

# ТЕОРЕТИЧЕСКИЕ ОСНОВЫ ИНФОРМАТИКИ (05.13.17)

УДК 007:519.816

DOI: 10.24160/1993-6982-2020-5-140-147

## Методы и программные средства для анализа и диагностики сложных патологий зрения

А.П. Еремеев, С.А. Ивлиев

Работа посвящена актуальным вопросам, связанным с разработкой перспективных интеллектуальных систем поддержки принятия решений (ИСППР) при анализе и диагностике сложных проблемных ситуаций на примере диагностики сложных патологий зрения. Цель исследования — разработка прототипа ИСППР, который позволял бы строить в автоматическом режиме заключения о возможном диагнозе на основе результатов медицинских исследований, получаемых со специального аппарата (электроретинографа), результатов обследования пациента и знаний экспертов-физиологов. Электроретинографией называют метод оценки функционального состояния сетчатки, основанный на регистрации биопотенциалов, возникающих в ней при световом раздражении, а отображающую их кривую именуют электроретинограммой.

Используемые методы включают в себя методы построения онтологий, нейронных сетей, обратной разработки приложений, построения ИСППР на основе экспертных знаний и человеко-машинных интерфейсов. Рассмотрены также методы для предварительной (препроцессорной) обработки больших данных и организации их хранения в специализированной базе данных, а также отображения выдаваемых системой результатов (диагностических решений). Новизна предлагаемого подхода состоит в интеграции ряда методов, а также обосновании применения онтологии и нереляционной модели (базы данных), в плане расширения сферы их применения на ранние стадии заболевания и повышения качества диагностики патологий зрения. Указаны разработанные программные средства прототипа ИСППР.

Представленные исследования и разработки выполнены совместно кафедрой прикладной математики и искусственного интеллекта НИУ «МЭИ» и отделом клинической физиологии зрения Московского НИИ глазных болезней им. Гельмгольца.

*Ключевые слова:* искусственный интеллект, поддержка принятия решений, обработка и анализ данных, нейронная сеть, диагностика, патология зрения.

*Для цитирования:* Еремеев А.П., Ивлиев С.А. Методы и программные средства для анализа и диагностики сложных патологий зрения // Вестник МЭИ. 2020. № 5. С. 140—147. DOI: 10.24160/1993-6982-2020-5-140-147.

## Methods and Software for Analysis and Diagnostics of Complex Vision Pathologies

A.P. Ereemeev, S.A. Ivliev

The article addresses topical matters concerned with development of prospective intelligent decision making support systems (IDMSS) in analysis and diagnostics of complex problem situations taking complex vision pathologies as an example. The aim of the research is to develop an IDMSS prototype that would make it possible to automatically draw conclusions about a possible diagnosis based on the results of medical studies obtained from a special apparatus (an electroretinograph), patient examination results, and the knowledge of expert physiologists. Electroretinography is a method for assessing the functional state of the retina, which is based on recording the biopotentials arising in it during light stimulation, and the curve that images them is called the electroretinogram.

The applied methods include those for constructing ontologies, neural networks, inverse development of applications, and constructing an IDMSS based on expert knowledge and human-machine interfaces. Methods for preliminary (preprocessor) processing of large data and for arranging their storage in a dedicated database and for displaying the results (diagnostic solutions) produced by the system are also considered. The novelty of the proposed approach consists in integrating several methods and in justifying the use of ontology and non-relational model (database) in terms of expanding their scope at the early stages of the disease and improving the quality of diagnosing visual pathologies. The developed software tools of the IDMSS prototype are pointed out.

The presented studies and developments have been carried out jointly by the Department of Applied Mathematics and Artificial Intelligence of the National Research University Moscow Power Engineering Institute (NRU MPEI) and the Department of Clinical Physiology of Vision of the Helmholtz Moscow Research Institute of Eye Diseases.

*Key words:* artificial intelligence, decision making support, data processing and analysis, neural network, diagnostics, pathology of vision.

*For citation:* Eremeev A.P., Ivliev S.A. Methods and Software for Analysis and Diagnostics of Complex Vision Pathologies. Bulletin of MPEI. 2020;5:140—147. (in Russian). DOI: 10.24160/1993-6982-2020-5-140-147.

## Введение

Рассмотрены алгоритмы, методы и программные средства, а также их интеграция в плане создания перспективных интеллектуальных систем поддержки принятия решений (ИСППР) при анализе и диагностике проблемных ситуаций на примере сложных патологий зрения с применением предварительной (препроцессорной) обработки данных, онтологий и нейросетевого подхода. Создаваемая ИСППР предназначена для выдачи в автоматическом режиме диагностического заключения по имеющейся у пациента патологии зрения на основе результатов медицинских исследований, получаемых при осмотре пациента с применением электроретинографа, и заложенных в ИСППР знаний экспертов-физиологов, используемых при диагностике [1 — 3]. С помощью электроретинографа проводят процедуру электроретинографии — оценки функционального состояния сетчатки глаза на основе регистрации биопотенциалов, возникающих в ней при световом раздражении. Результатом процедуры является электроретинограмма (ЭРГ), пример которой представлен на рис. 1.

ЭРГ состоит из трех основных компонент: начальной  $a$ -волны,  $b$ -волны и поздних  $c$ - и  $d$ -волн. Максимальная ЭРГ отражает электрическую активность большинства клеточных элементов сетчатки и зависимость от количества здоровых функционирующих клеток. Различные типы ЭРГ отражают все многообразие структуры сетчатки и позволяют проводить раннюю и дифференциальную диагностики заболеваний сет-

чатки. Негативная  $a$ -волна отражает функцию фоторецепторов как начальную часть позднего рецепторного потенциала. Более ранняя  $a_1$ -волна связана с активностью фотопической системы сетчатки,  $a_2$ -волна — со скотопической системой. Затем  $a$ -волна переходит в позитивную  $b$ -волну, характеризующую биоэлектрическую активность сетчатки, представленную волнами  $b_1$  и  $b_2$ . Волны  $c$  и  $d$  показывают процесс затухания и малоинформативны для постановки диагноза.

В последние годы в области компьютеризации диагностики патологий зрения методами, связанными с использованием специализированных диагностических аппаратов, в том числе, электроретинографов, выдвинулось направление, связанное с поиском новых значащих параметров ЭРГ и их анализ с применением методов искусственного интеллекта [3 — 5]. Новизна предлагаемого подхода состоит в интеграции ряда методов, а также обосновании применения онтологии и нереляционной модели (базы данных) в плане расширения сферы их применения на ранние стадии заболевания и повышение качества диагностики патологий зрения.

## Анализ предметной области

Основные сложности, возникшие со сбором данных о предметной области (анализируемых патологиях зрения), следующие:

- отсутствие автоматизации врачебной деятельности в области ведения историй болезни;
- использование в деятельности родственных медицинских организаций различных аппаратов с записью




Рис. 1. Схематическое изображение максимальной ЭРГ:

$a_1, a_2, b_1, b_2$  — амплитуды  $a$ - и  $b$ -волн;  $D$  — длительность  $b$ -волн;  $L$  — латентный период;  $Tb$  — время кульминации; по осям ординат и абсцисс отложены амплитуда и длительность волн ЭРГ

данных без возможности их экспорта во внешние системы (базы данных (БД));

- зашумлённость данных (наличие пропусков и малоинформативных данных), получаемых диагностическими аппаратами;

- наличие ошибок при сборе данных.

В связи с этим необходима разработка системы (и соответствующей БД) для хранения и анализа специализированных диагностических данных типа ЭРГ, позволяющей интегрировать источники данных, получаемые с разных аппаратов (в том числе из других учреждений), а также взаимодействовать с экспертами с целью создания ИСППР для диагностики сложных патологий зрения с применением современных методов интеллектуального анализа данных и поиска решений [5 — 7].

Исходя из экспертных данных [8], выделены основные наблюдаемые параметры, извлечение и анализ которых важны для последующей диагностики с применением нейросетевого подхода:

- диск зрительного нерва (ДЗН) — структура нерва глаза, при его анализе, в первую очередь, обращают внимание на цвет и границы;

- макула глаза — анатомическая структура, обеспечивающая цветовое восприятие зрительного образа (необходимо получение снимка макулы для дальнейшего анализа нейронными сетями) [5];

- периферическое зрение — зрительное восприятие, ответственное за способность видеть в сумеречное и тёмное время суток;

- поле зрения — угловое пространство, видимое глазом при фиксированном взгляде и неподвижной голове;

- данные оптической когерентной томографии, позволяющие визуализировать структуры глаза в поперечном срезе;

- острота зрения — возможность глаза видеть различительно две точки при максимальном их сближении.

Помимо отмеченных параметров для постановки диагноза необходимо наличие стандартной статистической информации о пациентах: возраст, пол, вредные привычки (алкоголизм, курение, наркомания) и т.д.

Для любой системы, связанной с анализом больших и гетерогенных, как в рассматриваемом случае, данных, требуется соответствующая модель и поддерживающая ее система для хранения и обработки информации [9]. В связи с этим проведен сравнительный анализ классической реляционной и нереляционной моделей представления данных.

В качестве примера обрабатываемых данных взята история болезни пациента, содержащая следующую информацию:

- результаты обследований специалистами, записанные на естественном языке;

- итоги анализов, представляющие из себя ряды данных, кортежи (наименование, значение), фотоматериалы (снимки).

Помимо распределённости данных во времени, что сложно учесть в реляционных моделях, требуются реализации дополнительных средств для работы с временными (темпоральными) данными (в виде временных рядов), данными, представленными на естественном языке и в виде изображений [10].

### Построение онтологии предметной области

Пусть БД и база знаний (БЗ) хранят как данные, так и получаемые из них знания. Тогда количество соответствующих таблиц в БД/БЗ будет расти по мере использования новых форм знаний. При этом качество доступа к сырым (зашумленным) данным — невысокое, поскольку используется деление изначальной сущности (обследования) на искусственные подсущности. Стоит отметить сложности с масштабируемостью, переносимостью и обработкой больших массивов данных в обычных реляционных БД (РБД) [11,12].

В результате сравнительного анализа предложено использование нереляционной модели (базы данных, НБД) на основе NoSQL, как альтернативы традиционным РБД [6, 11]. В отличие от концепции ACID (Atomicity (атомарность), Consistency (согласованность), Isolation (изолированность), Durability (надёжность)), используемой в РБД, в НБД взята за основу концепция BASE [13], что позволяет применять ее для решения задач, связанных с гетерогенной средой, так как нет необходимости хранения чётких схем данных.

Важнейшее свойство НБД — возможность хранения документов как единых сущностей. Это помогает эффективно организовывать разные виды обработки данных и поиска в знаниях (например, используя алгоритм MapReduce [14]), а также создавать новые формы хранения знаний и получения их из данных путём дополнения уже имеющихся документов и установления между ними связей, используя онтологии для интеллектуального анализа данных. В работе [15] показан пример использования онтологий, созданных на основе НБД в среде NoSQL, для представления геномных данных. В нашем случае следует использовать документные НБД с предварительным построением онтологии.

В качестве базовых элементов онтологии рассмотрим следующие.

Понятия (классы):

- обследование (*O*) — представляет данные некоторого обследования в виде документа полностью или неполностью определённой структуры;

- назначение (*N*) — конечный результат, выданный экспертом на основании анализа данных одного или нескольких обследований;

- знание (*Z*) — итог получения знаний из данных автоматическими методами (методами машинного обучения) либо в результате формирования при помощи опросников и/или других методов прямого получения знаний от экспертов;

— документ порождения ( $DR$ ) — документ, создаваемый при генерации новых документов с применением отношений порождения  $R_x$ .

Отношения:

— порождения ( $R_{gen}$ ) — порождение  $Z$  из множеств (классов)  $O, Z, N$ ;

— обобщения ( $R_{int}$ ) — порождение (расширение)  $Z$  из множества (класса)  $Z$ ;

— заключения ( $R_{sum}$ ) — порождение  $N$  из множества (класса)  $Z$  на основании экспертного заключения.

### Анализ нестационарных сигналов

Применительно к задаче диагностики возможно использование при анализе стационарных сигналов аппарата нейронных сетей. Однако при этом возникает проблема размерности (аналогичная анализу больших данных). Для её решения следует использовать для предварительной обработки данных дискретное вейвлет-преобразование (ДВП), доказавшее свою эффективность в сочетании с простой нейронной сетью при дифференциальной диагностике ряда патологий зрения [16]. На рисунке 2 изображен пример ЭРГ после применения ДВП. Относительно исходной ЭРГ (см. рис. 1) сохранена форма и часть характеристик, но исключены некоторые детали. Таким образом, ДВП реализует сжатие информации с потерей некоторых данных, что может привести к проблеме поиска скрытых закономерностей.

В связи с этим предложен достаточно эффективный метод обработки нестационарных сигналов на основе непрерывного вейвлет-преобразования (НВП), выделяющего характеристики не только в частотной, но и во временной (темпоральной) областях. Результатом НВП стала матрица, получаемая при свёртке некоторой вейвлет-функции (функции, удовлетворяющей опреде-




Рис. 2. ЭРГ после применения ДВП

лённым условиям) с сигналом. При лучшей по сравнению с ДВП репрезентацией сигнала при этом возможно существенное разрастание набора входных данных [16, 17]. Новые разработки в области нейронных сетей предлагают методы анализа данных, успешно примененные при медицинской диагностике [18, 19].

За последние 5 лет широкое распространение получили свёрточные нейронные сети (Convolutional Neural Network, CNN), основанные на разбиении матрицы входных данных на некоторые блоки и свёртки их с определёнными ядрами, которые являются матрицами, кодирующими графическое представление какого-либо признака. Они хорошо показали себя в задачах кластеризации сложных образов [20]. На рисунке 3 дана обобщенная структура CNN [21]:

Слой свёртки реализует обработку изображения по фрагментам, проводя операцию свёртки при помощи ядра (матрицы, коэффициенты которой подбираются в процессе обучения). Слой голосования вычисляет одно значение от нескольких результатов свёртки предыдущего слоя с целью сокращения размерности, при этом чаще всего используется функция взятия максимума, т. е. данный слой фактически выбирает наиболее сильно проявленные признаки. Итоговая полносвязная сеть необходима для построения отображения из пространства выделенных признаков в пространство определённых классов. Она позволяет с высокой точностью классифицировать входные данные.

На основе CNN может быть сформирован некоторый набор признаков, которые изначально не могут быть определены даже экспертом, но проявляются в процессе обучения. Однако метод, базирующийся на использовании CNN, требует наличия большой выборки входных данных, что ограничивает его практическое применение. При этом данные должны быть отнесены к определённым классам, что также требует достаточно кропотливой работы со стороны экспертов, а в некоторых случаях и не представляется возможным.

### Реализация базовых компонент прототипа интеллектуальной системы поддержки принятия решений для анализа и диагностики сложных патологий зрения

Основные подходы к разработке ИСППР для анализа и диагностики проблемных ситуаций применительно к медицинским данным описаны в [5, 6]. Рассмотрим основные компоненты прототипа.

*Подсистема хранения и предварительной обработки данных.*

Перечислим ряд основных требований к подсистеме и соответствующей БД (хранилищу данных):

- занесение данных о результатах биофизических исследований (в частности, данных ЕРГ);
- внесение и хранение клинических данных пациентов и результатов медицинских обследований;




Рис. 3. Обобщенная структура CNN

- добавление дополнительной информации к данным исследований (например, измерений, получаемых с других приборов), в том числе в графическом виде.

На основе собранного материала предложена онтология для формирования документов и извлечения из них знаний для постановки диагноза (рис. 4), и определены следующие коллекции документов для физического хранения в НБД NoSQL:

- коллекция Diagnosis — содержит возможные диагнозы пациентов;
- коллекция ClinicalData — включает информацию о разных типах клинических данных (название и возможные значения для каждого типа);
- коллекция Patient — хранит данные о пациенте (номер карты, ФИО пациента, предполагаемый и финальный диагнозы, список исследований, клинические данные, заметки врача, жалобы пациента, рекомендации врача и т. д.). В эту коллекцию входят вложенные

документы Exam и ClinicalDataValue с результатами обследований и клиническими данными.

### Подсистема машинного обучения

В плане решения поставленных перед ИСППР задач анализа и диагностики сложных патологий зрения на основе результатов ЭРГ предложен интегрированный подход, сочетающий предварительную обработку данных и кластеризацию с использованием онтологии и CNN. Такой подход и реализованная на его основе программная система позволяют успешно обрабатывать данные с проведением предварительного НВП для максимального извлечения полезной и отсеечения второстепенной (малоинформативной) информации.

Для сочетания кластеризации и CNN представлена модификация последнего слоя CNN (полносвязной сети) согласно алгоритму  $k$ -средних [22]. Ее суть состоит в том, что элементы векторов, подаваемых на вход, сортируются по возрастанию, что позволяет учиты-

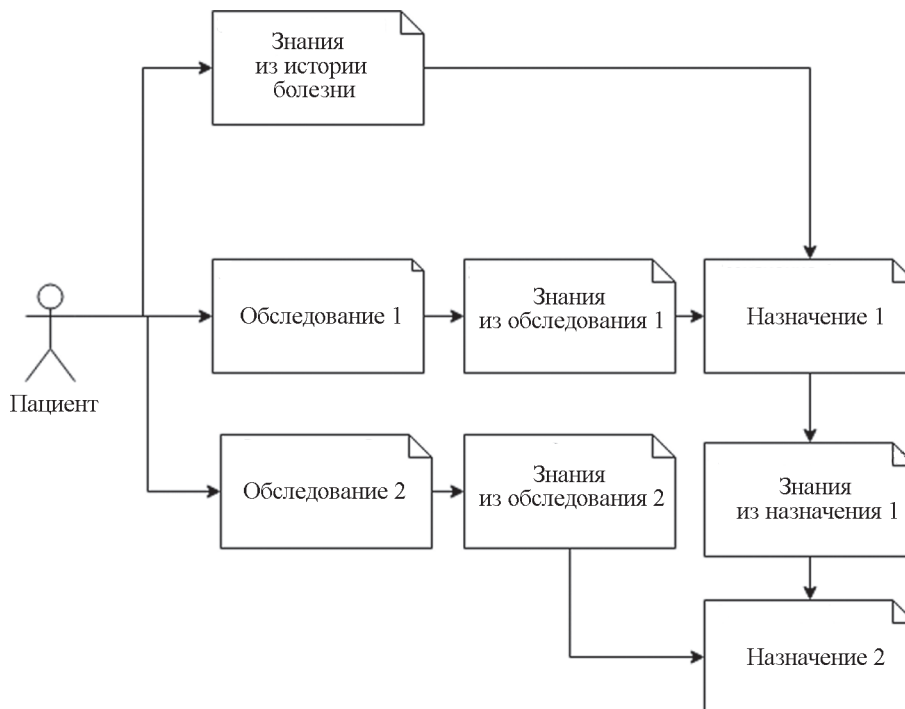


Рис. 4. Онтология для формирования документов и извлечения из них знаний

вать ситуации, связанные с тем, что на разных этапах работы сети отдельные признаки могут менять своё положение в результирующем векторе. Отметим, что для НВП используется преобразование типа Вейвлет Хаара, принимающее во внимание перепады графика ЭРГ, которые часто несут в себе важную информацию [3, 4].

Предложенный алгоритм включает следующие этапы (шаги).

1. Для каждого результата исследования ЭРГ выполняется НВП, размер матрицы, получаемый в результате преобразования —  $250 \times 250$ .

2. Каждой полученной матрице присваивается случайное значение вектора признаков.

3. Выполняется итерация обучения CNN (размер сети — 3 слоя, на первом выполняется свёртка —  $50 \times 50$ , на втором —  $25 \times 25$ , на третьем —  $10 \times 10$ ), в качестве значения отклонения ожидаемого результата от полученного используется погрешность алгоритма  $k$ -средних;

4. Проводится итерация по алгоритму  $k$ -средних.

5. Если изменение ошибки работы сети больше, чем некоторая константа (по сравнению с прошлой итерацией), то возврат на шаг 3.

Итог работы алгоритма — кластеризация результатов с использованием заранее (с помощью экспертов) определённого набора кластеров.

#### Анализ полученных результатов

Работа предложенного метода анализа с использованием CNN протестирована на выборке из 1400 исследований ЭРГ типа периодических ЭРГ (800 исследований использовались для обучения, 100 — для валидации и 500 — для оценки качества работы сети) [5, 8]. При разном количестве кластеров, требуемых в алгоритме  $k$ -средних, была выявлена наилучшая сходимость результатов для значений  $N$  в диапазоне (3; 5) (рис. 5), что обусловлено тем, что чаще всего представленные ЭРГ служили для диагностики только распространённых патологий.

При анализе полученных результатов с привлечением экспертов установлено, что для случая  $N=3$ , графики, попавшие в отдельные кластеры, соответствуют наблюдениям при миопии, отслоении сетчатки и глаукоме.

#### Заключение

Основная цель работы — разработка методов и базовых программных средств ИСППР (на примере прототипа) для анализа и диагностики проблемных ситуаций, помогающих практикующим врачам-офтальмологам, а также необходимых при обучении молодых врачей-ординаторов, диагностике сложных патологий зрения на основе результатов медицинских исследований с применением ЭРГ.

В плане достижения поставленной цели решены следующие задачи:

— проведена формализация предметной области патологий зрения, выявлены новые факторы, повышающие качество диагностики сложных патологий на ранних стадиях;

— разработана онтология предметной области, использованная для создания системы хранения данных на основе нереляционной БД;

— исследованы форматы хранения данных для медицинских аппаратов (электроретинографов) и разработаны программные средства для предварительной обработки данных;

— предложены, реализованы и апробированы методы анализа с применением нейронных сетей CNN.

Предложенный подход на основе интеграции ряда методов, а также применения онтологии и нереляционной модели (базы данных) позволяет расширить сферу применения ИСППР на ранние стадии заболевания и повысить качество диагностики патологий зрения. При реализации полномасштабной версии ИСППР для анализа и диагностики сложных патологий необходимо тесное взаимодействие с экспертами с целью формирования необходимых БД.




Рис. 5. Точность классификации по сгенерированным кластерам в зависимости от их количества

## Литература

## References

1. **Шамшинова А.М.** Электроретинография в офтальмологии. М.: Медика, 2009.
2. **Eremeev A.P., Tsapenko I.V.** The Use of Cognitive Graphics in the Diagnosis of Complex Vision Pathologies // Intern. J. Information Theories and Appl. 2019. V. 26. No. 1. Pp. 83—99.
3. **Eremeev A.P., Ivliev S.A.** Data Collection and Preparation of Training Samples for Problem Diagnosis of Vision Pathologies // Proc. 17 Russian Conf. Artificial Intelligence. 2019. V. 1093. Pp. 271—282.
4. **Анисимов Д.Н., Вершинин Д.В., Колосов О.С., Зуева М.В., Цапенко И.В.** Диагностика текущего состояния динамических объектов и систем сложной структуры методами нечеткой логики с использованием имитационных моделей // Искусственный интеллект и принятие решений. 2012. № 3. С. 39—50.
5. **Eremeev A.P., Ivliev S.A.** Using Convolutional Neural Networks for the Analysis of Nonstationary Signals on the Problem Diagnostics Vision Pathologies // Proc. 16 Russian Conf. Artificial Intelligence. 2018. V. 934. Pp. 164—175.
6. **Eremeev A.P., Ivliev S.A., Vagin V.N.** Using NoSql Databases and Machine Learning for Implementation of Intelligent Decision System in Complex Vision Pathologies // Proc. III Russian-pacific Conf. Computer Technol. and Appl. Vladivostok, 2018. Pp. 1—4.
7. **Barrac R. e. a.** A Comparison Among Different Techniques for Human ERG Signals Processing and Classification // Physica Medica: European J. Medical Phys. 2014. V. 30. Iss. 1. Pp. 86—95.
8. **Цапенко И.В.** Электрофизиологические исследования в диагностике заболеваний сетчатки и зрительного нерва (I). М: ФГУ «МНИИ глазных болезней им. Г. Гельмгольца Минздрава России», 2017.
9. **Джарратано Д., Райли Г.** Экспертные системы: принципы разработки и программирование. М.: Вильямс, 2007.
10. **Еремеев А.П., Куриленко И.В.** Реализация вывода в темпоральных моделях ветвящегося времени // Известия РАН. Серия «Теория и системы управления». 2017. № 1. С. 107—127.
11. **Ken Ka-Yin Leea, Wai-Choi Tangb, Kup-Sze Choia.** Alternatives to Relational Database: Comparison of NoSQL and XML Approaches for Clinical Data Storage // Computer Methods and Programs in Biomedicine. 2013. V. 110. Pp. 99—109.
12. **Goli-Malekabady Z., Akbari M.K., Javan M.S.** An Effective Model for Store and Retrieve Big Health Data in Cloud Computing // Computer Methods and Programs in Biomedicine. 2016. V. 132. Pp. 75—82.
13. **Козлов И.А.** Анализ и классификация нереляционных баз данных // Молодежный научно-технический вестник. 2013. № 2. С. 12—19.
14. **Lämmel R.** Google's MapReduce Programming Model — Revisited // Sci. of Computer Programming. 2008. V. 70. Iss. 1. Pp. 1—30.
1. **Shamshinova A.M.** Elektroretinografiya v Oftalmologii. M.: Medika, 2009. (in Russian).
2. **Eremeev A.P., Tsapenko I.V.** The Use of Cognitive Graphics in the Diagnosis of Complex Vision Pathologies. Intern. J. Information Theories and Appl. 2019;26;1: 83—99.
3. **Eremeev A.P., Ivliev S.A.** Data Collection and Preparation of Training Samples for Problem Diagnosis of Vision Pathologies. Proc. 17 Russian Conf. Artificial Intelligence. 2019;1093:271—282.
4. **Anisimov D.N., Vershinin D.V., Kolosov O.S., Zueva M.V., Tsapenko I.V.** Diagnostika Tekushchego Sostoyaniya Dinamicheskikh Ob'ektov i sistem Slozhnoy Struktury Metodami Nechetkoy Logiki s Ispol'zovaniem Imitatsionnykh Modeley. Iskusstvennyy Intellekt i Priyatie Resheniy. 2012;3:39—50. (in Russian).
5. **Eremeev A.P., Ivliev S.A.** Using Convolutional Neural Networks for the Analysis of Nonstationary Signals on the Problem Diagnostics Vision Pathologies. Proc. 16 Russian Conf. Artificial Intelligence. 2018;934: 164—175.
6. **Eremeev A.P., Ivliev S.A., Vagin V.N.** Using NoSql Databases and Machine Learning for Implementation of Intelligent Decision System in Complex Vision Pathologies. Proc. III Russian-pacific Conf. Computer Technol. and Appl. Vladivostok, 2018:1—4.
7. **Barrac R. e. a.** A Comparison Among Different Techniques for Human ERG Signals Processing and Classification. Physica Medica: European J. Medical Phys. 2014;30;1:86—95.
8. **Tsapenko I.V.** Elektrofiziologicheskie Issledovaniya v Diagnostike Zabolevaniy Setchatki i Zritel'nogo Nerva (I). M: FGU «MNII Glaznykh Bolezney im. G. Gel'mgol'tsa Minzdrava Rossii», 2017. (in Russian).
9. **Dzharratano D., Rayli G.** Ekspertnye Sistemy: Printsipy Razrabotki i Programirovanie. M.: Vil'yams, 2007. (in Russian).
10. **Eremeev A.P., Kurilenko I.V.** Realizatsiya Vyvoda v Temporal'nykh Modelyakh Vetvyashchegosya Vremeni. Izvestiya RAN. Seriya «Teoriya i Sistemy Upravleniya». 2017;1:107—127. (in Russian).
11. **Ken Ka-Yin Leea, Wai-Choi Tangb, Kup-Sze Choia.** Alternatives to Relational Database: Comparison of NoSQL and XML Approaches for Clinical Data Storage. Computer Methods and Programs in Biomedicine. 2013;110:99—109.
12. **Goli-Malekabady Z., Akbari M.K., Javan M.S.** An Effective Model for Store and Retrieve Big Health Data in Cloud Computing. Computer Methods and Programs in Biomedicine. 2016;132:75—82.
13. **Kozlov I.A.** Analiz i Klassifikatsiya Nerelyatsionnykh Baz Dannyykh. Molodezhnyy Nauchno-tekhnicheskyy Vestnik. 2013;2:12—19. (in Russian).
14. **Lämmel R.** Google's MapReduce Programming Model — Revisited. Sci. of Computer Programming. 2008;70;1:1—30.

15. Naresh Kumar Gundla, Zhengxin Chen. Creating NoSQL Biological Databases with Ontologies for Query Relaxation // *Procedia Computer Sci.* 2016. V. 91. Pp. 460—469.

16. Еремеев А.П., Ивлиев С.А. Анализ и диагностика сложных патологий зрения на основе вейвлет-преобразований и нейросетевого подхода // *Интегрированные модели и мягкие вычисления в искусственном интеллекте: Сборник трудов VIII Междунар. науч.-техн. конф. М.: Физматлит, 2015. Т. 2. С. 589—595.*

17. Brynolfsson J., Sandsten M. Classification of One-dimensional Non-Stationary Signals using the Wigner-Ville Distribution in Convolutional Neural Networks // *Proc. 25 European Signal Conf. Kos, 2017. Pp. 326—330.*

18. Lee H., Grosse R., Ranganath R., Ng A.Y. Convolutional Deep Belief Networks for Scalable Unsupervised Learning of Hierarchical Representations // *Proc. 26 Annual Intern. Conf. Machine Learning. Montreal, 2009. Pp. 609—616.*

19. Geert Litjens e. a. A survey on Deep Learning in Medical Image Analysis // *Medical Image Analysis.* 2017. V. 42. Pp. 60—88.

20. Krizhevsky A., Sutskever I., Hinton G.E. Imagenet Classification with Deep Convolutional Neural Networks. // *Advances in Neural Information Proc. Syst.* 2012. V. 25 (2). Pp. 1097—1105.

21. Davies E.R. *Computer Vision: Principles, Algorithms, Applications, Learning.* London: Elsevier, 2018. Pp. 453—493.

22. Bo L., Ren X., Fox D. Unsupervised Feature Learning for rgb-d Based Object Recognition // *Experimental Robotics. N.-Y.: Springer, 2013. Pp. 387—402.*

15. Naresh Kumar Gundla, Zhengxin Chen. Creating NoSQL Biological Databases with Ontologies for Query Relaxation. *Procedia Computer Sci.* 2016;91:460—469.

16. Eremeev A.P., Ivliev S.A. Analiz i Diagnostika Slozhnykh Patologiy Zreniya na Osnove Veyvlet-preobrazovaniy i Neyrosetevogo Podkhoda. *Integrirovannye Modeli i Myagkie Vychisleniya v Iskusstvennom Intellekte: Sbornik Trudov VIII Mezhdunar. Nauch.-tekhn. Konf. M.: Fizmatlit, 2015;2:589—595. (in Russian).*

17. Brynolfsson J., Sandsten M. Classification of One-dimensional Non-Stationary Signals using the Wigner-Ville Distribution in Convolutional Neural Networks. *Proc. 25 European Signal Conf. Kos, 2017:326—330.*

18. Lee H., Grosse R., Ranganath R., Ng A.Y. Convolutional Deep Belief Networks for Scalable Unsupervised Learning of Hierarchical Representations. *Proc. 26 Annual Intern. Conf. Machine Learning. Montreal, 2009:609—616.*

19. Geert Litjens e. a. A survey on Deep Learning in Medical Image Analysis. *Medical Image Analysis.* 2017;42:60—88.

20. Krizhevsky A., Sutskever I., Hinton G.E. Imagenet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Proc. Syst.* 2012;25 (2):1097—1105.

21. Davies E.R. *Computer Vision: Principles, Algorithms, Applications, Learning.* London: Elsevier, 2018: 453—493.

22. Bo L., Ren X., Fox D. Unsupervised Feature Learning for rgb-d Based Object Recognition. *Experimental Robotics. N.-Y.: Springer, 2013:387—402.*

#### Сведения об авторах:

**Еремеев Александр Павлович** — доктор технических наук, профессор кафедры прикладной математики и искусственного интеллекта НИУ «МЭИ», e-mail: eremeev@appmat.ru

**Ивлиев Сергей Андреевич** — ассистент кафедры прикладной математики и искусственного интеллекта НИУ «МЭИ», e-mail: siriusfrk@gmail.com

#### Information about authors:

**Eremeev Aleksandr P.** — Dr.Sci. (Techn.), Professor of Applied Mathematics and Artificial Intelligence Dept., NRU MPEI, e-mail: eremeev@appmat.ru

**Ivliev Sergey A.** — Assistant of Applied Mathematics and Artificial Intelligence Dept., NRU MPEI, e-mail: siriusfrk@gmail.com

**Работа выполнена при поддержке:** РФФИ (проекты № 18-01-00201, № 18-51-00007, № 18-29-03088, № 20-07-00498)  
**The work is executed at support:** RFBR (Projects No. 18-01-00201, No. 18-51-00007, No. 18-29-03088, No. 20-07-00498)

**Конфликт интересов:** авторы заявляют об отсутствии конфликта интересов

**Conflict of interests:** the authors declare no conflict of interest

**Статья поступила в редакцию:** 23.12.2019

**The article received to the editor:** 23.12.2019