

## О качестве обучения основанных на корнях принятия решений неполносвязных нейронных сетей в условиях ограниченных данных

*А.О. Алексеев, Л.В. Кожемякин*

*Пермский национальный исследовательский политехнический университет, Пермь  
Пермский центр поддержки принятия решений, Пермь*

**Аннотация:** Обсуждается качество обучения неполносвязных нейронных сетей, основанных на корнях принятия решений. На примере ограниченных данных о пациентах с клинически диагностированной болезнью Альцгеймера и условно здоровых пациентов путем преобработки данных найден корень принятия решений и соответствующая структура нейронной сети. Впервые демонстрируются результаты обучения неполносвязной искусственной нейронной сети данного типа. Результаты обучения такого типа нейронных сетей позволили в условиях ограниченных данных найти нейронную сеть, обладающую приемлемым уровнем точности для практического применения полученной нейронной сети в задаче поддержки принятия врачебных решений – в рассматриваемом примере для диагностики болезни Альцгеймера.

**Ключевые слова:** нейронные сети, механизмы комплексного оценивания; корни принятия решений, деревья критериев, матрицы свёртки, преобработка данных.

### Введение

Для достижения высокого уровня точности искусственных нейронных сетей (ИНС) необходим достаточно большой набор исходных данных для обучения, валидации и тестирования получаемых моделей. Нейронные сети, несмотря на высокую аппроксимирующую способность, не всегда способны показать высокий уровень точности в условиях с ограничениями по объему исходной выборки. Поэтому появляется потребность в разработке новых нейросетевых моделей, которые смогли бы описать исходный ограниченный набор данных с высоким уровнем точности.

### Теоретический анализ

Научной гипотезой последних исследований авторов [1] является предположение, что в условиях ограниченных данных путем их интервального кодирования можно получить в закодированном виде такой набор дискретных данных, что по ним можно построить дискретную функцию многих переменных в виде суперпозиции функций двух

---

переменных, каждая из которых представляется в матричном виде и соответствует определенному узлу ориентированного полного бинарного графа с поименными листьями, по которой, в свою очередь, можно предопределить структуру искусственной нейронной сети, которая после обучения по исходным данным будет обладать приемлемым уровнем точности для практического применения.

Основаниями для настоящей гипотезы является показанная в [1] возможность представления таких дискретных функции в виде неполносвязных искусственных нейронных сетей, которые полностью воспроизводят исходные данные в закодированном виде. Ожидаемо, что при обучении нейронной сети с найденной таким образом структурой по исходным данным, принадлежащим определенным интервалам, в процессе обучения будут подобраны параметры активационных функций, которые будут давать приемлемую точность.

Дискретные функции в виде совокупности порядковых шкал, дерева критериев с бинарной структурой и набора матриц свертки в [1] предложено называть «корнями принятия решений», поэтому в настоящей работе при описании нейронных сетей, речь будет идти об обучении основанных на корнях принятия решений нейронных сетях, на английском языке предлагается их называть Decisions-Root-based Neural Network (DRB NN).

В работе [1] показан пример построения корня принятия решений для диагностики болезни Альцгеймера, поэтому настоящая работа является ее логическим продолжением. Однако там же [1] было показано, что до настоящего времени отсутствовали доступные для пользователей без навыков программирования решения, позволяющие обучать нейронные сети, основанные на корнях принятия решений.

В конце 2023 года благодаря гранту Фонда содействия инновациям в рамках научно-исследовательских и опытно-конструкторских работ [2] при

---

непосредственном участии авторов настоящей работы был разработан специальный программный модуль [3], который позволит выполнить настоящее исследование.

Целью настоящего исследования является проверка гипотезы о приемлемом качестве обучения в условиях ограниченных данных неполносвязной нейронной сети, основанной на полученном в [1] корне принятия решений.

### **Материалы и данные**

В качестве исходных данных, как и в работе [1], выступают сведения о 59 пациентах с клинически диагностированной болезнью Альцгеймера и 21 условно здоровых пациентах. Эти сведения приведены в приложении к работе [4]. Как видно, исходные данные весьма ограничены в своем количестве.

Согласно [4], пациенты были обследованы с помощью мини-тестирования психического состояния (MMSE), Монреальского когнитивного теста (MoCA), задачи рисования часов (CDT) и шкалы активности повседневной жизни (ADL). Болезнь Альцгеймера была клинически диагностирована у 59 человек. Этим больных здесь и далее определяют, как это сделано в работе [4], как группу AD. 22 пациента не имеют проблем с когнитивными способностями и включены в контрольную группу (обозначается как группа CON).

В приложении к работе [4] приведены значения магнитной восприимчивости (MSV) левой и правой базальных вен (L\_BV и R\_BV соответственно), левой и правой внутренних мозговых вен (L\_ICV, R\_ICV), левой и правой вен таламуса (L\_TV, R\_TV), левой и правой перегородочных вен (L\_SV, R\_SV), левой и правой вен зубчатого ядра (L\_DNV, R\_DNV) (таблица 1).

Таблица № 1

Фрагмент исходных данных MSV головного мозга<sup>1</sup>

Субъект (пациент)	Группа	L_BV	R_BV	L_ICV	R_ICV	L_TV	R_TV	L_SV	R_SV	L_DNV	R_DNV
sub001	1	279	288	255	263	140	138	131	131	165	185
sub002	1	274	247	223	243	239	262	190	222	204	102
...											
sub080	0	249	232	221	232	154	142	165	151	161	143
sub081	0	300	259	295	299	216	197	163	131	162	129

<sup>1</sup> В этой таблице в столбце «Группа» 1 обозначает AD группу, 0 – CON группу.

### Методика

На первом этапе анализа данных предлагается проводить предварительную обработку исходных наборов для определения параметров ИНС на основе корня принятия решений. Научная гипотеза заключается в предположении, что получить приемлемую точность нейронной сети можно будет путем обучения предопределенной ИНС на исходных данных в непрерывной форме. В настоящей работе обсуждается проблема выбора структуры нейронных сетей.

Предварительная обработка данных заключается в интервальном кодировании исходных данных и поиске механизма комплексного оценивания (корня принятия решений).

Согласно [5], механизм комплексного оценивания (МКО) определяется как кортеж:

$$\langle G, M, X, P \rangle \quad (1)$$

где G – граф, описывающий последовательность свертки частных критериев, M – множество матриц свертки, соответствующих узлам дерева критериев, X

– множество шкал для оценки частных критериев,  $P$  – процедура агрегирования.

Одной из проблем при идентификации МКО является выбор структуры графа  $G$ , представляющего собой полное бинарное дерево с поимёнными листьями [6], так как их общее количество определяется по уравнению [7, 8]:

$$|G| = (2l - 3)!! \quad (2)$$

где  $l$  – общее количество рассматриваемых переменных (листьев в терминах древовидного графа). Количество структур  $G$  существенно зависит от числа переменных.

Для уменьшения числа переменных и решения задачи классификации использовались методы системно-когнитивного анализа (далее СКА), применяя программу для электронных вычислительных машин «EIDOS-X Professional (Система «EIDOS-Xpro»)» [9], разработанную профессором Луценко Е.В.

Алгоритм идентификации МКО [5] был использован для структурирования данных и представления их в виде корня принятия решений. Обучение нейронных сетей в настоящем исследовании выполнено с помощью программного модуля проектирования и обучения нейронных сетей, основанных на корнях принятия решений (Software Module for Designing and Training Decisions Root-based Neural Networks) [3].

## Результаты

### *Результаты предварительной обработки данных.*

Области наблюдаемых значений MSV были разделены на 3 равных интервала для каждой вены, т.к. при выборе 2 интервалов получается классическая задача нахождения булевой функции, а при выборе 4 интервалов формируется 80 признаков, а исходный набор данных, который

---

необходимо разделить на обучающее и тестовое множества, содержит всего 81 пример.

В результате применения методов СКА число анализируемых вен было сокращено до четырех: L\_BV, R\_BV, L\_TV, R\_TV. В таблице №2 приведены их интервалы для дискретного кодирования.

Таблица №2

Интервалы для дискретного кодирования наиболее значимых вен для диагностики болезни Альцгеймера

Переменная (вена)	Область определения MSV	1-й интервал	2-й интервал	3-й интервал
L_BV	{153,0; 324,0}	{153,0; 210,0}	{210,0; 267,0}	{267,0; 324,0}
R_BV	{164,0; 357,0}	{164,0; 228,3}	{228,3; 292,7}	{292,7; 357,0}
L_TV	{131,0; 288,0}	{131,0; 183,3}	{183,3; 235,7}	{235,7; 288,0}
R_TV	{109,0; 286,0}	{109,0; 168,0}	{168,0; 227,0}	{227,0; 286,0}

*Результаты интервального кодирования исходных данных в дискретные значения и выбор архитектуры нейронной сети.*

Исходные данные [4] были интервально закодированы, путем замены значений MSV у конкретного пациента в конкретных венах (L\_BV, R\_BV, L\_TV, R\_TV) на номера интервалов (таблица 3).

Таблица №3

Фрагмент закодированных данных

Субъект (пациент)	Группа	Закодированная переменная L_BV	Закодированная переменная L_TV	Закодированная переменная R_BV	Закодированная переменная R_TV
sub001	AD	3	1	2	1
sub002	AD	3	3	2	3
...					
sub080	CON	2	1	2	1
sub081	CON	3	2	2	2

В закодированном наборе данных встретились противоречивые примеры, имеющие одинаковые вектора дискретных значений, но

относящиеся к разным группам: AD и CON. Для сокращения противоречивых примеров, были исключены те подгруппы или субъекты, которые имели высокий уровень схожести с одной группой, в то время как по факту они относились к другой группе. Обучающая выборка после исключения конфликтных примеров включает 34 уникальных закодированных вектора. Им соответствовало 63 человека (пациента), что составило 78% от исходного числа людей.

Для 4-х факторов возможны 15 полных бинарных деревьев с поименованными листьями. Из всех возможных древовидных структур в [1] предложено воспроизводить свертки показателей, характеризующие левые вены друг с другом, а также правые друг с другом, в связи с особенностью физиологической работы кровообращения двух полушарий. Для каждой древовидной структуры критериев можно выделить несколько корней принятия решений, один из возможных примеров представлен в [1].

Следующий корень принятия решений (рис.1) был определен на основе обучающей выборки после исключения конфликтных примеров.

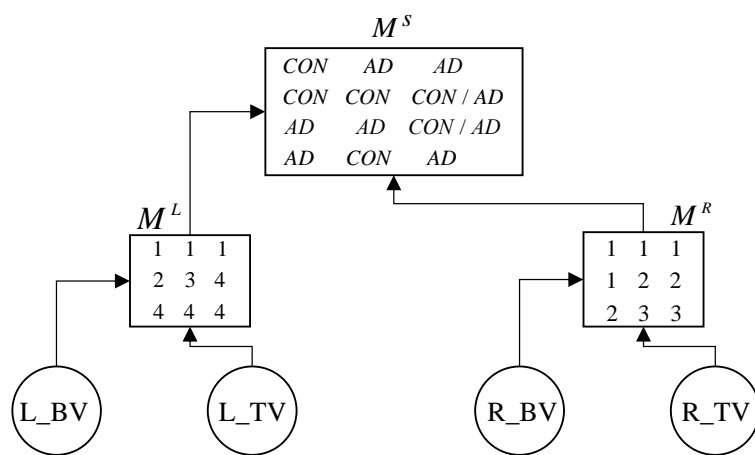


Рис. 1. – Корень принятия решений для постановки диагноза болезни Альцгеймера [1]

Представленный на рисунке выше (рис. 1) корень принятия решений отличается от найденного в [10], поскольку в работе [1] при принятии решений об исключении противоречивых примеров из исходных данных

дополнительно учитывалась информация о степени сходства с классами CON или AD. С одной стороны это сделало корень принятия решений более достоверным, с другой стороны в корневой матрице не смогли быть до конца идентифицированы два элемента (рис. 1, вторая и третья строка третьего столбца корневой матрицы). В действительности, этим элементам соответствуют как здоровые пациенты, так и пациенты с клинически диагностированным заболеванием Альцгеймера. В отношении этих пациентов результаты СКА были не информативными, поэтому сделать выбор в пользу какой-либо группы было невозможно.

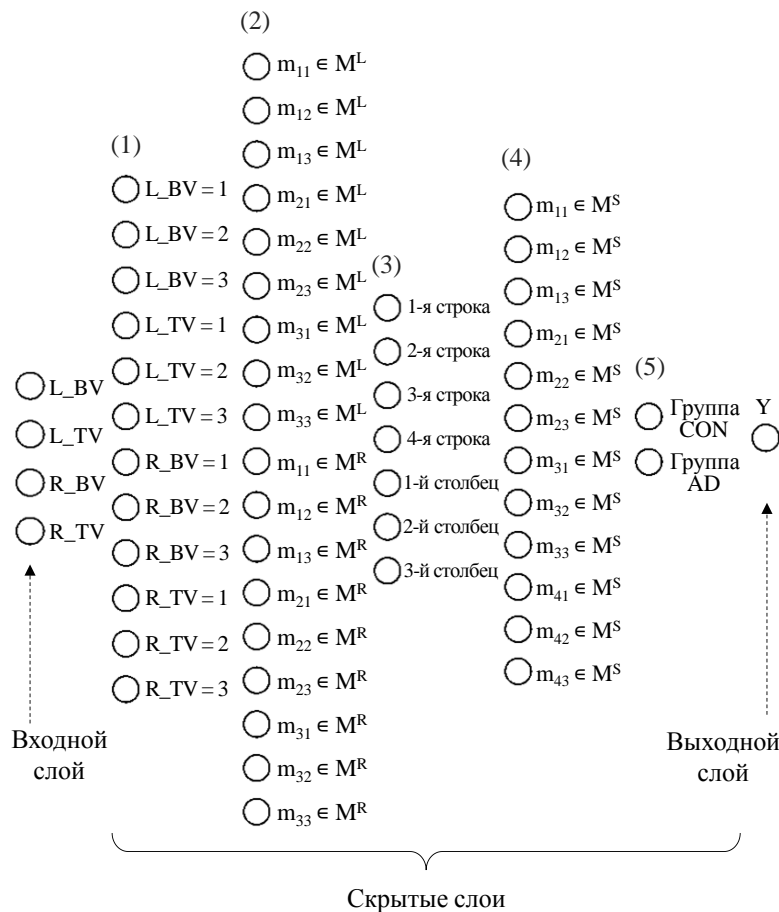


Рис. 2. – Нейроны искомой искусственной нейронной сети (вектор нейронов на входном слое  $\in R^4$ , вектор нейронов на скрытом слое (1)  $\in R^{12}$ , вектор нейронов на скрытом слое (2)  $\in R^{18}$ , вектор нейронов на скрытом слое (3)  $\in R^7$ , вектор нейронов на скрытом слое (4)  $\in R^{12}$ , вектор нейронов на скрытом слое (5)  $\in R^2$ , вектор нейронов на выходном слое  $\in R^1$ )



### *Результаты построения полносвязной нейронной сети.*

В работе [1] показано, что корень принятия решений с бинарной последовательной и непоследовательной структурой деревьев, может быть представлен в форме искусственной нейронной сети (далее ИНС). Спецификация структуры и связь между слоями и нейронами полносвязной нейронной сети, полученной на основе корня принятия решений (рис.1), представлены на рис.2 и рис.3.

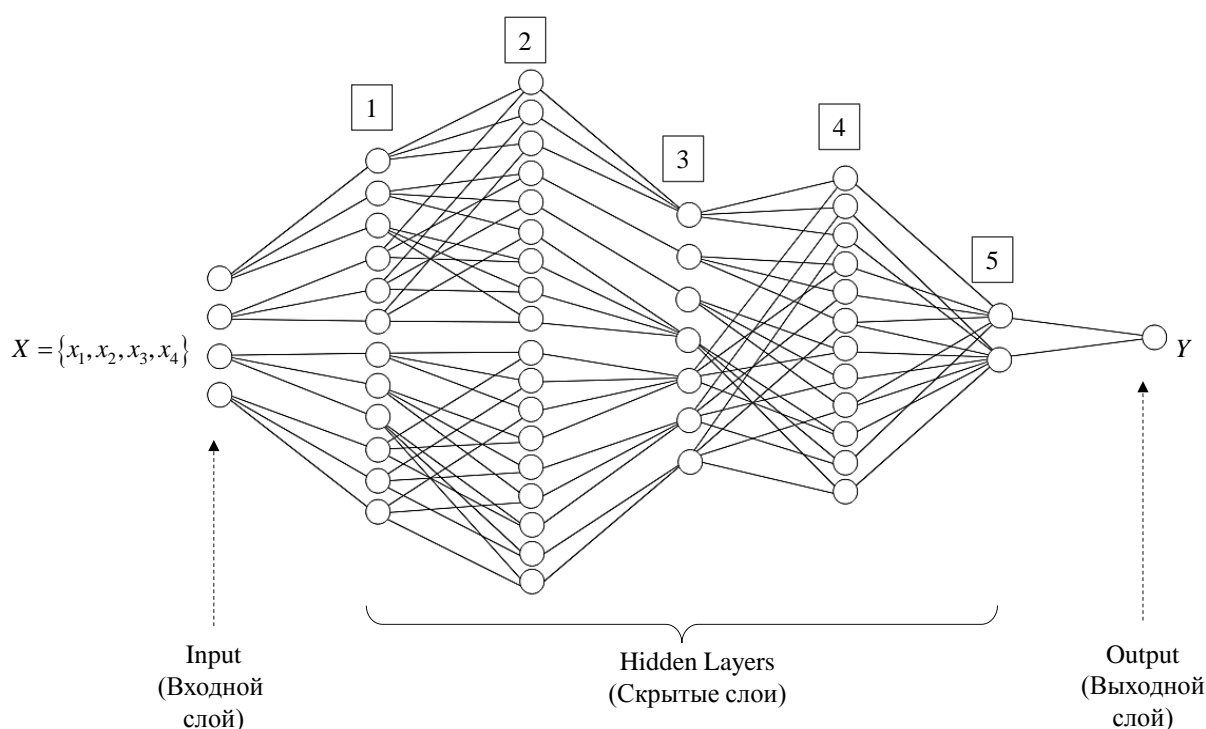


Рис. 3. – Полносвязная ИНС, основанная на корне принятия решений

Согласно общепринятой технологии проектирования ИНС все множество примеров разбивается на обучающее, тестирующее и валидирующее в соотношении 70% : 20% : 10% [11]. Однако в работе [11, с. 143] отмечается, что при небольшом количестве примеров допускается разделять весь исходный набор данных только на обучающее и тестирующее множество в соотношении 90% : 10%. В настоящем исследовании исходный набор данных содержит всего 81 пример, поэтому будем придерживаться подхода [11].

За активационную функцию был принят параметрический линейный выпрямитель (PreLU). В качестве алгоритма обучения выбран Adam (Adaptive Moment Estimation). Метриками качества обучения полносвязной ИНС на обучающем (Train) и валидирующем (Validation) множествах (рис.4, рис.5) были выбраны точность (Accuracy) и среднеквадратическая ошибка обучения (Mean Squared Error).

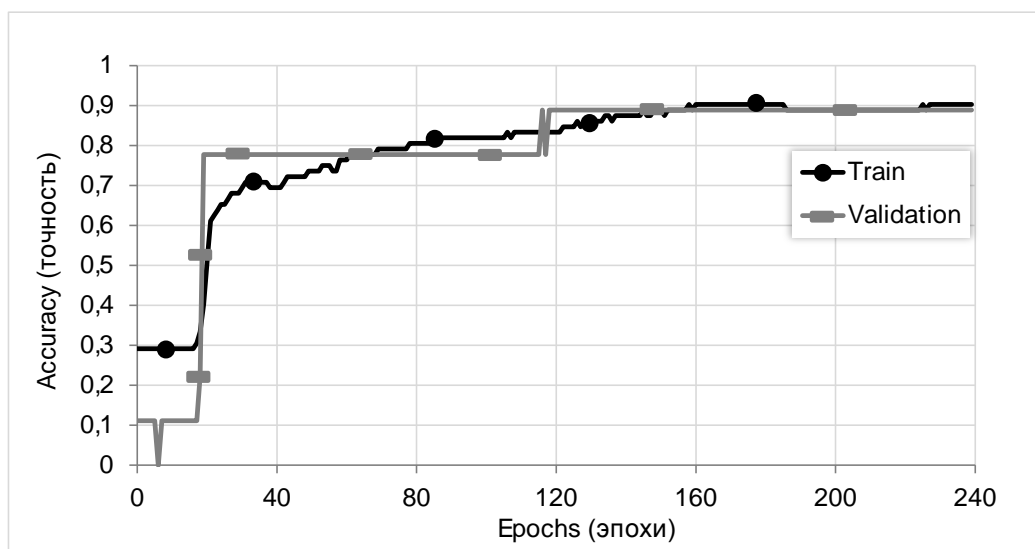


Рис. 4. – Изменение точности полносвязной нейронной сети, основанной на корне принятия решений в процессе нейросетевого моделирования

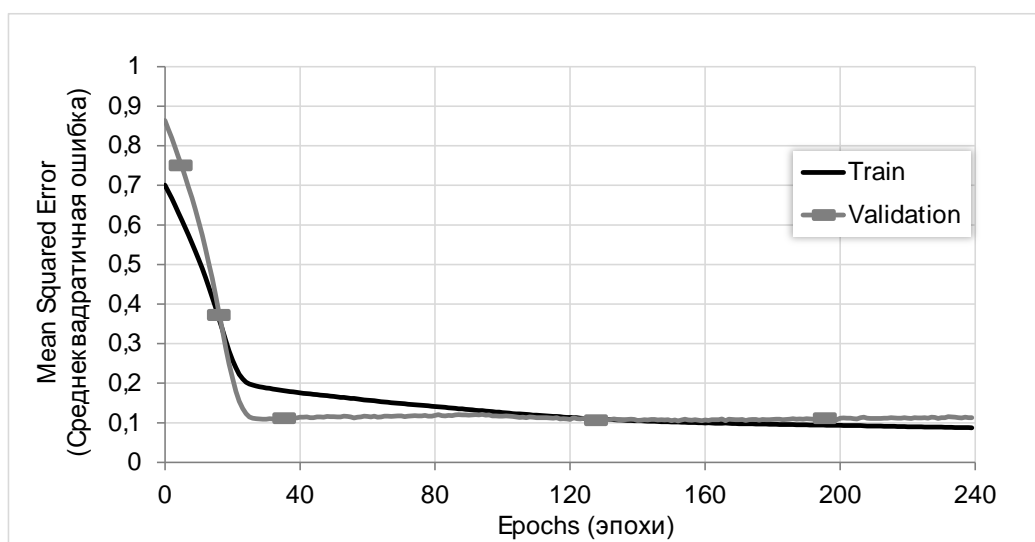


Рис. 5. – Изменение среднеквадратической ошибки обучения полносвязной нейронной сети, основанной на корне принятия решений в процессе нейросетевого моделирования

Результаты нейросетевого моделирования неполносвязной нейронной сети, основанной на корне принятия решений, имеют следующие значения: среднеквадратическая ошибка на обучающем множестве составила 8,8%; на валидирующем множестве составила 11%; точность полученной модели на обучающем множестве составила 90%; точность полученной модели на валидирующем множестве составила 89%.

### **Заключение**

Таким образом, с помощью специальных методов, основанных на МКО, удалось получить структуру неполносвязной нейросетевой модели, способную с достаточной точностью описывать изучаемую область на примере болезни Альцгеймера. Это еще раз подтверждает, что нейросетевые технологии достаточно успешны в медицине, что особенно ценно при ограниченном наборе исходных данных. Аналогичные выводы об успешном применении нейросетевого моделирования в медицине [12–15], и, в частности, при изучении мозга, можно найти в источниках [16–18], где предлагалось использовать свёрточные ИНС и модели глубокого обучения, что подтверждает значимость нейросетевых технологий в анализе медицинских данных.

### **Литература**

1. Alekseev A.O., Kozhemyakin L.V., Nikitin V.N., Bolshakova J.A. Data Preprocessing and Neural Network Architecture Selection Algorithms in Cases of Limited Training Sets – On an Example of Diagnosing Alzheimer’s Disease // Algorithms. 2023. Vol. 16. Art. 219. DOI: 10.3390/a16050219. URL: [mdpi.com/1999-4893/16/5/219](https://mdpi.com/1999-4893/16/5/219).
  2. Алексеев А.О., Кожемякин Л.В., Маккавеев А.В., Никитин В.Н. Отчет о НИОКР «Разработка и тестирование прототипа многопользовательской виртуальной среды интеллектуального анализа данных». Рег. № НИОКР 122122600007-1. Пермь, 2023. 64 с.
-

3. Алексеев А.О., Кожемякин Л.В., Маккавеев А.В. Свидетельство о государственной регистрации программы для ЭВМ № 2023685360 Российская Федерация. Программный модуль проектирования и обучения нейронных сетей, основанных на корнях принятия решений (Software Module for Designing and Training Decisions Root-based Neural Networks) // Программы для ЭВМ. Базы данных. Топологии интегральных микросхем. 2023. Бюл. № 12. 1 с.

4. Liu Y., Dong J., Song Q., Zhang N., Wang W., Gao B., Tian S., Dong C., Liang Z., Xie L., Miao Y. Correlation between cerebral venous oxygen level and cognitive status in patients with Alzheimer's disease using quantitative susceptibility mapping // *Frontiers in Neuroscience*. 2021. Vol. 14. Art. 570848. DOI: 10.3389/fnins.2020.570848. URL: [frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2020.570848/full](https://frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2020.570848/full).

5. Alekseev A.O. Identification of integrated rating mechanisms based on training set // *Proceedings of the 2020 2nd International Conference on Control Systems. Mathematical Modeling, Automation and Energy Efficiency (SUMMA)*. Lipetsk, Russia, 11-13 November. 2020. pp. 398–403. DOI: 10.1109/SUMMA50634.2020.9280751.

6. Barnett J.F., Correia H., Johnson P.D., Laughlin M.G., Wilson K. Meets Graph Theory on a Strange Planet: Counting Full n-ary Trees with Labeled Leafs // *Alabama Journal of Mathematics*. 2010. Vol. 35. pp. 16-23.

7. Korgin N., Sergeev V. Identification of integrated rating mechanisms on complete data sets. In *Advances in Production Management Systems // Artificial Intelligence for Sustainable and Resilient Production Systems. APMS 2021. IFIP Advances in Information and Communication Technology*. 2021. pp. 610-616. DOI: 10.1007/978-3-030-85874-2\_66.

8. Korgin N.A., Sergeev V.A. Identification of integrated rating mechanisms as an approach to discrete data analysis // *IFAC-PapersOnLine*. 2021. Vol. 54. Iss. 13. pp. 134-139. DOI: 10.1016/j.ifacol.2021.10.433.

---

9. Луценко, Е.В. Программа для ЭВМ RU 2022615135 «Персональная интеллектуальная онлайн-среда разработки «EIDOS-X Professional» (Система «EIDOS-Xpro»)» / Е. В. Луценко // Программы для ЭВМ. Базы данных. Топологии интегральных микросхем. База данных. Топологии интегральных схем. – 2022. – Бюл. № 4. – 1 с.

10. Кожемякин Л.В., Никитин В.Н., Алексеев А.О. Применение корней принятия решений для определения взаимосвязи между магнитной восприимчивостью вен головного мозга и наличием болезни Альцгеймера // Управление большими системами: труды XVIII Всероссийской школы-конференции молодых ученых. Челябинск. 05–08 сентября 2022 года. Челябинск: Издательский центр ЮУрГУ. 2022. С. 318–324.

11. Ясницкий Л.Н. Искусственный интеллект. Элективный курс: учеб. пособие. – М.: БИНОМ. Лаборатория знаний. 2011. – 197 с.

12. Сасов Д.А., Зубков А.В., Орлова Ю.А., Турицына А.В. Классификация рака молочной железы с помощью сверточных нейронных сетей // Инженерный вестник Дона, 2023, № 6. URL: [ivdon.ru/ru/magazine/archive/n6y2023/8507](http://ivdon.ru/ru/magazine/archive/n6y2023/8507).

13. Дунин В.О., Егоров В.А. Проблемы создания интеллектуальных средств поиска, анализа и обработки биомедицинской информации // Инженерный вестник Дона, 2012, № 4-1. URL: [ivdon.ru/ru/magazine/archive/n4p1y2012/1220](http://ivdon.ru/ru/magazine/archive/n4p1y2012/1220).

14. Gruvberger-Saal S.K., Edén P., Ringnér M., Baldetorp B., Chebil G., Borg A., Fernö M., Peterson C., Meltzer P.S. Predicting continuous values of prognostic markers in breast cancer from microarray gene expression profiles // Molecular Cancer Therapeutics. 2004. Vol. 3. № 2. pp. 161–168.

15. Carrara M., Bono A., Bartoli C., Colombo A., Lualdi M., Moglia D., Santoro N., Tolomio E., Tomatis S., Tragni G., Santinami M., Marchesini R. Multispectral imaging and artificial neural network: mimicking the management decision of the clinician facing pigmented skin lesions // Physics in Medicine & Biology. 2007. Vol. 52. № 9. pp. 2599–2613. DOI: 10.1088/0031-9155/52/9/018.

---

16. Chang P.D., Kuoy E., Grinband J., Weinberg B.D., Thompson M., Homo R., Chen J., Abcede H., Shafie M., Sugrue L., Filippi C.G., Su M.Y., Yu W., Hess C., Chow D. Hybrid 3D/2D convolutional neural network for hemorrhage evaluation on head CT // American Journal of Neuroradiology. 2018. Vol. 39. Iss. 9. pp. 1609–1616. DOI: 10.3174/ajnr.A5742.

17. Chao P.J., Chang L., Kang C.L., Lin C.H., Shieh C.S., Wu J.M., Tseng C.D., Tsai I.H., Hsu H.C., Huang Y.J., Lee T.F. Using deep learning models to analyze the cerebral edema complication caused by radiotherapy in patients with intracranial tumor // Scientific Reports. 2022. Vol. 12. Iss. 1. Art. 1555. 11 p. DOI: 10.1038/s41598-022-05455-w.

18. Esmailzadeh S., Belivanis D., Pohl K., Adeli E. End-To-End Alzheimer's Disease Diagnosis and Biomarker Identification // Proceedings of Machine learning in medical imaging. 2018. Vol. 11046. pp. 337-345. DOI: 10.1007/978-3-030-00919-9\_39.

### References

1. Alekseev A.O., Kozhemyakin L.V., Nikitin V.N., Bolshakova J.A. Algorithms. 2023. Vol. 16. Art. 219. DOI: 10.3390/a16050219. URL: [mdpi.com/1999-4893/16/5/219](https://mdpi.com/1999-4893/16/5/219).

2. Alekseev A.O., Kozhemjakin L.V., Makkaveev A.V., Nikitin V.N. Otchet o NIOKR «Razrabotka i testirovanie prototipa mnogopol'zovatel'skoj virtual'noj sredy intellektual'nogo analiza dannyh» [R&D report "Development and testing of a prototype of a multi-user virtual data mining environment"]. Reg. № NIOKR 122122600007-1. Perm', 2023. 64 p.

3. Alekseev A.O., Kozhemjakin L.V., Makkaveev A.V. Svidetel'stvo o gosudarstvennoj registracii programmy dlja JeVM № 2023685360 Rossijskaja Federacija. Programmnyj modul' proektirovaniya i obuchenija nejronnyh setej, osnovannyh na kornjah prinjatija reshenij [Software Module for Designing and Training Decisions Root-based Neural Networks]. Programmy dlja JeVM. Bazy dannyh. Topologii integral'nyh mikroshem. 2023. Bjul. № 12. 1 p.

4. Liu Y., Dong J., Song Q., Zhang N., Wang W., Gao B., Tian S., Dong C., Liang Z., Xie L., Miao Y. *Frontiers in Neuroscience*. 2021. Vol. 14. Art. 570848. DOI: 10.3389/fnins.2020.570848. URL: [frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2020.570848/full](https://frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2020.570848/full).
  5. Alekseev A.O. *Proceedings of the 2020 2nd International Conference on Control Systems. Mathematical Modeling, Automation and Energy Efficiency (SUMMA)*. Lipetsk, Russia, 11-13 November. 2020. pp. 398–403. DOI: 10.1109/SUMMA50634.2020.9280751.
  6. Barnett J.F., Correia H., Johnson P.D., Laughlin M.G., Wilson K. *Alabama Journal of Mathematics*. 2010. Vol. 35. pp. 16-23.
  7. Korgin N., Sergeev V. *Artificial Intelligence for Sustainable and Resilient Production Systems. APMS 2021. IFIP Advances in Information and Communication Technology*. 2021. pp. 610-616. DOI: 10.1007/978-3-030-85874-2\_66.
  8. Korgin N.A., Sergeev V.A. *IFAC-PapersOnLine*. 2021. Vol. 54. Iss. 13. pp. 134-139. DOI: 10.1016/j.ifacol.2021.10.433.
  9. Lucenko E.V. *Programma dlja JeVM RU 2022615135 «Personal'naja intellektual'naja onlajn-sreda razrabotki «EIDOS-X Professional» (Sistema «EIDOS-Xpro»)»* [“Personal intelligent online development environment “EIDOS-X Professional” (System “EIDOS-Xpro”)”]. *Programmy dlja JeVM. Bazy dannyh. Topologii integral'nyh mikroshem. Baza dannyh. Topologii integral'nyh shem*. 2022. Bjul. no.4. 1 p.
  10. Kozhemjakin L.V., Nikitin V.N., Alekseev A.O. *Upravlenie bol'shimi sistemami : trudy XVIII Vserossijskoj shkoly-konferencii molodyh uchenyh. Cheljabinsk. 05–08 sentjabrja 2022 goda (Managing large systems : proceedings of the 18st All-Russian School-Conference of Young Scientists. Chelyabinsk. 05-08 September 2022)*. Cheljabinsk: Izdatel'skij centr JuUrGU. 2022. pp. 318–324.
  11. Jasnitskij L.N. *Iskusstvennyj intellekt. Jelektivnyj kurs: ucheb. posobie [Artificial intelligence. Elective course: textbook]*. Moskva, BINOM. Laboratorija znaniy, 2011. 197 p.
-

12. Sasov D.A., Zubkov A.V., Orlova Ju.A., Turicyna A.V. Inzhenernyj vestnik Dona, 2023, № 6. URL: [ivdon.ru/ru/magazine/archive/n6y2023/8507](http://ivdon.ru/ru/magazine/archive/n6y2023/8507).
13. Dunin V.O., Egorov V.A. Inzhenernyj vestnik Dona, 2012, № 4-1. URL: [ivdon.ru/ru/magazine/archive/n4p1y2012/1220](http://ivdon.ru/ru/magazine/archive/n4p1y2012/1220).
14. Gruvberger-Saal S.K., Edén P., Ringnér M., Baldetorp B., Chebil G., Borg A., Fernö M., Peterson C., Meltzer P.S. Molecular Cancer Therapeutics. 2004. Vol. 3. № 2. pp. 161–168.
15. Carrara M., Bono A., Bartoli C., Colombo A., Lualdi M., Moglia D., Santoro N., Tolomio E., Tomatis S., Tragni G., Santinami M., Marchesini R. Physics in Medicine & Biology. 2007. Vol. 52. № 9. pp. 2599–2613. DOI: [10.1088/0031-9155/52/9/018](https://doi.org/10.1088/0031-9155/52/9/018).
16. Chang P.D., Kuoy E., Grinband J., Weinberg B.D., Thompson M., Homo R., Chen J., Abcede H., Shafie M., Sugrue L., Filippi C.G., Su M.Y., Yu W., Hess C., Chow D. American Journal of Neuroradiology. 2018. Vol. 39. Iss. 9. pp. 1609–1616. DOI: [10.3174/ajnr.A5742](https://doi.org/10.3174/ajnr.A5742).
17. Chao P.J., Chang L., Kang C.L., Lin C.H., Shieh C.S., Wu J.M., Tseng C.D., Tsai I.H., Hsu H.C., Huang Y.J., Lee T.F. Scientific Reports. 2022. Vol. 12. Iss. 1. Art. 1555. 11 p. DOI: [10.1038/s41598-022-05455-w](https://doi.org/10.1038/s41598-022-05455-w).
18. Esmaeilzadeh S., Belivanis D., Pohl K., Adeli E. Proceedings of Machine learning in medical imaging. 2018. Vol. 11046. pp. 337-345. DOI: [10.1007/978-3-030-00919-9\\_39](https://doi.org/10.1007/978-3-030-00919-9_39).

**Дата поступления: 30.01.2024**

**Дата публикации: 19.03.2024**