

Оригинальная статья

УДК: 621.74.08

DOI: 10.57070/2304-4497-2026-1(55)-84-93

**ОПТИМИЗАЦИЯ ТЕХНОЛОГИЧЕСКИХ ПАРАМЕТРОВ ЛИТЬЯ С
ИСПОЛЬЗОВАНИЕМ ФИЗИКО-ИНФОРМИРОВАННЫХ ГЕНЕРАТИВНЫХ
МОДЕЛЕЙ ДЛЯ МИНИМИЗАЦИИ ДЕФЕКТНОСТИ СТАЛЬНЫХ ОТЛИВОК**

**© 2026 г. А. И. Куценко, С. В. Князев, А. А. Усольцев, М. В. Темлянцев, А. А. Куценко,
М. М. Гусев**

**Сибирский государственный индустриальный университет (654007, Россия, Кемеровская обл. – Кузбасс,
Новокузнецк, ул. Кирова, 42)**

Аннотация. Представлено физико-информированное генеративное моделирование (ФИГМ) как подход системной оптимизации технологических параметров литья стальных отливок с целью минимизации комплексной дефектности. Методология объединяет методы машинного обучения (глубокие автоэнкодеры для снижения размерности и кластеризации) с фундаментальными физико-технологическими ограничениями, формализованными в виде аналитических выражений. Последние описывают причинно-следственные связи между входными параметрами процесса и возникновением конкретных видов дефектов, что обеспечивает генерацию физически реализуемых и технологически обоснованных решений. Апробация подхода выполнена на историческом датасете по производству отливок типа Рама из стали марки 20Л, содержащем 15 входных и 8 выходных параметров, оценивающих средний уровень дефектности (СУД). В результате применения ФИГМ были идентифицированы и формализованы две устойчивые технологические зоны с различными комплексами параметров, каждая из которых обеспечивает стабильно приемлемый уровень качества. Для количественной оценки разработана целевая функция, учитывающая взвешенную критичность различных видов брака. Ключевым практическим результатом является создание инструмента визуальной аналитики на основе контурных карт взаимосвязей параметров и дефектов. Он позволяет наглядно анализировать технологические компромиссы, выявлять области устойчивых режимов и обоснованно выбирать оптимальные параметры литья. Показано, что предложенная методика преодолевает ограничения традиционных методов, основанных на последовательном устранении отдельных дефектов, и обеспечивает переход к системному управлению качеством за счет одновременного учета взаимного влияния ключевых видов брака.

Ключевые слова: стальные отливки, дефектность, физико-информированные нейронные сети, генеративные модели, машинное обучение

Для цитирования: Куценко А.И., Князев С.В., Усольцев А.А., Темлянцев М.В., Куценко А.А., Гусев М.М. Оптимизация технологических параметров литья с использованием физико-информированных генеративных моделей для минимизации дефектности стальных отливок. *Вестник Сибирского государственного индустриального университета*. 2026;1(55):84–93. [http://doi.org/10.57070/2304-4497-2026-1\(55\)-84-93](http://doi.org/10.57070/2304-4497-2026-1(55)-84-93)

*Original article***OPTIMIZATION OF TECHNOLOGICAL PARAMETERS OF CASTING USING PHYSICO-INFORMED GENERATIVE MODELS TO MINIMIZE DEFECTS IN STEEL CASTINGS**

© 2026 A. I. Kutsenko, S. V. Knyazev, A. A. Usoltsev, M. V. Temlyantsev, A. A. Kutsenko, M. M. Gusev

Siberian State Industrial University (42 Kirova Str., Novokuznetsk, Kemerovo Region – Kuzbass, 654007, Russian Federation)

Abstract. Physicologically informed generative modeling (FIGM) is presented as an approach to system optimization of technological parameters of casting steel castings in order to minimize complex defects. The methodology combines machine learning methods (deep autoencoders for dimensionality reduction and clustering) with fundamental physical and technological limitations formalized in the form of analytical expressions. The latter describe the causal relationships between the input parameters of the process and the occurrence of specific types of defects, which ensures the generation of physically feasible and technologically sound solutions. The approach was tested on a historical dataset for the production of castings of the Frame type made of 20L grade steel, containing 15 input and 8 output parameters estimating the average defect level (SDA). As a result of the application of FIGM, two stable technological zones with different sets of parameters were identified and formalized, each of which provides a consistently acceptable level of quality. For quantitative assessment, an objective function has been developed that takes into account the weighted criticality of various types of defects. The key practical result is the creation of a visual analytics tool based on contour maps of the interrelationships of parameters and defects. It allows you to visually analyze technological compromises, identify areas of stable modes, and reasonably select optimal casting parameters. It is shown that the proposed methodology overcomes the limitations of traditional methods based on the sequential elimination of individual defects and ensures the transition to systematic quality management by simultaneously taking into account the mutual influence of key types of defects.

Keywords: steel castings, defectiveness, physical-informed neural networks, generative models, machine learning

For citation: Kutsenko A.I., Knyazev S.V., Usoltsev A.A., Temlyantsev M.V., Kutsenko A.A., Gusev M.M. Optimization of technological parameters of casting using physico-informed generative models to minimize defectiveness of steel castings. *Bulletin of the Siberian State Industrial University*. 2026;1(55):84–93. [http://doi.org/10.57070/2304-4497-2026-1\(55\)-84-93](http://doi.org/10.57070/2304-4497-2026-1(55)-84-93)

Введение

Современное литейное производство характеризуется сложностью технологических процессов и многофакторностью задач, связанных с обеспечением качества отливок. Традиционные подходы к оптимизации зачастую оказываются малоэффективными, что стимулирует развитие и внедрение методов искусственного интеллекта (ИИ) и машинного обучения. В настоящей работе рассматривается эволюция подходов: от классических методов к перспективным физико-информированным и генеративным моделям.

Исторически основным методом отладки технологии литья и минимизации дефектов был метод «проб и ошибок», основанный на эмпирическом опыте технологов. Этот подход требует значительных временных и материальных затрат на изготовление опытных образцов и их последующий контроль, а его результативность сильно зависит от квалификации персонала [1]. Кроме того,

такой метод плохо поддается формализации и масштабированию на новые виды отливок, особенно с повышенной технологической сложностью [2; 3].

С развитием вычислительной техники стали активно применяться статистические методы, в частности, регрессионный анализ, позволяющий установить количественные связи между параметрами процесса и выходными характеристиками отливки. Например, в работе [4] для прогнозирования прочностных свойств песчано-глинистых смесей использовался персептрон, обученный по методу обратного распространения ошибки на экспериментальных данных. Это позволило количественно оценить влияние состава смеси, влажности и температуры на сопротивление деформации.

Для задач классификации и прогнозирования дефектов успешно применяются различные архитектуры нейронных сетей. В работах [5 – 10] рассмотрено объединение сверточных (CNN) и рекуррентных (RNN) нейронных сетей с методами

нечеткой логики и традиционным неразрушающим контролем для создания автоматизированных систем диагностики литейных дефектов. Эти системы способны не только выявлять дефекты, но и предлагать решения по их устранению или отбраковке отливки.

Методы групповой классификации на основе самоорганизующихся карт Кохонена [2; 3; 11; 12] позволяют разбивать отливки на группы технологической сложности, что дает возможность применять проверенные технологические решения и типовые литниково-питающие системы (ЛПС) к новым, но схожим по классу деталям, значительно ускоряя процесс проектирования.

Несмотря на успехи классического машинного обучения, его ключевым ограничением является требование к большим объемам размеченных данных, получение которых в литейном производстве часто дорого и трудоемко. Перспективным направлением является интеграция физических знаний о процессе в модель ИИ.

В рассмотренных источниках прослеживается переход к более сложным гибридным подходам. Для прогнозирования механических свойств алюминиевых сплавов при кристаллизации под давлением используется нейросетевая модель [13], которая обучается на данных, отражающих физику процесса (давление, химический состав). Это является шагом к созданию физико-информированных нейронных сетей (Physics-Informed Neural Networks – PINNs), которые используют не только данные, но и включают в свою архитектуру уравнения в частных производных, описывающие фундаментальные законы (теплопередачу, гидродинамику, кинетику фазовых превращений).

Для задач, где данных мало, но много физических знаний, также перспективны генеративные модели. Для оптимизации химического состава чугуна с вермикулярным графитом применяется генетический алгоритм – метод [14], родственный идеям генеративного ИИ. Он позволяет в пространстве параметров, ограниченном физико-химическими законами, «генерировать» новые, оптимальные составы сплавов, минимизируя необходимость в полном переборе всех возможных комбинаций.

Рассматриваемые подходы открывают путь к созданию цифровых двойников литейных процессов [14 – 16], которые интегрируют данные, физические модели и алгоритмы ИИ для прогнозирования и минимизации дефектов в стальных отливках еще на этапе проектирования технологии.

Методика исследований

В основу исследования положен разработанный интегрированный алгоритм физико-информированного генеративного проектирования (ФИГОП) [17], реализованный на языке Python [18]. Алгоритм

представляет собой сквозной цикл, состоящий из трех последовательных этапов, ключевой особенностью которого является органичное объединение методов машинного обучения с фундаментальными физическими законами, что обеспечивает генерацию не только оптимальных, но и физически реализуемых решений для литейных процессов и оборудования.

Этап 1. Формализация задачи и подготовка данных

Начальный этап посвящен формализации технологической задачи для литейного производства:

- формулируется техническое задание, определяющее целевую операцию (плавка, кристаллизация), технологические параметры (температура, состав сплава, тип литниково-питающей системы) и критерии оптимизации (минимизация пористости, повышение механических свойств, снижение брака);

- осуществляется концептуальное проектирование, в ходе которого выбирается принцип действия и базовая схема технологического процесса или агрегата на основе законов тепломассопереноса, гидродинамики и кристаллизации;

- выполняется сбор и структурирование ретроспективных производственных данных (параметры режимов, характеристики шихты, результаты контроля качества отливок); проводится статистическая обработка данных, включая анализ корреляций для исключения мультиколлинеарных параметров ($|r| > 0,85$), снижение размерности методами PCA и t-SNE [19], а также кластерный анализ для выявления устойчивых технологических режимов [20].

Этап 2. Физико-информированная генерация решений

Второй этап направлен на создание и использование гибридной модели:

- разрабатывается и обучается суррогатная модель на основе глубокого автоэнкодера с архитектурой «бутылочное горлышко» ($128 \rightarrow 64 \rightarrow 32$ нейрона), которая сжимает исходные данные в латентное пространство и восстанавливает их с минимальной ошибкой (MSE);

- обеспечивается физическая обоснованность модели за счет интеграции формализованного словаря технологических ограничений; словарь включает в себя прямые ограничения (допустимые диапазоны температур, свойства формовочных и стержневых материалов, химического состава сплава), аналитические ограничения (уравнения, учитывающие значения входных параметров, при которых велика вероятность дефектов) и логические ограничения, отражающие технологические причинно-следственные связи.

Для решения обратной задачи (определения входных технологических параметров по заданным

целевым характеристикам отливки) применяется метод стохастической оптимизации на основе модифицированного алгоритма Монте-Карло. Алгоритм осуществляет поиск в латентном пространстве автоэнкодера, генерируя варианты, которые декодер преобразует в наборы входных параметров, обеспечивающих достижение целевых выходных показателей с заданной точностью.

Этап 3. Валидация и формирование документации

Заключительный этап направлен на верификацию и формализацию полученных решений:

– сгенерированные и прошедшие валидацию на соответствие словарю ограничений варианты группируются в кластеры (технологические зоны) с использованием алгоритмов машинного обучения (K-Means, GMM) [19; 20].

Для каждого кластера автоматически формируется паспорт, содержащий статистику по параметрам, оценку стабильности технологического процесса и детальную оценку оптимальности.

Результаты визуализируются в виде контурных карт и диаграмм, наглядно отображающих области оптимальных и допустимых режимов.

На основе апробированных оптимальных решений формируется комплект технологической и рабочей документации для внедрения в литейное производство.

Предложенная методика позволяет системно подойти к задаче оптимизации технологических параметров литья, обеспечивая переход от анализа ретроспективных данных к синтезу новых, физически обоснованных и оптимальных решений, направленных на минимизацию дефектности стальных отливок.

Результаты исследований

В настоящей работе была решена прикладная задача повышения качества стальных (сталь марки 20Л) отливок массой до 300 кг сложной конфигурации при толщине стенок 15 – 30 мм типа Рама, полученных способом литья в песчано-глинистые сырые формы с большим количеством стержней. В качестве исходных данных использовали исторический датасет, содержащий 15 входных технологических параметров (химический состав стали, параметры заливки, свойства формовочной и стержневой смесей) и 8 выходных параметров, представляющих собой средний уровень дефектов (СУД) в баллах от нуля до пяти и 530 строк с экспериментальными наблюдениями (табл. 1).

Для количественной оценки комплексного качества отливки была разработана целевая функция (*quality*), представляющая собой взвешенную сумму, обратную уровням дефектности. Весовые

коэффициенты были назначены в соответствии с критичностью и ремонтпригодностью каждого вида брака: наибольший вес получили наименее критичные и легкоустраняемые дефекты (20 % пригар; 18 % ужимины), а наименьший – наиболее критические и неремонтпригодные (5 % горячие трещины; 7 % усадочные раковины):

$$\begin{aligned} quality = & 0,05/(_GorTr + 1) + 0,12/(_GasRak + 1) + \\ & + 0,14/(_Porist + 1) + 0,20/(_Prigar + 1) + \\ & + 0,08/(_Spay + 1) + 0,18/(_Ugim + 1) + \\ & + 0,07/(_UsRak + 1) + 0,16/(_Zasor + 1); \\ quality \rightarrow & 1,0 \text{ (дефектность отливки отсутствует)}. \end{aligned}$$

Рассматриваемое распределение приоритетов позволяет сосредоточить внимание на борьбе с наиболее критичными и неисправимыми видами брака при разработке технологии литья и контроле качества.

Ключевым элементом методики стала формализация физико-технологических ограничений в виде системы аналитических выражений, описывающих причинно-следственные связи между входными параметрами и возникновением конкретных дефектов. Например, было включено известное правило, что комбинация высокой температуры заливки, низкой газопроницаемости смеси и высокого содержания серы с высокой вероятностью приводит к образованию горячих трещин и газовой пористости.

В результате применения алгоритма физико-информированного генеративного проектирования были идентифицированы две устойчивые технологические зоны (0 и 1) с различными характеристиками (табл. 2).

Зона 0 характеризуется более высоким содержанием углерода (примерно 0,24 %) в стали, пониженной температурой (1588 °С) и скоростью заливки (9,7 кг/с), а также меньшей газопроницаемостью формовочных и стержневых смесей.

Зона 1 отличается меньшим содержанием углерода (0,19 %), но более высокой температурой (1600 °С) и скоростью заливки (11 кг/с), а также повышенной газопроницаемостью смесей.

Анализ сгенерированных контурных карт (см. рисунок) позволил визуализировать сложные взаимосвязи между параметрами и дефектами. Области экстраполяции, отображенные на контурных картах как незаполненные (белые) зоны, служат важным диагностическим признаком, определяющим границы технологически допустимого пространства параметров. Внутри этих контуров формируются рабочие зоны, гарантирующие с заданной вероятностью стабильность целевых выходных характеристик.

**Структура датасета и система оценки дефектности стальных отливок
на основе среднего уровня дефектности (СУД)**

*Table 1. Dataset structure and defect assessment system for steel castings based
on the averaged defect level (COURT)*

Параметры				Обозначение	Минимум	Максимум
Входные						
Группа 1: Параметры стали (металла)						
Содержание углерода, %				C	0,151	0,315
Содержание серы, %				S	0,010	0,079
Содержание остаточного алюминия, %				Al	0,01	0,07
Температура заливки, °C				T	1562	1656
Группа 2: Параметры процесса заливки						
Скорость заливки стали, кг/сек				v	6,0	13,9
Группа 3: Параметры формовочной смеси (F)						
Влажность формовочной смеси, %				W	2,41	3,90
Прочность на сжатие формовочной смеси,кПа				F _{proch}	65	120
Газопроницаемость формовочной смеси,ед.				F _{gas}	83	238
Осыпаемость формовочной смеси, %				F _{osip}	0,30	0,98
Уплотняемость формовочной смеси, %				F _{uplot}	20	50
Содержание органических добавок в формовочной смеси, %				F _{potves}	4,2	6,2
Группа 4: Параметры стержневой смеси (S)						
Прочность на растяжение стержневой смеси, кПа				S _{rastyg}	172	349
Газопроницаемость стержневой смеси, ед.				S _{gas}	76	238
Уплотняемость стержневой смеси,%				S _{uplot}	17	49
Осыпаемость стержневой смеси, %				S _{osip}	0,32	0,70
Выходные (балльная оценка дефектности отливки)						
СУД по горячим трещинам				_GorTr	0	1,95
СУД по газовым раковинам				_GasRak	0	1,91
СУД по ситовидной пористости				_Porist	0	1,95
СУД по засорам				_Zasor	0	1,95
СУД по ужиминам				_Ugim	0	1,92
СУД по пригару				_Prigar	0	1,94
СУД по спаям				_Spay	0	1,95
СУД по усадочным раковинам				_UsRak	0	1,95
Балльные и численные значение СУД дефектности отливки						
Значение	Отсутствие дефектов	Нижний Уровень дефектности	Уровень дефектности соответствует техническим требованиям	Уровень дефектности соответствует техническим условиям	Высокий уровень дефектности	Появление брака по типу дефекта
Балл	0	1	2	3	4	5
Число	0 – 0,1	0,11 – 0,25	0,26 – 0,75	0,76 – 1,25	1,26 – 1,75	Более 1,75

Анализ таких областей позволяет не только установить пределы существования технологического процесса, но и выделить в них подпространства параметров, обеспечивающие воспроизводимое качество продукции.

Наглядно продемонстрирован компенсационный эффект: области технологических параметров,

обеспечивающие минимизацию одного типа дефектов (усадочных раковин), часто соседствуют с зонами роста других дефектов (горячих трещин или газовых раковин). Это подтверждает фундаментальную проблему литейного производства – наличие технологических противоречий [21].

Полученные «паспорта» технологических зон

Характеристики устойчивых технологических зон
Table 2.Characteristics of sustainable technological zones

Параметр	Значение параметра для зоны			
	<i>0</i>		<i>1</i>	
	Минимум	Максимум	Минимум	Максимум
Al	0,01	0,06	0,01	0,07
C	0,16	0,31	0,15	0,31
F_{gas}	83	235	104	234
F_{osip}	0,32	0,98	0,30	0,94
F_{potves}	4,2	6,2	4,2	6,1
F_{proch}	65	102	65	108
F_{uplot}	20	50	20	50
S	0,011	0,055	0,011	0,059
S_{gas}	76	199	85	235
S_{osip}	0,33	0,68	0,32	0,68
S_{rastyg}	172	349	175	346
S_{uplot}	17	49	17	48
T	1566	1656	1573	1648
W	2,45	3,89	2,42	3,90
ν	6,4	12,0	7,9	12,79
Стабильность предсказания				
GorTr	0,875		0,821	
GasRak	0,757		0,798	
Porist	0,603		0,636	
Zasor	0,885		0,841	
Ugim	0,532		0,557	
Prigar	0,855		0,761	
Spay	0,649		0,830	
UsRak	0,675		0.730	
П р и м е ч а н и е: от 0 до менее 0,7 – низкая стабильность; от 0,7 до менее 0,9 – умеренная стабильность; от 0.9 до 1,0 – высокая стабильность.				

содержат детальные статистические характеристики всех параметров и интегральную оценку качества (0,611 и 0,619 для зон *0* и *1*), что предоставляет инженеру-технологу строгий количественный инструмент для выбора оптимальных и устойчивых режимов работы, гарантирующих соблюдение заданных требований к качеству отливки.

Выводы

Разработан и успешно апробирован интегрированный физико-информированный генеративный подход для решения конкретной технологической задачи – минимизации дефектности стальных отливок. Подход продемонстрировал способность выявлять скрытые, неочевидные зависимости между параметрами технологического процесса и комплексным качеством литья.


В результате работы алгоритма были идентифицированы и формализованы две устойчивые технологические зоны с различными комплексами параметров, каждая из которых обеспечивает приемлемый и стабильный уровень качества. Это доказывает, что для достижения целевых показателей несколько различных, но равноценных с

точки зрения многокритериальной оптимизации, технологических стратегий.

Ключевым практическим результатом является создание инструмента визуальной аналитики на основе контурных карт. Такой инструмент позволяет инженеру-технологу наглядно анализировать компромиссы между различными видами дефектов, находить зоны технологической устойчивости и обоснованно выбирать режимные параметры, обеспечивающие оптимальный баланс качества.

Установлено, что традиционная практика последовательного устранения отдельных дефектов является малоэффективной из-за наличия сильных технологических противоречий. Предложенная методика позволяет перейти к системному управлению качеством, учитывающему взаимное влияние всех ключевых видов брака одновременно.

Полученные результаты обладают высокой практической значимостью и могут быть непосредственно внедрены в производство для оптимизации режимов литья стальных фасонных отливок, снижения процента брака и повышения стабильности технологического процесса.



б

Контурные карты взаимосвязи температуры стали и скорости ее заливки расплава в литейную форму с дефектами в виде ситовидной пористости (а), дефектов в виде ситовидной пористости с пригаром и горячими трещинами (б), с газовыми и усадочными раковинами (в) для различных технологических зон

Contour maps of the relationship between the temperature of steel and the rate of its casting into a casting mold with defects in the form of sieve porosity (a), defects in the form of sieve porosity with burn and hot cracks (б), with gas and shrink shells (в) for various technological zones

СПИСОК ЛИТЕРАТУРЫ

1. Matokhina A.V., Kizim A.V., Voronin Y.F. Automation of customer needs forecasting. *World Applied Sciences Journal*. 2013;24(24):126–132. <https://doi.org/10.5829/idosi.wasj.2013.24.itmi.es.80024>; EDN: SLAPBT
2. Одарченко И.Б., Жаранов В.А., Прусенко И.Н. Расширенная оценка технологической сложности отливок на основе применения методов нейросетей. В кн.: *Современные проблемы машиноведения: Материалы XIII Международной научно-технической конференции (научные чтения, посвященные 125-летию со дня рождения П. О. Сухого)*. Гомель: изд. Гомельского государственного технического университета им. П.О. Сухого, 2020:102–105. EDN: SMXSYJ.
3. Schmidhuber J. Deep Learning in neural networks: An overview. *Neural Networks*. 2015;61:85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>; EDN: YEWUEF.
4. Андреев С.М., Колокольцев М.В., Савинов Д.А. и др. Использование искусственных нейронных сетей для прогнозирования прочностных свойств песчано-глинистых смесей литейных форм. *Вестник Магнитогорского государственного технического университета им. Г.И. Носова*. 2023;21(4):23–33.
5. Смыков А.Ф., Кузовов С.С. Основы разработки автоматизированной системы по выявлению литейных дефектов в фасонных отливках на базе нейронных сетей и нечеткой логики. *Заготовительные производства в машиностроении*. 2025;23(7):295–301.
6. Schmidhuber J. Deep Learning in Neural Networks: An Overview. *Neural Networks*. 2015;61. EDN: YEWUEF.
7. Mikolov T., Karafiat M., Burget L., Cernocky J., Khudanpur S. Recurrent neural network based language model. In: *11th Annual Conference of the International Speech Communication Association*. Japan. 2010:38–45.
8. Kuzovov S.S., Smykov A.F. The Application of Convolutional Neural Networks and Fuzzy Logic in Control and Automation Systems for Recognizing and Assessing the Danger Level of Hot Cracks in the Production of Cast Products. In: *International Russian Smart Industry Conference (SmartIndustryCon)*. IEEE. 2024:984–988.
9. Angelini L., Carlo F., Marangi C., Pellicoro M., Nardullia M., Stramaglia S. Clustering Data by Inhomogeneous Chaotic Map Lattices. *Physical Review Letters*. 2000;85:199–329. EDN: LTNGNH.
10. Князев С.В., Козырев Н.А., Усольцев А.А., Михно А.Р. Алгоритмы управления подготовкой формовочных смесей. *Черная металлургия. Бюллетень научно-технической и экономической информации*. 2021;77(10):1076–1080. <https://doi.org/10.32339/0135-5910-2021-10-1076-1080>. EDN: AMYKQZ.
11. Oborskiy G.A., Bundyuk A.N., Tarakhtiy O.S. Control system of cogeneration power plant at partial electrical loads. *Journal of Automation and Information Sciences*. 2018;50(7):70–78. <https://doi.org/10.1615/jautomationinfscien.v50.i7.60>; EDN: FOFKWW.
12. Одарченко И.Б., Жаранов В.А., Прусенко И.Н. Оптимизация гидродинамики литниково-питающих систем с использованием нейросетевых методов классификации технологических параметров. *Литье и металлургия*. 2017;4(89):84–88.
13. Денисов М.С., Петрешин Д.И., Чеботарев П.А., Рязунов С.А. Разработка нейросетевой модели для прогнозирования механических свойств алюминиевых сплавов при литье с кристаллизацией под давлением. *Автоматизация. Современные технологии*. 2023;77(10):439–446.
14. Юсупов Л.Р., Ключкова К.В., Симонова Л.А. Методика моделирования химического состава чугуна с вермикулярным графитом на основе генетического алгоритма. В кн.: *Инновационные машиностроительные технологии, оборудование и материалы*. 2016:180–185.
15. Одарченко И.Б., Жаранов В.А., Прусенко И.Н. Интеграция нейросетевых моделей в процессы технологической подготовки производства отливок. *Литье и металлургия*. 2018;4(93):45–49.
16. Шайхутдинова И.И. Автоматизированные системы контроля качества в производстве отливок из алюминиевых сплавов. *Литейное производство*. 2025;9:25–33.
17. Черняев М.А., Терешина В.В. Гибридные модели на стыке физики и искусственного интеллекта: методы и приложения. *Вектор научной мысли*. 2025;7(24):159–164.
18. Dli M.I., Vlasova E.A., Sokolov A.M., Morgunova E.V. Creation of a chemical-technological system digital twin using the Python language. *Journal of Applied Informatics*. 2021;16(1(91)):22–31. <https://doi.org/10.37791/2687-0649-2021-16-1-22-31>; EDN: AGPYPO.
19. Holmes J., Ahmed I., Brindescu C. et al. Using Relative Lines of Code to Guide Automated Test Generation for Python. *ACM Transactions on Software Engineering and Methodology*. 2020;29(4):1–38. <https://doi.org/10.1145/3408896>. EDN: IZTCZY.

20. Kharisma Raharjana I., Faris Arifin M., Iklil Nur A., Mubarak N. Conversion of User Story Scenarios to Python-Based Selenium Source Code for Automated Testing. *TEM Journal*. 2023;12(1):309–315.
<https://doi.org/10.18421/tem121-39>; EDN: TDIVAF.
 21. Князев С.В., Куценко А.И., Усольцев А.А. и др. Перспективы и направления цифровой трансформации в литейном производстве. *Известия вузов. Черная металлургия*. 2023;66(2):140–147.
<https://doi.org/10.17073/0368-0797-2023-2-140-147>. EDN: JNMFIQ.
- ### REFERENCES
1. Matokhina A.V., Kizim A.V., Voronin Y.F. Automation of customer needs forecasting. *World Applied Sciences Journal*. 2013;24(24):126–132.
<https://doi.org/10.5829/idosi.wasj.2013.24.itmi.es.80024>; EDN SLAPBT
 2. Odarchenko I.B., Zharanov V.A., Prusenko I.N. Extended assessment of the technological complexity of castings based on the application of neural network methods. In: *Modern problems of mechanical engineering: Proceedings of the XIII International Scientific and Technical Conference (scientific readings dedicated to the 125th anniversary of P. O. Sukhoi's birth)*. Gomel: izd. Gomel State Technical University named after P. O. Sukhoi, 2020:102–105. (In Russ.). EDN SMXSYJ.
 3. Schmidhuber J. Deep Learning in neural networks: An overview. *Neural Networks*. 2015;61:85–117.
<https://doi.org/10.1016/j.neunet.2014.09.003>; EDN YEWUEF.
 4. Andreev S.M., Kolokol'tsev M.V., Savinov D.A. et al. The use of artificial neural networks to predict the strength properties of sand-clay mixtures of molds. *Vestnik Magnitogorskogo gosudarstvennogo tekhnicheskogo universiteta im. G.I. Nosova*. 2023;21(4):23–33. (In Russ.).
 5. Smykov A.F., Kuzovov S.S. Fundamentals of the development of an automated system for detecting casting defects in shaped castings based on neural networks and fuzzy logic. *Zagotovitel'nye proizvodstva v mashinostroenii*. 2025;23(7):295–301. (In Russ.).
 6. Schmidhuber J. Deep Learning in Neural Networks: An Overview. *Neural Networks*. 2015;61. EDN: YEWUEF.
 7. Mikolov T., Karafiat M., Burget L., Cernocky J., Khudanpur S. Recurrent neural network based language model. In: *11th Annual Conference of the International Speech Communication Association*. Japan. 2010: 38–45.
 8. Kuzovov S.S., Smykov A.F. The Application of Convolutional Neural Networks and Fuzzy Logic in Control and Automation Systems for Recognizing and Assessing the Danger Level of Hot Cracks in the Production of Cast Products. In: *International Russian Smart Industry Conference (SmartIndustryCon)*. IEEE. 2024:984–988.
 9. Angelini L., Carlo F., Marangi C., Pellicoro M., Nardullia M., Stramaglia S. Clustering Data by Inhomogeneous Chaotic Map Lattices. *Physical Review Letters*. 2000;85:199–329. EDN: LTNGNH.
 10. Knyazev S.V., Kozyrev N.A., Usolt'sev A.A., Mikhno A.R. Algorithms for controlling the preparation of molding mixtures. *Ferrous Metallurgy. Bulletin of Scientific, Technical and Economic Information*. 2021;77(10):1076–1080.
<https://doi.org/10.32339/0135-5910-2021-10-1076-1081>. EDN: AMYKQZ.
 11. Oborskiy G.A., Bundyuk A.N., Tarakhtiy O.S. Control system of cogeneration power plant at partial electrical loads. *Journal of Automation and Information Sciences*. 2018;50(7):70–78.
<https://doi.org/10.1615/jauto-matinfscien.v50.i7.60>; EDN: FOFKWW.
 12. Odarchenko I.B., Zharanov V.A., Prusenko I.N. Optimization of hydrodynamics of gate-feeding systems using neural network methods for classifying technological parameters. *Lit'e i metallurgiya*. 2017;4(89):84–88. (In Russ.).
 13. Denisov M.S., Petreshin D.I., Chebotarev P.A., Ryauzov S.A. Development of a neural network model for predicting the mechanical properties of aluminum alloys during injection molding. *Avtomatizatsiya. Sovremennye tekhnologii*. 2023;77(10):439–446. (In Russ.).
 14. Yusupov L.R., Klochkova K.V., Simonova L.A. Methodology for modeling the chemical composition of cast iron with vermicular graphite based on a genetic algorithm. In: *Innovative engineering technologies, equipment and materials*. 2016:180–185. (In Russ.).
 15. Odarchenko I.B., Zharanov V.A., Prusenko I.N. Integration of neural network models into the processes of technological preparation of castings. *Lit'e i metallurgiya*. 2018;4(93):45–49. (In Russ.).
 16. Shaikhutdinova I.I. Automated quality control systems in the production of aluminum alloy castings. *Liteinoe proizvodstvo*. 2025;9:25–33. (In Russ.).
 17. Chernyaev M.A., Tereshina V.V. Hybrid models at the junction of physics and artificial intelligence: methods and applications. *Vektor nauchnoi mysli*. 2025;7(24):159–164. (In Russ.).
 18. Dli M.I., Vlasova E.A., Sokolov A.M., Morgunova E.V. Creation of a chemical-technological system digital twin using the Python language. *Journal of Applied Informatics*. 2021;16(1(91)):22–31.
<https://doi.org/10.37791/2687-0649-2021-16-1-22-31>; EDN AGPYPO.

19. Holmes J., Ahmed I., Brindescu C. et al. Using Relative Lines of Code to Guide Automated Test Generation for Python. *ACM Transactions on Software Engineering and Methodology*. 2020;29(4):1–38.

<https://doi.org/10.1145/3408896>; EDN: IZTCZY.

20. Kharisma Raharjana I., Faris Arifin M., Iklil Nur A., Mubarak N. Conversion of User Story Scenarios to Python-Based Selenium Source Code for Automated Testing. *TEM Journal*. 2023;12(1):309–315.

<https://doi.org/10.18421/tem121-39>; EDN: TDIVAF.

21. Knyazev S.V., Kutsenko A.I., Usoltsev A.A. et al. Prospects and directions of digital transformation in foundry production. *Izvestiya vuzov. Chernaya metallurgiya*. 2023;66(2):140–147. (In Russ.). <https://doi.org/10.17073/0368-0797-2023-2-140-147>. EDN: JNMFIQ.

Сведения об авторах:

Андрей Иванович Куценко, к.т.н., доцент, главный специалист по управлению стратегическим проектом, Сибирский государственный индустриальный университет

ORCID: 0000-0003-4724-630X

E-mail: aik_mail@mail.ru

SPIN-код: 6707-3067

Сергей Валентинович Князев, к.т.н., доцент кафедры металлургии черных металлов и химической технологии, Сибирский государственный индустриальный университет

ORCID: 0000-0001-9637-4821

E-mail: krookia@mail.ru

SPIN-код: 7261-3100

Александр Александрович Усольцев, к.т.н., доцент кафедры металлургии черных металлов и химической технологии, Сибирский государственный индустриальный университет

ORCID: 0000-0001-6220-7910

E-mail: a.us@rambler.ru

SPIN-код: 8252-7303

Михаил Викторович Темлянец, д.т.н., профессор, проректор по реализации стратегического проекта, Сибирский государственный индустриальный университет

ORCID: 0000-0001-7985-5666

E-mail: uchebn_otdel@sibsiu.ru

SPIN-код: 6169-5458

Андрей Андреевич Куценко, к.т.н., доцент кафедры теплогазоводоснабжения, водоотведения и вентиляции, Сибирский государственный индустриальный университет

ORCID: 0000-0003-0503-7438

E-mail: aak_mail@mail.ru

SPIN-код: 4243-5030

Максим Михайлович Гусев, директор центра цифровых компетенций, Сибирский государственный индустриальный университет

ORCID: 0009-0008-7693-8405

E-mail: gusev_mm@sibsiu.ru

SPIN-код: 2010-1015

Information about the Authors

Andrey I. Kutsenko, Cand. Sci. (Eng.), Associate Professor, Chief Specialist in Strategic Project Management, Siberian State Industrial University

ORCID: 0000-0003-4724-630X

E-mail: aik_mail@mail.ru

SPIN-код: 6707-3067

Sergey V. Knyazev, Cand. Sci. (Eng.), Associate Professor of the Department of Ferrous Metallurgy and Chemical Technology, Siberian State Industrial University

ORCID: 0000-0001-9637-4821

E-mail: krookia@mail.ru

SPIN-код: 7261-3100

Alexander A. Usoltsev, Cand. Sci. (Eng.), Associate Professor of the Department of Ferrous Metallurgy and Chemical Technology, Siberian State Industrial University

ORCID: 0000-0001-6220-7910

E-mail: a.us@rambler.ru

SPIN-код: 8252-7303

Mikhail V. Temlyantsev, Dr. Sci. (Eng.), Prof., Vice-Rector for Strategic Project Implementation, Siberian State Industrial University

ORCID: 0000-0001-7985-5666

E-mail: uchebn_otdel@sibsiu.ru

SPIN-код: 6169-5458

Andrey A. Kutsenko, Cand. Sci. (Eng.), Associate Professor of the Department of Heat and Gas Supply, Sanitation and Ventilation, Siberian State Industrial University

ORCID: 0000-0003-0503-7438

E-mail: aak_mail@mail.ru

SPIN-код: 4243-5030

Maxim M. Gusev, Director of the Center for Digital Competencies, Siberian State Industrial University

ORCID: 0009-0008-7693-8405

E-mail: gusev_mm@sibsiu.ru

SPIN-код: 2010-1015

Авторы заявляют об отсутствии конфликта интересов.
The authors declare that there is no conflict of interest.

Поступила в редакцию 19.01.2026

После доработки 03.02.2026

Принята к публикации 15.02.2026

Received 19.01.2026

Revised 03.02.2026

Accepted 15.02.2026