

Федеральное государственное автономное образовательное учреждение  
высшего образования  
«Московский физико-технический институт (национальный исследовательский  
университет)»

**Анализ двигательной активности человека на основе данных с  
мобильных устройств**  
(Бакалаврская работа)

**Студент:**

Юсупов Игорь Рафаэлевич



---

*(подпись студента)*

**Научный руководитель:**

Нейчев Радослав Георгиев



---

*(подпись научного руководителя)*

Москва 2020

# Содержание

<b>1. Аннотация</b>	<b>3</b>
<b>2. Введение</b>	<b>4</b>
<b>3. Постановка задачи</b>	<b>6</b>
3.1. Постановка задачи классификации . . . . .	6
3.2. Постановка задачи прогнозирования . . . . .	6
<b>4. Теоретическая часть</b>	<b>8</b>
4.1. Локально-аппроксимирующие модели . . . . .	8
4.1.1. Векторная авторегрессия (VAR) . . . . .	8
4.1.2. Анализ сингулярного спектра (SSA). . . . .	8
4.2. Построение признакового пространства . . . . .	11
<b>5. Вычислительный эксперимент</b>	<b>12</b>
5.1. Описание данных. . . . .	12
5.2. Классификация без преобразования признакового пространства	12
5.3. Классификация на параметрах модели VAR . . . . .	14
5.4. Классификация на параметрах модели SSA . . . . .	15
<b>6. Заключение</b>	<b>18</b>

## 1. Аннотация

Данная работа посвящена анализу временных рядов с целью распознавания физических действий человека с помощью акселерометра. Предлагается построение признаковых пространств с помощью методов локальной аппроксимации временных рядов и демонстрируется работа известных алгоритмов классификации на признаковых пространствах. Качество классификации временных рядов сравнивается с результатом моделей, получивших широкое применение в подобных задачах.

**Ключевые слова:** *временные ряды; многомерные временные ряды; классификация; построение признакового пространства; авторегрессия; сверточные нейронные сети*

## 2. Введение

В течение последних двух десятилетий классификация временных рядов рассматривалась как одна из наиболее сложных задач в области интеллектуального анализа данных [13]. Современное состояние акселерометров беспроводных устройств позволяет быстро получить большие объемы данных, описывающие физическую активность человека, поэтому с 2015 года были предложены сотни алгоритмов классификации временных рядов [1]. Временные ряды присутствуют почти в каждой задаче, в которой требуются когнитивные процессы человека. Фактически любая задача классификации, в которой данные имеют некоторый порядок, может рассматриваться как задача классификации временных рядов [5]. Выделяют несколько методов решения задачи классификации временных рядов, такие как: нейронные сети [6], композиции различных классификаторов, метод ближайших соседей и т.п.

В данной работе рассматривается задача классификации многомерных временных рядов, в этих терминах временной ряд является объектом сложной структуры. При их классификации значимую роль играет модель признакового пространства. Построение признакового пространства, позволяющего добиться заданной точности классификации и значительно упрощающего последующий анализ, является важным этапом решения задачи классификации.

В общем случае задача классификации объектов сложной структуры делится на два этапа. На первом этапе формируется признаковое пространство, на втором этапе решается задача классификации на построенном признаковом пространстве.

Для построения признакового описания используют статистические функции [11], коэффициенты дискретного преобразования Фурье [10], параметры моделей авторегрессии [7]. В данной работе объектом анализа и классификации являются параметры локально-аппроксимирующих моделей, обученных на временных рядах.

Для практической проверки предлагаемого метода в рамках вычислитель-

ного эксперимента решается задача классификации физической активности человека на собранных данных с мобильных устройств и открытом датасете HAR. Эксперимент состоит из двух частей: в первой части осуществляется построение признакового пространства с помощью локально-аппроксимирующих моделей, во второй части решается задача классификации, результат которой сравнивается с результатом моделей, получивших широкое применение в подобных задачах.

### 3. Постановка задачи

#### 3.1. Постановка задачи классификации

Пусть  $X$  – множество описаний объектов,  $Y$  – множество меток классов,  $|Y| \geq 2$ .

**Определение 1.** Алгоритм классификации  $a : X \rightarrow Y$  – функция, преобразующая описание объекта  $x \in X$  в соответствующую ему метку класса  $y \in Y$ .

**Определение 2.** Ошибкой  $D = (x_i, y_i)_{i=1}^m$  алгоритма  $a$  на конечной выборке будем считать

$$S = \frac{1}{k} \sum_{i=1}^{|D|} |a(x_i) \neq y_i|$$

Требуется построить алгоритм  $a : X \rightarrow Y$ , способный произвольному объекту  $x \in X$  сопоставить метку класса  $y \in Y$  и минимизирующий функцию ошибки  $S$ .

#### 3.2. Постановка задачи прогнозирования

**Определение 3.** Моделью локальной аппроксимации  $g$  называется модель, аппроксимирующая временной ряд  $x(t)$  в промежутке времени  $[t, t + T]$ .

$$g : [t, t + T] \rightarrow \hat{x}$$

Метод локальной аппроксимации заключается в решении задачи оптимизации, описанной ниже.

Дан многомерный временной ряд, то есть собранный в разные моменты времени статистический материал о значении каких-либо параметров.

$$x = [x^{(1)}, x^{(2)}, \dots, x^{(t)}]$$

где  $x^{(i)}$  – вектор значений в момент времени  $i$ .

Обозначим  $X, Y$ :

$$X = [x^{(1)}, x^{(2)}, \dots, x^{(k)}], \quad Y = [x^{(k+1)}, x^{(k+2)}, \dots, x^{(t)}]$$

Будем называть матрицу  $X$  матрицей плана, а матрицу  $Y$  – матрицей прогнозируемых значений. В классе линейных моделей задача может быть решена с помощью линейной регрессии:

$$Y = XW + \epsilon$$

$W$  – матрица весов модели,  $\epsilon$  – случайная переменная, соответствующая случайной, непрогнозируемой ошибке модели.

Для нахождения оптимального вектора весов используем метод наименьших квадратов. Задача оптимизации ставится следующим образом:

$$W_* = \arg \min_W \|XW - Y\|^2$$

**Теорема (Гаусса – Маркова).** Для модели со следующими ограничениями:

- матожидание случайных ошибок равно нулю:  $\forall i : \mathbb{E}[\epsilon_i] = 0$
- дисперсия случайных ошибок одинакова и конечна:  
 $\forall i : \text{Var}(\epsilon_i) = \sigma^2 < \infty$
- случайные ошибки не скоррелированы:  $\forall i \neq j : \text{Cov}(\epsilon_i, \epsilon_j) = 0$

оценка весов  $W_* = (X^T X)^{-1} X^T Y$  минимизирует среднеквадратичную ошибку.

## 4. Теоретическая часть

### 4.1. Локально-аппроксимирующие модели

#### 4.1.1. Векторная авторегрессия (VAR)

Векторная авторегрессия (VAR) – это модель динамики нескольких временных рядов, в которой текущие значения этих рядов зависят от прошлых значений этих же рядов. Формально векторная авторегрессия это система уравнений, каждое из которых представляет из себя модель авторегрессии. Пусть  $x^i$  –  $i$ -й временной ряд, тогда VAR описывается формулой:

$$x_t^i = w_0^i + \sum_{j=1}^k w_{1j}^i x_{t-1}^j + \sum_{j=1}^k w_{2j}^i x_{t-2}^j + \dots + \sum_{j=1}^k w_{pj}^i x_{t-p}^j + \varepsilon_t^i$$

Или же для вектора временных рядов  $x_t = (x_t^1, \dots, x_t^k)$  уравнения можно записать одним в векторной форме

$$x_t = W_0 + W_1 x_{t-1} + W_2 x_{t-2} + \dots + W_p x_{t-p} + \varepsilon_t = W_0 + \sum_{m=1}^p W_m x_{t-m} + \varepsilon_t$$

#### 4.1.2. Анализ сингулярного спектра (SSA).

Анализ сингулярного спектра – метод анализа временных рядов, основанный на преобразовании одномерного временного ряда в многомерный ряд с последующим применением к полученному многомерному временному ряду метода главных компонент [3].

Рассмотрим временной ряд  $x = [x_{(0)}, x_{(1)}, \dots, x_{(N-1)}]$  длины  $N$ . На первом шаге метода выбирается длина окна  $L$  ( $2 \leq L \leq N/2$ ) и строится  $L \times K$ , где  $K = N - L + 1$ , траекторная матрица ряда  $\mathbf{X}$  следующим образом:

$$\mathbf{X} = \begin{bmatrix} x_0 & x_1 & x_2 & \dots & x_{K-1} \\ x_1 & x_2 & x_3 & \dots & x_K \\ x_2 & x_3 & x_4 & \dots & x_{K+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{L-1} & x_L & x_{L+1} & \dots & x_{N-1} \end{bmatrix}$$

**Определение 4.** Матрица является ганкелевой, если на всех антидиагоналях стоят равные элементы.



Матрица  $X$  является ганкелевой матрицей.

На следующем шаге метода производится сингулярное разложение траекторной матрицы  $\mathbf{X}$ :

$$\mathbf{X} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T$$

где

- $\mathbf{U}$  – ортогональная матрица размера  $L \times L$ , состоящая из левых сингулярных векторов матрицы  $\mathbf{X}$
- $\mathbf{\Sigma}$  – прямоугольная диагональная матрица размера  $L \times K$ , состоящая из сингулярных чисел, отвечающих за величины различных частот спектра временного ряда  $x$ , матрицы  $\mathbf{X}$
- $\mathbf{V}$  – ортогональная матрица размера  $K \times K$ , состоящая из правых сингулярных векторов матрицы  $\mathbf{X}$

В данной работе для временного ряда  $x$  рассматривается вектор сингулярных чисел его траекторной матрицы  $\mathbf{X}$  в качестве нового признакового пространства.

Сингулярное разложение можно записать в следующем виде:

$$\mathbf{X} = \sum_{i=0}^{d-1} \sigma_i U_i V_i^T \equiv \sum_{i=0}^{d-1} \mathbf{X}_i$$

где  $\sigma_i$  –  $i$ -ое сингулярное число,  $U_i, V_i$  – столбцы матриц  $\mathbf{U}$  и  $\mathbf{V}$  соответственно,  $\mathbf{X}_i$  –  $i$ -ая элементарная матрица траекторной матрицы  $\mathbf{X}$ ,  $d$  – ранг траекторной матрицы  $\mathbf{X}$ .

Если каждая элементарная матрица является ганкелевой, то из нее можно восстановить временной ряд, то есть таким образом представить исходный временной ряд в виде суммы элементарных временных рядов. Но в элементарных матрицах не всегда все элементы на антидиагоналях равны, поэтому необходим метод, с помощью которого можно элементарные матрицы преобразовать в ганкелевы матрицы.

Для восстановления элементарного ряда из элементарной матрицы мы используем усреднение по антидиагонали, то есть в качестве значений вос-

становленного временного ряда будет братья среднее антидиагонали элементарной матрицы. Формально это можно записать с помощью введения оператора  $\hat{\mathcal{H}}$ , который действует на  $L \times K$  матрицу  $\mathbf{X}_j$  и в результате выдает ганкелеву матрицу  $\tilde{\mathbf{X}}^{(j)}$ :

$$\tilde{\mathbf{X}}^{(j)} = \hat{\mathcal{H}}\mathbf{X}^{(j)}$$

Элемент  $\tilde{x}_{(m,n)}$  ганкелевой матрицы  $\tilde{\mathbf{X}}^{(j)}$  вычисляется следующим образом:

$$\tilde{x}_{m,n} = \begin{cases} \frac{1}{s+1} \sum_{l=0}^s x_{l,s-l} & 0 \leq s \leq L-1 \\ \frac{1}{L-1} \sum_{l=0}^{L-1} x_{l,s-l} & L \leq s \leq K-1 \\ \frac{1}{K+L-s-1} \sum_{l=s-K+1}^L x_{l,s-l} & K \leq s \leq K+L-2 \end{cases}$$

где  $s = m + n$

Иногда при таком разделении временного ряда некоторые из элементарных временных рядов почти ничем друг от друга не отличаются и их нужно объединить в один временной ряд. Пусть  $\tilde{F}_j$  – элементарный временной ряд, полученный из элементарной матрицы  $\mathbf{X}_j$ . Введем взвешенное умножение для элементарных временных рядов следующим образом:

$$\left( \tilde{F}_i, \tilde{F}_j \right)_w = \sum_{k=0}^{N-1} w_k \tilde{f}_{i,k} \tilde{f}_{j,k}$$

где  $\tilde{f}_{i,k}$  и  $\tilde{f}_{j,k}$  –  $k$ -ые значения  $\tilde{F}_i$  и  $\tilde{F}_j$  соответственно, а  $w_k$  вычисляется следующим образом:

$$w_k = \begin{cases} k+1 & 0 \leq k \leq L-1 \\ L & L \leq k \leq K-1 \\ N-k & K \leq k \leq N-1 \end{cases}$$

Вес  $w_k$  отражает, какое количество раз  $\tilde{f}_{i,k}$  и  $\tilde{f}_{j,k}$  встретилось в матрицах ганкеля  $\tilde{\mathbf{X}}^{(i)}$  и  $\tilde{\mathbf{X}}^{(j)}$ .

Введем меру сходства для элементарных временных рядов  $\tilde{F}_i$  и  $\tilde{F}_j$ :

$$W_{i,j} = \frac{\left( \tilde{F}_i, \tilde{F}_j \right)_w}{\left\| \tilde{F}_i \right\|_w \left\| \tilde{F}_j \right\|_w}$$

где  $\|\tilde{F}_k\|_w = \sqrt{(\tilde{F}_k, \tilde{F}_k)_w}$ . Чем больше похожи временные ряды  $\tilde{F}_i$  и  $\tilde{F}_j$ , тем ближе  $W_{i,j}$  к 1.

В данной работе для временного ряда  $x$  в качестве нового признакового пространства рассматриваются также его элементарные ряды. Значение меры сходства, при котором временные ряды складываются в один, является гиперпараметром.

## 4.2. Построение признакового пространства

Для построения нового признакового пространства мы будем использовать локально-аппроксимирующие модели. Для каждого временного ряда будем обучать локально-аппроксимирующую модель и в качестве новых описаний объектов будем использовать параметры моделей.

## 5. Вычислительный эксперимент

### 5.1. Описание данных.

Датасет HAR содержит данные с акселерометра для 6 видов деятельности человека: WALKING, WALKING UP, WALKING DOWN, SITTING, STANDING, LAYING. Датасет содержит 7352 объекта для обучения и 2947 объектов для теста, данные представляют собой многомерные ряды размером  $(128, 9)$ , то есть каждый многомерный ряд представляет собой 9 одномерных рядов длиной 128.




Рис. 1: График зависимости первой и второй главных компонент

### 5.2. Классификация без преобразования признакового пространства

**Выбор признаков.** В эксперименте в качестве описаний объектов использовались непосредственно сами временные ряды, но с изменением размера в  $(32, 36)$ .

**Классификатор.** В качестве алгоритма для решения задачи многоклассовой классификации использовалась сверточная нейронная сеть, архитектура которой изображена ниже.




Рис. 2: Архитектура нейронной сети

**Результаты.**

class	precision	recall	f1-score
0	0.99	0.94	0.96
1	0.98	0.94	0.96
2	0.89	1.00	0.94
3	0.85	0.77	0.81
4	0.82	0.87	0.84
5	0.99	0.99	0.99
<b>accuracy</b>			0.92
<b>macro avg</b>	0.92	0.92	0.92
<b>weighted avg</b>	0.92	0.92	0.92

Таблица 1: Результат классификации сверточной нейронной сети, архитектура которой изображена на рис. 2

- **accuracy** – доля правильных ответов алгоритма.
- **macro avg** – невзвешенное среднее метрик.
- **weighted avg** – взвешенное среднее метрик (веса берутся согласно количеству элементов для каждой метки).

### 5.3. Классификация на параметрах модели VAR

**Выбор признаков.** Для генерации нового признакового пространства использовалась векторная авторегрессия (VAR).

**Классификаторы.** В этот раз в качестве алгоритмов многоклассовой классификации использовались: полносвязная нейронная сеть с 6 полносвязными слоями в каждой 64 нейрона, функцией активации ReLu и регуляризацией dropout; Gradient Boosting [4]; SVM [12]; Random Forest [8]; Adaptive Boosting [9]; Hist Gradient Boosting [2].

**Результаты.**

class	precision	recall	f1-score	class	precision	recall	f1-score
0	0.82	0.68	0.74	0	0.62	0.65	0.63
1	0.57	0.93	0.71	1	0.56	0.55	0.55
2	0.84	0.72	0.77	2	0.74	0.71	0.72
3	0.75	0.66	0.70	3	0.71	0.40	0.51
4	0.78	0.70	0.73	4	0.55	0.80	0.65
5	0.88	0.83	0.86	5	0.95	0.90	0.92
<b>accuracy</b>			0.75	<b>accuracy</b>			0.67
<b>macro avg</b>			0.77	<b>macro avg</b>			0.69
<b>weighted avg</b>			0.77	<b>weighted avg</b>			0.67

Результат классификации Gradient Boosting

Результат классификации FNN

class	precision	recall	f1-score	class	precision	recall	f1-score
0	0.77	0.67	0.71	0	0.55	0.43	0.48
1	0.64	0.78	0.70	1	0.60	0.37	0.46
2	0.76	0.72	0.74	2	0.71	0.56	0.63
3	0.70	0.64	0.67	3	0.12	0.00	0.00
4	0.71	0.74	0.73	4	0.32	0.16	0.21
5	0.82	0.82	0.82	5	0.31	0.96	0.47
<b>accuracy</b>			0.73	<b>accuracy</b>			0.41
<b>macro avg</b>			0.73	<b>macro avg</b>			0.44
<b>weighted avg</b>			0.73	<b>weighted avg</b>			0.43

Результат классификации Random Forest

Результат классификации SVM

class	precision	recall	f1-score	class	precision	recall	f1-score
0	0.83	0.61	0.70	0	0.76	0.63	0.69
1	0.60	0.94	0.74	1	0.57	0.87	0.69
2	0.82	0.72	0.77	2	0.78	0.70	0.74
3	0.74	0.73	0.73	3	0.55	0.59	0.57
4	0.81	0.73	0.77	4	0.67	0.58	0.62
5	0.89	0.86	0.87	5	0.77	0.64	0.70
<b>accuracy</b>			0.76	<b>accuracy</b>			0.67
<b>macro avg</b>	0.78	0.76	0.76	<b>macro avg</b>	0.68	0.67	0.67
<b>weighted avg</b>	0.79	0.76	0.77	<b>weighted avg</b>	0.68	0.67	0.67

Результат классификации Hist Gradient  
Boosting

Результат классификации  
Adaptive Boosting

## 5.4. Классификация на параметрах модели SSA

**Выбор признаков.** В качестве признакового пространства рассматривались сингулярные числа траекторной матрицы временного ряда.

**Классификаторы.** Для многоклассовой классификации использовались алгоритмы из предыдущего эксперимента.

**Результаты.**

class	precision	recall	f1-score	class	precision	recall	f1-score
0	0.35	0.73	0.47	0	0.85	0.82	0.83
1	0.73	0.79	0.76	1	0.76	0.90	0.83
2	0.62	0.80	0.70	2	0.73	0.64	0.68
3	0.38	0.27	0.32	3	0.68	0.61	0.64
4	0.23	0.05	0.08	4	0.60	0.81	0.69
5	0.86	0.61	0.71	5	0.89	0.65	0.75
<b>accuracy</b>			0.53	<b>accuracy</b>			0.74
<b>macro avg</b>	0.53	0.54	0.51	<b>macro avg</b>	0.75	0.74	0.74
<b>weighted avg</b>	0.52	0.53	0.50	<b>weighted avg</b>	0.75	0.74	0.74

Результат классификации Gradient Boosting

Результат классификации FNN

class	precision	recall	f1-score	class	precision	recall	f1-score
0	0.94	0.59	0.73	0	0.28	0.81	0.42
1	0.76	0.76	0.76	1	0.46	0.86	0.60
2	0.55	0.81	0.65	2	0.74	0.76	0.75
3	0.52	0.34	0.42	3	0.15	0.05	0.08
4	0.43	0.02	0.04	4	0.00	0.00	0.00
5	0.37	0.84	0.52	5	0.83	0.01	0.02
<b>accuracy</b>			0.55	<b>accuracy</b>			0.39
<b>macro avg</b>			0.60	<b>macro avg</b>			0.41
<b>weighted avg</b>			0.59	<b>weighted avg</b>			0.39

Результат классификации Random Forest

Результат классификации SVM

class	precision	recall	f1-score	class	precision	recall	f1-score
0	0.87	0.46	0.61	0	0.36	1.00	0.53
1	0.37	0.89	0.52	1	0.53	0.07	0.12
2	0.45	0.60	0.51	2	0.00	0.00	0.00
3	0.72	0.35	0.47	3	0.32	0.99	0.49
4	0.57	0.79	0.66	4	0.56	0.02	0.03
5	0.90	0.02	0.03	5	0.35	0.01	0.02
<b>accuracy</b>			0.51	<b>accuracy</b>			0.35
<b>macro avg</b>			0.65	<b>macro avg</b>			0.36
<b>weighted avg</b>			0.66	<b>weighted avg</b>			0.37

Результат классификации Hist Gradient  
Boosting

Результат классификации  
Adaptive Boosting

Также в качестве признакового пространства использовались элементарные ряды, качество классификации оказалось выше.

**Результаты.**



class	precision	recall	f1-score	class	precision	recall	f1-score
0	0.71	0.74	0.73	0	0.89	0.85	0.87
1	0.68	0.69	0.68	1	0.84	0.86	0.85
2	0.74	0.80	0.77	2	0.84	0.88	0.86
3	0.85	0.76	0.80	3	0.79	0.80	0.80
4	0.81	0.81	0.81	4	0.85	0.78	0.81
5	1.00	0.99	1.00	5	0.96	1.00	0.98
<b>accuracy</b>			0.80	<b>accuracy</b>			0.86
<b>macro avg</b>	0.80	0.80	0.80	<b>macro avg</b>	0.86	0.86	0.86
<b>weighted avg</b>	0.80	0.80	0.80	<b>weighted avg</b>	0.86	0.86	0.86

Результат классификации Gradient Boosting

Результат классификации FNN

class	precision	recall	f1-score	class	precision	recall	f1-score
0	0.59	0.78	0.67	0	0.61	0.72	0.66
1	0.73	0.61	0.66	1	0.80	0.67	0.73
2	0.68	0.62	0.65	2	0.59	0.87	0.70
3	0.78	0.75	0.77	3	0.88	0.68	0.77
4	0.78	0.74	0.76	4	0.84	0.69	0.76
5	1.00	1.00	1.00	5	1.00	0.96	0.98
<b>accuracy</b>			0.76	<b>accuracy</b>			0.77
<b>macro avg</b>	0.76	0.75	0.75	<b>macro avg</b>	0.79	0.77	0.77
<b>weighted avg</b>	0.77	0.76	0.76	<b>weighted avg</b>	0.79	0.77	0.77

Результат классификации Random Forest

Результат классификации SVM

class	precision	recall	f1-score	class	precision	recall	f1-score
0	0.70	0.78	0.74	0	0.17	0.03	0.06
1	0.76	0.75	0.75	1	0.40	0.01	0.02
2	0.72	0.85	0.78	2	0.37	0.04	0.07
3	0.87	0.73	0.80	3	0.81	0.55	0.66
4	0.82	0.76	0.79	4	0.26	0.95	0.41
5	1.00	0.99	1.00	5	1.00	0.89	0.94
<b>accuracy</b>			0.81	<b>accuracy</b>			0.44
<b>macro avg</b>	0.81	0.81	0.81	<b>macro avg</b>	0.50	0.41	0.36
<b>weighted avg</b>	0.82	0.81	0.81	<b>weighted avg</b>	0.51	0.44	0.38

Результат классификации Hist Gradient  
Boosting

Результат классификации  
Adaptive Boosting

	FNN	Gradient Boosting	SVM	Random Forest	Adaptive Boosting	Hist Gradient Boosting
веса VAR	0.67	0.75	0.41	0.73	0.67	0.76
сингулярные числа SSA	0.74	0.53	0.39	0.55	0.35	0.51
элементарные ряды SSA	0.86	0.80	0.77	0.76	0.44	0.81

Таблица 2: Точность классификаторов на признаковых пространствах

## 6. Заключение

В данной работе рассматривалась задача построения признакового пространства с помощью моделей локальной аппроксимации для устойчивой классификации сигналов носимых устройств. Были предложены методы построения признаковых пространств и продемонстрирована работа известных алгоритмов классификации.

В ходе эксперимента было продемонстрировано, что качество классификации более простых алгоритмов классификации на предлагаемых признаковых пространствах сравнимо с качеством классификации моделей, получивших широкое применение в подобных задачах.

Также был проведен эксперимент, в ходе которого была построена нейросеть с тремя входами, один из которых принимал временные ряды, а остальные – предложенные признаковые пространства. Качество оказалось выше, чем у сверточной сети, которая принимала на вход только временные ряды. С помощью эксперимента показано, что предлагаемые признаковые пространства повышают устойчивость классификации.

class	precision	recall	f1-score
0	0.94	0.95	0.95
1	0.98	0.90	0.94
2	0.89	0.99	0.94
3	0.89	0.83	0.86
4	0.87	0.89	0.88
5	1.00	1.00	1.00
<b>accuracy</b>			0.93
<b>macro avg</b>	0.93	0.93	0.93
<b>weighted avg</b>	0.93	0.93	0.93

Таблица 3: Результат классификации нейронной сети с тремя входами

## Список литературы

- [1] Anthony Bagnall и др. «The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances». в: *Data Mining and Knowledge Discovery* 31.3 (2017), с. 606—660.
- [2] Anna Veronika Dorogush, Vasily Ershov и Andrey Gulin. «CatBoost: gradient boosting with categorical features support». в: *arXiv preprint arXiv:1810.11363* (2018).
- [3] James B Elsner и Anastasios A Tsonis. *Singular spectrum analysis: a new tool in time series analysis*. Springer Science & Business Media, 2013.
- [4] Jerome H Friedman. «Stochastic gradient boosting». в: *Computational statistics & data analysis* 38.4 (2002), с. 367—378.
- [5] John Cristian Borges Gamboa. «Deep learning for time-series analysis». в: *arXiv preprint arXiv:1701.01887* (2017).
- [6] Nima Hatami, Yann Gavet и Johan Debayle. *Classification of Time-Series Images Using Deep Convolutional Neural Networks*. 2017. arXiv: 1710.00886 [cs.CV].
- [7] B Venkataramana Kini и C Chandra Sekhar. «Large margin mixture of AR models for time series classification». в: *Applied Soft Computing* 13.1 (2013), с. 361—371.
- [8] Andy Liaw, Matthew Wiener и др. «Classification and regression by randomForest». в: *R news* 2.3 (2002), с. 18—22.
- [9] Dragos D Margineantu и Thomas G Dietterich. «Pruning adaptive boosting». в: *ICML*. т. 97. Citeseer. 1997, с. 211—218.
- [10] Fabian Mörchen. *Time series feature extraction for data mining using DWT and DFT*. 2003.
- [11] Alex Nanopoulos, Rob Alcock и Yannis Manolopoulos. «Feature-based classification of time-series data». в: *International Journal of Computer Research* 10.3 (2001), с. 49—61.
- [12] Johan AK Suykens и Joos Vandewalle. «Least squares support vector machine classifiers». в: *Neural processing letters* 9.3 (1999), с. 293—300.
- [13] Qiang Yang и Xindong Wu. «10 challenging problems in data mining research». в: *International Journal of Information Technology & Decision Making* 5.04 (2006), с. 597—604.