

ГЛАВА 4. ТИПЫ ДАННЫХ И КОНСТРУИРОВАНИЕ ПРИЗНАКОВ

До сих пор мы считали, что наши данные представлены в виде двумерного массива чисел с плавающей точкой, в котором каждый столбец является *непрерывным признаком* (*continuous feature*), описывающим точки данных. Однако во многих случаях это не так. Наиболее распространенным типом признаков являются *категориальные признаки* (*categorical features*). Они еще известны как *дискретные признаки* (*discrete features*), поскольку обычно не имеют числовых значений. Различие между категориальными и непрерывными признаками аналогично различию между классификацией и регрессией, но только с точки зрения входных данных, а не ответов. Примерами непрерывных признаков, которые мы уже рассматривали, являются яркость пикселей и измерения характеристик ирисов. Примерами категориальных признаков являются бренд продукта, цвет продукта или отдел, в котором он продается (книги, одежда, оборудование). Все они являются свойствами, которые могут описать продукт, но при этом не измеряются в непрерывной шкале. Продукт продается либо в отделе одежды, либо в отделе книг. Не существует золотой середины между книгами и одеждой и нет естественного способа упорядочить различные категории (книги не могут быть больше или меньше одежды, оборудование обязательно должно располагаться между книгами и одеждой и т.д.).

Независимо от типов признаков, которыми будут представлены ваши данные, способ их подготовки имеет огромное влияние на качество работы моделей машинного обучения. Мы уже убедились в главах 2 и 3, что масштабирование данных имеет важное значение. Другими словами, если вы не отмасштабируете данные (скажем, к единичной дисперсии), результаты моделирования будут зависеть от единиц измерения признаков. Кроме того, в главе 2 мы уже видели, что улучшить результаты может обогащение данных дополнительными признаками, например, можно добавить взаимодействия (произведения) признаков или полиномы.

Вопрос оптимальной подготовки данных для конкретного прикладного применения известен под названием *feature engineering* (*конструирование признаков*) и является одной из главных задач для специалистов по машинному обучению, пытающихся решить реальные проблемы.

В этой главе мы сначала рассмотрим важные и наиболее распространенные случаи использования категориальных признаков, а

затем приведем некоторые примеры полезных преобразований для конкретных сочетаний признаков и моделей.

Категориальные переменные

В качестве примера мы будем использовать данные о доходах взрослого населения США, полученные из переписи населения 1994 года. Задача, которую мы будем решать при работе с набором данных `adult`, заключается в том, чтобы спрогнозировать наличие у работника дохода более 50000 \$ и менее 50000 \$. Признаками этого набора данных являются возраст работника, тип занятости (частное предприятие, наемный работник, госслужащий и т.д.), образование, пол, продолжительность рабочей недели, род занятий и многое другое. Таблица 4.1 показывает первые несколько записей в наборе данных.

	age	workclass	education	gender	hours-per-week	occupation	income
0	39	State-gov	Bachelors	Male	40	Adm-clerical	<=50K
1	50	Self-emp-not-inc	Bachelors	Male	13	Exec-managerial	<=50K
2	38	Private	HS-grad	Male	40	Handlers-cleaners	<=50K
3	53	Private	11th	Male	40	Handlers-cleaners	<=50K
4	28	Private	Bachelors	Female	40	Prof-specialty	<=50K
5	37	Private	Masters	Female	40	Exec-managerial	<=50K
6	49	Private	9th	Female	16	Other-service	<=50K
7	52	Self-emp-not-inc	HS-grad	Male	45	Exec-managerial	>50K
8	31	Private	Masters	Female	50	Prof-specialty	>50K
9	42	Private	Bachelors	Male	40	Exec-managerial	>50K
10	37	Private	Some-college	Male	80	Exec-managerial	>50K

Таблица 4.1 Первые несколько записей набора данных `adult`

Задача сформулирована в виде классификационной задачи с двумя классами `доход<=50` тыс. и `доход>50` тыс. Можно было бы также спрогнозировать точное значение дохода и это уже была бы регрессионная задача. Однако это было бы гораздо более сложной задачей, а данное разбиение дохода долларов интересно само по себе.

В этом наборе данных `age` и `hours-per-week` являются непрерывными признаками, обработка которых нам уже знакома. Однако признаки `workclass`, `education`, `sex` и `occupation` являются категориальными. Вместо диапазона все они имеют фиксированный список возможных значений и обозначают качественный признак, а не непрерывный.

Для начала предположим, что мы хотим обучить классификатор логистической регрессии на этих данных. Из главы 2 мы знаем, что логистическая регрессия делает прогнозы \hat{y} , используя следующую формулу:

$$\hat{y} = w[0] * x[0] + w[1] * x[1] + \dots + w[p] * x[p] + b > 0$$

где $w[i]$ и b – коэффициенты, вычисленные на обучающей выборке, а $x[i]$ – входные признаки. Эта формула имеет смысл, когда $x[i]$ являются числовыми значениями, но не тогда, когда $x[2]$ соответствует "Masters" или "Bachelors". Очевидно, что нам нужно подготовить данные таким способом, чтобы можно было применить логистическую регрессию. В следующем разделе мы расскажем, как можно решить эту проблему.

Прямое кодирование (дамми-переменные)

На сегодняшний момент наиболее распространенным способом представления категориальных переменных является *прямое кодирование* или, если перевести дословно, *кодирование с одним горячим состоянием* (*one-hot-encoding* или *one-out-of-N encoding*). Идея, лежащая в основе прямого кодирования, заключается в том, чтобы заменить категориальную переменную одной или несколькими новыми признаками, которые могут принимать значения 0 и 1. Значения 0 и 1 придают смысл формуле линейной бинарной классификации (а также всем остальным моделям в `scikit-learn`) и с помощью дамми-переменных мы можем выразить любое количество категорий, вводя по одному новому признаку для каждой категории.

Скажем, признак `workclass` имеет возможные значения "Government Employee", "Private Employee", "Self Employed" и "Self Employed Incorporated". Для того, чтобы закодировать эти четыре возможных значения, мы создаем четыре новых характеристики "Government Employee", "Private Employee", "Self Employed" и "Self Employed Incorporated". Характеристика равна 1, если `workclass` принимает соответствующее значение, или равна 0 в противном случае, поэтому для каждой точки данных только *одна* из четырех новых характеристик будет равна 1. Вот почему данная операция называется *кодированием с одним горячим (активным) состоянием*.

Этот принцип показан в таблице 4.2. Один признак кодируется с помощью четырех новых характеристик. Включив эту информацию в модель машинного обучения, мы не используем исходный признак `workclass`, а работаем только с этими четырьмя характеристиками 0-1.

workclass	Government Employee	Private Employee	Self Employed	Self Employed Incorporated
Government Employee	1	0	0	0
Private Employee	0	1	0	0
Self Employed	0	0	1	0
Self Employed Incorporated	0	0	0	1

Таблица 4.2 Прямое кодирование признака workclass



Прямое кодирование, которое мы используем, довольно схоже с дамми-кодированием, применяемым в статистике, но не идентично ему. В целях упрощения мы кодируем категории переменной с помощью бинарных признаков. В статистике категориальную переменную, принимающую k различных возможных значений (категорий), общепринято кодировать с помощью $k-1$ признаков, при этом для последней категории все признаки будут иметь нулевые значения. Это делается для упрощения анализа (говоря более техническим языком, это позволяет избежать получения матрицы неполного ранга).

Существует два способа выполнить прямое кодирование категориальных переменных, используя либо `pandas`, либо `scikit-learn`. На момент написания книги использование `pandas` выглядело немного проще, поэтому давайте пойдем по этому пути. Сначала с помощью `pandas` загрузим данные, записанные в CSV-файле:

```
In[2]:
import pandas as pd
# Файл не содержит заголовков столбцов, поэтому мы передаем header=None
# и записываем имена столбцов прямо в "names"
data = pd.read_csv(
    "C:/Data/adult.data", header=None, index_col=False,
    names=['age', 'workclass', 'fnlwgt', 'education', 'education-num',
           'marital-status', 'occupation', 'relationship', 'race', 'gender',
           'capital-gain', 'capital-loss', 'hours-per-week', 'native-country',
           'income'])
# В целях упрощения мы выберем лишь некоторые столбцы
data = data[['age', 'workclass', 'education', 'gender', 'hours-per-week',
            'occupation', 'income']]
# IPython.display позволяет вывести красивый вывод, отформатированный в Jupyter notebook
display(data.head())
```

Таблица 4.3 показывает результат.

	age	workclass	education	gender	hours-per-week	occupation	income
0	39	State-gov	Bachelors	Male	40	Adm-clerical	<=50K
1	50	Self-emp-not-inc	Bachelors	Male	13	Exec-managerial	<=50K
2	38	Private	HS-grad	Male	40	Handlers-cleaners	<=50K
3	53	Private	11th	Male	40	Handlers-cleaners	<=50K
4	28	Private	Bachelors	Female	40	Prof-specialty	<=50K

Таблица 4.3 Первые пять строк набора данных adult

Проверка категориальных данных, закодированных в виде строк

Прочитав набор данных, аналогичный приведенному выше, как правило, неплохо было бы сперва проверить, содержит ли столбец на самом деле осмысленные категориальные данные. При работе с данными, которые были введены людьми (например, пользователями на сайте), получить фиксированный набор категорий невозможно, наличие различных вариантов написания слов может потребовать предварительной обработки. Например, некоторые могут определить свой пол как «мужской», а некоторые просто напишут «мужчина» и нам, возможно, потребуется поместить эти два варианта в одну и ту же категорию. Хороший способ проверить содержимое столбца – воспользоваться функцией `value_counts` для пандасовского типа данных `Series` (каждый столбец `DataFrame` является структурой `Series`), чтобы посмотреть, что представляют из себя уникальные значения и как часто они встречаются:

```
In[3]:  
print(data.gender.value_counts())
```

```
Out[3]:  
Male 21790  
Female 10771  
Name: gender, dtype: int64
```

Видно, что в этом наборе данных пол имеет строго два значения, `Male` и `Female`, то есть данные уже находятся в подходящем формате, чтобы записать их, используя прямое кодирование. В реальном примере вы должны просмотреть все столбцы и проверить их значения. Мы пропустим этот момент для краткости.

Библиотека `pandas` предлагает очень простой способ кодирования данных с помощью функции `get_dummies`. Функция `get_dummies` автоматически преобразует все столбцы, которые содержат объектные типы (например, строки) или являются категориальными данными (речь идет о специальном понятии `pandas`, о котором мы еще не говорили):

```
In[4]:  
print("Исходные признаки:\n", list(data.columns), "\n")  
data_dummies = pd.get_dummies(data)  
print("Признаки после get_dummies:\n", list(data_dummies.columns))
```

Out[4]:

Исходные признаки:

```
['age', 'workclass', 'education', 'gender', 'hours-per-week', 'occupation',
 'income']
```

Исходные признаки после get_dummies:

```
['age', 'hours-per-week', 'workclass_?', 'workclass_Federal-gov',
 'workclass_Local-gov', 'workclass_Never-worked', 'workclass_Private',
 'workclass_Self-emp-inc', 'workclass_Self-emp-not-inc',
 'workclass_State-gov', 'workclass_Without-pay', 'education_10th',
 'education_11th', 'education_12th', 'education_1st-4th',
 ...
 'education_Preschool', 'education_Prof-school', 'education_Some-college',
 'gender_Female', 'gender_Male', 'occupation_?',
 'occupation_Adm-clerical', 'occupation_Armed-Forces',
 'occupation_Craft-repair', 'occupation_Exec-managerial',
 'occupation_Farming-fishing', 'occupation_Handlers-cleaners',
 ...
 'occupation_Tech-support', 'occupation_Transport-moving',
 'income_<=50K', 'income_>50K']
```

Видно, что непрерывные признаки `age` и `hours-per-week` остались неизменными, тогда как для каждого возможного значения категориального признака были созданы новые характеристики.

In[5]:

```
data_dummies.head()
```

Out[5]:

	age	hours-per-week	workclass_?	workclass_Federal-gov	workclass_Local-gov	...	occupation_Tech-support	occupation_Transport-moving	income_<=50K	income_>50K
0	39	40	0.0	0.0	0.0	...	0.0	0.0	1.0	0.0
1	50	13	0.0	0.0	0.0	...	0.0	0.0	1.0	0.0
2	38	40	0.0	0.0	0.0	...	0.0	0.0	1.0	0.0
3	53	40	0.0	0.0	0.0	...	0.0	0.0	1.0	0.0
4	28	40	0.0	0.0	0.0	...	0.0	0.0	1.0	0.0

5 rows × 46 columns

Теперь мы можем воспользоваться атрибутом `values`, что преобразовать пандасовский data-фрейм `data_dummies` в массив NumPy, а затем обучить на его основе модель машинного обучения. Перед построением модели убедитесь в том, что зависимая переменная (которая теперь кодируется в двух столбцах `income`) отделена от данных. Включение зависимой переменной или некоторых признаков, являющихся производными от зависимой переменной, в пространство входных признаков является очень распространенной ошибкой при построении моделей машинного обучения с учителем.



Будьте осторожны: индексация столбцов в `pandas` включает конец диапазона, поэтому `'age': 'occupation_Transport-moving'` включает в себя `occupation_Transport-moving`. Данная операция отличается от нарезки массива NumPy, в котором конец диапазона не включается: например, `np.arange(11) [0:10]` не включает в себя элемент с индексом 10.

В данном случае мы извлечем только те столбцы, которые содержат входные признаки, то есть, все столбцы от `age` до `occupation_Transport`. Этот диапазон содержит все входные признаки, при этом зависимая переменная в него не включена:

In[6]:

```
# Берем только те столбцы, которые содержат признаки,
# то есть все столбцы, начиная с 'age' и заканчивая 'occupation_Transport-moving'
# Этот диапазон содержит все признаки, кроме целевой переменной
features = data_dummies.ix[:, 'age':'occupation_Transport-moving']
# Извлекаем массивы NumPy
X = features.values
y = data_dummies['income_>50K'].values
print("форма массива X: {} форма массива у: {}".format(X.shape, y.shape))
```

Out[6]:

```
форма массива X: (32561, 44) форма массива у: (32561,)
```

Теперь данные представлены в том формате, который `scikit-learn` умеет обрабатывать, и мы можем продолжить построение модели в обычном режиме:

In[7]:

```
from sklearn.linear_model import LogisticRegression
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y, random_state=0)
logreg = LogisticRegression()
logreg.fit(X_train, y_train)
print("Правильность на тестовом наборе: {:.2f}".format(logreg.score(X_test, y_test)))
```

Out[7]:

```
Правильность на тестовом наборе: 0.81
```



В этом примере мы вызвали функцию `get_dummies` и передали ей в качестве аргумента пандасовский `DataFrame`, содержащий как обучающие, так и тестовые данные. Это важно с точки зрения одинакового представления значений категориальных признаков в обучающем и тестовом наборах.

Представьте, что у нас обучающий и тестовые наборы записаны в двух разных пандасовских дата-фреймах. Если в тестовом наборе у признака `workclass` будет отсутствовать значение "Private Employee", `pandas` предположит, что существуют только три возможных значения этого признака и создаст лишь три новых дамми-переменных. Теперь у признака `workclass` разное количество дамми-переменных в обучающем и тестовом наборах и мы уже больше не можем применить к тестовому набору модель, построенную на обучающей выборке. Возьмем ситуацию еще хуже, представьте себе, что признак `workclass` принимает значения "Government Employee" и "Private Employee" в обучающем наборе и "Self Employed" и "Self Employed Incorporated" в тестовом наборе. В обоих случаях `pandas` создаст две новые дамми-переменные, таким образом перекодированные дата-фреймы будут иметь одинаковое количество дамми-переменных. Однако эти две дамми-переменные имеют совершенно различный смысл в обучающем и тестовом наборах. Столбец, соответствующий

значению "Government Employee" в обучающем наборе, будет закодирован как "Self Employed" в тестовом наборе.

Модель машинного обучения, построенная на этих данных, будет работать очень плохо, потому что исходит из того, что столбцы соответствуют одному и тому же возможному значению категориального признака (ведь они имеют одинаковое расположение в массивах), тогда как на самом деле они соответствуют совершенно разным значениям. Чтобы это исправить, вызовите функцию `get_dummies` и передайте ей в качестве аргумента дата-фрейм, содержащий как обучающие, так и тестовые данные, или уже после вызова `get_dummies` убедитесь в том, что имена столбцов одинаковы для обучающего и тестовых наборов и имеют один и тот же смысл.

Числа можно закодировать в виде категорий

В примере с набором данных `adult` категориальные переменные были закодированы в виде строк. С одной стороны, это чревато орфографическими ошибками, но, с другой стороны, это позволяет четко отнести признак к категориальной переменной. Часто для удобства хранения или из-за способа сбора данных категориальные переменные кодируются в виде целых чисел. Например, представьте, что данные переписи, представленные в наборе `adult`, были собраны с помощью анкеты, и ответы, касающиеся типа занятости (`workclass`), были записаны как 0 (первый пункт отмечен галочкой), 1 (второй пункт отмечен галочкой), 2 (третий пункт отмечен галочкой) и так далее. Теперь столбец будет содержать цифры от 0 до 8, а не строки типа "`Private`", и если кто-то посмотрит на таблицу, представляющую набор данных, он не сможет с уверенностью отличить непрерывную переменную от категориальной. Хотя мы знаем, что цифры указывают на тип занятости, ясно, что все они соответствуют совершенно различным состояниям и их не следует моделировать с помощью одной непрерывной переменной.



Категориальные признаки часто кодируются с помощью целых чисел. Тот факт, что для кодировки используются числа, вовсе не означает, что они должны обрабатываться как непрерывные признаки. Не всегда ясно, следует ли обрабатывать целочисленные значения признаков как непрерывные или дискретные (а также преобразованные с помощью прямого кодирования). Если кодируемые значения не упорядочены (как в примере с `workclass`), признак должен рассматриваться как дискретный. В остальных случаях, например, когда признак представляет собой пятизвездочный рейтинг, выбор оптимальной схемы кодирования зависит от конкретной задачи и данных, а также используемого алгоритма машинного обучения.

Функция `get_dummies` в `pandas` обрабатывает все числа как непрерывные значения и не будет создавать дамми-переменные для них. Чтобы обойти эту проблему, вы можете либо воспользоваться `OneHotEncoder` в `scikit-learn` (указав, какие переменные являются непрерывными, а какие – дискретными), либо преобразовать столбцы с числами, содержащиеся в дата-фрейме, в строки. Чтобы проиллюстрировать это, давайте создадим объект `DataFrame` с двумя столбцами, один из которых содержит строки, а другой – целые числа:

In[8]:

```
# создаем дата-фрейм с признаком, который принимает целочисленные значения,
# и категориальным признаком, у которой значения являются строками
demo_df = pd.DataFrame({'Целочисленный признак': [0, 1, 2, 1],
                        'Категориальный признак': ['socks', 'fox', 'socks', 'box']})
display(demo_df)
```

Таблица 4.4 показывает результат.

Категориальный признак	Целочисленный признак
0 socks	0
1 fox	1
2 socks	2
3 box	1

Таблица 4.4 Дата-фрейм, содержащий категориальный строковый признак и целочисленный признак

Функция `get_dummies` закодирует лишь строковый признак, тогда как целочисленный признак оставит без изменений, как это видно в таблице 4.5:

In[9]:

```
pd.get_dummies(demo_df)
```

Целочисленный признак	Категориальный признак_box	Категориальный признак_fox	Категориальный признак_sock
0 0	0.0	0.0	1.0
1 1	0.0	1.0	0.0
2 2	0.0	0.0	1.0
3 1	1.0	0.0	0.0

Таблица 4.5 Данные таблицы 4.4, преобразованные с помощью прямого кодирования, целочисленный признак остался без изменений

Если вы хотите создать дамми-переменные для столбца «Целочисленный признак», вы можете явно указать столбцы, которые

нужно закодировать, с помощью параметра `columns`. И тогда оба признака будут обработаны как категориальные переменные (см. табл. 4.6):

In[10]:

```
demo_df['Целочисленный признак'] = demo_df['Целочисленный признак'].astype(str)
pd.get_dummies(demo_df, columns=['Целочисленный признак', 'Категориальный признак'])
```

	Целочисленный признак_0	Целочисленный признак_1	Целочисленный признак_2	Категориальный признак_box	Категориальный признак_fox	Категориальный признак_socks
0	1.0	0.0	0.0	0.0	0.0	1.0
1	0.0	1.0	0.0	0.0	1.0	0.0
2	0.0	0.0	1.0	0.0	0.0	1.0
3	0.0	1.0	0.0	1.0	0.0	0.0

Таблица 4.6 Данные таблицы 4.4, преобразованные с помощью прямого кодирования, закодированы целочисленный и строковый признаки

Биннинг, дискретизация, линейные модели и деревья

Оптимальный способ представления данных зависит не только от содержательного смысла данных, но и от вида используемой модели. Линейные модели и модели на основе дерева (например, деревья решений, градиентный бустинг деревьев решений и случайный лес), представляющие собой две большие и наиболее часто используемые группы методов, сильно отличаются друг от друга с точки зрения обработки признаков различных типов. Давайте вернемся к набору данных `wave`, который мы использовали для регрессионного анализа в главе 2. Он имеет лишь один входной признак. Ниже приводится сравнение результатов модели линейной регрессии и дерева регрессии для этого набора данных (см. рис. 4.1):

In[11]:

```
from sklearn.linear_model import LinearRegression
from sklearn.tree import DecisionTreeRegressor

X, y = mglearn.datasets.make_wave(n_samples=100)
line = np.linspace(-3, 3, 1000, endpoint=False).reshape(-1, 1)

reg = DecisionTreeRegressor(min_samples_split=3).fit(X, y)
plt.plot(line, reg.predict(line), label="дерево решений")

reg = LinearRegression().fit(X, y)
plt.plot(line, reg.predict(line), label="линейная регрессия")

plt.plot(X[:, 0], y, 'o', c='k')
plt.ylabel("Выход регрессии")
plt.xlabel("Входной признак")
plt.legend(loc="best")
```

Как вам известно, линейные модели могут моделировать только линейные зависимости, которые представляют собой линии в случае одного признака. Дерево решений может построить гораздо более сложную модель данных. Результаты сильно зависят от представления

данных. Одним из способов повысить прогнозную силу линейных моделей при работе с непрерывными данными является *биннинг* характеристик (*binning*), также известный как *дискретизация* (*discretization*), который разбивает исходный признак на несколько категорий.

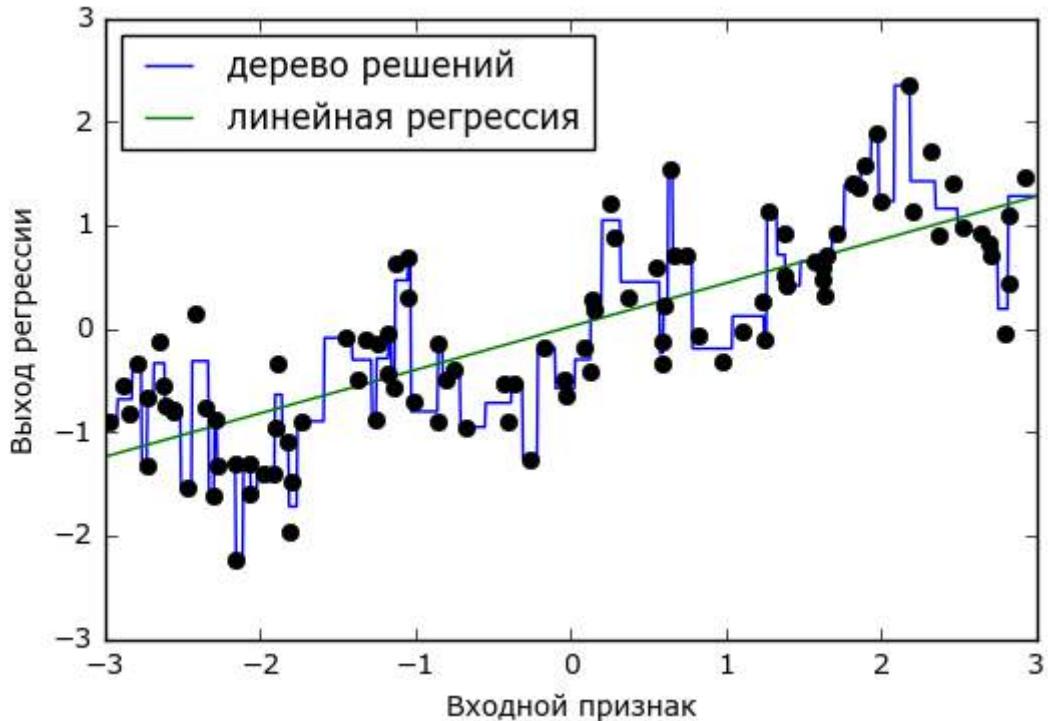


Рис. 4.1 Сравнение результатов модели линейной регрессии и дерева регрессии для набора данных wave

Представим, что диапазон значений входного признака (в данном случае от -3 до 3) разбит на определенное количество *категорий* или *бинов* (*bins*), допустим, на 10 категорий. Точка данных будет представлена категорией, в которую она попадает. Сначала мы должны задать категории. В данном случае мы зададим 10 категорий, равномерно распределенных между -3 и 3. Для этого мы используем функцию `np.linspace`, создаем 11 элементов, которые дадут 10 категорий – интервалов, ограниченных двумя границами:

```
In[12]:  
bins = np.linspace(-3, 3, 11)  
print("категории: {}".format(bins))
```

```
Out[12]:  
категории: [-3. -2.4 -1.8 -1.2 -0.6 0. 0.6 1.2 1.8 2.4 3. ]
```

При этом первая категория содержит все точки данных со значениями признака от -3 до -2.68, вторая категория содержит все точки со значениями признака от -2.68 до -2.37 и так далее.

Далее мы записываем для каждой точки данных категорию, в которую она попадает. Это можно легко вычислить с помощью функции `np.digitize`:

```
In[13]:  
which_bin = np.digitize(X, bins=bins)  
print("\nТочки данных:\n", X[:5])  
print("\nКатегории для точек данных:\n", which_bin[:5])  
  
Out[13]:  
Точки данных:  
[[-0.753]  
 [ 2.704]  
 [ 1.392]  
 [ 0.592]  
 [-2.064]]  
  
Категории для точек данных:  
[[ 4]  
 [10]  
 [ 8]  
 [ 6]  
 [ 2]]
```

То, что мы сделали здесь, называется преобразованием непрерывного входного признака набора данных `wave` в категориальный признак. С помощью категориального признака мы задаем категорию для каждой точки данных. Чтобы запустить модель `scikit-learn` на этих данных, мы выполним прямое кодирование этого дискретного признака с помощью функции `OneHotEncoder` из модуля `preprocessing`. Функция `OneHotEncoder` выполняет ту же самую кодировку, что и `pandas.get_dummies`, хотя в настоящее время она работает только с категориальными переменными, которые принимают целочисленные значения:

```
In[14]:  
from sklearn.preprocessing import OneHotEncoder  
# преобразовываем с помощью OneHotEncoder  
encoder = OneHotEncoder(sparse=False)  
# encoder.fit находит уникальные значения, имеющиеся в which_bin  
encoder.fit(which_bin)  
# transform осуществляет прямое кодирование  
X_binned = encoder.transform(which_bin)  
print(X_binned[:5])  
  
Out[14]:  
[[ 0.  0.  0.  1.  0.  0.  0.  0.  0.  0.]  
 [ 0.  0.  0.  0.  0.  0.  0.  0.  1.]  
 [ 0.  0.  0.  0.  0.  0.  0.  1.  0.  0.]  
 [ 0.  0.  0.  0.  0.  1.  0.  0.  0.  0.]  
 [ 0.  1.  0.  0.  0.  0.  0.  0.  0.  0.]]
```

Поскольку мы указали 10 категорий, преобразованный набор данных `X_binned` теперь состоит из 10 признаков:

```
In[15]:  
print("форма массива X_binned: {}".format(X_binned.shape))
```

Out[15]:

форма массива X_binned: (100, 10)

Сейчас мы строим новую модель линейной регрессии и новую модель дерева решений на основе данных, преобразованных с помощью прямого кодирования. Результат визуализирован на рис. 4.2, также показаны границы категорий, обозначенные вертикальными серыми линиями:

In[16]:

```
line_binned = encoder.transform(np.digitize(line, bins=bins))

reg = LinearRegression().fit(X_binned, y)
plt.plot(line, reg.predict(line_binned), label='линейная регрессия после биннинга')

reg = DecisionTreeRegressor(min_samples_split=3).fit(X_binned, y)
plt.plot(line, reg.predict(line_binned), label='дерево решений после биннинга')
plt.plot(X[:, 0], y, 'o', c='k')
plt.vlines(bins, -3, 3, linewidth=1, alpha=.2)
plt.legend(loc="best")
plt.ylabel("Выход регрессии")
plt.xlabel("Входной признак")
```

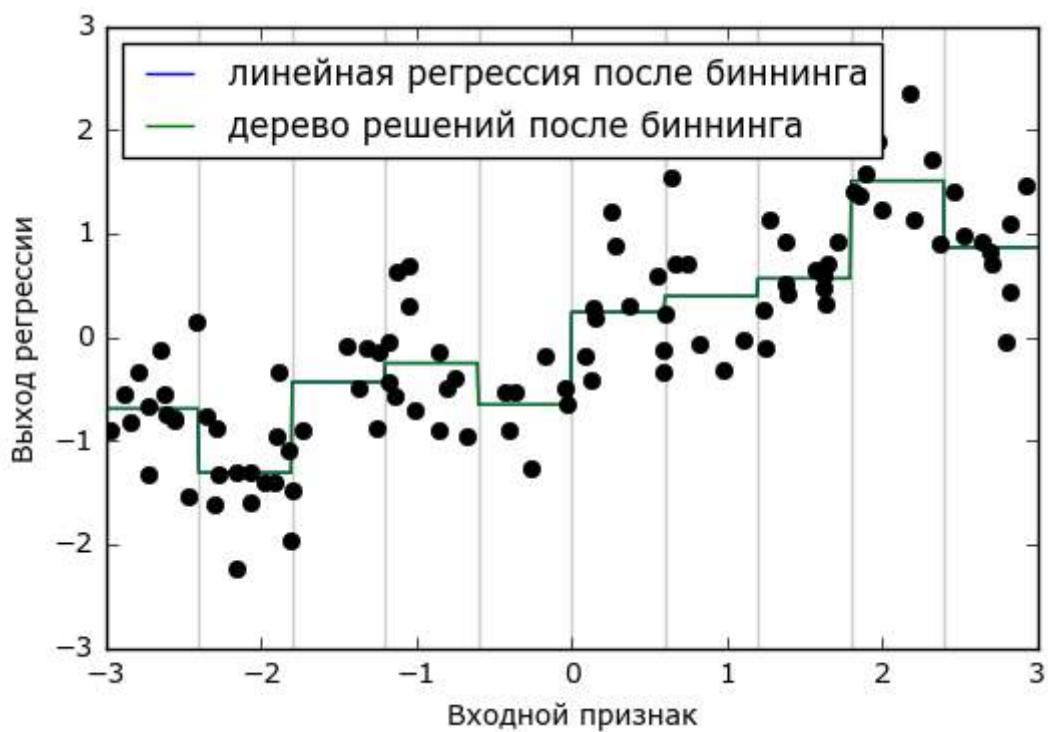


Рис. 4.2 Сравнение результатов модели линейной регрессии и дерева регрессии после проведения биннинга

Синяя и зеленая линии лежат точно поверх друг друга, это означает, что модель линейной регрессии и дерева решений дают одинаковые прогнозы. Для каждой категории они предсказывают одно и то же значение (константу). Поскольку признаки принимают одно и то же значение в пределах каждой категории, любая модель должна предсказывать одно и то же значение для всех точек, находящихся

внутри категории. Сравнив модели, обученные до и после биннинга переменных, мы видим, что линейная модель стала теперь гораздо более гибкой, потому что теперь она присваивает различные значения категориям, в то время как модель дерева решений стала существенно менее гибкой. В целом биннинг признаков не дает положительного эффекта для моделей на основе дерева, поскольку эти модели сами могут научится разбивать данные по любому значению. В некотором смысле это означает, что деревья решений могут самостоятельно осуществить биннинг для наилучшего прогнозирования данных. Кроме того, при выполнении разбиений дерева решений рассматривают несколько признаков сразу, в то время как обычный биннинг выполняется на основе анализа одного признака. Однако линейная модель после преобразования данных выиграла с точки зрения эффективности.

Если есть веские причины использовать линейную модель для конкретного набора данных (например, он имеет большой объем и является многомерным), но некоторые признаки имеют нелинейные взаимосвязи с зависимой переменной – биннинг может быть отличным способом увеличить прогнозную силу модели.

Взаимодействия и полиномы

Еще один способ обогатить пространство признаков, в частности, для линейных моделей, заключается в добавлении *взаимодействий признаков* (*interaction features*) и *полиномиальных признаков* (*polynomial features*). Конструирование признаков подобного рода получило распространение в статистическом моделировании, а также широко используется во многих практических сферах применения машинного обучения.

Для начала снова посмотрите на рис. 4.2. Для каждой категории признака линейная модель предсказывает одно и то же значение. Однако мы знаем, что линейные модели могут вычислить не только значения сдвига, но и значения наклона. Один из способов добавить наклон в линейную модель, построенную на основе категоризированных данных, заключается в том, чтобы добавить обратно исходный признак (ось x на графике). Это приведет к получению 11-мерного массива данных, как показано на рис. 4.3:

```
In[17]:  
X_combined = np.hstack([X, X_binned])  
print(X_combined.shape)
```

```
Out[17]:  
(100, 11)
```

```
In[18]:
reg = LinearRegression().fit(X_combined, y)

line_combined = np.hstack([line, line_binned])
plt.plot(line, reg.predict(line_combined), label='линейная регрессия после комбинирования')

for bin in bins:
    plt.plot([bin, bin], [-3, 3], ':', c='k')

plt.legend(loc="best")
plt.ylabel("Выход регрессии")
plt.xlabel("Входной признак")
plt.plot(X[:, 0], y, 'o', c='k')
```

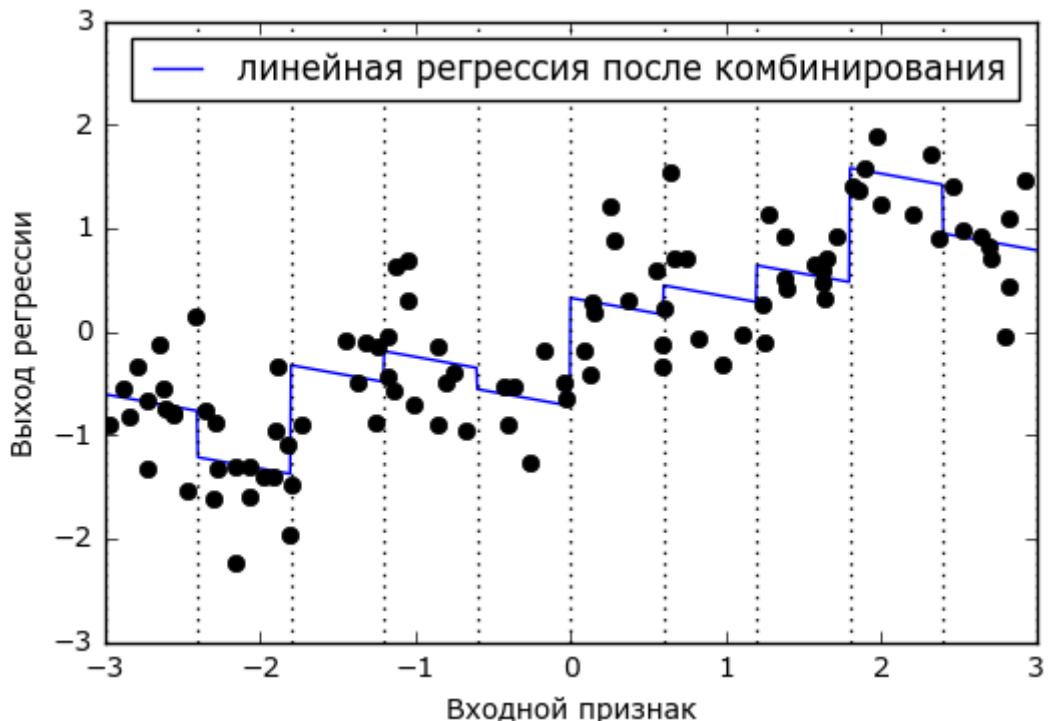


Рис. 4.3 Линейная регрессия с использованием категоризированных признаков и одним глобальным наклоном

В этом примере модель вычислила сдвиг для каждой категории, а также наклон. Вычисленный наклон направлен вниз и он является общим для всех категорий, так как у нас имеется только один признак по оси x с одним коэффициентом. Поскольку наличие одного наклона для всех категорий не очень сильно поможет с точки зрения моделирования, мы бы хотели вычислить для каждой категории свой собственный наклон! Мы можем добиться этого, добавив взаимодействие или произведение признаков, указывающее категорию точки данных и ее расположение на оси x . Данный признак является произведением индикатора категории и исходной переменной. Давайте создадим этот набор данных:

```
In[19]:
X_product = np.hstack([X_binned, X * X_binned])
print(X_product.shape)
```

```
Out[19]:  
(100, 20)
```

Теперь набор данных содержит 20 признаков: в него записывается индикатор категории, в которой находится точка данных, а также произведение исходного признака и индикатора категории. Произведение признаков можно представить как отдельную копию признака, отложенного по оси x , для каждой категории. Оно соответствует исходному признаку, попадающему в данную категорию, или нулю во всех остальных случаях. На рис. 4.4 показан результат линейной модели для этого нового пространства признаков:

```
In[20]:
```

```
reg = LinearRegression().fit(X_product, y)

line_product = np.hstack([line_binned, line * line_binned])
plt.plot(line, reg.predict(line_product), label='линейная регрессия произведение')

for bin in bins:
    plt.plot([bin, bin], [-3, 3], ':', c='k')

plt.plot(X[:, 0], y, 'o', c='k')
plt.ylabel("Выход регрессии")
plt.xlabel("Входной признак")
plt.legend(loc="best")
```

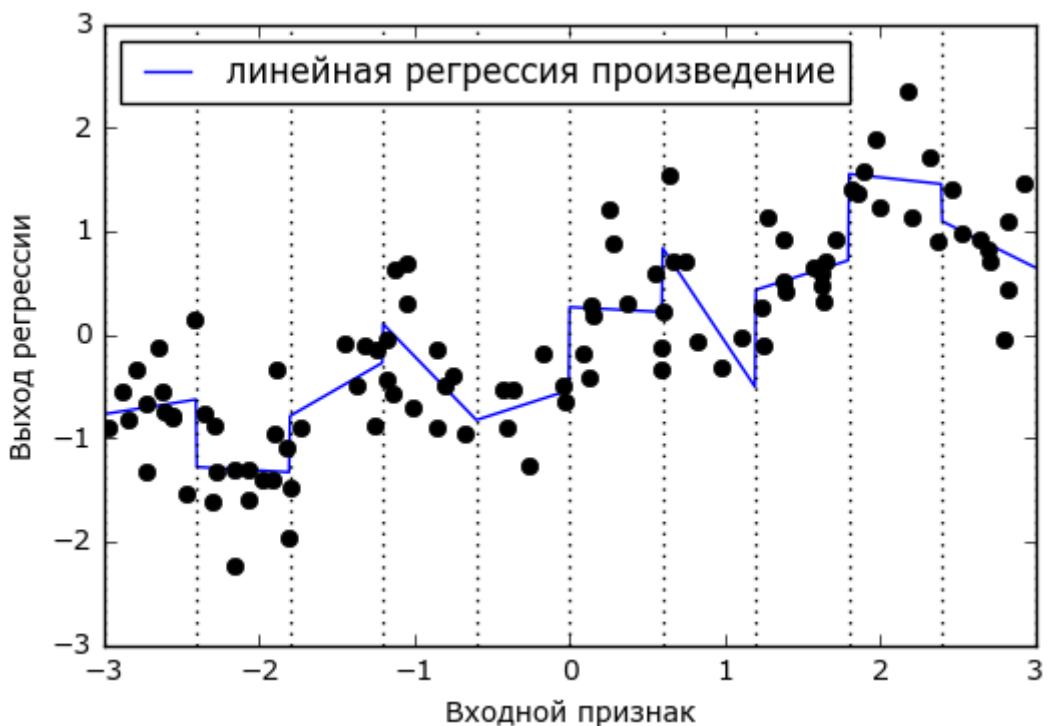


Рис. 4.4 Линейная регрессия с отдельным наклоном для каждой категории

Видно, что теперь каждая категория имеет свое собственное значение сдвига и свое собственное значение наклона.

Использование биннинга – это способ увеличения пространства входных признаков. Еще один способ заключается в использовании

полиномов (*polynomials*) исходных признаков. Для признака x мы рассмотрим $x^{** 2}$, $x^{** 3}$, $x^{** 4}$ и так далее. Данную операцию можно выполнить с помощью **PolynomialFeatures** модуля **preprocessing**:

In[21]:
`from sklearn.preprocessing import PolynomialFeatures`

```
# задаем степень полинома 10:  
# значение по умолчанию "include_bias=True" добавляет признак-константу 1  
poly = PolynomialFeatures(degree=10, include_bias=False)  
poly.fit(X)  
X_poly = poly.transform(X)
```

Использование 10-й степени дает 10 признаков:

In[22]:
`print("форма массива X_poly: {}".format(X_poly.shape))`

Out[22]:
форма массива X_poly: (100, 10)

Давайте сравним элементы массива `X_poly` с элементами массива `X`:

In[23]:
`print("Элементы массива X:\n{}".format(X[:5]))
print("Элементы массива X_poly:\n{}".format(X_poly[:5]))`

Out[23]:
Элементы массива X:
[[-0.753]
 [2.704]
 [1.392]
 [0.592]
 [-2.064]]

Элементы массива X_poly:
[[-0.753 0.567 -0.427 0.321 -0.242 0.182
 -0.137 0.103 -0.078 0.058]
 [2.704 7.313 19.777 53.482 144.632 391.125
 1057.714 2860.360 7735.232 20918.278]
 [1.392 1.938 2.697 3.754 5.226 7.274
 10.125 14.094 19.618 27.307]
 [0.592 0.350 0.207 0.123 0.073 0.043
 0.025 0.015 0.009 0.005]
 [-2.064 4.260 -8.791 18.144 -37.448 77.289
 -159.516 329.222 -679.478 1402.367]]

Вы можете понять содержательный смысл этих признаков, вызвав метод `get_feature_names`, который выведет название каждого признака:

In[24]:
`print("Имена полиномиальных признаков:\n{}".format(poly.get_feature_names()))`

Out[24]:
Имена полиномиальных признаков:
['x0', 'x0^2', 'x0^3', 'x0^4', 'x0^5', 'x0^6', 'x0^7', 'x0^8', 'x0^9', 'x0^10']

Видно, что первый столбец `X_poly` точно соответствует `X`, в то время как другие столбцы являются различными степенями первого элемента.

Использование полиномиальных признаков в модели линейной регрессии дает классическую модель *полиномиальной регрессии* (*polynomial regression*), представленную на рис. 4.5:

In[26]:

```
reg = LinearRegression().fit(X_poly, y)

line_poly = poly.transform(line)
plt.plot(line, reg.predict(line_poly), label='полиномиальная линейная регрессия')
plt.plot(X[:, 0], y, 'o', c='k')
plt.ylabel("Выход регрессии")
plt.xlabel("Входной признак")
plt.legend(loc="best")
```

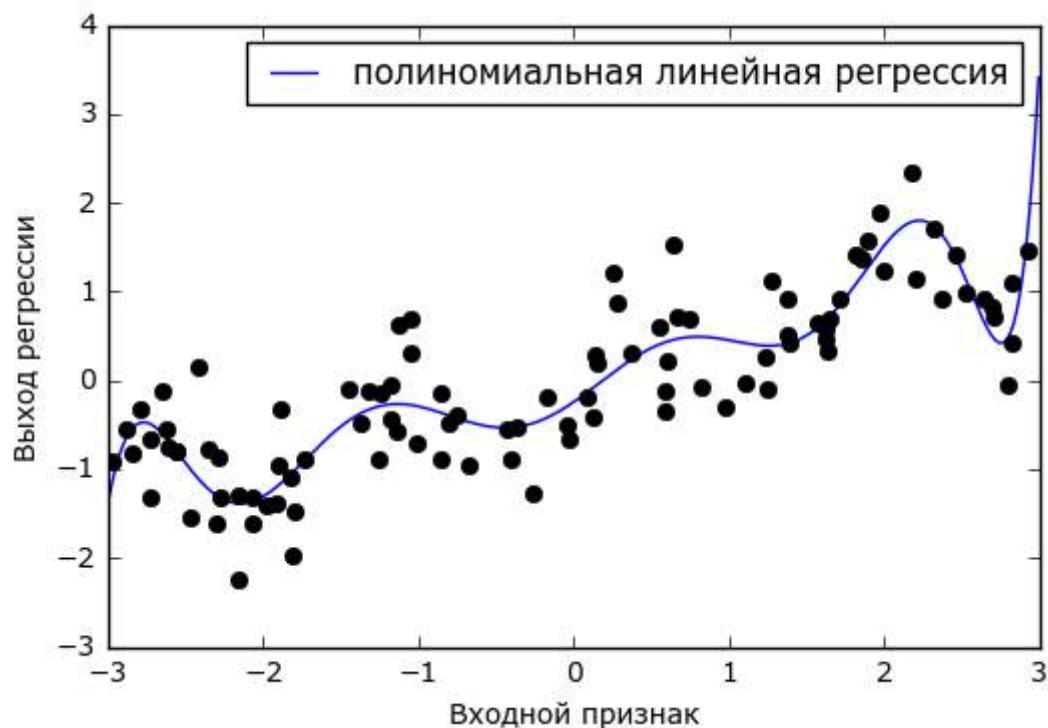


Рис. 4.5 Полиномиальная линейная регрессия, использовался полином 10-й степени

Видно, что на этом одномерном наборе данных полиномиальные признаки дают очень сглаженную подгонку. Однако полиномы высокой степени, как правило, резко меняют направление на границах области определения или в менее плотных областях данных.

Для сравнения ниже приводится модель ядерного SVM, обученная на исходных данных без каких-либо преобразований (см. рис. 4.6):

```
In[26]:  
from sklearn.svm import SVR  
  
for gamma in [1, 10]:  
    svr = SVR(gamma=gamma).fit(X, y)  
    plt.plot(line, svr.predict(line), label='SVR gamma={}'.format(gamma))  
  
plt.plot(X[:, 0], y, 'o', c='k')  
plt.ylabel("Выход регрессии")  
plt.xlabel("Входной признак")  
plt.legend(loc="best")
```

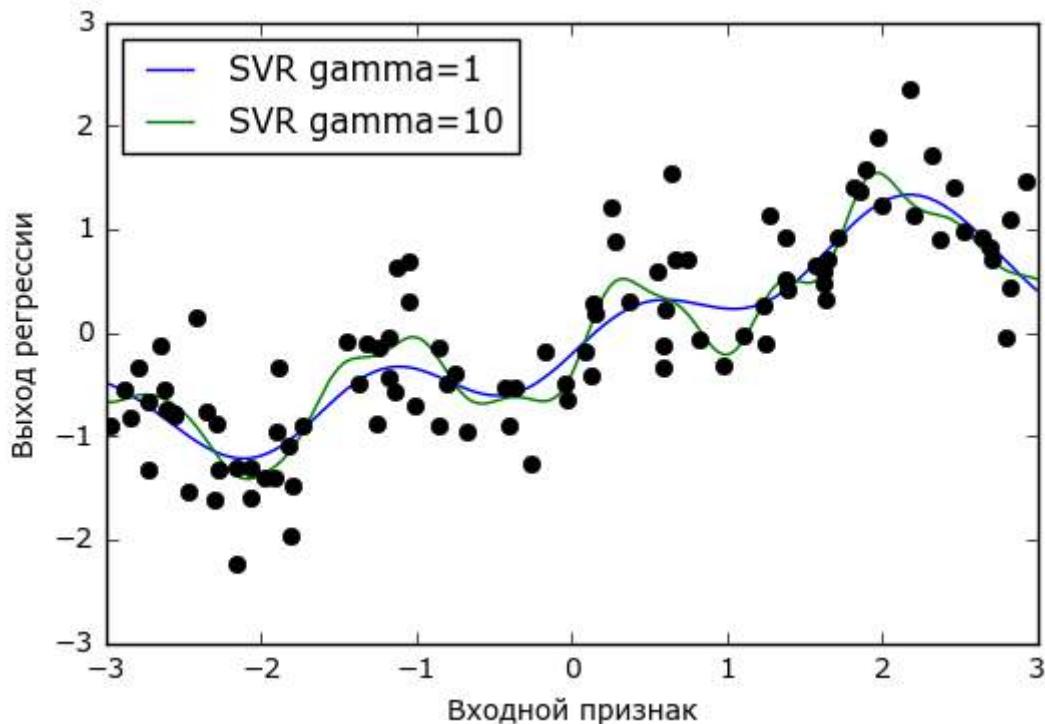


Рис. 4.6 Сравнение различных параметров гамма для SVM с RBF-ядром

Используя более сложную модель, модель ядерного SVM, мы можем получить такой же сложный прогноз, как в случае полиномиальной регрессии, не прибегая к явному преобразованию признаков.

В качестве более реального примера, иллюстрирующего применение взаимодействий и полиномов, давайте еще раз обратимся к набору данных Boston Housing. Мы уже использовали полиномиальные признаки этого набора данных в главе 2. Теперь давайте посмотрим, как были получены эти признаки и выясним, насколько они могут помочь нам улучшить прогноз. Сначала мы загрузим данные и отмасштабируем их с помощью `MinMaxScaler`, чтобы все признаки принимали значения в диапазоне между 0 и 1:

```
In[27]:
from sklearn.datasets import load_boston
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler

boston = load_boston()
X_train, X_test, y_train, y_test = train_test_split(boston.data, boston.target,
                                                    random_state=0)

# масштабируем данные
scaler = MinMaxScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)
```

Теперь, мы выделим полиномиальные признаки и взаимодействия вплоть до 2-й степени:

```
In[28]:
poly = PolynomialFeatures(degree=2).fit(X_train_scaled)
X_train_poly = poly.transform(X_train_scaled)
X_test_poly = poly.transform(X_test_scaled)
print("форма обучающего массива X: {}".format(X_train.shape))
print("форма обучающего массива X полиномы и взаим: {}".format(X_train_poly.shape))
```

```
Out[28]:
форма обучающего массива X: (379, 13)
форма обучающего массива X полиномы и взаим: (379, 105)
```

Набор данных первоначально содержал 13 признаков, которые в ходе преобразований превратились в 105 новых признаков. Эти новые признаки представляют собой все возможные взаимодействия между двумя различными исходными характеристиками, а также квадраты исходных характеристик. В данном случае `degree=2` означает, что мы рассматриваем признаки, которые являются произведением не более двух исходных характеристик. Точное соответствие между входными и выходными признаками можно найти с помощью метода `get_feature_names`:

```
In[29]:
print("Имена полиномиальных признаков:\n{}".format(poly.get_feature_names()))
```

```
Out[29]:
Имена полиномиальных признаков:
['1', 'x0', 'x1', 'x2', 'x3', 'x4', 'x5', 'x6', 'x7', 'x8', 'x9', 'x10',
 'x11', 'x12', 'x0^2', 'x0 x1', 'x0 x2', 'x0 x3', 'x0 x4', 'x0 x5', 'x0 x6',
 'x0 x7', 'x0 x8', 'x0 x9', 'x0 x10', 'x0 x11', 'x0 x12', 'x1^2', 'x1 x2',
 'x1 x3', 'x1 x4', 'x1 x5', 'x1 x6', 'x1 x7', 'x1 x8', 'x1 x9', 'x1 x10',
 'x1 x11', 'x1 x12', 'x2^2', 'x2 x3', 'x2 x4', 'x2 x5', 'x2 x6', 'x2 x7',
 'x2 x8', 'x2 x9', 'x2 x10', 'x2 x11', 'x2 x12', 'x3^2', 'x3 x4', 'x3 x5',
 'x3 x6', 'x3 x7', 'x3 x8', 'x3 x9', 'x3 x10', 'x3 x11', 'x3 x12', 'x4^2',
 'x4 x5', 'x4 x6', 'x4 x7', 'x4 x8', 'x4 x9', 'x4 x10', 'x4 x11', 'x4 x12',
 'x5^2', 'x5 x6', 'x5 x7', 'x5 x8', 'x5 x9', 'x5 x10', 'x5 x11', 'x5 x12',
 'x6^2', 'x6 x7', 'x6 x8', 'x6 x9', 'x6 x10', 'x6 x11', 'x6 x12', 'x7^2',
 'x7 x8', 'x7 x9', 'x7 x10', 'x7 x11', 'x7 x12', 'x8^2', 'x8 x9', 'x8 x10',
 'x8 x11', 'x8 x12', 'x9^2', 'x9 x10', 'x9 x11', 'x9 x12', 'x10^2', 'x10 x11',
 'x10 x12', 'x11^2', 'x11 x12', 'x12^2']
```

В данном случае первый новый признак является признаком-константой "1". Следующие 13 признаков являются исходными признаками (от "x0" до "x12"). Затем следует квадрат первого признака

(`"x0^2"`), после него приводятся произведения первого и остальных признаков.

Давайте вычислим правильность прогнозов, применив модель `Ridge` к данным, включающим взаимодействия, и данным без взаимодействий:

```
In[30]:  
from sklearn.linear_model import Ridge  
ridge = Ridge().fit(X_train_scaled, y_train)  
print("Правильность на тестовом наборе без взаимодействий: {:.3f}".format(  
    ridge.score(X_test_scaled, y_test)))  
ridge = Ridge().fit(X_train_poly, y_train)  
print("Правильность на тестовом наборе с взаимодействиями: {:.3f}".format(  
    ridge.score(X_test_poly, y_test)))
```

```
Out[30]:  
Правильность на тестовом наборе без взаимодействий: 0.621  
Правильность на тестовом наборе с взаимодействиями: 0.753
```

Очевидно, что в случае с гребневой регрессией взаимодействия и полиномиальные признаки позволяют улучшить правильность модели. Впрочем, применение более сложной модели типа случайного леса дает немного другого результат:

```
In[31]:  
from sklearn.ensemble import RandomForestRegressor  
rf = RandomForestRegressor(n_estimators=100).fit(X_train_scaled, y_train)  
print("Правильность на тестовом наборе без взаимодействий: {:.3f}".format(  
    rf.score(X_test_scaled, y_test)))  
rf = RandomForestRegressor(n_estimators=100).fit(X_train_poly, y_train)  
print("Правильность на тестовом наборе с взаимодействиями:  
 {:.3f}".format(rf.score(X_test_poly, y_test)))
```

```
Out[31]:  
Правильность на тестовом наборе без взаимодействий: 0.799  
Правильность на тестовом наборе с взаимодействиями: 0.763
```

Видно, что даже без дополнительных признаков случайный лес дает более высокую правильность прогнозов, чем гребневая регрессия. Включение взаимодействий и полиномов на самом деле немногого уменьшает правильность прогнозов.

Одномерные нелинейные преобразования

Мы только что увидели, что добавление признаков, возвещенных в квадрат или куб, может улучшить линейные модели регрессии. Существуют и другие преобразования, которые часто оказываются полезными в плане трансформации определенных признаков: в частности, применение математических функций типа `log`, `exp` или `sin`. Если модели на основе дерева заботятся лишь о выстраивании признаков в иерархию, то линейные модели и нейронные сети очень привязаны к масштабу и распределению каждого признака, поэтому наличие нелинейной взаимосвязи между признаком и зависимой переменной становится проблемой для модели, особенно для регрессии. Функции `log`

и `exp` позволяют скорректировать относительные шкалы переменных таким образом, чтобы линейная модель или нейронная сеть могли лучше обработать их. Мы видели подобный пример в главе 2, когда работали с набором данных `gam_prices`. Функции `sin` и `cos` могут пригодиться при работе с данными, которые представляют собой периодические структуры.

Большинство моделей работают лучше, когда признаки (а если используется регрессия, то и зависимая переменная) имеют гауссовское распределение, то есть гистограмма каждого признака должна в определенной степени иметь сходство с «колоколообразной кривой». Использование преобразований типа `log` и `exp` является банальным, но в то же время простым и эффективным способом добиться более симметричного распределения. Наиболее характерный случай, когда подобное преобразование может быть полезно, – обработка дискретных данных. Под дискретными данными мы подразумеваем признаки типа «как часто пользователь А входил в систему». Дискретные данные никогда не бывают отрицательными и часто подчиняются конкретным статистическим закономерностям. Здесь мы воспользуемся синтетическим набором дискретных данных с теми же самыми признаками, что можно встретить в реальной практике.²⁸ Все признаки имеют целочисленные значения, в то время как зависимая переменная является непрерывной:

```
In[32]:  
rnd = np.random.RandomState(0)  
X_org = rnd.normal(size=(1000, 3))  
w = rnd.normal(size=3)  
  
X = rnd.poisson(10 * np.exp(X_org))  
y = np.dot(X_org, w)
```

Давайте посмотрим на первые 10 элементов первого признака. Все они являются положительными и целочисленными значениями, однако выделить какую-то определенную структуру сложно.

Если посчитать частоту встречаемости каждого значения, распределение значений становится более ясным:

```
In[33]:  
print("Частоты значений:\n{}".format(np.bincount(X[:, 0])))
```

```
Out[33]:  
Частоты значений:  
[28 38 68 48 61 59 45 56 37 40 35 34 36 26 23 26 27 21 23 23 18 21 10 9 17  
 9 7 14 12 7 3 8 4 5 5 3 4 2 4 1 1 3 2 5 3 8 2 5 2 1  
 2 3 3 2 2 3 3 0 1 2 1 0 0 3 1 0 0 0 1 3 0 1 0 2 0  
 1 1 0 0 0 0 1 0 0 2 2 0 1 1 0 0 0 0 1 1 0 0 0 0 0  
 0 0 1 0 0 0 0 0 1 1 0 0 1 0 0 0 0 0 0 1 0 0 0 0 0  
 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0]
```

²⁸ Речь идет о распределении Пуассона, которое является основополагающим для дискретных величин.

Значение 2, по-видимому, является наиболее распространенным, оно встречается 68 раз (`bincount` всегда начинает считать с 0), а частоты более высоких значений быстро падают. Однако есть несколько очень высоких значений, например, 84 и 85, которые встречаются два раза. Мы визуализируем частоты на рис. 4.7:

In[34]:

```
bins = np.bincount(X[:, 0])
plt.bar(range(len(bins)), bins, color='w')
plt.ylabel("Частота")
plt.xlabel("Значение")
```

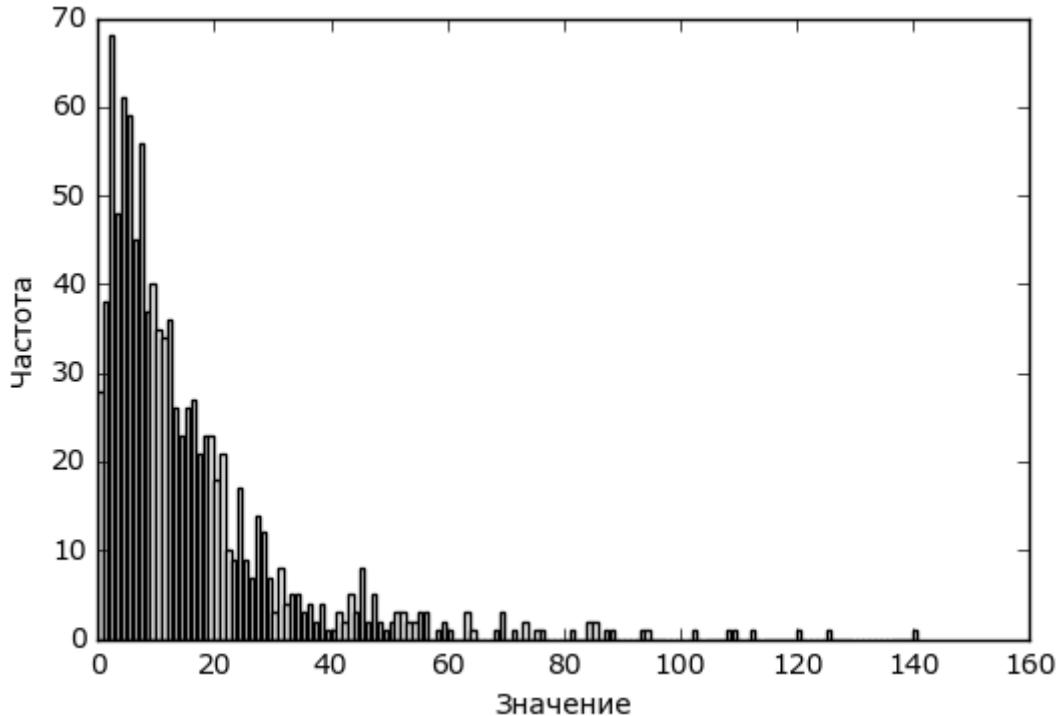


Рис. 4.7 Гистограмма значений $X[0]$

Признаки $X[:, 1]$ и $X[:, 2]$ имеют аналогичные свойства. Полученное распределение значений (высокая частота встречаемости маленьких значений и низкая частота встречаемости больших значений) является очень распространенным явлением в реальной практике. Однако для большинства линейных моделей оно может представлять трудность. Давайте попробуем подогнать гребневую регрессию:

In[35]:

```
from sklearn.linear_model import Ridge
X_train, X_test, y_train, y_test = train_test_split(X, y, random_state=0)
score = Ridge().fit(X_train, y_train).score(X_test, y_test)
print("Правильность на тестовом наборе: {:.3f}".format(score))
```

Out[35]:

Правильность на тестовом наборе: 0.622

Видно, что из-за относительно низкого значения R^2 гребневая регрессия не может должным образом смоделировать взаимосвязь между

X и y . Впрочем, применение логарифмического преобразования может помочь. Поскольку в данных появляется значение 0 (а логарифм 0 не определен), мы не можем просто взять и применить `log`, вместо этого мы должны вычислить $\log(X + 1)$:

```
In[36]:  
X_train_log = np.log(X_train + 1)  
X_test_log = np.log(X_test + 1)
```

После преобразования распределение данных стало менее асимметричным и уже не содержит очень больших выбросов (см. рис. 4.8):

```
In[37]:  
plt.hist(X_train_log[:, 0], bins=25, color='gray')  
plt.ylabel("Частота")  
plt.xlabel("Значение")
```

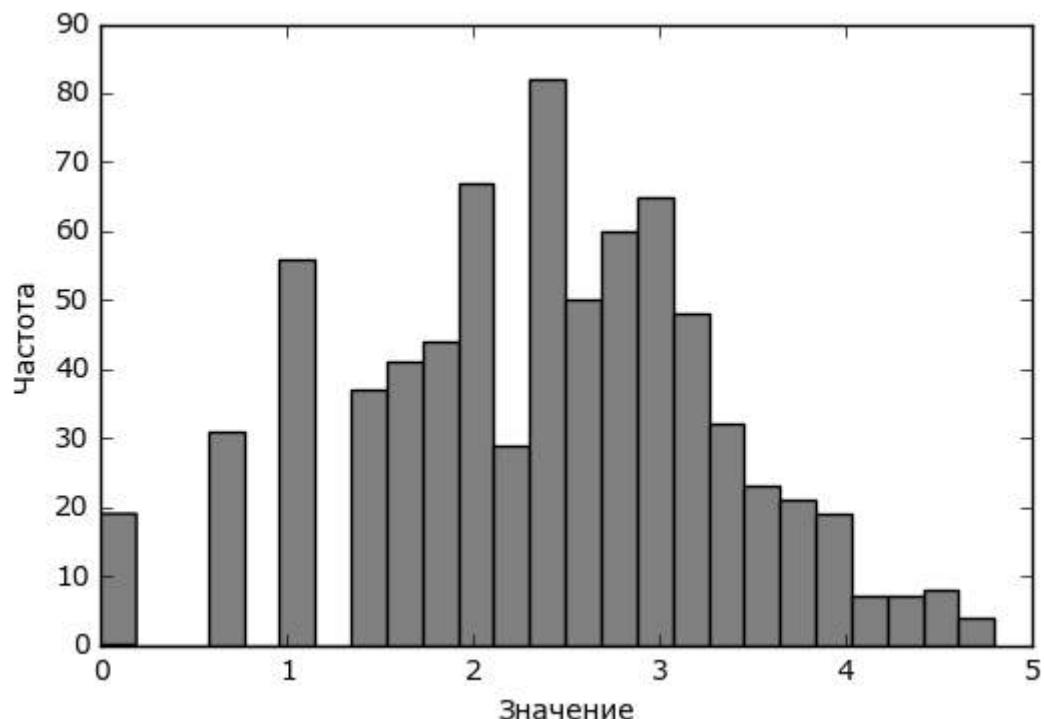


Рис. 4.8 Гистограмма значений $X[0]$ после логарифмического преобразования

Построение модели гребневой регрессии на новых данных дает гораздо более лучшее качество подгонки:

```
In[38]:  
score = Ridge().fit(X_train_log, y_train).score(X_test_log, y_test)  
print("Правильность на тестовом наборе: {:.3f}".format(score))
```

```
Out[38]:  
Правильность на тестовом наборе: 0.875
```

Поиск преобразования, которое наилучшим образом сработает для конкретного сочетания данных и модели – это в некоторой степени искусство. В этом примере все признаки имели одинаковые свойства. Такое редко бывает на практике, и как правило, лишь некоторые признаки нуждаются в преобразовании, либо в ряде случаев каждый признак необходимо преобразовывать по-разному. Как мы уже упоминали ранее, эти виды преобразований не имеют значения для моделей на основе дерева, но могут иметь важное значение для линейных моделей. Иногда при построении регрессии целесообразно преобразовать зависимую переменную y . Прогнозирование частот (скажем, количества заказов) является довольно распространенной задачей, и преобразование $\log(y + 1)$ часто помогает.²⁹

Как вы видели в предыдущих примерах, биннинг, полиномы и взаимодействия могут иметь огромное влияние на качество работы модели. Особенно это актуально для менее сложных моделей типа линейных моделей и наивных байесовских моделей. С другой стороны, модели на основе дерева, как правило, могут обнаружить важные взаимодействия самостоятельно и чаще всего не требуют явного преобразования данных. Использование биннинга, взаимодействий и полиномов в ряде случаев может положительно сказаться на работе моделей типа SVM, ближайших соседей и нейронных сетей, однако последствия, возникающие в результате этих преобразований, представляются менее ясными в отличие от преобразований, применяемых в линейных моделях.

Автоматический отбор признаков

При таком разнообразии способов, позволяющих сгенерировать новые признаки, у вас, возможно, возникнет искушение увеличить размерность данных, превысив количество исходных признаков. Однако добавление новых признаков делает модели более сложными и поэтому увеличивает вероятность переобучения. Добавляя новые признаки или работая с высокоразмерными наборами данных, неплохо бы уменьшить количество признаков и оставить только наиболее полезные из них. Это позволит получить более простые модели с лучшей обобщающей способностью. Однако как узнать, насколько полезен каждый признак? Существуют три основные стратегии: *одномерные статистики (univariate statistics)*, *отбор на основе модели (model-based selection)* и *итеративный отбор (iterative selection)*. Мы подробно рассмотрим все три стратегии. Все эти методы

²⁹ Это очень грубая аппроксимация с использованием регрессии Пуассона, которое было бы правильным решением с вероятностной точки зрения.

относятся методам машинного обучения с учителем, то есть для подгонки модели им требуется зависимая переменная. Это означает, что нам нужно разбить данные на обучающий и тестовый наборы и осуществить отбор признаков лишь на обучающей выборке.

Одномерные статистики

С помощью одномерных статистик мы определяем наличие статистически значимой взаимосвязи между каждым признаком и зависимой переменной. Затем отбираем признаки, сильнее всего связанные с зависимой переменной (имеющие уровень значимости, не превышающий заданного порогового значения). В случае классификации эта процедура известна как дисперсионный анализ (ANOVA). Ключевым свойством этих тестов является то, что они являются одномерными, то есть они рассматривают каждую характеристику по отдельности. Следовательно признак будет исключен, если он становится информативным лишь в сочетании с другим признаком. Как правило, одномерные тесты очень быстро вычисляются и не требуют построения модели. С другой стороны, они являются полностью независимыми от модели, которой вы, возможно, захотите применить после отбора признаков.

Чтобы осуществить одномерный отбор признаков в `scikit-learn`, вам нужно выбрать тест, обычно либо `f_classif` (по умолчанию) для классификации или `f_regression` для регрессии, а также метод исключения признаков, основанный на p -значениях, вычисленных в ходе теста. Все методы исключения параметров используют пороговое значение, чтобы исключить все признаки со слишком высоким p -значением (высокое p -значение указывает на то, что признак вряд ли связан с зависимой переменной). Методы отличаются способами вычисления этого порогового значения, самым простым из которых являются `SelectKBest`, выбирающий фиксированное число k признаков, и `SelectPercentile`, выбирающий фиксированный процент признаков. Давайте применим отбор признаков для классификационной задачи к набору данных `cancer`. Чтобы немного усложнить задачу, мы добавим к данным некоторые неинформативные шумовые признаки. Мы предполагаем, что отбор признаков сможет определить неинформативные признаки и удалит их:

```
In[39]:
from sklearn.datasets import load_breast_cancer
from sklearn.feature_selection import SelectPercentile
from sklearn.model_selection import train_test_split

cancer = load_breast_cancer()

# задаем определенное стартовое значение для воспроизводимости результата
rng = np.random.RandomState(42)
noise = rng.normal(size=(len(cancer.data), 50))
# добавляем к данным шумовые признаки
# первые 30 признаков являются исходными, остальные 50 являются шумовыми
X_w_noise = np.hstack([cancer.data, noise])

X_train, X_test, y_train, y_test = train_test_split(
    X_w_noise, cancer.target, random_state=0, test_size=.5)
# используем f_classif (по умолчанию)
# и SelectPercentile, чтобы выбрать 50% признаков
select = SelectPercentile(percentile=50)
select.fit(X_train, y_train)
# преобразовываем обучающий набор
X_train_selected = select.transform(X_train)

print("форма массива X_train: {}".format(X_train.shape))
print("форма массива X_train_selected: {}".format(X_train_selected.shape))
```

```
Out[39]:
форма массива X_train: (284, 80)
форма массива X_train_selected: (284, 40)
```

Как видно, количество признаков уменьшилось с 80 до 40 (на 50% от исходного количества признаков). Мы можем выяснить, какие функции были отобраны, воспользовавшись методом `get_support`, который возвращает булевые значения для каждого признака (визуализированы на рис. 4.9):

```
In[40]:
mask = select.get_support()
print(mask)
# визуализируем булевые значения: черный - True, белый - False
plt.matshow(mask.reshape(1, -1), cmap='gray_r')
plt.xlabel("Индекс примера")
```

```
Out[40]:
[ True  True  True  True  True  True  True  True  True  False  True  False
 True  True  True  True  True  True  False  False  True  True  True  True
 True  True  True  True  True  True  False  False  False  True  False  True
 False  False  True  False  False  False  False  True  False  False  True  False
 False  True  False  True  False  False  False  False  False  False  True  False
 True  False  False  False  False  True  False  True  False  False  False  False
 True  True  False  True  False  False  False  False ]
```



Рис. 4.9 Признаки, отобранные с помощью `SelectPercentile`

Благодаря визуализации видно, что большинство отобранных признаков являются исходными характеристиками, а большинство шумовых признаков были удалены. Тем не менее восстановление исходных признаков далеко от идеала. Давайте сравним правильность логистической регрессии с использованием всех признаков с

правильностью логистической регрессии, использующей лишь отобранные признаки:

```
In[41]:  
from sklearn.linear_model import LogisticRegression  
  
# преобразовываем тестовые данные  
X_test_selected = select.transform(X_test)  
  
lr = LogisticRegression()  
lr.fit(X_train, y_train)  
print("Правильность со всеми признаками: {:.3f}".format(lr.score(X_test, y_test)))  
lr.fit(X_train_selected, y_train)  
print("Правильность только с отобранными признаками: {:.3f}".format(  
    lr.score(X_test_selected, y_test)))  
  
Out[41]:  
Правильность со всеми признаками: 0.930  
Правильность только с отобранными признаками: 0.940
```

В данном случае удаление шумовых признаков повысило правильность, даже несмотря на то, что некоторые исходные признаки отсутствовали. Это был очень простой синтетический пример, результаты, получающиеся на реальных данных, как правило, получаются смешанными. Однако одномерный отбор признаков может быть очень полезен, если их количество является настолько большим, что невозможно построить модель, используя все эти характеристики, или же вы подозреваете, что многие характеристики совершенно неинформативны.

Отбор признаков на основе модели

Отбор признаков на основе модели использует модель машинного обучения с учителем, чтобы вычислить важность каждого признака, и оставляет только самые важные из них. Модель машинного обучения с учителем, которая используется для отбора признаков, не должна использоваться для построения итоговой модели. Модель, применяющаяся для отбора признаков, требует вычисления определенного показателя важности для всех признаков, с тем чтобы характеристики можно было ранжировать по этой метрике. В деревьях решений и моделях на основе дерева решений такой показатель реализован с помощью атрибута `feature_importances_`, в котором записывается важность каждого признака. У линейных моделей есть коэффициенты, абсолютные значения которых также можно использовать для оценки важности признаков. Как мы видели в главе 2, линейные модели с L1 штрафом позволяют вычислить разреженные решения³⁰, которые используют лишь небольшое подмножество признаков. Поэтому процедуру L1 регуляризации можно рассматривать

³⁰ Решения, при которых большинство коэффициентов тождественно равно 0. – Прим. пер.

как один из способов отбора признаков, выполняемый самой моделью. Кроме того, эту процедуру можно использовать в качестве инструмента предварительной обработки, позволяющего отобрать признаки для другой модели. В отличие от одномерного отбора отбор на основе модели рассматривает все признаки сразу и поэтому может обнаружить взаимодействия (если модель способна выявить их). Чтобы применить отбор на основе модели, мы должны воспользоваться модификатором `SelectFromModel`:

```
In[42]:  
from sklearn.feature_selection import SelectFromModel  
from sklearn.ensemble import RandomForestClassifier  
select = SelectFromModel(  
    RandomForestClassifier(n_estimators=100, random_state=42),  
    threshold="median")
```

Класс `SelectFromModel` отбирает все признаки, у которых показатель важности (заданный моделью машинного обучения с учителем) превышает установленное пороговое значение. Чтобы вычислить результат, сопоставимый с тем, который мы получили при однофакторном отборе признаков, мы использовали в качестве порогового значения медиану, поэтому будет отобрана половина признаков. Мы используем случайный лес на основе деревьев классификации (100 деревьев), чтобы вычислить важности признаков. Это довольно сложная модель, обладающая гораздо большей прогнозной силой, нежели одномерные тесты. Теперь давайте подгоним эту модель:

```
In[43]:  
select.fit(X_train, y_train)  
X_train_l1 = select.transform(X_train)  
print("форма обуч набора X: {}".format(X_train.shape))  
print("форма обуч набора X с l1: {}".format(X_train_l1.shape))
```

```
Out[43]:  
форма обуч набора X: (284, 80)  
форма обуч набора X с l1: (284, 40)
```

И снова мы можем взглянуть на отобранные признаки (рис. 4.10):

```
In[44]:  
mask = select.get_support()  
# визуализируем булевые значения -- черный - True, белый - False  
plt.matshow(mask.reshape(1, -1), cmap='gray_r')  
plt.xlabel("Индекс примера")
```



Рис. 4.10 Признаки, отобранные `SelectFromModel` с помощью `RandomForestClassifier`

На этот раз были отобраны все исходные признаки, кроме двух. Поскольку мы задали отбор лишь 40 признаков, некоторые шумовые признаки также будут выбраны. Давайте посмотрим на правильность:

```
In[45]:  
X_test_l1 = select.transform(X_test)  
score = LogisticRegression().fit(X_train_l1, y_train).score(X_test_l1, y_test)  
print("Правильность на тестовом наборе: {:.3f}".format(score))
```

```
Out[45]:  
Правильность на тестовом наборе: 0.951
```

Используя более оптимальный отбор признаков, мы смогли немного улучшить прогноз.

Итеративный отбор признаков

В одномерном отборе признаков мы не использовали модель, а в отборе признаков на основе модели мы построили одну модель, чтобы выбрать характеристики. В итеративном отборе признаков строится последовательность моделей с различным количеством признаков. Существует два основных метода. Первый метод начинается шага, когда в модель включена лишь одна константа (входных признаков нет) и затем добавляет признак за признаком до тех пор, пока не будет достигнут критерий остановки. Второй метод начинается с шага, когда все признаки включены в модель, и затем начинает удалять признак за признаком, пока не будет достигнут критерий остановки. Поскольку строится последовательность модели, эти методы с вычислительной точки зрения являются гораздо более затратными в отличие от ранее обсуждавшихся методов. Одним из таких методов является метод *рекурсивного исключения признаков* (*recursive feature elimination, RFE*), который начинается с включения всех признаков, строит модель и исключает наименее важный признак с точки зрения модели. Затем строится новая модель с использованием всех признаков, кроме исключенного, и так далее, пока не останется лишь заранее определенное количество признаков. Чтобы все получилось, модели, используемой для отбора признаков, необходима определенная метрика, измеряющая важность признаков, как было в случае с модельным отбором. Здесь мы воспользуемся той же самой моделью случайного леса, которую применяли ранее, и получим результаты, показанные на рис. 4.11:

```
In[46]:  
from sklearn.feature_selection import RFE  
select = RFE(RandomForestClassifier(n_estimators=100, random_state=42),  
              n_features_to_select=40)  
  
select.fit(X_train, y_train)  
# визуализируем отобранные признаки:  
mask = select.get_support()  
plt.matshow(mask.reshape(1, -1), cmap='gray_r')  
plt.xlabel("Индекс примера")
```



Рис. 4.10 Признаки, отобранные методом рекурсивного исключения признаков с помощью RandomForestClassifier

Отбор признаков стал лучше по сравнению с одномерным отбором и отбором на основе модели, однако одного признака по-прежнему не хватает. Кроме того, выполнение этого программного кода занимает значительно больше времени в отличие от модельного отбора, поскольку модель случайного леса обучается 40 раз, по одной итерации для каждого отбрасываемого признака. Давайте проверим правильность модели логистической регрессии с использованием RFE для отбора признаков:

```
In[47]:  
X_train_rfe= select.transform(X_train)  
X_test_rfe= select.transform(X_test)  
score = LogisticRegression().fit(X_train_rfe, y_train).score(X_test_rfe, y_test)  
print("Правильность на тестовом наборе: {:.3f}".format(score))
```

```
Out[47]:  
Правильность на тестовом наборе: 0.951
```

Кроме того, мы можем применить модель, использованную внутри РСЕ, чтобы вычислить прогнозы. Она использует лишь набор отобранных признаков:

```
In[48]:  
print("Правильность на тестовом наборе: {:.3f}".format(select.score(X_test, y_test)))
```

```
Out[48]:  
Правильность на тестовом наборе: 0.951
```

В данном случае правильность случайного леса, используемого внутри RFE, совпадает с правильностью, достигнутой в результате обучения модели логистической регрессии на основе наилучших отобранных признаков. Другими словами, как только мы выбрали правильные признаки, линейная модель показала ту же самую правильность, что и случайный лес.

Если у вас нет уверенности в том, какие признаки использовать в качестве входных данных для вашего алгоритма машинного обучения, автоматический отбор признаков может быть весьма полезен. Кроме того, он отлично подходит для уменьшения количества необходимых признаков, например, чтобы увеличить скорость вычисления прогнозов или получить более интерпретируемые модели. В большинстве реальных примеров применение отбора признаков вряд ли обеспечит большой прирост производительности. Тем не менее, он по-прежнему является ценным инструментом в арсенале специалиста по анализу данных.

Применение экспертных знаний

Как правило, конструирование признаков является тем важным этапом, на котором применяются *экспертные знания* (*expert knowledge*) в конкретной сфере. Хотя во многих случаях цель машинного обучения заключается в том, чтобы избежать построения набора экспертных правил, это вовсе не означает, что априорные знания в той или иной сфере или области должны быть отброшены. Как правило, эксперты могут помочь выделить полезные признаки, которые являются гораздо более информативным, чем исходные данные. Представьте, что вы работаете в туристическом агентстве и вам нужно спрогнозировать цены на авиарейсы. Допустим, у вас есть цены с датами, названиями авиакомпаний, местами отправления и назначения. Возможно, что модель машинного обучения вполне способна построить достойную модель на основе этих данных. Однако некоторые важные факторы, связанные с ценами на авиарейсы останутся без внимания. Например, стоимость авиарейсов, как правило, становится выше в месяцы, приходящиеся на период отпусков, и в праздничные дни. Хотя даты некоторых праздников (например, Рождество) фиксированы, и поэтому их эффект можно учесть, исходя из даты, другие могут зависеть от фазы луны (например, Ханука и Пасха) или устанавливаться органами власти (например, каникулы). Эти события нельзя извлечь из данных, если каждый рейс записывается только с помощью (григорианской) даты. Однако легко добавить признак, который будет фиксировать день полета как предшествующий дню государственного праздника/дню объявления школьных каникул или следующий после дня государственного праздника/дня объявления школьных каникул. Таким образом, априорное знание можно закодировать в признаки, чтобы помочь алгоритму машинного обучения. Добавление признака не означает его обязательное использование алгоритмом машинного обучения и даже если информация о празднике окажется малоинформационной с точки зрения прогнозирования цен на авиарейсы, обогащение данных этим признаком не принесет вреда.

Теперь мы рассмотрим конкретный случай применения экспертных знаний, хотя в данном случае их с полным правом можно назвать «здравым смыслом». Задача заключается в том, чтобы спрогнозировать количество велосипедов, взятых напрокат перед домом Андреаса.

Система общественного транспорта велосипедов City Bike в Нью-Йорке представляет собой сеть станций проката велосипедов, воспользоваться которой можно с помощью подписки. Станции расположены по всему городу и обеспечивают удобный способ передвижения. Данные о прокате велосипедов выложены на сайте City Bike в [анонимном виде](#) и были проанализированы различными

способами. Задача, которую мы хотим решить, заключается в том, чтобы предсказать, сколько людей воспользуется прокатом велосипедов перед домом Андреаса, поэтому он знает о количестве оставшихся велосипедов.

Сначала загрузим данные за август 2015 года для этой конкретной станции в виде пандасовского `DataFrame`. Мы разбили данные на 3-часовые интервалы, чтобы выделить основные тренды для каждого дня:

```
In[49]:  
def load_citibike():  
    data_mine = pd.read_csv("C:/Data/citibike.csv")  
    data_mine['one'] = 1  
    data_mine['starttime'] = pd.to_datetime(data_mine starttime)  
    data_starttime = data_mine.set_index("starttime")  
    data_resampled = data_starttime.resample("3h").sum().fillna(0)  
    return data_resampled.one  
citibike = load_citibike()
```

```
In[50]:  
print("данные Citi Bike:\n{}".format(citibike.head()))
```

```
Out[50]:  
данные Citi Bike:  
starttime  
2015-08-01 00:00:00 3.0  
2015-08-01 03:00:00 0.0  
2015-08-01 06:00:00 9.0  
2015-08-01 09:00:00 41.0  
2015-08-01 12:00:00 39.0  
Freq: 3H, Name: one, dtype: float64
```

Следующий пример показывает количество велосипедов, взятых в прокат, по дням месяца (рис. 4.12):

```
In[51]:  
plt.figure(figsize=(10, 3))  
xticks = pd.date_range(start=citibike.index.min(), end=citibike.index.max(),  
                      freq='D')  
plt.xticks(xticks, xticks.strftime("%a %m-%d"), rotation=90, ha="left")  
plt.plot(citibike, linewidth=1)  
plt.xlabel("Дата")  
plt.ylabel("Частота проката")
```

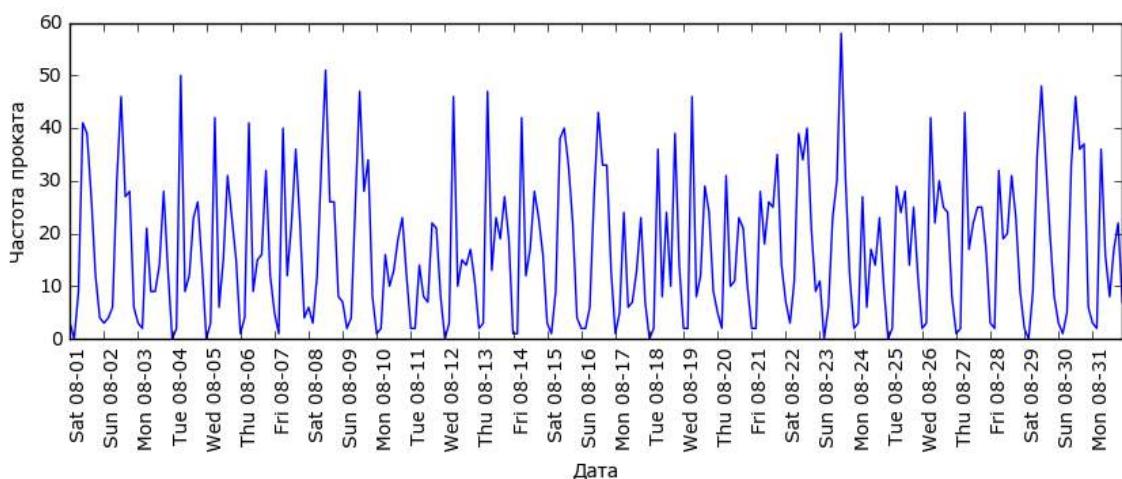


Рис. 4.12 Количество велосипедов, взятых на прокат в течение месяца для определенной станции

Взглянув на данные, мы можем четко выделить день и ночь для каждого 24-часового интервала. Структура данных для будних и выходных дней также выглядит совершенно по-разному. Решая задачу прогнозирования для временных рядов, мы *учимся на прошлом и делаем прогноз на будущее*. Это означает, что при разбиении данных на обучающий и тестовый наборы, нам нужно взять все данные до определенной даты в качестве обучающей выборки и все данные после этой даты в качестве тестовой выборки. Вот как мы обычно используем прогнозирование временных рядов: обладая информацией о прокате велосипедов в прошлом, мы строим предположения о том, что произойдет завтра. Мы используем первые 184 точки данных, соответствующие первым 23 дням, в качестве обучающего набора, а остальные 64 точки данных, соответствующие оставшимся 8 дням, в качестве тестового набора.

Единственный признак, который мы используем в нашей задаче прогнозирования, – дата и время проката. Таким образом, входной признак – это дата и время, например, `2015-08-01 00:00:00`, а зависимая переменная – количество велосипедов, взятых на прокат в последующие три часа (в соответствии с нашим `DataFrame`).

Широко распространенный способ хранения дат на компьютерах – использование POSIX-времени, которое представляет собой количество секунд, прошедших с полуночи (00:00:00) 1 января 1970 года (оно же является точкой отсчета Unix-времени). В качестве первой попытки мы можем воспользоваться им для нашего представления дат:

In[52]:

```
# извлекаем значения зависимой переменной (количество велосипедов, взятых в прокат)
y = citibike.values
# преобразуем время в формат POSIX с помощью "%s"
X = citibike.index.astype("int64").reshape(-1, 1) // 10**9
```

Сначала мы зададим функцию, чтобы разбить данные на обучающий и тестовый наборы, построим модель и визуализируем результат:

In[54]:

```
# используем первые 184 точки данных для обучения, а остальные для тестирования
n_train = 184
# функция, которая строит модель на данном наборе признаков и визуализирует ее
def eval_on_features(features, target, regressor):
    # разбиваем массив признаков на обучающую и тестовую выборки
    X_train, X_test = features[:n_train], features[n_train:]
    # также разбиваем массив с зависимой переменной
    y_train, y_test = target[:n_train], target[n_train:]
    regressor.fit(X_train, y_train)
    print("R^2 для тестового набора: {:.2f}".format(regressor.score(X_test, y_test)))
    y_pred = regressor.predict(X_test)
    y_pred_train = regressor.predict(X_train)
    plt.figure(figsize=(10, 3))

    plt.xticks(range(0, len(X), 8), xticks.strftime("%a %m-%d"), rotation=90,
               ha="left")

    plt.plot(range(n_train), y_train, label="обуч")
```

```

plt.plot(range(n_train, len(y_test) + n_train), y_test, '-',
         label="тест")
plt.plot(range(n_train), y_pred_train, '--',
         label="прогноз обуч")
plt.plot(range(n_train, len(y_test) + n_train), y_pred, '--',
         label="прогноз тест")
plt.legend(loc=(1.01, 0))
plt.xlabel("Дата")
plt.ylabel("Частота проката")

```

Ранее мы уже видели, что случайный лес требует очень незначительной предварительной обработки данных, что, по-видимому, делает его оптимальной моделью для старта. Мы передаем функции `eval_on_features` массив с признаком `X` (даты, преобразованные в POSIX-формат), `y` и модель случайного леса. Рис. 4.13 показывает результат:

In[55]:

```

from sklearn.ensemble import RandomForestRegressor
regressor = RandomForestRegressor(n_estimators=100, random_state=0)
plt.figure()
eval_on_features(X, y, regressor)

```

Out[55]:

R^2 для тестового набора: -0.04

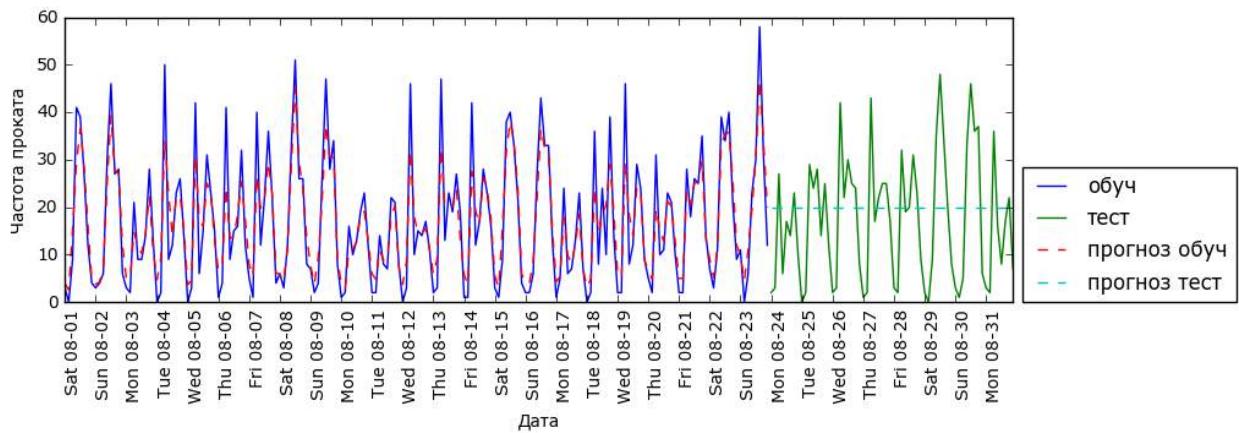


Рис. 4.13 Прогнозы, вычисленные случайным лесом
(использовались даты, преобразованные в формат времени POSIX)

Как это обычно бывает при построении случайного леса, правильность прогнозов на обучающем наборе получилась довольно высокой. Однако для тестового набора прогнозируется ровная линия. Значение R^2 равно -0.04, это означает, что наша модель ничему не научилась. Что произошло?

Проблема обусловлена сочетанием типа нашего признака и используемого метода (в данном случае случайного леса). Значения признака на основе POSIX-времени для тестового набора находятся вне диапазона значений этого признака в обучающей выборке: точки тестового набора в отличие от точек обучающего набора имеют более поздние временные метки. Дерево, а следовательно и случайный лес не могут *экстраполировать* (*extrapolate*) значения признаков, лежащие вне диапазона значений обучающих данных. Итог — модель просто

предсказывает значение зависимой переменной для ближайшей точки обучающего набора (для последней временной метки, которую она запомнила).

Ясно, что мы можем улучшить прогноз. Это тот момент, когда на помощь приходят наши «экспертные знания». Взглянув на то, как меняется частота проката в обучающих данных, можно выделить два очень важных фактора: время суток и день недели. Итак, давайте добавим эти два признака. Мы не смогли построить модель, используя время в формате POSIX, поэтому мы отбрасываем этот признак. Для начала давайте попробуем время суток. Как показывает рис. 4.14, теперь прогнозы имеют одинаковую структуру для каждого дня недели:

In[56]:

```
X_hour = citibike.index.hour.reshape(-1, 1)
eval_on_features(X_hour, y, regressor)
```

Out[56]:

R^2 для тестового набора: 0.60

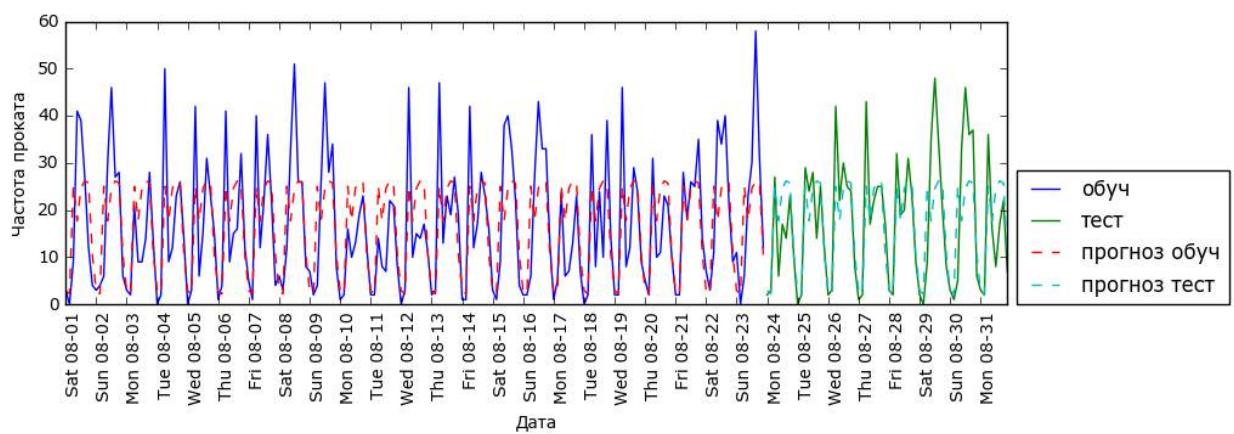


Рис. 4.14 Прогнозы, вычисленные случайным лесом
(использовалось время суток)

Значение R^2 стало уже намного лучше, но прогнозы явно не учитывают эффект, обусловленный днем недели. Теперь давайте еще добавим день недели (см. рис. 4.15):

In[57]:

```
X_hour_week = np.hstack([citibike.index.dayofweek.reshape(-1, 1),
                           citibike.index.hour.reshape(-1, 1)])
eval_on_features(X_hour_week, y, regressor)
```

Out[57]:

R^2 для тестового набора: 0.84

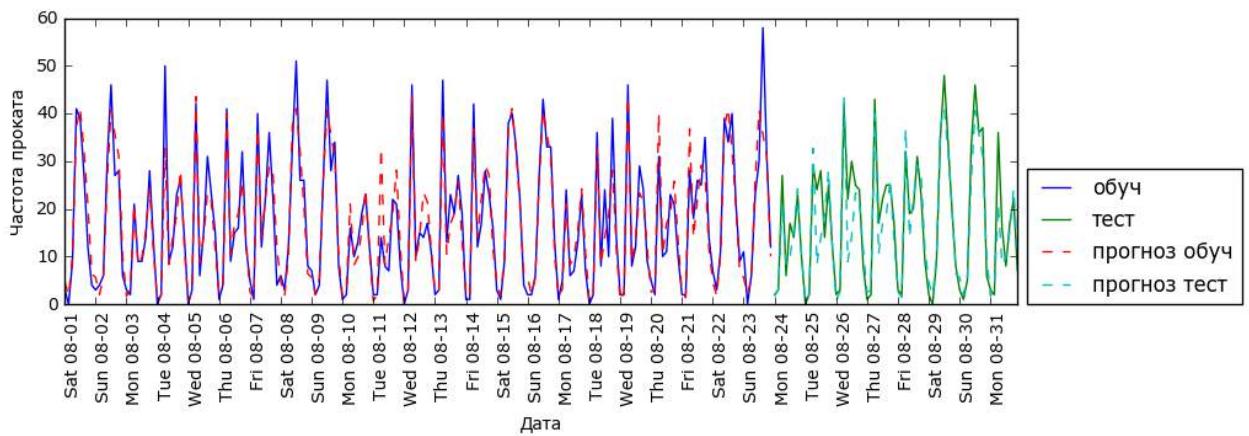


Рис. 4.15 Прогнозы, вычисленные случайнм лесом
(использовались день недели и время суток)

Теперь у нас есть модель, которая отражает периодичность поведения, учитывая день недели и время суток. Она имеет значение R^2 , равное 0.84, и демонстрирует довольно хорошую прогностическую способность. Модель научилась прогнозировать среднее количество арендованных велосипедов для каждой комбинации дня недели и времени суток на основе выборки, включающей первые 23 дня августа. На самом деле эта задача не требует такой сложной модели, как случайный лес, поэтому давайте попробуем более простую модель, например, `LinearRegression` (см. рис. 4.16):

In[58]:

```
from sklearn.linear_model import LinearRegression
eval_on_features(X_hour_week, y, LinearRegression())
```

Out[58]:

R^2 для тестового набора: 0.13

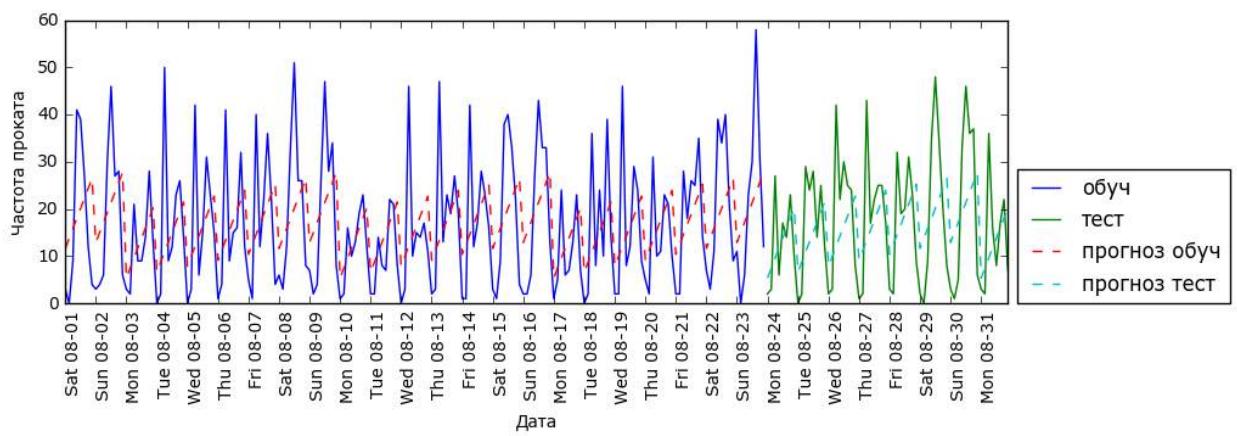


Рис. 4.16 Прогнозы, вычисленные линейной регрессией
(использовались день недели и время суток)

`LinearRegression` работает гораздо хуже, а периодическая структура данных выглядит странно. Причиной этого является тот факт, что мы закодировали день недели и время суток с помощью целочисленных

значений и теперь эти характеристики интерпретируются как непрерывные переменные. В силу этого линейная модель может построить лишь линейную функцию от времени суток – в более позднее время суток наблюдается большее количество арендованных велосипедов. Однако структура данных сложнее, чем предполагает модель. Мы можем учесть это, преобразовав признаки, закодированные целыми числами, в дамми-переменные с помощью `OneHotEncoder` (см. рис. 4.17):

In[59]:

```
enc = OneHotEncoder()
X_hour_week_onehot = enc.fit_transform(X_hour_week).toarray()
```

In[60]:

```
eval_on_features(X_hour_week_onehot, y, Ridge())
```

Out[60]:

R² для тестового набора: 0.62

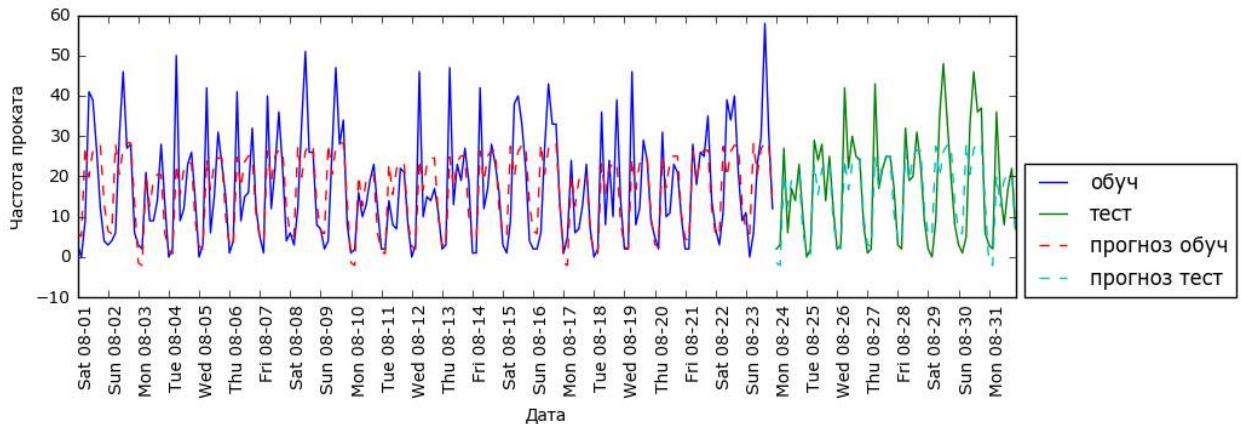


Рис. 4.17 Прогнозы, вычисленные линейной регрессией
(использовалось прямое кодирование времени суток и дня недели)

Данная процедура дает гораздо лучший результат в отличие от кодирования наших признаков в виде непрерывных переменных. Теперь линейная модель вычисляет один коэффициент для каждого дня недели и один коэффициент для каждого времени суток. Тем не менее, это означает, что паттерн «времени суток» распределяется по всем дням недели.

Используя взаимодействия, мы можем вычислить коэффициент для каждой комбинации дня недели и времени суток (см. рис. 4.18):

In[61]:

```
poly_transformer = PolynomialFeatures(degree=2, interaction_only=True,
                                      include_bias=False)
X_hour_week_onehot_poly = poly_transformer.fit_transform(X_hour_week_onehot)
lr = Ridge()
eval_on_features(X_hour_week_onehot_poly, y, lr)
```

Out[61]:

R² для тестового набора: 0.85

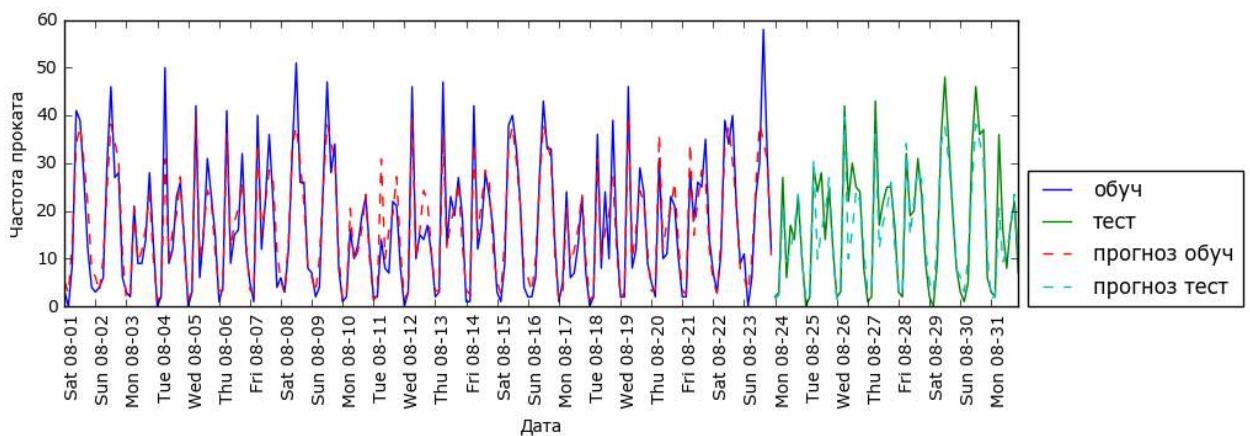


Рис. 4.18 Прогнозы, вычисленные линейной регрессией
(использовались взаимодействия дня недели и времени суток)

Наконец, это преобразование дает модель, которая обладает такой же высокой прогностической способностью, что и случайный лес. Большим преимуществом данной модели является ее понятность: мы вычисляем по одному коэффициенту для каждой комбинации дня недели и времени суток. Мы можем просто построить график коэффициентов, вычисленных с помощью модели, что было бы невозможно для случайного леса.

Во-первых, мы создаем имена для наших признаков:

```
In[62]:  
hour = ["%02d:00" % i for i in range(0, 24, 3)]  
day = ["Mon", "Tue", "Wed", "Thu", "Fri", "Sat", "Sun"]  
features = day + hour
```

Затем мы присваиваем имена всем взаимодействиям, извлеченным с помощью `PolyomialFeatures`, используя метод `get_feature_names`, и сохраняем лишь те признаки, у которых коэффициенты отличны от нуля:

```
In[63]:  
features_poly = poly_transformer.get_feature_names(features)  
features_nonzero = np.array(features_poly)[lr.coef_ != 0]  
coef_nonzero = lr.coef_[lr.coef_ != 0]
```

Теперь мы можем визуализировать коэффициенты, извлеченные с линейной модели (показаны на рис. 4.19):

```
In[64]:  
plt.figure(figsize=(15, 2))  
plt.plot(coef_nonzero, 'o')  
plt.xticks(np.arange(len(coef_nonzero)), features_nonzero, rotation=90)  
plt.xlabel("Оценка коэффициента")  
plt.ylabel("Признак")
```

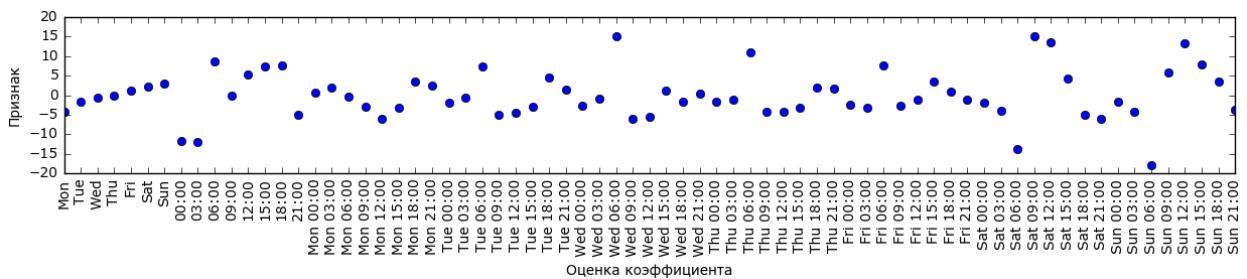


Рис. 4.19 Коэффициенты линейной регрессии
(использовались взаимодействия дня недели и времени суток)

Выводы и перспективы

В этой главе мы рассмотрели способы обработки различных типов данных (в частности, обработку категориальных переменных). Мы подчеркнули важность представления данных таким способом, который в наибольшей степени подходит для алгоритма машинного обучения, например, рассмотрели прямое кодирование категориальных переменных. Мы также обсудили важность конструирования новых признаков, а также возможность применения экспертных знаний при разработке новых переменных на основе ваших данных.

Создание новых признаков с помощью биннинга, добавления полиномов и взаимодействий может значительно улучшить качество линейных моделей, тогда как более сложные, нелинейные модели типа случайного леса и SVM могут решать более трудные задачи без явного расширения пространства признаков. На практике наличие признаков, подходящих для использования (а также их соответствие применяемой модели), часто является самым важным элементом, обеспечивающим хорошую работу методов машинного обучения.

Теперь у вас есть развернутое представление о том, как закодировать данные надлежащим образом и какой алгоритм использовать для решения определенной задачи. Следующая глава будет посвящена оценке качества моделей машинного обучения и выбору правильных параметров.