

# Анналин Ын, Кеннет Су

Научная библиотека

БНТУ



\* 8 0 1 2 3 4 1 5 1 \*

# ТЕОРЕТИЧЕСКИЙ МИНИМУМ ПО **BIG DATA**

**ВСЁ, ЧТО НУЖНО ЗНАТЬ О БОЛЬШИХ ДАННЫХ**

## НАУКОВАЯ БІЛЛЯТЭКА

Беларускага нацыянальнага  
тэхнічнага ўніверсітэта

Інв. № 1883848



Санкт-Петербург · Москва · Минск

2022

# Краткое содержание

Методы классификации	9
Метрика регрессии	15
Введение	36
Предисловие	12
Введение	16
Почему Data Science?	18
<b>Глава 1.</b> Об основах без лишних слов	21
<b>Глава 2.</b> Кластеризация методом k-средних	39
<b>Глава 3.</b> Метод главных компонент	51
<b>Глава 4.</b> Ассоциативные правила	65
<b>Глава 5.</b> Анализ социальных сетей	77
<b>Глава 6.</b> Регрессионный анализ	93
<b>Глава 7.</b> Метод k-ближайших соседей и обнаружение аномалий	107
<b>Глава 8.</b> Метод опорных векторов	117
<b>Глава 9.</b> Дерево решений	127
<b>Глава 10.</b> Случайные леса	137
<b>Глава 11.</b> Нейронные сети	149
<b>Глава 12.</b> А/В-тестирование и многорукые бандиты	167
Приложения	179
Глоссарий	188
Литература и ссылки на источники	199
Об авторах	204

# Оглавление

Предисловие .....	12
От издательства.....	15
Введение .....	16
Почему Data Science? .....	18
Глава 1. Об основах без лишних слов.....	21
1.1. Подготовка данных.....	22
Формат данных.....	23
Типы переменных .....	24
Выбор переменных .....	25
Конструирование признаков .....	25
Неполные данные .....	26
1.2. Выбор алгоритма .....	27
Обучение без учителя.....	28
Обучение с учителем .....	29
Обучение с подкреплением .....	30
Другие факторы.....	31

---

1.3. Настройка параметров .....	31
1.4. Оценка результатов .....	33
Метрики классификации .....	34
Метрика регрессии .....	35
Валидация.....	36
1.5. Краткие итоги .....	38
<b>Глава 2. Кластеризация методом k-средних .....</b>	<b>39</b>
2.1. Поиск кластеров клиентов.....	40
2.2. Пример: профили кинозрителей .....	41
2.3. Определение кластеров.....	42
Сколько кластеров существует? .....	44
Что включают кластеры? .....	46
2.4. Ограничения .....	48
2.5. Краткие итоги.....	49
<b>Глава 3. Метод главных компонент .....</b>	<b>51</b>
3.1. Изучение пищевой ценности .....	52
3.2. Главные компоненты.....	53
3.3. Пример: анализ пищевых групп.....	56
3.4. Ограничения .....	61
3.5. Краткие итоги.....	64
<b>Глава 4. Ассоциативные правила .....</b>	<b>65</b>
4.1. Поиск покупательских шаблонов.....	66
4.2. Поддержка, достоверность и лифт .....	67

4.3. Пример: ведение продуктовых продаж .....	69
4.4. Принцип Apriori .....	72
Поиск товарных наборов с высокой поддержкой.....	73
Поиск товарных правил с высокой достоверностью или лифтом.....	74
4.5. Ограничения .....	75
4.6. Краткие итоги.....	76
<b>Глава 5. Анализ социальных сетей .....</b>	<b>77</b>
5.1. Составление схемы отношений.....	78
5.2. Пример: geopolитика в торговле оружием.....	80
5.3. Лувенский метод .....	84
5.4. Алгоритм PageRank .....	86
5.5. Ограничения .....	90
5.6. Краткие итоги .....	91
<b>Глава 6. Регрессионный анализ .....</b>	<b>93</b>
6.1. Выявление линии тренда .....	94
6.2. Пример: предсказание цен на дома .....	95
6.3. Градиентный спуск .....	98
6.4. Коэффициенты регрессии.....	101
6.5. Коэффициенты корреляции.....	102
6.6. Ограничения .....	104
6.7. Краткие итоги.....	106
<b>Глава 7. Метод k-ближайших соседей и обнаружение аномалий .....</b>	<b>107</b>
7.1. Пищевая экспертиза.....	108

7.2. Яблоко от яблони недалеко падает .....	109
7.3. Пример: истинные различия в вине .....	111
7.4. Обнаружение аномалий.....	113
7.5. Ограничения .....	114
7.6. Краткие итоги.....	115
<b>Глава 8. Метод опорных векторов.....</b>	<b>117</b>
8.1 «Нет» или «о, нет!»?.....	118
8.2. Пример: обнаружение сердечно-сосудистых заболеваний .....	118
8.3. Построение оптимальной границы.....	120
8.4. Ограничения .....	124
8.5. Краткие итоги.....	125
<b>Глава 9. Дерево решений.....</b>	<b>127</b>
9.1. Прогноз выживания в катастрофе .....	128
9.2. Пример: спасение с тонущего «Титаника» .....	128
9.3. Создание дерева решений .....	131
9.4. Ограничения .....	133
9.5. Краткие итоги.....	135
<b>Глава 10. Случайные леса.....</b>	<b>137</b>
10.1. Мудрость толпы .....	138
10.2. Пример: предсказание криминальной активности.....	139
10.3. Ансамбли .....	144
10.4. Бэггинг.....	145

10.5. Ограничения.....	147
10.6. Краткие итоги .....	148
<b>Глава 11. Нейронные сети .....</b>	<b>149</b>
11.1. Создание мозга .....	150
11.2. Пример: распознавание рукописных цифр.....	152
11.3. Компоненты нейронной сети.....	156
11.4. Правила активации .....	159
11.5. Ограничения.....	161
11.6. Краткие итоги .....	165
<b>Глава 12. А/В-тестирование и многорукие бандиты ....</b>	<b>167</b>
12.1. Основы А/В-тестирования.....	168
12.2. Ограничения А/В-тестирования.....	169
12.3. Стратегия снижения эпсилона.....	169
12.4. Пример: многорукие бандиты .....	171
12.5. Забавный факт: ставка на победителя.....	174
12.6. Ограничения стратегии снижения эпсилона .....	175
12.7. Краткие итоги .....	176
<b>Приложения .....</b>	<b>179</b>
Приложение А. Обзор алгоритмов обучения без учителя .....	180
Приложение В. Обзор алгоритмов обучения с учителем .....	181
Приложение С. Список параметров настройки .....	182

---

Приложение D. Другие метрики оценки.....	183
Метрики классификации .....	183
Метрики регрессии.....	186
<b>Глоссарий .....</b>	<b>188</b>
<b>Литература и ссылки на источники .....</b>	<b>199</b>
Источники на английском языке .....	199
Литература на русском языке.....	202
<b>Об авторах.....</b>	<b>204</b>