



УДК 615.47:616-072.8
<https://doi.org/10.37661/1816-0301-2023-20-3-106-114>

Оригинальная статья
Original Paper

Распознавание признаков болезни Паркинсона на основе анализа голосовых маркеров и двигательной активности

В. А. Вишняков[✉], Ся Ивэй

Белорусский государственный университет
информатики и радиоэлектроники,
ул. П. Бровки, 6, Минск, 220013, Беларусь
[✉]E-mail: vish@bsuir.by

Аннотация

Цели. Решается задача ИТ-диагностики признаков болезни Паркинсона по анализу изменения голоса и замедления движения пациентов. Актуальность задачи связана с необходимостью ранней диагностики заболевания. Предлагается метод комплексного распознавания болезни Паркинсона с использованием машинного обучения, основанный на анализе голосовых маркеров и изменений в движениях пациентов на известных наборах данных.

Методы. Используются частотно-временная функция (функция вейвлета), функция кепстрального коэффициента Мейера, алгоритм k -ближайших соседей (k -Nearest Neighbors, KNN), алгоритм двухслойной нейронной сети для обучения и тестирования на общедоступных наборах данных по изменению речи и замедлению движения при болезни Паркинсона, а также байесовский оптимизатор для улучшения гиперпараметров алгоритма KNN.

Результаты. Алгоритм KNN использован для распознавания речи пациентов, точность теста 94,7 % достигнута при диагностике болезни Паркинсона по изменению голоса. Алгоритм байесовской нейронной сети применен для распознавания замедления движения пациентов, он дал точность теста 96,2 %.

Заключение. Полученные результаты распознавания признаков болезни Паркинсона близки к мировому уровню. На том же наборе данных по изменению речи пациентов один из лучших показателей зарубежных исследований составляет 95,8 %, а на наборе данных по замедлению движения пациентов – 98,8 %. Предлагаемая авторская методика предназначена для использования в подсистеме ИТ-диагностики неврологических заболеваний умного города.

Ключевые слова: распознавание болезни Паркинсона, машинное обучение, алгоритм KNN, голосовые маркеры, байесовская нейронная сеть, замедление движения, гиперпараметры

Для цитирования. Вишняков, В. А. Распознавание признаков болезни Паркинсона на основе анализа голосовых маркеров и двигательной активности // В. А. Вишняков, Ся Ивэй // Информатика. – 2023. – Т. 20, № 3. – С. 106–114. <https://doi.org/10.37661/1816-0301-2023-20-3-106-114>

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию | Received 12.04.2023

Подписана в печать | Accepted 16.05.2023

Опубликована | Published 29.09.2023

Recognition of signs of Parkinson's disease based on the analysis of voice markers and motor activity

Uladzimir A. Vishniakou[✉], Xia Yiwei

Belarusian State University of Informatics and Radioelectronics,
st. P. Brovka, 6, Minsk, 220013, Belarus

[✉]E-mail: vish@bsuir.by

Abstract

Objectives. The problem of IT diagnostics of signs of Parkinson's disease is solved by analyzing changes in the voice and slowing down the movement of patients. The urgency of the task is associated with the need for early diagnosis of the disease. A method of complex recognition of Parkinson's disease using machine learning is proposed, based on markers of voice analysis and changes in the patient's movements on known data sets.

Methods. The time-frequency function (the wavelet function) and the Meyer kepsstral coefficient function, the KNN algorithm (*k*-Nearest Neighbors, KNN) and the algorithm of a two-layer neural network are used for training and testing on publicly available datasets on speech changes and motion retardation in Parkinson's disease. A Bayesian optimizer is also used to improve the hyperparameters of the KNN algorithm.

Results. The KNN algorithm was used for speech recognition of patients, the test accuracy of 94.7% was achieved in the diagnosis of Parkinson's disease by voice change. The Bayesian neural network algorithm was applied to recognize the slowing down of the patients' movements, it gave a test accuracy of 96.2% for the diagnosis of Parkinson's disease.

Conclusion. The obtained results of recognition of signs of Parkinson's disease are close to the world level. On the same set of data on speech changes of patients, one of the best indicators of foreign studies is 95.8%. On the same set of data on motion deceleration, one of the best indicators of foreign researchers is 98.8%. The proposed author's technique is intended for use in the subsystem of IT diagnostics of neurological diseases of a Smart city.

Keywords: Parkinson's disease recognition, machine learning, KNN algorithm, voice markers, Bayesian neural network, motion deceleration, hyperparameters

For citation. Vishniakou U. A., Xia Yiwei. *Recognition of signs of Parkinson's disease based on the analysis of voice markers and motor activity*. Informatika [Informatics], 2023, vol. 20, no. 3, pp. 106–114 (In Russ.). <https://doi.org/10.37661/1816-0301-2023-20-3-106-114>

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

Введение. Болезнь Паркинсона (БП) – распространенное нейродегенеративное заболевание пожилых людей. Средний возраст заболевших составляет 60 лет, и число пораженных постепенно с возрастом увеличивается. Медицинские исследования показывают, что патология БП имеет два основных аспекта [1]: депигментацию черной субстанции вследствие дегенерации нейронов, содержащих меланин и дофамин, и образование тел Леви в черной субстанции и других областях мозга, таких как прилежащее ядро и части коры.

В работе [2] были выделены шесть стадий заболевания при условии, что нарушения обоняния и речи возникают на первых двух стадиях. Согласно исследованию 89 % пациентов с БП имеют различные степени нарушения речи, основными симптомами которых являются низкая громкость, невнятность, хрипота, монотонность, отсутствие эмоциональных изменений и замедленность речи. Третья и четвертая стадии отличаются более выраженными симптомами, наиболее значимые из них – тремор в состоянии покоя, замедление движения, а на поздних стадиях заболевания – нарушение равновесия. На заключительных стадиях (пятой и шестой) проявляются все клинические симптомы. Таким образом, изучение нарушений речи и движений как симптомов у пациентов с БП выступает исходной задачей для ранней диагностики заболевания, в том числе с использованием ИТ.

Методы исследования. ИТ-исследование выполнено с целью классификации больных паркинсонизмом и здоровых людей с выделением 14 особенностей фонации и 12 кепстральных особенностей речи. Проанализированные 14 признаков фонации включают пять вариантов

дрожания, шесть вариантов мерцания, два признака гармоничности и среднюю автокорреляцию основного частотного признака [3].

В работе [4] был использован метод, основанный на распознавании и классификации с применением глубокой нейронной сети (Deep Neural Network, DNN) в сочетании с мини-пакетным градиентным спуском (МППС) для отличия пациентов с БП от здоровых людей по признакам изменения голоса. Авторы применили метод взвешенных кепстральных коэффициентов Мейера WMFCC для извлечения объектов. Метод WMFCC может решить проблему, заключающуюся в том, что кепстральные коэффициенты Мейера высокого порядка малы, а способность компонента функции Features к представлению звука слаба. МППС снижает вычислительную нагрузку на функцию потерь и увеличивает скорость обучения системы.

Подход к анализу движения людей в работе [5] основан на квартильном отклонении нормального распределения для выбора наилучших признаков. В 2019 г. в работе [6] была предложена интеллектуальная система обнаружения БП, основанная на методах глубокого обучения для анализа информации о походке человека. Авторы использовали сверточную нейронную сеть 1D-Convnet для построения классификатора на основе DNN.

В работе [7] авторы проанализировали технику распознавания изменения речи людей, используя x-векторы, и осуществили автоматическое обнаружение признаков БП. Растущая популярность и успех сетей Transformer при обработке естественного языка и распознавании изображений побудили разработать новый метод решения проблемы, основанный на автоматическом извлечении признаков БП с помощью таких сетей. Использование их в 1D-сигнале еще не получило широкого распространения, но в работе [8] показано, что они эффективны при извлечении релевантных признаков из 1D-сигналов.

Алгоритмы распознавания БП. Рассмотрим использование машинного обучения и нейронных сетей в качестве методов выявления признаков БП. В зависимости от применяемых входных данных, метода обучения и выходных данных изученной модели алгоритмы машинного обучения и алгоритмы нейронных сетей можно разделить на следующие четыре категории:

1. *Контролируемое обучение.* Строится отображение от входных данных к выходным на основе наблюдений за серией выборок, каждая из которых имеет соответствующий выходной сигнал, и в конечном итоге создается прогностическая модель.

2. *Обучение без присмотра.* Требуется только серия точек выборки в качестве входных данных. Нет необходимости, чтобы выборки были предварительно помечены соответствующими выходными данными. Информация, полученная с помощью алгоритма, может быть применена для построения описательной модели, классическим примером которой является поисковая система.

3. *Обучение с полуконтролем.* Используются в большом количестве немаркированные данные, а также одновременно помеченные данные для выполнения работы по распознаванию образов.

4. *Обучение с подкреплением.* Выполняется путем повторения (несколько раз) и наблюдения за обратной связью, генерируемой средой после каждой итерации. Фактически выходные данные и действия, предпринимаемые моделью после каждой итерации, будут оказывать влияние на окружающую среду и окружающая среда будет обеспечивать обратную связь в ответ на эти воздействия. В основном используется для распознавания речи и текста.

Параметры служат ключом к алгоритмам машинного обучения и обычно делятся на общие и гиперпараметры. *Общие параметры* – это переменные, которые могут быть автоматически извлечены моделью из данных, например веса каждого слоя нейронной сети, априорная вероятность каждого класса в простом байесовском алгоритме и др. *Гиперпараметры* представляют собой внешние по отношению к модели конфигурации, значения которых не могут быть оценены по данным и обычно задаются вручную (как правило, являются эмпирически определенными переменными). Различные методы машинного обучения имеют разные гиперпараметры. В частности, в нейронных сетях гиперпараметрами служат скорость обучения, параметр регуляризации, количество слоев, эпоха, функция потерь, метод инициализации весов, функция активации нейронов и др.

Поскольку входные данные являются помеченными, разработки, приведенные в настоящей статье, относятся к контролируемому обучению. Использован алгоритм KNN для машинного

обучения сети распознавания БП по голосу и байесовский алгоритм нейронной сети распознавания БП по изменению движения.

Алгоритм KNN. Основная идея алгоритма k -ближайших соседей (k -Nearest Neighbors, KNN) заключается в том, что если большинство из k ближайших выборок в пространстве объектов принадлежат к определенной категории, то выборка также принадлежит к этой категории [9]. Алгоритм KNN имеет два основных параметра:

1. Расстояние. Распространенными методами вычисления расстояний между двумя точками являются манхэттенское расстояние, евклидово расстояние и расстояние Минковского. К расстоянию до каждой точки можно добавить вес, чтобы более близкая точка получила больший вес. К вычисленному значению добавляется значение функции, например обратной функции, функции Гаусса и т. д.

2. Значение k . Оно является целым числом, не превышающим 20. Значение k слишком мало, чтобы на него влияли выбросы, и слишком велико, чтобы на него влиял дисбаланс выборки.

Входные данные: k – количество ближайших соседей, набор тестовой выборки, набор обучающей выборки. В результате получаем набор этикеток тестового образца.

Реализация алгоритма KNN:

Шаг 1. Ввод данных обучения и тестирования.

Шаг 2. Определение параметра k .

Шаг 3. Вычисление расстояния до объекта по заданным обучающим данным: между точкой в наборе данных известной категории и текущей точкой; между точкой данных, класс которой должен быть предсказан, и всеми точками обучающих данных. Можно использовать евклидово расстояние.

Шаг 4. Сортировка результатов в порядке возрастания (последовательно от низкого к высокому).

Шаг 5. Выбор k точек с наименьшим расстоянием от текущей точки (классификация ближайших соседей на основе значения k).

Шаг 6. Определение частоты встречаемости категории, в которой расположены k точек.

Шаг 7. Возврат к категории с наибольшей частотой появления первых k точек в качестве прогнозируемой классификации текущей точки. При использовании категории ближайшего соседа как наиболее доминирующей она прогнозируется как метка объекта. Нахождение количества классов от ближайшего соседа и установка класса данных, подлежащих оценке.

Алгоритм KNN прост в вычислительном отношении, но требует больших вычислительных затрат и большого объема памяти, поэтому для него необходимо выбрать подходящее значение k .

Алгоритм байесовской нейронной сети. Байесовские нейронные сети (Bayesian Neural Networks, BNN) сочетают вероятностное моделирование с нейронными сетями и способны повысить прогнозируемый результат. Входной слой нейронной сети используется для описания ключевых параметров и ввода данных, выходной слой – для описания вероятности или распределения вероятностей. Апостериорное распределение вычисляется путем выборки или вариационного вывода. BNN отличаются от обычных нейронных сетей тем, что весовые параметры в них являются случайными величинами. В работе [10] BNN использовалась для распознавания БП по замедлению движения.

Гиперпараметры в BNN включают:

- количество скрытых слоев;
- параметры регуляризации. Коэффициенты регуляризации влияют на способность модели к обобщению;
- количество нейронов на слой;
- эпоху обучения;
- скорость обучения, график скорости обучения для обновления веса;
- функцию активации скрытого слоя (логистической регрессии, \tanh , relu и т. д.);
- размер мини-пакета для небольших пакетов данных, количество образцов за тренировочную сессию;

– решатель для оптимизации веса (lbfgs – оптимизатор в семействе квазиньютоновских методов, sgd – стохастический градиентный спуск, adam – оптимизатор на основе стохастического градиента).

Распознавание признаков заболевания. В 2019 г. в работе [10] были изучены речевые расстройства при БП и к собранным данным¹ применены различные алгоритмы обработки речевых сигналов, учитывающие особенности временной частоты, характеристики кепстрального коэффициента Мейера и др. Данные, использованные в этом исследовании (звук), были собраны у 188 пациентов с БП (107 мужчин и 81 женщины) в возрасте от 33 до 87 лет ($65,1 \pm 10,9$) в отделении неврологии медицинского факультета Серрахпа Стамбульского университета. Контрольную группу составили 64 здоровых человека (23 мужчины и 41 женщина) в возрасте от 41 до 82 лет ($61,1 \pm 8,9$). В процессе сбора данных микрофон настраивался на частоту 44,1 кГц, и после осмотра врачом у каждого испытуемого с тремя повторениями была получена устойчивая фонетика гласной *a*.

Проблема замедления движения при БП была исследована в работе [11]. Набор данных Daphnet (движение) был сформирован в лаборатории с акцентом на генерацию множества событий замедления². Пользователи выполняли три вида задач: ходьбу по прямой, ходьбу с многочисленными поворотами и, наконец, реальную повседневную задачу, когда пользователи заходили в разные комнаты, принося кофе, открывая двери и т. д. Набор данных получен с трех носимых беспроводных датчиков ускорения, регистрирующих 3D-ускорение с частотой 64 Гц. Датчики располагались на голени, бедре и тазобедренном суставе испытуемого. Для распознавания БП по движению была разработана модель нейронной сети, которая использует двухслойную полностью связанную сеть с первым и вторым слоями (10 нейронов), а также функцию ReLU для активации нейронов. Функция ReLU лучше сигмоидальных функций и функций гиперболического тангенса, поскольку легче находит производные, а также увеличивает нелинейность сети.

В настоящей статье вышеупомянутые общедоступные наборы данных (звук, движение) были выбраны в качестве экспериментальных. После очистки и предварительной обработки данных были извлечены характеристики частотно-временной области, обратные спектральные коэффициенты Мейера и вейвлет-коэффициенты в наборах данных «звук». В наборах данных «движение» были извлечены пять частотно-временных характеристик: энтропия вейвлета, энергия вейвлета, длина формы вейвлет-сигнала, дисперсия вейвлет-коэффициента и стандартное отклонение вейвлет-коэффициента. Затем набор признаков данных был нормализован и разделен на набор обучающих данных и набор тестовых данных в соотношении 9:1. Обучающие наборы данных обрабатывались и тестировались с помощью пятикратной перекрестной проверки с пятикратным повторением. Набор тестовых данных использовался для проверки окончательных результатов.

Результаты экспериментов. Перед началом экспериментов были введены параметры модели оценки. Показатели эффективности для конкретного класса k включали чувствительность ($Sens_k$), точность ($Prec_k$) и $F1$ -оценку ($F1_k$):

$$Sens_k = \frac{C_{k,k}}{\sum_{i=1}^K C_{i,k}},$$

$$Prec_k = \frac{C_{k,k}}{\sum_{j=1}^K C_{k,j}},$$

$$F1_k = 2 \cdot \frac{Prec_k \cdot Sens_k}{Prec_k + Sens_k},$$

где i – количество строк матрицы путаницы, j – количество столбцов матрицы путаницы, k – номер любого класса, C – единственный элемент в матрице путаницы.

¹Parkinson Data Set [Electronic resource]. – Mode of access: <https://archive.ics.uci.edu/ml/datasets/parkinsons>. – Date of access: 12.03.2023.

²Daphnet Freezing of Gait Data Set [Electronic resource]. – Mode of access: <https://archive.ics.uci.edu/ml/datasets/Daphnet%2BFreezing%2Bof%2BGait>. – Date of access: 12.03.2023.

Поскольку объем данных в наборе данных «звук» невелик, был использован алгоритм KNN, который представляет собой простой алгоритм классификации машинного обучения. Также был применен байесовский оптимизатор для улучшения гиперпараметров KNN. Количество итераций вычисления составило 30. На графике (рис. 1) видно, что минимальный индекс ошибки классификации стремится к стабильному состоянию, когда количество итераций 15, и достигает минимального значения на 29-й итерации. Поэтому для эксперимента значение параметра KNN 29-й итерации берется в качестве предпоследнего.




Рис. 1. График минимальной ошибки классификации по речевым признакам для алгоритма KNN
Fig. 1. Graph of the minimum classification error by speech features for the KNN algorithm

При проведении эксперимента был использован метод PCA (метод главных компонент), чтобы выбрать десять функций, которые больше всего соответствуют модели. Численными параметрами алгоритма KNN являлись: количество соседей, мера расстояния (функция косинуса), вес расстояния (алгоритм обратного взвешивания расстояния). Матрица путаницы и график ROC(Receiver Operating Characteristics)-кривой [12] результатов тестового эксперимента по распознаванию БП после обучения модели представлены на рис. 2.




Рис. 2. Матрица путаницы и ROC-графики тестового набора данных «звук»
Fig. 2. Confusion matrix and ROC plots of test dataset "sound"

Матрица путаницы и график ROC-кривой результатов тестового эксперимента для набора данных по изменению движения показаны на рис. 3.




Рис. 3. Матрица путаницы и ROC-графики тестового набора данных «движение»

Fig. 3. Confusion matrix and ROC plots of test dataset "action"

Данные тестовых экспериментов при распознавании БП по изменению речи и изменению движения приведены в таблице.

Показатели распознавания БП по набору данных «звук» и «движение»

Parkinson's disease recognition scores on the "sound" and "action" dataset

Набор данных <i>Data set</i>	Показатель, % <i>Indicator, %</i>			
	Средняя точность <i>Average accuracy</i>	Средняя чувствительность <i>Medium sensitivity</i>	Средняя F1-оценка <i>Average F1 score</i>	Точность тестирования <i>Testing accuracy</i>
Звук	92,95	92,95	92,95	94,7
Движение	62,78	87,13	72,98	96,2

Модель может достичь точности 94,7 % при диагностировании БП на основе речевых данных и высокого показателя F1-оценки (до 92,95 %). Точность набора обучающих данных составила 92,8 %, а точность набора тестовых данных – 94,7 %. Точность тестового набора на 1,9 % выше, чем точность обучающего набора. Следовательно, объем экспериментальных данных слишком мал, что приведет к неравномерному срезу набора данных, если модель правильно отражает структуру распределения внутри данных. Возможно, что внутренняя дисперсия обучающего набора будет больше, чем набора проверки. Это приведет к большей ошибке в обучающем наборе и потребует перераспределения набора данных, чтобы сделать его более равномерным. На том же наборе данных³ один из лучших показателей зарубежных исследований составляет 95,8 % [13].

В ходе экспериментов выяснилось также, что точность распознавания при использовании двухслойной нейронной сети для набора данных по изменению движения пациентов достигает 96,2 %. На том же наборе данных Daphnet один из лучших показателей зарубежных исследований составляет 98,8 % [12]. Однако матрица путаницы показывает, что средневзвешенный балл F1 тестового набора данных низок, всего 72,98 %, из-за несбалансированности набора данных. Данные о движении в наборе данных содержат сведения о различных его формах. Эти данные смешанные, что приводит к снижению точности распознавания БП.

³URL: <https://archive.ics.uci.edu/ml/datasets/parkinsons>

Заключение. Частотно-временные (вейвлет-) характеристики в исследованиях включали энтропию энергии вейвлета, энергию вейвлета, дисперсию коэффициента вейвлета, малую длину волны и коэффициент вейвлета. Методом извлечения признаков PCA было получено десять вейвлет-признаков. Алгоритм KNN применялся при распознавании речи пациентов, точность теста 94,7 % была достигнута при диагностике БП по изменению голоса. Алгоритм байесовской нейронной сети был использован для распознавания замедления движений пациентов, при диагностике БП он дал точность теста 96,2 %.

Результаты экспериментов показывают, что раннее выявление БП на основании данных об изменении голоса и движения является довольно эффективным. Видно также, что большое влияние на результаты экспериментов оказывает набор данных. Более сбалансированный набор данных с большим объемом может обеспечить лучшие результаты распознавания.

ИТ-технология для распознавания БП имеет прикладной характер и высокую исследовательскую значимость. Дальнейшая работа в этом направлении может заключаться в анализе частотно-временных характеристик и исследовании влияния количества различных вейвлетов, уровней разложения вейвлетов и их статистических характеристик на точность распознавания. Частота дискретизации набора данных также может быть увеличена. Увеличение частоты дискретизации позволит собирать более полную информацию для получения лучших вейвлет-характеристик. Кроме того, эксперимент с большим набором данных и сбалансированными категориями данных о БП даст более объективные и точные результаты.

Вклад авторов. В. А. Вишняков предложил концепцию, методы исследования, утвердил окончательный вариант статьи для публикации. Ся Ивэй реализовал алгоритмы и провел экспериментальные исследования.

References

1. Davie C. A. A review of Parkinson's disease. *British Medical Bulletin*, Feb. 2008, vol. 86, no. 1, pp. 109–127. <https://doi.org/10.1093/bmb/ldn013>
2. Braak H., Ghebremedhin E., Rüb U., Bratzke H., Tredici K. D. Stages in the development of Parkinson's disease-related pathology. *Cell and Tissue Research*, October 2004, vol. 318, no. 1, pp. 121–134. <https://doi.org/10.1007/s00441-004-0956-9>
3. Upadhyaya S. S., Cheeran A. N. Discriminating Parkinson and healthy people using phonation and cepstral features of speech. *Procedia Computer Science*, January 2018, vol. 143, pp. 197–202. <https://doi.org/10.1016/j.procs.2018.10.376>
4. Voiceprint recognition of Parkinson Patients Based on Deep Learning [Electronic resource] / Z. Xu [et al.]. – Dec. 2018. – P. 1–10. – Mode of access: <https://arxiv.org/ftp/arxiv/papers/1812/1812.06613.pdf>. – Date of access: 12.11.2022.
5. Transformers for 1D Signals in Parkinson's Disease Detection from Gait [Electronic resource] / D. M. D. Nguyen [et al.]. – Apr. 2022. – P. 1–7. – Mode of access: <https://arxiv.org/pdf/2204.00423.pdf>. – Date of access: 12.11.2022.
6. Arshad H., Khan M. A., Sharif M., Yasmin M., Javed M. Y. Multi-level features fusion and selection for human gait recognition: an optimized framework of Bayesian model and binomial distribution. *International Journal of Machine Learning and Cybernetics*, December 2018, vol. 10, no. 12, pp. 3601–3618. <https://doi.org/10.1007/s13042-019-00947-0>
7. Maachi I. E., Bilodeau G.-A., Bouachir W. Deep 1D-Convnet for accurate Parkinson disease detection and severity prediction from gait. *Expert Systems with Applications*, May 2020, vol. 143, pp. 1–27. <https://doi.org/10.1016/j.eswa.2019.113075>
8. Moro-Velazquez L., Gomez-Garcia J. A., Arias-Londoño J. D., Dehak N., Godino-Llorente J. I. Advances in Parkinson's Disease detection and assessment using voice and speech: A review of the articulatory and phonatory aspects. *Biomedical Signal Processing and Control*, April 2021, vol. 66, pp. 1–13. <https://doi.org/10.1016/j.bspc.2021.102418>
9. Zhang M.-L., Zhou Z.-H. ML-KNN: A lazy learning approach to multi-label learning. *Pattern Recognition*, 2007, vol. 40, no. 7, pp. 1–21.

10. Sakar C. O., Serbes G., Gunduz A., Tunc H. C., Nizam H., ..., Apaydin H. A comparative analysis of speech signal processing algorithms for Parkinson's disease classification and the use of the tunable Q-factor wavelet transform. *Applied Soft Computing*, January 2019, vol. 74, pp. 255–263. <https://doi.org/10.1016/j.asoc.2018.10.022>
11. Sakar B. E., Isenkul M. E., Sakar C. O., A. Sertbas, Gurgun F., ..., Kursun O. Collection and analysis of a Parkinson speech dataset with multiple types of sound recordings. *IEEE Journal of Biomedical and Health Informatics*, 2013, vol. 17(4), pp. 828–834.
12. Fawcett T. An introduction to ROC analysis. *Pattern Recognition Letters*, 2006, vol. 27, no. 8, pp. 861–874.
13. Li B., Yao Z., Wang J., Wang S., Yang X., Sun Y. Improved deep learning technique to detect freezing of gait in Parkinson's disease based on wearable sensors. *Electronics*, 2020, no. 9(11), pp. 1–12.

Информация об авторах

Вишняков Владимир Анатольевич, доктор технических наук, профессор кафедры инфокоммуникационных технологий, Белорусский государственный университет информатики и радиоэлектроники.

Ся Ивэй, аспирант кафедры инфокоммуникационных технологий, Белорусский государственный университет информатики и радиоэлектроники.

Information about the authors

Uladzimir A. Vishniakou, D. Sc. (Eng.), Professor of the Department of Infocommunication Technologies, Belarusian State University of Informatics and Radioelectronics.

Xia Yiwei, Postgraduate Student of the Department of Infocommunication Technologies, Belarusian State University of Informatics and Radioelectronics.