

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение
высшего образования

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

Кафедра дискретной математики и информационных технологий

**АНАЛИЗ И ПРОГНОЗИРОВАНИЕ ВРЕМЕННЫХ РЯДОВ
МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ**

АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ

студента 2 курса 271 группы
направления 09.04.01 — Информатика и вычислительная техника
факультета КНиИТ
Гатилова Дмитрия Сергеевича

Научный руководитель
профессор, д.ф.-м.н.

В. А. Молчанов

Заведующий кафедрой
доцент, к. ф.-м. н.

Л. Б. Тяпаев

Саратов 2021

СОДЕРЖАНИЕ

ВВЕДЕНИЕ	3
1 Понятие временного ряда и его основные свойства	5
2 Задачи, связанные с временными рядами	6
2.1 Задача классификации	6
2.2 Задача прогнозирования	6
3 Обзор методов анализа временных рядов	7
3.1 Аддитивная модель	7
3.2 Методы, основанные на функции регрессии	7
3.3 Авторегрессия скользящего среднего	7
3.4 Сингулярный спектральный анализ	8
3.5 Вейвлет-анализ	9
4 Программная реализация анализа временных рядов	10
4.1 Метод ARIMA	10
4.1.1 Основная идея метода	10
4.1.2 Проверка стационарности временных рядов	10
4.1.3 Параметры модели ARIMA	11
5 Понятие нейронной сети	12
6 Основные виды нейронных сетей	13
6.1 Классификация по количеству слоёв	13
6.2 Классификация по направлению передачи сигналов между ней- ронами	13
6.3 Классификация по методу обучения нейронных сетей	13
7 Задачи, решаемые нейронными сетями	14
8 Виды обучения нейронных сетей	15
8.1 Обучение с учителем	15
8.2 Обучение без учителя	15
9 Рекуррентные нейронные сети	16
10 Программная реализация машинного обучения на языке Python	17
10.1 Прогнозирование одномерного временного ряда	17
10.2 Прогнозирование многомерного временного ряда	17
ЗАКЛЮЧЕНИЕ	18
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ	19

ВВЕДЕНИЕ

В настоящее время, в эпоху цифровых технологий, люди постоянно работают с данными, представленными в том или ином виде. Достаточно часто нам приходится иметь дело со значениями какой-либо величины, которая изменяется со временем. Речь может идти о различных показателях — экономических, технических, медицинских и многих других. По характеру их изменений можно судить о том, является ли функционирование той или иной системы нормальным, каких изменений стоит ожидать в ближайшем будущем и т.п. В математике подобный объект носит название временного ряда.

Задачи анализа и прогнозирования временных рядов являются одними из ключевых в науке анализа данных. Они позволяют добиться значительных успехов в рассмотрении поведения разнообразных систем и моделей, а с этим, в свою очередь, напрямую связано развитие технологий и совершенствование методов и практик в самых разных прикладных областях.

В связи с актуальностью направления, для работы выбрана тема «Анализ и прогнозирование временных рядов методами машинного обучения».

Целью данной работы является изучение временных рядов, основных понятий и задач, связанных с ними, а также программная реализация анализа и прогнозирования временных рядов. Были выделены следующие задачи:

- определить понятие и свойства временных рядов;
- изучить основные методы анализа временных рядов;
- практически реализовать метод ARIMA анализа временных рядов;
- изучить основные понятия, связанные с машинным обучением и нейронными сетями;
- практически реализовать прогнозирование временного ряда при помощи машинного обучения.

В разделе 1 "Понятие временного ряда и его основные свойства" приводится определение временного ряда, его основные виды, а также основные свойства временных рядов.

В разделе 2 "Задачи, связанные с временными рядами" описана две основные задачи, связанные с временными рядами – классификация и прогнозирование.

В разделе 3 "Обзор методов анализа временных рядов" приведён обзор

методов анализа временных рядов.

В разделе 4 "Программная реализация анализа временных рядов" приведено описание основной идеи метода ARIMA анализа временных рядов, а также его программная реализация. Помимо этого описана проверка временного ряда на стационарность и оценка параметров модели ARIMA.

В разделе 5 "Понятие нейронной сети" приведено определение нейронной сети, а также основных понятий, связанных с нейронными сетями.

В разделе 6 "Основные виды нейронных сетей" приведены различные классификации нейронных сетей, их виды.

В разделе 7 "Задачи, решаемые нейронными сетями" описано, в чём заключаются задачи, которые принято решать нейронными сетями.

В разделе 8 "Виды обучения нейронных сетей" приведена постановка задачи обучения нейронных сетей, а также основные виды обучения.

В разделе 9 "Рекуррентные нейронные сети" описано строение рекуррентных нейронных сетей, а также особенности их применения.

В разделе 10 "Программная реализация машинного обучения на языке Python" описана реализация моделей для прогнозирования временных рядов при помощи нейронных сетей с LSTM, приведены сравнения различных конфигураций моделей, а также способ ускорения обучения моделей.

1 Понятие временного ряда и его основные свойства

Временной ряд $\{x_i\}_{i=1}^n$ представляет собой набор измерений некоторой величины $x(t)$ в моменты времени $t_i = t_0 + (i-1)\tau$, где t_0 – начальный момент времени, τ – период [1].

Пример графика временного ряда представлен на рисунке 1.1.




Рисунок 1.1 – График временного ряда

Для временных рядов существуют различные классификации по отдельным критериям. В [2] приводится следующая классификация:

1. По времени.
2. По форме представления уровней.
3. По расстоянию между интервалами времени.
4. По содержанию показателей.

Для анализа временных рядов используется множество моделей. Самая простая модель – представление временного ряда в виде суммы:

$$x_t = m_t + s_t + y_t, \quad (1.1)$$

где m_t – тренд (системная составляющая); s_t – регулярные колебания относительно тренда (сезонная составляющая); y_t – шум, или некоторая случайная компонента [3].

2 Задачи, связанные с временными рядами

При рассмотрении временных рядов возникают два основных класса задач – классификация и прогнозирование.

2.1 Задача классификации

Задача классификации заключается в следующем: пусть имеется n классов временных рядов, и необходимо найти отображение $f : x_t \rightarrow \{s_1, \dots, s_n\}$, где x_t – произвольный временной ряд, s_i – один из n классов [4]. Процесс поиска отображения называется обучением. Обучение осуществляется по некоторой обучающей выборке, в которой известен точный ответ.

Результат обучения – некоторая функция, которая будет выполнять отображение. Основная задача – максимизировать качество классификации данной функции.

2.2 Задача прогнозирования

Задача прогнозирования заключается в том, чтобы по известным значениям временного ряда определить будущие значения. Для этого в методах и моделях анализа временных рядов используются различные формулы и оценки.

3 Обзор методов анализа временных рядов

В данном разделе будут рассмотрены основные методы анализа временных рядов.

3.1 Аддитивная модель

Модель, описанная в формуле 1.1, называется аддитивной. Если принять в ней $s_t = 0$, а m_t – достаточно медленно меняющаяся функция, то m_t удобно представить в виде полинома:

$$m_t = a_0 + a_1 t + \dots + a_n t^n \quad (3.1)$$

3.2 Методы, основанные на функции регрессии

Другая модель использует понятие функции регрессии. Функция регрессии – это математическое ожидание случайной величины x_t , которое рассматривается, как функция времени. В данном случае не производится разделения на детерминированные и случайные компоненты [3].

Для определения функции регрессии могут использоваться различные методы:

1. Рекуррентные (адаптивные) методы.
2. Метод максимального правдоподобия.
3. Аппроксимация функции регрессии сплайнами.

3.3 Авторегрессия скользящего среднего

Пусть имеется временной ряд x_n и шум – последовательность некоррелирующих и одинаково распределённых случайных величин ξ_i . Тогда временной ряд можно представить в следующем виде:

$$x_n = F(x_{n-1}, \dots, x_{n-m}, \xi_n, \dots, \xi_{n-k}), \quad (3.2)$$

где k и m – целые числа, задающие порядок модели.

Сами значения временного ряда будут принимать следующий вид:

$$x_i = a_0 + \sum_{i=1}^m (a_i x_{i-j}) + \sum_{j=0}^k (b_j \xi_{i-j}), \quad (3.3)$$

где a_i – авторегрессионные коэффициенты, b_j – коэффициенты скользящего

среднего.

Данная модель носит название авторегрессии скользящего среднего (или ARMA – Auto Regression Moving Average).

3.4 Сингулярный спектральный анализ

Сингулярный спектральный анализ (SSA, Singular Spectrum Analysis) – метод, позволяющий решать следующие задачи:

- сглаживать исходные данные на основе отобранных составляющих;
- выделять компоненту с известным периодом;
- различать составляющие временного ряда;
- предсказывать дальнейшие изменения значений временного ряда.

Основная идея метода заключается в следующем: исходный ряд преобразуется в матрицу развёртки. После этого осуществляется сингулярное преобразование полученной матрицы. На выходе на данном этапе получается набор главных компонент. Из этого набора выбираются те компоненты, которые будут использованы для восстановления ряда.

Пусть дана матрица M порядка $m \times n$, элементы которой либо из поля вещественных чисел, либо из поля комплексных чисел. Неотрицательное вещественное число σ – это сингулярное число матрицы M тогда и только тогда, когда существуют u и v – векторы длины 1 такие, что выполняются соотношения:

$$Mv = \sigma u, M^*u = \sigma v \quad (3.4)$$

Здесь M^* – сопряжённо-транспонированная матрица (т.е. полученная из исходной матрицы транспонированием и заменой каждого элемента комплексно - сопряжённым ему) к M , u называется левым сингулярным вектором, а v – правым сингулярным вектором.

По определению, сингулярным разложением вещественной (или комплексной) прямоугольной матрицы M порядка $m \times n$ является разложение вида:

$$M = U\Sigma V^*, \quad (3.5)$$

где U (порядка $m \times m$) и V (порядка $n \times n$) – унитарные матрицы, которые состоят, соответственно, из левых и правых сингулярных векторов, а Σ – матрица размерности $m \times n$, у которой на главной диагонали расположены сингулярные числа, а остальные – нулевые.

3.5 Вейвлет-анализ

В основе вейвлет-анализа лежит вейвлет-преобразование, являющееся аналогом преобразования Фурье.

Вейвлет-преобразование для функции $f(t) \in L^2(\mathbb{R})$ задаётся следующим образом:

$$W(a, b) = \frac{1}{|a|^{1/2}} \int_{-\infty}^{\infty} f(t) \psi^* \left(\frac{t - b}{a} \right), \quad (3.6)$$

где $a, b \in \mathbb{R}$, a – масштаб вейвлета, b – сдвиг вейвлета, ψ – некоторая функция, называемая вейвлет-базисом, $*$ обозначает операцию комплексного сопряжения.

Для описания локальных свойств временного ряда применяют совокупность вейвлетов, которые:

- обладают возможностью сдвига по времени;
- обладают возможностью масштабирования;
- имеют ограниченный частотный спектр.

4 Программная реализация анализа временных рядов

4.1 Метод ARIMA

4.1.1 Основная идея метода

В названии модели заключена её суть:

- Авторегрессия [9] (AR) – в рамках модели в рассматриваемом во временном ряде элементы последовательно зависят друг от друга.
- Интегрирование (I) – в модели используется ряд с разностью порядка d , чтобы рассматриваемый ряд был стационарным.
- Скользящее среднее (MA) – в рамках модели в рассматриваемом временном ряде наблюдение зависит от суммарного воздействия предыдущих ошибок.

Слабо стационарный временной ряд [10] – это временной ряд, математическое ожидание и дисперсия которого не зависят от времени, а также ковариация между его значениями в моменты времени t и $t + x$ зависят только от x , но не от времени.

4.1.2 Проверка стационарности временных рядов

Для определения стационарности временных рядов используются различные методы и тесты. Одним из таких тестов является тест Дики-Фуллера.

Понятие единичного корня определяется следующим образом: временной ряд имеет единичный корень (или порядок интеграции 1), если ряд первых разностей временного ряда $\Delta y_t = y_t - y_{t-1}$ является стационарным.

При помощи теста Дики-Фуллера [11] проверяют значение коэффициента a в уравнении авторегрессии первого порядка:

$$x_t = ax_{t-1} + \xi_t, \quad (4.1)$$

Если $a = 1$, то процесс имеет единичный корень, и ряд не является стационарным. В случае $|a| < 1$ ряд будет являться стационарным. Также теоретически может возникнуть ситуация, когда $|a| > 1$, но большинству процессов, временные ряды которых рассматриваются, такая ситуация не свойственна.

Проверяется нулевая гипотеза о равенстве нулю коэффициента $b = a - 1$ (a из формулы 4.1).

4.1.3 Параметры модели ARIMA

У модели ARIMA 3 параметра:

- p – порядок авторегрессионной компоненты.
- d – порядок разности (интегрированности) временного ряда для получения стационарного ряда.
- q – порядок компоненты скользящей средней.

Далее в разделе описан способ оценки данных параметров. Для этого написана программа на языке Python для построения вспомогательных графиков, которые нужны для оценки параметров, а также проведения теста Дики-Фуллера и построения модели ARIMA для временного ряда, представляющего собой данные с ценами на нефть. На выходе получили модель, способную делать прогноз будущих значений временного ряда на основе имеющихся данных.

5 Понятие нейронной сети

Нейронная сеть (или искусственная нейронная сеть, ИНС) – это математическая модель, построенная по образу и подобию системы нервных клеток живых организмов. Нейронная сеть представляет собой систему соединённых между собой синапсами нейронов.

Нейрон – это некая вычислительная единица, которая получает информацию, обрабатывает и передаёт её дальше [13]. Они делятся на 3 основных типа:

1. Входные нейроны.
2. Скрытые нейроны.
3. Выходные нейроны.

Нейроны в сети объединяются в слои. Чаще всего нейронные сети содержат один входной, один выходной и один или несколько скрытых слоёв.

Вес – это некоторое значение, которое может быть как положительным, так и отрицательным. Во многом задача построения нейронной сети заключается в определении значений весов синапсов.

Также важным понятием является функция активации. Функция активации определяет выходное значение нейрона в зависимости от взвешенной суммы входов.

Обучение нейронной сети – это определение такого набора весов, который бы позволил минимизировать разницу между ожидаемым и фактическим результатом обработки сигналов.

6 Основные виды нейронных сетей

6.1 Классификация по количеству слоёв

1. Однослойные нейронные сети.
2. Многослойные нейронные сети.

6.2 Классификация по направлению передачи сигналов между нейронами

1. Однонаправленные нейронные сети (или нейронные сети прямого пространства).
2. Рекуррентные нейронные сети (или нейронные сети с обратными связями).

6.3 Классификация по методу обучения нейронных сетей

1. Обучение с учителем.
2. Обучение без учителя.

7 Задачи, решаемые нейронными сетями

1. Прогнозирование (или регрессия). Задача состоит в прогнозировании значения некоторой целевой переменной по заданному набору признаков объекта.
2. Классификация. Задача состоит в сопоставлении набора признаков входного образа (например, звукового сигнала или изображения) одному или нескольким заранее определённым классам.
3. Кластеризация. Задача состоит в группировке объектов в кластеры на основе набора признаков, описывающих объекты. В отличие от классификации, где классы заранее определены, при кластеризации перечень кластеров чётко не задан.
4. Выявление аномалий. У данной задачи есть два основных направления [17] – детектирование выбросов и детектирование новизны.

8 Виды обучения нейронных сетей

В данном разделе более подробно рассмотрим виды обучения нейронных сетей.

В общем случае задача обучения выглядит следующим образом. Пусть X – множество объектов, Y – множество допустимых ответов, $y : X \rightarrow Y$ – некоторая неизвестная зависимость.

Дана обучающая выборка $x_1, \dots, x_n \subset X$, известные ответы $y_i = y(x_i)$, где $i = 1, \dots, n$.

Требуется найти алгоритм $a : X \rightarrow Y$, приближающий y на всём множестве X .

8.1 Обучение с учителем

В случае обучения с учителем для каждого объекта обучающей выборки известен ответ. Требуется найти алгоритм, который приближал бы неизвестную зависимость $X \rightarrow Y$ как на элементах обучающей выборки, так и на всём множестве X .

Нейронной сети на вход подаются элементы из обучающей выборки, вычисляются выходные сигналы. С известными ожидаемыми результатами вычисляется ошибка, и если ошибка признана значимой, то по какому-либо алгоритму происходит перерасчёт весов в нейронной сети, и процесс повторяется заново. В обратном случае нейронная сеть считается обученной, и процесс обучения считается пройденным.

Чаще всего обучение с учителем используется для решения таких задач, как классификация и регрессия.

8.2 Обучение без учителя

В случае обучения без учителя [18], в отличие от обучения с учителем, мы не даём алгоритмам понимание, является ли полученный ответ правильным. У алгоритмов должна быть некоторая оценка производимых действий в процессе решения задачи.

9 Рекуррентные нейронные сети

Схематично однослойная рекуррентная нейронная сеть представлена на рисунке 9.1:




Рисунок 9.1 – Однослойная рекуррентная нейронная сеть

На каждой итерации внутренний слой A нейронов получает на вход информацию о предыдущем своём состоянии и элементы входной последовательности. Таким образом реализуется память. Это принципиально меняет характер работы нейронной сети.

В основу многих современных реализаций таких сетей легла архитектура с долгой краткосрочной памятью (Long Short-Term Memory, или LSTM). LSTM позволяет решить проблему, когда после большого количества итераций информация перезаписывается.

На рисунке 9.2 представлена схема рекуррентной нейронной сети с LSTM-модулями:




Рисунок 9.2 – Рекуррентная нейронная сеть с LSTM

10 Программная реализация машинного обучения на языке Python

В данной работе было принято решение строить модели для погодных параметров. Во-первых, прогнозирование погоды – достаточно востребованная область применения машинного обучения, во-вторых – имеются достаточно объёмные и качественные наборы данных.

10.1 Прогнозирование одномерного временного ряда

В данном разделе была описана программная реализация машинного обучения на языке Python для одномерного временного ряда (с данными о температуре воздуха). Проводилась предварительная обработка данных, построение и обучение модели с LSTM, которая способна делать прогноз следующего значения временного ряда на основе 20 предыдущих. Модель строилась и обучалась с различными конфигурациями, и также было описано, как можно ускорить обучение модели с использованием сервиса Google Colaboratory.

10.2 Прогнозирование многомерного временного ряда

В данном разделе описана программная реализация модели, способной предсказывать значения многомерного временного ряда (временной ряд содержит данные сразу по 6 величинам – погодным параметрам). Она способна предсказывать значения на основе измерений за последние 5 дней (или 720 измерений). А значения, которые предсказывались, брались через 12 часов (или 72 измерения).

ЗАКЛЮЧЕНИЕ

В ходе выполнения данной работы были изучены временные ряды, рассмотрены основные методы их анализа, основные задачи, связанные с ними, проведена программная реализация метода анализа временных рядов ARIMA, а также машинного обучения для прогнозирования одномерного и многомерного временного ряда.

Важным преимуществом реализованного подхода для прогнозирования временных рядов является то, что можно его применять совершенно в разных областях, поскольку временные ряды встречаются повсеместно. Нужно подготовить данные для обучения, подобрать параметры для модели, обучить её, и тогда модель можно использовать. Если есть возможность – то можно значительно ускорить обучение моделей, если использовать GPU.

Задачи данной работы выполнены, цель достигнута.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- 1 Лоскутов, Ю. А. Анализ временных рядов. Курс лекций [Электронный ресурс] // URL: https://chaos.phys.msu.ru/loskutov/PDF/Lectures_time_series_analysis (Дата обращения: 06.12.2019). Загл. с экрана. Яз. рус.
- 2 Афанасьев, В.Н. Анализ временных рядов и прогнозирование: учебник / В.Н. Афанасьев, М.М. Юзбашев. М.: Финансы и статистика, 2001. 228 с.
- 3 Медведев, Г.А. Практикум на ЭВМ по анализу временных рядов: учеб. пособие. / Г.А. Медведев, В.А. Морозов. Минск, 2001. 192 с.
- 4 Статистический анализ временных рядов [Электронный ресурс] // URL: <http://iee.tpu.ru/system/time.html> (Дата обращения: 06.12.2019). Загл. с экрана. Яз. рус.
- 5 Ахметханов, Р.С. Анализ временных рядов в диагностике технических систем / Р.С. Ахметханов, Е.Ф. Дубинин, В.И. Куксова. Машиностроение и инженерное образование 2013 №2. С. 11-20.
- 6 Жиглявский, А.А. Главные компоненты временных рядов: метод «Гусеница» / СПб.: Пресском, 1997. 307 с.
- 7 Верзунов, С.Н. Вейвлет-преобразование как инструмент анализа магнито- вариационных данных / Проблемы автоматки и управления. Бишкек: Илим, 2014. 52-61 с.
- 8 Верзунов, С.Н. Разработка программных средств вейвлет-анализа временных рядов / Проблемы автоматки и управления. Бишкек: Илим, 2014. С. 62-71.
- 9 Авторегрессионное скользящее среднее [Электронный ресурс] // URL: <http://www.machinelearning.ru/wiki/index.php?title=ARMA> (Дата обращения: 20.05.2020). Загл. с экрана. Яз. рус.
- 10 Догерти, К. Введение в эконометрику: учебник / К. Догерти. М.: ИНФРА-М, 2009. 465 с.
- 11 Тест Дики Фуллера [Электронный ресурс] // URL: <http://poivs.tsput.ru/ru/Math/ProbabilityAndStatistics/MathStatistics/>

- TimeSeriesAnalysis/DickeyFullerTest (Дата обращения: 20.05.2020). Загл. с экрана. Яз. рус.
- 12 Brent Oil Prices [Электронный ресурс] // URL: <https://www.kaggle.com/mabusalah/brent-oil-prices> (Дата обращения: 20.05.2020). Загл. с экрана. Яз. англ.
 - 13 Нейронные сети для начинающих. Часть 1 [Электронный ресурс] // URL: <https://habr.com/ru/post/312450/> (Дата обращения: 18.12.2020). Загл. с экрана. Яз. рус.
 - 14 Типы нейронных сетей. Принцип их работы и сфера применения [Электронный ресурс] // URL: <https://otus.ru/nest/post/1263/> (Дата обращения: 18.12.2020). Загл. с экрана. Яз. рус.
 - 15 Введение в машинное обучение [Электронный ресурс] // URL: <https://habr.com/ru/post/427867/> (Дата обращения: 18.12.2020). Загл. с экрана. Яз. рус.
 - 16 Искусственные нейронные сети (ИНС) [Электронный ресурс] // URL: <https://www.it.ua/ru/knowledge-base/technology-innovation/iskusstvennye-nejronnye-seti-ins> (Дата обращения: 18.12.2020). Загл. с экрана. Яз. рус.
 - 17 Поиск аномалий (Anomaly Detection) [Электронный ресурс] // URL: <https://dyakonov.org/2017/04/19/поиск-аномалий-anomaly-detection/> (Дата обращения: 18.12.2020). Загл. с экрана. Яз. рус.
 - 18 Нейросеть – обучение без учителя. Метод Policy Gradient [Электронный ресурс] // URL: <https://habr.com/ru/post/506384/> (Дата обращения: 18.12.2020). Загл. с экрана. Яз. рус.
 - 19 Основы теории нейронных сетей. Алгоритмы обучения [Электронный ресурс] // URL: <https://intuit.ru/studies/courses/88/88/lecture/20555?page=1> (Дата обращения: 18.12.2020). Загл. с экрана. Яз. рус.
 - 20 Азбука ИИ: Рекуррентные нейросети [Электронный ресурс] // URL: <https://nplus1.ru/material/2016/11/04/recurrent-networks> (Дата обращения: 18.12.2020). Загл. с экрана. Яз. рус.

- 21 Орельен, Жерон. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем. Пер. с англ. СПб.: ООО "Альфа-книга", 2018. 688 с.
- 22 Функции активации нейросети: сигмоида, линейная, ступенчатая, ReLu, tanh [Электронный ресурс] // URL: <https://neurohive.io/ru/osnovy-data-science/activation-functions/> (Дата обращения: 18.12.2020). Загл. с экрана. Яз. рус.
- 23 All symbols in TensorFlow 2 [Электронный ресурс] // URL: https://www.tensorflow.org/api_docs/python/tf/all_symbols (Дата обращения: 18.03.2021). Загл. с экрана. Яз. англ.
- 24 Добро пожаловать в Colaboratory [Электронный ресурс] // URL: <https://colab.research.google.com/notebooks/intro.ipynb> (Дата обращения: 20.05.2021). Загл. с экрана. Яз. рус.