

Ясницкий, Л. Н. Программные инструментальные средства для разработки мероприятий по снижению брака серийного производства / Л. Н. Ясницкий, М. А. Голдобин, А. С. Мезенцев // Прикладная математика и вопросы управления. – 2025. – № 2. – С. 99–116. DOI 10.15593/2499-9873/2025.2.07

Библиографическое описание согласно ГОСТ Р 7.0.100–2018

Ясницкий, Л. Н. Программные инструментальные средства для разработки мероприятий по снижению брака серийного производства / Л. Н. Ясницкий, М. А. Голдобин, А. С. Мезенцев. – Текст : непосредственный. – DOI 10.15593/2499-9873/2025.2.07 // Прикладная математика и вопросы управления / Applied Mathematics and Control Sciences. – 2025. – № 2. – С. 99–116.



ПРИКЛАДНАЯ МАТЕМАТИКА
И ВОПРОСЫ УПРАВЛЕНИЯ

№ 2, 2025

<https://ered.pstu.ru/index.php/amcs>



Научный обзор

DOI: 10.15593/2499-9873/2025.2.07

УДК 004.032.26:621.74



Программные инструментальные средства для разработки мероприятий по снижению брака серийного производства

Л.Н. Ясницкий^{1,2}, М.А. Голдобин³, А.С. Мезенцев⁴

¹Высшая школа экономики, Пермь, Российская Федерация

²Пермский государственный национальный исследовательский университет,
Пермь, Российская Федерация

³ОДК-Пермские моторы, Пермь, Российская Федерация

⁴ИНТЕЛЛЕКТ СОФТ, Пермь, Российская Федерация

О СТАТЬЕ

Получена: 10 мая 2025

Одобрена: 05 июля 2025

Принята к публикации:
08 августа 2025

Финансирование

Исследование выполнено за счет
гранта Российского научного
фонда № 22–61–00096
(<https://rscf.ru/project/22-61-00096/>). Главным исполнителем
гранта является НИУ «МЭИ».

Конфликт интересов

Авторы заявляют об отсутствии
конфликта интересов.

Вклад авторов

равноценен.

Ключевые слова:

серийное производство, техноло-
гические параметры, дефекты,
регламент, химический состав

АННОТАЦИЯ

Представлен обзор современных методов и основанных на них программных инструментах, применяемых для математического моделирования серийных производственных процессов с целью снижения брака и повышения качества производимых изделий. Перечисляются группы работ, нацеленных на обнаружение и классификацию дефектов, работ, в которых решаются задачи прогнозирования образования дефектов и определения значимости параметров, работ направленных на поиск оптимального сочетания технологических параметров изготовления изделий, работ, нацеленных на выявление причин брака. Отмечается, что авторам обзора не удалось найти работы, посвященные применению методов нейросетевого моделирования для решения важной производственной проблемы определения регламентов на технологические параметры. Не были найдены работы, посвященные применению нейронных сетей для ликвидации последствий нештатных ситуаций, связанных с резким возрастанием процента брака. Не встретились работы, направленные на решение проблемы борьбы с выбросами, которыми обычно изобилуют статистические данные, снятые во время работы серийных производственных предприятий, и которые в значительной степени препятствуют созданию математических моделей в области серийного производства. В связи с этим в статье приведено подробное описание результатов публикаций авторов настоящей статьи, посвященных решению именно этих важных проблем построения и применения математических моделей для снижения брака серийных производственных производств.

© Ясницкий Леонид Нахимович – доктор технических наук, профессор, профессор кафедры информационных технологий в бизнесе, e-mail: yasn@psu.ru, ORCID 0000-0002-8212-3826.

Голдобин Максим Алексеевич – ведущий инженер-программист, бюро автоматизации измерений,
e-mail: goldmaxprof@rambler.ru, ORCID 0009-0004-9226-1482.

Мезенцев Алексей Сергеевич – директор по продуктам, e-mail: alexey537@yandex.ru, ORCID 0000-0001-8867-8956.



Эта статья доступна в соответствии с условиями лицензии Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

Perm Polytech Style: Yasnitsky L.N., Goldobin M.A., Mezentsev A.S. Software tools for developing measures to reduce defects in serial production. *Applied Mathematics and Control Sciences*. 2025, no. 2, pp. 99–116. DOI: 10.15593/2499-9873/2025.2.07

MDPI and ACS Style: Yasnitsky, L.N.; Goldobin, M. A.; Mezentsev, A.S. Software tools for developing measures to reduce defects in serial production. *Appl. Math. Control Sci.* **2025**, *2*, 99–116. <https://doi.org/10.15593/2499-9873/2025.2.07>

Chicago/Turabian Style: Yasnitsky, Leonid N., Maxim A. Goldobin, and Alexey S. Mezentsev. 2025. “Software tools for developing measures to reduce defects in serial production”. *Appl. Math. Control Sci.* no. 2: 99–116. <https://doi.org/10.15593/2499-9873/2025.2.07>



APPLIED MATHEMATICS
AND CONTROL SCIENCES

№ 2, 2025

<https://ered.pstu.ru/index.php/amcs>



Review

DOI: 10.15593/2499-9873/2025.2.07

UDC 004.032.26:621.74



Software tools for developing measures to reduce defects in serial production

L. N. Yasnitsky^{1,2}, M. A. Goldobin³, A. S. Mezentsev⁴

¹National Research University Higher School of Economics, Perm, Russian Federation

²Perm State National Research University, Perm, Russian Federation

³UEC-Perm Engines, Perm, Russian Federation

⁴INTELLECT SOFT, Perm, Russian Federation

ARTICLE INFO

Received: 10 May 2025
Approved: 05 July 2025
Accepted for publication:
08 August 2025

Funding

The study was supported by the Russian Science Foundation Grant No. 22-61-00096 (<https://rscf.ru/en/project/22-61-00096/>). The main executor of the grant is the NRU "Moscow Power Engineering Institute"

Conflicts of Interest

The author declares no conflict of interest.

Author Contributions

Equal.

Keywords:

serial production, technological parameters, defects, regulations, chemical composition

ABSTRACT

The article presents a review of modern methods and software tools based on them, applied for mathematical modeling of serial production processes in order to reduce defects and improve the quality of manufactured products. The article lists groups of works aimed at detection and classification of defects, works in which the problems of predicting the formation of defects and determining the significance of parameters are solved, works aimed at finding the optimal combination of technological parameters for manufacturing products, works aimed at identifying the causes of defects. It is noted that the authors of the review failed to find works devoted to the application of neural network modeling methods for solving an important production problem of determining regulations for technological parameters. No works were found devoted to the use of neural networks for eliminating the consequences of emergency situations associated with a sharp increase in the percentage of defects. There are no works aimed at solving the problem of combating emissions, which are usually abundant in statistical data taken during the operation of serial production enterprises and which significantly hinder the creation of mathematical models in the field of serial production. In this regard, the article provides a detailed description of the results of publications by the authors of this article, devoted to solving these important problems of constructing and applying mathematical models to reduce defects in serial production.

© **Leonid N. Yasnitsky** – Doctor of Technical Sciences, professor, professor of the Department of Information Technologies in Business, e-mail: yasn@psu.ru, ORCID 0000-0002-8212-3826.

Maxim A. Goldobin – leading engineer-programmer, buorou of measurement avtomatisation, e-mail: goldmaxprof@rambler.ru, ORCID 0009-0004-9226-1482.

Alexey S. Mezentsev – CPO, Product department, e-mail: alexey537@yandex.ru, ORCID 0000-0001-8867-8956.



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

Введение

В любой отрасли серийного промышленного производства всегда была актуальна проблема улучшения качества производимых изделий и снижение процента брака.

В конце XX в. для решения этой проблемы пользовались популярностью методы математического моделирования, основанные на решении краевых задач математической физики. Однако, несмотря на сложность и красоту математического аппарата, они обладали весьма серьезным недостатком, заключающимся в невозможности учета всего многообразия явлений, факторов и параметров моделируемых производственных процессов и необходимостью введения весьма грубых упрощающих гипотез.

В настоящее время все большее распространение получают инструменты, основанные на методах, лишенных указанного недостатка. Это в основном методы, методы машинного обучения, в частности – искусственные нейронные сети.

Следует отметить, что проблема качества изделий серийного производства методами математического моделирования решается с разных сторон.

Так, математические модели, разрабатываемые авторами работ [1–9], нацелены только на обнаружение и классификацию брака.

Работы [10–18] посвящены поискам взаимосвязи состава сырья и конечных характеристик изготавливаемого продукта. Целью этих исследований является определение оптимального состава сырьевого материала, обеспечивающего максимально высокое качество производимых изделий.

В работах [19–37], помимо диагностики, методы машинного обучения используются для прогнозирования образования дефектов и определения значимости параметров по отношению к тем или иным видам дефектов, а также оптимизации технологических процессов.

Часть работ направлена на поиск технологических параметров изготовления за счет проведения компьютерных экспериментов на основе полученной модели [22; 38; 39]. Такие модели часто предлагается использовать в качестве основы для разработки систем поддержки принятия решений [21; 29].

Редко методы машинного обучения используются для выявления причин брака [38–41], а также изучения закономерностей технологических процессов [10; 14–18].

Если не считать публикаций авторов настоящей статьи [42–46], то совсем не встречаются работы, посвященные применению методов нейросетевого моделирования для решения важной производственной проблемы определения регламентов на технологические параметры, обеспечивающих минимум брака и максимум качества производимых изделий. В работах этих же авторов, по-видимому, впервые показано, как нейронные сети могут применяться для ликвидации последствий нештатных ситуаций, периодически случающихся на серийных производственных предприятиях.

Кроме того, если не считать публикаций авторов настоящей статьи [42–46], среди работ, посвященных проблеме брака серийно производимых изделий, практически не встречаются такие, где при создании математических моделей придавалось бы значение проблеме борьбы с выбросами, которыми, как правило, изобилуют данные, снятые во время работы серийных производственных предприятий, в особенности металлургического и литейного профилей. Как показал наш опыт, наличие статистических выбросов, обусловленных низкой точностью и сбоями измерительной аппаратуры, ошибками и низким уровнем дисциплины персонала, занимающегося сбором статистических данных, часто служит

причиной низкой точности создаваемых математических моделей, что делает их непригодными для практического применения.

В связи с этим опишем результаты исследований публикаций [42–46] более подробно.

Определение регламентов на технологические параметры

В работах [42; 43] сообщается о построении нейросетевой модели, прогнозирующей величину коробления керамического изделия, изготовляемого из мелкодисперсной сырьевой массы. Помимо выявленных с помощью модели закономерностей технологического процесса, авторы работы использовали эти закономерности для разработки регламентов на технологические параметры, обеспечивающие получение изделия без нарушения допуска на его коробление. Для этого они построили графики зависимости величины коробления изделия от параметров «Высота опоки» (рис. 1) и «Время варки сырьевой массы» (рис. 2). Как видно из рис. 1 и 2, изделие будет изготовлено без нарушения допуска по короблению (10 мкм), если технологический параметр «Высота опоки» не будет превышать 75 мм, а «Время варки сырьевой массы» будет не менее 70 мин.




Рис. 1. Зависимость прогнозируемой величины коробления керамического изделия от технологического параметра «Высота опоки» и его регламент: от 25 до 75 мм.
Рисунок заимствован из [42; 43]




Рис. 2. Зависимость прогнозируемой величины коробления керамического изделия от технологического параметра «Время варки сырьевой массы» и его регламент: от 70 до 150 мин. Рисунок заимствован из [42; 43]

В работе [44] сообщается о применении созданной авторами ранее системы искусственного интеллекта DefectPredictor [45] для разработки регламентов на их технологические параметры изготовления керамических литейных стержней. С помощью этой системы построены зависимости вероятности образования дефектов типа «Трещина» и «Непропрессовка» от технологических параметров «Температура пресс-формы перед прессованием» (рис. 3) и «Давление прессования» (рис. 4). Как видно из рисунков, вероятность образования дефектов будет минимальной, если температура пресс-формы перед прессованием будет выдержана в пределах от 20,0 до 29,9°C, а «Давление прессования» – от 2,6 до 7,0 бар.




Рис. 3. Зависимости вероятности возникновения дефектов типа «Трещина» и «Непропрессовка» от технологического параметра «Температура пресс-формы перед прессованием» и его регламент: от 20,0 до 29,9°C. Рисунок заимствован из [44]




Рис. 4. Зависимости вероятности возникновения дефектов типа «Трещина» и «Непропрессовка» от технологического параметра «Давление прессования» и его регламент: от 2,6 до 7,0 бар. Рисунок заимствован из [44]

Ликвидация последствий нештатных ситуаций

На любом производственном предприятии случаются нештатные ситуации, связанные с поломками оборудования, изменением состава сырьевого материала, изменением метеорологической обстановки, ошибками технолога и др. Нештатные ситуации обычно приво-

дят к временной остановке производственного процесса в связи с резким ростом образования брака.

В рассмотренной ранее статье [44], помимо возможности определения регламентов, показано, что последствия некоторых нештатных ситуаций можно оперативно ликвидировать с помощью нейросетевых программных систем. Эта возможность продемонстрирована на примере, когда в рассмотренном выше процессе производства литейных керамических стержней случилась нештатная ситуация – произошел перегрев пресс-формы с регламентного значения 24 до 34 °С, в связи с чем вероятность брака типа «Трещина» повысилась до 57 %.

Для произошедшей нештатной ситуации с помощью упомянутой выше системы DefectPredictor [45] авторы статьи [44] построили зависимости вероятности возникновения дефектов от технологического параметра «Давление прессования». Как видно из рис. 5, снизить вероятность брака «Трещина» до 13 % позволяет уменьшение параметра «Давление прессования» с медианного значения 4,9 до 2,1 бар.

На этом же рисунке отчетливо видно, что дальнейшее снижение давления прессования ниже 2,1 бар, хотя и приводит к дальнейшему понижению вероятности брака «Трещина», однако при этом наблюдается резкое возрастание вероятности брака типа «Непропрессовка». Поэтому давление 2,1 бар в данном случае является оптимальным для оперативной ликвидации последствий случившейся нештатной ситуации.




Рис. 5. Ликвидация последствий нештатной ситуации, связанной с перегревом пресс-формы. Снижение давление прессования с медианного значения 4,9 до 2,1 бар позволяет понизить вероятность брака типа «Трещина» с 57 до 13 %. Давление прессования 2,1 бар является оптимальным, поскольку его дальнейшее снижение приводит к резкому возрастанию другого типа брака «Непропрессовка». Рисунок заимствован из [44]

Возможность оперативной ликвидации нештатной ситуации на другом металлургическом предприятии, производящем пятисоткилограммовые стальные отливки мартеновским способом, описана в публикации [46]. Здесь смоделирован случай нештатной ситуации, вызванной тем, что на завод вовремя не завезли ферросиликомарганец, применяемый в качестве комплексной легирующей и раскисляющей добавки. Отсутствие этого компонента привело к резкому возрастанию брака типа «Горячая трещина» до 14,43 %.

Применение нейронной сети, моделирующей процесс выплавки стали, позволило установить, что оперативно снизить процент брака до 1,34 % можно, не останавливая производственный процесс и не дожидаясь новой поставки ферросиликомарганца, путем увеличения подачи ферросилиция на 609 кг при одновременном увеличении продолжительности чистого кипения расплава на 38 мин и снижении содержания серы на 0,004 %.

Решение проблемы выбросов статистической информации

Сегодня средства массовой и научной информации изобилуют сообщениями об успехах практического применения методов искусственного интеллекта в самых различных предметных областях. Однако этого нельзя сказать о серийных производствах, в частности, литейных изделий.

Серийное производство литейных изделий отличается, в первую очередь, влиянием большого количества разнородных факторов, начиная от внешних: климатических, экономических, астрономических, политических, кадровых, и заканчивая внутренними факторами, такими как периодичность и качество поставляемого сырья, его химический состав, множество технологических параметров производственных линий, дисциплина труда производственного персонала и др. Естественно, такое изобилие параметров статистических выборок, снимаемых в условиях действующего серийного производства, порождает большое количество выбросов статистической информации, в которые и упираются методы машинного обучения. Поэтому в качестве одной из главных причин, препятствующих созданию успешных систем управления качеством серийного производства литейных изделий, являются выбросы.

Надо отметить, что существующие методы борьбы со статистическими выбросами развиты достаточно слабо, что наглядно продемонстрировано в работе [47], в которой приведен пример простейшей модельной предметной области, графически изображенной на рис. 6 показано множество точек, координаты которых, за исключением координат точки **B**, удовлетворяют уравнению

$$y = (x - 6)^2. \quad (1)$$

Поэтому наблюдение, представленное точкой **B**, является выбросом, не имеющим физической (в данном случае геометрической) природы.




Рис. 6. Наблюдение, соответствующее точке **B**, является выбросом, так как удовлетворяют уравнению параболы $y = (x - 6)^2$, которому удовлетворяют все остальные точки.

Рисунок заимствован из [47]

Очевидно, что применение любого из статистических методов (Граббса, Тьюки, boxplot и др.) в силу своего принципа действия не позволяет выявить выброс, соответствующий точке **B**, тогда как точку **C**, не являющуюся выбросом, статистические методы с большой долей вероятности классифицируют как выброс. Столь же очевидно, что метрические методы (основанные на расстояниях Махаланобиса, Евклида и др.), наоборот, позволяют правильно классифицировать точку **B** как выброс, тогда как точки **A** и **C**, не являющиеся выбросами, эти методы, в силу заложенной в них идеи, с большой долей вероятности классифицируют как выбросы, что неправильно. Интересно заметить, что даже наиболее со-

временный и широко рекламируемый метод обнаружения выбросов, основанный на применении автоэнкодеров [48], тоже классифицирует точку **C** как выброс, хотя на самом деле она выбросом не является.

В отличие от статистических и метрических методов, нейросетевой метод, предложенный в работе [49], принципиально позволяет правильно решить проблему выявления выброса (рис. 6). В основе этого метода лежит свойство некоторых нейронных сетей показывать наибольшую погрешность обучения на наблюдениях, являющихся выбросами. Однако, как показано в работе [47], далеко не все нейронные сети обладают таким свойством.

Для иллюстрации этого утверждения в работе [47] на рис. 6, *а*, приведен результат обучения нейронной сети с одним входным нейроном, одним выходным нейроном и одним скрытым слоем с двумя нейронами. Все нейроны нейронной сети имеют активационные функции в виде гиперболического тангенса. В верхней части рис. 7, *а*, показан график функции, которую построила нейронная сеть в результате обучения на наблюдениях, отмеченных точками, а в нижней части – распределение погрешности обучения нейросети ε на тех же наблюдениях. Видно, что наибольшая ошибка обучения ε сконцентрировалась на наблюдении, изображенном точкой **B**, являющемся выбросом. Это значит, что нейронная сеть правильно обнаружила выброс.




Рис. 7. Пример попыток выявить выброс **B** с помощью нейронных сетей, имеющих на скрытом слое: *а* – два нейрона, *б* – три нейрона, *в* – пять нейронов. Рисунок заимствован из [47]

На рис. 7, *б*, такие же графики построены для нейросети, имеющей на скрытом слое три нейрона, а на рис. 7, *в*, – пять нейронов. Видно, что нейросеть с тремя скрытыми нейронами (см. рис. 7, *б*) тоже показывает наибольшую погрешность обучения на наблюдении, соответствующем точке **B**, и, следовательно, правильно выявляет выброс. Нейронная же сеть с пятью скрытыми нейронами (см. рис. 7, *в*) вместо точки **B**, имеющей координату $x = 15$, показала наибольшую погрешность обучения на соседней точке с координатой $x = 16$, которая выбросом не является. Следовательно, такая нейронная сеть для выявления выбросов непригодна.

Аналогичные эксперименты, выполненные при дальнейшем увеличении количества нейронов на скрытом слое, показали, что нейронные сети правильно обнаруживают выброс только в том случае, когда на их скрытом слое содержится от нуля до четырех нейронов. При любом другом количестве нейронов скрытого слоя нейронные сети теряют свое

замечательное свойство показывать наибольшие ошибки обучения на наблюдениях, являющихся выбросами, и, следовательно, они не пригодны для обнаружения выбросов.

В работах [47; 49] с помощью модификации следствия из теоремы Арнольда – Колмогорова предприняты попытки построения методики проектирования нейронных сетей, пригодных для обнаружения выбросов. В частности, предложено для поиска выбросов использовать слоистую нейронную сеть прямого распространения с одним скрытым слоем нейронов с активационной функцией в виде гиперболического тангенса, число нейронов которого рассчитывается по формуле

$$N_i = N_{i,\min} + \xi(N_{i,\max} - N_{i,\min}), \quad (2)$$

где

$$N_{i,\min} = \frac{N_y Q}{(1 + \log_2 Q)(N_x + N_y)}, \quad (3)$$

$$N_{i,\max} = \frac{N_y}{N_x + N_y} \left(\left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + 1 \right). \quad (4)$$

В этих формулах N_x – количество нейронов входного слоя; N_y – количество нейронов выходного слоя; Q – количество наблюдений набора данных; $\xi \in [-0,007; 0,004]$.

Однако методика, предложенная в [47; 49], не является универсальной и для каждой конкретной задачи требует дополнительной настройки параметра ξ . Такая настройка применительно к задаче управления качеством технологического процесса прессования литейных керамических стержней выполнена в работе [44], а применительно к процессу изготовления пятисот килограммовых стальных отливок мартеновским способом – в работе [46]. Настройка параметров ξ для обоих технологических процессов производилась путем варьирования коэффициента ξ в пределах указанного интервала $\xi \in [-0,007; 0,004]$ с шагом 0,001. В результате было найдено его оптимальное значение, которое для процесса производства литейных керамических стержней составило 0,002, а для процесса мартеновского производства пятисоттонных стальных отливок составило 0,003. Применение алгоритма поиска и удаления выбросов в итоге позволило снизить погрешность нейронных сетей приблизительно на 4–6 %.

Заключение

В области серийного промышленного производства всегда была и остается актуальной проблема улучшения качества производимых изделий и снижение процента брака. Для решения этой проблемы в настоящее время все большее распространение получают инструменты, основанные на методах машинного обучения, в частности – искусственные нейронные сети. Причем проблема качества решается с различных сторон.

Имеется большое количество публикаций, нацеленных только на обнаружение и классификацию дефектов. Имеются работы, в которых, помимо диагностики, решаются задачи прогнозирования образования дефектов и определения значимости параметров по отношению к тем или иным видам дефектов, а также оптимизации технологических процессов. Часть работ направлена на поиск технологических параметров изготовления за счет прове-

дения компьютерных экспериментов на основе полученных моделей. Такие модели часто предлагается использовать в качестве основы для разработки систем поддержки принятия решений.

Довольно редко методы машинного обучения используются для выявления причин брака, а также изучения закономерностей технологических процессов с целью получения новых знаний, например, для поиска взаимосвязи состава сырья и конечных характеристик изготавливаемого продукта

Практически не встречаются работы, посвященные применению методов нейросетевого моделирования для решения важной производственной проблемы – определения регламентов на технологические параметры. Не встречаются работы, посвященные применению нейронных сетей для оперативной ликвидации последствий нештатных ситуаций, связанных с резким возрастанием процента брака. Практически не встречаются работы, направленные на решение проблемы борьбы с выбросами, которыми, как правило, изобилуют данные, снятые во время работы серийных производственных предприятий, и которые в значительной степени препятствуют созданию и успешному применению математических моделей в области серийного, особенно металлургического, производства.

В связи с этим особое внимание было уделено подробному описанию результатов публикаций авторов настоящей статьи, посвященных решению именно этих трех важных научно-производственных проблем.

Список литературы

1. Обнаружение и классификация дефектов прокатного происхождения на торцах гильз с использованием сверточной нейронной сети / И.Т. Билан, К.В. Трубников, Д.Ю. Звонарев, М.Н. Носкова // Вестник ЮУрГУ. Серия: Металлургия. – 2023. – Т. 23, № 1. – С. 22–29. DOI: 10.14529/met230103
2. Определение дефектов на стальных листах с использованием сверточных нейронных сетей / Р.Д. Гаскаров, А.М. Бирюков, А.Ф. Никонов, Д.В. Агнияшвили, Д.А. Хайрисламов // Электронные библиотеки. – 2020. – Т. 23, № 6. – С. 1155–1171.
3. Barai, S. Defect detection and classification using machine learning classifier / S. Barai, M. Popat // 16th World Conference on NDT. – 2004. – Montreal (Canada). e-Journal of Nondestructive Testing.
4. Бабаец, К.В. Разработка программной системы по обнаружению дефектов керамической плитки на производственной линии с использованием искусственных нейронных сетей / К.В. Бабаец // Вып. квалиф. работа магистра по направлению «Фундаментальная информатика и информационные технологии»: 02.04.02 / Южно-Уральский государственный университет. – Челябинск, 2019.
5. Daolei, W. A cascaded twin dense network based metallic surface defect detection algorithm / W. Daolei, L. Yiteng, W. Du, Z. Rui // Journal of Computer-Aided Design and Computer Graphics. – 2022. – Vol. 34, № 6. – P. 946–952 (in Chinese). DOI: 10.3724/Sp.J.1089.2022.19056
6. Debroy, S. An opposite transfer-learned DCNN model for prediction of structural surface cracks under optimal threshold for class-imbalanced data / S. Debroy, A. Sil // Journal of Building pathology and Rehabilitation. – 2022. – Vol. 7, № 1. – Article 83. DOI: 10.1007/s41024-022-00226-6
7. Нейросетевой алгоритм распознавания брака отливок на рентгеновских снимках / И.А. Митрофанов, М.А. Голдобин, А.А. Морозов, Л.Н. Ясницкий // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века : сборник ста-

тей по материалам Четвертой всероссийской научно-практической конференции, проводимой в рамках Пермского естественнонаучного форума «Математика и глобальные вызовы XXI века», Пермь, 21–23 мая 2019 года. – Пермь: Пермский государственный национальный исследовательский университет – 2019. – Ч. I. – С. 264–267.

8. Автоматизированная система диагностики и ликвидации литейных дефектов / Ю.Ф. Воронин, А.В. Матохина, Е.О. Сикорский, А.Б. Рогудеев // Известия Волгоградского государственного технического университета. – 2014. – № 12(139). – С. 116–121.

9. Ultrasonic Sensing Classification of Foundry pieces Applying Neural Networks / A. Liliziaro, I. Serrano, J.P. Oria, C. de Miguel // 5th International Workshop on Advanced Motion Control. – 1999. – P.653–658.

10. Долгополова, Л.Б. Использование нейросетевой обработки данных в литейном производстве / Л.Б. Долгополова, И.Х. Тухватулин // Литейные процессы. – 2015. – № 14. – С. 99–105.

11. Оптимизация состава износостойких сплавов с помощью нейросетей / И.Х. Тухватулин, Л.Б. Долгополова, В.М. Колокольников, Ю.П. Ланкин // Литейные процессы: межрегион. сб. науч. тр. – Магнитогорск: МГТУ. – 2000. – С. 40–43.

12. Выбор легирующих комплексов для разработки износостойких сталей с помощью нейросетей / А.Ф. Миляев, И.Х. Тухватулин, Л.Б. Долгополова, Ю.П. Ланкин // Теория и технология металлургического производства. Вып. 2: межрегион. сб. науч. тр. – Магнитогорск: МГТУ, 2001. – С. 188–196.

13. Тухватулин, И.Х. Применение нейросетей для изучения влияния механических свойств сталей на износостойкость / И.Х. Тухватулин, Л.Б. Долгополова, Ю.П. Ланкин // Теория и технология металлургического производства: межрегион. сб. науч. тр. – Магнитогорск: МГТУ, 2001. – Вып. 1. – С. 118–120.

14. Разработка сплавов с заданными свойствами с помощью нейросетевой экспертной системы / И.Х. Тухватулин, Ю.П. Ланкин, В.М. Колокольников, Л.Б. Долгополова // Материалы 15-й Ежегодной Международной научно-технической конференции «Прогрессивные технологии в машиностроении». – Киев, 2000. – С. 251–252.

15. Металловедческая нейросетевая экспертная система для оценки свойств сплавов и выдачи практических рекомендаций / И.Х. Тухватулин, В.М. Колокольников, Л.Б. Долгополова, Ю.П. Ланкин // Литейное производство. – 2000. – № 3. – С. 6–8.

16. Решение обратной металлургической задачи прогноза химического состава сплавов на нейросетевой экспертной системе / Ю.П. Ланкин, И.Х. Тухватулин, В.М. Колокольников, Л.Б. Долгополова // VII Всероссийская конференция «Нейрокомпьютеры и их применение» с международным участием «НКП-2001». – М.: ИПРЖР, 2001. – С. 334–337.

17. Миляев, А.Ф. Моделирование и разработка составов сплавов с помощью нейросетей / А.Ф. Миляев, И.Х. Тухватулин, Л.Б. Долгополова // Наука и производство: сб. докл. 60-й науч.-техн. конф. МГТУ-ММК по итогам научно-исследовательских работ 2000–2001 гг. – Магнитогорск: МГТУ, 2001. – С. 48–54.

18. Тухватулин, И.Х. Моделирование и разработка составов литейных износостойких сталей нейросетевым методом: дис. ... канд. техн. наук: специальность 2.6.3 / И.Х. Тухватулин; ФГБОУ ВО «Магнитогорский государственный технический университет им. Г.И. Носова» – Магнитогорск, 2002. – 191 с.

19. Karnakaran, Prevention of defects in casting using back propagation neural networks / Karnakaran, D. Benny, D.L. Datta // International Journal Advanced Manufacturing Technologies. – 2008. – Vol. 39, iss. 11–12. – P. 1111–1124. DOI: 10.1007/s00170-007-1289-0

20. Pei, Zhang. Optimizing Casting parameters of Ingot Based on Neural Network and Genetic Algorithm / Zhang Pei, Xu Zhiqiang, Du Fengshan // 4th International Conference on Natural Computation. – IEEE Computer Society. – 2008. – P. 545–548.
21. Mares, E. Artificial intelligence-based control system for the analysis of metal casting properties / E. Mares, J.H. Sokolowski // Journal of Achievements in Materials and Manufacturing Engineering, – 2010. – Vol. 40, iss. 2. – P. 149–153.
22. Аверин, П.И. Вариант решения задачи прогнозирования признаков разрушения металлов с помощью нейронных сетей на основе данных вейвлет-анализа импульсов акустической эмиссии / П.И. Аверин, Н.И. Крайнюков // Вектор науки ТГУ. – Тольятти – 2011. – № 4(18) – С. 789–794.
23. Process parameter dependent Machine Learning model for densification prediction of selective laser melted Al-50Si alloy and its validation / K. L. Raju, S. Thapliyal, S. Sigatapu, A.K. Shukla, G. Bajargan, B. Pant // Journal of Materials Engineering and performance. – 2022. – № 31. – P. 8451–8458. DOI: 10.1007/s11665-022-06831-3
24. Шкатов, В.В. Применение нейронных сетей для прогнозирования характеристик пластичности горячекатаных листовых сталей / В.В. Шкатов, В.В. Шкатов // Современные материалы, техника и технологии. – 2018. – Т. 18, № 3. – С. 42–46.
25. Гусев, А.Д. Применение нейронных сетей для прогнозирования измерения микротвердости в зоне термического влияния листов углеродистых и низколегированных сталей после лазерной резки / А.Д. Гусев, И.В. Тихонова, Я.А. Стаханова // Черные металлы. – 2022. – № 5. – С. 79–83.
26. Lopes, N. Part quality prediction in an injection molding process using neural networks / N. Lopes, B. Ribeiro // Proceedings of the Second World Manufacturing Congress (WMC'99). – 1999. – P. 1–7.
27. Osarenmwinda, J.O. Optimization of injection moulding process parameters in the molding of High Density polyethylene (HdpE) / J.O. Osarenmwinda, D.D. Olodu // Journal of Applied Sciences and Environmental Management. – 2018. – Vol. 22, № 2. – P. 203–206. DOI: 10.4314/jasem.v22i2.8
28. Использование искусственных нейронных сетей для прогнозирования прочностных свойств песчано-глинистых смесей литейных форм / С.М. Андреев, М.В. Колокольников, Д.А. Савинов, В.К. Дубровин, Е.В. Петроченко // Вестник Магнитогорского государственного технического университета им. Г.И. Носова. – 2023. – Т. 21, № 4. – С. 23–33.
29. Ворыпаев, А.Н. Мониторинг качества процесса шлифования с использованием нейросетевых моделей: дис. ... канд. техн. наук: Специальность 2.5.6 / А.Н. Ворыпаев; ФГБОУ ВО «Саратовский государственный технический университет имени Гагарина Ю.А.» – Саратов, 2003. – 159 с.
30. Нургаянова, О.С. Обучение нейронной сети для прогнозирования свойств никелевых сплавов на основе генетического алгоритма / О.С. Нургаянова, Н.И. Юсупова // Труды ИСА РАН. – 2019. – Т. 69. – С. 22–28. DOI: 10.14357/20790279190403
31. Marcin, P. Prediction of Ductile Cast Iron Quality by Artificial Neural Networks / P. Marcin, A. Kochanski // Journal of Material processing Technology. – Vol. 109. – 2001. – P. 305–307.
32. Marcin, P. Detection of Causes of Casting Defects Assisted by Artificial Neural Networks / P. Marcin, A. Kochanski // Proceedings of The Institution of Mechanical Engineers Part B-journal of Engineering Manufacture. – 2003. – Vol. 217. – P. 1279–1284.

33. Нургаянова, О.С. Автоматизированное проектирование литейных жаропрочных никелевых сплавов на основе методов искусственного интеллекта: дис. ... канд. техн. наук: Специальность 2.6.3 / О.С. Нургаянова; ГОУ ВПО «Уфимский государственный авиационный технический университет». – Уфа, 2006. – 153 с.
34. Нургаянова, О.С. Применение искусственных нейронных сетей в задачах классификации многокомпонентных сплавов / О.С. Нургаянова // Информационные технологии интеллектуальной поддержки принятия решений (ITIDS'2018): труды VI Всероссийской конференции (с приглашением зарубежных ученых), Уфа-Ставрополь, 28–31 мая 2018 года. – Уфа–Ставрополь: ГОУ ВПО «Уфимский государственный авиационный технический университет». – 2018. – Т. 3. – С. 21–26. – EDN VKQTLZ.
35. Модели представления знаний для поддержки принятия решений при управлении сложными системами в условиях неопределенности и ресурсных ограничений / Н.И. Юсупова, Д.А. Ризванов, О.Н. Сметанина, К.Р. Еникеева // Information Technologies for Intelligent Decision Making Support (ITIDS'2016): Proceedings of the 4th International Conference, Ufa, 17–19 мая 2016 года. – Ufa: ГОУ ВПО «Уфимский государственный авиационный технический университет». – 2016. – Т. 2. – С. 24–27. – EDN WJDSQV.
36. Юсупова, Н.И. Обработка слабоструктурированной информации на основе методов искусственного интеллекта: монография / Н.И. Юсупова; Уфимский государственный авиационный технический университет (УГАТУ). – М.: Инновационное машиностроение, 2016. – 250 с.
37. Методические аспекты искусственного интеллекта: монография / М.Б. Гузаиров, Н.И. Юсупова, О.Н. Сметанина [и др.]; Уфимский государственный авиационный технический университет; Научный совет РАН по методологии искусственного интеллекта. – М., 2014.
38. Ersöz, T. Defective products management in a furniture production company: A data mining approach / T. Ersöz, İ. Güven, F. Ersöz // Applied Stochastic Models in Business and Industry. – 2022. – Vol. 38, no. 5. – P. 901–914. DOI: 10.1002/asmb.2685
39. Козлова, Е.И. Нейросетевые методы анализа и прогнозирования структуры синтетических алмазов / Е.И. Козлова, И.И. Азарко, О.Н. Янковский // Международный конгресс по информатике: информационные системы и технологии: материалы международного научного конгресса 31 окт. – 3 нояб. 2011 г.: в 2 ч. – Минск: БГУ, 2011. – Ч. 2. – С. 174–179.
40. Marcin, P. Prediction of Ductile Cast Iron Quality by Artificial Neural Networks / P. Marcin, A. Kochanski // Journal of Material processing Technology. – 2001. – Vol. 109. – P. 305–307. DOI: 10.1016/S0924-0136(00)00822-0
41. Marcin, P. Detection of Causes of Casting Defects Assisted by Artificial Neural Networks / P. Marcin, A. Kochanski // Proceedings of The Institution of Mechanical Engineers Part B-journal of Engineering Manufacture. – 2003. – Vol. 217. – P. 1279–1284. DOI: 10.1243/095440503322420205
42. Мезенцев, А.С. Нейросетевая модель для определения регламентных параметров технологического процесса переработки рудного сырья / А.С. Мезенцев, Л.Н. Ясницкий // Прикладная информатика. – 2022. – Т. 17, № 6. – С. 56–67. DOI: 10.37791/2687-0649-2022-17-6-56-67
43. Ясницкий, Л.Н. Определение регламента на технологические и сырьевые параметры изготовления серийно выпускаемых изделий / Л.Н. Ясницкий, А.С. Мезенцев, В.Л. Ясницкий // Математические методы в технологиях и технике. – 2023. – № 8. – С. 21–24. DOI: 10.52348/2712-8873_MMTT_2023_8_21

44. Ясницкий, Л.Н. Применение нейросетевого программного комплекса для разработки технологических регламентов серийного производства / Л.Н. Ясницкий, М.А. Голдобин // Прикладная информатика. – 2025.
45. Система искусственного интеллекта «Defectpredictor 2.0» в виде настольного приложения / Л.Н. Ясницкий, Ф.М. Черепанов, А.С. Мезенцев, В.Л. Ясницкий, А.А. Морозов, М.А. Голдобин // Свидетельство Роспатент о регистрации программы для ЭВМ № 2023666283 от 28.07.2023 г. (Россия).
46. Возможности искусственного интеллекта для поддержки принятия решений технолога по снижению брака литых деталей и по ликвидации последствий нештатных ситуаций. / Л.Н. Ясницкий, С.В. Мартыненко, М.Ф. Поленова, А.С. Мезенцев // Литейное производство. – 2025.
47. Ясницкий, Л.Н. Нейросетевой алгоритм выявления и удаления выбросов в зашумленных наборах данных / Л.Н. Ясницкий, Е.Г. Плотникова // Прикладная информатика. – 2024. – Т. 19, № 5. – С. 88–100.
48. Abhaya, A. An efficient method for autoencoder based outlier detection / A. Abhaya, Kr. Bidyut, B.Kr. Patra // Expert Systems with Applications. – 2023. – Vol. 213, Part A. – 118904.
49. Yasnitsky, L.N. Algorithm for searching and analyzing abnormal observations of statistical information based on the Arnold – Kolmogorov – Hecht-Nielsen theorem / L.N. Yasnitsky // International Journal of Advanced Trends in Computer Science and Engineering, – 2020. – Vol. 9, no. 2, – P. 1814–1819. DOI: 10.30534/ijatcse/2020/139922020

References

1. Bilan I.T., Trubnikov K.V., Zvonarev D.Yu., Noskova M.N. Detection and classification of rolling defects on the ends of sleeves using a convolutional neural network. *Vestnik YuUrGU. Seriya "Metallurgiya"* [Bulletin of the South Ural State University. Series "Metallurgy"], 2023, vol. 23, no. 1, pp. 22–29. DOI: 10.14529/met230103.
2. Gaskarov R.D., Biryukov A.M., Nikonov A.F., Agniashvili D.V., Khairislamov D.A. Defect detection on steel sheets using convolutional neural networks. *Elektronnye biblioteki* [Digital Libraries], 2020, vol. 23, no. 6, pp. 1155–1171.
3. Barai S., Porat M. Defect detection and classification using machine learning classifier. *16th World Conference on NDT*, 2004, Montreal (Canada). *e-Journal of Nondestructive Testing*.
4. Babayets K.V. Razrabotka programmnoi sistemy po obnaruzheniyu defektov keramicheskoi plitki na proizvodstvennoi linii s ispolzovaniem iskusstvennykh neironnykh setei [Development of a software system for detecting defects in ceramic tiles on a production line using artificial neural networks]: Master's thesis, 02.04.02. South Ural State University, Chelyabinsk, 2019.
5. Daolei W., Yiteng L., Du W., Rui Z. A cascaded twin dense network based metallic surface defect detection algorithm. *Journal of Computer-Aided Design and Computer Graphics*, 2022, vol. 34, no. 6, pp. 946–952. DOI: 10.3724/SP.J.1089.2022.19056.
6. Debroy S., Sil A. An opposite transfer-learned DCNN model for prediction of structural surface cracks under optimal threshold for class-imbalanced data. *Journal of Building Pathology and Rehabilitation*, 2022, vol. 7, no. 1, Article 83. DOI: 10.1007/s41024-022-00226-6.
7. Mitrofanov I.A., Goldobin M.A., Morozov A.A., Yasnitsky L.N. Neurosetevoi algoritim raspoznavaniya braka otlivok na rentgenovskikh snimkakh [Neural network algorithm for recognizing casting defects on X-ray images]. *Iskusstvennyi intellekt v reshenii aktualnykh sotsialnykh*

i ekonomicheskikh problem XXI veka [Artificial Intelligence in Solving Actual Social and Economic Problems of the 21st Century]: Proc. of the 4th All-Russian Sci.-Pract. Conf., Perm, May 21-23, 2019. Part I. Perm State National Research University, 2019, pp. 264–267.

8. Voronin Yu.F., Matokhina A.V., Sikorsky E.O., Rogudev A.B. Avtomatizirovannaya sistema diagnostiki i likvidatsii liteinykh defektov [Automated system for diagnostics and elimination of foundry defects]. *Izvestiya Volgogradskogo gosudarstvennogo tekhnicheskogo universiteta* [Proceedings of the Volgograd State Technical University], 2014, no. 12(139), pp. 116–121.

9. Liliaro A., Serrano I., Oria J.P., de Miguel C. Ultrasonic Sensing Classification of Foundry pieces Applying Neural Networks. *5th International Workshop on Advanced Motion Control*, 1998, pp. 653–658.

10. Dolgopolova L.B., Tukhtatulin I.Kh. Ispolzovanie neirosetevoi obrabotki dannykh v liteinom proizvodstve [Use of neural network data processing in foundry production]. *Liteinye protsessy* [Foundry Processes], 2015, no. 14, pp. 99–105.

11. Tukhtatulin I.Kh., Dolgopolova L.B., Kolokoltsov V.M., Larkin Yu.P. Optimizatsiya sostava iznosostoikikh splavov s pomoshchyu neirosetei [Optimization of the composition of wear-resistant alloys using neural networks]. *Liteinye protsessy* [Foundry Processes]: interregional collection of scientific papers. Magnitogorsk: MSTU, 2000, pp. 40–43.

12. Milyaev A.F., Tukhtatulin I.Kh., Dolgopolova L.B., Larkin Yu.P. Vybór legiruyushchikh kompleksov dlya razrabotki iznosostoikikh stalei s pomoshchyu neirosetei [Selection of alloying complexes for the development of wear-resistant steels using neural networks]. *Teoriya i tekhnologiya metallurgicheskogo proizvodstva. Vyp. 2* [Theory and Technology of Metallurgical Production. Issue 2]: interregional collection of scientific papers. Magnitogorsk: MSTU, 2001, pp. 188–196.

13. Tukhtatulin I.Kh., Dolgopolova L.B., Larkin Yu.P. Primenenie neirosetei dlya izucheniya vliyaniya mekhanicheskikh svoystv stalei na iznosostoikost [Application of neural networks to study the influence of mechanical properties of steels on wear resistance]. *Teoriya i tekhnologiya metallurgicheskogo proizvodstva. Vyp. 1* [Theory and Technology of Metallurgical Production. Issue 1]: interregional collection of scientific papers. Magnitogorsk: MSTU, 2001, pp. 118–120.

14. Tukhtatulin I.Kh., Larkin Yu.P., Kolokoltsov V.M., Dolgopolova L.B. Razrabotka splavov s zadannymi svoystvami s pomoshchyu neirosetevoi ekspertnoi sistemy [Development of alloys with specified properties using a neural network expert system]. *Materialy 15-i Ezhegodnoi Mezhdunarodnoi nauchno-tekhnicheskoi konferentsii "Progressivnye tekhnologii v mashinostroenii"* [Proceedings of the 15th Annual International Scientific and Technical Conference "Advanced Technologies in Mechanical Engineering"]. Kiev, 2000, pp. 251–252.

15. Tukhtatulin I.Kh., Kolokoltsov V.M., Dolgopolova L.B., Larkin Yu.P. Metallovedcheskaya neirosetevaya ekspertnaya sistema dlya otsenki svoystv splavov i vydachi prakticheskikh rekomendatsii [Metallurgical neural network expert system for assessing alloy properties and issuing practical recommendations]. *Liteinoe proizvodstvo* [Foundry Production], 2000, no. 3, pp. 6–8.

16. Larkin Yu.P., Tukhtatulin I.Kh., Kolokoltsov V.M., Dolgopolova L.B. Reshenie obratnoi metallovedcheskoi zadachi prognoza khimicheskogo sostava splavov na neirosetevoi ekspertnoi sisteme [Solution of the inverse metallurgical problem of predicting the chemical composition of alloys on a neural network expert system]. *VII Vserossiiskaya konferentsiya "Neirokompyutery i ikh primeneniye" s mezhdunarodnym uchastiem "NKP-2001"* [VII All-Russian Conference "Neurocomputers and Their Applications" with international participation "NKP-2001"]. Moscow: IPRZHR, 2001, pp. 334–337.

17. Milyaev A.F., Tukhtatulin I.Kh., Dolgopolova L.B. Modelirovanie i razrabotka sostavov splavov s pomoshchyu neirosetei [Modeling and development of alloy compositions using neural networks]. *Nauka i proizvodstvo: sb. dokl. 60-i nauch.-tekhn. konf. MG TU-MMK po itogam nauchno-issledovatel'skikh rabot 2000-2001 gg.* [Science and Production: collection of reports of the 60th Scientific and Technical Conference of MSTU-MMK on the results of research works 2000-2001]. Magnitogorsk: MSTU, 2001, pp. 48–54.
18. Tukhtatulin I.Kh. Modelirovanie i razrabotka sostavov liteinykh iznosostoikikh stalei neirosetevym metodom [Modeling and development of compositions of foundry wear-resistant steels by the neural network method]: Ph.D. (Engineering) dissertation, speciality 2.6.3. Nosov Magnitogorsk State Technical University, Magnitogorsk, 2002, 191 p.
19. Karnakaran, Benny D., Datta D.L. Prevention of defects in casting using back propagation neural networks. *International Journal Advanced Manufacturing Technologies*, 2008, vol. 39, no. 11-12, pp. 1111–1124. DOI: 10.1007/s00170-007-1289-0.
20. Zhang P., Xu Z., Du F. Optimizing Casting parameters of Ingot Based on Neural Network and Genetic Algorithm. *4th International Conference on Natural Computation*, IEEE Computer Society, 2008, pp. 545–548.
21. Mares E., Sokolowski J.H. Artificial intelligence-based control system for the analysis of metal casting properties. *Journal of Achievements in Materials and Manufacturing Engineering*, 2010, vol. 40, no. 2, pp. 149–153.
22. Averin P.I., Krainyukov N.I. Variant resheniya zadachi prognozirovaniya priznakov razrusheniya metallov s pomoshchyu neironnykh setei na osnove dannykh veivlet-analiza impulsov akusticheskoi emissii [A variant of solving the problem of predicting signs of metal destruction using neural networks based on wavelet analysis data of acoustic emission pulses]. *Vektor nauki TGU* [Science Vector of Togliatti State University], 2011, no. 4(18), pp. 789–794.
23. Raju K.L., Thapliyal S., Sigatapu S., Shukla A.K., Bajargan G., Pant B. Process parameter dependent Machine Learning model for densification prediction of selective laser melted Al-50Si alloy and its validation. *Journal of Materials Engineering and Performance*, 2022, no. 31, pp. 8451–8458. DOI: 10.1007/s11665-022-06831-3.
24. Shkatov V.V., Shkatov V.V. Primenenie neironnykh setei dlya prognozirovaniya kharakteristik plastichnosti goryachekatanykh listovykh stalei [Application of neural networks for predicting the ductility characteristics of hot-rolled sheet steels]. *Sovremennye materialy, tekhnika i tekhnologii* [Modern Materials, Equipment and Technologies], 2018, vol. 18, no. 3, pp. 42–46.
25. Gusev A.D., Tikhonova I.V., Stakhanova Ya.A. Primenenie neironnykh setei dlya prognozirovaniya izmereniya mikrotverdosti v zone teplovogo vliyaniya listov uglerodistykh i nizkolegirovannykh stalei posle lazernoi rezki [Application of neural networks for predicting microhardness measurement in the heat-affected zone of sheets of carbon and low-alloy steels after laser cutting]. *Chernye metally* [Ferrous Metals], 2022, no. 5, pp. 79–83.
26. Lopes N., Ribeiro B. Part quality prediction in an injection molding process using neural networks. *Proceedings of the Second World Manufacturing Congress (WMC'99)*, 1999, pp. 1–7.
27. Osarenmwinda J.O., Olodu D.D. Optimization of injection moulding process parameters in the molding of High Density polyethylene (HdPE). *Journal of Applied Sciences and Environmental Management*, 2018, vol. 22, no. 2, pp. 203–206. DOI: 10.4314/jasem.v22i2.8.
28. Andreev S.M., Kolokoltsov M.V., Savinov D.A., Dubrovin V.K., Petrochenko E.V. Ispolzovanie iskusstvennykh neironnykh setei dlya prognozirovaniya prochnostnykh svoystv peschano-glinistykh smesei liteinykh form [Use of artificial neural networks for predicting the strength properties of sand-clay mixtures of foundry molds]. *Vestnik Magnitogorskogo gosudar-*

stvennogo tekhnicheskogo universiteta im. G.I. Nosova [Bulletin of Nosov Magnitogorsk State Technical University], 2023, vol. 21, no. 4, pp. 23–33.

29. Vorypaev A.N. Monitoring kachestva protsessa shlifovaniya s ispolzovaniem neirosetevykh modelei [Monitoring of the grinding process quality using neural network models]: Ph.D. (Engineering) dissertation, speciality 2.5.6. Yuri Gagarin Saratov State Technical University, Saratov, 2003, 159 p.

30. Nurgayanova O.S., Yusupova N.I. Obuchenie neironnoi seti dlya prognozirovaniya svoystv nikelevykh splavov na osnove geneticheskogo algoritma [Training a neural network to predict the properties of nickel alloys based on a genetic algorithm]. *Trudy ISA RAN* [Proceedings of the ISA RAS], 2019, vol. 69, pp. 22–28. DOI: 10.14357/20790279190403.

31. Marcin P., Kochanski A. Prediction of Ductile Cast Iron Quality by Artificial Neural Networks. *Journal of Material Processing Technology*, 2001, vol. 109, pp. 305–307.

32. Marcin P., Kochanski A. Detection of Causes of Casting Defects Assisted by Artificial Neural Networks. *Proceedings of The Institution of Mechanical Engineers Part B-journal of Engineering Manufacture*, 2003, vol. 217, pp. 1279–1284.

33. Nurgayanova O.S. Avtomatizirovanoe proektirovanie liteinykh zharoprochnykh nikelevykh splavov na osnove metodov iskusstvennogo intellekta [Automated design of foundry heat-resistant nickel alloys based on artificial intelligence methods]: Ph.D. (Engineering) dissertation, speciality 2.6.3. Ufa State Aviation Technical University, Ufa, 2006, 153 p.

34. Nurgayanova O.S. Primenenie iskusstvennykh neironnykh setei v zadachakh klassifikatsii mnogokomponentnykh splavov [Application of artificial neural networks in the tasks of classifying multicomponent alloys]. *Informatsionnye tekhnologii intellektualnoi podderzhki prinyatiya reshenii (ITIDS'2018)* [Information Technologies for Intelligent Decision Making Support (ITIDS'2018)]: Proc. of the 6th All-Russian Conf. (with invitation of foreign scientists), Ufa-Stavropol, May 28-31, 2018. Vol. 3. Ufa-Stavropol: Ufa State Aviation Technical University, 2018, pp. 21–26. EDN VKQTLZ.

35. Yusupova N.I., Rizvanov D.A., Smetanina O.N., Enikeeva K.R. Modeli predstavleniya znaniy dlya podderzhki prinyatiya reshenii pri upravlenii slozhnymi sistemami v usloviyakh neopredelennosti i resursnykh ogranichenii [Knowledge representation models for decision support in managing complex systems under uncertainty and resource constraints]. *Information Technologies for Intelligent Decision Making Support (ITIDS'2016)*: Proceedings of the 4th International Conference, Ufa, May 17-19, 2016. Vol. 2. Ufa: Ufa State Aviation Technical University, 2016, pp. 24–27. EDN WJDSQV.

36. Yusupova N.I. Obrabotka slabostrukturirovannoi informatsii na osnove metodov iskusstvennogo intellekta [Processing of weakly structured information based on artificial intelligence methods]: Monograph. Ufa State Aviation Technical University. Moscow: Innovatsionnoe mashinostroenie, 2016, 250 p.

37. Guzairov M.B., Yusupova N.I., Smetanina O.N. et al. Metodicheskie aspekty iskusstvennogo intellekta [Methodological aspects of artificial intelligence]: Monograph. Ufa State Aviation Technical University, Scientific Council of the Russian Academy of Sciences on the Methodology of Artificial Intelligence. Moscow, 2014.

38. Ersöz T., Güven İ., Ersöz F. Defective products management in a furniture production company: A data mining approach. *Applied Stochastic Models in Business and Industry*, 2022, vol. 38, no. 5, pp. 901–914. DOI: 10.1002/asmb.2685.

39. Kozlova E.I., Azarko I.I., Yankovsky O.N. Neirosetevye metody analiza i prognozirovaniya struktury sinteticheskikhalmazov [Neural network methods for analysis and forecasting of the structure of synthetic diamonds]. *Mezhdunarodnyi kongress po informatike: infor-*

matsionnye sistemy i tekhnologii [International Congress on Informatics: Information Systems and Technologies]: materials of the international scientific congress, October 31 – November 3, 2011: in 2 parts. Part 2. Minsk: BSU, 2011, pp. 174–179.

40. Marcin P., Kochanski A. Prediction of Ductile Cast Iron Quality by Artificial Neural Networks. *Journal of Material Processing Technology*, 2001, vol. 109, pp. 305–307. DOI: 10.1016/S0924-0136(00)00822-0.

41. Marcin P., Kochanski A. Detection of Causes of Casting Defects Assisted by Artificial Neural Networks. *Proceedings of The Institution of Mechanical Engineers Part B-journal of Engineering Manufacture*, 2003, vol. 217, pp. 1279–1284. DOI: 10.1243/095440503322420205.

42. Mezentsev A.S., Yasnitsky L.N. Neirosetevaya model dlya opredeleniya reglamentnykh parametrov tekhnologicheskogo protsessa pererabotki rudnogo syrya [Neural network model for determining the regulatory parameters of the technological process of ore raw materials processing]. *Prikladnaya informatika* [Applied Informatics], 2022, vol. 17, no. 6, pp. 56–67. DOI: 10.37791/2687-0649-2022-17-6-56-67.

43. Yasnitsky L.N., Mezentsev A.S., Yasnitsky V.L. Opredelenie reglamenta na tekhnologicheskie i syrevye parametry izgotovleniya seriino vypuskaemykh izdelii [Determination of regulations for technological and raw material parameters for the manufacture of serially produced products]. *Matematicheskie metody v tekhnologiyakh i tekhnike* [Mathematical Methods in Technologies and Engineering], 2023, no. 8, pp. 21–24. DOI: 10.52348/2712-8873_MMTT_2023_8_21.

44. Yasnitsky L.N., Goldobin M.A. Primenenie neirosetevogo programmnogo kompleksa dlya razrabotki tekhnologicheskikh reglamentov seriinogo proizvodstva [Application of a neural network software package for the development of technological regulations for serial production]. *Prikladnaya informatika* [Applied Informatics], 2025, vol. XX, no. X, pp. XX–XX. DOI: (In press).

45. Yasnitsky L.N., Cherepanov F.M., Mezentsev A.S., Yasnitsky V.L., Morozov A.A., Goldobin M.A. Sistema iskusstvennogo intellekta "Defectpredictor 2.0" v vide nastolnogo prilozheniya [Artificial intelligence system "Defectpredictor 2.0" as a desktop application]. Svidetelstvo Rospatent o registratsii programmy dlya EVM № 2023666283 ot 28.07.2023 g. (Russia) [Certificate of state registration of the computer program No. 2023666283 dated 28.07.2023 (Russia)].

46. Yasnitsky L.N., Martynenko S.V., Polenova M.F., Mezentsev A.S. Vozmozhnosti iskusstvennogo intellekta dlya podderzhki prinyatiya reshenii tekhnologa po snizheniyu braka litykh detalei i po likvidatsii posledstviy neshtatnykh situatsii [Possibilities of artificial intelligence for supporting the decision-making of a technologist to reduce defects of cast parts and to eliminate the consequences of emergency situations]. *Liteinoe proizvodstvo* [Foundry Production], 2025. (Submitted for publication).

47. Yasnitsky L.N., Plotnikova E.G. Neirosetevoi algoritm vyyavleniya i udaleniya vybrosov v zazhumlennykh naborakh dannykh [Neural network algorithm for detecting and removing outliers in noisy datasets]. *Prikladnaya informatika* [Applied Informatics], 2024, vol. 19, no. 5, pp. 88–100.

48. Abhaya A., Bidyut Kr., Patra B.Kr. An efficient method for autoencoder based outlier detection. *Expert Systems with Applications*, 2023, vol. 213, Part A, 118904.

49. Yasnitsky L.N. Algorithm for searching and analyzing abnormal observations of statistical information based on the Arnold – Kolmogorov – Hecht-Nielsen theorem. *International Journal of Advanced Trends in Computer Science and Engineering*, 2020, vol. 9, no. 2, pp. 1814–1819. DOI: 10.30534/ijatcse/2020/139922020.