

Разработка системы замены стиля одного изображения стилем другого изображения

Эрдман Александр Алексеевич

Приамурский государственный университет имени Шолом-Алейхема

Студент

Аннотация

В статье рассмотрен процесс создания программы, способной заменять стиль одного изображения стилем другого изображения. Программа написана на языке программирования Python с использованием нейронной сети и библиотеки TensorFlow. Результатом исследования будет являться программа с возможностью замены стилей изображения и описание её работы.

Ключевые слова: python, нейронная сеть, tensorflow

Development of a system for replacing the style of one image with the style of another image

Erdman Alexander Alekseevich

Sholom-Aleichem Priamursky State University

Student

Abstract

The article describes the process of creating a program capable of replacing the style of one image with the style of another image. The program is written in the Python programming language using a neural network and TensorFlow library. The result of the study will be a program with the ability to replace image styles and a description of its work.

Keywords: python, neural network, tensorflow

1 Введение

1.1 Актуальность

В области искусственного интеллекта и компьютерного зрения в последние годы значительное внимание уделяется передаче стиля изображения. Возможность заменить стиль одного изображения стилем другого изображения имеет множество применений в различных областях, включая моду, дизайн интерьера и рекламу. Однако процесс редактирования стиля изображения вручную — трудоемкая и сложная задача. Следовательно, разработка автоматизированной системы, которая может точно перенести стиль одного изображения на другое изображение, стала важной областью исследований. В этой статье мы обсудим разработку такой системы, которая сможет плавно заменить стиль одного изображения стилем другого изображения.

1.2 Обзор исследований

П.М. Горбунов, Ю.А. Мацкевич и А.В. Чубарь описали автоматизацию выбора модели машинного обучения с использованием методов машинного обучения; обсуждали, как этот процесс можно оптимизировать и сделать более эффективным, чтобы сократить время и затраты, необходимые для выбора лучшей модели для данной задачи [1]. С. А. Сохина, С. А. Немченко раскрыли понятие машинного обучения, а также раскрыли его типы и виды; объяснили принципы функционирования различных видов машинного обучения [2]. С.И.Билал рассмотрел наиболее известные методы, используемые для анализа настроений в твитах в Твиттере, включая методы машинного обучения, глубокого обучения и обработки естественного языка [3]. И.А. Попова рассмотрела рассмотрен ряд систем автоматизированного машинного обучения, описаны их ключевые особенности, решаемые задачи [4]. С. Рокхая представила обзор распространенных методов классификации изображений в машинном обучении, т.е. методов отнесения объекта к одной из категорий на основании его признаков [5]. В.Е. Садовников рассмотрел алгоритмы искусственного интеллекта в качестве основополагающего функции обработки изображений с видеонаблюдения [6]. А.В. Юдин и Самб Рокхая изучили и продемонстрировали в практике различные методы искусственного интеллекта и машинного обучения, используемые для решения задач распознавания образов и интеллектуальной обработки изображений [7].

1.3 Цель исследования

Целью исследования является создание программы на языке программирования Python, способной заменять стили изображения, при помощи нейронной сети и библиотеки TensorFlow.

2 Материалы и методы

Для создания программы используется язык программирования Python и библиотека TensorFlow. В качестве IDE используется Google Colab.

3 Результаты и обсуждения

Для начала работы нужно импортировать необходимые библиотеки такие, как `numpy`, `matplotlib.pyplot`, `tensorflow`, `keras`, которые являются основными библиотеками, а также вспомогательные библиотеки для работы с файлами и изображениями `google.colab.files`, `BytesIO` и `Image`. После импорта модулей и библиотек, необходимо загрузить изображения, с которыми предстоит работать. Для этого используется команда `«url = files.upload()»` для загрузки изображений с компьютера. Данные изображения имеют конкретные названия. Каждое изображение имеет свое уникальное название, которое будет использоваться для сохранения его в соответствующую переменную `"picture"` или `"style_picture"` Для этого используются две соответствующие команды (рис. 1)

```
[17] upl = files.upload()  
      picture = Image.open(BytesIO(upl['car.jpg']))  
      style_picture = Image.open(BytesIO(upl['style.jpg']))
```

Рисунок 1. Команды загрузки изображений

В процессе работы программы будет совершена обработка фотографии автомобиля и картины в стиле футуризма, чтобы в результате получить изображение автомобиля, оформленное в футуристическом стиле.

Для создания функционала замены стиля применяется нейронная сеть vgg19. Нейронная сеть vgg19 была разработана компанией Visual Geometry Group в Университете Оксфорда и состоит из 19 слоев. Эта сеть широко используется в задачах компьютерного зрения, таких как классификация изображений, распознавание объектов и детектирование объектов на изображениях. В данном проекте сеть vgg19 используется для извлечения характеристик изображений, которые затем будут использоваться для создания изображения автомобиля в выбранном стиле. Vgg19 работает с изображениями в формате BGR, в то время как выбранные изображения имеют формат RGB. Следовательно, для корректной работы необходимо преобразовать формат RGB в BGR. Это выполняется с помощью функции `preprocess_input` (рис. 2), которая заменяет среднее значение у цветовых компонентов: (B) 103.939, (G) 116.779 и (R) 123.68.

```
[6] x_picture = keras.applications.vgg19.preprocess_input( np.expand_dims(picture, axis=0) )  
     x_style_picture = keras.applications.vgg19.preprocess_input(np.expand_dims(style_picture, axis=0))
```

Рисунок 2. Функция преобразования формата RGB в BGR

Добавление оси с индексом 0 с помощью параметра `axis=0` позволяет изменить форму массива таким образом, чтобы он мог быть обработан сетью vgg19. В дополнение к функции `preprocess_input`, реализована обратная функция, которая преобразует изображение из формата BGR обратно в формат RGB для удобного просмотра полученного результата (рис. 3). Функция обратного назначения используется для преобразования изображений из формата BGR, необходимого для работы сети vgg19, в формат RGB, который используется для визуализации результатов. В начале функции с помощью метода `np.squeeze(x, 0)` удаляется нулевая ось, которая была добавлена в функции `preprocess_input`. Затем проверяется количество осей - должно быть три, используя `assert len(x.shape) == 3`. Далее к соответствующим цветовым компонентам добавляются средние значения, которые ранее были вычтены в функции `preprocess_input`. После этого цветовые компоненты меняют местами, чтобы из формата BGR получить формат RGB. Чтобы убедиться, что цветовые компоненты не выходят за допустимый диапазон, используется метод `np.clip(x, 0, 255).astype('uint8')`, который обрезает значения, меньшие 0 и большие 255, и преобразует массив в формат `uint8`.

```
[7] def deprocess_img(processed_img):
    x = processed_img.copy()
    if len(x.shape) == 4:
        x = np.squeeze(x, 0)
    assert len(x.shape) == 3, ("Предупреждение")
    if len(x.shape) != 3:
        raise ValueError("Error")

    # perform the inverse of the preprocessing step
    x[:, :, 0] += 103.939
    x[:, :, 1] += 116.779
    x[:, :, 2] += 123.68
    x = x[:, :, ::-1]

    x = np.clip(x, 0, 255).astype('uint8')
    return x
```

Рисунок 3. Функция преобразования BGR в RGB

Наконец, функция возвращает изображение в формате RGB. После загрузки сети vgg19 следует ее предварительная обработка и настройка перед использованием (рис. 4).

```
[8] vgg = keras.applications.vgg19.VGG19(include_top=False, weights='imagenet')
    vgg.trainable = False
```

Рисунок 4. Загрузка сети VGG19

Параметр `include_top=False` отключает полносвязный слой нейронной сети на конце, а параметр `weights='imagenet'` задает использование весов, обученных на наборе данных 'imagenet' из 10 миллионов изображений. Команда `vgg.trainable = False` делает веса неизменяемыми (необучаемыми). В дальнейшем будет использоваться данная сеть, на ее вход будет подаваться изображение, а на выходе будут получаться карты признаков на определенных слоях. Затем создаются вспомогательные коллекции, которые содержат имена слоев, выделенных в предыдущем шаге с помощью сети vgg19 (рис. 5).

Были выбраны имена слоев в соответствии со структурой сети vgg19. Цифра после слова "block" указывает на уровень слоя. Для вычисления контента будет использоваться последний сверточный слой "block5_conv2". Для вычисления потерь стиля будут использоваться пять сверточных слоев, определенных в переменной "style_layers": "block1_conv1" - "block5_conv1". Последние две команды на рисунке 7 указывают количество данных слоев. Эти переменные "content_layers" и "style_layers" будут использоваться далее в программе в качестве вспомогательных.

```
[ ] content_layers = ['block5_conv2']

style_layers = ['block1_conv1',
               'block2_conv1',
               'block3_conv1',
               'block4_conv1',
               'block5_conv1'
               ]

num_content_layers = len(content_layers)
num_style_layers = len(style_layers)
```

Рисунок 5. Создание слоёв для работы нейронной сети

Для построения модели нейронной сети используется класс `keras.models.Model(inputs, outputs)`, который принимает на вход коллекцию входов и коллекцию выходов и на основе связей между слоями строит модель сети. В данном случае, модель будет построена на основе иерархии слоёв, включая полно связные слои и сверточные слои, и будет использоваться архитектура VGG19. Используя переменные `content_layers` и `style_layers` будут выделены соответствующие слои (рис. 6).

```
style_outputs = [vgg.get_layer(name).output for name in style_layers]
content_outputs = [vgg.get_layer(name).output for name in content_layers]
```

Рисунок 6. Выделение слоёв style и content

В обоих переменных происходит обращение к сети `vgg19` и из неё происходит выделение выходов (`output`), которые соответствуют именам `block5_conv2`, `block1_conv1`-`block5_conv1`. Для переменной `style_outputs` выделяются слои `block1_conv1` - `block5_conv1`, которые находятся в коллекции `style_layers`. Для переменной `content_outputs` выделяется только один слой `block5_conv2`. Затем используется операция объединения выходов с помощью команды `model_outputs = style_outputs + content_outputs`. Для вывода на экран соответствующих слоёв используется следующий код: `print(vgg.input)`, `for m in model_outputs:`, `print(m)`. Затем создается модель сети, используя класс `Model`: `model = keras.models.Model(vgg.input, model_outputs)`, где указывается один вход и необходимые выходы, полученные ранее с помощью объединения (рис. 7).

```

KerasTensor(type_spec=TensorSpec(shape=(None, None, None, 3), dtype=tf.float32, name='input_1'), name='input_1', description='created by layer 'input_1'')
KerasTensor(type_spec=TensorSpec(shape=(None, None, None, 64), dtype=tf.float32, name=None), name='block1_conv1/Relu:0', description='created by layer 'block1_conv1'')
KerasTensor(type_spec=TensorSpec(shape=(None, None, None, 128), dtype=tf.float32, name=None), name='block2_conv1/Relu:0', description='created by layer 'block2_conv1'')
KerasTensor(type_spec=TensorSpec(shape=(None, None, None, 256), dtype=tf.float32, name=None), name='block3_conv1/Relu:0', description='created by layer 'block3_conv1'')
KerasTensor(type_spec=TensorSpec(shape=(None, None, None, 512), dtype=tf.float32, name=None), name='block4_conv1/Relu:0', description='created by layer 'block4_conv1'')
KerasTensor(type_spec=TensorSpec(shape=(None, None, None, 512), dtype=tf.float32, name=None), name='block5_conv1/Relu:0', description='created by layer 'block5_conv1'')
KerasTensor(type_spec=TensorSpec(shape=(None, None, None, 512), dtype=tf.float32, name=None), name='block5_conv2/Relu:0', description='created by layer 'block5_conv2'')
Model: "model"

```

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	(None, None, None, 3)	0
block1_conv1 (Conv2D)	(None, None, None, 64)	1792
block1_conv2 (Conv2D)	(None, None, None, 64)	36928
block1_pool (MaxPooling2D)	(None, None, None, 64)	0
block2_conv1 (Conv2D)	(None, None, None, 128)	73856
block2_conv2 (Conv2D)	(None, None, None, 128)	147584
block2_pool (MaxPooling2D)	(None, None, None, 128)	0
block3_conv1 (Conv2D)	(None, None, None, 256)	295168
block3_conv2 (Conv2D)	(None, None, None, 256)	590080
block3_conv3 (Conv2D)	(None, None, None, 256)	590080
block3_conv4 (Conv2D)	(None, None, None, 256)	590080
block3_pool (MaxPooling2D)	(None, None, None, 256)	0
block4_conv1 (Conv2D)	(None, None, None, 512)	1180160
block4_conv2 (Conv2D)	(None, None, None, 512)	2359808
block4_conv3 (Conv2D)	(None, None, None, 512)	2359808
block4_conv4 (Conv2D)	(None, None, None, 512)	2359808
block4_pool (MaxPooling2D)	(None, None, None, 512)	0
block5_conv1 (Conv2D)	(None, None, None, 512)	2359808
block5_conv2 (Conv2D)	(None, None, None, 512)	2359808

```

=====
Total params: 15,304,768
Trainable params: 0
Non-trainable params: 15,304,768
None

```

Рисунок 7. Вывод слоёв и структуры нейронной сети

После выполнения операций на экран были выведены тензоры - выходные слои и структура построенной нейронной сети.

После создания сети необходимо создать функцию, которая будет вычислять потери. Сначала создаётся функция `get_content_loss`, которая будет определять потери, связанные с контентом (8).

```

def get_content_loss(base_content, target):
    return tf.reduce_mean(tf.square(base_content - target))

```

Рисунок 8. Функция потерь по контенту

После пропуска исходного изображения с автомобилем через сверточную сеть получается коллекция тензоров, хранящихся в переменной `base_content`. После пропуска преобразованного изображения через эту же сеть получается вторая коллекция тензоров `target`. С помощью операции `tf.square` из TensorFlow вычисляется квадрат разницы между двумя коллекциями, а затем используется функция `tf.reduce_mean` для получения среднего значения. Таким образом, определяются потери по контенту.

Для вычисления потерь по стилям используется функция матрицы Грамма (9).

```
def gram_matrix(input_tensor):  
    channels = int(input_tensor.shape[-1])  
    a = tf.reshape(input_tensor, [-1, channels])  
    n = tf.shape(a)[0]  
    gram = tf.matmul(a, a, transpose_a=True)  
    return gram / tf.cast(n, tf.float32)
```

Рисунок 9. Матрица Грамма

Данная функция вычисляет матрицу грамма, которая используется для вычисления сходства или корреляции между векторами признаков изображения. В качестве аргумента используется тензор `input_tensor`. Входной тензор представлен трёхмерным, содержащий количество каналов, которые являются картами признаков. Для выбора каналов используется операция `channels = int(input_tensor.shape[-1])`. В ходе операции `tf.reshape` происходит преобразование трёхмерного тензора в двумерный. Преобразование 3D-тензора в 2D-тензор часто необходимо, когда нам нужно передать данные в модель машинного обучения, которая ожидает двумерный ввод. Трёхмерный тензор содержит три измерения (длина, ширина и глубина), последнее из которых является картами признаков. Третье измерение записано в переменной `channels`. В преобразованном двумерном тензоре будет два измерения, одно из которых – это произведение длины и ширины трехмерного тензора, а вторым измерением является глубина трехмерного тензора (карта признаков). Переменная `gram` включает в себя операцию умножение транспонированной переменной `a` на исходную `a`. Операция `gram / tf.cast(n, tf.float32)` разделяет полученное выше произведение в переменной `gram` для того, чтобы усреднить вычисления. В результате выполнение данных операций получается матрица Грамма.

Следующая функция вычисляет стиль для строго определённого слоя нейронной сети (10).

```
def get_style_loss(base_style, gram_target):  
    gram_style = gram_matrix(base_style)  
    return tf.reduce_mean(tf.square(gram_style - gram_target))
```

Рисунок 10. Функция вычисления стиля

Для разных слоёв нейронной сети будет происходить вычисление рассогласование по стилям. Параметр `base_style` – это карта стилей формируемого изображения, параметр `gram_target` – матрица Грамма для соответствующего слоя целевого изображения. В переменной `gram_style` происходит вычисление матрицы Грама для формируемого изображения. Последняя операция данной функции вычисляет среднее арифметическое квадрата рассогласований.

Общей функцией, вычисляющей все потери, является функция `compute_loss` (рис. 11).


```
def compute_loss(model, loss_weights, init_image, gram_style_features, content_features):
    style_weight, content_weight = loss_weights

    model_outputs = model(init_image)

    style_output_features = model_outputs[:num_style_layers]
    content_output_features = model_outputs[num_style_layers:]

    style_score = 0
    content_score = 0

    weight_per_style_layer = 1.0 / float(num_style_layers)
    for target_style, comb_style in zip(gram_style_features, style_output_features):
        style_score += weight_per_style_layer * get_style_loss(comb_style[0], target_style)

    weight_per_content_layer = 1.0 / float(num_content_layers)
    for target_content, comb_content in zip(content_features, content_output_features):
        content_score += weight_per_content_layer * get_content_loss(comb_content[0], target_content)

    style_score *= style_weight
    content_score *= content_weight

    loss = style_score + content_score
    return loss, style_score, content_score
```

Рисунок 11. Общая функция потерь

В качестве параметров, данная функция принимает модель нейронной сети (`model`), `loss_weights` – содержит в себе два элемента `content_weight` и `style_weight`. Параметр `init_image` – это формируемое изображение, которое пропускается через нейронную сеть с помощью операции `model(init_image)`, в результате которой получаются значения на каждом сверточном слое (`model_outputs`).

Из полученных результатов происходит выделение из коллекции `model_outputs` карты признаков для стилей (`style_output_features`) и для контента (`content_output_features`). Переменные `style_score` и `content_score` хранят величины потерь для стилей и контента. Далее происходит определение весов для суммирования потерь стилей каждого слоя (`weight_per_style_layer`). В цикле происходит перебор матриц Грама для стилизованного изображения, которые заранее вычисленные (параметр `gram_style_features` в функции `compute_loss`), и карт признаков, которые были вычислены с помощью нейронной сети. Внутри цикла происходит суммирование квадрата рассогласований для каждого слоя.

Для контентного слоя происходит тоже самое. Так как слой в данном случае один, следовательно цикл сработает только один раз. В переменных `style_score` и `content_score` происходит умножение на вычисленные переменные на величины `style_weight` и `content_weight`. Далее следует операция суммирования. `Loss` – это общий критерий вычисленный критерий качества. В результате функция `compute_loss` возвращает общие потери, потери по стилю и контенту.

После определения функций потерь в коде программы, задаются значения для нескольких переменных, которые будут использоваться в дальнейшем. Например, переменная `num_iterations`, определяющая количество итераций, которые будут использоваться в процессе формирования нового изображения. Значение этой переменной равно 100. Также определены переменные `content_weight` и `style_weight`, которые являются коэффициентами, отвечающими за вклад контента и стиля в формируемое

изображение соответственно. Значение `content_weight` равно 1000, что означает, что на изображении будет сохранено большинство контента из исходного изображения, содержащего автомобиль. Значение `style_weight` равно 0.01, что указывает на то, что стиль второго изображения будет учтен в небольшой степени при формировании нового изображения.

С помощью метода `get_feature_representations(model)` два исходных изображения (изображение с автомобилем (контент) и с футуристической картиной (стиль)) проходят через нейронную сеть. На выходе данной нейронной сети получатся карты признаков по стилю и контенту. После завершения данной операции, следует вычисление матрицы Грама для стилового изображения.

Переменная `init_image` содержит начальное изображение, которое соответствует изображению с автомобилем. Это изображение будет изменяться с помощью библиотеки TensorFlow. Для корректной работы с изображением, оно должно быть преобразовано в переменную типа `tf.Variable`. Для выполнения алгоритма градиентного спуска, создаются оптимизаторы. В данном случае используется оптимизатор `AdamOptimizer` из TensorFlow с заданным `learning_rate=2`, `beta1=0.99`, `epsilon=1e-1`. Оптимизатор позволяет настроить параметры обучения модели, такие как скорость обучения и коэффициенты регуляризации.

Параметр `learning_rate` — это гиперпараметр, который управляет размером шага на каждой итерации при движении к минимуму функции потерь. Другими словами, он определяет скорость обновления параметров модели во время обучения.

Параметр `beta1` — это гиперпараметр, который управляет скоростью экспоненциального затухания для оценок первого момента. Это значение от 0 до 1, которое определяет, какой вес следует придавать прошлым градиентам при вычислении текущей оценки градиента. Более высокое значение `beta1` означает, что прошлым градиентам придается больший вес, что может помочь сгладить оценки градиента и сделать оптимизацию более стабильной.

Параметр `epsilon` — это гиперпараметр, который предотвращает деление на ноль при вычислении правила обновления. Это небольшая величина, добавленная к знаменателю для обеспечения числовой стабильности.

Переменная `iter_count` - это счетчик итераций, который изначально равен 1. Каждая итерация представляет собой один проход через оптимизируемую функцию потерь. В данном случае, на каждой итерации происходит вычисление градиента потерь по отношению к переменной `init_image`, после чего переменная `init_image` обновляется в направлении уменьшения потерь с помощью оптимизатора. Таким образом, с каждой итерацией изображение становится все более похожим на искомое. Количество итераций определяется заранее и является гиперпараметром, который может быть подобран экспериментальным путем.

Переменные `best_loss` и `best_img` являются вспомогательными в рамках данного алгоритма. Первая переменная хранит наименьшие потери, которые достигаются в процессе вычислений сети, а вторая переменная содержит

лучшее сформированное изображение, соответствующее минимальным потерям. Коллекция `loss_weights` содержит два параметра: `style_weight` и `content_weight`, описанные ранее. Чтобы удобно работать с параметрами, они сведены в словарь, что позволяет легко получать доступ к нужным параметрам для выполнения определенных.

Метрикой является переменная `loss`, которая используется для хранения значения потери (`loss`) при стилизации изображения и вычисляется с помощью функции `compute_loss`. Метрика `loss` представляет собой суммарную потерю (`style_score + content_score`) и используется для оценки качества стилизации изображений. Переменная `loss` является числовым значением, которое позволяет оценить, насколько хорошо текущая модель стилизации выполняет свою задачу. Чем меньше значение `loss`, тем ближе стилизованное изображение к желаемому результату.

Часть кода, которая отвечает за преобразование изображения из BGR формата в RGB, а также массив `img`, который будет содержать все изображения, которые будут сформированы в процессе работы нейронной сети (рис. 12).

```
norm_means = np.array([103.939, 116.779, 123.68])
min_vals = -norm_means
max_vals = 255 - norm_means
imgs = []
```

Рисунок 12. Преобразование изображения из BGR в RGB

В конце нейронной сети прописывается запуск алгоритма градиентного спуска (рис.13).

Функция `compute_loss` обрабатывает формируемое изображение через нейронную сеть и возвращает значения потерь. Вызов функции осуществляется в области видимости объекта `GradientTape`, который записывает все необходимые величины для последующего вычисления градиента для изменения пикселей формируемого изображения в соответствии с функцией потерь. С помощью объекта `GradientTape` происходит автоматическое вычисление всех необходимых производных, с помощью которых для подстраиваемых параметров (пикселей изображения) будут вычисляться градиенты, относительно пикселей изображения. С помощью команды `opt.apply_gradients([(grads, init_image)])` происходит применение вычисленного градиента к пикселем формируемого изображения. С помощью метода `tf.clip_by_value` происходит ограничение пикселя изображения минимальными (`min_vals`) и максимальными (`max_vals`) значениями, так как каждая цветовая компонента может находиться в строго определённых числовых значениях, и соответственно выход за данные числовые значения не допускается. С помощью условия `If` происходит проверка изображений, для которых получились минимальные потери.

```
for i in range(num_iterations):
    with tf.GradientTape() as tape:
        all_loss = compute_loss(**cfg)

    loss, style_score, content_score = all_loss
    grads = tape.gradient(loss, init_image)

    opt.apply_gradients([(grads, init_image)])
    clipped = tf.clip_by_value(init_image, min_vals, max_vals)
    init_image.assign(clipped)

    if loss < best_loss:
        best_loss = loss
        best_img = deprocess_img(init_image.numpy())

    plot_img = deprocess_img(init_image.numpy())
    imgs.append(plot_img)
    print('Iteration: {}'.format(i))

Iteration: 5
Iteration: 6
Iteration: 7
Iteration: 8
Iteration: 9
Iteration: 10
Iteration: 11
Iteration: 12
```

Рисунок 13. Алгоритм градиентного спуска

После проверки и выбора изображения происходит его сохранение. Вывод изображения осуществляется с помощью команд `plt.imshow` и `print` (рис. 14).

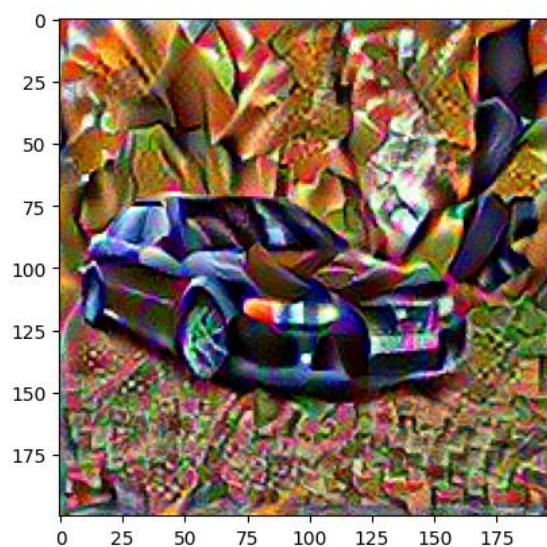


Рисунок 14. Результат работы сети

Для тестов были взяты несколько изображений, для проверки работы сети (рис. 15, 16 и 17)



Рисунок 15. Результат работы сети (снизу) на основе двух изображений (сверху: слева исходное изображение, справа изображение стиля)



Рисунок 16. Результат работы сети (снизу) на основе двух изображений (сверху: слева исходное изображение, справа изображение стиля)



Рисунок 17. Результат работы сети (снизу) на основе двух изображений (сверху: слева исходное изображение, справа изображение стиля)

В результате исследования была построена система с нейронной сетью, которая способна заменять стили двух изображений с сохранением содержимого изменяемого изображения. Для проверки работоспособности сети были проведены несколько тестов с несколькими изображениями, в результате которых были получены удовлетворительные результаты работы системы.

Библиографический список

1. Горбунов П. М., Мацкевич Ю. А., Чубарь А. В. Машинное обучение. Автоматизация подбора модели машинного обучения // Робототехника и искусственный интеллект. 2021. С. 155-160.
2. Сохина С. А., Немченко С. А. Машинное обучение. Методы машинного

- обучения // Современная наука в условиях модернизационных процессов: проблемы, реалии, перспективы. 2021. С. 165-168.
3. Билал С. И. Обзор анализа настроений с использованием методов машинного обучения и глубокого обучения // Инновационные технологии, экономика и менеджмент в промышленности. 2022. С. 195-199.
 4. Попова И. А. Системы automl как современный инструмент для построения моделей машинного обучения // StudNet. 2022. Т. 5. №. 1. С. 815-825.
 5. Рокхая С. Различные типы обработки изображений с помощью искусственного интеллекта // Интернаука. 2021. №. 7-1. С. 17-21.
 6. Садовников В. Е. Возможности видеонаблюдения с последующей обработкой изображения на основе алгоритмов искусственного интеллекта // Россия молодая. 2021. С. 31521.1-31521.4.
 7. Юдин А. В., Рокхая С. Различные типы обработки изображений с помощью искусственного интеллекта // Общество-наука-инновации: сборник статей Международной научно-практической. 2021. С. 8.