
13.4.3. Варианты аренды GPU	488
13.4.4. Тензорные процессоры	489
13.5. Сокращение объема потребляемой памяти при обучении модели.....	490
13.6. Как почерпнуть полезную информацию о модели с помощью TensorBoard	493
13.6.1. Визуализация вложений слов.....	493
Резюме	496

Приложения

Приложение А. Инструменты для работы с NLP	498
A.1. Anaconda3	498
A.2. Установка пакета nlpia.....	499
A.3. IDE	500
A.4. Система управления пакетами Ubuntu	501
A.5. Mac	502
A.5.1. Система управления пакетами для Macintosh	502
A.5.2. Дополнительные пакеты	502
A.5.3. Настройки.....	502
A.6. Windows	504
A.6.1. Переходите в виртуальность.....	505
A.7. Автоматизация в пакете nlpia	505

Приложение Б. Эксперименты с Python и регулярные выражения	506
Б.1. Работа со строковыми значениями	507
Б.1.1. Типы строк: str и bytes.....	507
Б.1.2. Шаблоны в Python: .format()	508
Б.2. Ассоциативные массивы в Python: dict и OrderedDict	508
Б.3. Регулярные выражения	508
Б.3.1. — OR	509
Б.3.2. () — группы	510
Б.3.3. [] — классы символов	511
Б.4. Стиль	511
Б.5. Овладейте в совершенстве.....	512
Приложение В. Векторы и матрицы: базовые элементы линейной алгебры	513
В.1. Векторы	513
В.2. Расстояния	515
Приложение Г. Инструменты и методы машинного обучения	520
Г.1. Выбор данных и устранение предвзятости	520
Г.2. Насколько хорошо подогнана модель	521
Г.3. Знание — половина победы	523
Г.4. Перекрестное обучение.....	524
Г.5. Притормаживаем модель.....	525
Г.5.1. Регуляризация	525
Г.5.2. Дропаут	526
Г.5.3. Нормализация по мини-батчам	527
Г.6. Несбалансированные тренировочные наборы данных	527
Г.6.1. Супердискретизация	528
Г.6.2. Субдискретизация.....	528
Г.6.3. Дополнение данных	529
Г.7. Метрики эффективности	530
Г.7.1. Оценка эффективности классификатора	530
Г.7.2. Оценка эффективности регрессора	532
Г.8. Советы от профессионалов	533
Приложение Д. Настройка GPU на AWS	535
Д.1. Шаги создания экземпляра с GPU на AWS	536
Д.1.1. Контроль затрат.....	547

16 Оглавление

Приложение Е. Хеширование с учетом локальности	549
E.1. Векторы высокой размерности принципиально различны	550
E.1.1. Индексы и хеши векторного пространства	550
E.1.2. Мыслим многомерно	551
E.2. Многомерная индексация	554
E.2.1. Хеширование с учетом локальности.....	555
E.2.2. Приближенный метод поиска ближайших соседей	555
E.3. Предсказание лайков	556
Источники информации	558
Приложения и идеи проектов.....	558
Курсы и учебные руководства	560
Утилиты и пакеты.....	560
Научные статьи и обсуждения	561
Конкурсы и премии	564
Наборы данных	565
Поисковые системы	565
Глоссарий.....	569
Акронимы	570
Терминология	574