



## АНАЛИЗ ПОГРЕШНОСТЕЙ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ КАК ОСНОВА ФОРМИРОВАНИЯ НАВЫКОВ ИХ ИСПОЛЬЗОВАНИЯ

*Е. В. Славутская<sup>1</sup>, Л. А. Славутский<sup>2</sup>*

*<sup>1</sup>Чувашский государственный педагогический университет им. И. Я. Яковлева,  
Чебоксары, Российская Федерация*

*<sup>2</sup>Чувашский государственный университет им. И. Н. Ульянова,  
Чебоксары, Российская Федерация*

### АННОТАЦИЯ

**Введение.** Методы машинного обучения и элементы искусственного интеллекта используются для анализа случайных данных, процессов и сигналов. Изучение соответствующих инструментов уже входит в учебные программы направлений подготовки разного уровня. Цель исследования – продемонстрировать на доступных для студентов разных специальностей примерах, что анализ погрешностей методов машинного обучения при решении конкретных задач может являться основой формирования в учебном процессе навыков применения элементов искусственного интеллекта.

**Материалы и методы.** Для обработки случайных сигналов и данных используется открытое доступное программное обеспечение: Microsoft Excel для подготовки обучающей и тестовой выборки, аналитическая платформа Deductor для реализации алгоритмов машинного обучения. В качестве примера для технических специальностей обрабатываются квазигармонические сигналы со случайными параметрами, а для обработки многомерных случайных данных используются результаты психодиагностики.

**Результаты исследования.** В качестве характерного решения аппроксимационных технических задач анализируются ошибки использования нейронной сети прямого распространения для определения случайных параметров сигналов. В качестве решения классификационных задач многомерные случайные данные с разной размерностью обрабатывались при помощи нейронных сетей и метода «дерево решений». Проанализированы преимущества комбинированного использования этих двух методов машинного обучения. Приведённые примеры и их анализ апробированы на занятиях со студентами университета в рамках дисциплин «Цифровая обработка сигналов» и «Основы статистики».

**Обсуждение и заключения.** Обсуждаются статистические особенности полученных результатов, возможности сокращения обучающей выборки и селективного анализа многомерных случайных данных. Показано, что адекватная оценка погрешностей методов машинного обучения позволяет существенно расширить возможности их применения и может являться основой для формирования навыков их использования.

*Ключевые слова:* методы машинного обучения, погрешности, искусственные нейронные сети, дерево решений

**Для цитирования:** Славутская Е. В., Славутский Л. А. Анализ погрешностей методов машинного обучения как основа формирования навыков их использования // Вестник Мининского университета. 2024. Т. 12, № 2. С. 4. DOI: 10.26795/2307-1281-2024-12-2-4.

## ERROR ANALYSIS OF MACHINE LEARNING METHODS AS THE EDUCATIONAL BACKGROUND FOR ITS USE SKILLS FORMATION

*E. V. Slavutskaya<sup>1</sup>, L. A. Slavutskii<sup>2</sup>*

*<sup>1</sup>I.Ya. Yakovlev Chuvash State Pedagogical University, Cheboksary, Russian Federation*

*<sup>2</sup>Chuvash State University, Cheboksary, Russian Federation*

### ABSTRACT

**Introduction.** Machine learning methods and elements of artificial intelligence are used to analyze random data, processes and signals. The study of relevant tools is already included in the various levels curricula. The purpose of the study is to demonstrate, using examples available to students of various specialties, that the error analysis of machine learning methods in solving specific tasks can be the basis in the educational process for the skills formation of using artificial intelligence elements.

**Materials and Methods.** For processing random signals and data, widely available software is used: Microsoft Excel for preparing training and test samples, the Deductor analytical platform for implementing machine learning algorithms. As an example, quasi-harmonic signals with random parameters are processed for technical specialties, and the results of psycho diagnostics are used to process multidimensional random data.

**Results.** As a typical solution of approximation technical problems, direct propagation neural network errors in using to determine random signal parameters are analyzed. As a solution of classification problems, multidimensional random data with different dimensions were processed using neural networks and the "decision tree" method. The advantages of the combined use of these two machine learning methods are analyzed. These examples and their analysis were tested in classes with university students in the disciplines of "Digital Signal Processing" and "Fundamentals of Statistics".

**Discussion and Conclusions.** The statistical features of the obtained results, the possibilities of reducing the training sample and selective analysis of multidimensional random data are discussed. It is shown that an adequate assessment of the machine learning methods errors can significantly expand the possibilities of their application, and can be the basis for the formation of skills for their use.

*Keywords:* machine learning methods, errors, artificial neural networks, decision tree

**For citation:** Slavutskaya E. V., Slavutskii L. A. Error analysis of machine learning methods as the educational background for its use skills formation // Vestnik of Minin University. 2024. Vol. 12, no. 2. P. 4. DOI: 10.26795/2307-1281-2024-12-2-4.

## Введение

Методы машинного обучения (ММО) и аппарат искусственных нейронных сетей (ИНС) как основа искусственного интеллекта [1, 8] находят применение во всё более широком круге задач [14, 15, 39, 40]. Базовые знания в этой области необходимо включать в учебный процесс вузов не только для технических, естественно-научных направлений подготовки, но и для экономических, психологических, медицинских, социологических и так далее. Студенты всех обозначенных специальностей в той или иной мере изучают основы математической статистики. Методы машинного обучения оказываются непосредственно связаны с задачами статистической обработки данных. Результаты вычислений при помощи ММО всегда носят статистический характер. Изучение основ таких методов не только дополняет знания и навыки в области статистики, но может служить при подготовке студентов более глубокому пониманию научных принципов статистической обработки данных [12].

В настоящей работе на простейших конкретных примерах и при использовании доступного открытого программного обеспечения показано, как анализ погрешностей ММО может служить основой для формирования навыков использования таких инструментов.

## Обзор литературы

ММО широко используются в современных персональных компьютерах и гаджетах достаточно давно. Самым характерным примером является распознавание текстов с голоса и использование программ для перевода на иностранные языки. Возникающие при этом ошибки и неточности исправляются без поиска их причин. Широко используется ряд терминов, связанных с ММО: искусственный интеллект (artificial intelligence) [25, 26, 31], глубокое обучение (deep learning) [38], искусственные нейронные сети (artificial neural networks) [34, 42], интеллектуальный анализ данных (data mining) [30], большие данные (big data, data science) [24, 36]. Считается, что ММО используются в задачах распознавания образов (pattern recognition) [21, 44], принятия решений (decision-making) [10] и т.д., однако единая однозначная классификация таких задач отсутствует в силу их разнообразия.

Чаще всего задачи делятся на два класса: регрессионные (аппроксимационные) и классификационные [22]. Их очень легко и наглядно можно разделить по виду целевой функции: если целевая функция непрерывна (вещественна), то решается задача регрессии; если она дискретна – классификации.

Аппроксимация в технических приложениях используется для анализа случайных динамических процессов и сигналов [17, 33, 43], в том числе для решения предсказательных (predictive) задач, нахождения трендов в социологии, экономике и т.д. [18]. Классификация используется для селективного анализа данных, обнаружения аномалий и неисправностей в режимах работы технических объектов, новых закономерностей в психосоциальном развитии и т.д.

Существуют российские монографии и учебники (или переведенные на русский язык) с достаточно подробным описанием ММО [4, 5, 7, 11, 19, 20], но они могут быть использованы только студентами технических специальностей, специализирующимися в области информационных технологий [28]. С другой стороны, задачи, например, анализа многомерных данных (big data), могут решаться специалистами в психологии [16], медицине [3, 13], социологии [32], экономике и т.д. Такие задачи тесно связаны задачами

статистического анализа данных, и поэтому ММО на самом начальном этапе могут преподаваться вместе с основами статистики. Ниже возможности преподавания основ ММО будут показаны для студентов разных специальностей на конкретных примерах обозначенных двух классов задач.

### Материалы и методы

Для демонстрации возможности использования методов ММО и интеллектуального анализа данных в работе использовались два апробированных инструмента: метод «дерево решений» [2] и аппарат искусственных нейронных сетей (ИНС) в самом простейшем случае нейронной сети прямого распространения (многослойного персептрона) [41] (рисунок 1). Выбор этих инструментов обусловлен тем, что «дерево решений» разработано для решения задач классификации, а персептрон является простейшей нейронной сетью и основой искусственного интеллекта [27]. Персептрон позволяет решать оба класса задач, классификации и регрессии. Оба инструмента широко представлены в современных аналитических платформах (программном обеспечении), все процедуры, связанные с их использованием, автоматизированы, решение соответствующих задач не требует навыков, превышающих навыки использования, например, Microsoft Excel. Данные для обработки и использования обозначенных инструментов могут быть подготовлены в Microsoft Excel и импортированы в открытые программные продукты, имеющие русифицированные версии, в частности – Deductor [9] и Statistica.

Значимые отличия в использовании метода «дерево решений» и ИНС заключаются в следующем:

1. Метод «дерево решений» не требует большой обучающей выборки.
2. Этот метод даёт возможность оценить значимость входных данных при классификации по выбранной целевой функции (атрибуту).
3. ИНС требует значительно большей обучающей выборки в зависимости от количества скрытых (ассоциативных) слоев и нейронов (см. рисунок 1). Обучающая выборка должна во много раз превышать количество связей между нейронами.

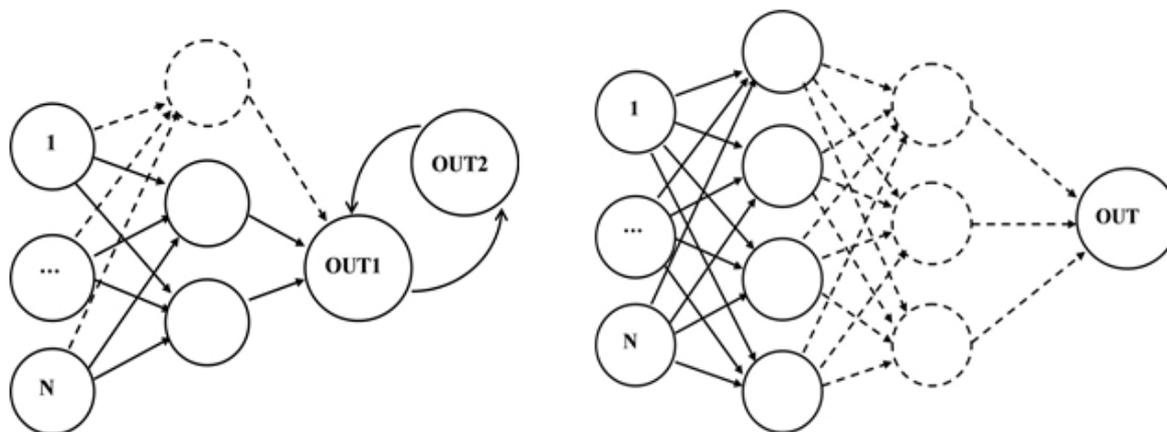


Рисунок 1 – Нейронная сеть с заменой целевой функции, количества нейронов и слоев /  
Figure 1 – Neural network with replacement of the target function, the number of neurons and layers

4. ИНС предоставляет гораздо больше возможностей, но при этом нужно менять ее структуру, целевую функцию, оценивать количество эпох обучения и т.д.

Оценка результата использования методов ММО в обоих случаях носит статистический характер, и анализ использования обозначенных инструментов должен учитывать возникающие статистические погрешности. Оба обозначенных выше программных пакета позволяют визуализировать как в числовом, так и графическом виде результаты машинного обучения.

Возможности освоения навыков использования обозначенных инструментов демонстрируются на простейших примерах обработки сигналов для технических приложений (при обучении студентов технических специальностей) и обработки многомерных случайных данных, как пример, при подготовке социологов, психологов, экономистов, медиков и т.д. При этом ключевым аспектом является оценка погрешности методов машинного обучения, что позволяет не только приобрести навыки их использования, но и гораздо лучше изучить основы статистической теории оценивания на конкретных примерах.

### Результаты исследования

**ИНС для обработки сигналов в технических приложениях.** В задачах обработки сигналов для технических приложений наиболее характерным и распространённым примером может являться обработка гармонических или квазигармонических сигналов со случайными параметрами. Случайная амплитуда, частота и фаза таких сигналов может принимать вещественное значение в широком диапазоне. Определение этих параметров при помощи аппарата искусственных нейронных сетей представляет собой классическую задачу аппроксимации, когда целевой функцией является непрерывная вещественная функция. На рисунке 2б представлены результаты обучения обыкновенного персептрона с одним скрытым слоем, состоящим всего из двух нейронов (рисунок 2а), на вход которого подаются пять отсчётов гармонического сигнала за случайной амплитудой, частотой и фазой. Каждый из этих параметров может быть определён с достаточно высокой точностью. В данном случае на выходе ИНС частота сигнала  $f$ . Количество дискретных отчётов, подаваемых на вход ИНС, соответствует приблизительно одному периоду гармонического сигнала.

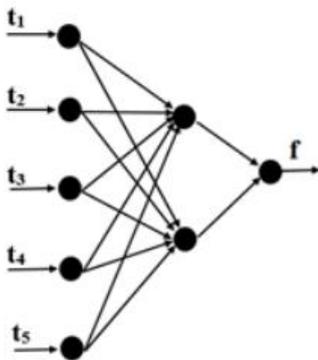


Рисунок 2а – Нейронная сеть для обработки квазигармонического сигнала / Figure 2a – Neural network for a quasi-harmonic signal processing

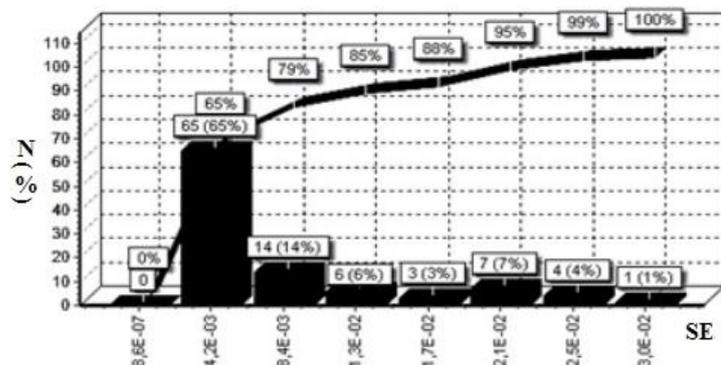


Рисунок 2б – Гистограмма распределения ошибок SE на ее выходе / Figure 2б – The histogram of the error SE distribution at its output

Как видно из гистограммы распределения ошибок (рисунок 2б), при дискретизации сигнала всего пять точек на период, средняя ошибка при определении частоты не превышает полпроцента. При этом максимальная ошибка достигает 3 %. То есть даже при длительном адекватном обучении нейросети, она не может обеспечить точность менее 1 % со стопроцентной вероятностью.

Ещё более характерным примером, демонстрирующим статистические особенности использования нейронных сетей, является определение фазы гармонического сигнала при помощи перцептрона, показанного на рисунке 2а. Соответствующая диаграмма рассеяния, показанная на рисунке 3, очень наглядно демонстрирует, что при средней ошибке менее 1 % (если рассматривать среднее отклонение по всей диагонали диаграммы) максимальные ошибки могут составлять десятки процентов. В данном случае такие ошибки соответствуют значениям фазы  $0, \pi, 2\pi$  рисунка 3.

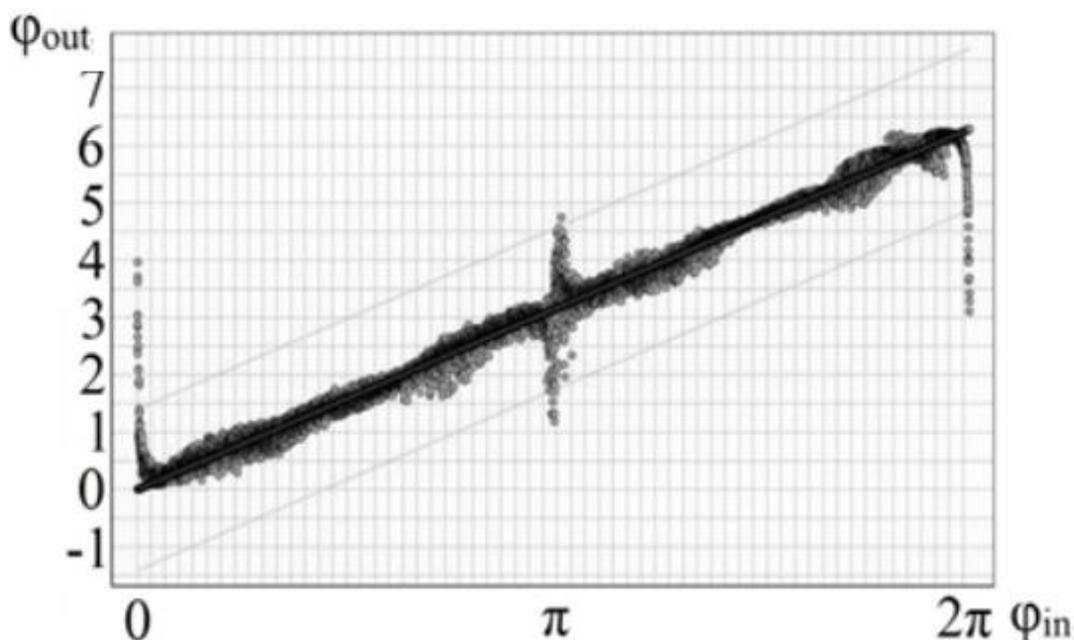


Рисунок 3 – Диаграмма рассеяния для фазы сигнала на выходе нейронной сети /  
Figure 3 – Scattering diagram for the signal phase at the neural network output

Для студентов технических специальностей приведённый пример позволяет не только обсуждать статистические особенности обучения ИНС, но и сопоставить полученные результаты с возможностью использования других традиционных методов, таких как спектральный анализ при помощи преобразования Фурье. Для углубленного анализа функционирования ИНС в обучающей выборке на сигнал может быть наложен случайный шум.

**Ошибки при использовании методов машинного обучения как инструмент селективного анализа многомерных данных.** Для экономических, социологических, медицинских, психологических специальностей представляет интерес обработка многомерных случайных данных. Такие данные могут иметь разную числовую размерность и разные диапазоны варьирования. Анализ самого процесса обучения простейшей нейросети (рисунки 1, 2а) позволяет получить очень важную информацию при решении таких задач. В качестве примера на рисунке 4 приведена диаграмма рассеяния, полученная при обучении ИНС по данным двух апробированных психологических опросников: изучения родительских

установок ("Parental Attitude Research Instrument", PARI [37]) и «Анализ семейных взаимоотношений» (АСВ, "Analysis of family relationships"[23]). В опросах приняли участие 496 родителей (матерей) дошкольников. Шкалирование тестов сильно отличается: если результаты PARI принимают вещественные значения со статистическим распределением, близким к нормальному, то результаты АСВ имеют целочисленные значения в узком диапазоне. В этих условиях корреляционный анализ взаимосвязей не дает адекватных результатов.

Диаграмма рассеяния на рисунке 4 соответствует значениям признака из PARI «Отношение к семейной роли» на выходе ИНС при значениях всех остальных показателей PARI и АСВ на ее входе. Из диаграммы следует, что для 90 % выборки ошибки не превышают 5 %. Для остальных респондентов, данные которых обведены кружками, ошибки достигают 22 %. То есть респонденты, данные которых выпадают из общей массы, могут быть выделены по взаимосвязям между показателями. С ними может быть проведена дополнительная диагностика (углубленная схема) и т.д. Такие результаты, соответствующие селективной оценке многомерных данных, представляют интерес не только для психологии, медицины, социологии, но и для задач кибернетической безопасности, контроля аномалий в информационных потоках.

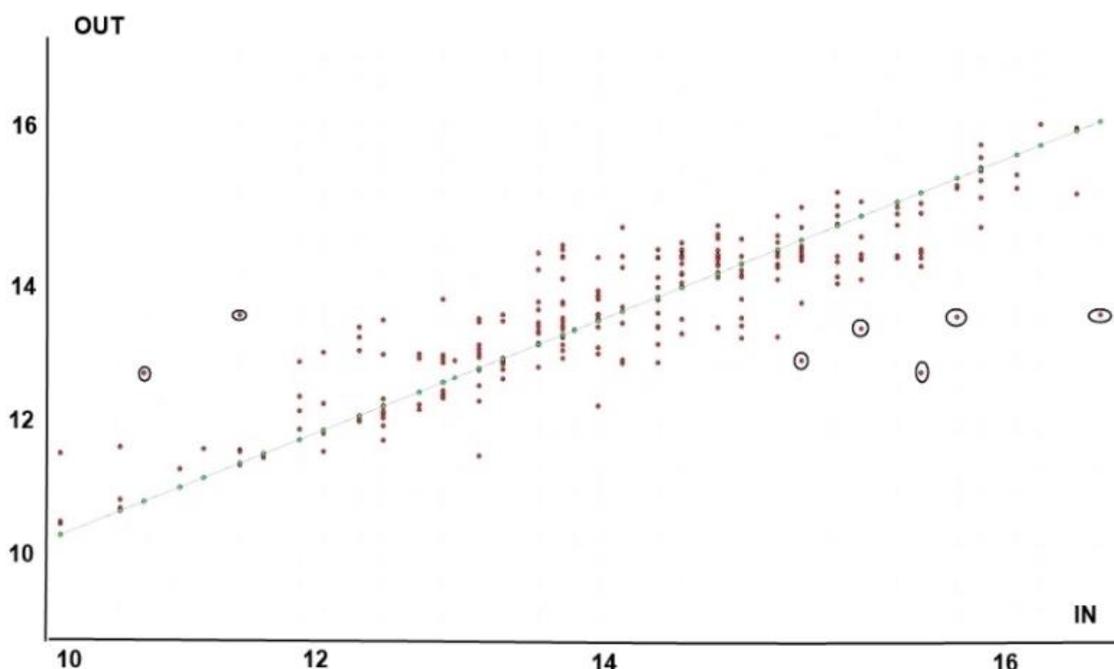


Рисунок 4 – Диаграмма рассеяния при обучении нейронной сети по результатам двух тестов /  
Figure 4 – The scattering diagram when training the neural network based on the results of two tests

Необходимо иметь в виду, что речь идёт не о самих аномальных значениях в определённых наборах данных, а именно о связи между входными и выходными параметрами ИНС.

**Комбинированное использование дерева решений и ИНС.** Методы машинного обучения могут быть основаны на сильно отличающихся друг от друга числовых алгоритмах. Однако все эти методы объединяет следующее. Они основаны на многократной математической процедуре, при которой находятся такие связи между входными данными и целевой функцией, которые обеспечивают минимальную погрешность. Критерием

«достаточности обучения» могут являться минимальные среднеквадратичные ошибки, процент нераспознанных связей и т.д. Поэтому анализ статистических погрешностей ММО имеет ключевое значение. И поэтому же комбинированное использование разных методик, инструментов ММО может давать значительно более адекватную информацию.

Приведём пример комбинированного использования метода «дерево решений» и ИНС для обработки психодиагностических данных. Используются те же психодиагностические данные (PARI и АСВ).

Метод «дерево решений» позволяет строить иерархическую структуру связей между входными и выходными данными (атрибутами). Его погрешности при классификации данных оцениваются в процентах распознанных и нераспознанных связей [35]. Особенно важным является тот факт, что этот метод позволяет разделить классифицируемые признаки по значимости в результатах распознавания и построения иерархического дерева.

На рисунке 5 приведена соответствующая гистограмма, полученная при анализе данных психодиагностики 496 родителей: R1-R7 – результаты PARI, E1-E20 – результаты АСВ. То есть 26 признаков R2-E20 классифицируется по целевому атрибуту R1.

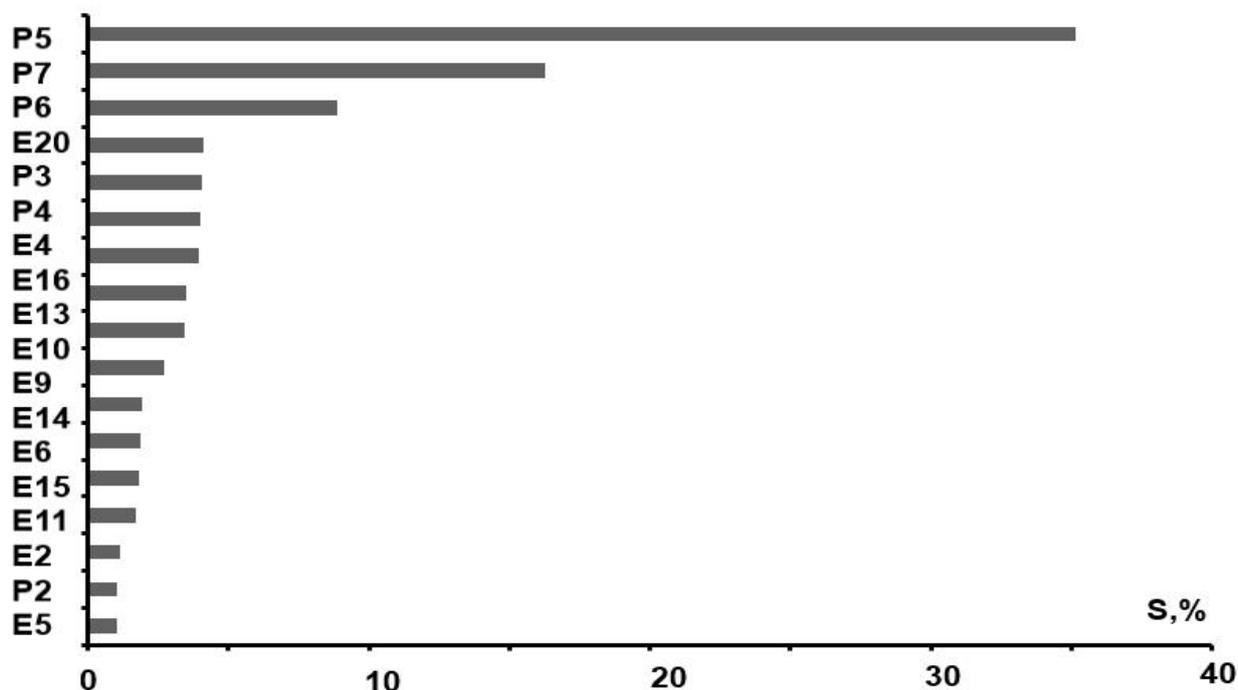


Рисунок 5 – Значимость признаков S при классификации данных методом «дерево решений» /

Figure 5 – The features significance S at the data classification by the decision tree method

Из гистограммы следует, что можно выделить семь признаков, значимость которых превышает 4 %, и при этом их суммарная значимость в результате классификации оказывается выше 80 %. Проверка адекватности функционирования алгоритма «дерево решений» может быть проведена при использовании простейшей нейронной сети. На рисунке 6 показано соответствующее распределение ошибок при обучении нейросети при 26 входных признаках (рисунок 4) и при выделенных семи наиболее значимых признаках (рисунок 5). Как видно из гистограмм распределения ошибок, средние и максимальные ошибки при обучении нейронных сетей, отличающихся только количеством входных нейронов, отличаются на порядок. Если максимальная ошибка в первом случае составляет 22 %, во втором случае она составляет 2,5 %. Соответствующее соотношение имеет место и для среднеквадратичных ошибок.

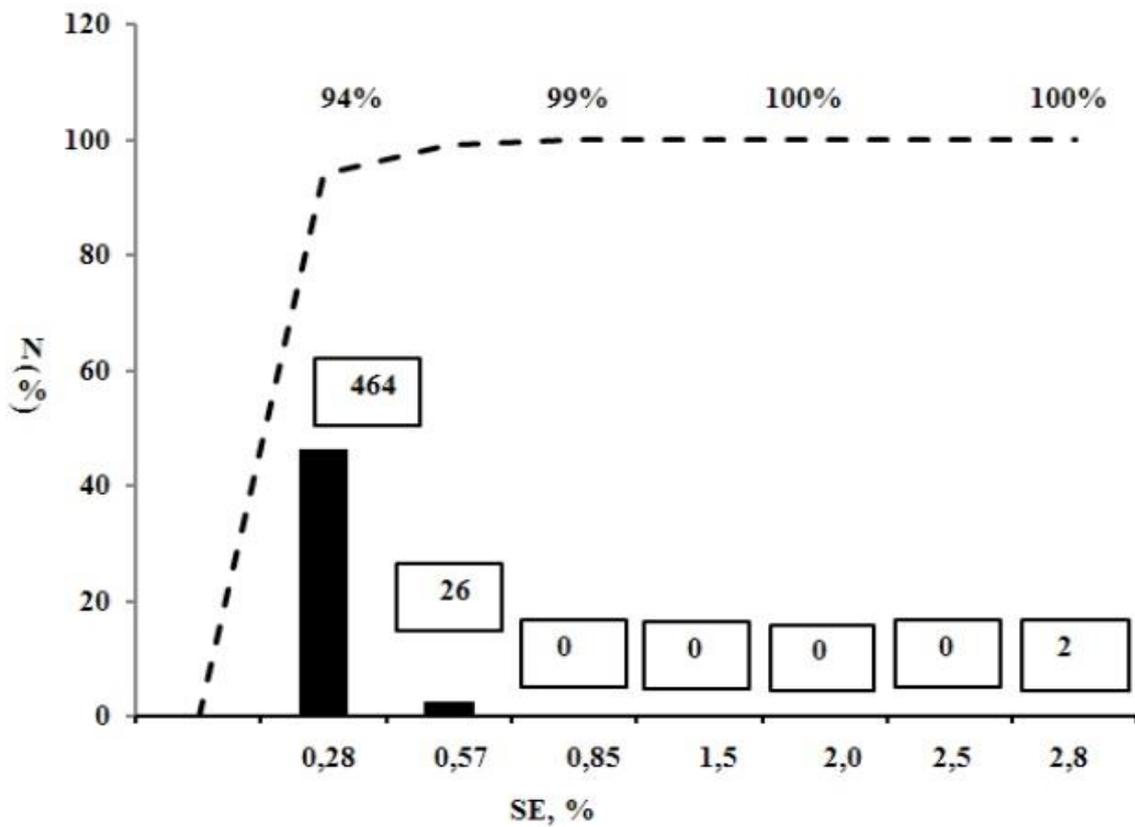
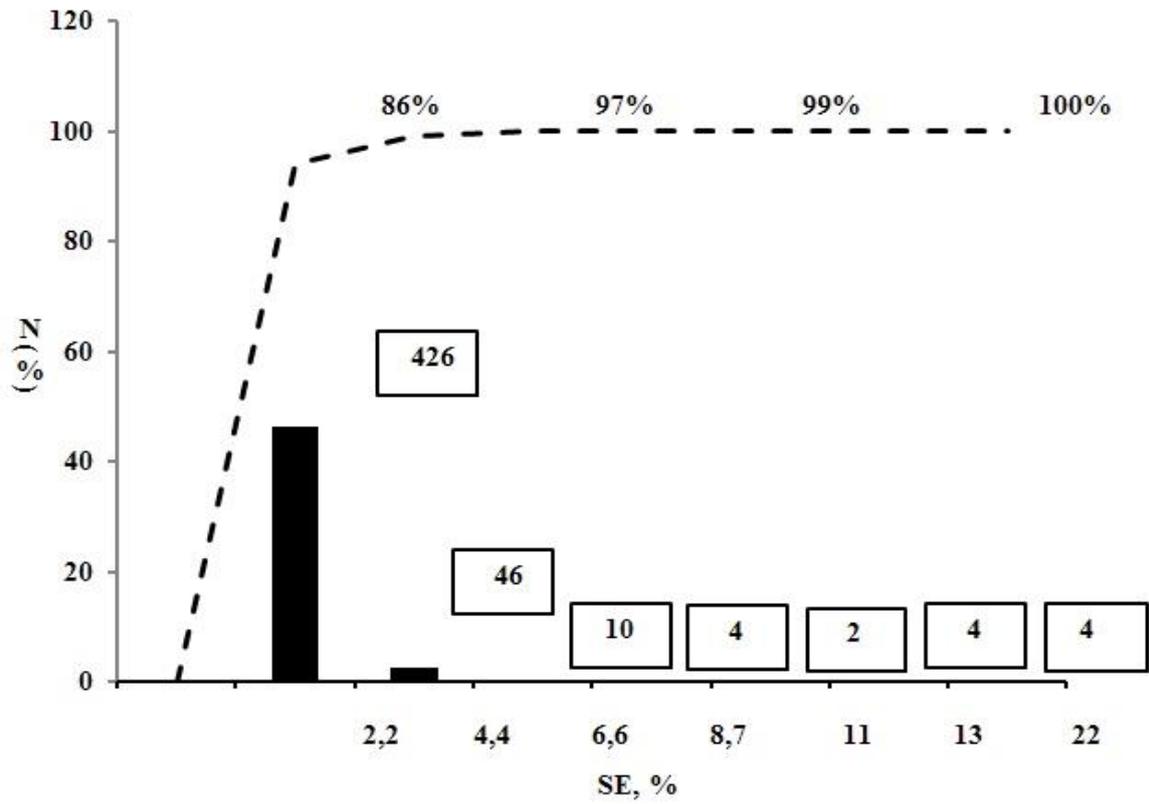


Рисунок 6 – Гистограммы распределения ошибок для нейронной сети с 26 входными признаками (верхняя гистограмма) и 7 наиболее значимыми входными признаками (нижняя гистограмма) / Figure 6 – Error distribution histograms for the neural network with 26 input features (upper histogram) and 7 most significant input features (lower histogram)

При этом нужно иметь в виду, что уменьшение количества входных признаков при обучении нейронной сети автоматически позволяет уменьшить обучающую выборку, которая определяется качеством связей между нейронами.

Приведённые результаты очень наглядно показывают, что скрытые (опосредованные) связи между случайными данными могут быть структурированы и изучены разными методами. Системный анализ данных не всегда может проводиться традиционными статистическими методами, такими как корреляционный или факторный анализ.

Приведённые примеры обработки данных апробированы на занятиях со студентами второго курса технического направления подготовки Чувашского государственного университета в рамках дисциплины «Цифровая обработка сигналов». Потребовалось шесть академических часов практических занятий, включая освоение аналитической платформы Deductor, обсуждение и анализ полученных результатов. Для студентов психологических, медицинских, экономических специальностей могут использоваться более упрощённые примеры – нейросетевая оценка средних величин из набора случайных данных, случайной выборки, определение дисперсии по такой выборке. Полученный материал в виде времени обучения, размера необходимой выборки, статистического распределения результатов может использоваться для практического освоения методов машинного обучения.

### Обсуждение и заключения

Приведённые выше результаты могут рассматриваться в качестве характерных примеров для изучения основ искусственного интеллекта на отечественном программном обеспечении студентами самых разных специальностей. При этом усваиваются широко применяемые термины, смысл которых очень часто искажается в средствах массовой информации.

Простейшая нейронная сеть прямого распространения («персептрон», рисунок 1) является «ячейкой», из которых строятся широко используемые в настоящее время рекуррентные, свёрточные и т.д. нейронные сети.

На этих примерах студенты могут получить начальные знания о широко используемых терминах:

- решение задачи аппроксимации для нахождения случайных параметров сигнала может рассматриваться как задача «распознавания образов»;
- селективный анализ данных с выделением аномальных примеров в обучающей выборке может рассматриваться как задача «принятия решений»;
- системный анализ многомерных данных при комбинированном использовании методов машинного обучения позволяет разъяснить термины «большие данные» (big data) и «интеллектуальный анализ данных» (data mining).

Deductor позволяет визуализировать процесс обучения ИНС. Может быть показано, что слишком длительное обучение приводит к запоминанию обучающей выборки и росту ошибок. Это позволяет наглядно разъяснить термины «глубокое обучение» и «переобучение».

Приведем подстрочный перевод аннотации отчета круглого стола с участием ведущих специалистов из Канады, США, ОАЭ и др.: «Искусственный интеллект не может быть использован без квалифицированного специалиста в области образования до тех пор, пока не будет найден способ обеспечить достоверность его взаимосвязей, входных данных и данных

на выходе» [29]. Понимание студентами того, что методы машинного обучения и основы искусственного интеллекта дают возможность получать результаты только в статистическом смысле, представляется важнейшим. При использовании даже готовых алгоритмов [6], проведения вычислений через Интернет, когда расчёты осуществляются на удалённых серверах, необходимо усвоение студентами того факта, что отсутствие очень значительных ошибок не гарантировано. Даже при низком уровне средних ошибок максимальные ошибки могут быть очень значительны и отличаться от средних ошибок на порядок.

Таким образом, предложенный подход позволяет студентам более глубоко освоить статистическую теорию оценивания.

#### Список использованных источников

1. Агеев А. И., Золотарева О. А., Золотарев В. А. Россия в глобальном мире искусственного интеллекта: оценка по мировым рейтингам // Экономические стратегии. 2022. № 2 (182). С. 20-31. <http://dx.doi.org/10.33917/es-2.182.2022.20-31>.
2. Бичурина С. У., Славутская Е. В., Славутский Л. А., Аbruков В. С., Садовая В. В. Вертикальный системный анализ данных психодиагностики учащихся с использованием метода «дерево решений» // Science for Education Today. 2020. № 3. С. 87-107. <http://dx.doi.org/10.15293/2658-6762.2003.05>.
3. Выучейская М. В., Крайнова И. Н., Грибанов А. В. Нейросетевые технологии в диагностике заболеваний (обзор) // Журнал медико-биологических исследований. 2018. Т. 6, № 3. С. 284-294. <https://doi.org/10.17238/issn2542-1298.2018.6.3.284>.
4. Горбань А. Н., Дунин-Барковский В. Л., Кирдин А. Н., Миркес Е. М., Новоходько А. Ю., Россиев Д. А., Терехов С. А., Сенашова М. Ю., Царегородцев В. Г. Нейроинформатика. Новосибирск, 1998. 296 с.
5. Дюк В., Самойленко А. Data Mining: учебный курс. Санкт-Петербург, 2001. 386 с.
6. Котлярова И. О. Технологии искусственного интеллекта в образовании // Вестник ЮУрГУ. Серия «Образование. Педагогические науки». 2022. Т. 14, № 3. С. 69-82. <https://doi.org/10.14529/ped220307>.
7. Круглов В. В., Борисов В. В. Искусственные нейронные сети. Теория и практика. Москва, 2001. 382 с.
8. Куприянов Р. Б., Агранат Д. Л., Сулейманов Р. С. Использование технологий искусственного интеллекта для выстраивания индивидуальных образовательных траекторий обучающихся // Вестник Российского университета дружбы народов. Серия: Информатизация образования. 2021. Т. 18, № 1. С. 27-35. <https://doi.org/10.22363/2312-8631-2021-18-1-27-35>.
9. Лаборатория BaseGroup. Технологии анализа данных. URL: <http://www.basegroup.ru> (дата обращения: 22.05.2024).
10. Левитин А. В. Ограничения мощности алгоритмов: Деревья принятия решения. Алгоритмы. Введение в разработку и анализ (глава 10). Москва, 2006. С. 409-417.
11. Люгер Дж. Ф. Искусственный интеллект: стратегии и методы решения сложных проблем = Artificial Intelligence: Structures and Strategies for Complex Problem Solving / под ред. Н. Н. Куссуль. 4-е изд. Москва, 2005. 864 с.
12. Плеханов Д. А. Большие данные и официальная статистика: обзор международной практики внедрения новых источников данных // Вопросы статистики. 2017. Т. 1, № 12. С. 49-60.

13. Резниченко Н. С., Шилов С. Н., Абдулкин В. В. Нейросетевой подход в решении медико-психологических проблем и в диагностическом процессе у лиц с ограниченными возможностями здоровья (обзор литературы) // Журнал Сибирского федерального университета. Серия: Гуманитарные науки. 2013. Т. 6, № 9. С. 1256-1264. URL: <https://www.elibrary.ru/item.asp?id=20253460> (дата обращения: 22.05.2024).
14. Славутская Е. В., Вострецова Н. С. Нейросеть как инструмент анализа интеллектуальной и эмоциональной сферы дошкольников // Казанский педагогический журнал. 2019. № 4 (135). С. 61-66.
15. Славутская Е. В., Славутский Л. А. О выборе структуры искусственных нейросетей и алгоритмов анализа психодиагностических данных // Казанский педагогический журнал. 2020. № 5 (142). С. 202-211.
16. Славутская Е. В., Славутский Л. А. Интеллектуальный анализ данных психодиагностики: традиционные методы и современные подходы: монография. Чебоксары, 2022. 218 с. ISBN 978-5-88297-646-9.
17. Славутский А. Л., Славутский Л. А., Алексеев В. В. Нейросетевой алгоритм восстановления в реальном времени сигнала промышленной частоты при нелинейных искажениях // Электротехника. 2021. № 8. С. 21-25.
18. Федотова М. А., Мартынов И. А. Интеллектуальные системы в информационно-аналитических (ситуационных) центрах в условиях перехода к цифровой экономике // Московский экономический журнал. 2019. № 1. С. 32. <https://doi.org/10.24411/2413-046X-2019-11032>.
19. Хайкин С. Нейронные сети: полный курс. 2-е изд. Москва, 2006. 1104 с.
20. Шитиков В. К., Мастицкий С. Э. Классификация, регрессия и другие алгоритмы Data Mining с использованием R. 2017. URL: <https://ranalytics.github.io/data-mining> (дата обращения: 22.05.2024).
21. Bezdek J. C., Keller J. M., Krisnapuram R., Pal N. R. Fuzzy models and algorithms for pattern recognition and image processing. Springer Science & Business Media, 2005. 759 p.
22. Breiman L., Friedman J. H., Olshen R. A., Stone C. J. Classification and regression trees. Monterey CA: Wadsworth & Brooks/Cole Advanced Books & Software, 1984. 366 p.
23. Eidemiller E. G., Yustitsky V. V. Family psychotherapy: The basic principles and practical experience // International Journal of Family Psychiatry. 1989. Vol. 10 (3-4). Pp. 325-337.
24. Golan A., Harte J. Information theory: A foundation for complexity science // Proceedings of the National Academy of Sciences. 2022. Vol. 119, no. 33. <https://doi.org/10.1073/pnas.2119089119>.
25. Grossberg S. A. Path Toward Explainable AI and Autonomous Adaptive Intelligence: Deep Learning, Adaptive Resonance, and Models of Perception, Emotion, and Action // Front Neurobot. 2020. Vol. 14. P. 36. <https://doi.org/10.3389/fnbot.2020.00036>.
26. Grossberg S. Toward Autonomous Adaptive Intelligence: Building Upon Neural Models of How Brains Make Minds // IEEE Transactions on Systems, Man, and Cybernetics: Systems. 2021. Vol. 51 (1). Pp. 51-75. <https://doi.org/10.1109/TSMC.2020.3041476>.
27. Grossberg S. A half century of progress toward a unified neural theory of mind and brain with applications to autonomous adaptive agents and mental disorders // Artificial Intelligence in the Age of Neural Networks and Brain Computing (Second Edition). Academic Press, 2024. Pp. 41-59. ISBN 9780323961042. <https://doi.org/10.1016/B978-0-323-96104-2.00009-9>.
28. Holena M., Pulc P., Kopp M. Classification Methods for Internet Applications. Springer, 2020. 296 p. <https://doi.org/10.1007/978-3-030-36962-0>.

29. Hurlburt G., Reisman S. Experts Speak Out About Artificial Intelligence in Education: Second of Two Panel Roundtables // *Computer*. 2024. Vol. 57 (2). Pp. 14-20. <https://doi.org/10.1109/MC.2023.3334798>.
30. Kantardzic M. *Data mining: concepts, models, methods, and algorithms*. John Wiley & Sons, 2011. 550 p.
31. Keller J. M., Liu D., Fogel D. B. *Fundamentals of computational intelligence neural networks fuzzy systems and evolutionary computation*. Wiley-IEEE Press, 2016. 378 p.
32. Kharitonova Y. S. Legal Means of Providing the Principle of Transparency of the Artificial Intelligence // *Journal of Digital Technologies and Law*. 2023. Vol. 1 (2). Pp. 337-358. <https://doi.org/10.21202/jdtl.2023.14>.
33. Leonowicz Z., Jasinski M. Machine Learning and Data Mining Applications in Power Systems // *Energies*. 2022. Vol. 15 (5). P. 1676. <https://doi.org/10.3390/en15051676>.
34. Rosenblatt F. *Principles of neurodynamics*. Washington: Spartan books, 1962. 616 p.
35. Rumelhart D. E., Hinton G. E., Williams R. J. Learning Internal Representations by Error Propagation // *Parallel Distributed Processing*. Cambridge: MA-MIT Press, 1986. Vol. 1. Pp. 318-362. Available at: [https://stanford.edu/~jlmcc/papers/PDP/Volume%201/Chap8\\_PDP86.pdf](https://stanford.edu/~jlmcc/papers/PDP/Volume%201/Chap8_PDP86.pdf) (accessed: 22.05.2024).
36. Salgado C. M., Fernandes M. P., Horta A., Xavier M., Sousa J. M. C., Vieira S. M. Multistage modeling for the classification of numerical and categorical datasets // *International Conference on Fuzzy Systems (FUZZ-IEEE)*. Naples. Italy, 2017. Pp. 1-6. <https://doi.org/10.1109/FUZZ-IEEE.2017.8015665>.
37. Schaefer E. S., Bell R. Q. Development of a parental attitude research instrument // *Child Development*. 1958. Vol. 29, no. 3. Pp. 339-361. <https://doi.org/10.2307/1126348>.
38. Schmidhuber J. Deep learning in neural networks: An overview // *Neural networks*. 2015. Vol. 61. Pp. 85-117. <https://doi.org/10.48550/arXiv.1404.7828>.
39. Semenov A. L., Kondratiev V. V. Learners as extended minds of the digital age // *Информатизация образования и методика электронного обучения: цифровые технологии в образовании: материалы IV Международной научной конференции: в 2 ч. Ч. 2 (Красноярск, 6–9 октября 2020 г.) / под ред. М. В. Носкова*. Красноярск: Сибирский федеральный университет, 2020. С. 560-566.
40. Sivaraj Priyadharsini. Stability Analysis of Fractional Nonlinear Dynamical Systems // *Debnath P., Torres D. F. M., Cho Yeol Je (eds) Advanced Mathematical Analysis and its Applications*. New York, 2023. <https://doi.org/10.1201/9781003388678-17>.
41. Slavutskaya E., Slavutskii L., Zakharova A., Nikolaev E. Integrated Use of Data Mining Techniques for Personality Structure Analysis // *Bylieva D., Nordmann A. (eds) Technology, Innovation and Creativity in Digital Society. PCSF 2021. Lecture Notes in Networks and Systems*, vol. 345. Springer, Cham, 2022. Pp. 522-533. [https://doi.org/10.1007/978-3-030-89708-6\\_44](https://doi.org/10.1007/978-3-030-89708-6_44).
42. Slavutskaya E., Slavutskii L., Nikolaev E., Zakharova A. Neural Network Models for the Analysis and Visualization of Latent Dependencies: Examples of Psycho Diagnostic Data Processing // *Bylieva D., Nordmann A., Shipunova O., Volkova V. (eds) Knowledge in the Information Society. PCSF CSIS 2020 2020. Lecture Notes in Networks and Systems*, vol. 184. Springer, Cham, 2021. Pp. 61-70. [https://doi.org/10.1007/978-3-030-65857-1\\_7](https://doi.org/10.1007/978-3-030-65857-1_7).
43. Slavutskii L. A., Lazareva N. M., Portnov M. S., Slavutskaya E. V. Neural net without deep learning: signal approximation by multilayer perceptron // *Proceedings. SPIE 12564, 2nd International Conference on Computer Applications for Management and Sustainable*

Development of Production and Industry (CMSD-II-2022), 125640P (5 January 2023). 2023. P. 125640. <https://doi.org/10.1117/12.2669233>.

44. Slavutskaya E., Vostretsova N., Nikolaev E., Zakharova A., Petunova S. Specifics of Interrelations among Emotional, Personal and Intellectual Characteristics in Preschool Children: Data Mining // Proceedings of the International Scientific Conference on Philosophy of Education, Law and Science in the Era of Globalization (PELSEG 2020). Ekaterinburg: Atlantis Press, 2020. Pp. 415-419. <https://doi.org/10.2991/assehr.k.200723.085>.

### References

1. Ageev A. I., Zolotareva O. A., Zolotarev V. A. Russia in the global world of artificial intelligence: assessment according to world ratings. *Ekonomicheskie strategii*, 2022, no. 2 (182), pp. 20-31, <http://dx.doi.org/10.33917/es-2.182.2022.20-31>. (In Russ.)
2. Bichurina S. U., Slavutskaya E. V., Slavutskij L. A., Abrukov V. S., Sadovaya V. V. Vertical system analysis of students' psychodiagnostic data using the "decision tree" method. *Science for Education Today*, 2020, no. 3, pp. 87-107, <http://dx.doi.org/10.15293/2658-6762.2003.05>. (In Russ.)
3. Vyuchejskaya M. V., Krajnova I. N., Griбанov A. V. Neural network technologies in the diagnosis of diseases (review). *ZHurnal mediko-biologicheskikh issledovanij*, 2018, vol. 6, no. 3, pp. 284-294, <https://doi.org/10.17238/issn2542-1298.2018.6.3.284>. (In Russ.)
4. Gorban' A. N., Dunin-Barkovskij V. L., Kiridin A. N., Mirkes E. M., Novohod'ko A. YU., Rossiev D. A., Terekhov S. A., Senashova M. YU., Caregorodcev V. G. Neuroinformatics. Novosibirsk, 1998. 296 p. (In Russ.)
5. Dyuk V., Samojlenko A. Data Mining: training course. St. Petersburg, 2001. 386 p. (In Russ.)
6. Kotlyarova I. O. Technologies of artificial intelligence in education. *Vestnik YUUrGU. Seriya «Obrazovanie. Pedagogicheskie nauki»*, 2022, vol. 14, no. 3, pp. 69-82, <https://doi.org/10.14529/ped220307>. (In Russ.)
7. Kruglov V. V., Borisov V. V. Artificial neural networks. Theory and practice. Moscow, 2001. 382 p. (In Russ.)
8. Kupriyanov R. B., Agranat D. L., Sulejmanov R. S. Using artificial intelligence technologies to build individual educational trajectories of students. *Vestnik Rossijskogo universiteta družby narodov. Seriya: Informatizaciya obrazovaniya*, 2021, vol. 18, no. 1, pp. 27-35, <https://doi.org/10.22363/2312-8631-2021-18-1-27-35>. (In Russ.)
9. BaseGroup laboratory. Data analysis technologies. Available at: <http://www.basegroup.ru> (accessed: 22.05.2024). (In Russ.)
10. Levitin A. V. Limitations on the power of algorithms: Decision Trees. Algorithms. Introduction to Design and Analysis (Chapter 10). Moscow, 2006. Pp. 409-417. (In Russ.)
11. Lyuger Dzh. F. Artificial Intelligence: Strategies and Methods for Solving Complex Problems / ed. N. N. Kussul. 4th ed. Moscow, 2005. 864 p. (In Russ.)
12. Plekhanov D. A. Big data and official statistics: a review of international practice in introducing new data sources. *Voprosy statistiki*, 2017, vol. 1, no. 12, pp. 49-60. (In Russ.)
13. Reznichenko N. S., SHilov S. N., Abdulkin V. V. Neural network approach to solving medical and psychological problems and in the diagnostic process for persons with disabilities (literature review). *ZHurnal Sibirskogo federal'nogo universiteta. Seriya: Gumanitarnye nauki*, 2013, vol. 6, no. 9, pp. 1256-1264. Available at: <https://www.elibrary.ru/item.asp?id=20253460> (accessed: 22.05.2024). (In Russ.)

14. Slavutskaya E. V., Vostrecova N. S. Neural network as a tool for analyzing the intellectual and emotional sphere of preschoolers. *Kazanskij pedagogicheskij zhurnal*, 2019, no. 4 (135), pp. 61-66. (In Russ.)
15. Slavutskaya E. V., Slavutskij L. A. On the choice of the structure of artificial neural networks and algorithms for analyzing psychodiagnostic data. *Kazanskij pedagogicheskij zhurnal*, 2020, no. 5 (142), pp. 202-211. (In Russ.)
16. Slavutskaya E. V., Slavutskij L. A. Intellectual analysis of psychodiagnostic data: traditional methods and modern approaches: monograph. Cheboksary, 2022. 218 p. ISBN 978-5-88297-646-9. (In Russ.)
17. Slavutskij A. L., Slavutskij L. A., Alekseev V. V. Neural network algorithm for real-time reconstruction of an industrial frequency signal with nonlinear distortions. *Elektrotehnika*, 2021, no. 8, pp. 21-25. (In Russ.)
18. Fedotova M. A., Martynov I. A. Intelligent systems in information and analytical (situational) centers in the context of the transition to a digital economy. *Moskovskij ekonomicheskij zhurnal*, 2019, no. 1, pp. 32, <https://doi.org/10.24411/2413-046X-2019-11032>. (In Russ.)
19. Hajkin S. Neural networks: a complete course. 2nd ed. Moscow, 2006. 1104 p. (In Russ.)
20. SHitikov V. K., Mastickij S. E. Classification, regression and other Data Mining algorithms using R. 2017. Available at: <https://ranalytics.github.io/data-mining> (accessed: 22.05.2024). (In Russ.)
21. Bezdek J. C., Keller J. M., Krisnapuram R., Pal N. R. Fuzzy models and algorithms for pattern recognition and image processing. Springer Science & Business Media, 2005. 759 p.
22. Breiman L., Friedman J. H., Olshen R. A., Stone C. J. Classification and regression trees. Monterey CA, Wadsworth & Brooks/Cole Advanced Books & Software, 1984. 366 p.
23. Eidemiller E. G., Yustitsky V. V. Family psychotherapy: The basic principles and practical experience. *International Journal of Family Psychiatry*, 1989, vol. 10 (3-4), pp. 325-337.
24. Golan A., Harte J. Information theory: A foundation for complexity science. *Proceedings of the National Academy of Sciences*, 2022, vol. 119, no. 33, <https://doi.org/10.1073/pnas.2119089119>.
25. Grossberg S. A. Path Toward Explainable AI and Autonomous Adaptive Intelligence: Deep Learning, Adaptive Resonance, and Models of Perception, Emotion, and Action. *Front Neurorobot*, 2020, vol. 14, p. 36, <https://doi.org/10.3389/fnbot.2020.00036>.
26. Grossberg S. Toward Autonomous Adaptive Intelligence: Building Upon Neural Models of How Brains Make Minds. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2021, vol. 51 (1), pp. 51-75, <https://doi.org/10.1109/TSMC.2020.3041476>.
27. Grossberg S. A half century of progress toward a unified neural theory of mind and brain with applications to autonomous adaptive agents and mental disorders. *Artificial Intelligence in the Age of Neural Networks and Brain Computing (Second Edition)*. Academic Press, 2024. Pp. 41-59. ISBN 9780323961042. <https://doi.org/10.1016/B978-0-323-96104-2.00009-9>.
28. Holena M., Pulc P., Kopp M. Classification Methods for Internet Applications. Springer, 2020. 296 p. <https://doi.org/10.1007/978-3-030-36962-0>.
29. Hurlburt G., Reisman S. Experts Speak Out About Artificial Intelligence in Education: Second of Two Panel Roundtables. *Computer*, 2024, vol. 57 (2), pp. 14-20, <https://doi.org/10.1109/MC.2023.3334798>.
30. Kantardzic M. Data mining: concepts, models, methods, and algorithms. John Wiley & Sons, 2011. 550 p.

31. Keller J. M., Liu D., Fogel D. B. Fundamentals of computational intelligence neural networks fuzzy systems and evolutionary computation. Wiley-IEEE Press, 2016. 378 p.
32. Kharitonova Y. S. Legal Means of Providing the Principle of Transparency of the Artificial Intelligence. *Journal of Digital Technologies and Law*, 2023, vol. 1 (2), pp. 337-358, <https://doi.org/10.21202/jdtl.2023.14>.
33. Leonowicz Z., Jasinski M. Machine Learning and Data Mining Applications in Power Systems. *Energies*, 2022, vol. 15 (5), p. 1676, <https://doi.org/10.3390/en15051676>.
34. Rosenblatt F. Principles of neurodynamics. Washington, Spartan books, 1962. 616 p.
35. Rumelhart D. E., Hinton G. E., Williams R. J. Learning Internal Representations by Error Propagation. *Parallel Distributed Processing*. Cambridge, MA-MIT Press, 1986. Vol. 1. Pp. 318-362. Available at: [https://stanford.edu/~jlmcc/papers/PDP/Volume%201/Chap8\\_PDP86.pdf](https://stanford.edu/~jlmcc/papers/PDP/Volume%201/Chap8_PDP86.pdf) (accessed: 22.05.2024).
36. Salgado C. M., Fernandes M. P., Horta A., Xavier M., Sousa J. M. C., Vieira S. M. Multistage modeling for the classification of numerical and categorical datasets. *International Conference on Fuzzy Systems (FUZZ-IEEE)*. Naples. Italy, 2017. Pp. 1-6. <https://doi.org/10.1109/FUZZ-IEEE.2017.8015665>.
37. Schaefer E. S., Bell R. Q. Development of a parental attitude research instrument. *Child Development*, 1958, vol. 29, no. 3, pp. 339-361, <https://doi.org/10.2307/1126348>.
38. Schmidhuber J. Deep learning in neural networks: An overview. *Neural networks*, 2015, vol. 61, pp. 85-117, <https://doi.org/10.48550/arXiv.1404.7828>.
39. Semenov A. L., Kondratiev V. V. Learners as extended minds of the digital age. *Informatizaciya obrazovaniya i metodika elektronogo obucheniya: cifrovye tekhnologii v obrazovanii: materialy IV Mezhdunarodnoj nauchnoj konferencii: v 2 ch. CH. 2 (Krasnoyarsk, 6–9 oktyabrya 2020 g.) / pod redakciej M. V. Noskova*. Krasnoyarsk, Sibirskij federal'nyj universitet Publ., 2020. Pp. 560-566.
40. Sivaraj Priyadharsini. Stability Analysis of Fractional Nonlinear Dynamical Systems. *Debnath P., Torres D. F. M., Cho Yeol Je (eds) Advanced Mathematical Analysis and its Applications*. New York, 2023. <https://doi.org/10.1201/9781003388678-17>.
41. Slavutskaya E., Slavutskii L., Zakharova A., Nikolaev E. Integrated Use of Data Mining Techniques for Personality Structure Analysis. *Bylieva D., Nordmann A. (eds) Technology, Innovation and Creativity in Digital Society. PCSF 2021. Lecture Notes in Networks and Systems, vol. 345*. Springer, Cham, 2022. Pp. 522-533. [https://doi.org/10.1007/978-3-030-89708-6\\_44](https://doi.org/10.1007/978-3-030-89708-6_44).
42. Slavutskaya E., Slavutskii L., Nikolaev E., Zakharova A. Neural Network Models for the Analysis and Visualization of Latent Dependencies: Examples of Psycho Diagnostic Data Processing. *Bylieva D., Nordmann A., Shipunova O., Volkova V. (eds) Knowledge in the Information Society. PCSF CSIS 2020 2020. Lecture Notes in Networks and Systems, vol. 184*. Springer, Cham, 2021. Pp. 61-70. [https://doi.org/10.1007/978-3-030-65857-1\\_7](https://doi.org/10.1007/978-3-030-65857-1_7).
43. Slavutskii L. A., Lazareva N. M., Portnov M. S., Slavutskaya E. V. Neural net without deep learning: signal approximation by multilayer perceptron. *Proceedings. SPIE 12564, 2nd International Conference on Computer Applications for Management and Sustainable Development of Production and Industry (CMSD-II-2022), 125640P (5 January 2023)*. 2023. P. 125640. <https://doi.org/10.1117/12.2669233>.
44. Slavutskaya E., Vostretsova N., Nikolaev E., Zakharova A., Petunova S. Specifics of Interrelations among Emotional, Personal and Intellectual Characteristics in Preschool Children: Data Mining. *Proceedings of the International Scientific Conference on Philosophy*

*of Education, Law and Science in the Era of Globalization (PELSEG 2020)*. Ekaterinburg, Atlantis Press, 2020. Pp. 415-419. <https://doi.org/10.2991/assehr.k.200723.085>.

© Славутская Е. В., Славутский Л. А., 2024

### Информация об авторах

**Славутская Елена Владимировна** – доктор психологических наук, профессор кафедры педагогики и психологии, Чувашский государственный педагогический университет имени И. Я. Яковлева, Чебоксары, Российская Федерация, ORCID: <https://orcid.org/0000-0002-3759-6288>, ResearcherID: [Q-7031-2018](https://orcid.org/Q-7031-2018), [slavutskayaev@gmail.com](mailto:slavutskayaev@gmail.com)

**Славутский Леонид Анатольевич** – доктор физико-математических наук, профессор кафедры автоматизации и управления в технических системах, Чувашский государственный университет, Чебоксары, Российская Федерация, ORCID: <https://orcid.org/0000-0001-6783-2985>, ResearcherID: [M-6976-2018](https://orcid.org/M-6976-2018), [lenya@slavutskii.ru](mailto:lenya@slavutskii.ru)

### Information about the authors

**Slavutskaya Elena V.** – Doctor of Psychological Sciences, Professor, Department of Psychology and Social Pedagogy, I. Ya. Yakovlev Chuvash State Pedagogical University, Cheboksary, Russian Federation, ORCID: <https://orcid.org/0000-0002-3759-6288>, ResearcherID: [Q-7031-2018](https://orcid.org/Q-7031-2018), [slavutskayaev@gmail.com](mailto:slavutskayaev@gmail.com)

**Slavutskii Leonid A.** – Doctor of Physical and Mathematical Sciences, Professor, Department of Automation and Control in Technical Systems, Chuvash State University, Cheboksary, Russian Federation, ORCID: <https://orcid.org/0000-0001-6783-2985>, ResearcherID: [M-6976-2018](https://orcid.org/M-6976-2018), [lenya@slavutskii.ru](mailto:lenya@slavutskii.ru)

### Вклад авторов

**Славутская Елена Владимировна** – постановка задач, психодиагностические данные, анализ и интерпретация результатов.

**Славутский Леонид Анатольевич** – примеры технических приложений, обработка данных, анализ результатов

### Contribution of the authors

**Slavutskaya Elena V.** – problem setting, psycho diagnostic data, analysis and interpretation of results.

**Slavutskii Leonid A.** — examples of technical applications, data processing, analysis of results.

Поступила в редакцию: 03.03.2024

Принята к публикации: 20.06.2024

Опубликована: 28.06.2024