

60. Chen X., Xu J., Liang T., He Z., Pang J., Yu D., Song L., Liu Q., Zhou M., Zhang Z., others. Do not think that much for $2+3=?$ on the overthinking of o1-like llms, *arXiv preprint arXiv:2412.21187*, 2024.
61. Pu X., Saxon M., Hua W., Wang W.Y. THOUGHTTERMINATOR: Benchmarking, Calibrating, and Mitigating Overthinking in Reasoning Models, *arXiv preprint arXiv:2504.13367*, 2025.
62. Sui Y., Chuang Y.-N., Wang G., Zhang J., Zhang T., Yuan J., Liu H., Wen A., Chen H., Hu X., others. Stop Overthinking: A Survey on Efficient Reasoning for Large Language Models, *arXiv preprint arXiv:2503.16419*, 2025.
63. Fang G., Ma X., Wang X. Thinkless: LLM Learns When to Think, *arXiv preprint arXiv:2505.13379*, 2025.
64. Chen Y., Benton J., Radhakrishnan A., Uesato J., Denison C., Schulman J., Somani A., Hase P., Wagner M., Roger F., others. Reasoning Models Don't Always Say What They Think, *arXiv preprint arXiv:2505.05410*, 2025.
65. Yue Y., Chen Z., Lu R., Zhao A., Wang Z., Song S., Huang G. Does Reinforcement Learning Really Incentivize Reasoning Capacity in LLMs Beyond the Base Model?, *arXiv preprint arXiv:2504.13837*, 2025.
66. Liu Z., Chen C., Li W., Pang T., Du C., Lin M. There May Not be Aha Moment in R1-Zero-like Training — A Pilot Study, 2025.
67. Mancoridis M., Weeks B., Vafa K., Mullainathan S. Potemkin Understanding in Large Language Models, *arXiv preprint arXiv:2506.21521*, 2025.
68. Shojaaee P., Mirzadeh I., Alizadeh K., Horton M., Bengio S., Farajtabar M. The illusion of thinking: Understanding the strengths and limitations of reasoning models via the lens of problem complexity, *arXiv preprint arXiv:2506.06941*, 2025.
69. Opus C., Lawsen A. The Illusion of the Illusion of Thinking, *arXiv preprint arXiv:2506.09250*, 2025.
70. Malek A., Ge J., Jin C., György A., Szepesvári C. Frontier LLMs Still Struggle with Simple Reasoning Tasks, *arXiv preprint arXiv:2507.07313*, 2025.

Савинов Владимир Борисович – Балтийский федеральный университет имени Иммануила Канта; e-mail: vsavinov@kantiana.ru; г. Калининград, Россия; Балтийский центр нейротехнологий и искусственного интеллекта; аспирант.

Шушарина Наталья Николаевна – Балтийский федеральный университет имени Иммануила Канта; e-mail: nshusharina@kantiana.ru; г. Калининград, Россия; Балтийский центр нейротехнологий и искусственного интеллекта; к. пед. н.; начальник управления развития и инновационной деятельности; старший научный сотрудник.

Savinov Vladimir Borisovich – Immanuel Kant Baltic Federal University; e-mail: vsavinov@kantiana.ru; Kaliningrad, Russia; Center for Neurotechnologies and Artificial Intelligence; postgraduate student.

Shusharina Natalia Nikolaevna – Immanuel Kant Baltic Federal University; e-mail: nshusharina@kantiana.ru; Kaliningrad, Russia; Baltic Center for Neurotechnologies and Artificial Intelligence; cand. of ped. sc.; head of the Department of Development and Innovation Activity; senior researcher.

УДК 004.722

DOI 10.18522/2311-3103-2026-1-270-284

А.В. Бобряков, С.А. Прокопенко

РАННЕЕ ВЫЯВЛЕНИЕ ПРОИЗВОДСТВЕННОГО БРАКА НА МЕЛКОСЕРИЙНЫХ ПРОИЗВОДСТВАХ С ИСПОЛЬЗОВАНИЕМ НЕЙРО-НЕЧЕТКИХ СИСТЕМ

Постановка задачи: Повышение требований к качеству продукции на мелкосерийных производствах и сложность раннего выявления производственного брака актуализируют необходимость разработки инновационных подходов к прогнозированию и контролю дефектов на ранних этапах производства сложных технических объектов. Известные методы, применяемые в массовом производстве, не подходят для мелкосерийных производств вследствие высокой изменчивости технологических процессов и недостаточности данных для традиционного статистического анализа. **Целью работы** является снижение уровня производственного брака путем раннего выявления отклонений на подготовительных этапах производства. Предлагается использование ней-

ро-нечетких систем, которые позволяют адаптивно прогнозировать дефекты на основе исторических данных. **Используемые методы:** для решения задачи раннего выявления производственного брака использованы нейро-нечеткие компоненты на основе нечеткого нейрона Квана–Кэи, позволяющие интегрировать экспертные знания с данными производства. Система включает подсистему обучения и тонкой настройки, состоящую из модулей подготовки, валидации и нормализации данных, фазификации данных и вычисления ошибки прогноза. В качестве структурного элемента прогнозирования применены темпоральные нейро-нечеткие сети Петри, которые обеспечивают учет временных аспектов и неопределенности в производственных процессах. **Новизна:** к элементам новизны относятся использование темпоральных нейро-нечетких сетей Петри и нейро-нечетких компонентов на основе нечеткого нейрона Квана–Кэи, позволяющих производить раннюю диагностику брака и принимать упреждающие меры. Новым является также подход интеграции нейро-нечетких методов с существующими системами управления производством. **Результат:** внедрение предложенных методов позволило снизить процент производственного брака на 15% за счет раннего выявления отклонений и своевременного принятия корректирующих мер. Реализованные программно-инструментальные средства обеспечивают оперативный анализ производственной ситуации и прогнозирование дефектов в режиме, близком к реальному времени. **Практическая значимость:** предлагаемое решение реализовано в виде специализированного программного обеспечения, интегрируемого в существующие производственные системы. Оно обеспечивает повышение эффективности управления качеством, снижает затраты на исправление дефектов и может быть адаптировано к различным мелкосерийным производствам, существенно улучшая показатели их работы.

Нейро-нечеткие компоненты; сети Петри; производственный брак.

A.V. Bobryakov, S.A. Prokopenko

EARLY DETECTION OF MANUFACTURING DEFECTS IN SMALL-SCALE PRODUCTION USING NEURO-FUZZY SYSTEMS

Problem Statement: The increasing demand for higher quality products in small-scale production and the complexity associated with the early detection of manufacturing defects necessitate the development of innovative approaches to predict and control defects at the early stages of manufacturing complex technical objects. Traditional methods applied in mass production settings are unsuitable for small-scale manufacturing due to the high variability of technological processes and the insufficient data required for conventional statistical analyses. **The objective of this study** is to reduce the incidence of manufacturing defects by identifying deviations at the preparatory stages of production. The proposed solution involves employing neuro-fuzzy systems capable of adaptively forecasting defects based on historical production data. **Methods:** To address the early detection of manufacturing defects, neuro-fuzzy components based on the fuzzy neuron proposed by Kwan–Cai were employed, integrating expert knowledge with production data. The system includes a training and fine-tuning subsystem consisting of modules for data preparation, validation and normalization, fuzzification of data, and calculation of forecasting errors. Temporal neuro-fuzzy Petri nets were used as structural forecasting elements, enabling the consideration of temporal aspects and uncertainties inherent in manufacturing processes. **Novelty:** The novel aspects of this research include the utilization of temporal neuro-fuzzy Petri nets and neuro-fuzzy components based on the Kwan–Cai fuzzy neuron, enabling the early detection of defects and the implementation of proactive measures. Another innovative aspect is the approach for integrating neuro-fuzzy methods into existing production management systems. **Results:** The implementation of the proposed methods resulted in a 15% reduction in manufacturing defects through early identification of deviations and the timely adoption of corrective actions. Developed software tools provide operational analysis of production situations and defect forecasting in near real-time. **Practical Significance:** The presented solution has been realized as specialized software integrated into existing production systems. It improves the effectiveness of quality management, reduces the costs associated with defect correction, and can be adapted to various small-scale production environments, significantly enhancing their operational performance.

Neuro-fuzzy components; Petri nets; manufacturing defects.

Введение. Целью данного исследования является изучение и разработка методов на основе нейро-нечетких систем для раннего выявления производственного брака и повышения эффективности управления качеством на мелкосерийных производствах. Актуальность темы обусловлена ростом требований к качеству продукции, сложностью процессов контроля и высокой стоимостью производственного брака. Особенно остро эта

проблема стоит на предприятиях, выпускающих продукцию малыми партиями с большим разнообразием номенклатуры. Даже незначительные дефекты могут приводить к серьезным потерям, поэтому важно обнаруживать отклонения как можно раньше. Согласно правилу «1-10-100» [1], цена исправления дефекта многократно возрастает на каждой следующей стадии производства. Следовательно, эффективное раннее выявление брака способно существенно снизить издержки за счёт предотвращения переработки, простоя оборудования, переделок и рекламаций.

Массовые и крупносерийные производства традиционно используют множество инструментов управления качеством (статистический контроль процессов, шесть сигм и др.). Однако для мелкосерийного и единичного производства таких разработок значительно меньше. Основное отличие мелкосерийного производства – большая номенклатура изделий и частая смена уникальных технологических процессов, что затрудняет применение стандартных методов обеспечения качества. В условиях высокой изменчивости процессов трудно накопить достаточно данных для статистического контроля стабильности процессов, и требования к гибкости системы качества возрастают. Таким образом, возникает необходимость в инновационных подходах к мониторингу и прогнозированию качества, способных адаптироваться к новым условиям и небольшим объёмам однотипных данных.

В данной работе предложен подход, основанный на нейро-нечетких системах раннего обнаружения дефектов в производственном процессе. Нейро-нечеткие системы интегрируют способности искусственных нейронных сетей и нечеткой логики, сочетая обучаемость с человеческим стилем рассуждения на основе правил. Предлагаемые нейро-нечеткие компоненты прогнозирования брака обучаются на исторических данных и позволяют оценивать качество выполняемых операций до их завершения [2].

Производственный брак. Производственный брак – это продукция, изготовленная с отклонениями от установленных стандартов качества, не соответствующая техническим требованиям и не пригодная для использования по назначению. В процессе производства сложных технических объектов (СТО), включающем множество технологических операций, брак может возникать на разных этапах. На предприятиях применяются традиционные методы выявления брака, включая визуальный контроль и контроль качества на заключительных стадиях [3]. Однако такие подходы зачастую неэффективны для предупреждения дефектов на ранних этапах, особенно в условиях мелкосерийного и уникального производства, где каждый экземпляр изделия может проходить свою уникальную технологическую цепочку.

Основными причинами возникновения брака являются:

- ◆ дефекты в сырье, материалах, полуфабрикатах, поставленные внешними поставщиками;
- ◆ неисправность оборудования, вызванная неправильной наладкой оборудования и компонентов;
- ◆ ошибки в нормативно-технической документации;
- ◆ недостаточная квалификации рабочих;
- ◆ нарушение технологической дисциплины;
- ◆ чрезвычайное обстоятельство (стихийное бедствие).

По месту обнаружения различают внутренний брак (выявленный на предприятии при внутренних контрольных мероприятиях) и внешний брак (выявленный конечным потребителем при эксплуатации изделия). Внешний брак наиболее опасен и дорог для предприятия, так как обнаруживается поздно – когда продукт уже произведён и поставлен. Стоимость такого дефекта включает не только затраты на изготовление бракованного изделия, но и возможные штрафы, возвраты и снижение репутации предприятия.

Ключевые факторы, влияющие на соответствие СТО стандартам качества, можно разделить на несколько классов:

- ◆ оборудование – техническое состояние средств производства, правильность их настройки, износ и т.д.;

- ◆ персонал – профессиональное мастерство, знания, навыки и психофизиологическое состояние работников, соблюдение ими инструкций;
- ◆ сырьё и материалы – качество исходных материалов, полуфабрикатов, комплекующих, соответствие их спецификациям;
- ◆ методы и процесс – корректность технологической документации, адекватность выбранных режимов обработки, условия внешней среды.

Для массовых и серийных процессов разработаны многочисленные системы управления качеством, однако для мелкосерийных производств сложность состоит в постоянной смене продуктов и процессов. Каждая новая партия изделия может требовать новых настроек и контроля новых параметров, что затрудняет использование стандартных статистических методов. Необходим инструмент, способный быстро обучаться на небольших выборках данных, учитывать экспертные знания о процессе и работать в условиях неполной определённости.

Необходимо стремиться к выявлению потенциальных дефектов ещё до выполнения технологической операции – превентивно [4, 5]. Однако сделать это сложно, так как нужно предсказывать результат операции на основе совокупности факторов до её завершения. Для решения этой задачи могут быть использованы методы искусственного интеллекта, в частности нейро-нечеткие системы, способные обрабатывать большой набор входных параметров, неопределённости и взаимодействия факторов в реальном времени.

Нейро-нечеткие компоненты. Нейро-нечеткие системы – это гибрид искусственной нейронной сети и нечеткого логического вывода [6]. Такие системы сочетают обучаемость и способность аппроксимировать сложные зависимости, характерные для нейросетей, с прозрачностью и интерпретируемостью, присущей нечеткой логике (правила вида «если – то»). В контексте управления качеством нейро-нечеткие компоненты могут служить для прогнозирования появления дефектов на основе множества параметров процесса.

На ряде современных предприятий (автомобилестроение, аэрокосмическая отрасль, электроника и др.) уже успешно применяются нейро-нечеткие системы в задачах контроля качества. Внедрение таких систем позволяет своевременно выявлять потенциальные дефекты, оптимизировать технологические режимы и снижать затраты на бракованную продукцию [7]. Например, в литейном производстве колесных дисков предложен нейро-нечеткий классификатор дефектов рентгеновских снимков, показавший практически идеальную точность (площадь под ROC-кривой $A_c = 0.9976$) при разделении дефектов и ложных срабатываний [8, 9], что демонстрирует возможности нейро-нечетких подходов в задачах обнаружения брака.

Использование нейро-нечеткого компонента для раннего определения брака позволяет предсказать возможные дефекты ещё до выполнения технологической операции. То есть система, получив текущие параметры оборудования, материала и состояния процесса, может выдать предупреждение о вероятном браке, и тогда можно принять меры заблаговременно (подстроить режим, заменить инструмент, провести дополнительную настройку). Такой упреждающий контроль сокращает издержки на переработку бракованных деталей и повышает эффективность всего производственного цикла.

Нейро-нечеткие компоненты обладают рядом существенных преимуществ в задачах мониторинга качества.

1. Адаптивность и гибкость, достигающиеся за счёт обучения на исторических данных. Такая нейро-нечеткая система способна подстраиваться под меняющиеся условия производства и доступны возможности тонкой настройки модели при появлении новых видов продукции или изменении процесса, что делает её универсальным инструментом анализа качества.

2. Нейро-нечеткие системы являются универсальными аппроксиматорами [10] и могут моделировать практически любые нелинейные зависимости, сохраняя при этом интерпретируемость в виде нечетких правил.

3. Высокая точность и скорость обработки данных. Обученная нейро-нечеткая модель способна обрабатывать большие объемы данных, характеризующих процессы, и выдавать решение в реальном или квазиреальном времени. Такая модель обнаруживает

скрытые многомерные зависимости между параметрами, обеспечивая более точное выявление потенциальных дефектов. В реальных экспериментах такие системы успешно классифицируют дефекты даже при большом количестве признаков, используя лишь наиболее информативные из них.

4. Нейро-нечеткий компонент обладает способностью к обучению на исторических данных. По мере пополнения базы данных система будет проводить тонкую самонастройку, улучшая точность прогнозов, автоматически подстраивая внутренние правила и параметры, что особенно важно в условиях мелкосерийного производства, где статистика ограничена – система способна извлечь максимум полезной информации даже из небольшого числа наблюдений.

5. Автоматизация процесса выявления брака с помощью нейро-нечетких алгоритмов минимизирует влияние человеческого фактора [11, 12], снижая влияние субъективности оператора. Система объективно оценивает параметры и выдает рекомендации, включая «человеческий фактор» – усталость, невнимательность или разночтения технических требований. Роль человека смещается в сторону принятия решений по результатам работы интеллектуальной подсистемы, что повышает общую надежность контроля.

6. Экономический эффект представляет собой улучшение качества и снижение брака. Инвестиции в интеллектуальную систему окупаются за счёт сокращения потерь материала, времени и трудозатрат на переделки [13]. Повышение выхода годной продукции с первого раза увеличивает прибыль предприятия, кроме того, улучшается репутация за счёт стабильного качества, что косвенно влияет на экономику.

7. Нейро-нечеткие модули прогнозирования могут быть относительно легко интегрированы в существующие системы управления производством и контроля качества. Их можно встроить в АСУ ТП, SCADA или MES-системы предприятия, используя потоки данных, которые уже собираются. Благодаря модульности, подобные компоненты находят применение в различных отраслях без кардинальной перестройки действующей инфраструктуры.

Применение нейро-нечеткого компонента для предсказания брака требует не только наличия алгоритма, но и организации процесса обучения модели. Только при корректном обучении на качественных данных система будет надёжно работать.

Нечеткий нейрон Квана и Кэи. Нечеткий нейрон Квана и Кэи впервые был представлен в 1994 году. Он успешно применяется в задачах классификации [14]. Структурно он состоит из четырех слоев нейронов, предназначенных для фаззификации входных данных, анализа и классификации информации. Простота реализации и высокая точность классификации делают его эффективным инструментом в задачах прогнозирования брака. Схема нечеткого нейрона представлена на рис. 1.

Первый слой представляет входные данные и состоит из нечетких входов, каждый из которых представляет вектор параметров характеристик. В случае двумерной выборки, содержащей векторные элементы $N_1 \times N_2$, у нас будет первый слой с нейронами $N_1 \times N_2$. Для нейрона в позиции (i, j) уравнения имеют вид:

$$s_{ij}^{[1]} = z_{ij}^{[1]} = x_{ij},$$

$$y_{ij}^{[1]} = y_{ij}^{[1]} / P_{vmax},$$

где $i=1, 2, \dots, N_1; j=1, 2, \dots, N_2$, где $s_{ij}^{[1]}$ представляет состояние нейрона на (i, j) позиции для первого слоя; $z_{ij}^{[1]}$ – его входное значение; x_{ij} – значение элемента (i, j) во входном векторе выборки ($x_{ij} \geq 0$); $y_{ij}^{[1]}$ – его выходное значение; P_{vmax} – максимальное значение из всех входных элементов.




Рис. 1. Структура нечеткого нейрона Квана и Кэи

Второй слой построен из $N_1 \times N_2$ нейронов, и его задача – выполнить фаззификацию входных векторов с помощью весовой функции $w(m, n)$ – называемой функцией фаззификации, графически представленной на рис. 2 и определяемой как:

$$w(m, n) = e^{-\beta^2(m^2+n^2)},$$

где параметры $m = -(N_1 - 1), \dots, (N_1 - 1)$; $n = -(N_2 - 1), \dots, (N_2 - 1)$ и β определяют, какую большую часть выборочного вектора видит каждый нечеткий нейрон. Каждый нейрон второго слоя имеет M выходов, по одному на каждый нейрон третьего слоя. Выходные данные для нейрона второго слоя в позиции (p, q) :

$$y_{pqm}^{[2]} = q_{pqm}^{[2]},$$

где $p = 1, \dots, N_1$; $q = 1, \dots, N_2$; $m = 1, \dots, M$; $y_{pqm}^{[2]}$ m -выход нейрона второго слоя в позиции (p, q) к m -нейрону третьего уровня. Выходная функция q_{pqm} определяется в рамках алгоритма обучения. Для более упрощенного подхода использованы равнобедренные треугольники с основанием α и высотой 1, математически определяемые как:

$$y_{pqm}^{[2]} = q_{pqm}^{[2]}(s_{pq}^{[2]}) = \begin{cases} 1 - \frac{2|s_{pq}^{[2]} - \theta_{pqm}| \leq \frac{\alpha}{2}}{\alpha}, & \text{for } 2|s_{pq}^{[2]} - \theta_{pqm}| \leq \frac{\alpha}{2}, \\ 0 & \text{other} \end{cases}$$

где $\alpha \geq 0$, $p = 1, \dots, N_1$; $q = 1, \dots, N_2$; $m = 1, \dots, M$. Параметр θ_{pqm} – центр основания равнобедренного треугольника. С помощью алгоритма обучения определяются значения p , q и m , соответствующие α и θ_{pqm} .

Третий слой состоит из M нейронов, где M – это количество определяемых классов. Его можно рассматривать как нечеткий слой вывода (вывода). Выходные данные нейрона третьего слоя:

$$y_m^{[3]} = s_m^{[3]} = \min_{p=1 \dots N_2} (y_{pqm}^{[2]}),$$

где $m = 1, \dots, M$.

Четвертый и последний слой является выходным слоем сети и состоит из конкурирующих нейронов, по одному на каждый из выходных классов – это слой дефаззификации. Если входной шаблон более похож на m -класс, который был изучен, то выходу m сравнительного нейрона будет присвоено значение 1, а остальным – значение 0:

$$y_m^{[4]} = s_m^{[4]} = z_m^{[4]},$$

$$y_{pqm}^{[4]} = q[s_m^{[4]} - T] = \begin{cases} 0, & \text{if } s_m^{[4]} < T \\ 1, & \text{if } s_m^{[4]} = T \end{cases},$$

$$T = \max_{m=1\dots M} (\max_{j=1\dots N_2} (y_m^{[3]}))$$

где $m=1, \dots, M$, где T определяется как порог активации для всех нейронов четвертого слоя.




Рис. 2. Представление функции нечеткого нейрона Квана и Кэи

Нечеткий нейрон Квана–Кэи обеспечивает сквозной нечеткий вывод: от фаззификации входов через нечеткие правила к четкому решению о классе. Его важное свойство – возможность выдавать вектор выходов $(y_1 \dots y_M)$ с интерпретацией как значения функций принадлежности образца ко всем M классам. Это означает, что система не просто даёт «вердикт», но и предоставляет степень уверенности в каждом возможном исходе, что ценно для принятия решений (например, при промежуточных значениях можно направить операцию на дополнительный контроль).

В контексте задачи прогнозирования брака мы используем данную архитектуру следующим образом: на вход нейрона подаются параметры текущей производственной ситуации (характеристики оборудования, материалы, параметры процесса, данные об операторе и т.д.), а на выходе получаем принадлежность к классам «операция пройдет успешно», «возможны отклонения – нужен контроль» или «высокая вероятность брака». Далее эти результаты интерпретируются системой управления качеством для принятия мер.

Успешное применение таких компонентов требует их тщательной настройки и обучения на примерах.

Подсистема обучения нейро-нечеткого компонента. Для обеспечения работоспособности нейро-нечеткого компонента в реальных условиях разработана специальная подсистема обучения и тонкой настройки. Она предназначена для автоматической адаптации модели к новым данным и включает в себя набор модулей, представленных на рис. 3.



Рис. 3. Компоненты подсистемы обучения и тонкой настройки нейро-нечетких компонент (ННК)

Модуль подготовки, валидации и нормализации данных, отвечающий за формирование обучающих выборок из сырьевых производственных данных. В рамках данного модуля происходит сбор информации о функционировании сложной системы за заданный период из различных источников (датчики оборудования, системы учёта качества, журналы операторов и т.д.). Далее данные проходят валидацию – проверку на соответствие критериям полноты и корректности (например, отсеивание аномальных или противоречивых записей). После очистки данные нормализуются – приводятся к единому масштабу, чтобы ни один параметр не доминировал из-за размерности. Также этот модуль разбивает данные на обучающую и тестовую выборки для последующей оценки качества обучения модели. Результатом работы модуля являются эталонные размеченные данные – множество векторов параметров с указанием исхода (успех/брак), разнесённых по тематическим классам факторов: оборудование, материалы, персонал, продукция, результат операции.

$$I = \left\{ \begin{array}{l} \{eq_1, eq_2, \dots, eq_n\} \\ \{mt_1, mt_2, \dots, mt_m\} \\ \{pr_1, pr_2, \dots, pr_l\} \\ \{st_1, st_2, \dots, st_k\} \end{array} \right\},$$

где eq – характеристики оборудования, mt – параметры материалов, pr – свойства продукции, st – характеристики сотрудников.

Модуль фаззификации данных: преобразует количественные (числовые) параметры класса «результат операции» в качественные нечеткие оценки. Например, фактическое отклонение размера детали от номинала можно перевести в лингвистическую переменную «отклонение: малое/среднее/большое» с соответствующей функцией принадлежности, что необходимо для сравнения с результатом, получаемым от нейро-нечеткого компонента, и вычисления ошибки.

Модуль вычисления ошибки, предназначенный для сравнения нечеткого вывода нейро-нечеткого компонента с эталонным нечетким результатом и вычисления сигнала ошибки. Ошибка определяется, как разница (например, по некоторой метрике близости нечетких множеств) между предсказанным исходом операции и фактическим исходом (в нечетком представлении). Полученный сигнал ошибки используется для корректировки параметров нейро-нечеткого компонента – он поступает на алгоритм обучения (например, обратное распространение ошибки или его модификацию, адаптированную под нечеткие нейроны):

$$\tilde{O}_e \setminus \tilde{O} = \max\{\tilde{O}_e(x) - \tilde{O}(x), 0\}, x \in X.$$

Нейро-нечеткий компонент (ННК) представляет собой модель на основе описанного выше нечеткого нейрона Квана–Кэи. Он принимает на вход подготовленные четкие вектора параметров (разбитые по классам факторов: оборудование (*eq*), материалы (*mt*), персонал (*st*), параметры продукции (*pr*)) и выдает нечеткое множество исходов операции. Поскольку на производстве существуют разные типы технологических операций (сборка, сварка, окраска, проверка и т.п.), то для каждой категории операций настраивается свой экземпляр ННК с отдельным набором синаптических весов, наиболее подходящих для данного процесса. Выходы ННК показанные на рис. 4, интерпретируются в терминах трех классов:

- ◆ исход операции успешен – проведение данной технологической операции с заданными условиями не приведет к браку, результат соответствует стандартам качества;
- ◆ исход требует внимания – результат операции находится на грани допуска или есть повышенная неопределенность. Требуется принять решение о проведении дополнительных контрольных мероприятий (например, усиленный контроль качества, корректировка процесса), чтобы снизить вероятность негативного исхода;
- ◆ исход операции неудачен (брак) – с высокой вероятностью результат не соответствует требованиям (сильное отклонение параметров, явный дефект) либо имеется прямая индикация брака. В этом случае необходимо либо скорректировать процесс до выполнения операции, либо отбраковать изделие, либо запланировать его переделку после операции.

Такая градация выходов позволяет не просто бинарно решать задачу вида «брак/не брак», а учитывать промежуточное состояние, когда система не уверена или качество под вопросом. Это соответствует принципам риск-ориентированного подхода к качеству: если есть риск брака – принять меры превентивно.




Рис. 4. Представление выходов нейро-нечеткого компонента

Модуль выбора конфигурации ННК: необходим в случае, если технологическая операция комплексная и задействует сразу несколько ресурсов (нескольких рабочих, единиц оборудования или материалов одновременно). Тогда операцию целесообразно

разбить на несколько более простых подопераций, каждая из которых оценивается своим нейро-нечетким компонентом. Модуль выбора решает, какую конфигурацию ННК применять для данной операции, исходя из её типа и задействованных ресурсов. По сути, это правило диспетчеризации: например, если операция «сборка» – использовать модель А, если «пайка» – модель В, если комбинированная – последовательно две модели и т.д.

В рамках подсистемы обучения предусмотрены два основных режима обучения нейро-нечеткого компонента (ННК):

- ◆ полное обучение: глобальное переобучение модели на всем массиве накопленных исторических данных за определенный период. Этот режим обеспечивает максимальную точность, но требователен к вычислительным ресурсам и времени, поэтому проводится относительно редко (например, при внедрении системы или при существенных изменениях процесса). Полное обучение позволяет ННК заново построить зависимости с нуля, учитывая весь накопленный опыт;

- ◆ тонкая настройка: периодическое дообучение модели на новых поступающих данных без полного переобучения. Используя свежие данные (например, последние смены или дни производства), ННК немного подстраивается под актуальные условия. Это быстрее и требует меньше ресурсов, позволяя поддерживать модель «в тонусе». Тонкую настройку целесообразно проводить в периоды низкой загрузки системы (например, во время ночных перерывов или технических окон), чтобы не влиять на производственный процесс. Она обеспечивает адаптацию к дрейфу процесса или медленным изменениям (например, постепенному износу оборудования, сезонным изменениям свойств материалов и т.д.).

Комбинация этих режимов обучения позволяет поддерживать высокую точность прогноза брака: редкие полные обучения дают глобальную корректировку модели, а регулярные тонкие настройки учитывают текущие изменения. Вся обучающая подсистема функционирует автономно, обеспечивая непрерывное улучшение интеллектуального компонента контроля качества по мере накопления данных.

Пример реализации на основе сетей Петри. Для демонстрации возможностей нейро-нечеткого подхода в управлении производством был разработан пример моделирования производственного процесса с использованием темпоральной нейро-нечеткой сети Петри (ТННСП). Сети Петри широко применяются для моделирования дискретных событийных систем, включая производственные процессы, благодаря наглядности и строгому математическому аппарату. В рассматриваемой модели ТННСП комбинируется с нечеткой логикой и временными параметрами.

Классические сети Петри описывают структуру процесса, но не учитывают явно время. Расширение до темпоральной сети Петри позволяет задавать временные задержки и интервалы для переходов и состояний, тем самым более точно отражая динамику реального производства. Данные особенности важны для планирования – например, учёт длительности операций, ожидания материалов, простоя оборудования. Модель с временем способна предсказывать поведение системы на шаг вперед, выявляя потенциальные конфликты или задержки.

Применение элементов с нечеткой логикой в узлах сети Петри позволяет оперировать с неточными понятиями (например, «высокая загрузка», «небольшая задержка») и неполной информацией. В реальном производстве часто данные бывают неточными или экспертными (оценочными). Нечеткая сеть Петри интегрирует правила вида «если состояние близко к перегрузке, то увеличить интервал обслуживания оборудования» и т.п., повышая реалистичность модели.

Нейро-нечеткая составляющая означает, что веса переходов и функции принадлежности в сети Петри могут настраиваться на основе данных или экспертного опыта, повышая адаптивность модели в целом, что делает её живым инструментом, способным эволюционировать вместе с системой.

Несмотря на сложность внутреннего устройства (нейросети, нечеткая логика, временные реляции), итоговая модель представима в виде наглядного графа, понятного инженерам, что облегчает восприятие и верификацию модели. Специалист по производству может интерпретировать элементы сети Петри, соотнеся их с этапами технологического процесса.

Подход на основе ТННСП является универсальным и может быть адаптирован и к другим предметным областям – управление транспортными системами, медицинскими процессами, финансами и т.д., везде, где есть процессы с событиями во времени и неопределённостью. В нашем случае, мы применяем её для задач планирования производства сложных технических объектов.

Формально темпоральная нейро-нечеткая сеть Петри определяется следующим образом.

$$TNPN = (PN, C, \alpha, f, B, R, Pl, m_0),$$

Она включает:

- ◆ классическую сеть Петри $PN = (P, T, F)$ – множество позиций (P) и переходов (T) с отношениями (F) между ними;
- ◆ множество времён дуг $C = \{C_1, C_2, \dots, C_{nc}\}$ – каждому ребру могут сопоставляться интервалы времени, задающие задержку или временное окно срабатывания;
- ◆ вектор нечетких порогов $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_{nc}\}$ – пороги срабатывания переходов в нечетких условиях;
- ◆ функции принадлежности $f = \{f_1, f_2, \dots, f_{nc}\}$ – определяют степень выполнения нечетких условий для переходов;
- ◆ множество $B = \{b, bi, m, mi, o, oi, d, di, s, si, f, fi, e\}$ – базовые интервальные отношения логики Аллена для описания отношений во времени между событиями (предшествует, следует, совпадает, длится и т.д.) [15];
- ◆ множество ресурсов $R = \{R_1, R_2, \dots, R_{nr}\}$, учитываемых в модели (оборудование, люди, оснастка, ограниченные ресурсы);
- ◆ производственный план Pl , задающий последовательности операций, партии изделий, сроки и пр.;
- ◆ начальную маркировку m_0 – вектор, задающий начальное состояние (расположение маркеров) с учетом нечеткой наличия маркеров в позициях.

На основе этой модели можно описывать, как выполняются операции, как перетекают маркеры (например, маркер – это деталь на определённой стадии, переход – выполнение операции, позиции – состояние детали: ожидание, обработка, проверка). Использование темпоральных нейро-нечетких сетей Петри позволяет учесть временные аспекты и неопределённость информации, достигая более высокой точности прогнозирования, чем традиционные методы, которые зачастую рассматривают усреднённые или детерминированные процессы [16], что особенно актуально для сложного планирования: например, модель способна показать, что если одна операция задержится (с вероятностью, характеризующей нечетко), то последующие сдвинутся и возможен простой оборудования, влияющий на весь план.

Разработанные программно-инструментальные средства. Для практического применения описанных методов разработано специализированное программное обеспечение. Оно интегрируется в инфраструктуру предприятия и обеспечивает сбор данных, обучение модели и поддержку принятия решений в режиме, близком к реальному времени [17]. Основные возможности созданного программно-инструментального комплекса включают:

- ◆ формирование онтологической модели сложной системы. Пользователь или эксперт может задать онтологию производства – классы информационных сущностей (оборудование, операции, материалы, дефекты и т.п.) и связи между ними. Такая модель знаний служит основой для настройки нейро-нечеткой системы, позволяя ей учитывать структуру предметной области (например, что определённый тип станка связан с определёнными видами дефектов и операциями);

♦ сбор и хранение данных из различных источников. ПО позволяет автоматически получать данные как от операторов (через интерфейсы ввода), так и из внешних систем (сенсоры, ERP, MES) [18, 19]. Все данные о параметрах процессов, результатах контроля, действиях персонала агрегируются в едином хранилище, пригодном для последующего обучения;

♦ валидация внешних и аналитических данных нейросетевым супервизором. Встроенный модуль на базе нейросети контролирует качество поступающих данных. Он может отслеживать, например, аномалии (всплески показаний датчиков, сбои в передаче данных) и сигнализировать о них, тем самым обеспечивая надежность входной информации для нашей системы;

♦ средства моделирования и прогнозирования на основе ТННСП. Реализован графический конструктор, экранная форма изображена на рисунке 5, позволяющий специалистам строить модели процессов в виде темпоральных нечетких сетей Петри, не погружаясь в кодирование алгоритмов. Визуально смоделировав процесс и задав начальные условия, пользователь может запустить имитацию и получить прогноз – например, выявить узкие места или оценить риск брака на каждом этапе. Отмечено, что смоделированные таким образом траектории производственного процесса на ~80% совпадают с решениями, принимаемыми экспертами вручную на основе опыта (что свидетельствует о достаточной адекватности модели);

♦ интеграция с системами управления производством. Программный комплекс может взаимодействовать с существующими системами (PLM, ERP, MES) [20]. Например, результаты прогнозирования брака могут автоматически генерировать задания на корректировку технологических параметров или план профилактики оборудования. Кроме того, реализована возможность выгрузки отчетов и показателей эффективности (KPI) для менеджмента качества.

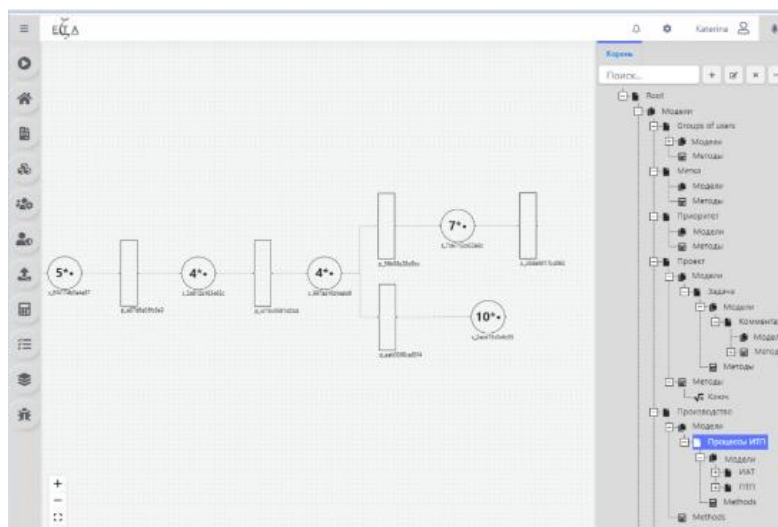


Рис. 5. Экранная форма разработанного инструмента

Разработанные инструменты были опробованы в опытной эксплуатации на предприятии ООО «Дозатор-плюс» при производстве «Гидромотор героторный Д06.125-01 (M22x1,5)», «Гидромотор ДС160». Они показали способность в режиме реального времени обрабатывать данные нескольких десятков контролируемых параметров процесса и выдавать рекомендации по предотвращению брака, которые затем внедрялись ответственным персоналом, что подтверждает работоспособность предложенного подхода в условиях мелкосерийного производства.

Во время внедрения на предприятии было показано, что подобная модель может успешно поддерживать задачу календарного планирования производства. Построенное программное приложение позволило проектировать информационно-технологические процессы с помощью конструктора моделей на базе ТННСП. Выяснилось, что траектории процессов, сгенерированные моделью, в 80% случаев совпадают с планами, составленными экспертами-технологами вручную (расхождения касались в основном нештатных ситуаций, которые модель пока не учитывала детально). Такой результат демонстрирует перспективность предложенного подхода для автоматизации планирования и прогнозирования в производственных системах.

Заключение. Проведенное исследование показало эффективность использования нейро-нечетких компонентов для управления качеством и прогнозирования производственного брака на мелкосерийных предприятиях. Предложенные модели и алгоритмы позволяют на ранней стадии обнаруживать потенциальные дефекты и принимать упреждающие меры, тем самым существенно сокращая издержки на бракованную продукцию и переделки.

В работе обосновано, что нейро-нечеткие системы способны объединить преимущества адаптивного обучения и логической интерпретируемости, что особенно ценно в условиях сложных и вариативных процессов. Разработанный нейро-нечеткий компонент на основе нечеткого нейрона Квана–Кэи успешно справляется с задачей классификации исходов технологических операций, а подсистема его обучения обеспечивает постоянную адаптацию к изменениям в процессе. Интеграция временных и нечетких моделей (темпоральных нечетких сетей Петри) продемонстрировала возможность более точного планирования и имитации производственных процессов, учитывающих неопределенность и динамику.

Практическая реализация в виде программного комплекса подтвердила применимость метода: интеллектуальная система качества может работать в реальном времени параллельно с производством, не нарушая его, и генерировать ценные рекомендации. Таким образом, цели исследования достигнуты – показано, что применение нейро-нечетких методов действительно повышает эффективность управления качеством на мелкосерийных производствах.

Перспективы дальнейших исследований видятся в развитии специализированных нейро-нечетких алгоритмов именно для производственных задач. Например, создание гибридных моделей, объединяющих нейро-нечеткий подход с методами статистического контроля (SPC) для учета как данных прошлого, так и онлайн-сигналов. Интересным направлением является интеграция предложенной системы с концепцией Цифрового двойника производства, когда нейро-нечеткая модель станет ядром цифрового двойника, постоянно обучающегося на данных и управляющего качеством в замкнутом цикле. Также планируется расширить базу знаний системы за счёт добавления правил экспертной системы, чтобы улучшить интерпретируемость рекомендаций для операторов.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Perfecting the 1:10:100 Rule in Data Quality // Medium.com: электронный блог. 17.03.2025. – URL: <https://medium.com/grepsr-blog/perfecting-the-1-10-100-rule-in-data-quality-a1f31143f40b> (дата обращения: 17.03.2025).
2. *Misnik A., Borisov V.* Compositional neuro network modeling of complex technical systems // *Neurocomputers: Development, Application.* – 2016. – No. 7. – P. 39-46.
3. *Таненбаум Э.* Распределенные системы: принципы и парадигмы. – СПб.: Питер, 2003. – 877 с.
4. *Haykin S.* Neural networks: A comprehensive foundation. – 2nd ed. – New Jersey: Prentice Hall International, Inc, 1999. – 1103 p.
5. *Hernández S., Sáez D., Mery D.* Neuro-Fuzzy Method for Automated Defect Detection in Aluminium Castings / In: *Campilho, A., Kamel, M. (eds.) // Image Analysis and Recognition. ICIAR 2004. Lecture Notes in Computer Science.* – Vol. 3212. – Springer, Berlin, Heidelberg, 2004.
6. *Орлов А.И.* Теория принятия решений. – М.: Экзамен, 2005. – 656 с.
7. *Тарасик В.П.* Математическое моделирование технических систем: учебник для вузов. – Мн.: ДизайнПРО, 2004. – 640 с.

8. Марка Д., МакГоуэн К. Методология структурного анализа и проектирования. – М.: МетаТехнология, 1993. – 240 с.
9. Bobryakov A.V., Krutalevich S.K., Misnik A.E., Prokopenko S.A. Modeling of Industrial and Technological Processes in Complex Systems Based on NeuroFuzzy Petri Nets // *Journal of Physics: Conference Series*, Volume 2096, International Conference on Automatics and Energy (ICAE 2021) 7-8 October 2021, Vladivostok, Russia.
10. Tax N., Verenich I., La Rosa M., Dumas M. Predictive Business Process Monitoring with LSTM neural networks // *Proceedings of the International Conference on Advanced Information Systems Engineering (CAiSE)*. – P. 477-492. arXiv:1612.02130 Freely accessible. – doi: 10.1007/978-3-319-59536-8_30.
11. Попов Э.В. Экспертные системы. – М.: Наука, 1987. – 288 с.
12. Леоненков А.В. Нечеткое моделирование в среде MATLAB и fuzzyTECH. – СПб.: БХВ-Петербург, 2003.
13. Ash T. Dynamic Node Creation in Back-Propagation Networks // *II Connection Science*. – 1989. – Vol. 1.
14. Kwan H., Cai L. A fuzzy neural network and its application to pattern recognition // *IEEE Transactions on Fuzzy Systems*. – 1994. – Vol. 2, No. 3. – P. 185-193. – DOI: 10.1109/91.298447.
15. Allen J.F. Maintaining knowledge about temporal intervals // *Communications of the ACM*. – 1983. – Vol. 26, No. 11. – P. 832-843.
16. Wu J. and Yan S. Reliability Evaluation for Mechanical Systems by Petri Nets // *Petri Nets in Science and Engineering*. – 2018.
17. Balbiani P., Boudou J., Diéguez M., Fernández-Duque D. Intuitionistic Linear Temporal Logics // *ACM Transactions on Computational Logic*. – 2019. – 21. – P. 1-32.
18. Vajnilovich Yu., Zaharchenkov K. and Zakharova A. Integrated System Approach to Improving the Efficiency of IT Projects Management Based on Evolutionary Modeling // *Computing in Physics and Technology*. – P. 309-314.
19. Borisov V.V., Misnik A.E. Ontological Engineering of Interrelated Processes in Complex Cyber-Physical Systems / In: Kovalev, S., Sukhanov, A., Akperov, I., Ozdemir, S. (eds) // *Proceedings of the Sixth International Scientific Conference “Intelligent Information Technologies for Industry” (IITI’22)*. IITI 2022. Lecture Notes in Networks and Systems. – Vol. 566. – Springer, Cham, 2023. – https://doi.org/10.1007/978-3-031-19620-1_39.
20. Karabach A. Information integration systems based on semantic technologies // *Science, technology and education*. – 2014. – Vol. 2 (2).

REFERENCES

1. Perfecting the 1:10:100 Rule in Data Quality // *Medium.com: электронный блог*. 17.03.2025. Available at: <https://medium.com/grepsr-blog/perfecting-the-1-10-100-rule-in-data-quality-a1f31143f40b> (accessed 17 March 2025).
2. Misnik A., Borisov V. Compositional neuro network modeling of complex technical systems, *Neurocomputers: Development, Application*, 2016, No. 7, pp. 39-46.
3. Tanenbaum E. *Raspredeleennye sistemy: printsipy i paradigm* [Distributed systems: principles and paradigms]. Saint Petersburg: Piter, 2003, 877 p.
4. Haykin S. *Neural networks: A comprehensive foundation*. 2nd ed. New Jersey: Prentice Hall International, Inc, 1999, 1103 p.
5. Hernández S., Sáez D., Mery D. Neuro-Fuzzy Method for Automated Defect Detection in Aluminium Castings, In: Campilho, A., Kamel, M. (eds.), *Image Analysis and Recognition. ICIAR 2004. Lecture Notes in Computer Science*, Vol. 3212. Springer, Berlin, Heidelberg, 2004.
6. Orlov A.I. *Teoriya prinyatiya resheniy* [Decision theory]. Moscow: Ekzamen, 2005, 656 p.
7. Tarasik V.P. *Matematicheskoe modelirovanie tekhnicheskikh sistem: uchebnik dlya vuzov* [Mathematical modeling of technical systems: a textbook for universities]. Minsk: DizaynPRO, 2004, 640 p.
8. Марка Д., МакГоуэн К. Методология структурного анализа и проектирования [Methodology of structural analysis and design]. Moscow: MetaTekhnologiya, 1993, 240 p.
9. Bobryakov A.V., Krutalevich S.K., Misnik A.E., Prokopenko S.A. Modeling of Industrial and Technological Processes in Complex Systems Based on NeuroFuzzy Petri Nets, *Journal of Physics: Conference Series*, Volume 2096, International Conference on Automatics and Energy (ICAE 2021) 7-8 October 2021, Vladivostok, Russia.
10. Tax N., Verenich I., La Rosa M., Dumas M. Predictive Business Process Monitoring with LSTM neural networks, *Proceedings of the International Conference on Advanced Information Systems Engineering (CAiSE)*, pp. 477-492. arXiv:1612.02130 Freely accessible. doi: 10.1007/978-3-319-59536-8_30.
11. Попов Э.В. *Экспертные системы* [Expert systems]. Moscow: Nauka, 1987, 288 p.

12. Leonenkov A.V. Nechetkoe modelirovanie v srede MATLAB i fuzzyTECH [Fuzzy modeling in MATLAB and FuzzyTECH]. Saint Petersburg: BKhV-Peterburg, 2003.
13. Ash T. Dynamic Node Creation in Back-Propagation Networks, *II Connection Science*, 1989, Vol. 1.
14. Kwan H., Cai L. A fuzzy neural network and its application to pattern recognition // *IEEE Transactions on Fuzzy Systems*. – 1994. – Vol. 2, No. 3. – P. 185-193. – DOI: 10.1109/91.298447.
15. Allen J.F. Maintaining knowledge about temporal intervals, *Communications of the ACM*, 1983, Vol. 26, No. 11, pp. 832-843.
16. Wu J. and Yan S. Reliability Evaluation for Mechanical Systems by Petri Nets, *Petri Nets in Science and Engineering*, 2018.
17. Balbiani P., Boudou J., Diéguez M., Fernández-Duque D. Intuitionistic Linear Temporal Logics, *ACM Transactions on Computational Logic*, 2019, 21, pp. 1-32.
18. Vajnilovich Yu., Zaharchenkov K. and Zakharova A. Integrated System Approach to Improving the Efficiency of IT Projects Management Based on Evolutionary Modeling, *Computing in Physics and Technology*, pp. 309-314.
19. Borisov V.V., Misnik A.E. Ontological Engineering of Interrelated Processes in Complex Cyber-Physical Systems, In: Kovalev, S., Sukhanov, A., Akperov, I., Ozdemir, S. (eds), *Proceedings of the Sixth International Scientific Conference "Intelligent Information Technologies for Industry" (IITI'22). IITI 2022. Lecture Notes in Networks and Systems*, Vol. 566. Springer, Cham, 2023. Available at: https://doi.org/10.1007/978-3-031-19620-1_39.
20. Karabach A. Information integration systems based on semantic technologies, *Science, technology and education*, 2014, Vol. 2 (2).

Прокопенко Сергей Александрович – Белорусско-Российский университет; e-mail: puss95@yandex.by; г. Могилев, Беларусь; тел.: +375447535081; +79679872264; ассистент; ассистент НИУ «МЭИ».

Бобряков Александр Владимирович – НИУ «МЭИ»; e-mail: avbob@mail.ru; г. Москва, Россия; тел.: +74953627407; д.т.н.; зав. кафедрой УИТ.

Prokopenko Sergey Aleksandrovich – Belarusian-Russian University; e-mail: puss95@yandex.by; Mogilev, Belarus; phones: +375447535081; +79679872264; assistant; assistant of National Research University "Moscow Power Engineering Institute".

Bobryakov Alexander Vladimirovich – National Research University "Moscow Power Engineering Institute"; e-mail: avbob@mail.ru; Moscow, Russia; phone: +74953627407; dr. of eng. sc.; head of the Department of Information Technologies;

УДК 004.932

DOI 10.18522/2311-3103-2026-1-284-295

В.Е. Бондарева, Т.С. Черноморова, А.В. Кривцун, А. Абдулкарем

АЛГОРИТМ РАСПОЗНАВАНИЯ ЯЗЫКА ЖЕСТОВ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

Рассматривается задача автоматического распознавания русского жестового языка (РЖЯ) на основе методов компьютерного зрения и глубокого обучения. Актуальность исследования обусловлена устойчивым ростом численности лиц с нарушениями слуха: по данным Всемирной организации здравоохранения, в настоящее время их количество составляет около 70 млн человек, и, согласно прогнозам, может увеличиться до 630 млн к 2035 году. Разработка эффективных алгоритмов распознавания жестов является важным направлением создания систем бесконтактного человеко-машинного взаимодействия, направленных на повышение доступности информационных технологий и улучшение качества жизни людей с ограниченными возможностями слуха. Целью работы является разработка и экспериментальная апробация алгоритма распознавания букв русского жестового языка в видеопотоке в реальном времени с использованием сверточной нейронной сети. В ходе исследования сформирован специализированный датасет, включающий 430 изображений жестов, соответствующих буквам алфавита РЖЯ, представленных с различных ракурсов и при изменяющихся условиях освещения. Для реализации модели использованы библиотеки TensorFlow и Keras, а интеграция с видеопотоком выполнена с применением средств OpenCV и системы отслеживания положения руки на основе маркеров. В результате проведенного обучения и тестирования предложенная модель продемонстрировала точность распознавания на уровне 99