



<http://dx.doi.org/10.35596/1729-7648-2024-22-3-93-100>

Оригинальная статья
Original paper

УДК 004.934.2+534.784

МЕТОД РАСПОЗНАВАНИЯ ЭМОЦИЙ В РЕЧЕВОМ СИГНАЛЕ С ИСПОЛЬЗОВАНИЕМ МАШИНЫ ОПОРНЫХ ВЕКТОРОВ И НАДСЕГМЕНТНЫХ АКУСТИЧЕСКИХ ПРИЗНАКОВ

Д. В. КРАСНОПРОШИН, М. И. ВАШКЕВИЧ

*Белорусский государственный университет информатики и радиоэлектроники
(г. Минск, Республика Беларусь)*

Поступила в редакцию 19.12.2023

© Белорусский государственный университет информатики и радиоэлектроники, 2024
Belarusian State University of Informatics and Radioelectronics, 2024

Аннотация. Исследована задача распознавания эмоций в речевом сигнале с использованием мел-частотных кепстральных коэффициентов при помощи классификатора на основе метода опорных векторов. При проведении экспериментов применялся набор данных RAVDESS. Предложена модель, которая использует 306-компонентный вектор надсегментных признаков в качестве входных данных для классификатора на основе метода опорных векторов. Оценка качества модели проводилась с помощью невзвешенного среднего значения полноты (UAR). Рассмотрено применение в классификаторе на основе метода опорных векторов в качестве ядра линейной, полиномиальной и радиальной базисной функций. Исследовано использование разных размеров фрейма анализа сигнала (от 23 до 341 мс) на этапе извлечения мел-частотных кепстральных коэффициентов. Результаты исследований выявили значительную точность полученной модели (UAR = 48 %). Предлагаемый подход демонстрирует потенциал для таких приложений, как голосовые помощники, виртуальные агенты и диагностика психического здоровья.

Ключевые слова: голосовой сигнал, мел-частотные кепстральные коэффициенты, извлечение аудиопризнаков, распознавание, машинное обучение.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Для цитирования. Краснопрошин, Д. В. Метод распознавания эмоций в речевом сигнале с использованием машины опорных векторов и надсегментных акустических признаков / Д. В. Краснопрошин, М. И. Вашкевич // Доклады БГУИР. 2024. Т. 22, № 3. С. 93–100. <http://dx.doi.org/10.35596/1729-7648-2024-22-3-93-100>.

SPEECH EMOTION RECOGNITION METHOD BASED ON SUPPORT VECTOR MACHINE AND SUPRASEGMENTAL ACOUSTIC FEATURES

DANIIL V. KRASNOPROSHIN, MAXIM I. VASHKEVICH

Belarusian State University of Informatics and Radioelectronics (Minsk, Republic of Belarus)

Submitted 19.12.2023

Abstract. The problem of recognizing emotions in a speech signal using mel-frequency cepstral coefficients using a classifier based on the support vector machine has been studied. The RAVDESS data set was used in the experiments. A model is proposed that uses a 306-component suprasegmental feature vector as input to a support vector machine classifier. Model quality was assessed using unweighted average recall (UAR). The use of linear, polynomial and radial basis functions as a kernel in a classifier based on the support vector machine is considered. The use of different signal analysis frame sizes (from 23 to 341 ms) at the stage of extracting mel-frequency cepstral coefficients was investigated. The research results revealed significant accuracy of the resulting mo-

del (UAR = 48 %). The proposed approach shows potential for applications such as voice assistants, virtual agents, and mental health diagnostics.

Keywords: voice signal, mel-frequency cepstral coefficients, audio feature extraction, recognition, machine learning.

Conflict of interests. The authors declare no conflict of interests.

For citation. Krasnoproshin D. V., Vashkevich M. I. (2024) Speech Emotion Recognition Method Based on Support Vector Machine and Suprasegmental Acoustic Features. *Doklady BGUIR*. 22 (3), 93–100. <http://dx.doi.org/10.35596/1729-7648-2024-22-3-93-100> (in Russian).

Введение

Область распознавания эмоций по речи быстро развивается благодаря росту производительности вычислительных систем и широкому интересу к этому вопросу исследователей в сфере психологии, психиатрии и информатики [1, 2]. Эмоции часто влияют на процессы принятия решений, поэтому их распознавание может представлять интерес для построения более эффективного общения, включая диалоговые системы (голосовые помощники, чат-боты). Задача распознавания негативных эмоций, таких как стресс, гнев, усталость, является важным аспектом с точки зрения обеспечения безопасности дорожного движения при использовании интеллектуальных транспортных средств, поскольку позволяет им реагировать на эмоциональное состояние водителя [3]. В сфере взаимодействия человека и компьютера точное распознавание эмоций по речи является ключевым фактором. В статье рассматривается задача определения эмоций на основе анализа речевого сигнала. Одна из основных проблем данного подхода связана с определением набора признаков, эффективно описывающих эмоциональное состояние человека [1, 4–6].

При построении системы распознавания эмоций предлагается использовать мел-частотные кепстральные коэффициенты (МЧКК) [7] для получения признаков и метод опорных векторов (МОВ) [7] в качестве классификатора. Признаки на основе МЧКК широко применяются в системах распознавания эмоций по речи [1, 5]. МЧКК воспроизводят реакцию слуховой системы человека на звук, улавливая соответствующую акустическую информацию [8]. Формируя представление аудиосигнала в частотной области, МЧКК уменьшают размерность данных, сохраняя при этом важные особенности, что делает их пригодными для алгоритмов машинного обучения, таких как МОВ. В свою очередь, МОВ является простым и надежным подходом к задаче классификации, который обеспечивает адаптируемость к многомерным пространствам признаков. МОВ основан на принципе поиска оптимальной гиперплоскости, максимально разделяющей разные классы в пространстве признаков [9]. В контексте распознавания эмоций по речи это означает, что МОВ может эффективно дифференцировать эмоциональные состояния [5], а также учитывать нелинейные отношения с помощью функций ядра (kernel function), что позволяет улавливать сложные закономерности в речевых данных.

Извлечение речевых признаков

На начальном этапе в системе распознавания эмоций по речи выполняется предварительная обработка входных аудиоданных [1, 5]. Речевые признаки рассчитываются на основании МЧКК [8]. Расчет МЧКК относится к методам кратковременного анализа речевого сигнала, которые предполагают разбиение сигнала на фреймы (короткие сегменты). Считается, что в интервале от 10 до 30 мс голосовой сигнал можно считать стационарным. На рис. 1 представлена схема вычисления МЧКК.

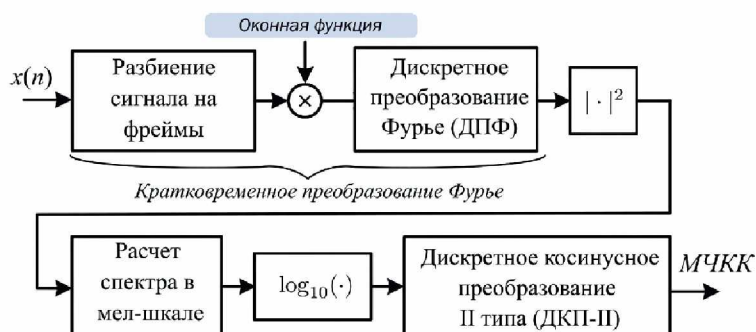


Рис. 1. Схема вычисления мел-частотных кепстральных коэффициентов
Fig. 1. Scheme for calculating mel-frequency cepstral coefficients

Согласно рис. 1, процесс извлечения МЧКК включает следующие шаги:

- 1) вычисление кратковременного преобразования Фурье (КВПФ) и нахождение квадрата модуля КВПФ для получения спектрограммы сигнала;
- 2) вычисление мел-спектрограммы (энергия сигнала из шкалы герц переводится в мел-шкалу, отражающую свойства человеческого слуха);
- 3) взятие логарифма от энергии сигнала в мел-частотных полосах;
- 4) применение декоррелирующего преобразования, в качестве которого используется дискретное косинусное преобразование II типа (ДКП-II).

В качестве иллюстрации на рис. 2 показан пример речевого сигнала, выражающего эмоцию гнева.




Рис. 2. Представление речевого сигнала, выражающего гнев
Fig. 2. Representation of the speech signal expressing anger

На рис. 3 показан результат вычисления КВПФ и мел-спектрограммы сигнала, представленного на рис. 1. На рис. 4 изображена временная последовательность МЧКК, рассчитанная для сигнала на рис. 1.

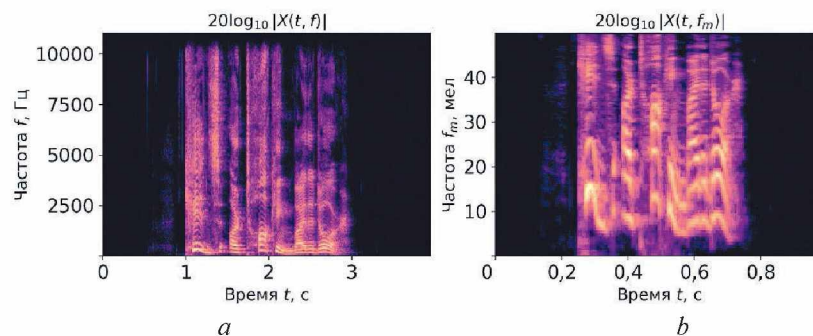


Рис. 3. Речевой сигнал, выражающий гнев: *a* – спектрограмма кратковременного преобразования Фурье; *b* – мел-спектрограмма

Fig. 3. Speech signal expressing anger: *a* – short time Fourier transform spectrogram; *b* – mel-spectrogram




Рис. 4. Временная последовательность мел-частотных кепстральных коэффициентов
Fig. 4. Time-sequence of mel-frequency cepstral coefficients

В экспериментах использовались речевые сигналы с частотой дискретизации 48 кГц. Для обработки аудиосигналов применялась библиотека librosa, написанная на языке Python. КВПФ рассчитывалась для различных размеров фреймов $N = \{1024, 2048, 4096, 8192\}$. Перекрывание между фреймами принималось равным 50 % от размера фрейма. Из каждого фрейма извлекался век-

тор МЧКК размером D . После обработки одного аудиофайла получается матрица $MFCC(k, m)$ размером $D \times N_{frames}$, где N_{frames} – количество фреймов. Таким образом, m -й столбец матрицы представляет собой вектор МЧКК, вычисленный для временного фрейма с номером m .

Для получения единого вектора признаков для каждого аудиофайла вычисляются средние $meanMFCC(k)$ (D признаков) и среднеквадратичные (СКО) отклонения, $SDMFCC(k)$ (D признаков) для МЧКК в матрице $MFCC$ вдоль оси времени. СКО может быть полезно для оценки степени изменчивости в МЧКК во времени. По матрице МЧКК также производилось извлечение первой и второй производных (первой и второй разностей).

Первая производная МЧКК (Δ -МЧКК) представляет собой скорость изменения каждого коэффициента во времени. Таким образом, Δ -МЧКК отражает быстроту изменения спектральных характеристик звука во времени, помогает в выявлении моментов, когда звук становится более высокочастотным или громким, что может быть полезным для распознавания звуковых событий. Вторая производная МЧКК (Δ^2 -МЧКК) представляет собой ускорение изменения каждого коэффициента во времени. Принятие во внимание Δ^2 -МЧКК позволяет более полно описать характер спектральных изменений речевого сигнала во времени.

Известно, что применение производных МЧКК дает возможность улучшить производительность систем распознавания, классификации и детектирования речевых сигналов [1, 5, 10]. Они могут использоваться для выделения важных характеристик аудиосигнала, таких как изменения в тональности, интонации и ритме речи. Это делает их полезными в приложениях по распознаванию речи, детектированию звуковых событий и музыкальному анализу.

Для полученных матриц Δ -МЧКК и Δ^2 -МЧКК рассчитывали их средние значения и СКО, что в итоге дало $4D = 136$ дополнительных признаков. На основании матрицы МЧКК также были рассчитаны коэффициент асимметрии (skewness), эксцесс (kurtosis) и межквартильный размах (Interquartile Range, IQR). Коэффициент асимметрии – это мера степени асимметрии распределения случайной величины. Она показывает, насколько сильно и в какую сторону смещено распределение относительно своего среднего значения. В контексте анализа МЧКК коэффициент асимметрии может дать информацию о форме распределения и подчеркнуть определенные аспекты вариативности звукового сигнала. Коэффициент асимметрии вычислялся для каждого МЧКК

$$SkMFCC(k) = \left(\frac{1}{N_{frames}} \right) \sum_{m=0}^{N_{frames}} \frac{(MFCC(k, m) - meanMFCC(k))^3}{SDMFCC(k)^3}. \quad (1)$$

Эксцесс – мера формы распределения случайной величины, которая показывает, насколько оно остроконечное или плоское по сравнению с нормальным распределением. Для вычисления эксцесса использовали формулу моментов

$$kurtosisMFCC(k) = \left(\frac{1}{N_{frames}} \right) \sum_{m=0}^{N_{frames}} \frac{(MFCC(k, m) - meanMFCC(k))^4}{SDMFCC(k)^4 - 4}. \quad (2)$$

Межквартильный размах – это мера разброса данных, которая используется для измерения разницы между верхним и нижним квартилями. Она показывает разброс значений в данных. При вычислении IQR выполняются шаги:

- 1) упорядочиваются данные по возрастанию;
- 2) находится значение первого квартиля (Q_1), которое отделяет нижние 25 % наблюдений;
- 3) находится значение третьего квартиля (Q_3), которое отделяет нижние 75 %;
- 4) вычисляется IQR как разница между значениями Q_3 и Q_1

$$IQR = Q_3 - Q_1. \quad (3)$$

В контексте решаемой задачи IQR может быть полезен для измерения разброса в параметрах МЧКК. Результирующая схема формирования вектора признаков приведена на рис. 5. В итоговый набор признаков были включены среднее значение МЧКК (D признаков), среднеквадратичное отклонение МЧКК (D признаков), среднее от первой и второй производных от МЧКК ($2D$ признаков), их среднеквадратическое отклонение ($2D$), а также коэффициент асимметрии,

эксцесс и межквантильный размах (по D признаков для каждой характеристики соответственно). Таким образом, для каждого аудиофайла получается $9D$ -компонентный вектор надсегментных признаков МЧКК.

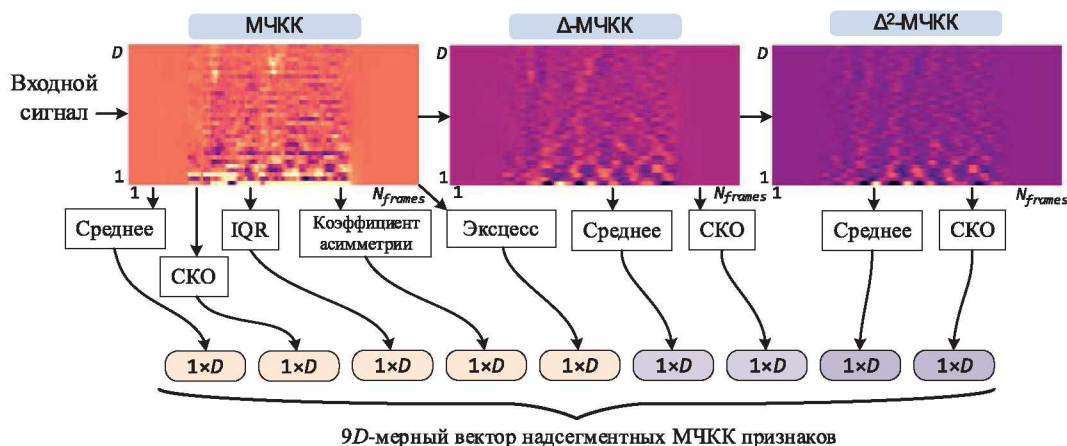


Рис. 5. Схема формирования вектора признаков
Fig. 5. The scheme of feature vector extraction

Речевая база и описание эксперимента

При проведении исследования применяли набор данных Ryerson Audio-Visual Database of Emotional Speech and Song (RAVDESS) [11]. RAVDESS содержит записи 24 актеров (12 мужчин, 12 женщин). Каждый актер произнес 104 различных сообщения (60 речевых высказываний и 44 песенных). В экспериментах использовалась только часть базы RAVDESS, содержащая речевые высказывания – 1440 файлов в формате wav (16 бит, 48 кГц): 60 записей на каждого из 24-х актеров. Речевые эмоции включали нейтральность, спокойствие, счастье, грусть, гнев, страх, удивление и отвращение. Все эмоциональные состояния, кроме нейтрального, озвучивались на двух уровнях эмоциональной громкости (нормальном и повышенном). Актеры повторяли каждую вокализацию дважды.

Для классификации в системе распознавания эмоционального состояния по речи применяется МОВ. Данный метод выполняет классификацию путем построения разделяющей гиперплоскости, которая оптимально разделяет данные на классы. В МОВ предусмотрено использование функции ядра для преобразования исходного набора данных в многомерное пространство признаков. И уже в новом пространстве признаков выполняется построение оптимальной разделяющей гиперплоскости. В исследовании использовались известные ядерные функции: линейная, полиномиальная и гауссово ядро с радиальной базисной функцией (РБФ) [9].

Построение классификатора на опорных векторах с применением перечисленных выше ядер осуществлялось с помощью библиотеки sklearn языка Python. Для тестирования классификатора использовался метод перекрестной проверки по k блокам (k -fold cross-validation) [9], который заключается в следующем.

1. Набор разбивается на k блоков.
2. В цикле для $i = 1, 2, \dots, k$ выполняются следующие операции:
 - блок i устанавливается в качестве тестового набора данных (test data);
 - оставшиеся блоки принимаются как тренировочные данные (train data);
 - выполняется обучение модели классификатора на тренировочных и оценивается ее эффективность на тестовых данных;
 - сохранение результатов классификации для данных из тестового набора;
 - сброс параметров модели до исходного состояния для следующей итерации.
3. Расчет оценки эффективности модели на основе сохраненных результатов классификации тестовых данных.

Полученные данные, согласно схеме, предложенной в [12], разбивали на блоки следующим образом (в скобках указаны номера актеров):

- блок 0: (2, 5, 14, 15, 16);

- блок 1: (3, 6, 7, 13, 18);
- блок 2: (10, 11, 12, 19, 20);
- блок 3: (8, 17, 21, 23, 24);
- блок 4: (1, 4, 9, 22).

Выбранная стратегия заключается в том, что каждый блок должен содержать одинаковое количество случайно выбранных образцов для каждого класса. При этом должно выполняться условие, что каждый актер представлен либо в обучающей, либо в валидационной выборке, но не в обеих. Для оценки качества модели вычисляли среднее арифметическое (невзвешенное) полноты (unweighted average recall, UAR). UAR – это показатель, используемый для измерения общей производительности модели многоклассовой классификации, вычисляет средний уровень запоминания по всем классам, придавая каждому классу одинаковую важность без учета классового дисбаланса:

$$UAR = \frac{1}{N_c} \sum_{i=1}^{N_c} \frac{A_{ii}}{\sum_{j=1}^{N_c} A_{ij}}, \quad (4)$$

где A – матрица спутанности (confusion matrix); N_c – количество классов.

Значение UAR находится в диапазоне от 0 до 1. Эксперимент проводился в три этапа:

- 1) подготовка обучающей выборки;
- 2) обучение и тестирование классификатора с использованием различных функций ядра и разных размеров длины фрейма анализа речевых сигналов;
- 3) оценка модели с использованием метрики UAR.

Результаты исследований и их обсуждение

На первом этапе проводили эксперименты по подбору числа D извлекаемых МЧКК. Выбирался размер фрейма, равный 1024 отчета (~23 мс), классификатор на основе МОВ с линейным ядром и определялось оптимальное число D МЧКК из множества {30,32,34,36,38,40,42,44}. Наилучший результат классификации был получен при $D = 34$. Это значение затем использовали в дальнейших исследованиях.

На втором этапе выполнялись эксперименты с классификатором на основе МОВ и различными ядерными функциями. Известно, что функция полиномиального ядра имеет параметр deg (степень полинома), а радиальная базисная функция – параметр γ . Также классификатор на основе МОВ имеет параметр C , который представляет собой «бюджет» некоторой величины, отражающий степень нарушения зазора решающей границы [9]. Подобные нарушения происходят, поскольку данные в признаковом пространстве не могут быть разделены идеально. Таким образом, параметры deg , γ и C являются гиперпараметрами классификатора на основе МОВ. Для выбора оптимальных значений гиперпараметров использовалась техника поиска по сетке (grid search): для deg – сетку значений от 1 до 8 с шагом 1; для C – сетку из 12 значений от 0,1 до 100,0, расположенных эквидистантно в логарифмическом масштабе; для γ формировалась сетка из 10 значений в диапазоне от $10^{-3,5}$ до $10^{-1,5}$, расположенных эквидистантно в логарифмическом масштабе. Поиск оптимальных значений параметров, позволяющих получить наибольшее значение UAR, выполнялся для векторов признаков, полученных при различных значениях размера фрейма анализа. Результаты эксперимента приведены в табл. 1.

Таблица 1. Результирующий UAR для классификатора на основе метода опорных векторов с различными ядрами
Table 1. Resulting UAR for a support vector machine classifier with different kernels

| Размер фрейма / Frame size | Линейное ядро / Linear kernel | Полиномиальное ядро / Polynomial kernel | Радиальная базисная функция ядра / Radial basis kernel function |
|-------------------------------|----------------------------------|--|--|
| 1024 | 0,458 ($C = 0,01$) | 0,457 ($C = 0,01, \gamma = 1, deg = 1$) | 0,469 ($C = 8,11, \gamma = 0,0008$) |
| 2048 | 0,451 ($C = 0,10$) | 0,450 ($C = 0,01, \gamma = 1, deg = 1$) | 0,471 ($C = 8,11, \gamma = 0,0008$) |
| 4096 | 0,454 ($C = 0,01$) | 0,455 ($C = 0,05, \gamma = 0,1, deg = 1$) | 0,476 ($C = 2,31, \gamma = 0,0014$) |
| 8192 | 0,469 ($C = 0,01$) | 0,474 ($C = 0,05, \gamma = 0,1, deg = 1$) | 0,482 ($C = 28,48, \gamma = 0,0014$) |

Наилучшее значение $UAR = 48,2\%$ достигается при использовании классификатора с ядрами РБФ и МЧКК, рассчитанными на фрейме размером 8192. Поверхность UAR , рассчитанная в ходе поиска по сетке для этой модели, представлена на рис. 6, *a*. Из рисунка видно, что большое значение параметра C приводит к более гибкому классификатору с высокой производительностью. При увеличении размера фрейма анализа до 16 384 показатель UAR резко падал до значения 0,13. На рис. 6, *b* представлена матрица спутывания для лучшей модели.

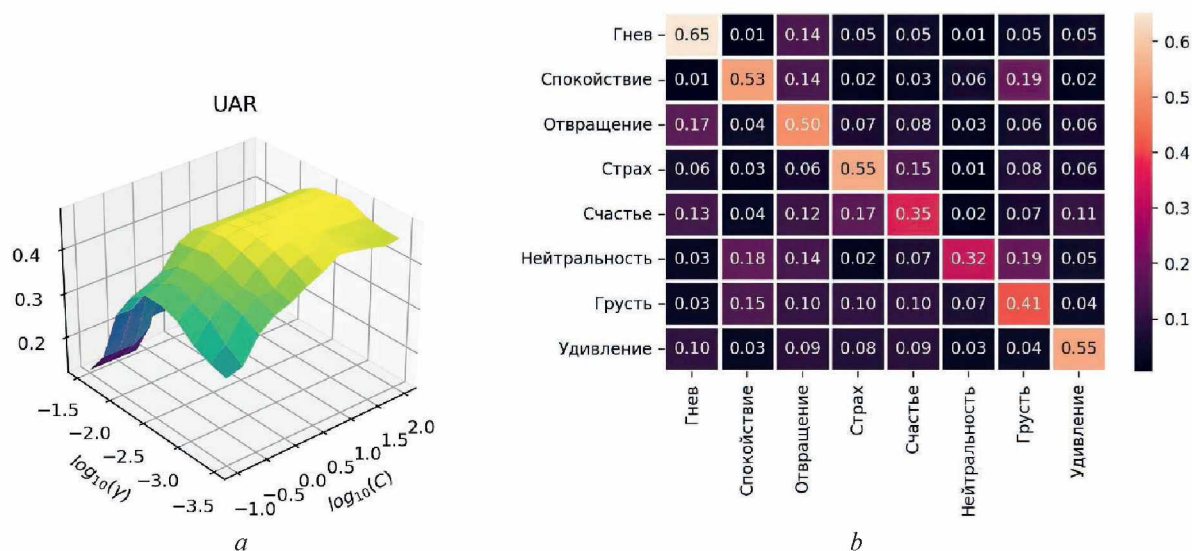


Рис. 6. Результаты экспериментов: *a* – поверхность UAR ; *b* – матрица спутывания
Fig. 6. Experimental results: *a* – UAR surface; *b* – confusion matrix

Анализ матрицы спутывания позволяет выявить важные закономерности в распознавании эмоций. Можно заметить, что наиболее часто неправильно классифицированными эмоциями являются нейтральность (32 %) и счастье (35 %). Примечательно, что нейтральность часто путается с грустью и спокойствием, что позволяет предположить некоторое сходство их акустических характеристик. И наоборот, гнев имеет высокую точность распознавания (65 %) и редко ошибочно классифицировался как другая эмоция, что указывает на отличительные особенности его акустического профиля. Эти результаты проливают свет на проблемы, с которыми сталкивается классификатор при различении тонких эмоциональных нюансов, и подчеркивают важность разработки функций и совершенствования моделей для улучшения эффективности распознавания эмоций.

Результаты исследований показывают, что выбор ядра оказывает существенное влияние на точность классификации. Классификатор с РБФ продемонстрировал высокую производительность в отношении множества эмоций, в то время как использование линейного ядра позволяет хорошо различать лишь отдельные эмоциональные состояния.

Размер фрейма, используемый для извлечения МЧКК, играет существенную роль в общей точности системы: более короткие фреймы обеспечивают более мелкие временные детали, а более длинные собирают более широкую контекстную информацию, что позволяет лучше распознавать эмоции. Полученные результаты подчеркивают важность точной настройки ядра классификатора и подбора размера фрейма при разработке систем распознавания эмоций по речи. Точность (UAR) полученной модели, использующей 306-компонентный вектор признаков, составляет 48,2 %, что больше, чем у модели на основе МОВ [12], использующей в качестве вектора признаков 2048-компонентный вектор, полученный от внутреннего слоя нейронной сети AlexNet ($UAR = 45,8\%$). Следует также отметить, что человек справляется с задачей распознавания эмоций по речи с точностью 67 % [12].

Заключение

Рассмотрен подход к задаче распознавания эмоций по речи, основанный на классификаторе на базе метода опорных векторов и использующий надсегментные мел-частотные кепстральные коэффициенты. Наилучшие результаты ($UAR = 48,2\%$) получены в случае применения клас-

сификатора с радиальной базисной функцией ядра и признаками мел-частотных кепстральных коэффициентов, рассчитанными на фрейме длительностью 170 мс.

Список литературы / References

1. Issa D., Demirci F. M., Yazici A. (2020) Speech Emotion Recognition with Deep Convolutional Neural Networks. *Biomedical Signal Processing and Control*. 59.
2. Luna-Jiménez C., Griol D., Callejas Z., Kleinlein R., Montero J. M., Fernández-Martínez F. (2021) Multimodal Emotion Recognition on RAVDESS Dataset Using Transfer Learning. *Sensors*. 21 (22), 1–29.
3. Xiao H., Li W., Zeng G., Wu Y., Xue J., Zhang J., [et al.] (2022) On-Road Driver Emotion Recognition Using Facial Expression. *Appl. Sci*. 12.
4. Sadok S., Leglaive S., Séguier R. (2023) A Vector Quantized Masked Autoencoder for Speech Emotion Recognition. *arXiv preprint arXiv*. 2304.
5. Bhavan A., Chauhan P., Shah R. R. (2019) Bagged Support Vector Machines for Emotion Recognition from Speech. *Knowledge-Based Systems*. 184, 1–7.
6. Baruah M., Banerjee B. (2022) Speech Emotion Recognition via Generation Using an Attention-Based Variational Recurrent Neural Network. *Proc. Interspeech*. 4710–4714.
7. Yu C., Tian Q., Cheng F., Zhang S. (2011) Speech Emotion Recognition Using Support Vector Machines. *Advanced Research on Computer Science and Information Engineering. Communications in Computer and Information Science*. 152.
8. Huang X., Acero A., Hon H.-W., Foreword By-Reddy R. (2001) Spoken Language Processing: A Guide to Theory, Algorithm, and System Development. *Prentice Hall PTR*.
9. Hastie T., Tibshirani R., Friedman J. H., Friedman J. H. (2009) The Elements of Statistical Learning: Data Mining, Inference, and Prediction. *Springer*.
10. On C. K., Pandiyan P. M., Yaacob S., Saudi A. (2006) Mel-Frequency Cepstral Coefficient Analysis in Speech Recognition. *In 2006 International Conference on Computing & Informatics*. 1–5.
11. Livingstone S. R., Russo F. A. (2018) The Ryerson Audio-Visual Database of Emotional Speech and Song (RAVDESS): A Dynamic, Multimodal Set of Facial and Vocal Expressions in North American English. *PLoS One*. 13 (5).
12. Luna-Jiménez C., Griol D., Callejas Z., Kleinlein R., Montero J. M., Fernández-Martínez F. (2021) Multimodal Emotion Recognition on RAVDESS Dataset Using Transfer Learning. *Sensors*. 21.

Вклад авторов / Authors' contribution

Авторы внесли равный вклад в написание статьи / The authors contributed equally to the writing of the article.

Сведения об авторах

Краснопрошин Д. В., магистрант каф. электронных вычислительных средств, Белорусский государственный университет информатики и радиоэлектроники

Вашкевич М. И., д-р техн. наук, проф. каф. электронных вычислительных средств, Белорусский государственный университет информатики и радиоэлектроники

Адрес для корреспонденции

220013, Республика Беларусь,
г. Минск, ул. П. Бровки, 6
Белорусский государственный университет
информатики и радиоэлектроники
Тел.: +375 17 293-84-78
E-mail: vashkevich@bsuir.by
Вашкевич Максим Иосифович

Information about the authors

Krasnoproshin D. V., Master's Student at the Department of Electronic Computing Facilities, Belarusian State University of Informatics and Radioelectronics

Vashkevich M. I., Dr. of Sci. (Tech.), Professor at the Department of Electronic Computing Facilities, Belarusian State University of Informatics and Radioelectronics

Address for correspondence

220013, Republic of Belarus,
Minsk, P. Brovki St., 6
Belarusian State University
of Informatics and Radioelectronics
Tel.: +375 17 293-84-78
E-mail: vashkevich@bsuir.by
Vashkevich Maxim Iosifovich