

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение
высшего образования

**«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ИМЕНИ Н. Г. ЧЕРНЫШЕВСКОГО»**

Кафедра технологий программирования

СОВРЕМЕННЫЕ МЕТОДЫ РАСПОЗНАВАНИЯ ЛИЦ

АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ

студента 2 курса 273 группы
направления 02.04.03 — Математическое обеспечение и администрирование
информационных систем
факультета КНиИТ
Давыдова Виктора Вениаминовича

Научный руководитель

доцент, к. ф.-м. н.

А. А. Кузнецов

Заведующий кафедрой

к. ф.-м. н.

И. А. Батраева

Саратов 2020

СОДЕРЖАНИЕ

ВВЕДЕНИЕ	3
1 Одна из основных задач машинного обучения - подготовка обучающей выборки	4
1.1 Общий алгоритм подготовки набора данных	5
2 МТСNN	6
2.1 МТСNN, подготовка датасета	6
2.2 МТСNN, обучение	7
2.3 МТСNN, как работает	8
2.4 Результат тестирования обучения сети при новой генерации данных	9
3 ResNet-Arcface, обзор датасетов для сетей распознавания	10
3.1 ResNet-Arcface, функционирование	11
3.2 STN — Сеть пространственного изменения	13
ЗАКЛЮЧЕНИЕ	15
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ	16

ВВЕДЕНИЕ

Машинное обучение (Machine Learning) — раздел искусственного интеллекта, предоставляющий компьютерным системам возможность учиться и улучшаться за счет накапливаемого опыта. Различают два вида обучения:

- Обучение на примерах (индуктивное обучение) — тип обучения, при котором интеллектуальной системе предоставляется набор верных и неверных суждений, связанных с какой-либо заранее неизвестной закономерностью;
- Дедуктивное обучение — тип обучения, при котором знания экспертов формализуются и помещаются в компьютер в виде базы знаний.

Последнее относится к сфере экспертных систем, в связи с чем, понятия машинное обучение и обучение на примерах могут считаться синонимами.

Помимо того, что в основании машинного обучения находятся методы оптимизации, математическая статистика и иные классические математические дисциплины, оно также имеет свою специфику, связанную с понятием переобучения «overfitting» и с проблемами вычислительной эффективности. Множество способов индуктивного обучения разрабатывались, как альтернатива классическим статистическим подходам.

Машинное обучение является не только математической, но и практической (инженерной) дисциплиной. Основываясь исключительно на теории, нельзя сразу перейти к алгоритмам и методам, которые можно применять на практике. Поэтому в машинном обучении разрабатываются эвристические приемы позволяющие оценить пригодность теоретических методов для практических задач.

Целью дипломной работы является реализация полного цикла распознавания лиц, с работой по его улучшению. Данная цель определила следующие задачи:

- Подобрать библиотеку для реализации и обучения нейронных сетей;
- Реализовать метод обнаружения лиц на изображении;
- Реализовать метод идентификации принадлежности лица определенному классу лиц;
- Реализовать приложение для обучения и демонстрации работы сетей;
- Произвести попытку улучшения сети обнаружения лиц;
- Произвести попытку улучшения сети идентификации лиц.

1 Одна из основных задач машинного обучения - подготовка обучающей выборки

В настоящее время технологии машинного обучения прочно обосновываются в жизни людей. Этому способствует глобализация, увеличение вычислительных мощностей, большое число библиотек, для реализации нейронных сетей, а также перспективы развития данного направления.

Но, несмотря на это, практическая тренировка искусственных нейронных сетей не является простой задачей. Для решения собственных задач и задач бизнеса при помощи нейронных сетей следует учитывать следующее.

- Значимость данных и важность предварительной подготовки;
Большая часть времени при решении реальных задач машинного обучения уходит на подготовку датасета.
Для каждой конкретной задачи необходим свой набор данных. Он должен быть сбалансированным, содержать необходимый для тренировки набор данных и иметь единый формат. Также процесс его подготовки не должен быть дороже выполняемой задачи.
- Неравномерность распределения классов входных данных в реальных задачах;
Большинство существующих академических наборов данных являются сбалансированными. Это означает, что, например, для задачи классификации, подобрано одинаковое число элементов для каждого класса. В реальных же задачах — данные, чаще всего, будут несбалансированными. В случае задачи классификации — это означает, что число меток классов будет сильно различаться.
В зависимости от задачи влияние неоднородности классов обучающей выборки может иметь разный результат, но положительным он не будет. Для решения данной проблемы следует преобразовать набор данных к сбалансированному виду. Можно прибегнуть к игнорированию наиболее часто встречающихся классов, изменению частотности демонстрации классов обучаемой модели или сопоставления веса каждому классу сообразно его размеру.
- Представление модели.
При разработке новых методов и подходов в машинном обучении главной целью является опережение предыдущих в точности работы. В ре-

альных задачах важна стабильность и предсказуемость. О методах глубокого машинного обучения в отличие от других, решающих схожие задачи трудно судить в виду их нелинейности.

Нейронная сеть, может как сама ошибаться на некоторых примерах, так и выдать неверный результат ввиду целенаправленной атаки на нее. Поэтому при оценке работы сети для реальных задач применяются различные методы позволяющие понять поведение сети в той или иной ситуации.

1.1 Общий алгоритм подготовки набора данных

1. Выборка данных — отбор признаков (свойств) и объектов подходящих для целей поставленной задачи машинного обучения, соответствующие необходимому уровню качества и техническим ограничениям;
2. Очистка данных — удаление некорректных значений, отсутствующих значений, дублей и разных описаний одного и того же объекта, восстановление уникальности, целостности и логических связей;
3. Генерация признаков — выделение производных свойств, а также их преобразование с целью повышения точности работы алгоритма машинного обучения;
4. Интеграция — сочленение, агрегация данных из различных источников данных и составление на их основе одного датасета;
5. Форматирование — преобразование данных к виду подходящему для чтения инструментами моделирования и загрузки датасетов;

В данной работе используются существующие датасеты, которые изменяются для улучшения работы сетей.

2 MTCNN

MTCNN как каскадный, мультизадачный подход обнаружения лиц, который использует наследственную связь между задачами, чтобы улучшить их производительность. В частности используется каскадная структура из трех уровней глубоких сверточных нейронных сетей, которые предсказывают положение лиц подходом от худшего к лучшему. В дополнение в процессе обучения используется метод генерации примеров для обучения в реальном времени, что может улучшить производительность автоматически, без ручного выбора примеров. Данный метод достигает хороших результатов, сохраняя при этом производительность достаточную для работы в реальном времени.

2.1 MTCNN, подготовка датасета

Главным источником данных для обучения MTCNN выступает датасет WIDER FACE. Это датасет, который был создан как метрика оценки качества обнаружения лиц. Он был сформирован на основе публично доступного датасета WIDER dataset. WIDER FACE состоит из 32 203 изображений с размеченными 393 703 лицами, причем фотографии и изображения лиц на них обладают различными размерами, расположением и перекрытиями (лицо видно не полностью). WIDER FACE организован основываясь на 61 различном состоянии изображения лица (классе). Для каждого такого класса случайно выбраны 40% как тренировочные данные, 10% как проверочные и 50%, как тестовые.

Попытка улучшения работы данной каскадной сети заключается в дополнительной обработке датасета — не обычной нарезке квадратов из исходного изображения с просчетом NMS, а вычисление сетки квадратов с поворотом на случайный угол.

Алгоритм получения примеров для обучения из исходного датасета следующий:

1. Получить на вход изображение из датасета с информацией о местоположении лиц на нем;
2. составить набор из лиц, удалив те которые меньше чем искомое;
3. В зависимости от размеров изображения вычисляется шаг сетки, так чтобы ячейка была не менее четверти от искомого изображения;
4. Производится подсчет центра полученного прямоугольника и переме-

щение центра координат в центр прямоугольника;

5. Формируется набор координат сетки, который поворачивается на случайный угол;

$$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix} = \begin{pmatrix} x \\ y \end{pmatrix} * \begin{pmatrix} \cos(\phi) & -\sin(\phi) \\ \sin(\phi) & \cos(\phi) \end{pmatrix}$$

6. Точки возвращаются в исходную систему координат;
7. Производится разбиение множества ячеек на положительные, частичные и отрицательные примеры;
8. Используется свой метод подсчета NMS
 - вычислить число точек входящих в прямоугольник лица;
 - вычислить координаты пересечения прямоугольника ячейки с прямоугольником лица;
 - по формуле площади Гаусса вычислить площадь пересечения прямоугольников и сами их площади;
 - ответом будет частное области пересечения к области объединения.
9. Согласно данной метрике распределить примеры:
 - менее 0.4 — отрицательный пример;
 - от 0.4 до 0.6 — частичный;
 - выше 0.6 — положительный.

2.2 MTCNN, обучение

MTCNN (Multi-task Cascaded Convolutional Networks) — мультизадачные каскадные сверточные сети. Это метод обнаружения лица человека на изображении в основе которого лежат 3 уровня — 3 нейронные сети:

- PNet (Proposal Network) — небольшая сверточная нейронная сеть первого уровня, которая отвечает за выдачу набора первичных окон-кандидатов, в которых, в большинстве случаев, содержатся лица или их части;
- RNet (Refine Network) — более сложная нейронная сеть отвечающая за исключение окон-кандидатов в которых лица не содержатся;
- ONet (Output Network) — последняя нейронная сеть отвечающая за выдачу окон-кандидатов, которые содержат лицо целиком.

Для того, чтобы алгоритм выявления лиц заработал необходимо обучить каждую из нейронных сетей.

Для каждой из нейронных сетей входными данными являются картин-

ки определенного размера с координатами окон-кандидатов (BoundingBoxes — ВВ):

- Для PNet, входной размер картинки должен составлять (12,12,3), где первые два значения это ширина и длина, а последнее число каналов изображения, к примеру красный, зеленый и синий (RGB);
- Для RNet, входной размер картинки должен составлять (24,24,3);
- Для ONet, входной размер картинки должен составлять (48,48,3);

Данные для PNet генерируются на основании вручную размеченных данных, то есть где люди выступали в роли распознавателя лиц на изображении. Для RNet, данные генерируются на основе окон-кандидатов полученных из обученной PNet, а для ONet из RNet соответственно.

2.3 MTCNN, как работает

Из получаемого на вход изображения формируется массив изображений разного масштаба, строится пирамида изображений, которая и является входным значением каскадной модели.

На первом уровне используется полносвязная сеть PNet для получения окон кандидатов и векторов из Bounding Box-ов (прямоугольников предполагаемых лиц). Затем производится оценка полученных окон-кандидатов и их калибровка. Далее применяется метод подавление не-максимумов Non-Maximum Suppression (NMS), для объединения сильно пересекающихся кандидатов.

Выдаваемые PNet результаты это большое количество, пересекающихся, предположений для классификации. В данном случае данное предположение — это не что иное, как окна-кандидаты лиц. Большинство подходов используют метод скользящего окна поверх карты признаков и производят оценки внешние в внутренние в зависимости от признаков, вычисленных в конкретном окне. Соседние окна имеют схожие в некоторой степени оценки и считаются окнами-кандидатами. Это приводит к сотням предположений. Поскольку метод генерации предположений должен быть крайне эффективным с точки зрения скорости выдачи результата, на данном этапе — этапе генерации окон-кандидатов, строгие ограничения не налагаются. Однако обработка многочисленных предположений сквозь всю сеть классификации RNet, является слишком ресурсоемкой задачей. Данный недостаток привел к созданию метода фильтрации предположений основанный на некоторых критериях, это

NMS. Он заключается в быстром удалении прямоугольников лиц, которые стоят близко и имеют схожие коэффициенты метрики IoU.

После применения NMS, полученный набор Bounding Box-ов передается на вход следующей нейронной сети RNet. Она исключает значительное число неподходящих кандидатов, выдает новый набор окон-кандидатов, после чего к нему вновь применяется NMS.

Далее, происходит обработка данного набора окон-кандидатов последней сетью — ONet, принцип ее функционирования похож на RNet. Она окончательно улучшает выходную выборку исключая все не имеющие лица окна-кандидаты.

2.4 Результат тестирования обучения сети при новой генерации данных

Основной идеей подготовки датасета при помощи решетки было заставить сеть PNet сконцентрировать внимание на отдельных частях лица и по ним предсказывать общее положение лица. Также, обычно при подготовке датасетов не прибегают к сложным методам подготовки данных, то есть, в данном случае, просто нарезают из исходного участка с лицом случайные прямоугольники, включающие большую часть лица, за случайное положение лица отвечает сам набор данных. Но при этом первая сеть, обнаружения пытается научиться искать именно лицо, но если ее задача находить окна кандидаты, то есть вероятность, что обнаруживать нужно элементы лица, и чтобы увеличить данную способность было предложено по-другому подготовить для нее датасет.

В ходе экспериментов было выяснено, что при применении данного метода, работа сети не улучшается. Ухудшения замечено не было. Вероятнее всего это связано с тем, что сеть PNet выполняет не основную роль и главными распознавателями выступают RNet и ONet.

3 ResNet-Arcface, обзор датасетов для сетей распознавания

ResNet (Residual Network, Остаточная сеть) — глубокая, остаточная, сверточная нейронная сеть, которая отвечает за распознавание объектов. Ее задача по входному изображению выдать характеристический вектор изображения, который будет относить изображение к некоторому классу. Для обучения такой нейронной сети нужен датасет отвечающей задаче распознавания лиц, в нем должно быть множество изображений лиц людей.

Датасеты для распознавания имеют большой объем, к примеру известный датасет ImageNet имеет размер более 300 гигабайт. Для того чтобы хранить такой датасет требуется не только место для файлов но и для метаданных файлов, а допустимый размер метаданных хранимых в каждой файловой системе невелик. Существует библиотека машинного обучения MxNet, в которой существует специальный формат данных для упаковки датасетов в один бинарный файл. Этот формат удобен тем, что весь датасет со всей метаданной информацией представляется в виде одного файла и его удобно перемещать и просматривать.

Входные данные для сети должны иметь формат (112, 112, 3), что соответствует ширине, длине и числу каналов изображения. Также каждое изображение должно обладать идентификационным номером, который отделяет классы лиц людей.

Источниками данных выступают датасеты FACES MS1M, FACES CASIA и FACES GLINT. Каждый из них представлен в виде набора файлов mxnet. Вот пример файловой структуры датасета:

```
faces_webface_112x112/  
|-- agedb_30.bin  
|-- calfw.bin  
|-- cfp_ff.bin  
|-- cfp_fp.bin  
|-- cplfw.bin  
|-- lfw.bin  
|-- property  
|-- train.idx  
|-- train.lst  
+-- train.rec
```

Файлы из которых будет производиться чтение это файлы `train.idx` и `train.rec`, первый содержит индексы указывающие на данные, а второй сами данные или записи(records).

В данной работе была реализована возможность просмотра данных из MxNet и их извлечение. Извлеченные данные представляют собой папку с пронумерованными изображениями и один метафайл в котором содержится информация о принадлежности изображения классу.

3.1 ResNet-Arcface, функционирование

Современные глубокие нейронные сети состоят из блоков-слоев разного типа, производящих разные операции над входными данными.

Вот список обычно используемых блоков:

- слой свертки;
- слой субдискретизации (pooling);
- полносвязный слой;
- слой нормализации.

Сверточный слой включает в себе простую и, вместе с тем универсальную и мощную математическую операцию — свертку.

Простейший вариант свертки — двумерная свертка. Ее функционирование заключается в следующем, есть ядро, представляющее из себя матрицу весов. Это ядро проходит над двумерным изображением, поэлементно выполняя операцию умножения с той частью входных данных, над которой оно находится в этот конкретный момент времени, и затем суммирует все полученные значения в один выходной пиксель.

Ядро повторяет эту процедуру с каждой областью входных данных, соответствующей размеру ядра, преобразуя двумерную матрицу в иную, но все еще двумерную матрицу признаков. Признаки на выходе являются взвешенными суммами признаков на входе, расположенных примерно в том же месте, что и выходной пиксель на входном слое.

У ядра свертки есть параметр — его размер. Размер ядра сверточной нейронной сети определяет количество признаков, которые будут объединены для получения нового признака на выходе.

При операции свертки, слой свертки состоит из нескольких ядер, после прохождения через которые входные данные преобразуются в карты признаков (feature maps).

Для вычисления свертки часто применяются следующие три техники:

- padding(отступ)
- stride(шаг)
- dilation(расширение)

Первая, padding, заключается в добавлении к матрице входных данных дополнительных значений по краям. Это расширение необходимо для того, так как если отступа нет, то крайние $n/2$ (n — размер ядра) элементов не попадают в центр ядра. Обычно дополнительные значения равны нулю. И, при использовании padding-а размерности входных значений и выходных совпадают при отступе равном $n/2$.

Вторая, stride, состоит в том, чтобы проходить ядром матрицу входных значений не поэлементно, а через шаг. При таком подходе входная матрица сокращается в число раз равное установленному шагу.

Третья, dilation, заключается в постоянном шаге внутри матрицы ядра, т.е. матрица накладывается не подряд элемент за элементом, а через шаг.

Функционирование слоя субдискретизации заключается в уменьшении размерности сформированных карт признаков. Данная операция применяется, если считается, что данные о факте наличия искомого признака важнее точного знания его координат.

Полносвязный слой — обычный перцептрон. В нем всякий нейрон связан со всеми нейронами предыдущего слоя, так, что всякая связь имеет свой собственный весовой коэффициент.

Простое складывание большого числа слоев не дает увеличения производительности и точности сети, наоборот с увеличением числа слоев точность падает. Решить данную проблему получилось благодаря изобретению Остаточных слоев. Остаточный слой — это блок обычных слоев, в котором к выходному значению добавляется исходное входное.

Для увеличения расстояния(различимости) классов изображений без потери точности определения классов была придумана функция потерь аддитивного углового смещения — ArcFace. Ее идея заключается в добавлении угла между вектором весов и характеристическим вектором изображения, что приводит к лучшему разграничению классов изображения.

В данной работе используется сеть ResNet-18, в которой в качестве функции потерь используется ArcFace.

Работает данная сеть как обычная функция. На вход подается изображение размера соответствующего тому, которое использовалось при обучении сети — 112×112 . Далее вычисляется функция сети, получается характеристический вектор, если он соответствует какому-то из классов, выводится соответствующая информация, иначе формируется информация о новом классе.

3.2 STN — Сеть пространственного изменения

Сверточные нейронные сети являются мощным классом моделей, но они все же имеют ограничение. Им недостает способности быть пространственно независимыми по отношению к входным данным в вычислительном и параметрическом смысле. Для того, чтобы исправить данный недостаток были созданы обучаемые модули пространственной трансформации, которые напрямую позволяют манипулировать пространством входных данных внутри сети. Такой модуль называется STN — Spatial Transformer Network, он является дифференцируемым и может быть интегрирован в любую существующую архитектуру сверточных нейронных сетей, давая им, таким образом, возможность активно трансформировать входные карты признаков, основываясь на самих признаках, без дополнительного обучения или модификации процесса обучения сети. STN позволяет модели сверточной нейронной сети вычислять точные характеристические вектора объектов независимо от их положения, масштаба, поворота или сжатия.

Модуль пространственного преобразования состоит из трех частей. Первая часть — сеть выделения (localisation network), она пропускает входные данные через несколько скрытых слоев и выдает параметры, определяющие пространственное преобразование, которое должно быть применено к карте признаков, что и дает преобразование на основе входных данных. Затем, во второй части, на основе полученных параметров создается решетка выборки, которая является набором точек, на основе которых из входной карты признаков должна получиться преобразованная карта признаков. Эта операция осуществляется за счет генератора решеток. На последнем, третьем этапе, карта признаков и решетка выборки поступает на вход выборщику в виде параметров, чтобы он произвел необходимые операции — заложенное в решётку преобразование.

В зависимости от преобразования заключенного в третьем этапе модуля пространственного изменения меняется его поведение. В данной работе

использовано два типа преобразователей на основе статьи [18]. Отличие заключается в глубине сетей локализации. Было использовано три слоя вместо двух, в предположении, что так получится выделить более точные параметры для преобразований. В ходе экспериментов было выяснено, что удаётся улучшить работу сети идентификации при помощи слоёв пространственного изменения, но что усложнение сетей не приводит к улучшению результата работы общей модели.

ЗАКЛЮЧЕНИЕ

В рамках научно-исследовательской работы было реализовано приложение с полным циклом распознавания человека по изображению его лица. В приложении реализован процесс обучения сетей для выполнения подобного распознавания. Было принято два варианта улучшения работы сетей для обнаружения и идентификации лиц. При проведении эксперимента выяснилось, что предложенным методом подготовки датасета для сети обнаружения, не удастся видимо улучшить работу этой сети. В ходе улучшения работы сети ResNet18 при помощи слоев пространственного изменения выяснилось, что можно улучшить распознающую способность сети ResNet18, но нельзя достигнуть на ней результатов идентичных более глубоким сетям.

Помимо этого, было выяснено, что для функции потерь ArcFace при обучении сети ResNet18 значения упомянутые в статье [9], о размере сферы и отступе не подходят, так как сеть быстро сходится — переобучается. Экспериментально было установлено, что размер сферы должен быть 34, а отступ 0.35.

Что касается общего процесса обучения сетей, было выяснено, что сети пространственного изменения должны иметь скорость обучения меньшую нежели основная сеть распознавания и, что при обучении сети с несколькими модулями пространственного изменения скорости обучения данных модулей также не должно совпадать.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- 1 SphereFace: Deep Hypersphere Embedding for Face Recognition [Электронный ресурс]. — URL: <https://arxiv.org/abs/1704.08063> (Дата обращения 10.09.2019). Загл. с экр. Яз. англ.
- 2 С. Николаенко,. Глубокое обучение. Погружение в мир нейронных сетей / С. Николаенко, А. Кадуриин, Е. Архангельская. — Питер, 2018.
- 3 Artificial Intelligence [Электронный ресурс]. — URL: <https://arxiv.org/list/cs.AI/recent> (Дата обращения 20.11.2019). Загл. с экр. Яз. англ.
- 4 Non-maximum Suppression (NMS) [Электронный ресурс]. — URL: <https://towardsdatascience.com/non-maximum-suppression-nms-93ce178e177c> (Дата обращения 27.11.2019). Загл. с экр. Яз. англ.
- 5 NumPy [Электронный ресурс]. — URL: <http://github.com/numpy/numpy> (Дата обращения 09.10.2019). Загл. с экр. Яз. англ.
- 6 A Discriminative Feature Learning Approach for Deep Face Recognition [Электронный ресурс]. — URL: <https://ydwen.github.io/papers/WenECCV16.pdf> (Дата обращения 22.09.2019). Загл. с экр. Яз. англ.
- 7 Large-Margin Softmax Loss for Convolutional Neural Networks [Электронный ресурс]. — URL: <https://arxiv.org/abs/1612.02295> (Дата обращения 11.09.2019). Загл. с экр. Яз. англ.
- 8 CosFace: Large Margin Cosine Loss for Deep Face Recognition [Электронный ресурс]. — URL: <https://arxiv.org/abs/1801.09414> (Дата обращения 15.09.2019). Загл. с экр. Яз. англ.
- 9 ArcFace: Additive Angular Margin Loss for Deep Face Recognition [Электронный ресурс]. — URL: <https://arxiv.org/abs/1801.07698> (Дата обращения 01.09.2019). Загл. с экр. Яз. англ.
- 10 TensorFlow [Электронный ресурс]. — URL: <https://github.com/tensorflow/tensorflow> (Дата обращения 09.08.2019). Загл. с экр. Яз. англ.
- 11 PyTorch [Электронный ресурс]. — URL: <https://pytorch.org/> (Дата обращения 17.09.2019). Загл. с экр. Яз. англ.

- 12 MxNet [Электронный ресурс]. — URL: <https://mxnet.apache.org/> (Дата обращения 17.10.2019). Загл. с экр. Яз. англ.
- 13 Multicolumn Networks for Face Recognition [Электронный ресурс]. — URL: <https://arxiv.org/pdf/1807.09192.pdf> (Дата обращения 15.10.2019). Загл. с экр. Яз. англ.
- 14 Principal Component Analysis [Электронный ресурс]. — URL: <https://setosa.io/ev/principal-component-analysis/> (Дата обращения 06.01.2020). Загл. с экр. Яз. англ.
- 15 Principal Components Analysis [Электронный ресурс]. — URL: <https://personal.utdallas.edu/~herve/abdi-awPCA2010.pdf> (Дата обращения 05.01.2020). Загл. с экр. Яз. англ.
- 16 Principal component analysis (PCA) [Электронный ресурс]. — URL: <https://scikit-learn.org/stable/modules/decomposition.html#pca> (Дата обращения 05.01.2020). Загл. с экр. Яз. англ.
- 17 Matplotlib [Электронный ресурс]. — URL: <https://github.com/matplotlib/matplotlib> (Дата обращения 09.10.2018). Загл. с экр. Яз. англ.
- 18 Deep Diffeomorphic Transformer Networks [Электронный ресурс]. — URL: http://www2.compute.dtu.dk/~sohau/papers/cvpr2018/detlefsen_cvpr_2018.pdf (Дата обращения 25.10.2019). Загл. с экр. Яз. англ.
- 19 *Уэсли Дж. Чан.*, Python создание приложений / Уэсли Дж. Чан. — Вильямс, 2015.
- 20 Transformations Based on Continuous Piecewise-Affine Velocity Fields [Электронный ресурс]. — URL: <https://backend.orbit.dtu.dk/ws/portalfiles/portal/139267800/07814343.pdf> (Дата обращения 20.03.2020). Загл. с экр. Яз. англ.
- 21 Spatial Transformer Networks [Электронный ресурс]. — URL: <https://arxiv.org/pdf/1506.02025.pdf> (Дата обращения 22.09.2019). Загл. с экр. Яз. англ.