

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РОССИЙСКОЙ ФЕДЕРАЦИИ
МОСКОВСКИЙ ФИЗИКО-ТЕХНИЧЕСКИЙ ИНСТИТУТ (государственный университет)
ФАКУЛЬТЕТ УПРАВЛЕНИЯ И ПРИКЛАДНОЙ МАТЕМАТИКИ
КАФЕДРА «ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ»

Исаченко Роман Владимирович

**Метрическое обучение в задачах мультиклассовой
классификации временных рядов**

010990 — Интеллектуальный анализ данных

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА БАКАЛАВРА

Научный руководитель:

д. ф.-м. н. Стрижов Вадим Викторович

Москва

2016

Содержание

1	Введение	4
2	Постановка задачи	7
2.1	Выравнивание временных рядов	7
2.2	Метрическое обучение	9
2.3	Классификация временных рядов	10
3	Вычислительный эксперимент	11
3.1	Синтетические данные	11
3.2	Реальные данные	12
4	Заключение	16

Аннотация

Работа посвящена построению модели многоклассовой классификации временных рядов. Предлагается выравнить временные ряды относительно центроидов классов. Процедура нахождения центроидов и выравнивания временных рядов осуществляется с помощью алгоритма динамической трансформации времени. Для повышения качества классификации в данной работе используются методы метрического обучения. Метрическое обучение позволяет модифицировать расстояния между временными рядами, сближая временные ряды из одного класса и отдаляя временные ряды из разных классов. Расстояние между временными рядами измеряется с помощью метрики Махаланобиса. Процедура метрического обучения состоит в определении оптимальной матрицы трансформаций в метрике Махаланобиса. Для анализа качества построенного алгоритма произведён вычислительный эксперимент на синтетических и реальных данных показаний с акселерометра мобильного телефона.

Ключевые слова: *классификация временных рядов; выравнивание; метрическое обучение; алгоритм LMNN.*

1 Введение

Актуальность темы. В работе решается задача мультиклассовой классификации временных рядов [2, 3]. В статье [1] рассматриваются 3 подхода к классификации временных рядов. Первый подход подразумевает использование «сырых» временных рядов для обучения алгоритма классификации. При этом вся информация содержится в метрической конфигурации данных. Вторым подходом предполагается наличие этапа выделения признаков-характеристик множества временных рядов. Исходные данные преобразуются в вектора признаков, находящихся в пространстве существенно меньшей размерности. После этого классификатор строится на новых преобразованных данных. Третий подход основан на идее классификации временных рядов по полученным параметрам модели. В данной работе предлагается использование первого подхода.

Для решения задачи классификации временных рядов ранее использовались метод опорных векторов [4, 5], нейронные сети [6], байесовский подход [7]. Классификация временных рядов по сырым данным в первую очередь зависит от введённой меры расстояния между объектами. В работе используется идея ближайших соседей [8].

Цель работы. Целью работы является построение простого, точного, устойчивого алгоритма классификации временных рядов. В данной работе вычислительный эксперимент проводится на синтетических данных временных рядов, представляющих аналитические функции, и реальных данных показаний акселерометра мобильного телефона. Цель эксперимента — определение вида активности человека по форме сигнала акселерометра. Получена оценка качества работы построенного алгоритма и произведён анализ его свойств.

Методы исследования. Для улучшения качества классификации предлагается использовать методы метрического обучения [9–11]. Метрическое обучение позволяет модифицировать расстояния между временными рядами с помощью линейного преобразования признаков пространства объектов. В результате преобразования вре-

менные ряды одного класса оказываются ближе друг к другу по отношению к выбранной метрике, а временные ряды, принадлежащие разным классам, отдаляются друг от друга. Методы метрического обучения применяются при ранжировании поисковой выдачи [12], идентификации лиц [13], распознавании рукописных цифр [14]. В данной работе в качестве алгоритма метрического обучения был выбран алгоритм $LMNN$ (Large Margin Nearest Neighbor) [15]. Данный алгоритм основан на идеях метода k ближайших соседей. Алгоритм для каждого объекта минимизирует расстояния до k ближайших соседей, принадлежащих тому же классу и штрафует объекты из других классов, попавшие на расстояние порядка расстояния до k -ого ближайшего соседа.

Алгоритм $LMNN$ позволяет произвести отбор признаков. С помощью линейного преобразования алгоритм помещает объекты в новое пространство. Если размерность нового пространства меньше размерности исходного пространства, то происходит снижение размерности признакового пространства, т. е. отбор признаков.

Для вычисления расстояний между временными рядами в данной работе производится их выравнивание относительно центроидов классов. Выравнивание производится методом динамической трансформации времени DTW (Dynamic Time Warping) [16]. Задача поиска оптимального центроида класса решается с помощью метода выравненного взвешенного усреднения DBA (DTW Barycenter Averaging) [17]. Классификация, основанная на идее ближайших соседей чувствительна к изменению масштабов признаков. Для повышения устойчивости классификации выравненные временные ряды были отнормированы.

Тем самым полученная модель классификации представляет собой суперпозицию алгоритмов: построение центроидов, выравнивания временных рядов относительно центроидов классов, метрического обучения, классификации.

Основные положения, выносимые на защиту.

- Алгоритм многоклассовой классификации временных рядов.
- Решение прикладной задачи распознавания типа активности по сигналу акселе-

рометра мобильного телефона.

- Экспериментальное исследование разработанного алгоритма.

Степень достоверности и апробация работы. Достоверность результатов подтверждена математическими доказательствами, экспериментальной проверкой полученных методов на реальных задачах классификации временных рядов, публикациями результатов исследования в рецензируемых научных изданиях [18, 19] и выступлением на конференции Ломоносова 2016.

2 Постановка задачи

Пусть объект $\mathbf{x}_i \in \mathbb{R}^n$ — временной ряд, последовательность измерений некоторой исследуемой величины в различные моменты времени. Пусть \mathbf{X} — множество всех временных рядов фиксированной длины n , $Y = \{1, \dots, K\}$ — множество меток классов. Пусть задана выборка $\mathfrak{D} = \{(\mathbf{x}_i, y_i)\}_{i=1}^\ell$ — множество объектов с известными метками классов $y_i \in Y$.

Требуется построить точную, простую, устойчивую модель классификации

$$a : \mathbf{X} \rightarrow Y.$$

Данную модель представим в виде суперпозиции

$$a(\mathbf{x}) = b \circ \mathbf{f} \circ G(\mathbf{x}, \{\mathbf{c}_e\}_{e=1}^K), \quad (1)$$

где G — процедура выравнивания временных рядов относительно центроидов классов $\{\mathbf{c}_e\}_{e=1}^K$, \mathbf{f} — алгоритм метрического обучения, b — алгоритм многоклассовой классификации.

2.1 Выравнивание временных рядов

Для повышения качества и устойчивости алгоритма классификации предлагается провести выравнивание временных рядов каждого класса относительно центроида.

Пусть \mathbf{X}_e — множество объектов обучающей выборки \mathfrak{D} , принадлежащих одному классу $e \in \{1, \dots, K\}$. Центроидом множества объектов $\mathbf{X}_e = \{\mathbf{x}_i | y_i = e\}_{i=1}^\ell$ по расстоянию ρ назовем вектор $\mathbf{c}_e \in \mathbb{R}^n$ такой, что

$$\mathbf{c}_e = \operatorname{argmin}_{\mathbf{c} \in \mathbb{R}^n} \sum_{\mathbf{x}_i \in \mathbf{X}_e} \rho(\mathbf{x}_i, \mathbf{c}). \quad (2)$$

Для нахождения центроида предлагается в качестве расстояния между временными рядами использовать путь наименьшей стоимости [20], найденный методом динамической трансформации времени. Псевдокод решения оптимизационной задачи (2) приведен в алгоритме 1.

Алгоритм 1 Нахождение центроида DBA(\mathbf{X}_e, n_iter)

Вход: \mathbf{X}_e — множество временных рядов, принадлежащих одному и тому же классу,
 n_iter — количество итераций алгоритма.

Выход: \mathbf{c} — центроид множества \mathbf{X}_e .

- 1: задать начальное приближение приближение центроида \mathbf{c} ;
- 2: **для** $i = 1, \dots, n_iter$
- 3: **для** $\mathbf{x} \in \mathbf{X}_e$
- 4: вычислить выравнивающий путь между \mathbf{c} и \mathbf{x}
 $\text{alignment}(\mathbf{x}) := \text{DTWalignment}(\mathbf{c}, \mathbf{x})$;
- 5: объединить поэлементно множества индексов для каждого отсчета времени
 $\text{alignment} := \bigcup_{\mathbf{x} \in \mathbf{X}_e} \text{alignment}(\mathbf{x})$;
- 6: $\mathbf{c} = \text{mean}(\text{alignment})$

ПРОЦЕДУРА DTWalignment(\mathbf{c}, \mathbf{x})

Вход: \mathbf{c}, \mathbf{x} — временные ряды.

Выход: alignment — выравнивающий путь. // каждый индекс временного ряда \mathbf{x}
поставлен в однозначное соответствие индексу временного ряда \mathbf{c}

- 1: построить $n \times n$ -матрицу деформаций DTW
 $\text{cost} := \text{DTW}(\mathbf{c}, \mathbf{x})$;
 - 2: вычислить выравнивающий путь по матрице деформаций
 $\text{alignment} := \text{DTWpath}(\text{cost})$;
-

Общая процедура выравнивания имеет следующий вид:

- 1) построить множество центроидов классов $\{\mathbf{c}_e\}_{e=1}^K$;
- 2) по множеству центроидов найти пути наименьшей стоимости между каждым временным рядом \mathbf{x}_i и центроидом его класса \mathbf{c}_{y_i} ;
- 3) по каждому пути восстановить выравненный временной ряд;
- 4) привести множества выравненных временных рядов к нулевому среднему и нор-

мировать на дисперсию.

Результатом выравнивания должно стать множество выровненных временных рядов.

2.2 Метрическое обучение

Введем на множестве выровненных временных рядов расстояние Махаланобиса

$$d_{\mathbf{A}}(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{(\mathbf{x}_i - \mathbf{x}_j)^{\top} \mathbf{A} (\mathbf{x}_i - \mathbf{x}_j)},$$

где матрица трансформаций $\mathbf{A} \in \mathbb{R}^{n \times n}$ является симметричной и неотрицательно определенной ($\mathbf{A}^{\top} = \mathbf{A}$, $\mathbf{A} \succeq 0$). Представим матрицу \mathbf{A} в виде разложения $\mathbf{A} = \mathbf{L}^{\top} \mathbf{L}$. Матрица $\mathbf{L} \in \mathbb{R}^{p \times n}$ — матрица линейного преобразования, где p задает размерность преобразованного пространства. Если параметр $p < n$, то происходит снижение размерности признакового пространства.

Расстояние $d_{\mathbf{A}}(\mathbf{x}_i, \mathbf{x}_j)$ есть евклидово расстояние между $\mathbf{L}\mathbf{x}_i$ и $\mathbf{L}\mathbf{x}_j$:

$$d_{\mathbf{A}}(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{(\mathbf{x}_i - \mathbf{x}_j)^{\top} \mathbf{L}^{\top} \mathbf{L} (\mathbf{x}_i - \mathbf{x}_j)} = \sqrt{(\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j))^{\top} (\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j))} = \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j)\|_2.$$

В качестве алгоритма метрического обучения в данной работе был выбран алгоритм LMNN. Данный алгоритм сочетает в себе идеи метода k ближайших соседей. Первая идея заключается в минимизации расстояний между k ближайшими объектами, находящимися в одном классе. Запишем функционал качества в виде

$$Q_1(\mathbf{L}) = \sum_{j \rightsquigarrow i} \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j)\|^2 \rightarrow \min_{\mathbf{L}},$$

где $j \rightsquigarrow i$ означает, что \mathbf{x}_j является одним из k ближайших соседей для \mathbf{x}_i . Вторая идея состоит в максимизации расстояния между каждым объектом и его объектами-нарушителями. Объектом-нарушителем для \mathbf{x}_i назовем объект \mathbf{x}_l такой, что

$$\|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_l)\|^2 \leq \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j)\|^2 + 1, \quad \text{где } j \rightsquigarrow i. \quad (3)$$

Таким образом, необходимо минимизировать следующий функционал:

$$Q_2(\mathbf{L}) = \sum_{j \rightsquigarrow i} \sum_l (1 - y_{il}) [1 + \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j)\|^2 - \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_l)\|^2]_+ \rightarrow \min_{\mathbf{L}},$$

где $y_{il} = 1$, если $y_i = y_l$, и $y_{il} = 0$ в противном случае. Положительная срезка позволяет штрафовать только те объекты, которые удовлетворяют условию (3).

Задача метрического обучения состоит в нахождении линейного преобразования $\mathbf{f}(\mathbf{x}) = \mathbf{L}\mathbf{x}$, то есть нахождении матрицы \mathbf{L} в виде решения оптимизационной задачи

$$Q(\mathbf{L}) = \mu Q_1(\mathbf{L}) + (1 - \mu) Q_2(\mathbf{L}) \rightarrow \min_{\mathbf{L}}, \quad (4)$$

где $\mu \in (0, 1)$ — весовой параметр, определяющий вклад каждого из функционалов. Задача (4) представляет собой задачу полуопределенного программирования [21] и может быть решена существующими оптимизационными пакетами.

2.3 Классификация временных рядов

Пусть $\mathbf{x} \in \mathbf{X}$ — неразмеченный временной ряд. Выравниваем временной ряд \mathbf{x} относительно всех центроидов классов

$$\hat{\mathbf{x}}_e = G(\mathbf{x}, \mathbf{c}_e), \quad \text{где } e = \{1, \dots, K\}.$$

Отнесем временной ряд к классу, для которого минимально расстояние до соответствующего центроида. В качестве расстояния используем обученную метрику Махаланобиса с фиксированной матрицей \mathbf{A}

$$\hat{y} = \operatorname{argmin}_{e \in \{1, \dots, K\}} d_{\mathbf{A}}(\hat{\mathbf{x}}_e, \mathbf{c}_e).$$

После нахождения оптимальных центроидов классов и нахождения оптимальной матрицы трансформаций процедура классификации заключается в измерении расстояния между найденными центроидами и новыми неразмеченными объектами.

Для оценки качества работы алгоритма будем вычислять ошибку классификации как долю неправильно классифицированных объектов тестовой выборки \mathcal{U} :

$$\text{error} = \frac{1}{|\mathcal{U}|} \sum_{i=1}^{|\mathcal{U}|} [a(\mathbf{x}_i) \neq y_i].$$

3 Вычислительный эксперимент

3.1 Синтетические данные

Цель вычислительного эксперимента — проверить работоспособность предложенного подхода. Предполагается, что построенный алгоритм мультиклассовой классификации способен определить тип активности человека по форме сигнала акселерометра мобильного телефона.

Для проведения базового вычислительного эксперимента были подготовлены синтетические временные ряды, принадлежащие двум классам [22]. Первый класс — синусы вида $\sin(x + b)$, где параметр b определяет сдвиг каждого временного ряда. Второй класс — пилообразные функции с различными сдвигами по временной шкале. На каждый временной ряд был наложен нормальный шум. Число временных рядов каждого класса = 60. Длина каждого временного ряда $n = 50$.

Построенные центроиды классов проиллюстрированы на рис. 1. Из рисунка видно, что процедура корректно определяет сдвиги временных рядов.

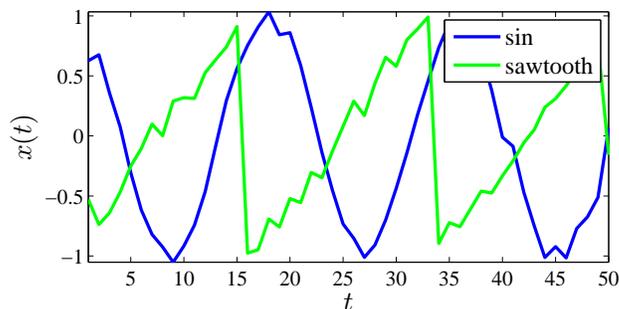


Рис. 1: Центроиды синтетических временных рядов

Для того чтобы убедиться в целесообразности применения метрического обучения, данные временные ряды классифицировались в пространстве с евклидовой метрикой и в пространстве с метрикой Махаланобиса. Число ближайших соседей $k = 5$, размерность преобразованного пространства $p = 40$. Полученные ошибки классификации составили:

евклидова метрика — 27%

метрика Махаланобиса — 6%.

3.2 Реальные данные

Реальные данные [23] представляли собой временные ряды акселерометра мобильного телефона. Каждый из шести классов соответствовал определенной физической активности испытуемых. Для проведения вычислительного эксперимента было выбрано по 200 объектов каждого класса. Длина каждого временного ряда равнялась $n = 128$ отсчетам времени.

Построенные центроиды классов изображены на рис. 2. Найденные центроиды обладают периодичностью, свойственной временным рядам показаний активности человека. На рис. 3 показаны примеры временных рядов каждого класса. Эти же вре-

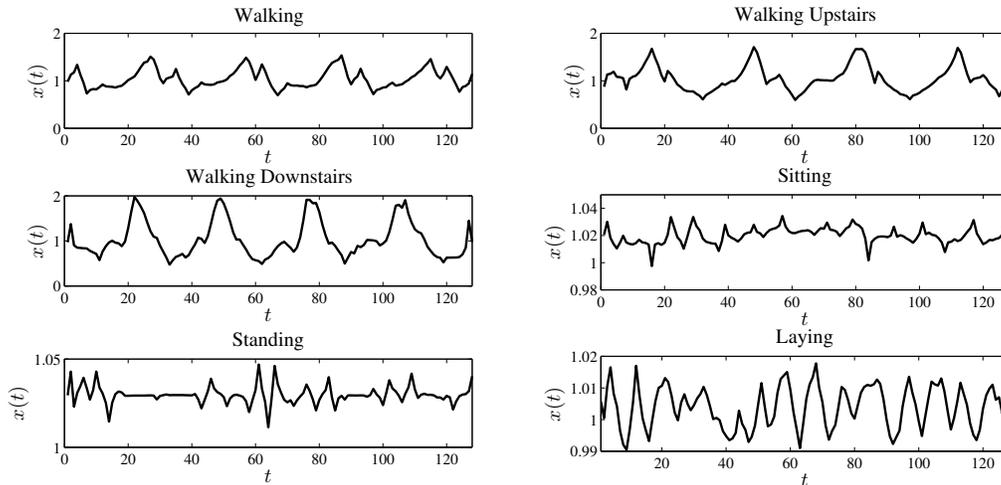


Рис. 2: Центроиды временных рядов акселерометра

менные ряды после процедуры выравнивания относительно построенных центроидов изображены на рис. 4.

Ошибка классификации без использования метрического обучения составила 37,5%. Алгоритм LMNN позволяет настроить параметры: число ближайших соседей k , раз-

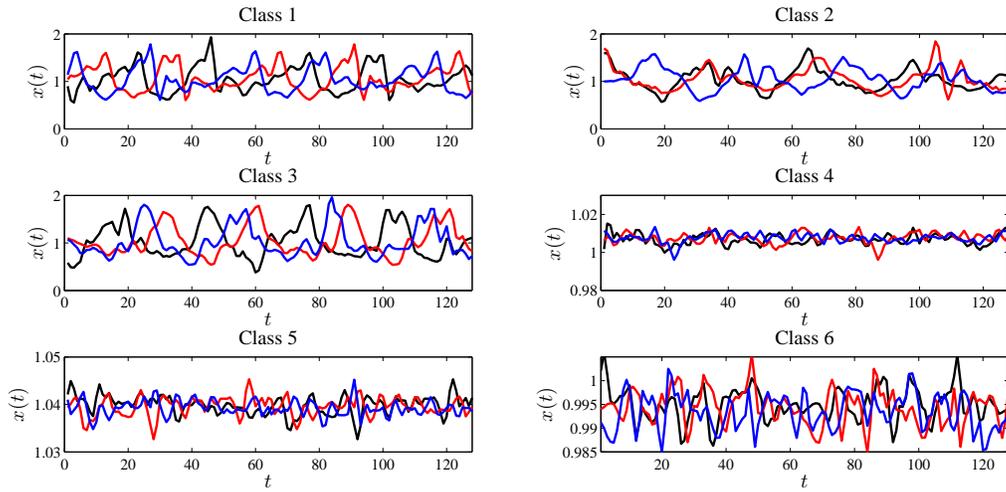


Рис. 3: Временные ряды акселерометра

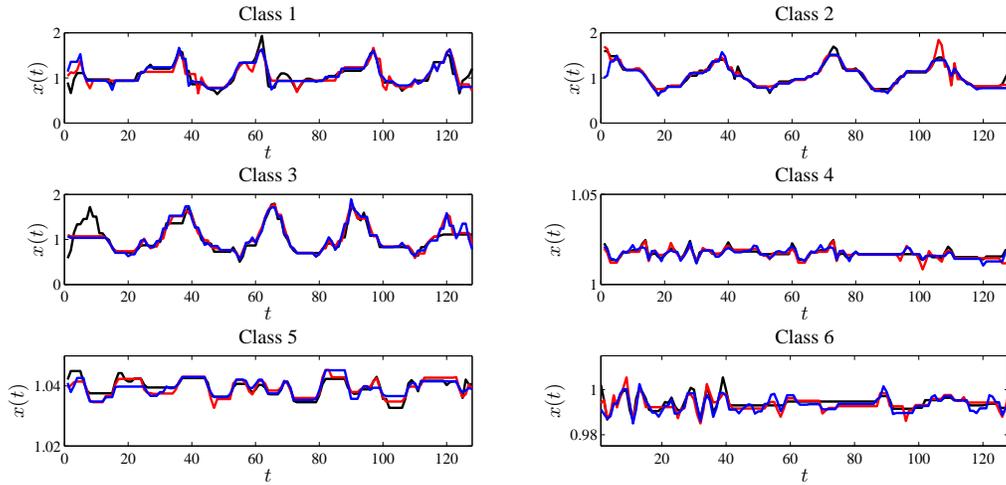


Рис. 4: Выравненные временные ряды акселерометра

мерность преобразованного евклидова пространства p . Для выбора оптимальных параметров воспользуемся процедурой кросс-проверки. На рис. 5 цветом показана ошибка классификации алгоритма в зависимости от его параметров. На данной выборке алгоритм LMNN оказывается слабо чувствителен к числу ближайших соседей, и при уменьшении размерности пространства объектов ошибка классификации растет.

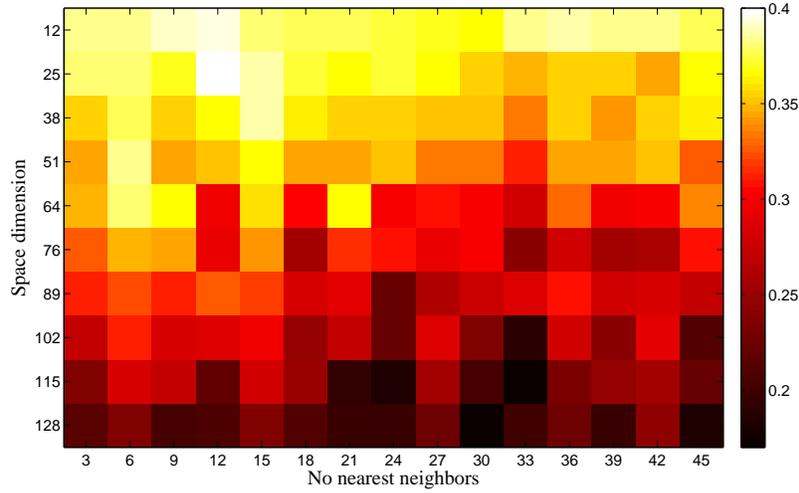


Рис. 5: Ошибка классификации в зависимости от параметров

Настроим алгоритм LMNN со следующими параметрами: число ближайших соседей $k = 30$, размерность выходного пространства $p = 128$. Ошибка классификации составила 17,25%, что вдвое меньше ошибки классификации с использованием евклидовой метрики.

Таблица 1: Матрицы несоответствий

(a) Евклидова метрика

	Истинные метки классов					
	1	2	3	4	5	6
1	80	0	5	0	0	0
2	4	56	33	0	0	0
3	5	5	86	0	0	0
4	7	8	5	168	4	21
5	51	61	57	12	192	11
6	53	70	14	20	2	168

(b) Метрика Махаланобиса

	Истинные метки классов					
	1	2	3	4	5	6
1	151	12	13	0	0	0
2	10	142	14	0	0	0
3	9	10	171	0	0	0
4	10	7	0	173	9	21
5	2	11	0	12	186	9
6	18	18	2	15	5	170

В табл. 1 представлены матрицы несоответствий результатов классификации при

использовании евклидовой метрики и метрики Махаланобиса. Столбцы соответствуют истинным меткам классов объектов, строки — предсказанным меткам. Диагональное преобладание матрицы несоответствий указывает на высокую предсказательную способность алгоритма.

В табл. 2 продемонстрировано увеличение точности классификации при использовании в качестве меры расстояния метрики Махаланобиса. Пересечение i -го столбца и j -й строки отвечает изменению доли объектов класса i , отнесенных к классу j . Положительное суммарное значение диагональных элементов таблицы соответствует увеличению качества классификации. Значительное улучшение предсказания происходит при классификации первых трех классов. Данные классы соответствуют следующим видам физической активности: ходьба, ходьба вверх, ходьба вниз.

Таблица 2: Увеличение точности классификации при использовании адекватной оценки матрицы трансформаций

	Истинные метки классов					
	1	2	3	4	5	6
1	0,355	0,06	0,04	0	0	0
2	0,03	0,43	-0,095	0	0	0
3	0,02	0,025	0,425	0	0	0
4	0,015	-0,005	-0,025	0,025	0,025	0
5	-0,245	-0,25	-0,28	0	-0,03	-0,01
6	-0,175	-0,26	-0,06	-0,025	0,005	-0,01

4 Заключение

В данной работе предложен новый подход к задаче многоклассовой классификации временных рядов. Сравнивались результаты классификации множества временных рядов, основанных на измерении расстояний с помощью евклидовой метрики и обученной метрики Махаланобиса. Проведён вычислительный эксперимент на реальных данных показаний акселерометра мобильного телефона. Построенная модель классификации показала высокое качество распознавания активности человека по форме сигнала акселерометра.

Список литературы

- [1] Warren T. Liao Clustering of time series data — a survey. *Pattern Recognition*, 38(11):1857–1874, 2005
- [2] Попова М. С., Стрижов В. В.. Выбор оптимальной модели классификации физической активности по измерениям акселерометра. *Информатика и её приложения*, 9(1):79–89, 2015.
- [3] Ignatov A. D. and Strijov V. V.. Human activity recognition using quasiperiodic time series collected from a single tri-axial accelerometer. *Multimedia Tools and Applications*, pages 1–14, 2015.
- [4] Inan Güler and Elif Derya Ü Beyli. Multiclass support vector machines for eeg-signals classification. *Information Technology in Biomedicine, IEEE Transactions on*, 11(2):117–126, 2007.
- [5] Elif Derya Übeyli. Ecg beats classification using multiclass support vector machines with error correcting output codes. *Digital Signal Processing*, 17(3):675–684, 2007.
- [6] Rangachari Anand, Kishan Mehrotra, Chilukuri K Mohan, and Sanjay Ranka. Efficient classification for multiclass problems using modular neural networks. *Neural Networks, IEEE Transactions on*, 6(1):117–124, 1995.
- [7] Mehran Kafai and Bir Bhanu. Dynamic bayesian networks for vehicle classification in video. *Industrial Informatics, IEEE Transactions on*, 8(1):100–109, 2012.
- [8] Wanpracha Art Chaovalitwongse, Ya-Ju Fan, and Rajesh C Sachdeo. On the time series k-nearest neighbor classification of abnormal brain activity. *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on*, 37(6):1005–1016, 2007.
- [9] Aurélien Bellet, Amaury Habrard, and Marc Sebban. A survey on metric learning for feature vectors and structured data. *arXiv preprint arXiv:1306.6709*, 2013.

- [10] Liu Yang and Rong Jin. Distance metric learning: A comprehensive survey. *Michigan State University*, 2, 2006.
- [11] Fei Wang and Jimeng Sun. Survey on distance metric learning and dimensionality reduction in data mining. *Data Mining and Knowledge Discovery*, 29(2):534–564, 2015.
- [12] Brian McFee and Gert R Lanckriet. Metric learning to rank. In *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, pages 775–782, 2010.
- [13] Matthieu Guillaumin, Jakob Verbeek, and Cordelia Schmid. Is that you? metric learning approaches for face identification. In *Computer Vision, 2009 IEEE 12th international conference on*, pages 498–505. IEEE, 2009.
- [14] Kilian Q Weinberger and Lawrence K Saul. Fast solvers and efficient implementations for distance metric learning. In *Proceedings of the 25th international conference on Machine learning*, pages 1160–1167. ACM, 2008.
- [15] Kilian Q Weinberger, John Blitzer, and Lawrence K Saul. Distance metric learning for large margin nearest neighbor classification. In *Advances in neural information processing systems*, pages 1473–1480, 2005.
- [16] Donald J Berndt and James Clifford. Using dynamic time warping to find patterns in time series. In *KDD workshop*, volume 10, pages 359–370. Seattle, WA, 1994.
- [17] François Petitjean, Alain Ketterlin, and Pierre Gançarski. A global averaging method for dynamic time warping, with applications to clustering. *Pattern Recognition*, 44(3):678–693, 2011.
- [18] Исаченко Р.В., Катруца А.М. Метрическое обучение и снижение размерности пространства в задачах кластеризации. *Journal of Machine Learning and Data Analysis*, 2(1):17–25, 2015.

- [19] Исаченко Р. В., Стрижов В. В. Метрическое обучение в задачах мультиклассовой классификации временных рядов. *Информатика и её применения*, 10(2), 2016.
- [20] Гончаров А. В., Попова М. С., Стрижов В. В. Метрическая классификация временных рядов с выравниванием относительно центроидов классов. *Системы и средства информатики*, 25(4):52–64, 2015.
- [21] Lieven Vandenberghe and Stephen Boyd. Semidefinite programming. *SIAM review*, 38(1):49–95, 1996.
- [22] Project Code. Available at: <https://sourceforge.net/p/mlalgorithms/code/HEAD/tree/Group274/Isachenko2015TimeSeries/code/>.
- [23] UCI repository: Human Activity Recognition Using Smartphones Dataset. Available at: <https://archive.ics.uci.edu/ml/datasets/Human+Activity+Recognition+Using+Smartphones>.