

ЭП при снижении требований к точности сборки и изготовления.

3. Контроль пространственных характеристик ЭП обеспечивает стабильность воздействия на обрабатываемый материал и способствует повышению воспроизводимости технологического процесса ЭЛС.

Список литературы

1. **Additive** manufacturing of metallic components — Process, structure and properties / T. DebRoy et al. // Progress in Materials Science. — 2018. — Vol. 92. — P. 112–224.
2. **LaFlamme G., D. Powers** / Diagnostic device quantifies, defines geometric characteristics of electron-beams // Welding Journal. — 1991. — Vol. 70. — № 10. — pp. 33–40.
3. **Automated** pinhole-aperture diagnostic for the current profiling of TWT electron beams / Yu.-X. Wei et al. // Measurement Science and Technology. — 2013. — Vol. 24. — № 2.
4. **Palmer T. A., Elmer J. W.** Characterization of electron beams in multiple welders using the enhanced modified faraday cup // International Institute of Welding Quebec City, Canada. — 2006. — 39 p.
5. **Elmer J. W., Teruya A. T.** An Enhanced Faraday Cup for Rapid Determination of Power Density Distribution in Electron

Beams // International Institute of Welding Quebec City, Canada. — 2006. — 8 p.

6. **Elmer J. W., Teruya A., O'Brien D.** Tomographic imaging of noncircular and irregular electron beam current density distributions // Welding Journal. — 1993. — Vol. 72. — № 11. — P. 493–505.

7. **J. W. Elmer, A. T. Teruya** / An enhanced faraday cup for rapid determination of power density distribution in electron beams // Welding Journal. — 2001. — Vol. 80. — № 12. — P. 288–295.

8. **Palmer T. A., Elmer J. W.** Characterisation of electron beams at different focus settings and work distances in multiple welders using the enhanced modified Faraday cup // Science and Technology of Welding & Joining. — 2007. — Vol. 12. — № 2. — P. 161–174.

9. **Пат. 2580266 РФ, МПК В 23 К 15/02.** Устройство для определения распределения плотности энергии и контроля фокусировки электронного пучка / Д. Н. Трушников и др.; № 2015100016/02; заявл. 12.01.2015; опубл. 10.04.2016. Бюл. № 10. — 13 с.

10. **Лаптенок В. Д., Мурыгин А. В., Серегин Ю. Н., Браверман Я.** Управление электронно-лучевой сваркой // Красноярск: САА. — 2000. — 234 с.

11. **Терещенко С. А.** Методы вычислительной томографии. — М.: Физматлит, 2004. — 320 с.

Поступила в редакцию 14.10.2022; после доработки 14.10.2022; принята к публикации 14.10.2022.

УДК 65.011.56

Прогнозирование значений предела прочности сплавов с помощью нейросетевого моделирования на примере системы Al—Ca—Mn

д.т.н. Л. А. Симонова¹, к.т.н. К. В. Клочкова², И. С. Брединин²

// ¹ Набережночелнинский институт ФГАОУ ВО «Казанский (Приволжский) федеральный университет», РФ, Набережные Челны;

² ФГБОУ ВО «МГТУ «СТАНКИН», РФ, Москва. E-mail: lasimonova@mail.ru, kvsimonova@mail.ru

Аннотация. Статья посвящена вопросу организации такой структуры нейронной сети и выбора оптимального алгоритма ее обучения, которая позволяет получить прогнозируемые значения предела прочности сплавов с высокой точностью за минимальное количество итераций на примере сплава системы Al—Ca—Mn. **Ключевые слова:** нейронная сеть, искусственный интеллект, прогнозирование свойств, сплавы системы Al—Ca—Mn.

Abstract. This article is devoted to the organization of such a neural network structure and the choice of an optimal algorithm for its training, which allows to obtain the predicted values of the ultimate strength of alloys with high accuracy in the minimum number of iterations on the example of an alloy of the Al—Ca—Mn system. **Keywords:** neural network, artificial intelligence, prediction of properties, alloys of the Al—Ca—Mn system

Введение. Одним из распространенных конструкционных материалов на данный момент является алюминий, так как имеет ряд преимуществ: легкий, прочный, ковкий и устойчивый к коррозии, обладает высокой электропроводностью и теплопроводностью, широко используется для производства частей элементов (деталей и др.) в аэрокосмической, транспортной и строительной отраслях. Универсальность алюминия делает его наиболее широко используемым материалом после стали [1–3]. Механические свойства алюминия зависят от содержа-

ния примесей, наличие которых ведет к изменениям его физических и технологических параметров и свойств.

В настоящее время физические и механические свойства сплавов алюминия часто не удовлетворяют требованиям, которые к ним предъявляют в зависимости от условий эксплуатации. Таким образом, становится очевидной актуальность и необходимость решения данной проблемы благодаря разработке и внедрению в производство новых сплавов на основе алюминия с более высокими физико-механическими свойствами.

На данный момент активно ведется изучение сплавов системы Al—Ca—Mn, как наиболее перспективных ввиду их хороших эксплуатационных характеристик. Система Al—Ca—Mn демонстрирует превосходные литейные свойства. Механические свойства образцов сплава, полученного методом литья в кокиль в литом состоянии, превосходит требования ГОСТ 1583—93 к свойствам отливок из сплава АК12М2 в литом состоянии, также указанный сплав превосходит сплав АК12М2 по устойчивости к коррозии.

При проектировании и исследовании новых материалов свойства конечных изделий определяют по контрольным образцам, что требует высоких затрат и исполь-

зования большого объема ресурсов. Так как основная цель этих исследований — выявление зависимостей конечных свойств материалов от концентрации химических элементов, входящих в их состав, необходимым является внедрение методик, позволяющих прогнозировать свойства с высокой точностью. Также внедрение этих методик позволит повысить эффективность процесса проектирования в результате снижения сроков разработки и трудоемкости. В настоящее время наиболее перспективные разработки в этой области связаны с использованием элементов искусственного интеллекта.

Методы. В качестве инструмента для решения задачи прогнозирования предела прочности сплавов системы Al—Ca—Mn выбраны нейронные сети, так как их применение при решении задач такого рода показало хорошие результаты [4—11]. Нейронные сети — мощный инструмент для прогнозирования, это обусловлено тем, что они способны обучаться, основываясь на создании связей между входными и выходными данными. Также нейронные сети показывают хорошие результаты при работе с неформализованными данными, а также с данными, отношения между которыми не поддаются описанию с помощью традиционного математического аппарата. В качестве среды для осуществления нейросетевого моделирования выбран MATLAB R2021b, пакет Deep Learning Toolbox.

Корректная работа и адекватность полученных результатов в значительной мере зависит от выбранного типа и сформированной архитектуры нейронной сети (количества слоев и нейронов в слоях), а также грамотного выбора алгоритма ее обучения.

Результаты и обсуждение. Для реализации задачи была выбрана однонаправленная сеть по типу многослойный персептрон, так как в ходе анализа работ [12—20] выявлено, что такая структура является наиболее подходящей для решения задач прогнозирования.

Точность предсказания зависит от числа скрытых слоев и числа нейронов в скрытом слое. Опираясь на характер исходных данных и их число было принято решение использовать один скрытый слой. В процессе моделирования были выполнены изменения числа нейронов в скрытом слое от 10 до 30. Было установлено, что минимум среднеквадратической ошибки и хороший коэффициент корреляции был достигнут при числе 30 нейронов в скрытом слое. Архитектура нейронной сети показана на рис. 1.

Выборки для обучения и тестирования нейронной сети были сформированы в

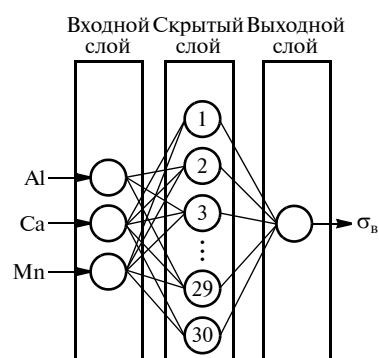


Рис. 1. Архитектура нейронной сети

результате анализа источников [21 и 22]. В качестве входных данных принято процентное содержание химических элементов (Al, Ca, Mn), а в качестве выходного параметра — значение предела прочности.

Выборка входных и выходных параметров для обучения нейронной сети включает в себя следующие парамет-

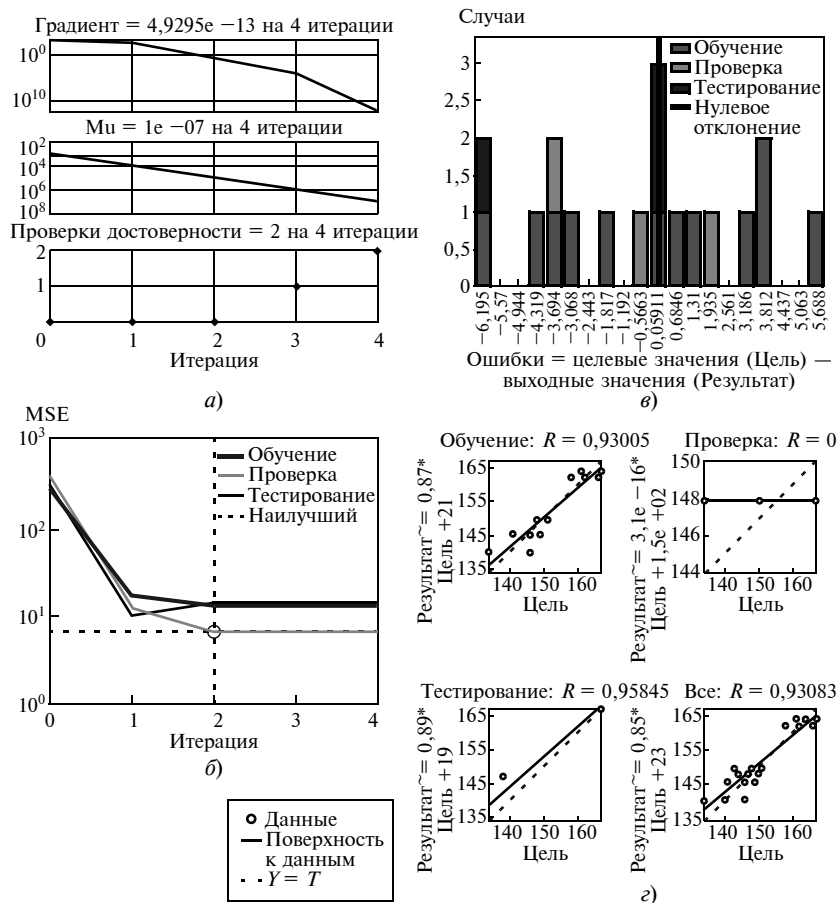


Рис. 2. Графики состояния обучения сети в процессе тренировки с помощью алгоритма обратного распространения Левенберга-Марквардта (а) и графики обучения сети в процессе тренировки (лучший результат проверки 6,7028 на 2 итерации (б); гистограмма ошибок обучения сети (20 интервалов) (в) и графики регрессии (г)

ры: Al1,5Ca2Mn ($\sigma_B = 140 \pm 6$ МПа), Al1,5Ca2,5Mn ($\sigma_B = 164 \pm 3$ МПа), Al2Ca1Mn ($\sigma_B = 127 \pm 5$ МПа), Al2Ca1,5Mn ($\sigma_B = 147 \pm 4$ МПа), Al3Ca1,5Mn ($\sigma_B = 162 \pm 4$ МПа). При расчете были приняты следующие объемы обучающей и тестовой выборки: 70 % — для обучения нейронной сети, 15 % — для измерения сетевого обобщения (обучение прекращается, когда обобщение перестает улучшаться) и 15 % — для проверки работы обученной сети.

В задаче прогнозирования механических свойств системы Al—Ca—Mn с помощью нейронных сетей важным является выбор метода обучения сети. Самые распространенные алгоритмы обучения следующие: обратного распространения Левенберга-Марквардта, Байесовской регуляризации и сопряженных градиентов. Для выбора подходящего алгоритма обучения при решении поставленной задачи произведем расчеты с помощью пакета Deep Learning Toolbox и сравним результаты.

Процесс тренировки нейронной сети для прогнозирования предела прочности с помощью алгоритма Левенберга—Марквардта показан на рис. 2, а и б. Результаты тренировки нейронной сети для прогнозирования предела прочности с помощью алгоритма Левенберга—Марквардта показаны на рис. 2, в и г. Основные результаты обучения: коэффициент корреляции $R = 0,93183$, среднеквадратическое отклонение $MSE = 6,7028$, число итераций до достижения наилучшего результата — 4.

Процесс тренировки нейронной сети для прогнозирования предела прочности с помощью алгоритма Байесовской регуляризации показан на рис. 3, а и б. Результаты тренировки нейронной сети для прогнозирования предела прочности с помощью алгоритма Байесовской регуляризации показаны на рис. 3, в и г.

Основные результаты обучения: коэффициент корреляции $R = 0,93105$, среднеквадратическое отклонение $MSE = 8,7005$, число итераций до достижения наилучшего результата — 95.

Процесс тренировки нейронной сети для прогнозирования предела прочности с помощью алгоритма сопряженных градиентов показан на рис. 4, а и б. Результаты тренировки нейронной сети для прогнозирования предела прочности с помощью алгоритма сопряженных градиентов показаны (рис. 4, в и г). Основные результаты обучения: коэффициент корреляции $R = 0,92003$,

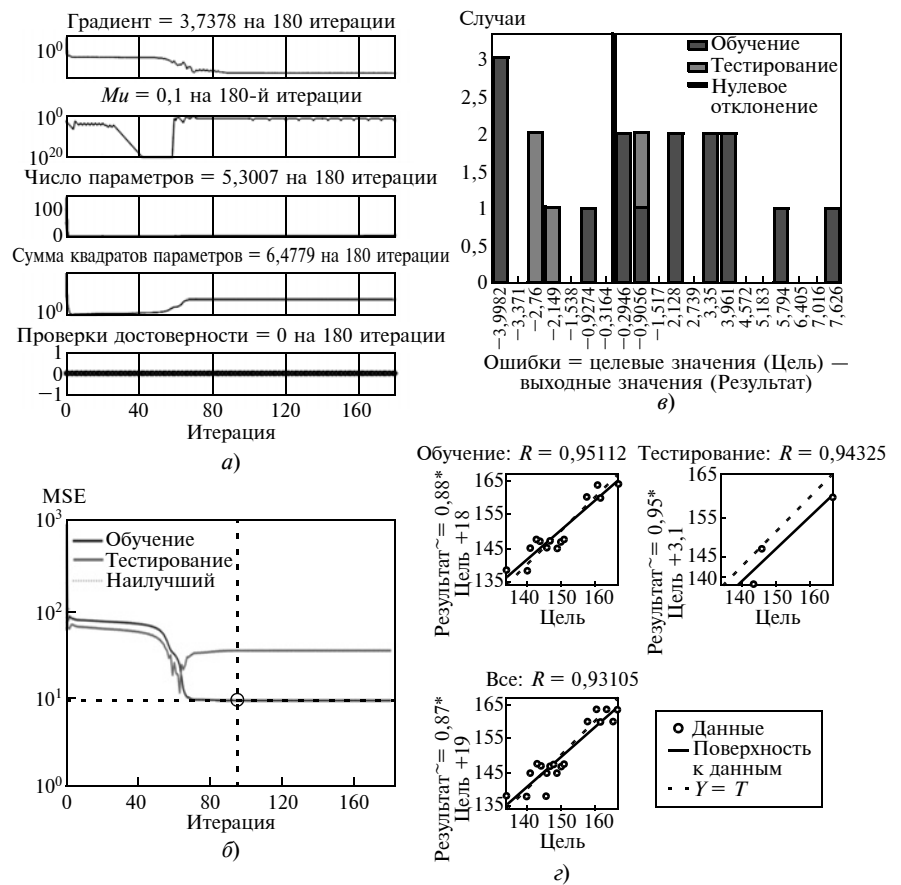


Рис. 3. Графики состояния обучения сети в процессе тренировки с помощью алгоритма Байесовской регуляризации (а) и графики обучения сети в процессе тренировки (лучший результат проверки 87 005 на 95 итерации) (б); гистограмма ошибок обучения сети (20 интервалов) и графики регрессии (в)

среднеквадратическое отклонение $MSE = 24,2392$, число итераций до достижения наилучшего результата — 21.

Выводы. В результате расчетов для обучающих, тестовых и проверочных выборок были получены коэффициент корреляции R и среднеквадратическое отклонение MSE между выходами сети и фактическими (экспериментальными) данными. На основании значений этих показателей, а также числа n итераций до достижения наилучшего результата, осуществим выбор алгоритма обучения нейронной сети. Значения показателей, используемых для выбора алгоритма обучения приведены в табл. 1.

Таблица 1

Алгоритм обучения	R	MSE	n
Алгоритм Левенберга—Марквардта	0,93183	6,7028	4
Алгоритм Байесовской регуляризации	0,93105	8,7005	95
Алгоритм сопряженных градиентов	0,92033	24,2392	21

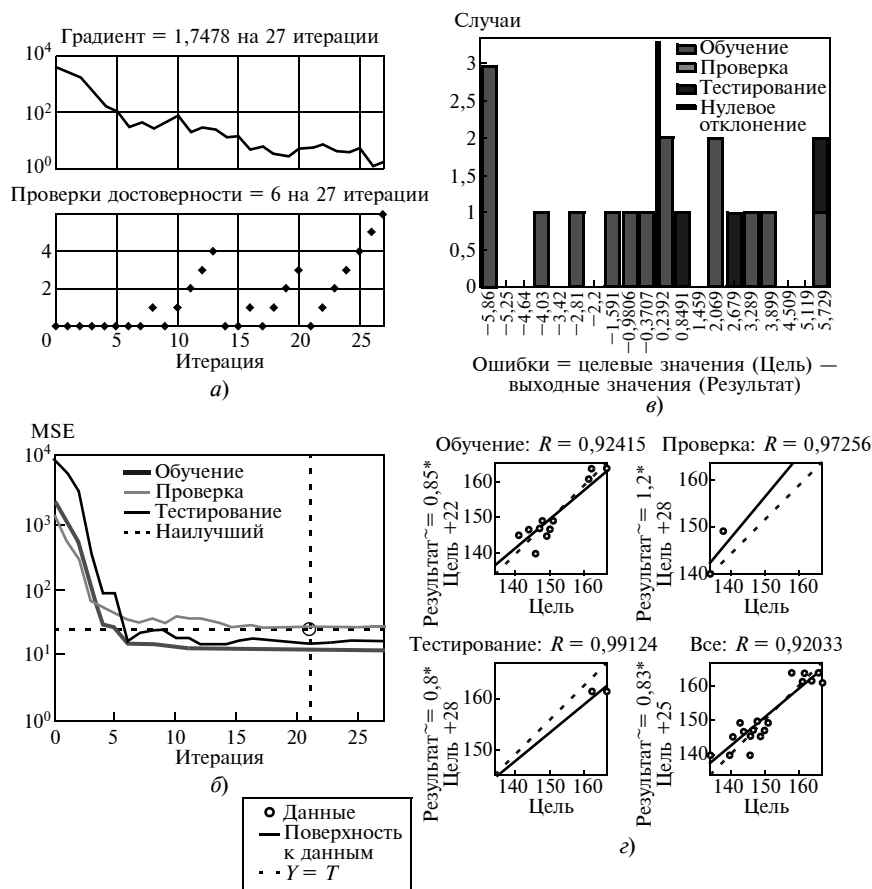


Рис. 4. Графики состояния обучения сети в процессе тренировки с помощью алгоритма сопряженных градиентов (а) и графики обучения сети в процессе тренировки (лучший результат проверки 24,2392 на 21 итерации) (б); гистограмма ошибок обучения сети (20 интервалов) (в) и графики регрессии (г)

На основании расчетов для обучения нейронной сети, имеющей три нейрона входного слоя и 30 нейронов в скрытом слое, выбран алгоритм Левенберга—Марквардта.

Для проверки работоспособности нейронной сети использована контрольная выборка, приведенная в табл. 2.

Таблица 2

Обозначение сплава	Al, %	Ca, %	Mn, %	σ_b , МПа
Al1,5Ca2,5Mn	96	1,5	2,5	164

На выходе нейронной сети получено значение 158,8695 МПа, при целевом 164 МПа. Ошибка прогнозирования составила 3,13 %.

Сформированная и обученная нейронная сеть позволила спрогнозировать предел прочности сплава системы Al—Ca—Mn с ошибкой 3,13 %, что является прогнозом высокой точности.

Заключение

Предложенная в статье организация нейронной сети и алгоритм ее обучения показала высокую точность при прогнозировании значения предела прочности сплавов системы Al—Ca—Mn. Это позволяет сделать вывод, что применение нейронных сетей при прогнозировании механических свойств материалов способствует повышению эффективности принятия решений ввиду их высокой прогнозирующей способности, гибкости и скорости обработки данных.

Кроме того, внедрение этого метода позволит повысить эффективность процесса проектирования путем снижения сроков разработки и трудоемкости.

Список литературы

1. Белецкий В. М., Кривов Г. А. Алюминиевые сплавы — Справочник / Под общей редакцией академика РАН И. Н. Фридляндера. — К.: «КОМИНТЕХ», 2005. — 365 с.
2. Шеметев Г. Ф. Алюминиевые сплавы: составы, свойства, применение: Учеб. пособие по курсу «Производство отливок из сплавов цветных металлов». Ч. 1 (Электронный ресурс). — Санкт-Петербург, 2012. — 155 с.
3. Мутылина И. Н. Материаловедение. Цветные металлы и сплавы на их основе: Учебно-методический комплекс. — М.: Проспект, 2019. — 156 с.
4. Лемзиков А. В., Кундас С. П., Куцыло В. В., Иванов Д. Г. Применение нейросетей для определения характерных точек фазовых превращений в сталях с различным химическим составом // Информатика. — 2007. — № 1 (13). — С. 89—97.
5. Лемзиков А. В., Кундас С. П. Обучение нейронных сетей для прогнозирования свойств сталей // Информатика. — 2009. — № 4 (24). — С. 101—111.
6. Нургайнова О. С., Юсупова Н. И. Обучение нейронной сети для прогнозирования свойств никелевых сплавов на основе генетического алгоритма // Труды ИСА РАН. — 2019. — Т. 69. — № 4. — С. 22—28.
7. Большаков А. Е., Ловушкин М. Ю. Прогнозирование составов алюминиевых сплавов по их свойствам // Машиностроение и безопасность жизнедеятельности. — 2011. — № 2 (9). — С. 37—43.
8. Нургайнова О. С. Применение искусственных нейронных сетей в задачах классификации многокомпонентных сплавов // Proceedings of the 6th All-Russian Scientific Conference «Information Technologies for Intelligent Decision Making Support». — 2018. — Vol. 3.
9. Тухватулин И. Х., Ланкин Ю. П. Прогноз свойств металлических сплавов с помощью нейронных сетей // Научная сессия МИФИ—2000. II Всероссийская научно-техническая конференция «Нейроинформатика—2000». Сборник научных трудов. В 2 ч. Ч. 2. — М.: МИФИ, 2000. — С. 119—125.
10. Тухватулин И. Х., Колокольцев В. М., Долгополова Л. Б., Ланкин Ю. П. Металловедческая нейросетевая экспертная система для оценки свойств сплавов и выдачи практических рекомендаций // Литейное производство. — 2000. — № 3. — С. 6—8.

11. Ланкин Ю. П., Колокольцев В. М., Тухватулин И. Х., Долгополова Л. Б. Использование нейросетевых методов при создании новых сплавов // Известия высших учебных заведений. Черная металлургия. — 2000. — № 11. — С. 44–48.

12. Нургаянова О. С., Юсупова Н. И. Обучение нейронной сети для прогнозирования свойств никелевых сплавов на основе генетического алгоритма // Труды ИСА РАН. — 2019. — Т. 69. — С. 22–28.

13. Юсупова Н. И., Богданова Д. Р., Бойко М. В. Обработка слабоструктурированной информации на основе методов искусственного интеллекта: Монография. — М.: Инновационное машиностроение, 2016. — 250 с.

14. Харитонова Л. П. К вопросу об использовании нейросетевого моделирования для оценки потребления энергии большими массивами потребителей (зданиями) // Междунар. науч.-исслед. журнал. — 2016. — № 3–8 (50). — Р. 155–158. DOI: 10.18454/IRJ.2016.50.176.

15. Pradhan R. P., Kumar R. Forecasting Exchange Rate in India: An Application of Artificial Neural Network Model // Journal of Mathematics Research. — 2010. — Vol. 2. — № 4. — Р. 111–117.

16. Большаков В. И., Дубров Ю. И., Ткаченко А. Н. Задача идентификации качественных характеристик материалов на основе экспертных систем. — Д.: ПДАБА, 2010. — № 1. — С. 46–49.

17. Тухватулин И. Х., Ланкин Ю. П. Прогноз свойств металлических сплавов с помощью нейронных сетей // Научная сес-

сия МИФИ—2000. Нейроинформатика—2000. 2-я Всероссийская научно-техническая конференция. Прикладные задачи нейроинформатики. Экономика и управление производством. Аппаратная реализация нейронных сетей. Нейроинформатика в образовании и гуманитарной сфере. — 2000. — Ч. 2. — С. 119–125.

18. Ключкова, К. В., Абрамова В. В., Петрович С. В. Обучение нейронной сети с применением генетического алгоритма для прогнозирования свойств чугунов с вермикулярным графитом // Грани науки. — 2013. — Т. 1. — № 2. — С. 104–107.

19. Круглов В. В., Борисов В. В. Искусственные нейронные сети. Теория и практика. — М.: Горячая линия-Телеком, 2002. — 382 с.

20. Ростовцев В. С. Искусственные нейронные сети: Учебник. — Санкт-Петербург: Лань, 2019. — 216 с. — ISBN 978-5-8114-3768-9. — URL: <https://e.lanbook.com/book/122180> (дата обращения: 24.08.2020). — Текст: электронный.

21. Дорошенко В. В. Технологичность многокомпонентных алюминиево-кальциевых сплавов при литье и обработке давлением: дисс. ... канд. техн. наук, 2019. — 147 с.

22. Легагин Н. В. Влияние дополнительного легирования (La, Cu, Mn) на структуру, технологичность и механические свойства композиционных алюмокальциевых сплавов.: дисс. ... канд. техн. наук, 2021. — 115 с.

Поступила в редакцию 10.09.2022; после доработки 10.09.2022; принята к публикации 10.09.2022.

ОБЩИЕ ВОПРОСЫ ПРОИЗВОДСТВА. ЭКОНОМИЧЕСКАЯ ДЕЯТЕЛЬНОСТЬ ПРЕДПРИЯТИЯ

УДК 338.3

Перспективы использования технологий «low-code» и «no-code» при проектировании цифровой инфраструктуры высокотехнологичного предприятия

д.э.н. Р. С. Голов, к.э.н. А. В. Мыльник

// МАИ (национальный исследовательский университет), РФ, Москва. E-mail: roman_golov@rambler.ru, vint215@yandex.ru

Аннотация. Авторское исследование посвящено анализу перспектив применения технологий «low-code» и «no-code» при решении задач проектирования цифровой инфраструктуры высокотехнологичного предприятия. Данные технологии нацелены на автоматизацию создания и интеграции модулей и программных компонентов в существующую цифровую инфраструктуру на основе использования упрощенного визуального интерфейса. Подобный подход позволяет привлекать к ее проектированию не только программистов и специалистов инженерно-технического профиля, но также и сотрудников экономического профиля, не владеющих специализированными техническими компетенциями. Благодаря этому становится возможным построение полноценных междисциплинарных команд разработчиков, обеспечивающих активную интеграцию формируемой инфраструктуры не только в оборудование и технические системы предприятия, но также в его программные системы экономического профиля и общую структуру бизнес-процессов предприятия. **Ключевые слова:** высокотехнологичное предприятие, цифровая трансформация, цифровая инфраструктура, междисциплинарная команда, low-code, no-code.

Abstract. The author's research is devoted to the analysis of the prospects of application of «low-code» and «no-code» technologies when solving the problems of designing digital infrastructure of a high-tech enterprise. These technologies aim to automate the creation and integration of software components into the existing digital infrastructure based on the use of a simplified visual interface. Such approach allows to involve not only programmers and specialists of engineering and technical profile, but also employees of economic profile, who do not have specialized technical competences, to its design. This makes it possible to build full-fledged interdisciplinary development teams, providing active integration of the formed infrastructure not only in the equipment and technical systems of the enterprise, but also in its software systems of economic profile and the overall structure of business processes of the enterprise. **Keywords:** high-tech enterprise, digital transformation, digital infrastructure, interdisciplinary team, low-code, no-code.

В современных экономических условиях одним из приоритетных направлений развития высокотехнологичных отраслей промышленности выступает системная