

Ясницкий, Л. Н. Об управлении химическим составом сырьевого материала и режимом плавки для обеспечения требуемых механических свойств стальных изделий серийного производства / Л. Н. Ясницкий, А. С. Мезенцев // Прикладная математика и вопросы управления. – 2023. – № 3. – С. 109–126. DOI 10.15593/2499-9873/2023.3.08

Библиографическое описание согласно ГОСТ Р 7.0.100–2018

Ясницкий, Л. Н. Об управлении химическим составом сырьевого материала и режимом плавки для обеспечения требуемых механических свойств стальных изделий серийного производства / Л. Н. Ясницкий, А. С. Мезенцев. – Текст : непосредственный. – DOI 10.15593/2499-9873/2023.3.08 // Прикладная математика и вопросы управления / Applied Mathematics and Control Sciences. – 2023. – № 3. – С. 109–126.



ПРИКЛАДНАЯ МАТЕМАТИКА
И ВОПРОСЫ УПРАВЛЕНИЯ

№ 3, 2023

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



Научная статья

DOI: 10.15593/2499-9873/2023.3.08

УДК 620.173.2:669.15-194



Об управлении химическим составом сырьевого материала и режимом плавки для обеспечения требуемых механических свойств стальных изделий серийного производства

Л.Н. Ясницкий^{1,2}, А.С. Мезенцев¹

¹Пермский государственный национальный исследовательский университет, Пермь, Российская Федерация

²Пермский филиал Национального исследовательского университета «Высшая школа экономики», Пермь, Российская Федерация

О СТАТЬЕ

Получена: 28 августа 2023
Одобрена: 20 сентября 2023
Принята к публикации:
02 октября 2023

Финансирование

Исследование выполнено за счет гранта Российского научного фонда № 22–61–00096.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Вклад авторов:

равноценен

Ключевые слова:

химический состав, сырьевой материал, ударная вязкость, параметры плавки, нейронная сеть, прогнозирование, стальные отливки, низкоуглеродистая сталь, мартеновский сталеплавильный процесс.

АННОТАЦИЯ

Целью работы является создание математической модели, пригодной для оперативного управления прочностными характеристиками получаемого стального изделия в условиях серийного сталеплавильного производства. Существующие подходы, основанные на результатах испытаний опытных образцов, получаемых в лабораторных условиях, для этой цели не подходят, поскольку в условиях серийного сталеплавильного производства на прочностные характеристики изделий, помимо их химического состава, влияет структура металла и множество других условий плавки. Подходы, в которых при прогнозировании принимается во внимание структура металла, также не могут быть использованы, так как получение параметров структуры металла возможно уже только после разливки и затвердевания стали, когда оперативные управляющие воздействия на результаты плавки уже невозможны. Главная идея исследования состоит в том, чтобы обучить нейронную сеть на тех данных серийного производственного процесса, которые прямо или косвенно влияют на механические характеристики получаемых изделий, и, таким образом, учитывать структуру металла неявным образом. Отмечается, что данные, собранные в условиях действующего серийного производства, неизбежно содержат множество статистических выбросов, поэтому datasets подвергались тщательной очистке с помощью авторского алгоритма, что позволило создать пригодную для практического применения нейросетевую модель. С помощью разработанной нейросетевой модели методом замораживания в графическом виде построены зависимости ударной вязкости от режимов работы мартеновской печи, условий плавки и химического состава. Исследование нейросетевой модели позволило выявить некоторые закономерности моделируемого процесса, в частности, установить, что в условиях мартеновского производства химический состав играет не первостепенную роль в формировании прочностных характеристик изделий. В результате исследований нейросетевой модели получены рекомендации по повышению ударной вязкости производимых изделий и по выводу некоторых из них из брака за счет изменения условий плавки и химического состава металла.

© ПНИПУ

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

Мезенцев Алексей Сергеевич – аспирант кафедры прикладной математики и информатики, 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., Mezentsev A.S. On control the chemical composition of raw material and melting mode to ensure the required mechanical properties of steel products of mass production. *Applied Mathematics and Control Sciences*. 2023, no. 3, pp. 109–126. DOI: 10.15593/2499-9873/2023.3.08

MDPI and ACS Style: Yasnitsky, L.N.; Mezentsev, A. S. On control the chemical composition of raw material and melting mode to ensure the required mechanical properties of steel products of mass production. *Appl. Math. Control Sci.* **2023**, *3*, 109–126. <https://doi.org/10.15593/2499-9873/2023.3.08>

Chicago/Turabian Style: Yasnitsky, Leonid N., and Aleksey S. Mezentsev. 2023. “On control the chemical composition of raw material and melting mode to ensure the required mechanical properties of steel products of mass production”. *Appl. Math. Control Sci.* no. 3: 109–126. <https://doi.org/10.15593/2499-9873/2023.3.08>



APPLIED MATHEMATICS
AND CONTROL SCIENCES
№ 3, 2023
<https://ered.pstu.ru/index.php/amcs>



Article

DOI: 10.15593/2499-9873/2023.3.08

UDC 620.173.2:669.15-194



On control the chemical composition of raw material and melting mode to ensure the required mechanical properties of steel products of mass production

L.N. Yasnitsky^{1,2}, A.S. Mezentsev¹

¹ Perm State University, Perm, Russian Federation

² National Research University “Higher School of Economics” – branch in Perm, Perm, Russian Federation

ARTICLE INFO

Received: 28 August 2023
Approved: 20 September 2023
Accepted for publication:
02 October 2023

Funding

The study was carried out with financial support from the Russian Science Foundation grant no. 22-61-00096.

Conflicts of Interest

The author declares no conflict of interest.

Author Contributions

equalent.

Keywords:

chemical composition, raw material, impact strength, melting parameters, neural network, forecasting, steel castings, low-carbon steel, open-hearth steelmaking process.

ABSTRACT

A The goal of the work is to create a mathematical model suitable for operational control of the strength characteristics of the resulting steel product in the conditions of serial steelmaking. Existing approaches based on the results of testing prototypes obtained in laboratory conditions are not suitable for this purpose, since in the conditions of serial steelmaking, the strength characteristics of products, in addition to their chemical composition, are affected by the structure of the metal and many other melting conditions. Approaches in which the structure of the metal is taken into account when making predictions also cannot be used, because obtaining parameters of the metal structure is possible only after casting and solidification of the steel, when operational control actions on the results of melting are no longer possible. The main idea of the study is to train a neural network on those data from a serial production process that directly or indirectly affect the mechanical characteristics of the resulting products and, thus, take into account the structure of the metal in an implicit way. It is noted that data collected under the conditions of existing mass production inevitably contain many statistical outliers, so the datasets were thoroughly cleaned using the author's algorithm, which made it possible to create a neural network model suitable for practical use. Using the developed neural network model using the freezing method, the dependences of impact strength on the operating modes of the open-hearth furnace, melting conditions and chemical composition were plotted in graphical form. The study of the neural network model made it possible to identify some regularities of the simulated process, in particular, to establish that in the conditions of open-hearth production, the chemical composition does not play a primary role in the formation of the strength characteristics of products. As a result of studies of the neural network model, recommendations were obtained for increasing the impact strength of manufactured products and for removing some of them from reject by changing the melting conditions and the chemical composition of the metal.

© PNRPU

© Leonid N. Yasnitsky – Doctor of Technical Sciences, Professor, Professor of the Department of Applied Mathematics and Informatics, Professor of the Department of Informational Technologies in Business, e-mail: yasn@psu.ru, ORCID: 0000-0002-8212-3826.

Aleksey S. Mezentsev – Ph. D. student of the Department of Applied Mathematics and Informatics, 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

Попытки экспериментального исследования зависимостей механических свойств сталей от их химического состава и построения по результатам экспериментов математических моделей продолжают уже не одно десятилетие. Так, еще в 1994 г. N. Ohkubo et al. опубликовали статью [1] с сообщением о серии экспериментов с опытными образцами аустенитной нержавеющей стали с различным химическим составом, включающим углерод, кремний, марганец, фосфор, серу, никель, хром, молибден, медь, азот. В результате этих экспериментов авторами получены экспериментальные кривые зависимости твердости, предела текучести и предела прочности от размера зерен и процентного содержания указанных химических элементов. Экспериментальные кривые затем аппроксимированы линейными регрессионными уравнениями, которые затем использованы для анализа полученных результатов.

Рябинкина и Ткаченко [2] на основании выборки из 300 наблюдений, полученных в условиях производства листовой стали завода «Азовсталь» (Россия), построили регрессионные уравнения, отражающие зависимости предела текучести и предела прочности получаемых изделий от девяти компонент: углерода, марганца, кремния, серы, фосфора, хрома, никеля, меди, алюминия. Несмотря на низкое качество регрессионных моделей, авторы использовали их для выявления степени влияния каждого из химических элементов на результирующие показатели качества изделий, а также разработали практические рекомендации по содержанию углерода, кремния и марганца, которые обеспечивают наиболее высокое качество производимых изделий.

Mashekov et al. [3] выполнили серию экспериментов, состоящих в следующем. Из рельсов, изготовленных из стали, вырезались полосы длиной 300 мм и сечением 10×200 мм, которые подвергались прочностным испытаниям. В результате авторы получили линейные регрессионные зависимости временного сопротивления и предела текучести опытных образцов от процентного содержания углерода, марганца, кремния, хрома, меди, никеля. Авторы пришли к важному в отношении практики промышленного производства выводу, что регулирование механических свойств с помощью изменения химического состава возможно только путем установления достаточно узких пределов колебаний по содержанию углерода, марганца, кремния, хрома и ванадия.

Han et al. [4] на примере производства горячекатаных ребер (Hot-rolled ribbed bar) получили линейные регрессионные уравнения, выражающие зависимость предела прочности, предела текучести и относительного удлинения в зависимости от содержания углерода, марганца, хрома, никеля, ванадия. С помощью математической модели ими получен допустимый диапазон содержания хрома, который не понижает качество производимых изделий, что обеспечивает энергосбережение и улучшает экономические показатели производственного процесса.

Lino et al. [5] построили уравнение множественной линейной регрессии, которое позволяет быстро выполнять расчет содержания кальция в ковше, необходимого для перевода твердых включений в жидкое состояние перед заливкой в кристаллизатор машины непрерывного литья. Расчет производится в зависимости от количества содержащегося в расплаве алюминия, кремния, углерода и серы.

Sheyko et al. [6] выполнили следующую серию лабораторных экспериментов. Лабораторные отливки с различным содержанием легирующих элементов производились в индукционной печи, а затем выковывались на заготовки $10 \times 80 \times 120$ мм, у которых определялись механические характеристики: предел прочности на растяжение, предел текучести,

относительное удлинение, ударная вязкость. Обработав результаты экспериментов, авторы [6] получили регрессионные уравнения, отражающие зависимость механических свойств испытываемой низкоуглеродистой стали от содержания легирующих элементов: хрома, титана и ванадия. С помощью этих зависимостей они подобрали оптимальные сочетания легирующих элементов, обеспечивающие, по их мнению, наиболее благоприятные в эксплуатационном отношении механические свойства опытных образцов.

Однако В.А. Луценко с соавт. [7] выступили с критикой подобных подходов. Они отметили, что «существующие подходы к оптимизации химического состава стали, обеспечивающие необходимые механические свойства металлопродукции, как правило, базируются на статистических моделях состав – свойство» и не отражают физико-химические аспекты поведения многокомпонентного расплава на завершающих стадиях технологии получения готовой продукции». В связи с этим авторы [7] советуют пользоваться подходом, состоящем в следующем. Поскольку фазовые превращения являются следствием межатомного взаимодействия в многокомпонентном расплаве, предлагается пользоваться «сверткой» химического состава через параметр структурного состояния d . В физическом плане параметр d представляет собой среднестатистическое межъядерное расстояние между взаимодействующими атомами исследуемой стали. С использованием этого подхода авторы [7] изучили влияние легирующих элементов (хром, молибден, ванадий) на формирование механических свойств стали. Ими построены зависимости предела прочности и относительного удлинения от физико-химического критерия – структурного модельного параметра d . В результате показано, что повышение содержания хрома увеличивает предел прочности, а легирование молибденом и ванадием повышает пластичность.

В.В. Шкатов и В.И. Шкатов [8] разработали свои математические модели с учетом характеристик структуры получаемого металла, причем их модели разрабатывались с помощью регрессионной и нейросетевой технологий. В моделях [8] в качестве входных параметров использовались содержание марганца, кремния, фосфора, мышьяка и несвязанного азота, объемная доля перлита, степень сфероидизации перлита доли, средний размер зерна феррита, толщина полосы. Среднеквадратичная ошибка прогноза относительного удлинения, полученная при использовании регрессионной модели, составила 3,09 %, а нейронной сети – 1,91 %.

По нашему мнению, следует признать, что авторам работы [8] удалось создать довольно качественные модели, прогнозирующие механические свойства изделий из стали на основании их химического состава и параметров структуры металла. Поэтому полученный научный результат, несомненно, имеет важное теоретическое значение. Однако, если иметь в виду возможность практического применения построенных моделей для управления качеством изделий, получаемых в условиях действующего производства, то для этих целей данные модели вряд ли годятся. Дело в том, что если получение данных о химическом составе литейной массы в ковше в заводских условиях проблемы не составляет, то получение параметров структуры закристаллизовавшегося металла возможно уже только после разливки и затвердевания расплава, когда применять какие-либо управляющие воздействия уже поздно.

Подводя итог приведенному здесь краткому обзору литературных источников, можно разделить все упомянутые статьи на две группы:

1. Статьи, в которых результаты натуральных либо лабораторных экспериментов обобщены в виде простейших регрессионных уравнений или нейросетевых моделей, входными переменными которых являются только процентное содержание химического состава, а выходными переменными являются прочностные характеристики испытанного опытного образца или производимого изделия. Это работы [2–6].

2. Статьи, в которых входными переменными являются не только процентное содержание химического состава, но и характеристики структуры получаемого металла. Это работы [1; 7; 8].

Целью нашей исследовательской работы является создание математической модели, пригодной для оперативного управления прочностными характеристиками получаемого стального изделия в условиях действующего сталеплавильного производственного процесса.

По-видимому, подход, используемый для построения моделей первой группы, для этой цели не подходит, поскольку такие модели в принципе не могут обеспечить достаточно высокую точность прогнозирования ввиду того, что прочностные характеристики получаемых изделий зависят не только от химического состава, но и от структуры металла и других факторов.

Второй подход тоже нельзя считать приемлемым для достижения поставленной цели, поскольку получение параметров структуры металла возможно уже только после разлива и затвердевания стали, когда об оперативных управляющих воздействиях на результаты плавки говорить уже не приходится.

Выход из положения мы видим в том, чтобы воспользоваться свойством нейронных сетей принимать на вход любое количество параметров, без проявления нежелательного эффекта, называемого «проклятием размерности» [9]. Пользуясь этим свойством, на вход нейронной сети, помимо химического состава, мы предлагаем подавать любые параметры, которые, по каким-либо соображениям, могут оказывать влияние на качество отливок. Предлагается подавать на вход нейронной сети и такие параметры, действие которых представляется сомнительным, например, время года, направление ветра, температура воздуха, солнечная активность, день недели, номер смены и т.д. Предлагается подавать на вход нейронных сетей условия плавки и термической обработки, от которых зависит структура выплавляемого металла. Поэтому структура металла, о необходимости учета которой говорится в [7; 8], в нашей математической модели учитывается автоматически неявным образом.

1. Данные

Данные для обучения нейронной сети собирались в течение трех лет на одном из крупных металлургических предприятий, производящих стальные изделия мартеновским способом. Всего были собраны данные о 16 200 плавках. Данные о каждой плавке содержали 58 входных параметров, характеризующих химический состав металла, параметры плавки и режимы работы мартеновской печи, время проведения плавки, время года, метеорологические условия и пр. Выходным параметром являлась ударная вязкость KCV^{60} , замеренная на образце-свидетеле, изготовленном из металла, отлитого из того же ковша, что и само производимое заводом изделие.

Одновременно с ударной вязкостью на образце-свидетеле измерялись: предел текучести, временное сопротивление, относительное удлинение и относительное сужение. Однако прогнозирование величин этих прочностных характеристик интереса на представляло, поскольку на донном заводе их разброс был крайне мал, и все они, как правило, укладывались в допустимые пределы, т.е. производимые изделия по этим параметрам не отбраковывались.

Первоначально была предпринята попытка создания нейронной сети, на вход которой подавались одни только параметры, характеризующие химический состав стали: C, Mn, P, S, Si, Cr, Ni, Cu, Al. Однако создать нейронную сеть, прогнозирующую на основании этих

данных прочностные характеристики получаемых изделий со сколько-нибудь приемлемой точностью, нам не удалось.

Коэффициенты корреляции Пирсона между содержанием указанных химических элементов и измеренной ударной вязкостью, представленные в табл. 1, также свидетельствуют о практически полном отсутствии зависимости между этими величинами.

Таблица 1

Коэффициенты корреляции Пирсона между содержанием химических элементов и ударной вязкостью образцов-свидетелей

Элемент	C	Mn	P	S	Si	Cr	Ni	Cu	Al
Коэффициент Пирсона	-0,077	0,102	0,024	-0,143	0,058	0,013	-0,045	0,033	0,088

На основании этого был сделан вывод, что в реальных условиях выплавки стали мартеновским способом, помимо химического состава, на прочностные характеристики получаемых изделий значительное влияние оказывают факторы иной природы, которые тоже необходимо учитывать при создании математических моделей.

Обратим внимание, что этот вывод совпадает с мнением авторов публикаций [7; 8].

2. Предобработка данных

Дальнейшие работы проводились уже со всеми 58 входными параметрами.

Понимая, что статистические данные, собранные вручную в течение трех лет в условиях действующего металлургического предприятия, неизбежно содержат статистические выбросы, обусловленных неточностью и сбоями в показаниях измерительных приборов, ошибками работников завода при считывании и переносе данных на электронные носители и т.д., нами была проведена тщательная предобработка данных. Для поиска и исключения статистических выбросов был применен авторский алгоритм [10; 11]. В основе этого алгоритма лежит свойство некоторых специально спроектированных нейронных сетей плохо обучаться на примерах, являющихся статистическими выбросами. После применения процедуры обучения такой специально спроектированной нейронной сети более высокая погрешность обучения концентрируется на тех примерах, которые выпадают из общих закономерностей моделируемой предметной области, т.е. являются статистическими выбросами.

В нашем случае для поиска статистических выбросов использовалась специально спроектированная для этих целей нейронная сеть в виде персептрона с одним скрытым слоем сигмоидных нейронов, количество которых рассчитывалось по формулам, предложенным в [11], являющихся авторской модификацией следствия из теоремы Арнольда – Колмогорова – Хехт-Нильсена [9]:

$$N = N_{\min} + \xi(N_{\max} - N_{\min}), \quad (1)$$

$$N_{\min} = \frac{N_y Q}{(1 + \log_2(Q))(N_x + N_y)}, \quad (2)$$

$$N_{\max} = \frac{N_y}{N_x + N_y} \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + N_y. \quad (3)$$

В этих формулах N_x – количество нейронов входного слоя; N_y – количество нейронов выходного слоя; Q – количество элементов (строк) dataset, $\xi = 0,1$ – эмпирический коэффициент, предложенный в [11].

Всего было обнаружено и удалено приблизительно 600 выбросов.

Следует заметить, что примененная здесь авторская методика обнаружения и исключения статистических выбросов [10; 11] уже неоднократно использовалась нами при решении задач нейросетевого моделирования в самых разнообразных областях, таких как экономика [12], медицина [13], лингвистика [14], криминалистика [15], кинематография [16], промышленность, политология, социология, психология [9] и др. Каждый раз благодаря этой методике нам удавалось снижать погрешности нейросетевых моделей на 3–7 %. С помощью же применения других известных методик обнаружения и исключения выбросов статистической информации подобных положительных эффектов достичь не удавалось. Теперь мы видим, что наш алгоритм выявления и исключения статистических выбросов оказался эффективным и в случае создания нейросетевых моделей в области металлургии.

4. Создание нейросетевой модели

Оставшееся после исключения статистических выбросов множество было разделено на обучающее 3000 элементов, валидирующее 300 элементов и тестовое 300 элементов.

Для генерации, обучения, валидации и тестирования нейронных сетей мы использовали собственный программный инструмент «Нейросимулятор 5.1» [17], который хорошо зарекомендовал себя при выполнении многих наших проектов [9; 12–16]. С помощью этого программного инструмента были сгенерированы нейронные сети различной архитектуры, которые обучались методами обратного распространения ошибки, методом Левенберга – Марквардта, методом упругого обратного распространения и другими методами. В процессе валидации с помощью программного инструмента [17] была подобрана оптимальная архитектура нейронной сети. В окончательном виде нейронная сеть имела 27 входных нейронов, один выходной нейрон с линейной активационной функцией и два скрытых слоя с девятью и четырьмя нейронами с активационными функциями в форме гиперболического тангенса. Указанные гиперпараметры, включая число скрытых слоев, число нейронов на скрытых слоях, виды активационных функций, виды и параметры обучающих алгоритмов, подбирались вручную с помощью программного инструмента [17] и с привлечением многолетнего опыта нейросетевого моделирования [9; 18] авторов настоящей статьи.

Метрики качества обучения, валидации и тестирования нейронной сети приведены в табл. 2, в которой: MaxAE – максимальное отклонение прогнозируемой нейронной сетью ударной вязкости от фактической, измеренной в заводских испытаниях; MAE – средняя абсолютная ошибка; MAPE – средняя абсолютная ошибка в процентах; MSE – среднеквадратичная ошибка; RMSE – корень из среднеквадратичной ошибки; R^2 – коэффициент детерминации.

Таблица 2

Метрики качества обучения, валидации и тестирования нейронной сети

Metrix	Training	Validation	Testing
MaxAE	71,77	76,15	86,35
MAE	23,71	25,8	30,32
MAPE	9,97	11,65	12,02
MSE	985,3	1022,9	1260,7
RMSE	31,39	31,98	35,5
R^2	0,69	0,66	0,54

Для наглядности оценки качества созданной нейросетевой модели на рис. 1 в графической форме представлены результаты тестирования нейронной сети на фрагменте тестового множества из 50 примеров. Результаты приведены в виде сопоставления столбцов, соответствующих данным заводских замеров ударной вязкости (KCV^{60}) и нейросетевых прогнозов.

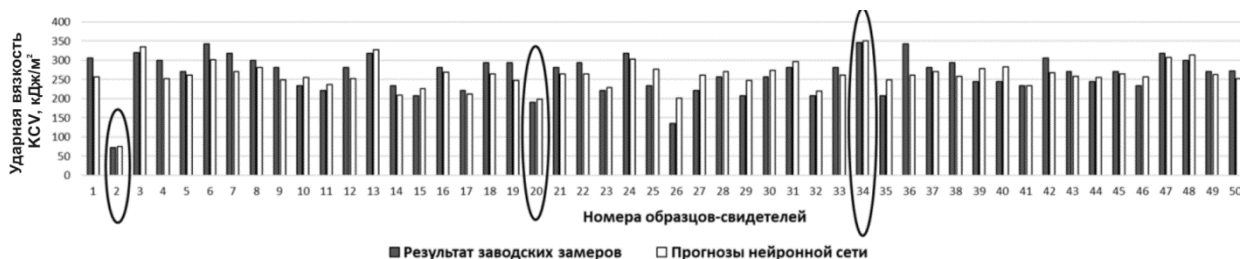


Рис. 1. Сопоставление результатов заводских замеров ударной вязкости с прогнозами нейросети на фрагменте тестового множества 50 примеров. Образцы-свидетели, номера которых отмечены овалами, выбраны для проведения виртуальных компьютерных экспериментов

Из результатов тестовых испытаний, приведенных на рис. 1 и в табл. 2, видно, что, хотя и с большой погрешностью, но нейронная сеть в целом правильно выполняет прогнозы заводских замеров ударной вязкости. Это значит, что она усвоила закономерности моделируемого процесса и является его математической моделью, или, как это принято сейчас называть, цифровым двойником реального процесса. Это означает, что в разных ситуациях созданная модель должна вести себя так же, как вел бы себя реальный металлургический процесс. Поэтому над математической моделью можно ставить виртуальные компьютерные эксперименты, позволяющие выявлять закономерности реального металлургического процесса.

4. Виртуальные компьютерные эксперименты и их обсуждение

Результаты виртуальных экспериментов представлены на рис. 2–8.

4.1. Эксперимент 1: оценка значимости входных параметров

Итак, созданную нейронную сеть можно использовать для выявления закономерностей моделируемого металлургического процесса. Так, следуя методике [9], поочередно исключая входные нейроны (либо поочередно подавая на них случайные числа, либо поочередно перемешивая подаваемые на них сигналы) и, наблюдая за погрешностью обучения (либо за погрешностью тестирования), можно понять, какие из входных параметров нейронной сети в наибольшей степени влияют на прогнозируемую ударную вязкость. Чем выше оказывается погрешность нейросети при исключении какого-либо входного нейрона, тем значимее входной параметр, соответствующий исключенному нейрону. Гистограмма распределения значимости входных параметров, полученная таким способом и приведенная к интервалу от 0 до 1, изображена на рис. 2.

Как видно из результатов, представленных на рис. 2, наиболее значимыми параметрами, в наибольшей степени влияющими на ударную вязкость изделий, являются «Продолжительность кипения расплава в печи», «Содержание фосфора в ковше», «Скорость окисления углерода» и т.д. Наименее значимыми являются «Содержание алюминия в ковше», «Основность шлака», «Содержание углерода в ковше» и т.д.

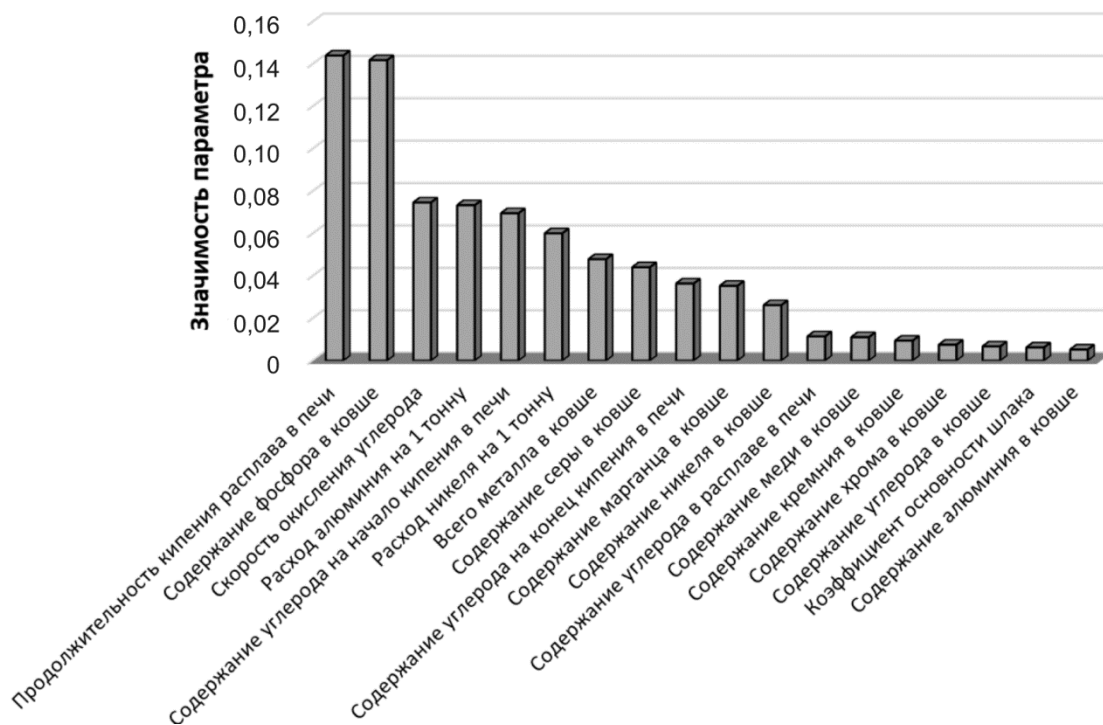


Рис. 2. Значимость входных параметров нейронной сети по отношению к ударной вязкости KCV

Анализируя данные рис. 2, можно также заключить, что, помимо химического состава, на величину ударной вязкости изделий весьма существенное влияние оказывают и другие параметры выплавки стали. Именно этим можно объяснить описанные выше первоначальные неудачи создания нейронной сети, предназначенной для прогнозирования прочностных характеристик отливаемых изделий на основании одних только данных о их химическом составе.

4.2. Эксперимент 2: влияние параметра «Продолжительность кипения расплава в печи»

Для проведения виртуальных компьютерных экспериментов выберем образцы-свидетели, значения ударной вязкости которых на рис. 1 выделены овалами. Это образец № 2, имеющий ударную вязкость $75,56 \text{ кДж/м}^2$, образец № 20, имеющий ударную вязкость $197,94 \text{ кДж/м}^2$ и образец № 34, имеющий ударную вязкость $350,33 \text{ кДж/м}^2$.

Образцы выбраны так, что образец № 2 имеет наименьшую, зафиксированную во всей выборке ударную вязкость, образец № 34 имеет максимальную по выборке ударную вязкость. Ударная вязкость образца № 20 имеет приблизительно среднее значение между двумя этими крайностями. Изделия, соответствующие образцам-свидетелям № 2 и № 20, считаются браком, поскольку их ударная вязкость меньше предельно допустимой 200 кДж/см^2 .

Химический состав и параметры плавки образцов-свидетелей, выбранных для виртуальных экспериментов, приведены в табл. 3.

Виртуальные компьютерные эксперименты над выбранными образцами-свидетелями выполнены методом замораживания [9]. Суть этого метода заключается в следующем. На вход нейронной сети подаются параметры какого-либо образца-свидетеля из табл. 3. Затем интересующий нас параметр, влияние которого на результат плавки требуется изучить, подвергается постепенному изменению, например, он с определенным шагом увеличивается от своего минимального значения до максимального. Одновременно с этим на

каждом шаге снимаются результаты вычислений нейронной сети, которые изображаются графически в виде зависимости прогнозируемой ударной вязкости от изменяющегося входного параметра. Остальные входные параметры нейронной сети во время эксперимента «замораживаются», т.е. не меняются.

Таблица 3

Параметры химического состава и условий плавки образцов-свидетелей, выбранных для проведения виртуальных компьютерных экспериментов

Номер образца-свидетеля	Продолжительность кипения расплава в печи, мин	Содержание фосфора в ковше, %	Скорость окисления углерода, %/ч	Расход алюминия на 1 тонну, кг	Содержание углерода на начало кипения в печи, %	Расход никеля на 1 тонну, кг	Всего металла в ковше, т	Содержание серы в ковше, %	Содержание углерода на конец кипения в печи, %	Содержание марганца в ковше, %	Содержание никеля в ковше, %	Содержание углерода в расплаве в печи, %	Содержание меди в ковше, %	Содержание кремния в ковше, %	Содержание хрома в ковше, %	Содержание углерода в ковше, %	Коэффициент основности шлака	Содержание алюминия в ковше, %	Ударная вязкость KCV, кДж/м ²
2	45	0,016	0,573	1,142	0,60	0,51	28,9	0,016	0,17	1,28	0,49	1,13	0,09	0,37	0,22	0,21	1,47	0,047	75,56
20	50	0,017	0,456	1,440	0,57	0,14	24,3	0,022	0,19	1,23	0,18	1,25	0,09	0,25	0,15	0,21	1,65	0,031	197,94
34	70	0,013	0,471	1,304	0,72	0,11	25,3	0,014	0,17	1,41	0,18	1,25	0,08	0,42	0,14	0,22	1,66	0,052	350,33

На рис. 3 приведены полученные таким способом результаты исследования зависимостей ударной вязкости всех трех отобранных для экспериментов образцов от параметра плавки «Продолжительность кипения расплава в печи».

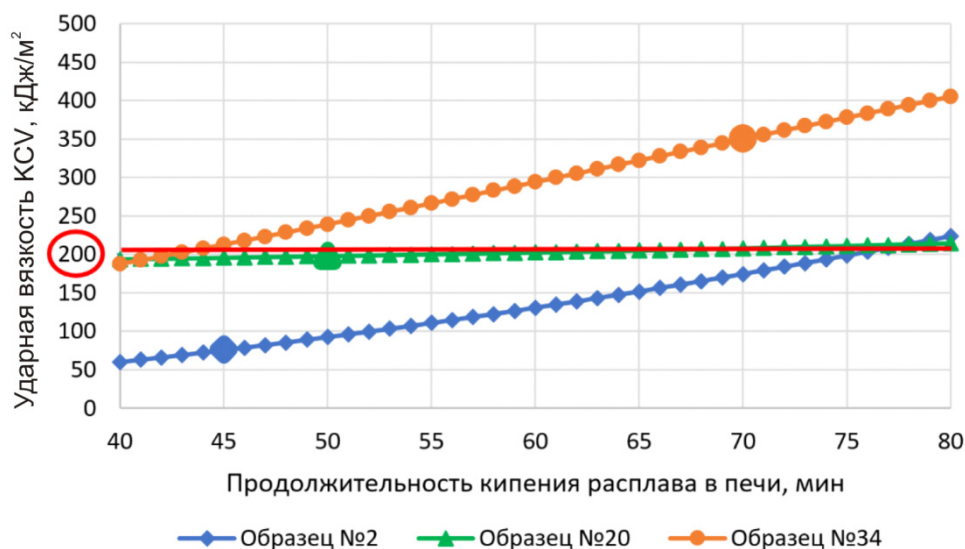


Рис. 3. Зависимость прогнозируемой ударной вязкости отобранных для экспериментов образцов-свидетелей от параметра «Продолжительность кипения расплава в печи». Маркерами увеличенных размеров отмечены реальные значения продолжительности кипения, при которых производились плавки, и им соответствующие реальные значения ударной вязкости

Как видно из рис. 3, ударная вязкость 2-го и 34-го образцов-свидетелей линейно увеличивается с возрастанием параметра «Продолжительность кипения расплава в печи». Значение же ударной вязкости 20-го образца мало зависит от этого параметра.

Пользуясь данными рис. 3, можно сделать выводы, имеющие практическое значение для конкретного производственного процесса:

1. Путем увеличения продолжительность кипения расплава в печи при изготовлении 2-го образца-свидетеля с 45 до 76 мин, можно было бы увеличить ударную вязкость этого образца с 75,56 до 203,39 кДж/м², т.е. превысить допустимый предел 200 кДж/м², выше которого изделие, соответствующее этому образцу-свидетелю, уже не считается браком.

2. Аналогично путем увеличения продолжительности кипения расплава в печи при изготовлении изделия, соответствующего 20-му образцу-свидетелю, с 50 до 55 мин, можно было бы повысить ударную вязкость с 197,94 до 200,16 кДж/м² и, таким образом, вывести изделие из брака.

Следует заметить, что в этом и во всех последующих компьютерных экспериментах кроме ударной вязкости прогнозировались также значения других прочностных характеристик: предел текучести, временное сопротивление, относительное удлинение и относительное сужение. Однако результаты прогнозирования значений этих характеристик интереса не представляли, поскольку все они в пределах области исследуемых входных параметров модели укладывался в допустимые пределы, т.е. брака по этим характеристикам практически не наблюдалось.

4.3. Эксперимент 3: влияние параметра «Содержание фосфора в ковше»

На рис. 4 изображена зависимость ударной вязкости от второго по значимости параметра «Содержание фосфора в ковше». Все остальные параметры во время виртуального эксперимента сохранены неизменными, соответствующими значениям, приведенным в табл. 3.

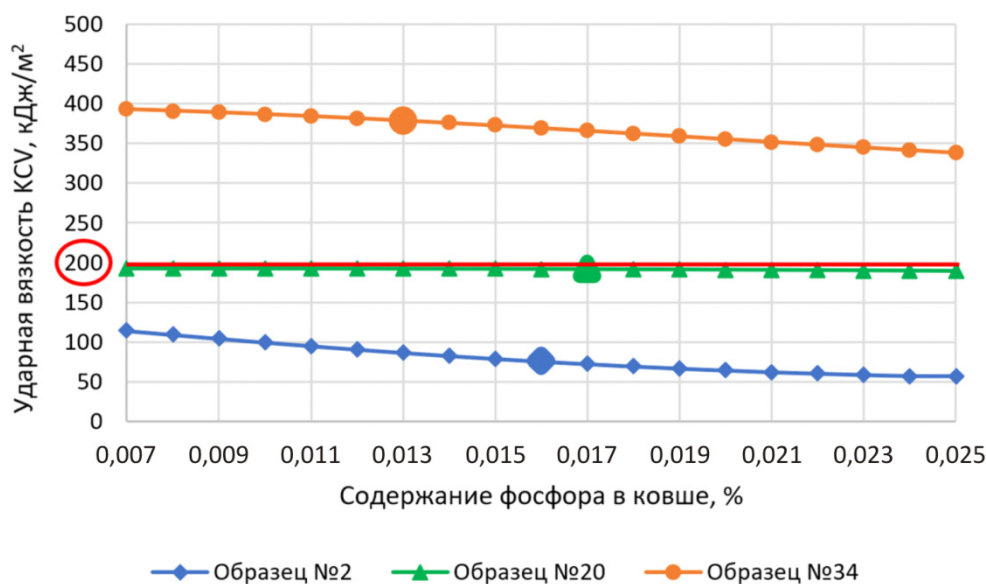


Рис. 4. Зависимость прогнозируемой ударной вязкости образцов-свидетелей от параметра «Содержание фосфора в ковше»

На основании этих прогнозных результатов можно заключить, что влияние содержания фосфора оказывает весьма слабое влияние на ударную вязкость отобранных для экспериментов образцов-свидетелей и что путем изменения содержания фосфора в исследуемых пределах невозможно вывести из брака изделия, которые соответствуют образцам-свидетелям № 2 и № 20.

4.4. Эксперимент 4: влияние параметра «Скорость окисления углерода»

На рис. 5 изображена зависимость прогнозируемой ударной вязкости изделий от следующего по значимости параметра «Скорость окисления углерода». Значения всех остальных параметров во время виртуального эксперимента сохранены неизменными, указанными в табл. 3.

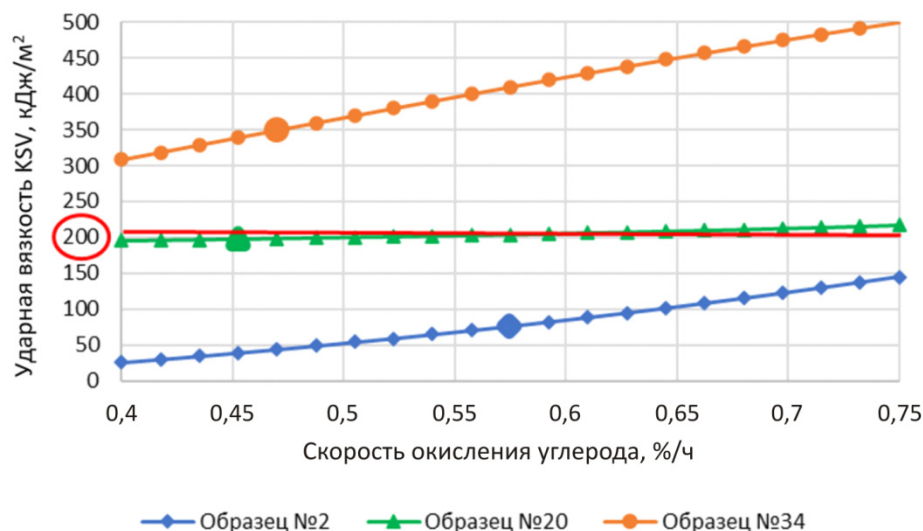


Рис. 5. Зависимость прогнозируемой ударной вязкости образцов-свидетелей от параметра «Скорость окисления углерода»

Как видно из рис. 5, ударная вязкость всех трех образцов-свидетелей с возрастанием параметра «Скорость окисления углерода» увеличивается по линейному закону.

Повышение скорости окисления углерода с 0,456 до 0,5 %/ч и выше приводит к увеличению прогнозируемой ударной вязкости 20-го образца-свидетеля с 197,94 до 200,3 кДж/м² и выше, т.е., позволяет виртуально вывести изделие, соответствующее этому образцу-свидетелю, из брака.

Изделие же, соответствующее образцу-свидетелю № 2, как видно из результатов, представленных на рис. 5, не может быть выведено из брака за счет увеличения скорости окисления углерода.

Интересно заметить, что при увеличении скорости окисления углерода до 0,75 %/ч прогнозная ударная вязкость образца-свидетеля № 34 достигает рекордно высокого значения 500,06 кДж/м².

4.5. Эксперимент 5: влияние параметра «Содержание марганца в ковше»

На рис. 6 изображена зависимость ударной вязкости образцов-свидетелей от параметра «Содержание марганца в ковше». Все остальные параметры во время виртуального эксперимента сохранены неизменными, указанными в табл. 3.

Как следует из результатов, представленных на рис. 6, зависимость ударной вязкости от содержания марганца имеет нелинейный характер. Причем, если в случае с образцами № 20 и № 34 с увеличением содержания марганца ударная вязкость имеет тенденцию к повышению, то на кривой, соответствующей образцу № 2, имеются участки как возрастания, так и убывания.

Из рис. 6 также видно, что изделие, соответствующее образцу-свидетелю № 2, можно было бы вывести из брака, если бы содержание марганца в ковше при его выплавке было меньше, чем 1,10 %.

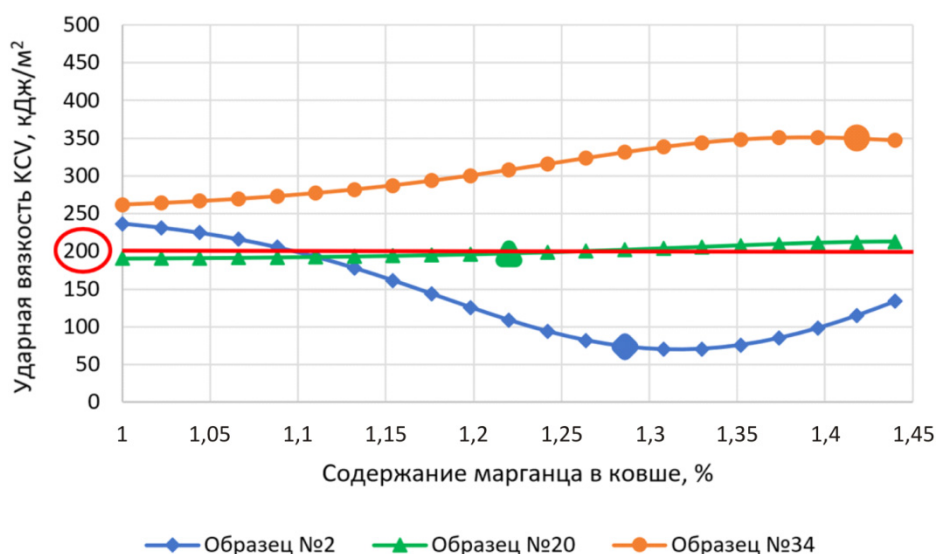


Рис. 6. Зависимость прогнозируемой ударной вязкости образцов-свидетелей от параметра «Содержание марганца в ковше»

Изделие, соответствующее образцу-свидетелю № 20, можно было вывести из брака, если бы при его выплавке содержание марганца в ковше было больше, чем 1,25 %.

4.6. Эксперимент 6: влияние параметра «Содержание никеля в ковше»

На рис. 7 изображена зависимость ударной вязкости отобранных для экспериментов образцов-свидетелей от параметра «Содержание никеля в ковше». Все остальные параметры во время экспериментов сохранены неизменными, указанными в табл. 3.

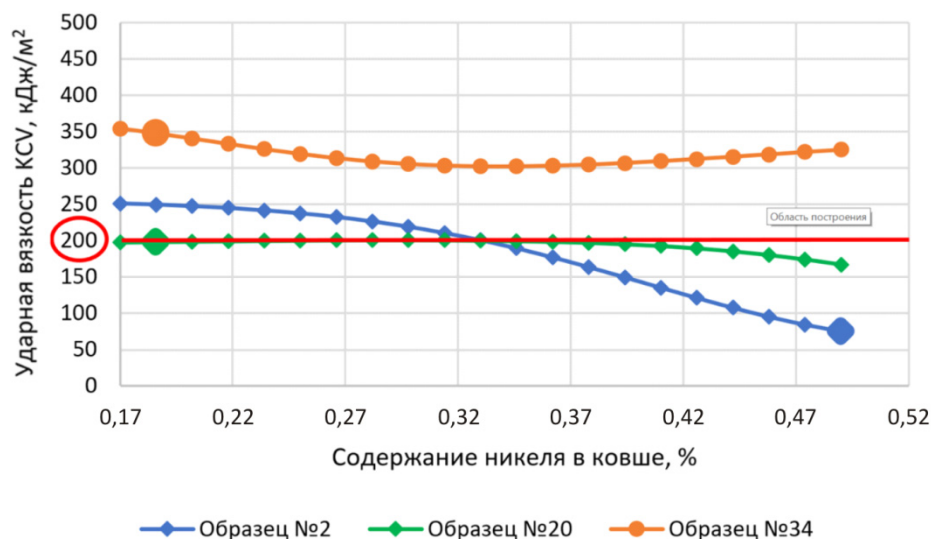


Рис. 7. Зависимость прогнозируемой ударной вязкости образцов-свидетелей от параметра «Содержание никеля в ковше»

Как следует из результатов рис. 7, виртуальное снижение содержания никеля в ковше с 0,49 до 0,33 % и ниже позволило бы вывести из брака изделие, соответствующее образцу-свидетелю № 2.

Изделие, соответствующее образцу-свидетелю № 20, не удастся вывести из брака путем изменения содержания никеля в исследуемых пределах.

4.7. Эксперимент 7: совместное влияние параметров

Из трех образцов-свидетелей, над которыми выполнялись виртуальные эксперименты, самым проблематичным является образец № 2, ударная вязкость которого составила всего 75,56 кДж/м², что значительно меньше порогового значения 200 кДж/м², ниже которого изделие считается браком. В виртуальных компьютерных экспериментах п. 4.2–4.6 была обнаружена возможность увеличения ударной вязкости этого образца за счет поочередного изменения пяти параметров: «Продолжительность кипения расплава в печи», «Содержание фосфора в ковше», «Скорость окисления углерода», «Содержание марганца в ковше», «Содержание никеля в ковше». В частности, было установлено, что:

- увеличение параметра «Продолжительность кипения расплава в печи» с 45 до 76 мин приведет к увеличению ударной вязкости изделия № 2 с 75,56 до 203,39 кДж/м²;
- уменьшение параметра «Содержание фосфора в ковше» с 0,016 до 0,007 % приведет к увеличению ударной вязкости изделия № 2 с 75,5 до 114 кДж/м²;
- увеличение параметра «Скорость окисления углерода» с 0,57 до 0,75 %/ч приведет к увеличению ударной вязкости изделия № 2 с 75,5 до 145 кДж/м²;
- уменьшение параметра «Содержание марганца в ковше» с 1,28 до 1,0 % приведет к увеличению ударной вязкости изделия № 2 с 75,5 до 236 кДж/м²;
- уменьшение параметра «Содержание никеля в ковше» с 0,49 до 0,17 % приведет к увеличению ударной вязкости изделия № 2 с 75,5 до 250 кДж/м².

Представляет практический интерес получить прогноз ударной вязкости изделия № 2 при одновременном изменении всех пяти параметров в исследованных выше пределах. Результаты такого виртуального эксперимента приведены на рис. 8.

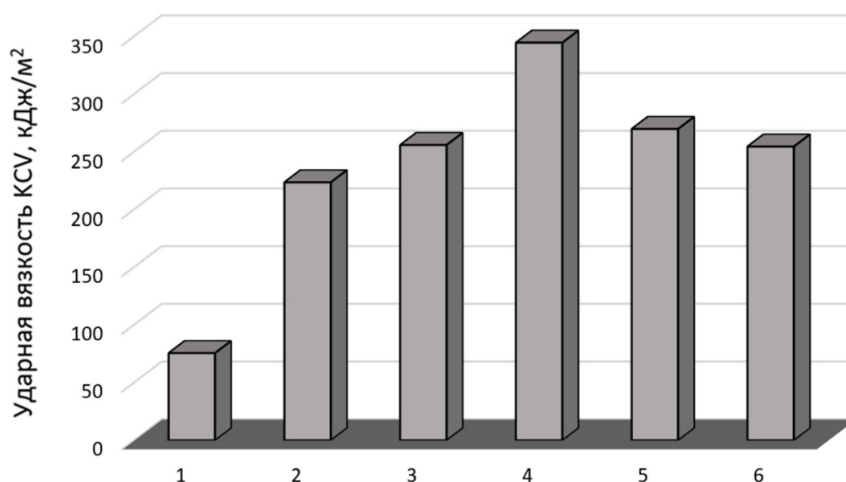


Рис. 8. Прогноз ударной вязкости образца-свидетеля № 2 при последовательном изменении параметров в исследованных выше пределах: 1 – исходное состояние; 2 – увеличили параметр «Продолжительность кипения расплава в печи» с 45 до 76 мин; 3 – дополнительно уменьшили параметр «Содержание фосфора в ковше» с 0,016 до 0,007 %; 4 – дополнительно увеличили параметр «Скорость окисления углерода» с 0,57 до 0,75 %/ч; 5 – дополнительно убавили параметр «Содержание марганца в ковше» с 1,28 до 1,0 %; 6 – дополнительно убавили «Содержание никеля в ковше» с 0,49 до 0,17 %

Как видно из рис. 8, одновременное увеличение параметра «Продолжительность кипения расплава в печи», уменьшение параметра «Содержание фосфора в ковше» и увеличение параметра «Скорость окисления углерода» позволило увеличить показатель ударной вязкости образца-свидетеля № 2 с 75,5 до 344,5 кДж/м², т.е. в 4,5 раза.

Логично было бы ожидать, что последующее уменьшение параметров «Содержание марганца в ковше» и «Содержание никеля в ковше» до указанных выше значений приведет к дальнейшему увеличению ударной вязкости образца-свидетеля, как это было зафиксировано на рис. 6 и 7. Однако, как видно из рис. 8, при уменьшении значений этих параметров в указанных пределах ударная вязкость, наоборот, уменьшилась.

Этот результат нейросетевого моделирования свидетельствует о существовании сложных нелинейных зависимостей между параметрами моделируемого процесса. Поэтому рекомендации по увеличению ударной вязкости изделия, разработанные для одного набора параметров плавки, могут не годиться для плавки с другими комплексами параметров.

Отсюда следует важный практический вывод: заниматься подбором оптимального химического состава и параметров сталеплавильного процесса следует в каждом конкретном случае в зависимости от конкретных условий, каждый раз пользуясь математическими моделями, разработанными для конкретных металлургических процессов, например, по предлагаемой в настоящей статье методике.

Продолжая обсуждения результатов вычислительных экспериментов, представленных на рис. 2–8, следует заметить, что кривые, изображенные на этих рисунках, представляют собой результаты экспериментов над нейросетевой моделью, являющейся цифровым двойником изучаемого явления. Они отражают закономерности этого явления, извлеченные нейронной сетью из статистических данных, собранных с реального металлургического процесса. Поэтому, как видно из рисунков, эти закономерности не всегда совпадают с теоретическими положениями теории металлургических процессов, которая сформировалась на основе упрощенных экспериментов, выполненных в идеальных лабораторных условиях, отличающихся от реального производства и не учитывающих множество его нюансов.

Также следует заметить, что созданный цифровой двойник и все полученные с помощью него закономерности справедливы только для одного конкретного металлургического процесса, для которого он был разработан.

Заключение

Создана нейросетевая математическая модель, пригодная для оперативного управления прочностными характеристиками получаемого изделия в условиях серийного сталеплавильного производства. Показано, что в реальных условиях выплавки стали мартеновским способом, помимо химического состава, на прочностные характеристики получаемых изделий значительное влияние оказывают режимы работы печи и параметры плавки. С помощью разработанной нейросетевой математической модели выявлены некоторые закономерности сталеплавильного процесса, и на их основе получены практические рекомендации по повышению ударной вязкости производимых изделий и по выводу некоторых изделий из брака за счет изменения условий плавки и химического состава металла. Выявленные с помощью нейросетевой модели зависимости представляют собой результаты экспериментов над нейросетевой моделью, являющейся цифровым двойником изучаемого явления. Они извлечены нейронной сетью из статистических данных, собранных с реального металлургического процесса. Поэтому эти закономерности не всегда совпадают с теоретическими положениями теории металлургических процессов, которая сформировалась на основе упрощенных экспериментов, выполненных в идеальных лабораторных условиях, отличающихся от реального производства и не учитывающих множества его нюансов. Виртуальные компьютерные эксперименты, проведенные над нейросетевой математической моделью, показали наличие

сложных нелинейных зависимостей между параметрами сталеплавильного процесса, включая химический состав отливок. Поэтому рекомендации по оперативному управлению прочностными характеристиками получаемых изделий, разработанные для конкретного завода, конкретного цеха и конкретного набора параметров плавки, могут не годиться для других заводов, цехов и параметров плавки. Отсюда следует, что заниматься подбором оптимального химического состава и параметров сталеплавильного процесса следует в каждом конкретном случае в зависимости от конкретных условий, каждый раз разрабатывая математические модели, подобные предлагаемой в настоящей статье.

Список литературы

1. Effect of Alloying Elements on the Mechanical Properties of the Stable Austenitic Stainless Steel / N. Ohkubo, K. Miyakusu Y. Uemats, H. Kimura / *ISIJ International*. – 1994. – Vol. 34, № 9. – P. 764–772.
2. Рябинкина М.А., Ткаченко К.И. Математические модели зависимости механических свойств листовой стали категории А537/А537М от плавочного химического состава // *Вісник приазовського державного технічного університету*. – 2004. – № 14. – С. 1–5.
3. Mashekov S.A., Absadykov B.N., Alimkulov M.M. The influence of chemical composition of steel 76f on the quality of rails // *Modern problems of science and education*. – 2015. – № 2 (part 2). – P. 32–32.
4. The Influence of Chemical Element on Properties of Deformed Steel Bar / R. Han, M. Hu, Q. Pei, D. Gong, Y. Song / *Open Journal of Statistics*. – 2016. – Vol. 6, № 6. – P. 1174–1180. DOI 10.4236/ojs.2016.66095
5. Influence of the chemical composition on steel casting performance / R.E. Lino, Â.M.F. Marins, L.A. Marchi, J.A. Mendes, L.V. Penna, J.G.C. Neto, J.H.P. Caldeira, A.L. Vasconcellos da Costa e Silva / *Journal of Materials Research and Technology*. – 2017. – Vol. 6, № 1. – P. 50–56.
6. Development of rational chemical composition of special steel with increased mechanical and performance characteristics / S. Sheyko, Y. Beloko, A. Kripak, V. Shalomoev, V. Tsyganov, E. Kulabneva / *Journal of Chemical Technology and Metallurgy*. – 2023. – Vol. 58, № 4. – P. 798–805.
7. Влияние химического состава на механические свойства легированной стали / В.А. Луценко, Т.Н. Голубенко, О.В. Луценко, А.С. Козачек, Н.А. Глазунова / *Литье и металлургия*. – 2018. – № 1 (90). – С. 120–123.
8. Шкатов В.В., Шкатов В.В. Применение нейронных сетей для прогнозирования характеристик пластичности горячекатаных листовых сталей // *Современные материалы, техника и технологии*. – 2018. – № 3 (18). – С. 42–46.
9. Ясницкий Л.Н. Интеллектуальные системы. – М: Лаборатория знаний. – 221 с.
10. Черепанов Ф.М., Ясницкий Л.Н. Нейросетевой фильтр для исключения выбросов в статистической информации // *Вестник Пермского университета. Математика. Механика. Информатика*. – 2008. – № 4. – С. 151–155.
11. 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, № 2. – P. 1814–1819. DOI: 10.30534/ijatcse/2020/139922020
12. Yasnitsky L.N., Yasnitsky V.L., Alekseev A.O. The Complex Neural Network Model for Mass Appraisal and Scenario Forecasting of the Urban Real Estate Market Value That Adapts Itself to Space and Time // *Complexity*. – 2021. – P. 5392170. DOI: 10.1155/2021/5392170

13. Capabilities of neural network technologies for extracting new medical knowledge and enhancing precise decision making for patients / L.N. Yasnitsky, A.A. Dumler, F.M. Cherepanov, V.L. Yasnitsky / *Expert Review of Precision Medicine and Drug Development*. – 2021. – Vol. 7, № 8. – P. 1–9. DOI: 10.1080/23808993.2021.1993595
14. Isaeva E., Yasnitsky L. Neurostimulation for Finding Metaphor in erminology // 2022 Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus 2022): proceedings, Saint Petersburg, Russia 11–13 Janary 2020. – 2020. – P. 307–311. DOI: 10.1109/ElConRus54750.2022.9755757
15. The use of artificial intelligence methods in the analysis of serial killers' personal characteristics / L.N. Yasnitsky, S.V. Vauleva, D.N. Safonova, F.M. Cherepanov / *Criminology Journal of Baikal National University of Economics and Law*. – 2015. – Vol. 9, № 3. – P. 423–430. DOI: 10.17150/1996-7756.2015.9(3).423-430
16. Yasnitsky L.N., Mitrofanov I.A., Immis M.V. Intelligent System for Prediction Box Office of the Film // *Lecture Notes in Networks and Systems*. – 2020. – Vol. 78. – P. 18–25. DOI: 10.1007/978-3-030-22493-6_3
17. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0 // Свидетельство Роспатент о государственной регистрации программы для ЭВМ № 2014618208 от 12.07.2014 г. (Россия).
18. Ясницкий Л.Н. Развитие научной школы искусственного интеллекта в пермских университетах: история и научный приоритет (обзорная статья) // *Прикладная математика и вопросы управления*. – 2018. – № 4. – P. 99–130. DOI: 10.15593/2499-9873/2018.4.06
19. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // *Нейрокомпьютеры: разработка, применение*. – 2015. – № 5. – С. 48–56.

References

1. Ohkubo N., Miyakusu R., Uematsu Y., Kimura H. Effect of Alloying Elements on the Mechanical Properties of the Stable Austenitic Stainless Steel. *ISIJ International*, 1994, vol. 34, no 9, pp. 764-772.
2. Ryabinkina M.A., Tkachenko K.I. Matematicheskie modeli zavisimosti mekhanicheckih svoystv listovoj stali kategorii A537/A537M ot plavochnogo himicheskogo sostava [Mathematical models of the dependence of the mechanical properties of sheet steel of category A537/A537M on the melting chemical composition]. *Visnik priazovskogo derzhavnogo tekhnicheskogo universitetu*, 2004, no. 14, pp. 1-5.
3. Mashekov S.A., Absadykov B.N., Alimkulov M.M. The influence of chemical composition of steel 76f on the quality of rails. *Modern problems of science and education*, 2015, no. 2 (part 2), pp. 32-32.
4. Han R, Hu M., Pei Q., Gong D., Song Y. The Influence of Chemical Element on Properties of Deformed Steel Bar. *Open Journal of Statistics*, 2016, vol. 6, no. 6, pp. 1174-1180. DOI:10.4236/ojs.2016.66095.
5. Lino R. E., Marins Â. M. F., Marchi L. A., Mendes J. A., Penna L. V., Neto J. G. C., Caldeira J. H. P., Vasconcellos da Costa e Silva A. L. Influence of the chemical composition on steel casting performance. *Journal of Materials Research and Technology*, 2017, vol. 6, no. 1, pp. 50-56.
6. Sheyko S., Beloko Y., Kripak A., Shalomeev V., Tsyganov V., Kulabneva E. Development of rational chemical composition of special steel with increased mechanical and performance characteristics. *Journal of Chemical Technology and Metallurgy*, 2023, vol. 58, no. 4, pp. 798-805.

7. Lucenko V.A., Golubenko T.N., Lucenko O.V., Kozachek A.S., Glazunova N.A. Vliyanie himicheskogo sostava na mekhanicheskie svoystva legirovannoy stali [The influence of chemical composition on the mechanical properties of alloy steel]. *Lit'e i metallurgiya*, 2018, no. 1 (90), pp.120-123.
8. SHkatov V.V., SHkatov V.V. Primenenie nejronnyh setej dlya prognozirovaniya ha-rakteristik plastichnosti goryachekatanyh listovyh stalej [Application of neural networks to predict the ductility characteristics of hot-rolled sheet steels]. *Sovremennyye materialy, tekhnika i tekhnologii*, 2018, no. 3 (18), pp. 42-46.
9. YAsnickij L.N. Intellekual'nyae sistemy [Intelligent systems], Moscow, Laboratoriya znaniy, 221p.
10. CHerepanov F.M., YAsnickij L.N. Nejrosetevoj fil'tr dlya isklyucheniya vybrosov v statisticheskoy informacii [Neural network filter to eliminate outliers in statistical information]. *Vestnik Permskogo universiteta. Matematika. Mekhanika. Informatika*, 2008, no. 4, pp. 151-155.
11. 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
12. Yasnitsky, L.N., Yasnitsky, V.L., Alekseev, A.O. The Complex Neural Network Model for Mass Appraisal and Scenario Forecasting of the Urban Real Estate Market Value That Adapts Itself to Space and Time. *Complexity*, 2021, 5392170. DOI: 10.1155/2021/5392170.
13. Yasnitsky L.N., Dumler A.A., Cherepanov F.M., Yasnitsky V.L. Capabilities of neural network technologies for extracting new medical knowledge and enhancing precise decision making for patients. *Expert Review of Precision Medicine and Drug Development*, 2021, vol. 7, no. 8, pp. 1-9. DOI: 10.1080/23808993.2021.1993595.
14. Isaeva E., Yasnitsky L.N. Neurostimulation for Finding Metaphor in erminology. *2022 Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus 2022)*, 2020, pp. 307-311. DOI: 10.1109/ElConRus54750.2022.9755757
15. Yasnitsky L.N., Vauleva S.V., Safonova D.N., Cherepanov F.M. The use of artificial intelligence methods in the analysis of serial killers' personal characteristics. *Criminology Journal of Baikal National University of Economics and Law*, 2015, vol. 9, no. 3, pp. 423–430. DOI: 10.17150/1996-7756.2015.9(3).423-430.
16. Yasnitsky L.N., Mitrofanov I.A., Immis M.V. Intelligent System for Prediction Box Of- fice of the Film. *Lecture Notes in Networks and Systems*, 2020, vol. 78, pp. 18–25. DOI: 10.1007/978-3-030-22493-6_3
17. CHerepanov F.M., YAsnickij L.N. Nejrosimulyator 5.0 [Neurosimulator 5.0.]. *Svide- tel'stvo Rospatent o gosudarstvennoj registracii programmy dlya EVM*, no. 2014618208, 12.07.2014 (Rossiya).
18. YAsnickij L.N. Razvitie nauchnoj shkoly iskusstvennogo intellekta v permskih universitetah: istoriya i nauchnyj prioritet (obzornaya stat'ya) [Development of the scientific school of artificial intelligence at Perm universities: history and scientific priority (review arti- cle)] // *Applied Mathematics and Control Sciences*, 2018, no. 4, pp. 99-130. DOI:10.15593/2499-9873/2018.4.06.
19. YAsnickij L.N. Nejronnye seti – instrument dlya polucheniya novyh znaniy: uspe-hi, problemy, perspektivy [Neural networks are a tool for obtaining new knowledge: successes, prob- lems, prospects]. *Nejrokompyutery: razrabotka, primenenie*, 2015, no. 5, pp. 48-56.