

Создание нейронной сети классификации одежды ЛАБОРАТОРНАЯ РАБОТА

<http://www.kimrt.ru>

Онлайн-курс

[Суперкомпьютерные технологии в задачах моделирования](#)

Задача классификации одежды Fashion-MNIST — это новый стандартный набор данных, используемый в компьютерном зрении и глубоком обучении. Хотя набор данных относительно прост, его можно использовать в качестве основы для обучения и практики разработки, оценки и использования глубоких сверточных нейронных сетей. Это включает в себя разработку надежной системы тестирования для оценки производительности модели, исследование улучшений модели, а также сохранение модели и ее загрузка, чтобы делать прогнозы на основе новых данных [1, 2].

Набор данных Fashion-MNIST предлагается в качестве более сложной замены набора данных MNIST. Сначала установим TensorFlow и импортируем его, а также установим дополнительные библиотеки. Затем мы загружаем fashion-mnist, который является одним из наборов данных Keras.

Листинг 1. Загрузка размеченного набора данных

```
# установка библиотек
import tensorflow as tf
from tensorflow import keras

import numpy as np
import matplotlib.pyplot as plt
from tensorflow.keras.optimizers import Adam
%matplotlib inline

#Загрузка датасета
fashion_mnist = keras.datasets.fashion_mnist

# Разделение датасета на тренировочные и тестовые данные
(x_train, y_train), (x_test, y_test) = fashion_mnist.load_data()
```

Это набор данных, состоящий из 60000 небольших квадратных изображений (размером 28x28 пикселей) десяти видов предметов одежды, таких как обувь, футболки, платья и многое другое. Сопоставление всех целых чисел от 0 до 9 с метками классов показано ниже:

- 0: T-shirt/top,
- 1: Trouser,

<http://www.kimrt.ru>

- 2: Pullover,
- 3: Dress,
- 4: Coat,
- 5: Sandal,
- 6: Shirt,
- 7: Sneaker,
- 8: Bag,
- 9: Ankle boot.

После данных операций необходимо создать массив `class_names`, содержащий значения видов одежды. Также создается график первых пятнадцати изображений в наборе данных, показывающий, что изображения действительно представляют собой фотографии предметов одежды в градациях серого (см. листинг 2).

Листинг 2. Визуализация датасета

```
def plot(images, labels, predictions=None):
    n_cols = min(5, len(images))
    n_rows = math.ceil(len(images) / n_cols)
    fig, axes = plt.subplots(n_rows, n_cols, figsize=(n_cols+3, n_rows+4))

    if predictions is None:
        predictions = [None] * len(labels)

    for i, (x, y_true, y_pred) in enumerate(zip(images, labels, predictions)):
        ax = axes.flat[i]
        ax.imshow(x, cmap=plt.cm.binary)

        ax.set_title(f"lbl: {class_names[y_true]}")

        if y_pred is not None:
            ax.set_xlabel(f"pred: {y_pred}")

        ax.set_xticks([])
        ax.set_yticks([])
    plot(x_train[:15], y_train[:15])
```

В цветовом режиме изображения «Градация серого» используется до 256 оттенков серого [3]. Каждый пиксель изображения в градациях серого содержит значение яркости в диапазоне от 0 (черный) до 255 (белый). Перед непосредственным созданием модели необходимо провести нормализацию данных следующими строками кода.

```
x_train = x_train / 255
x_test = x_test / 255
```

Таким образом, интенсивность серого цвета пикселей определяется диапазоном значений от 0 до 1 (где 0 – черный, 1 – белый) в массивах `x_train` и `x_test`.

Базовым строительным блоком нейронной сети является слой. Слои извлекают представления из данных, переданных им. Большая часть сетей глубокого обучения состоит из связанных вместе простых слоев.

```
# Создание модели
model = tf.keras.models.Sequential([
# ЗДЕСЬ ПРОПИСЫВАЮТСЯ СЛОИ МОДЕЛИ ])
```

Первый слой в этой сети, `tf.keras.layers.Flatten`, преобразует формат изображений из 2х-мерного массива (28 на 28 пикселей) в одномерный массив $28 * 28 = 784$ пикселей. Рассматривайте этот слой как разложенные из стека и построенные в линию слои пикселей в изображении. Этот слой не имеет параметров для обучения, это только преобразование данных. После того как пиксели преобразованы сеть состоит из последовательности двух `tf.keras.layers.Dense` слоев. Это полносвязанные или полностью связанные нейронные слои. Первый Dense слой имеет 512 узлов (или нейронов). Второй (последний) слой – 10-узловой софтмакс слой. Он возвращает массив десяти расчетов вероятностей, которые в сумме равны 1. Каждый узел содержит значение, которое показывает вероятность того, что текущее изображение принадлежит одному из 10 классов.




Рис. 1. Схематический рисунок сети

Перед тем как модель будет готова к тренировке ей потребуются еще некоторые настройки. Настройки добавляются на этапе компиляции модели:

Функция потерь – она измеряет погрешность модели (loss) в ходе тренировки. Мы хотим минимизировать эту функцию, чтобы управлять моделью в правильном направлении.

Оптимизатор – управляет тем, как модель обновляется (ее веса и скорость обучения), основываясь на данных, которые видит, и функции потерь.

Метрики – используются для наблюдения за тренировочным и тестовым шагами.

```
# компилируем модель
model.compile(optimizer='adam', loss='sparse_categorical_crossentropy',
metrics=['accuracy'])
```

Тренировка модели нейронной сети требует следующих шагов:

- передать модели тренировочные данные – в этом примере, `train_images` и `train_labels` массивы;
- модель обучается связывать изображения с метками;

Прогнозы делаются на тестовом наборе – в этом примере, `x_test` массив. Проверяем, что прогнозы соответствуют меткам из `y_test` массива. Чтобы начать тренировку, вызовем `model.fit` метод – модель "приспосабливается" ("fit") к тренировочным данным. Этому методу мы передаем сами тренировочные данные (`x_train` и `y_train`), количество эпох тренировки (`epochs`), использование многопоточности (`use_multiprocessing`), размер поступающих партий картинок (`batch_size`), а также максимальное количество процессов (`workers`), которые необходимо запустить при использовании многопоточности.

```
model = model.fit(x_train, y_train, epochs=#, use_multiprocessing=True, batch_size=#, workers=3)
```

Убедитесь, что после тренировки модели ее точность не меньше 90%.

```
Epoch 1/10
938/938 [=====] - 7s 7ms/step - loss: 0.4894 - accuracy: 0.8262
Epoch 2/10
938/938 [=====] - 8s 9ms/step - loss: 0.3650 - accuracy: 0.8674
Epoch 3/10
938/938 [=====] - 6s 6ms/step - loss: 0.3216 - accuracy: 0.8815
Epoch 4/10
938/938 [=====] - 6s 6ms/step - loss: 0.3007 - accuracy: 0.8889
Epoch 5/10
938/938 [=====] - 6s 6ms/step - loss: 0.2818 - accuracy: 0.8961
Epoch 6/10
938/938 [=====] - 6s 6ms/step - loss: 0.2676 - accuracy: 0.9001
Epoch 7/10
938/938 [=====] - 6s 6ms/step - loss: 0.2535 - accuracy: 0.9051
Epoch 8/10
938/938 [=====] - 6s 6ms/step - loss: 0.2423 - accuracy: 0.9093
Epoch 9/10
938/938 [=====] - 7s 7ms/step - loss: 0.2331 - accuracy: 0.9121
Epoch 10/10
938/938 [=====] - 6s 6ms/step - loss: 0.2214 - accuracy: 0.9171
```

Рис. 2. Результаты тренировки модели

На рис. 2 можно заметить, что на каждом этапе тренировки значение потерь уменьшается, а точность постепенно возрастает. После того, как мы убедились, что модель обучена, приступим к предсказанию результатов.

Листинг 3. Предсказание результатов

```
preds = np.argmax(model.predict(x_test), axis=-1)

# выбираем случайные 20 картинок из датасета
rand_idx = np.random.permutation(len(x_test))[:20]

pr = [class_names[i] for i in preds[rand_idx]]
```

```
plot(x_test[rand_idx], y_test[rand_idx], pr)
```



Рис. 2. Результат предсказаний

Под меткой *lbl* указывается истинный класс одежды, под меткой *pred* – предсказание, основанное на обученной модели. Как можно заметить, в некоторых случаях две эти метки не сходятся. Это нормально, так как наша модель не обучена на 100%, поэтому она может допускать ошибки. Повысить точность модели можно при увеличении количества эпох обучения.

Выполните следующие задания.

Задание 1. Напишите нейронную сеть классификатора одежды, используя при тренировке модели 10 эпох и размер партий, равный 64. Убедитесь, что точность модели не меньше 90%.

Задание 2. Постройте в Excel график зависимости скорости обучения модели при использовании и не использовании многопоточности на основе процессов (параметр `use_multiprocessing`) от величины параметра `batch_size`.

Ниже представлен пример реализации такого графика при использовании Google Colaboratory CPU: Intel(R) Xeon(R) CPU @ 2.20GHz, GPU: Tesla T4.




Рис. 3. Анализ влияния параметров multiprocessing и batch_size

http://www.kimrt.ru/index/course_stm/0-24

Проект реализуется победителем Конкурса на предоставление грантов преподавателям магистратуры 2020/2021 благотворительной программы «Стипендиальная программа Владимира Потанина» Благотворительного фонда Владимира Потанина.

Источники

1. Xiao, H., Rasul, K., & Vollgraf, R. (2017). Fashion-MNIST: a Novel Image Dataset for Benchmarking Machine Learning Algorithms. CoRR, abs/1708.07747. <http://arxiv.org/abs/1708.07747>
2. Dataset Card for FashionMNIST. https://huggingface.co/datasets/fashion_mnist
3. Цветовые режимы изображения. <https://helpx.adobe.com/ru/photoshop-elements/using/using-image-modes-color-tables.html>