

УДК 621.771.07:004.94

DOI 10.24412/2413-7383-2025-3-38-65-77

В. С. Солод, В. М. Зуев, С. Б. Иванова

Федеральное государственное бюджетное научное учреждение  
«Институт проблем искусственного интеллекта», г. Донецк  
283048, г. Донецк, ул. Артема, 118 б

## ОЦЕНКА ВОЗМОЖНОСТЕЙ ИСПОЛЬЗОВАНИЯ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЛЯ ОПТИМИЗАЦИИ ТЕХНОЛОГИИ ОХЛАЖДЕНИЯ АРМАТУРНОЙ СТАЛИ

V. S. Solod, V. M. Zuyev, S. B. Ivanova

Federal State Budgetary Scientific Institution «Institute of Artificial Intelligence Problems»  
283048, Donetsk, Artema str, 118-b

## EVALUATION OF THE POSSIBILITIES OF USING NEURAL NETWORK MODELS TO OPTIMIZING REINFORCING STEEL COOLING TECHNOLOGY

Целью работы является оценка возможностей применения простых искусственных нейронных сетей (ИНС) для моделирования сложных металлургических производственных процессов. Рассмотрено применения ИНС для описания технологии ускоренного охлаждения (УО) арматурного проката в потоке прокатного стана, предназначенной для формирования заданного уровня механических свойств готового проката. На основе анализа литературы определен набор входных и целевых параметров, архитектура ИНС. Разработан набор данных для обучения ИНС, полученный расчетом по математической модели авторов. Процесс обучения осуществляли при переменном количестве нейронов и целевых параметров. Проведен анализ результатов оценки моделей. Предложено направление дальнейших исследований.

**Ключевые слова:** арматурный профиль, ускоренное охлаждение, перцептрон, сетевая модель

The aim of the work is to evaluate the possibilities of using simple artificial neural networks (ANN) for modeling complex metallurgical production processes. The application of ANN for describing the technology of accelerated cooling (AC) of reinforcing bars in the rolling mill flow, designed to form a specified level of mechanical properties of finished rolled products, is considered. Based on the literature analysis, a set of input and target parameters, the ANN architecture are determined. A data set for training the ANN, obtained by calculating according to the mathematical model of the authors, is developed. The training process was carried out with a variable number of neurons and target parameters. The analysis of the results of model evaluation is carried out. The direction of further research is proposed.

**Keywords:** reinforcement profile, accelerated cooling, perceptron, network model

## Введение

Современной тенденцией на рынке горячекатаного проката является расширение его номенклатуры при одновременном ужесточении требований к качеству, в том числе по структуре и механическим свойствам. Этим требованиям возможно удовлетворить путём применения комплексного подхода к решению задач определения влияния химического состава стали и основных технологических параметров производственного процесса на конечные показатели качества [1].

Однако здесь исследователи сталкиваются со значительными трудностями, вызванными наличием сложной связи между параметрами процесса [2], температурными изменениями при прокатке, недостаточно изученным процессом формирования микроструктуры металла [3] и его физико-механических свойств. Кроме того, в реальных металлургических условиях неизбежно существуют возмущающие воздействия, такие как колебания химического состава стали, а также колебания параметров температурно-деформационных режимов производства.

За последние двадцать лет значительно вырос интерес к искусственным нейронным сетям. В самых разных областях науки и техники пытаются применить возможности, предоставляемые этой технологией, и ищут приложения ее внутри своих дисциплин [4].

Поэтому для решения поставленных задач, возможно, целесообразно использовать нейросетевое моделирование.

При этом, первой, возникает проблема выбора оптимальной архитектуры нейронной сети. Так как области применения наиболее известных подходов пересекаются, то для решения конкретной задачи можно использовать различные типы нейронных сетей и при этом результаты могут оказаться одинаковыми [5]. Будет ли та или иная сеть лучше и практичнее, зависит в большинстве случаев от условий задачи, полноты набора обучающих данных, выбора метода обработки.

Набор обучающих данных должен быть типичным для задачи, решению которой обучается сеть. Обучение часто оказывается уникальным процессом, когда приемлемые решения многих проблем могут быть получены только в процессе многочисленных экспериментов [2].

В 2021 г. В.М. Зуевым предложен подход, при котором обучение нейросети происходит на наборе данных, являющимся комбинацией данных, получаемых из теоретической модели механизма, и данных, получаемых в ходе эксперимента с работающим механизмом [6-8].

Федоров М.В. в 2024 г. [9] презентовал доклад, в котором также предложен новый подход к построению моделей глубокого обучения на основе синтеза данных теоретических моделей и дополненных данных реального эксперимента (аугментация).

В данной работе. в качестве фундаментального знания предложено использовать физико-математическую модель [10] ускоренного многостадийного охлаждения арматурной стали в потоке прокатного стана.

Описанная в этой работе математическая модель разработана на основе фундаментальных знаний в области теплотехники [11], гидравлики [12], металловедения [13], в том числе – с применением методов статистической обработки данных заводских экспериментов. Также приведенная модель учитывает реальную конструкцию термоустановки и элементов камеры охлаждения.

Указанная модель может применяться как в качестве инструмента для создания обучающего набора данных для обучения искусственной нейронной сети, так и для оптимизации технологии при охлаждении профилей из различных марок стали при возможных изменениях температурно-скоростных режимов прокатки.

## Построение моделей

В качестве пакета программ для разработки сети выбран MATLAB. Это решение обусловлено развитым графическим интерфейсом, наличием ряда встроенных полезных модулей для разработки, таких как модуль проектирования архитектуры искусственной нейросети и др.

Исходными данными для искусственной нейросети (ИНС) типа двухслойный перцептрон выбраны следующие 7 величин:

- номер профиля прокатки № (10, 12, 14, 16, 18, 20, 22, 25, 28, 32);
- скорость прокатки  $V$  (5.0 ... 14.5 м/с);
- температура прокатки (аустенизации)  $t$  (1000 ... 1090 °С);
- содержание углерода  $C$  (0.16 ... 0.32%);
- содержание марганца  $Mn$  (0.4 ... 1.3%);
- содержание кремния  $Si$  (0.08 ... 0.6%);
- условный предел текучести готового проката  $\sigma_{0.2}$  (467...880 МПа).

Разработанная нейросеть должна правильно предсказывать необходимые установки для прокатного стана, то есть в случае с установкой из 6 секций [14] — это давления воды на форсунках каждой из 6 секций  $P_1$ - $P_6$ .

При попытке описать ИНС простой архитектурой на основе перцептрона с обратным распространением ошибки (7 входов, 18 нейронов в 1-ом скрытом слое, 6 нейронов во 2-ом выходном слое) установлено, что она не способна адекватно описать модель. Результат для набора данных из 188 опытов, полученный с помощью приложения NNfitting показан ниже на рис. 1 и не удовлетворяет требования по точности прогноза.

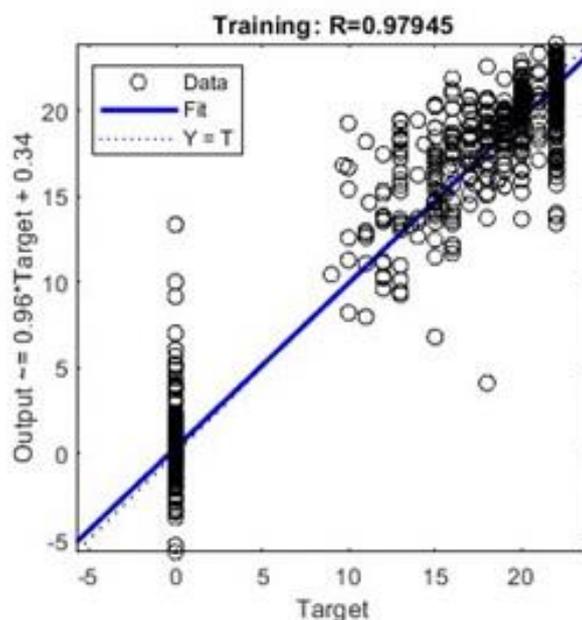


Рисунок 1 – результат обучения ИНС1: метод обучения – Levenberg-Marquardt, функция потерь – среднеквадратичное отклонения (MSE), функция активации –  $\tanh(x)$ .

Принятое решение обрабатывать каждый отклик отдельно слегка улучшило результат, но точность прогноза по-прежнему осталась неудовлетворительной.

На наш взгляд это обусловлено влиянием интегральных откликов в каждом опыте на результат процесса. На степень упрочнения металла ( $\sigma_{0.2}$ ) кроме указанных выше входных шести параметров в каждом случае влияет время охлаждения и гидродинамические условия (давление). Время охлаждения зависит от суммарной длины активной зоны теплообмена (длины камер и количества включенных секций), а интенсивность охлаждения зависит от суммарного давления во включенных секциях. При этом первая секция с целью вариации времени охлаждения может быть короткой или длинной. Это тоже необходимо учитывать в выборе формы откликов.

Поэтому принято решение изменить архитектуру ИНС на (7x18x4) и обучение осуществлять для каждого целевого параметра индивидуально,

В качестве целевых параметров (Y1- Y4) приняты:

Y1- условная длина первой секции установки  $L$  (0-короткая, 1-длинная);

Y2 - количество включенных секций установки  $N_{\text{вкл}}$ ;

Y3- сумма давлений на форсунках по установке  $S$ ;

Y4 - давление в 1-й секции  $P_{r1}$  (опционально).

В табл.1 показан пример расчета по модели [10] параметров режима при разном распределении давления по длинным секциям установки для двух профилей арматуры, из которого следует, что суммарную величину давлений можно распределить исходя из свойства аддитивности давлений в длинных секциях. То есть, зная сумму всех давлений и давление в 1-й секции, остальные распределить, например равномерно или по определенному закону.

Таблица 1 – Влияние распределения давлений по секциям установки на условный предел текучести арматуры №14 и 28 класса прочности А500 (к-короткая, д-длинная 1-я секция).

№	Скор.	t ауст	C	Mn	Si	$\sigma_{0.2}$	Длина 1 сек	Pфор1	Pфор2	Pфор3
армат.	м/с	°С	%	%	%	Мпа	к=0/д=1	ати	ати	ати
14	12	1060	0.2	0.6	0.15	534.5	0	22	13	16
14	12	1060	0.2	0.6	0.15	534.3	0	22	15	14
14	12	1060	0.2	0.6	0.15	533.8	0	22	18	11
14	12	1060	0.2	0.6	0.15	534.4	0	22	14.5	14.5
14	12	1060	0.2	0.6	0.15	533.6	0	22	11	18
28	6.6	1044	0.2	0.6	0.15	563.3	1	18	14	14
28	6.6	1044	0.2	0.6	0.15	560.2	1	12	17	17
28	6.6	1044	0.2	0.6	0.15	562.9	1	16	15	15

В процессе подготовки моделирования создан набор обучающих данных из 188 опытов, основу которого составили расчетные данные моделирующей программы [10], с добавлением (на этапе адаптации модели) незначительного количества экспериментальных производственных данных с сортового прокатного стана.

Математически задача формулируется следующим образом.

Дан набор векторов  $x_i = X_i(p_1, \dots, p_m)$ , где  $i=1, \dots, I$  номера экспериментов, а  $p_m$  соответствует значениям указанных входных данных ( $N_{\text{вкл}}, V, T, C, Mn, Si, \sigma_{0.2}$ ), центрированным и поделенным на величину среднеквадратичного отклонения вдоль выборки по  $i$ .

Кроме набора векторов  $x_i$  считается известным набор векторов  $d_i = D_i(s_1, \dots, s_k)$ , позиционно соответствующий  $x_i$ , но такой, что величины  $s_k$  соответствуют значениям параметров  $L, N, S, P_1$ .

Необходимо вместо в общем-то неизвестной функции  $X_i(p_1, \dots, p_m)$  подобрать аппроксимирующую её функцию  $\tilde{X}_i(p_1, \dots, p_m; w_1, \dots, w_n)$ , такую, что

$$J = \sum_i^I \sum_k^K (u_{ik} - s_{ik})^2 < eps$$

не превышает некоторой технологически допустимой величины  $eps$ . Здесь  $u_{ik}$  выход нейросети.

В неравенстве выше величины  $w_1, \dots, w_n$  являются параметрами нейросети: определяются количеством нейронных слоёв и количеством нейронов в слое.

В процессе моделирования были испробованы варианты нейросетей с разными количествами входных, выходных нейронов и разными количествами нейронов в разных внутренних слоях. За основной критерий выбора структуры нейросети был взят минимум функции среднеквадратичной ошибки прогноза. Так как планировалось создание аппаратного инструмента, указывающего операторам необходимые установки для прокатного стана, то предпочтение оказывалось такой нейросети, которая наиболее легко реализовывалась аппаратно.

Для успешного обучения нейронной сети следует уделить особое внимание подготовке набора данных. Пусть диапазоны изменений величин  $N_b, V, T, C, Mn, Si, \bar{b}_{0.2}$  от минимальной до максимальной составляют соответственно  $B_n$ , где индекс  $n \in \{N_b, V, T, C, Mn, Si, \bar{b}_{0.2}\}$ .

Тогда объем пространства аппроксимации составит

$$W = \prod_n B_n,$$

Если задана относительная точность аппроксимации  $\delta_n$ , то согласно теореме В.А. Котельникова, количество точек данных при равномерной аппроксимации должно быть не менее

$$Np = \frac{W}{M},$$

где

$$M = \prod_n \bar{B}_n \delta_n,$$

а  $\bar{B}_n$  - среднее значение  $B_n$ .

Подставляя данные из [6], получаем оценку для  $Np=10^6-10^7$ , то есть для уверенной аппроксимации массив обучающих данных должен иметь порядка миллиона значений.

Значительно уменьшить число данных для обучения модели можно применив неравномерную аппроксимацию. Для этого пространство  $W$  необходимо разбить на две (или более) частей в зависимости от значения производных

$$\frac{\partial B_i}{\partial B_j} \quad (i \neq j)$$

И в области больших значений производных оставить исходную плотность точек обучения, а в области малых - уменьшить эту плотность на 2-3 порядка. Так как величины  $B_n$  сильно разнятся, то, чтобы сравнение частных производных имело смысл, нужно величины  $B_n$  предварительно отнормировать.

## Результаты моделирования

Результаты обучения нейросети, имеющей 6 входов, 18 нейронов внутреннего слоя и 4 выхода (поочередное обучение каждого) показаны ниже на рис.2. Результат тестирования ИНС1 – удовлетворительный, максимальная ошибка в 188 опытах в определении: L -0%, N-0%, S – 6%, Pr<sub>1</sub>-10%. Однако, оценка модели на данных даже незначительно отличающихся от обучающих показала низкую адекватность. Ошибки в определении каждого из четырех откликов накладываются друг на друга, кроме того, ошибка в определении Pr<sub>1</sub> даже в процессе обучения достаточно велика для прогноза по  $b_{0.2}$  с требуемой точностью  $\pm 2\%$ . Поэтому было принято решение сократить число интегральных целевых параметров до двух: Y1- время охлаждения ( $T_{\text{охл}}$ ) и Y2- интенсивность охлаждения (S).

Здесь следует охарактеризовать процесс с точки зрения оптимизации технологии. Критерием оптимизации выступает минимально возможный расход воды и следовательно - электроэнергии на насосах при достижении допустимых значений механических свойств, определяемых стандартом для соответствующего класса арматуры. Очевидно, что экономии ресурсов можно добиться, проектируя режим таким образом, чтобы указанные свойства выполнялись с величиной близкой к минимально допустимой с учетом возможной погрешности прогноза. Например, согласно требованию стандарта ГОСТ 10884-94 допустимый нижний предел  $b_{0.2}$  для класса Ат500 составляет 500Мпа, верхний – 599Мпа, а оптимальным может быть выбрано, скажем, 530 Мпа.

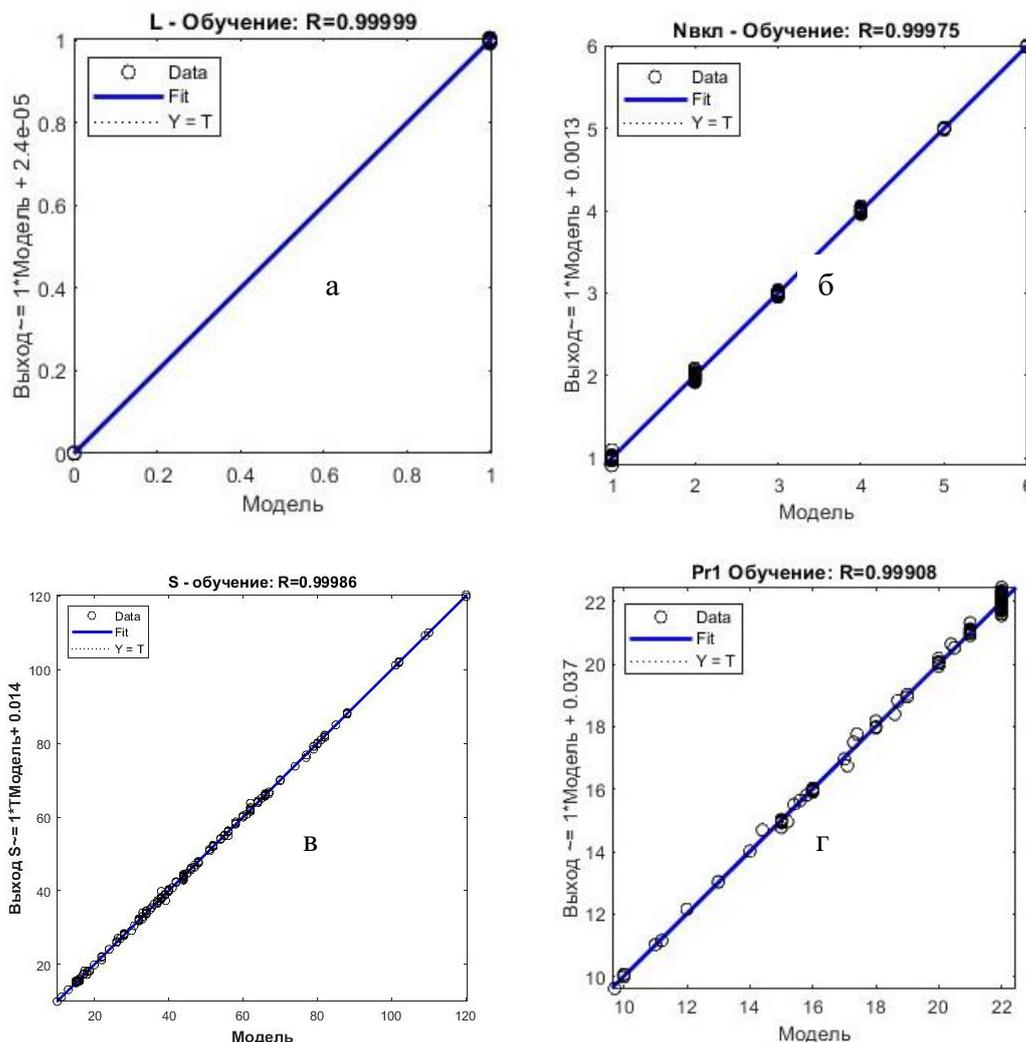
Одновременно необходимо выполнить ряд ограничений процесса, таких как:

- ограничение по max скорости прокатки – определяется максимальной пропускной способностью оборудования прокатного стана на разных профилях;
- максимально возможное давление на форсунке;
- незначительное превышение температуры конца прокатки над критической при которой совершаются химические изменения и физические превращения, имеющие влияние на свойства, стали, зависящей от химического состава стали;
- отсутствие перегрева охлаждающей воды в каждой из секций;
- наличие существенной силы гидротранспортирования на мелких профилях.

Последние два зависят от давления на форсунках. Указанные ограничения должны учитываться при проектировании обучающего набора. Задача усложняется еще и потому, что для одного и того же набора данных возможны несколько решений.

В табл. 2 показано влияние длины первой секции на расход воды и время охлаждения, из которой следует, что одного и того же значения параметра  $b_{0.2}$  можно достигнуть как с длинной, так и с короткой первой секцией. Установка короткой секции применяется во избежание перегрева воды при максимальной температуре проката на входе в установку или для сокращения времени охлаждения. При этом снижение времени охлаждения на первой секции компенсируется повышением суммы давлений на длинных. Расход воды на установке с короткой секцией выше, чем с длинной на 19-30%.

Рисунок 2 - Результаты моделирования ИНС1 (метод обучения – Levenberg-Marquardt,



функция потерь – среднеквадратичное отклонения (MSE), функция активации –  $\tanh(x)$  ):  
 а- условная длина первой секции установки; б – количество включенных секций установки  
 Nвкл; в – сумма давлений на форсунках; г – давление в 1-й секции;

Таблица 2 - Влияние длины первой секции на расход охлаждающей воды и время охлаждения при производстве арматуры №14.

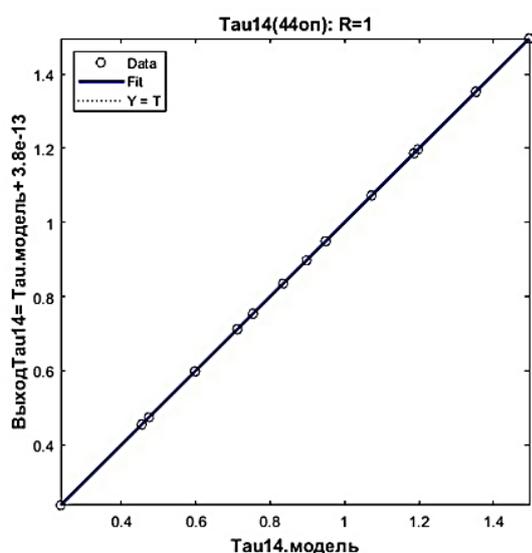
№ армат.	Скор. м/с	t пр °C	C %	Mn %	Si %	C <sub>экв</sub> -	σ <sub>0.2</sub> Мпа	Длина 1 секц 0-к/1-д	τ <sub>охл</sub> сек	S атм	Nвкл -	Pфор1 атм	Pфор2 атм	Pфор3 атм	Pфор4 атм	Pфор5 атм	Pфор6 атм	Расход воды W, м <sup>3</sup> /ч	ΔW/W %
14	11.50	1042.00	0.16	0.40	0.15	0.24	452	0	0.455	44	2	22	22	0	0	0	0	282	
						0.24	452	1	0.598	31	2	16	15	0	0	0	0	194	-31%
	14.50	1069.00	0.17	0.40	0.08	0.24	526	0	0.835	88	4	22	22	22	22	0	0	518	
						0.24	526	1	0.949	72	4	18	18	18	18	0	0	422	-19%
	14.50	1069.00	0.19	0.50	0.15	0.29	624	0	1.072	88	5	16.0	18	18	18	18	0	560	
						0.29	627	1	1.186	68	5	13.6	13.6	13.6	13.6	0	0	450	-20%
	11.50	1042.00	0.22	0.65	0.30	0.36	706	0	0.754	55	3	19	18	18	0	0	0	362	
						0.36	705	1	0.897	45	3	15	15	15	0	0	0	280	-23%
	14.50	1069.00	0.28	0.80	0.60	0.47	883	0	0.835	76	4	20	20	18	18	0	0	479	
						0.47	883	1	0.949	60	4	18	14	14	14	0	0	380	-21%

Примечание: C<sub>экв</sub> – углеродный эквивалент (характеристика свариваемости стали) согласно ДСТУ 3760:2006 определяется по формуле C<sub>экв</sub>=C+ Mn/6+Si/10.

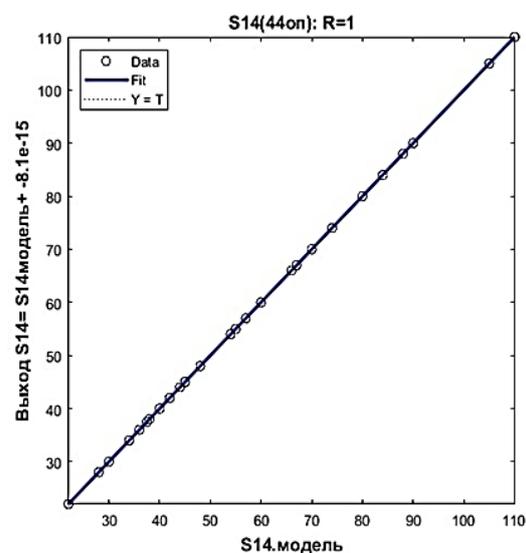
Учитывая указанные выше ограничения, разработан обучающий набор данных из 44 опытов для охлаждения профиля №14 при двух значениях  $V$  (14.5, 11.5 м/с) и соответствующих им значениях  $t$  (1069, 1042°C) соответственно для классов арматуры Ат400, Ат500, Ат600 и Ат800 по ГОСТ 10884-94 при вариации  $C_{экр}$  (0.23...0.59). В этом наборе короткая первая секция использовалась только в том случае, когда избежать перегрева воды ( $t_{в,ср} > 80^\circ\text{C}$ ) в длинной секции не удалось при максимальном давлении на форсунке. Таким образом удастся оценить отдельно степень влияния изменения факторов  $C$ ,  $Mn$ ,  $Si$  и  $b_{0,2}$  на ошибку прогноза ИНС. В табл.3 показан фрагмент этого набора данных. На рис. 3 показаны регрессионные тренды результатов обучения ИНС2.

Таблица 3 – Фрагмент набора данных для обучения ИНС2.

№ армат.	Скор. м/с	t ауст. °C	C %	Mn %	Si %	C <sub>экр</sub>	σв, Мпа	T <sub>охл</sub> сек	S атм	Рфор1	Рфор2	Рфор3	Рфор4	Рфор5	Рфор6
										атм					
14	14.50	1069.00	0.16	0.40	0.15	0.233	472	0.712	46	16	16	14	0	0	0
14	14.50	1069.00	0.17	0.40	0.08	0.245	472	0.712	55	19	18	18	0	0	0
14	14.50	1069.00	0.18	0.50	0.18	0.281	472	0.712	38	12.5	12.5	12.5	0	0	0
14	14.50	1069.00	0.20	0.60	0.20	0.320	467	0.474	44	22	22	0	0	0	0
14	14.50	1069.00	0.22	0.65	0.20	0.348	470	0.474	38	19	19	0	0	0	0
14	11.50	1042.00	0.17	0.40	0.08	0.24	475	0.598	41	20.5	20.5	0	0	0	0
14	11.50	1042.00	0.16	0.40	0.15	0.24	467	0.598	36	18	18	0	0	0	0
14	11.50	1042.00	0.18	0.50	0.18	0.28	470	0.598	30	15	15	0	0	0	0
14	11.50	1042.00	0.20	0.60	0.20	0.32	467	0.598	27	14.50	12.50	0	0	0	0
14	14.50	1069.00	0.17	0.40	0.08	0.24	532	0.949	88	22	22	22	22	0	0
14	14.50	1069.00	0.18	0.50	0.18	0.28	536	0.712	66	22	22	22	0	0	0
14	14.50	1069.00	0.20	0.60	0.20	0.32	534	0.712	55	18	18.5	18.5	0	0	0
14	14.50	1069.00	0.22	0.65	0.30	0.36	542	0.712	38	18	10	10	0	0	0
14	14.50	1069.00	0.27	0.70	0.30	0.42	532	0.474	44	22	22	0	0	0	0
14	14.50	1069.00	0.30	0.80	0.30	0.46	540	0.474	28	18	10	0	0	0	0
14	11.50	1042.00	0.17	0.40	0.08	0.24	536	0.897	51	17.00	17.00	17.00	0	0	0
14	11.50	1042.00	0.18	0.50	0.18	0.28	535	0.897	33	17	8	8	0	0	0
14	11.50	1042.00	0.20	0.60	0.20	0.32	534	0.598	40	20	20	0	0	0	0
14	11.50	1042.00	0.22	0.65	0.30	0.36	533	0.598	36	18	18	0	0	0	0
14	11.50	1042.00	0.27	0.70	0.30	0.42	533	0.598	27	18	8.5	0	0	0	0



а)



б)

Рисунок 3 - Результаты моделирования ИНС2 (метод обучения – Levenberg-Marquardt, функция потерь – среднеквадратичное отклонения (MSE), функция активации –  $\tanh(x)$ ):

а- Y1- $\tau_{охл}$ ; б – Y2- S.

В табл. 4 показаны результаты оценки точности прогноза ИНС2, откуда следует, что изменение целевого параметра  $b_{0.2}$  в пределах  $\pm 7\%$  приводит к ошибке прогноза -2.8-+4%. Изменение характеристик химсостава приводит к ошибкам от --5.0 до +9%. Значительная ошибка ожидаемо соответствует изменениям параметров  $V$  и  $T$ , варьируемым только на двух уровнях, особенно для классов Ат400. Кроме того, поскольку существует ограничение по max давлению на форсунке, а модель это не учитывает, то возможен абсурдный результат прогноза (опыты 17, 18 –  $S_p$  больше предельно допустимой величины).

Таким образом, решение поставленной задачи с помощью ИНС на основе двухслойного перцептрона не представляется возможным. Для получения более точного прогноза необходимо применить другие методы машинного обучения, например такой, как Boosting - метод машинного обучения, при котором несколько слабых моделей (обычно деревья решений) обучаются последовательно, каждая следующая модель пытается исправить ошибки предыдущей. Итоговое предсказание строится как взвешенная сумма всех моделей [15-20]. Один из его видов XGBoost – оптимизированная библиотека распределённого градиентного Boosting, отличающаяся, по мнению авторов [15] высокой эффективностью, гибкостью и переносимостью. Полученные первые результаты применения XGBoost обнадеживают, однако эта информация выходит за рамки настоящего сообщения.

Таблица 4 – Оценка точности прогноза ИНС2.

№ опыта	Класс арматуры	Задание							Расчетные данные						
		№	V	t	C	Mn	Si	$b_{0.2}$	Lp	Np	$\tau_{охлр}$	Sp	$b_{0.2p}$	$\Delta b_{0.2}$	
		X1	X2	X3	X4	X5	X6	X7			Y1	Y2	X7p		
1	Ат400	14	11.5	1042	0.18	0.50	0.18	440	1	2	0.517	25	430	-2.3%	
2	Ат600	14	14.5	1069	0.27	0.70	0.30	670	0	3	0.796	74	644	-3.9%	
3	Ат400	14	14.5	1069	0.17	0.40	0.08	440	0	3	0.633	48	436	-0.9%	
4	Ат500	14	14.5	1069	0.22	0.65	0.30	530	1	3	0.673	40	545	2.8%	
5	Ат600	14	14.5	1069	0.27	0.70	0.30	670	1	3	0.796	74	659	-1.6%	
6	Ат600	14	14.5	1069	0.32	1.00	0.30	670	0	4	0.783	39	669	-0.1%	
7	Ат500	14	11.5	1042	0.20	0.60	0.20	520	1	2	0.588	37	514	-1.2%	
8	Ат800	14	11.5	1042	0.32	0.80	0.30	850	1	3	0.861	66	864	1.6%	
9	Ат800	14	11.5	1042	0.32	0.80	0.28	850	1	3	0.871	67	858	0.9%	
10		14	11.5	1042	0.32	0.85	0.30	850	1	3	0.819	59	878	3.3%	
11		14	11.5	1042	0.30	0.80	0.30	850	1	3	0.918	63	853	0.4%	
12		14	11.5	1047	0.32	0.80	0.30	850	1	3	0.830	47	824	-3.1%	
13		14	12.0	1042	0.32	0.80	0.30	850	0	4	1.008	45	840	-1.2%	
14	Ат600	14	14.5	1069	0.27	0.70	0.25	670	0	4	0.804	57	634	-5%	
15		14	14.5	1069	0.27	0.60	0.30	670	0	4	0.813	84	732	9%	
16		14	14.5	1069	0.24	0.70	0.30	670	0	4	0.876	62	647	-3%	
17		14	14.5	1059	0.27	0.70	0.30	670	1	3	0.739	76	?	?	
18		14	13.5	1069	0.27	0.70	0.30	670	1	2	0.541	103	?	?	

Примечание: в выделенных ячейках значения варьируемых параметров.

## Заключение

1. Результаты моделирования с помощью простой ИНС на основе перцептрона процесса ускоренного охлаждения арматурного проката показали, что приемлемое решение получить не удалось.

2. Ошибки прогноза  $b_{0.2}$  превышают допустимые значения (2-3%), которые гарантируют получение заданных свойств проката в пределах, допускаемых стандартом. Область определения задачи имеет неоднородные несбалансированные данные и нерегулярную форму, которая сложно поддается описанию линейной регрессионной моделью.

3. Наличие ряда ограничений процесса усложняет задачу обучения, решение получается малоинформативным так как не отражает соответствие ограничениям.

4. Учитывая малые временные затраты одного прямого расчета по физико-математической модели [10] (3-5сек), еще одним вариантом решения может быть прямой расчет по физико-математической модели с алгоритмом оптимизации, учитывающим все ограничения, с выводом на монитор оператора таких параметров, как средняя температура охлаждающей воды на выходе секции, минимальная, средняя и максимальная скорость воды, силы гидротранспортирования, расход воды по секциям, производительность установки, температуру самоотпуска и других параметров эффективности режима. Окончательную подстройку системы можно осуществить по данным заводского эксперимента.

## Список литературы

1. Нейросетевое моделирование процесса получения широкополосной горячекатаной стали с заданными механическими свойствами / В. М. Салганик, А. М. Песин, С. В. Денисов [и др.]. *Производство проката*. 2008. № 8. С. 26-27. EDN JTHZKJ.
2. Губинский В.И., Рыбалов А.А. Моделирование ускоренного охлаждения арматурного проката в потоке непрерывных мелкосортных станов. *Промышленная теплотехника*, 2002, т.24, №6.-С.24-28.
3. Пилюшенко В.Л., Ноговицин А.В. Феноменологическая модель механических свойств проката из низкоуглеродистой микролегированной стали *Фундаментальные и прикладные проблемы черной металлургии*. Киев: Наукова думка, 1995. 218с.
4. Николаева С.Г. *Нейронные сети. Реализация в Matlab: учебное пособие* / С.Г. Николаева. Казань: Казан. гос. энерг. ун-т, 2015. 92 с.
5. Горбань А. Н., Россиев Д. А. *Нейронные сети на персональном компьютере*. Новосибирск: Наука, 1996. 224 с.
6. Зуев В.М. Использование нейросети для управления механизмами. (подъема мишеней).[Тезисы доклада]. *Материалы Донецкого международного научного круглого стола «Искусственный интеллект: теоретические аспекты и практическое применение» ИИ-2020*. Донецк: ГУ ИПИИ, 2020. С. 73–77.
7. Зуев В.М. Использование нейросети для управления механизмами. *Материалы конференции в Дивногорском 2021г. Всероссийская мультikonференция по проблемам управления*
8. В. М. Зуев, О. А. Бутов, С. Б. Иванова, А. А. Никитина, С. И. Уланов. Способ обучения нейронной сети управления роботом. *International Peer-Reviewed Scientific Journal «Problems of Artificial Intelligence»*, ISSN 2413-7383. 2021. № 2 (21). С. 22–33.
9. Федоров, М. В. (член-корр. РАН) Новые методы машинного обучения: использование фундаментального знания для решения практических задач: [тезисный онлайн-доклад] [Электронный ресурс] / М. В. Федоров // Программа II Всероссийской школы-семинара по искусственному интеллекту и большим данным в технических, промышленных, природных и социальных системах. – Национальный центр физики и математики (НЦФМ). – Дата проведения: 25-29 ноября 2024 г. – (дата обращения: 04.04.2025).
10. Солод В.С. Физико-математическая модель для разработки экспертной системы ускоренного охлаждения арматурного проката / В. С. Солод / *Проблемы искусственного интеллекта* 2025 № 2 (37). С. 44-58. DOI 10.34757/2413-7383.2025-2-37-44-58
11. *Тепломассообмен* /С.И.Гинкул, В.И.Шелудченко, В.В.Кравцов, С.В.Палкина.Донецк: Норд-Пресс, 2006. 298 с.
12. Моргунов К. П. *Гидравлика: Учебник*. СПб.: Издательство «Лань», 2014. 288 с.: ил.
13. Чудина, О.В. *Теория и практика термической обработки металлов: учебно-методическое пособие к мультимедийному изданию* / О.В. Чудина, Г.В. Гладова, А.В. Остроух. М.: МАДИ, 2013. 64 с.
14. О.Цкитишвили, А.Н.Чудновец, В.Н.Бруханский, Д.П.Кукуй, В.С.Солод, А. А.Мальцев Освоение производства высококачественной продукции на самом новом в Украине среднесортно-мелкосортном стане 390. *ОАО «Черметинформация» Бюллетень «Черная металлургия»*. 2011. №7.– С.56–65.
15. XGBoost Documentation" [Электронный ресурс]. *Документация XGBoost* : [сайт]. URL: [https://xgboost.readthedocs.io/en/release\\_3.0.0/#](https://xgboost.readthedocs.io/en/release_3.0.0/#) (дата обращения: 04.05.2025).

16. А.Д. Смородинов, Т. В. Гавриленко, В. А. Галкин, Теоретические основы искусственных нейронных сетей для решения задачи аппроксимации и интерполяции. *Успехи кибернетики* 2023;4(4):41–53 DOI: 10.51790/2712-9942-2023-4-4-04
17. Сергеев, А. П. Введение в нейросетевое моделирование : учеб. пособие / А. П. Сергеев, Д. А. Тарасов ; под общ. ред. А. П. Сергеева. Екатеринбург : Изд-во Урал. ун-та, 2017. 128 с. ISBN 978-5-7996-2124-7
18. Хливненко Л. В. *Практика нейросетевого моделирования : учебное пособие для вузов* / Л. В. Хливненко, Ф. А. Пятакович. 2е изд., стер. Санкт-Петербург : Лань, 2021. 200 с.: ил. Текст : непосредственный. ISBN 978.5.8114.8264.1
19. Головкин, В. А. *Нейросетевые технологии обработки данных : учеб. пособие* / В. А. Головкин, В. В. Краснопрошин. Минск : БГУ, 2017. 263 с. ISBN 978.985.566.467.4.
20. Вичугов В.Н Модифицированный градиентный алгоритм обучения радиально-базисных нейронных сетей. *Известия Томского политехнического университета. Управление, вычислительная техника и информатика*. 2009. Т. 315. № 5 с150-152

## References

1. Neural network modeling of the process of obtaining wide-strip hot-rolled steel with specified mechanical properties / V. M. Salganik, A. M. Pesin, S. V. Denisov [et al.] // *Rolled products production*. - 2008. - No. 8. - P. 26-27. - EDN JTHZKJ.
2. V. I. Gubinsky, A. A. Rybalov Modeling of accelerated cooling of reinforcing bars in the flow of continuous small-section mills. "Industrial heat engineering", 2002, v. 24, No. 6.-P. 24-28.
3. Pilyushenko V. L., Nogovitsyn A. V. Phenomenological model of mechanical properties of rolled low-carbon microalloyed steel. / *Fundamental and applied problems of ferrous metallurgy*. - Kyiv: Naukova Dumka, 1995. 218 p.
4. Nikolaeva S.G. Neural networks. Implementation in Matlab: tutorial / S.G. Nikolaeva. - Kazan: Kazan. state power University, 2015. - 92 p.
5. Gorban A.N., Rossiev D.A. Neural networks on a personal computer. - Novosibirsk: Nauka, 1996. - 224 p.
6. Zuev V.M. Using a neural network to control mechanisms. (lifting targets). [Abstracts of the report]. Proceedings of the Donetsk international scientific round table "Artificial Intelligence: theoretical aspects and practical application" AI-2020. – Donetsk: State University of Artificial Intelligence, 2020. – P. 73–77.
7. Zuev V. M. Using a neural network to control mechanisms. Proceedings of the conference in Divnomorskoye 2021. All-Russian multi-conference on control problems.
8. V. M. Zuev, O. A. Butov, S. B. Ivanova, A. A. Nikitina, S. I. Ulanov. A method for training a neural network to control a robot/ *International Peer-Reviewed Scientific Journal "Problems of Artificial Intelligence"*, ISSN 2413-7383. – 2021 – No. 2 (21). – P. 22–33.
9. Fedorov, M. V. (Corresponding Member of the Russian Academy of Sciences) New Methods of Machine Learning: Using Fundamental Knowledge to Solve Practical Problems: [online abstract report] [Electronic resource] / M. V. Fedorov // Program of the II All-Russian School-Seminar on Artificial Intelligence and Big Data in Technical, Industrial, Natural and Social Systems. - National Center for Physics and Mathematics (NCPM). - Date: November 25-29, 2024 - (date of access: 04.04.2025).
10. Solod V. S. Physical and mathematical model for the development of an expert system for accelerated cooling of reinforcing bars / V. S. Solod / *Problems of Artificial Intelligence* 2025 No. 2 (37). - P. 44-58. DOI 10.34757/2413-7383.2025-2-37-44-58
11. Heat and Mass Transfer/S.I.Ginkul, V.I.Sheludchenko, V.V.Kravtsov, S.V.Palkina. -Donetsk: Nord-Press, 2006.-298 p.
12. Morgunov K.P. Hydraulics: Textbook.- St. Petersburg: Lan Publishing House, 2014. - 288 p.: ill.
13. Chudina, O.V. Theory and Practice of Heat Treatment of Metals: a teaching aid to a multimedia publication / O.V. Chudina, G.V. Gladova, A.V. Ostroukh. - M.: MADI, 2013. - 64 p.
14. O. Tskitishvili, A. N. Chudnovets, V. N. Brukhansky, D. P. Kukuy, V. S. Solod, A. A. Maltsev Development of high-quality production at the newest medium- and small-section mill 390 in Ukraine // *JSC "Chermetinformatsiya" Bulletin "Ferrous Metallurgy"*. - 2011. - No. 7. - P. 56 - 65.
15. "XGBoost Documentation" / [Electronic resource] // XGBoost Documentation: [website]. - URL: [https://xgboost.readthedocs.io/en/release\\_3.0.0/#](https://xgboost.readthedocs.io/en/release_3.0.0/#) (accessed: 04.05.2025).
16. A. D. Smorodinov, T. V. Gavrilenko, V. A. Galkin, Theoretical foundations of artificial neural networks for solving the problem of approximation and interpolation. *Advances in Cybernetics* 2023;4(4):41–53 DOI: 10.51790/2712-9942-2023-4-4-04

17. Sergeev, A. P. Introduction to neural network modeling: textbook / A. P. Sergeev, D. A. Tarasov; under the general editorship of A. P. Sergeev. — Ekaterinburg: Publishing house of the Ural. University, 2017. — 128 p. ISBN 978-5-7996-2124-7
18. Khlivnenko L. V. Practice of neural network modeling: a textbook for universities / L. V. Khlivnenko, F. A. Pyatakovich. - 2nd ed., reprinted. St. Petersburg: Lan, 2021. -200 p.: ill. - Text: direct. ISBN 978.5.8114.8264.1
19. Golovko, V. A. Neural network data processing technologies: a textbook / V. A. Golovko, V. V. Krasnoproshin. - Minsk: BSU, 2017. - 263 p. - ISBN 978.985.566.467.4.
20. Vichugov V.N. Modified gradient algorithm for training radial-basis neural networks. News of Tomsk Polytechnic University. Management, Computer Engineering and Informatics. 2009. Vol. 315. No. 5 p.150-152

## RESUME

*V. S. Solod, V. M. Zuyev, S. B. Ivanova*

*Evaluation of the possibilities of using neural network models to optimizing reinforcing steel cooling technology.*

The tightening of requirements for the quality of reinforcement bars, including their structure and mechanical properties, can be met by using an integrated approach to solving the problems of determining the influence of the chemical composition of steel and the main technological parameters of the production process on the final quality indicators. Given the growing interest in artificial neural networks (ANN), an idea arose to use neural network modeling to predict the settings of an accelerated cooling thermal line that ensure high quality properties with minimal energy costs.

*Methods:*

- mathematical modeling of the process based on the synthesis of theoretical model data and supplemented data from a real experiment;
- deep learning of a neural network with a perceptron-based architecture with backpropagation of errors;
- statistical analysis of the modeling results.

A mathematical model was obtained for predicting the settings of an existing thermal unit based on such target parameters as cooling time (in the form of the length and number of included cooling sections) and cooling intensity (in the form of the total value of water pressure at the inlet of the included sections). The accuracy of the mechanical properties forecast is within  $\pm 7\%$ .

It is not possible to solve the problem with the required accuracy using an ANN based on a two-layer perceptron. To obtain a more accurate forecast, it is necessary to use other machine learning methods, such as Boosting, or to develop an optimization algorithm for direct calculation using the existing theoretical model, taking into account all equipment limitations, with subsequent adjustment using a small amount of factory data.

## РЕЗЮМЕ

*В. С. Солод, В. М. Зуев, С. Б. Иванова*

*Оценка возможностей использования нейросетевых моделей для оптимизации технологии охлаждения арматурной стали*

Ужесточение требований к качеству арматурных профилей, в том числе по структуре и механическим свойствам возможно удовлетворить путём применения комплексного подхода к решению задач определения влияния химического состава стали и основных технологических параметров производственного процесса на конечные показатели качества. Учитывая рост интереса к искусственным нейронным

сетям (ИНС), возникла идея использовать нейросетевое моделирование для прогнозирования настроек термоустановки ускоренного охлаждения, обеспечивающих высокое качество свойств при минимальных затратах энергоресурсов.

*Методы:*

- математическое моделирование процесса на основе синтеза данных теоретических моделей и дополненных данных реального эксперимента;
- глубокое обучение нейронной сети с архитектурой на основе перцептрона с обратным распространением ошибки;
- статистический анализ результатов моделирования.

Получена математическая модель для прогнозирования настроек существующей термоустановки по таким целевым параметрам, как время охлаждения (в виде длины и количества включенных секций охлаждения) и интенсивности охлаждения (в виде суммарной величины давления воды на входе включенных секций). Точность прогноза механических свойств находится в пределах  $\pm 7\%$ .

Решение поставленной задачи с помощью ИНС на основе двухслойного перцептрона с необходимой точностью не представляется возможным. Для получения более точного прогноза необходимо применить другие методы машинного обучения, например такой, как Boosting, или разработать алгоритм оптимизации для прямого расчета по имеющейся теоретической модели, учитывающий все ограничения оборудования, с дальнейшей подстройкой по небольшому количеству заводских данных.

**Солод Владимир Сергеевич** – научный сотрудник, Федеральное государственное бюджетное научное учреждение «Институт проблем искусственного интеллекта». *Область научных интересов:* компьютерное моделирование технологии прокатного производства, эл. почта vs.solod@mail.ru, адрес: 283048, г. Донецк, ул. Артема, д. 118 б, телефон +7(949) 459- 02 -42.

**Зуев Владимир Михайлович** – заведующий отдела Интеллектуальных робототехнических систем, Федеральное государственное бюджетное научное учреждение «Институт проблем искусственного интеллекта». *Область научных интересов:* компьютерное моделирование технологии прокатного производства, нейронные сети. эл. почта zvm.ipai@mail.ru, адрес: 283048, г. Донецк, ул. Артема, д. 118 б, телефон +7(949) 317-39-60.

**Иванова Светлана Борисовна** – директор Федерального государственного бюджетного научного учреждения «Институт проблем искусственного интеллекта», г. Донецк, эл. почта iai\_sb\_ivanova@mail.ru, адрес: 283048, г. Донецк, ул. Артема, д. 118 б, телефон: +7949 3347877 *Область научных интересов:* искусственный интеллект, интеллектуальные робототехнические системы.

Статья поступила в редакцию 23.07.2025.