

УДК 004.93.1

КЛАССИФИКАЦИЯ ЛЕЙКОЦИТОВ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ИЗОБРАЖЕНИЙ С НИЗКИМ РАЗРЕШЕНИЕМ

РАЦКЕВИЧ Д.Г., ДИК С.К.

*Белорусский государственный университет информатики и радиоэлектроники**Ул. П. Бровки, 6, Минск, 220013, Республика Беларусь*

Аннотация. Традиционные методы классификации часто не могут обрабатывать исходные изображения непосредственно. В задачах классификации предпочтительнее использовать автоматические методы, которые могут извлекать функции непосредственно из исходных данных. Эти обучаемые автоматические системы решают проблемы классификации без предварительных знаний данных. В данной работе были рассмотрены три классификатора: метод опорных векторов, метод опорных векторов с уменьшением размерности и свёрточная нейронная сеть. Предложенные классификаторы сравнивались с помощью экспериментов, проведенных на цитологических изображениях низкого разрешения мазков нормальной крови. Наилучшие результаты были получены с помощью свёрточной нейронной сети со скоростью распознавания, либо более высокими, либо сопоставимыми с классификаторами на основе метода опорных векторов для всех пяти типов лейкоцитов.

Ключевые слова: Классификация лейкоцитов, свёрточные нейронные сети, метод опорных векторов.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Для цитирования. Рацкевич Д.Г., Дик С.К. Классификация лейкоцитов с использованием свёрточных нейронных сетей для изображений с низким разрешением. Доклады БГУИР. 20**; **(*): ***_***.

CLASSIFICATION OF LEUKOCYTES USING CONVOLUTION NEURAL NETWORKS FOR LOW RESOLUTION IMAGES

Ratskevich D.G., Dick S.K.

*Belarussian State University of Informatics and Radioelectronics.**P. Brovki street 6, 220013 Minsk Republic of Belarus.*

Abstract. Traditional classification methods often cannot process images directly. In classification tasks, it is preferable to use automatic methods that can extract functions directly from raw data. These trainable automatic systems solve classification problems without prior knowledge of the data. Three classifiers have been considered in this paper: Support Vector Machine with Principal Component Analysis, Support Vector Machine without dimensional reduction, and the Convolutional Neural Network. The proposed classifiers were compared using experiments carried out on low resolution cytological images of normal blood samples. The best results were obtained using a convolution neural network with recognition rates either higher or comparable with classifiers based on the method of reference vectors for all five types of leukocytes.

Keywords: *WBC classification, convolutional neural network, support vector machine.*

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

For citation. Ratskevich D.G., Dick S.K. Classification of leukocytes using convolution neural networks for low resolution images. Doklady BGUIR. 20**; **(*): ***_***.

Введение

Классификация лейкоцитов является важным шагом, так как она может помочь гематологам в диагностике некоторых заболеваний крови, таких как лейкемия, иммунологические расстройства и некоторые виды рака. Процедура анализа может быть выполнена с помощью автоматического и ручного подходов к подсчету и классификации лейкоцитов. Ручная классификация лейкоцитов сопряжена со многими трудностями медицинского характера, в том числе с ошибками в точности результатов из-за ошибок выборки и статистических вероятностей, а также с низкой чувствительностью, специфичностью и прогностическими значениями [1]. Кроме того, некоторые автоматические подходы в лабораториях используют такие инструменты, как проточная цитометрия и автоматическая счетная машина для обнаружения и классификации лейкоцитов. Эти приборы не используют методы обработки изображений, и они могут рассчитывать и классифицировать лейкоциты количественно, а не качественно [2]. Поэтому необходимо разработать автоматическую систему, включающую в себя обработку изображений, обработку сигналов, распознавание образов или методы глубокого изучения, чтобы обеспечить качественную и количественную оценку, точные результаты и быструю обработку. Автоматическая классификация лейкоцитов состоит из шести этапов: получение изображения; пред-

варительная обработка изображения; сегментация; выделение и представление признаков; классификация ячеек; процесс оценки.

Теоретический анализ

Основными типами лейкоцитов являются: Гранулоциты, моноциты и лимфоциты. Из этих типов разработано семь подтипов. Гранулоциты могут быть классифицированы на нейтрофилы, базофилы или эозинофилы. Моноциты можно классифицировать в макрофаги или дендритные клетки, а лимфоциты – в В-лимфоциты или Т-лимфоциты [1,2].

Лейкоциты получают из костного мозга и находят в крови и лимфатической системе. Лейкоцит имеет ядро, которое часто большое и лоббированное, и это помогает отличить Лейкоцит от других клеток крови. Каждая структура лейкоцита состоит из ядра, цитоплазмы и клеточной стенки [1].

Ядра лейкоцитов имеют различные формы, текстуру и размеры и могут представлять одну или несколько долей в зависимости от реакции их специфических гранул с процессом окрашивания. Наиболее полезной информацией о форме, размере и текстуре для сегментации и классификации клеток являются ядра лейкоцитов [2]. Чтобы дать краткий обзор и перспективу, особенности и функции типов и подтипов лейкоцитов, а также информацию о форме ядер лейкоциты классифицируются следующим образом:

1) Гранулоциты – это фагоциты, обладающие способностью поглощать вирусы, бактерии и другие паразиты. В их цитоплазме имеются видимые гранулы или зерна, а также крупные вытянутые или лопастные ядра. Диаметр клетки составляет 12–20 мкм, и их нуклеолы не видны. Они составляют приблизительно 60% лейкоцитов. Подтипы гранулоцитов: нейтрофил, базофил и эозинофил [5]. Нейтрофилы являются частью врожденной иммунной системы и необходимой линией защиты от бактерий. Форма ядра напоминает скрученный стержень до сегментации. Они также известны как "полосовые нейтрофилы". Диаметр обычно находится в диапазоне 10–18 мкм. Цитоплазма умеренная или обильная с несколькими неспецифическими гранулами. Нейтрофилы составляют приблизительно 1%–3% периферических лейкоцитов. Диаметр сегментированной нейтрофильной клетки обычно колеблется в пределах 9–16 мкм. Они имеют многолопастное ядро (обычно три или четыре), и эти доли могут перекрываться или скручиваться [6]. Количество долей может увеличиваться в зависимости от возраста клетки. Например, гиперсегментированная нейтрофильная клетка имеет семь долей в зрелой стадии. Внутриклеточные гранулы видны в цитоплазме [5]. Базофилы выделяют антикоагулянтные вещества и антитела, способные бороться с реакциями гиперчувствительности в кровотоке. Они являются мельчайшими циркулирующими гранулоцитами. Базофильные гранулы в этой клетке большие и очень многочисленные, поэтому они часто маскируют ядро. Ядро часто бывает двустворчатым или несегментированным и редко разделяется на три или четыре доли. Средний диаметр колеблется в пределах примерно 10–15 мкм. Эозинофилы обладают способностью выделять из гранул токсины, убивающие патогенных микроорганизмов, таких как паразиты и черви. Они легко распознаются в окрашенных мазках по своим крупным гранулам. Ядро эозинофила часто имеет две доли, соединенные между собой полосой ядерного материала. Диаметр обычно колеблется в пределах 9–15 мкм. Они находятся между 1%–4% периферическими лейкоцитами [2, 5].

2) Моноциты стимулируют клетки остеокластов, способные растворять кость. Они являются самым крупным типом лейкоцитов. Их средний диаметр колеблется в пределах 10–30 мкм и часто называют мусорными клетками или фагоцитами. Они содержат только одно ядро, которое редко или почти не лопается. Форма ядра в моноцитах часто имеет форму изгиба (подкова) или почки (реновидная форма). Из моноцитных клеток могут развиваться два типа клеток: макрофаги и дендритные клетки [5]. Макрофаги – это фагоцитарные клетки, которые питаются любым типом мертвой клетки в организме. Они крупнее и живут дольше, чем нейтрофилы, и имеют крупное одиночное ядро, часто почечной формы. Они также способны действовать как антигенпрезентирующие клетки. Дендритные клетки способствуют развитию антигенного иммунитета. Форма ядра мала и имеет округлую форму, которая по мере созревания клетки превращается в большое ядро с неправильной звездооб-

разной формой и цитоплазматическими выступами (дендритами) [7].

3) Лимфоциты описываются в соответствии с размером и зернистостью цитоплазмы и могут иметь маленькое или большое ядро в зависимости от стадии созревания. Малые лимфоциты хорошо известны, а диаметр малого ядра колеблется в пределах 6–9 мкм, тогда как диаметр большого ядра составляет примерно 10–15 мкм. В нем содержится только одно ядро, которое редко или едва лепестковое [6,7]. Форма ядра слегка овальная или округлая и окрашена в темный цвет. Патологоанатомы не могут легко различить Т-клетки и В-клетки с помощью традиционных световых или электронных микроскопов. Они всегда используют оптический микроскоп для различения между ними. В В-лимфоцитах (В-клетках) вырабатываются антитела и белки, которые соединяются с инфицированными микробами или клетками организма и дифференцируются в плазматическую клетку на незрелой стадии. Они производятся в костном мозге. Они имеют овальные ядра. Они имеют низкий размер фрактала и гладкую поверхность клетки. Патологи инкубировали слайды с пятном Гимзы. Т-лимфоциты (Т-клетки) вырабатывают белки, называемые цитокинами, которые помогают направить ответ других клеток. У них есть круглые ядра и морщинистая поверхность клеток. Они окрашены в темно-синий цвет [6, 7].

Шаги, связанные с автоматической классификацией лейкоцитов, следующие:

1) Сбор изображений – первый процесс автоматизированной классификации. Важно знать, как входные изображения лейкоцитов берутся из образцов мазка периферийной крови на предметных стеклах микроскопа. Эти изображения получают, помещая слайды под составной или оптический микроскоп под освещением с высоким увеличением и записывая их цифровой камерой. Анализ под микроскопом начинается с меньшего увеличения 10x до 1000x. Качественные цифровые камеры фиксируют изображения для демонстрации, улучшения и наблюдения за клетками крови. Некоторые цифровые камеры могут использоваться независимо от самого микроскопа. Изображения сохраняются на внутренних картах памяти и загружаются на компьютер в виде 24-битной карты (bmp), изображения или видео совместной фотографической группы экспертов (jpeg). Другие коммерческие камеры не могут быть оптически подключены к микроскопу без дополнительной оптики. Как правило, результаты неудовлетворительны. Зеркальные камеры могут быть подключены оптически к микроскопам с помощью адаптеров SLR, которые доступны на большинстве микроскопов и изображения загружаются автоматически на компьютер [6]. Микроскопические изображения клеток получаются после процесса окрашивания, в результате которого ядра клеток и цитоплазма клетки окрашиваются в разные цвета, а фон изображения крови (плазмы). Лейкоцитарное окрашивание является методом, используемым для увеличения контрастности за счет изменения цвета некоторых частей структуры клетки, чтобы обеспечить более четкое представление о структуре клетки. Существуют различные микроскопические пятна, которые могут быть использованы, и он известен как "пятна Романовского". В пятне Романовского используется раствор метиленового синего для выявления малярийных паразитов в крови [1]. Этими типами пятен являются: пятна Дженнера, Нохта, Лейшмана, Гимзы, Райта и Лейшмана. Типы, используемые для окрашивания лейкоцитов: пятно Гимзы, пятно Райта, пятно Райта-Гимзы и пятно Лейшмана. Они точно сформулированы, оптимально и предсказуемо действуют при использовании ручного или автоматического окрашивания. Большинство из них окрашивают ядра в темно-фиолетовый или розовый цвет [6]. Пятна могут также обнаруживать гранулы, присутствующие в цитоплазме некоторых лейкоцитах. Процесс окрашивания дает достаточный контраст для сегментации, подсчета и классификации отдельных клеток. Изображения затем захватываются разными цифровыми камерами с разным разрешением.

2) Предварительная обработка или улучшение изображения – это улучшение данных изображения, которое подавляет нежелательные искажения, устраняет шумы или улучшает некоторые особенности изображения, важные для дальнейших исследований в процессах сегментации и классификации. Этап предварительной обработки также включает в себя геометрические преобразования изображений, такие как поворот, масштабирование и трансляция [8].

3) Процесс сегментации обнаруживает лейкоциты и их ядра и цитоплазму, и отличает их от эритроцитов, фона и плазмы изображения мазка периферической крови с помощью обработки изображений и методов обработки сигналов. Эти методы основаны на форме, цвете, краях или геометрии для сегментации. На сегодняшний день было предложено несколько методов и в сочетании с другими методами для обнаружения и сегментации лейкоцитов. К ним относятся методы порогового значения [9], морфологические операторы и анализ пространства масштаба [10], определение краев и границ [6] и метод установки уровня с помощью геометрических активных контуров [4]. Некоторые существующие методы включают цветовое пространство, такое как RGB, CMYK и HSV с пороговым значением Оцу [2], и цветовую полосу с пороговой процедурой в [8].

4) Представление выделения признаков является важным шагом в классификации лейкоцитов. Извлекаемые элементы включают геометрические особенности, такие как площадь, радиус, периметр, выпуклая область, длина основной оси, компактность и ориентация; текстурные элементы, такие как импульс, контраст, энтропия и асимметрия; и цветовые элементы, такие как цветовое распределение и гистограмма.

5) Процесс классификации отличает тип лейкоцита. Этот процесс может позволить оценить и диагностировать многие заболевания. Для классификации лейкоцитов использовались различные современные методы машинного обучения, такие как случайный лес, метод опорных векторов (SVM) и глубокое обучение (DL), включая искусственные нейронные сети (ANN), многослойные перцептроны (MLP) и гиперпрямоугольные композитные нейронные сети (HCNN) [14] и другие методы.

6) Процесс оценки является важным этапом в процессе классификации. Классификация оценивается с использованием числовой метрики, такой как точность, или графического представления производительности, такой как кривая эксплуатационных характеристик приемника (ROC). Точность является наиболее популярной мерой измерения производительности и представляет собой долю от общего числа классов прогнозирования, которые правильно классифицированы, и сравнивается с фактическим классом. Эти прогнозы вычисляются для создания матрицы путаницы: Истинные положительные результаты (TP) - выборки, которые были правильно классифицированы как положительные; истинные отрицательные результаты (TN) - выборки, которые были правильно классифицированы как отрицательные; ложные положительные результаты (FP) - выборки, которые были неправильно классифицированы как положительные; и ложные отрицательные результаты (FN) - выборки, которые были неправильно классифицированы как отрицательные. Эти параметры можно получить, используя протокол тестирования и обучения, основанный на методе удержания, перекрестной валидации [9].

Методика

Изображения лейкоцитов имеют низкое разрешение (28x28 пикселей) и небольшие размеры, где тонкая внутренняя структура едва заметна. В данном исследовании применим классификатор на основе метода опорных векторов. Данный метод широко используется в связи с его способностью работать с объемными данными и эффективностью при моделировании различных источников данных. В методе опорных векторов построена максимальная граница, разделяющая гиперплоскость в высокоразмерном пространстве признаков. Нелинейное отображение ядра во входном пространстве позволяет построить границы решений, которые являются нелинейными во входном пространстве. Типичными функциями ядра, используемыми в приложениях, являются радиальные базисные функции (РБФ), сигмоидальные и полиномиальные ядра. В методе опорных векторов используется жесткое или мягкое поле (последнее позволяет классификатору неправильно классифицировать некоторые точки). Метод опорных векторов предназначен для решения двуклассных задач

Параметры ядра оказывают непосредственное влияние на границу решения метода опорных векторов [7]. В текущем исследовании использовалось полиномиальное ядро наименьшей степени, т.е. линейное ядро (полином с $D = 1$). Полиномиальные ядра приводят к переполнению высокоразмерной задачи с большим количеством интенсивностей и особенностей гистограммы с небольшим

набором входных данных (по 28 выборок для каждого из пяти классов WBC) [16].

В данном исследовании использовался метод опорных векторов с линейной функцией полиномиального ядра, софт-маржинальную и однодоменную (1AA) стратегию с 5-кратной валидацией, использующую особенности интенсивности и гистограммы, а также особенности, генерируемые методом главных компонент. Для оптимизации параметров набор данных далее делится на два подмножества, состоящих из 85% выборок для обучения, а остальные 15% – для настройки и тестирования.

С учетом небольшого набора данных по обучению и настройке, состоящего из пяти основных классов, каждый из которых включает 28 выборок (всего $5 \cdot 28 = 140$ выборок). Каждая выборка описывается 896-мерным характерным вектором ($28 \cdot 28$ (значения интенсивности) + $4 \cdot 28$ (среднее, стандартное отклонение, асимметрия, вычисляется по 28 столбцам изображения шириной в один пиксель)).

Так же в работе применялись свёрточные нейронные сети (СНН) для автоматического извлечения признаков из изображений лейкоцитов, подлежащих классификации. Исследовались свёрточные нейронные сети [5], которые чувствительны к топологии классифицируемых изображений. Свёрточная нейронная сеть представляет собой многослойный перцептрон со специальной топологией, содержащей более одного скрытого слоя. Она допускает автоматическое выделение признаков в своей архитектуре в качестве исходных данных. СНН используется для распознавания объектов [10] и рукописных символов [8, 9]. СНН использует метод обратной связи для подачи нейронов и обратного распространения для обучения параметрам. Основным преимуществом СНН является способность автоматически извлекать топологические свойства из необработанного серого изображения и генерировать предсказания для классификации высокоразмерных шаблонов. СНН состоит из двух отдельных частей. Первая часть состоит из нескольких слоев, которые извлекают свойства из входного изображения композицией из слоев свертывания и субдискретизации. Концептуально, визуальные особенности из локальных рецептивных полей [8] извлекаются методом расширенной двумерной свертки для получения соответствующей пространственно-локальной корреляции, присутствующей во входных изображениях. Так как точное местоположение извлекаемого объекта является несущественным и несущественным, уменьшение разрешения на два объекта происходит через слои субдискретизации. Вторая отдельная часть классифицирует шаблон по классам. В общем случае СНН состоит из трех различных слоев: слоя свертки, слоя субдискретизации (макс-дискретизации) и ансамбля полностью связанных слоев.

В исследовании применялась СНН с архитектурой LeNet5 [10] (рисунок 1). В первых слоях (свойствах экстракторов) над изображением накладываются свёрточные фильтры в окне пикселей 5×5 . Настоятельно рекомендуется добавлять по два пустых пикселя в каждом из четырех направлений, чтобы избежать пропуска реальных данных на каждой границе при вычислениях сверток. Количество альтернативных трех основных слоев зависит от входной базы данных и может варьироваться между различными входными размерами для получения лучшей производительности и уверенности. В данной работе используется LeNet5 с восемью слоями (включая первый слой в качестве входного изображения в градациях серого, а также выходной слой). Каждый свёрточный слой (С-слой) имеет различные карты характеристик, C_1 состоит из 6 единиц, C_3 – из 16, C_5 – из 120. Также из-за размера окон свертки 5×5 и входного размера 28×28 , размер каждого слоя свертки определяется, как показано на рисунке 1: C_1 – 28×28 , C_3 – 10×10 , а C_5 – 1×1 , один нейрон.




Рис. 1. Структура сети LeNet-5 для изображения размером 28x28

Fig.1. LeNet-5 network structure for 28x28 image size

Результаты и их обсуждение

Ниже представлены результаты классификации лейкоцитов, полученные в результате применения предложенных подходов на существующей базе данных (115 образцов обучения и 25 тестовых) с использованием трех типов классификаторов: Метод опорных векторов с интенсивностью и особенностями гистограммы, метод опорных векторов с методом главных компонент и свёрточные нейронные сети. Матрицы ошибок и коэффициенты ошибок приведены в таблицах 1–3:

Таблица 1. Матрица ошибок для свёрточной нейронной сети

Table 1. Confusion matrix for the convolution neural network

| | Базофил Basophil | Эозинофил Eosinophil | Лимфоцит Lymphocyte | Моноцит Monocyte | Нейтрофил Neutrophil |
|--------------------------|---------------------|-------------------------|------------------------|---------------------|-------------------------|
| Базофил Basophil | 0.625 | 0.125 | 0.250 | 0 | 0 |
| Эозинофил Eosinophils | 0 | 0.95 | 0.05 | 0 | 0 |
| Лимфоцит Lymphocyte | 0.125 | 0 | 0.875 | 0 | 0 |
| Моноцит Monocyte | 0 | 0 | 0 | 0.80 | 0.20 |
| Нейтрофил Neutrophil | 0 | 0 | 0 | 0.015 | 0.985 |

Таблица 2. Матрица ошибок для метода опорных векторов с применение метода главных компонент

Table 2. Confusion matrix for the support vector machine with application of the principal component analysis

| | Базофил Basophil | Эозинофил Eosinophil | Лимфоцит Lymphocyte | Моноцит Monocyte | Нейтрофил Neutrophil |
|-------------------------|---------------------|-------------------------|------------------------|---------------------|-------------------------|
| Базофил Basophil | 0.60 | 0 | 0.30 | 0.10 | 0 |
| Эозинофил Eosinophil | 0 | 1.0 | 0. | 0 | 0 |
| Лимфоцит Lymphocyte | 0.30 | 0.10 | 0.60 | 0 | 0 |
| Моноцит Monocyte | 0 | 0 | 0.20 | 0.80 | 0 |
| Нейтрофил Neutrophil | 0.10 | 0 | 0.20 | 0 | 0.70 |

Таблица 3. Матрица ошибок для метода опорных векторов без снижения размерности

Table 3. Confusion matrix for the support vector machine without dimension reduction

| | Базофил Basophil | Эозинофил Eosinophil | Лимфоцит Lymphocyte | Моноцит Monocyte | Нейтрофил Neutrophil |
|---------|---------------------|-------------------------|------------------------|---------------------|-------------------------|
| Базофил | 0.30 | 0 | 0.70 | 0 | 0 |

| | | | | | |
|-------------------------|------|------|------|------|------|
| Basophil | | | | | |
| Эозинофил Eosinophil | 0 | 1.0 | 0 | 0 | 0 |
| Лимфоцит Lymphocyte | 0.40 | 0.10 | 0.50 | 0 | 0 |
| Моноцит Monocyte | 0.20 | 0 | 0 | 0.80 | 0 |
| Нейтрофил Neutrophil | 0 | 0 | 0.10 | 0.20 | 0.70 |

В таблицах приведены матрицы ошибок для тестирования изображений лейкоцитов. В частности, для нормальных лейкоцитов, используя СНН, 85% известных лейкоцитов были классифицированы как таковые, при этом этот коэффициент классификации уменьшился до 74% для метода опорных векторов с применением метода главных компонент, и до 66% для метода опорных векторов без снижения размерности. Таким образом, основываясь на матрицах ошибок с пятью классами, предлагаемый классификатор СНН намного надежнее и точнее даже при наличии сходства между классами (особенно между Базофилом и Лимфоцитом) в этой сложной базе данных, что дает приемлемую точность при сравнении с методом опорных векторов.

СНН дает ложноположительную оценку в 14%, т.е. доля отрицательных выборок, неправильно классифицированных как положительные, при этом эта частотность увеличивается до 23% для метода опорных векторов с применением метода главных компонент, а затем до 31% для метода опорных векторов без снижения размерности. Ложноположительная оценка СНН также меньше, чем ложноположительная оценка метода опорных векторов с применением метода главных компонент, и это еще раз подтверждает эффективность автоматического извлечения элементов СНН.

Классификатор СНН обладает наилучшей точностью, оптимизируя топологические характеристики в сложной базе данных, содержащей малое количество изображений без ограничений по условиям фона или захвата. Еще одним преимуществом СНН является автоматическое извлечение функций, в то время как в большинстве других классификаторов эти функции выбираются разработчиком.

Заключение

Целью исследования является разработка надежной автоматической системы подсчета клеток лейкоцитов. В этом контексте мы рассмотрели новый подход автоматической функции извлечения и классификация лейкоцитов с использованием сверточной нейронной сети. Для проверки эффективности СНН было проведено сравнение с более широко используемым классификатором на базе метода опорных векторов со стандартными характеристиками (с сокращением размерности и без). Как показывают матрицы ошибок даже в случае некачественных образцов (грязные изображения, маленькие и выцветшие клетки) более точным является классификатор, основанный на СНН а не классификатор, основанный на методе опорных векторов.

Результаты экспериментов показывают, что система, основанная на СНН, предлагает усовершенствованную точность распознавания даже при наличии некачественных образцов. Ожидается, что точность классификации будет еще выше при увеличении набора данных (особенно, чтобы избежать путаницы между базофилами и лимфоцитами в виду того что их формы очень похожи при небольшом увеличении изображения), а также путем оптимизации структуры СНН для достижения более высокой производительности. в обучении и тестировании.

Список литературы

1. Ben-Hur, A., Weston, J.: A user's guide to support vector machines. In: Carugo, O., Eisenhaber, F. (eds.) Data Mining Techniques for the Life Sciences. Methods in Molecular Biology 2010 – vol. 609, pp. 223–239. Humana Press.
2. Breiman, L.: Random forests. Machine Learning 45(1), 2001 – 5–32.

3. Chan, H., Li-Jun, J., Jiang, B.: Wavelet transform and morphology image segmentation algorithm for blood cell. In: 4th IEEE International Conference on Industrial Electronics and Applications, Xi'an, China, May 25-28 2009 – pp. 542–545.
4. Comaniciu, D., Meer, P.: Cell image segmentation for diagnostic pathology. In: *Advanced Algorithmic Approaches to Medical Image Segmentation*, Springer, New York 2002 – pp. 541–558.
5. Cortes, C., Vapnik, V.: Support-vector networks. *Machine Learning* 20(3), 2000 – 273–297.
6. Dorini, L.B., Minetto, R., Leite, N.: Semi-automatic white blood cell segmentation based on multiscale analysis. *IEEE 2012 – Transactions on Information Technology in Biomedicine*.
7. Duda, R.O., Hart, P.E., Stork, D.G.: *Pattern Classification*, 2nd edn. Wiley- Interscience November 2001.
8. Habibzadeh, M., Krzyżak, A., Fevens, T.: Application of pattern recognition techniques for the analysis of thin blood smear images. *Journal of Medical Informatics & Technologies*, 2018 – 18, 29–40.
9. Habibzadeh, M., Krzyżak, A., Fevens, T.: Analysis of white blood cell differential counts using dual-tree complex wavelet transform and support vector machine classifier. In: Bolc, L., Tadeusiewicz, R., Chmielewski, L.J., Wojciechowski, K. (eds.) *ICCVG 2012 – vol. 7594*, pp. 414–422.
10. Habibzadeh, M., Krzyżak, A., Fevens, T., Sadr, A.: Counting of RBCs and WBCs in noisy normal blood smear microscopic images. In: *SPIE Medical Imaging: Computer-Aided Diagnosis*, Orlando, FL, USA, 2011 – February 12-17, vol. 7963, p. 79633.

References

1. Ben-Hur, A., Weston, J.: A user's guide to support vector machines. In: Carugo, O., Eisenhaber, F. (eds.) *Data Mining Techniques for the Life Sciences. Methods in Molecular Biology* 2010 – vol. 609, pp. 223–239. Humana Press.
2. Breiman, L.: Random forests. *Machine Learning* 45(1), 2001 – 5–32.
3. Chan, H., Li-Jun, J., Jiang, B.: Wavelet transform and morphology image segmentation algorithm for blood cell. In: 4th IEEE International Conference on Industrial Electronics and Applications, Xi'an, China, May 25-28 2009 – pp. 542–545.
4. Comaniciu, D., Meer, P.: Cell image segmentation for diagnostic pathology. In: *Advanced Algorithmic Approaches to Medical Image Segmentation*, Springer, New York 2002 – pp. 541–558.
5. Cortes, C., Vapnik, V.: Support-vector networks. *Machine Learning* 20(3), 2000 – 273–297.
6. Dorini, L.B., Minetto, R., Leite, N.: Semi-automatic white blood cell segmentation based on multiscale analysis. *IEEE 2012 – Transactions on Information Technology in Biomedicine*.
7. Duda, R.O., Hart, P.E., Stork, D.G.: *Pattern Classification*, 2nd edn. Wiley- Interscience November 2001.
8. Habibzadeh, M., Krzyżak, A., Fevens, T.: Application of pattern recognition techniques for the analysis of thin blood smear images. *Journal of Medical Informatics & Technologies*, 2018 – 18, 29–40.
9. Habibzadeh, M., Krzyżak, A., Fevens, T.: Analysis of white blood cell differential counts using dual-tree complex wavelet transform and support vector machine classifier. In: Bolc, L., Tadeusiewicz, R., Chmielewski, L.J., Wojciechowski, K. (eds.) *ICCVG 2012 – vol. 7594*, pp. 414–422.
10. Habibzadeh, M., Krzyżak, A., Fevens, T., Sadr, A.: Counting of RBCs and WBCs in noisy normal blood smear microscopic images. In: *SPIE Medical Imaging: Computer-Aided Diagnosis*, Orlando, FL, USA, 2011 – February 12-17, vol. 7963, p. 79633.

Сведения об авторах

Рацкевич Дмитрий Геннадьевич, аспирант каф. ЭТТ Белорусского государственного университета информатики и радиоэлектроники; Ведущий инженер по медицинскому оборудованию ООО «ВЭМ инжиниринг».

Дик Сергей Константинович, кандидат физико-математических наук, доцент, депутат Палаты представителей Национального собрания Республики Беларусь VII созыва.

Information about the authors

Ratskevich Dzmitry, PhD student Electronic Technology and Engineering Department, Belarussian State University of Informatics and Radioelectronics. Senior medical equipment engineer. «WEM engineering» LLC

Dick Sergey, PhD, Deputy of the House of Representatives of the National Assembly of the Republic of Belarus of VII convocation.

Адрес для корреспонденции

220104, Республика Беларусь,

Address for correspondence

МЕДЭЛЕКТРОНИКА–2020. СРЕДСТВА МЕДИЦИНСКОЙ ЭЛЕКТРОНИКИ И НОВЫЕ МЕДИЦИНСКИЕ ТЕХНОЛОГИИ

г. Минск, ул. Жудро, 33, кв.92
тел. +375(29)351-79-72 (A1);
e-mail: ratskevichdg@gmail.com
Рацкевич Дмитрий Геннадьевич

220104, Republic of Belarus,
Minsk, Zhudro str. 33, apartment 92,
tel. +375(29)351-79-72 (A1);
e-mail: ratskevichdg@gmail.com
Dzmitry Ratskevich