



УДК 681.513

*А.И. Писарев, И.И. Суляев***НЕЙРОЭМУЛЯТОР ТЕМПЕРАТУРНОГО РЕЖИМА ПЛАВКИ  
МЕДНО-НИКЕЛЕВОГО СЫРЬЯ В ПЕЧИ ВАНЮКОВА***A.I. Pisarev, I.I. Sulyaev***NEURAL EMULATOR TEMPERATURE MODE OF COPPER-NICKEL RAW  
MATERIALS SMELTING IN VANYUKOV FURNACE**

Одна из проблем плавки в печах Ванюкова – большие потери цветных металлов со шлаком, приводящие к снижению производительности процесса. На эффективное разделение продуктов плавки и, как следствие, на их химический состав, существенно влияет температура расплава. Описано построение модели температурного режима плавки медно-никелевого сырья в печи Ванюкова с помощью искусственных нейронных сетей. Разработанная модель позволит создать автоматическую систему управления, поддерживающую оптимальный температурный режим в печи.

ПЕЧЬ ВАНЮКОВА. НЕЙРОННАЯ СЕТЬ. НЕЙРОЭМУЛЯТОР. ТЕМПЕРАТУРНЫЙ РЕЖИМ. МЕДНО-НИКЕЛЕВОЕ СЫРЬЕ. ШТЕЙН. ПРОГНОЗ.

One of Vanyukov furnace smelting problems is large losses of non-ferrous metals with slag, which lead to lower process. Melt temperature significantly influences effective separation of melting products and consequently their chemical composition. The purpose of work is to create temperature smelting model of copper-nickel raw materials in Vanyukov furnace based on artificial neural networks and statistic data use. The elaborated model will create automatic control system supporting optimal temperature mode in furnace.

VANYUKOV FURNACE. NEURAL NETWORK. NEURAL NETWORK EMULATOR. TEMPERATURE MODE. COPPER-NICKEL RAW MATERIALS. MATTE, FORECAST.

Печь Ванюкова (ПВ) – автогенная плавильная печь шахтного типа, предназначенная для переработки медного никельсодержащего сырья, обеднения жидких конвертерных шлаков. Конечными продуктами плавки в ПВ являются: богатые по диоксиду серы отходящие газы (объемная доля до 70 %), бедные по содержанию цветных металлов жидкие отвалы (объемная доля менее 1 %) и жидкий штейн с высокой концентрацией меди (не менее 50 %) [1, с. 101]. Необходимые условия устойчивой работы печи: непрерывная загрузка шихты заданного состава; бесперебойная подача дутья фиксированного объема (воздух, кислород, природный газ); непрерывный выпуск продуктов плавки в сифоны; постоянство уровней шлаковой и штейновой ванны в плавильной зоне [1]. Объемная

модель печи Ванюкова приведена на рис. 1.

Для эффективного разделения продуктов плавки, уменьшения химических и механических потерь цветных металлов со шлаком необходимо поддерживать оптимальную температуру в шахте печи [2]. Температура штейна в ПВ должна поддерживаться в диапазоне 1050–1150 °С, шлака 1200–1250 °С [1, с. 29]. Стабилизация температуры расплава в ПВ возможна при неизменном расходе кислорода на тонну шихты. При этом эффективное регулирование температуры достигается согласованным изменением расходов воздуха и угля. Еще больший эффект дает управление расходом технологического кислорода и содержанием кислорода в дутье [1].

Температура шлака ниже 1200 °С приводит к низкой растворимости магнетита и его




Рис. 1. Печь Ванюкова

выделению в самостоятельную фазу, происходит увеличение механических потерь цветных металлов со шлаком [1, с. 61].

Температура шлака выше 1250 °С вызывает ускоренный износ футеровки печи, перегрев отходящих газов. Стабилизация температуры приведет к снижению потерь цветных металлов со шлаком (рис. 2).

Таким образом, при окислительном процессе Ванюкова следует придерживаться оптимального диапазона температур, обеспечивающих нормальную производительность агрегата при наибольшем извлечении цветных металлов [2].

В статье разрабатывается нейроэмулятор теплового режима плавки медно-никелевого сырья в ПВ. Для этого используются статистические данные работы ПВ

Медного завода горно-металлургической компании «Норильский никель».

Исследованию и созданию температурной модели расплава в ПВ посвящены работы [3, 7], однако полученные математические модели не обладают свойством адаптации к внешним возмущениям, были учтены не все параметры процесса Ванюкова. Такие модели неэффективны в решении задачи оптимального управления печью.

#### Анализ входных факторов нейроэмулятора

Температура расплава в печи Ванюкова не измеряется в силу определенных причин (высокая температура, агрессивная среда и, тем самым, непродолжительный срок службы контрольно-измерительного прибора). Таким образом, единственным до-




Рис. 2. График зависимости потерь меди со шлаком от температуры расплава в печи Ванюкова

стоверным параметром, косвенно характеризующим температурный режим, является температура воды на сливе с прикладных кессонов 1, 2 ряда горна печи, которая дает надежную информацию о тепловом режиме процесса, в частности, о температуре штейна [1].

В работе [1] при проведении испытаний на опытно-промышленном комплексе печи жидкой ванны было установлено, что перепад температуры в кессонах на 1 °С соответствует изменению температуры ванны расплава печи примерно на 20 °С.

В первом ряду кессонированного пояса печи расположено 22 водоохлаждаемых элемента, во втором – 5. Таким образом, с каждой стороны печи располагается 27

медных прикладных кессонов [8]. Охлаждающая вода подается отдельно на левую и правую сторону печи.

При разработке нейронной сети в первую очередь необходимо определить входные и выходные факторы [9]. В нашей модели только один выходной параметр – средняя температура воды на сливе с прикладных кессонов 1, 2 ряда правой стороны печи, косвенно характеризующая температуру штейна. Отметим, что давление и, как следствие, расход охлаждающей воды на каждую сторону печи разное, поэтому целесообразно выбрать только одну из сторон. Для определения степени влияния входных факторов на выходную величину проведены статистические исследования и выпол-

Таблица 1

## Значения коэффициентов корреляции основных технологических параметров процесса Ванюкова

	Температура воды после охлаждения кессонов (правая сторона), °С
Расход КВС после смесителя, нм <sup>3</sup> /ч	0,57
Давление КВС после смесителя, кПа	0,63
Температура КВС после смесителя, °С	0,13
Расход кислорода к смесителю, нм <sup>3</sup> /ч	0,22
Давление кислорода к смесителю, кПа	0,1
Расход воздуха к смесителю, нм <sup>3</sup> /ч	0,3
Давление воздуха к смесителю, кПа	0,3
Содержание кислорода в КВС, %	-0,61
Расход природного газа к зоне плавления, нм <sup>3</sup> /ч	0,63
Давление природного газа к зоне плавления, кПа	0,44
Производительность конвейера 1, т/ч	-0,2
Производительность конвейера 2, т/ч	0,42
Скорость питателя 1, %	0,38
Скорость питателя 2, %	0,34
Скорость питателя 3, %	0,3
Скорость питателя 4, %	0,3
Скорость питателя 5, %	0,5
Скорость питателя 6, %	0,3
Скорость питателя 7, %	0,45
Скорость питателя 8, %	-0,4
Давление воды на охлаждение кессонов (правая сторона), кПа	0,65
Температура воды до охлаждения кессонов (правая сторона), °С	0,62




Рис. 3. График автокорреляционной функции средней температуры воды на сливе с прикладных кессонов 1, 2 ряда горна печи Ванюкова

нен корреляционный анализ (табл. 1).

Корреляционный анализ проводился на выборке объемом 200–300 минутных значений по каждому параметру процесса. Отметим, что при вычислении коэффициента парной корреляции между входным фактором и выходной величиной выбирался такой период работы печи, когда остальные параметры процесса были фиксированы или имели незначительные колебания. Такой подход позволяет увидеть реальное влияние отдельного фактора на температурный режим в шахте ПВ.

К примеру, коэффициент корреляции между температурой воды после охлаждения кессонов и расходом природного газа к зоне плавления составил больше 0,6, что отражает значимость фактора и высокую степень влияния на выходную переменную (см. табл. 1).

Из графика автокорреляционной функции  $K_x(\tau)$  по температуре кессонов видно, что дискретность опроса температуры должна быть не более 13 мин (рис. 3). Следовательно, используемый в работе шаг квантования в 1 мин вполне приемлем.

С целью «отслеживания» динамики изменения температуры на вход модели подается средняя температура кессонов на текущем  $j$  и предыдущем временном шаге  $j - 1$ .

Таким образом, входными факторами модели являются:

$x_{1j}$  – расход кислородо-воздушной смеси (КВС) после смесителя,  $\text{нм}^3/\text{ч}$ ;

$x_{2j}$  – давление КВС после смесителя, кПа;

$x_{3j}$  – содержание кислорода в КВС, %;

$x_{4j}$  – расход природного газа к зоне плавления,  $\text{нм}^3/\text{ч}$ ;

$x_{5j}$  – суммарный расход шихты, т/ч;

$x_{6j}$  – температура воды до охлаждения кессонов печи,  $^{\circ}\text{C}$ ;

$x_{7j}$  – давление воды на охлаждение кессонов правой стороны печи, кПа;

$x_{8j} \dots x_{15j}$  – скорости питателей под расходными бункерами, косвенно характеризующие объемную производительность по каждому компоненту загружаемой шихты м/с;

$x_{16,j-1}$  – средняя температура воды на сливе с прикладных кессонов 1, 2 ряда горна печи Ванюкова на  $j - 1$  шаге,  $^{\circ}\text{C}$ ;

$x_{17j}$  – средняя температура воды на сливе с прикладных кессонов 1, 2 ряда горна печи Ванюкова на  $j$  шаге,  $^{\circ}\text{C}$ .

Выходной параметр модели:

$y$  – средняя температура воды на сливе с прикладных кессонов 1, 2 ряда горна печи Ванюкова на  $j + 1$  шаге,  $^{\circ}\text{C}$ .

### Преобработка обучающих данных

Как известно [6, 9, 10], для нейронных сетей весьма верно эмпирическое правило «мусор на входе – мусор на выходе», поэтому очень важна предварительная обработка (преобработка) исходных данных для обучения сети. Введем обозначение массива обучающих данных для нейронной сети:

$$Z = \begin{pmatrix} x_{1j} \\ x_{2j} \\ \vdots \\ x_{ij} \\ y_j \end{pmatrix}_{\substack{j=1+17 \\ j=1+10000}},$$

где  $i$  – номер входного параметра;  $j$  – момент времени.

В массиве  $Z$  каждому набору входных параметров  $x_{ij}$  в момент времени  $j$  соответствует выходное значение  $y_j$ . Таким образом, данные синхронизированы во времени с дискретностью одна минута. Размер обучающего набора соответствует одной неделе работы ПВ (10 000 значений по каждому параметру).

Из массива исключаем строки данных, когда ПВ простаивала или показания контрольно-измерительных приборов были недостоверными (об этом сигнализирует бит состояния параметра в контроллере).

Моделирование и прогнозирование временных рядов с помощью нейронной сети не предполагает пропусков, поэтому пропущенные значения в обучающей выборке заполняются методом линейной интерполяции. Неизвестное значение  $x_{ij}$  в момент времени  $t_j$  вычисляется следующим образом:

$$x_{ij} = \frac{t_j(x_{i,j-1} - x_{i,j+1}) + (t_{j-1}x_{i,j-1} - t_{j+1}x_{i,j+1})}{t_{j-1} - t_{j+1}}.$$

Преобразование данных осуществляется как по входным факторам  $x_{ij}$ , так и по выходному параметру  $y_j$ .

Для снижения «нагрузки» на сеть данные подвергаем нормированию, позволяющему предотвратить насыщение нейрона (значительные изменения входов нейрона приводят к незначительному изменению его выхода):

$$\hat{x}_{ij} = \frac{x_{ij} - x_{i \min}}{x_{i \max} - x_{i \min}}, \quad (1)$$

где  $\hat{x}_{ij}$  – нормированное значение  $i$ -го параметра;  $x_{i \min} = \min\{x_{ij}\}$  – минимальное значение  $i$ -го параметра;  $x_{i \max} = \max\{x_{ij}\}$  – максимальное значение  $i$ -го параметра.

Данные приводим к интервалу (0;1), соответствующему диапазону изменения

логистической функции активации каждого нейрона сети. Нормирование исходных данных снижает нагрузку на сеть, что позволяет улучшить соотношение «ошибка/время обучения» [9].

Далее каждый параметр подвергается фильтрации посредством соотношения:

$$\tilde{x}_{ij} = \tilde{x}_{i,j-1} \cdot K_n + \hat{x}_{ij} \cdot K_d, \quad (2)$$

где  $\tilde{x}_{ij}$  – отфильтрованное значение сигнала;  $\tilde{x}_{i,j-1}$  – отфильтрованное значение сигнала на предыдущем шаге;  $\hat{x}_{ij}$  – фильтруемое значение сигнала;  $K_n, K_d$  – коэффициенты ( $K_n = 0,97, K_d = 0,03$ ).

Задача фильтрации – очистка от шума, выделение «полезного» сигнала для обучения нейронной сети [10].

Данный метод фильтрации временного ряда позволяет улучшить качество нейросетевого прогноза [10].

Массив  $Z$  разбиваем на три множества: обучающее, контрольное и тестовое. Количество данных первого множества выбираем в пределах 50–70 % от исходного. На его основании происходит подстройка синаптических весов нейронной сети. Второе множество – контрольное, на котором при поиске оптимальной структуры выбирается наилучшая модель. Третье множество – тестовое. Итоговая модель проверяется на данных из этого множества, чтобы убедиться, что результаты, достигнутые на обучающем и контрольном множествах, реальны, а не являются артефактами процесса обучения [4].

Отметим, что универсального алгоритма выбора структуры нейросети нет, поэтому подбор количества слоев сети и нейронов в них осуществлялся экспериментально. Основным критерием выбора сети было оптимальное соотношение между временем и ошибкой обучения на обучающем множестве. После экспериментов с обучением различных нейронных сетей была выведена теоретическая кривая соотношения между временем и ошибкой обучения, из которого видно, что при дальнейшем увеличении числа итераций ( $t > t_{opt}$ ), среднеквадратичная ошибка  $\varepsilon$  уменьшается незначительно, а вероятность возникновения явления переобучения сети возрастает [8].

В результате эвристического перебора множества моделей лучшее соотношение показала нейросеть со следующей структурой:

- тип нейронной сети – многослойный персептрон;
- количество слоев – 3;
- количество нейронов во входном слое – 17;
- количество нейронов в скрытом слое – 17;
- количество нейронов в выходном слое – 1;
- алгоритм обучения – метод Левенберга–Марквардта.

Выбранное количество нейронов в первом слое является логичным, т. к. количество входных факторов модели равно 17. Аналогично был выбран один нейрон в выходном слое, отвечающий за вывод нормированного значения средней температуры воды на сливе с прикладных кессонов 1,2 ряда горна печи на  $j + 1$  шаге.

Активационная функция всех нейронов сети – логистическая (сигмоидальная), описываемая следующей формулой:

$$f(s) = \frac{1}{1 + e^{-\alpha \cdot s}}, \quad (3)$$

где  $\alpha$  – параметр наклона логистической функции ( $\alpha = 1$ );  $s$  – взвешенная сумма входов нейрона.

Сигмоидальная функция является гладкой, а ее производная легко вычисляется,

что весьма существенно для алгоритма обучения нейронной сети.

В качестве алгоритма обучения сети выбран метод Левенберга–Марквардта (метод доверительных интервалов), суть которого заключается в минимизации среднеквадратичной ошибки на обучающем множестве посредством подбора весовых коэффициентов и смещений у нейронов [6]. Метод Левенберга–Марквардта – самый быстрый алгоритм обучения, но имеющий ряд важных ограничений:

- применяется только для сетей с одним выходным элементом;
- работает только со среднеквадратичной функцией ошибок;
- требует памяти порядка  $W^2$  (где  $W$  – количество синаптических весов у сети, поэтому для обучения больших сетей он неэффективен) [6].

Накладываемые алгоритмом ограничения приемлемы в контексте поставленной задачи по прогнозированию температурного режима печи.

Формула вычисления среднеквадратичной ошибки имеет вид:

$$\varepsilon = \frac{1}{N} \sum_{i=1}^N (T_{эj} - T_j)^2 \rightarrow \min,$$

где  $T_{эj}$  – экспериментальное значение температуры на  $j$ -м шаге;  $T_j$  – рассчитанное значение температуры на  $j$ -м шаге;  $N$  – объем обучающей выборки (10 000 значений).

Нейронная сеть реализует функцию ре-




Рис. 4. Результат обучения персептрона структуры 17-17-1 (-----) теоретические данные; (—) экспериментальные данные

Таблица 2

## Весовые коэффициенты и смещения нейронов сети

	Номер нейрона скрытого слоя сети																	Номер нейрона выходного слоя сети
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	
$w_1$	1,26	2,6	2,15	-1,96	-0,3	2,06	-14,9	-0,56	1,4	-3,58	4,26	-2,64	0,27	0,95	-4,28	0,4	3,6	2,3
$w_2$	0,33	-2,08	0,94	1,57	-0,76	1,28	-6,74	0,58	1,21	-2,18	1,21	1,51	0,4	-1,56	0,72	3,57	5,39	-2,08
$w_3$	0,34	-2,26	-3,3	-3,21	0,44	-2,29	1,74	0,26	-1,94	1,97	-3,14	-1,19	-0,32	-2,37	-3,61	-2,8	-1,61	-2,22
$w_4$	0,64	0,4	0,36	-1,78	-1,06	2,31	7,51	-1,3	0,53	0,09	6,78	-7,3	4,35	0,17	-1,2	5,14	5,52	0,44
$w_5$	-1,78	-2,14	-1,29	0,74	-1,64	-2,97	-4,39	2,1	-0,51	-3,47	3,6	3,77	-1,9	-3,9	3,92	-0,31	1,14	-2,14
$w_6$	0,2	0,58	-1,03	0,69	0,39	0,44	12,31	-1,78	-0,49	-0,24	2,72	-0,26	-0,07	0,32	-0,12	5,96	4,99	0,58
$w_7$	-0,26	0,16	-0,79	0,6	0,03	0,47	9,5	-1,27	-0,24	-0,61	3,41	0,14	-0,32	0,11	0,2	0,63	2,69	0,1
$w_8$	-3,24	-4,19	2,74	-2,99	-0,78	-0,42	18,54	-2,24	-2,78	-1,59	10,96	-0,3	-5,54	1,17	0,66	0,67	1,56	-2,19
$w_9$	0,96	0,61	-0,89	0,65	1,16	-2,33	1,15	1,73	0,84	2,11	-10,17	0,37	-4,88	-0,64	-0,46	-3,87	3,01	0,61
$w_{10}$	-1,18	-2,02	0,56	0,82	-0,9	0,75	-5,13	1,07	0,98	-1,65	3,08	1,36	-0,82	-1,07	0,62	2,53	6,41	-2,02
$w_{11}$	0,28	-0,05	0,75	-0,68	-0,02	-0,5	-9,22	1,22	0,18	0,68	-3,43	-0,21	0,38	-0,04	-0,24	-5,08	5,38	-0,05
$w_{12}$	2,65	-2,58	3,5	-2,94	3,54	0,59	5,49	-0,75	-1,65	-1,27	-10,81	-2,57	0,44	4,18	-3,06	0,63	0,73	-2,58
$w_{13}$	-3,64	-1,15	1,94	3,22	1,34	-0,07	13,51	-0,09	-0,86	1,75	2,33	-2,7	-3,19	-1,07	-1,47	4,53	4,15	-1,17
$w_{14}$	-3,34	-2,04	0,43	0,27	-1,21	1,52	-2,7	1,52	1,54	-2,96	-2,79	4,24	1,66	-1,15	-1,36	1,61	-2,03	-2,04
$w_{15}$	-1,63	-4,31	1,04	-0,26	0,23	1,98	-17,76	-1,44	0,13	-1,98	-4,02	2,94	-2,16	-2,63	-1,56	3,15	-2,76	-4,31
$w_{16}$	0,53	0,73	1,11	-3,12	-1,37	0,63	-10,63	-3,47	0,86	-3,87	7,15	1,81	3,85	3,87	-2,06	2,98	-2,59	0,71
$w_{17}$	2,65	-0,88	-1,48	0,31	2,22	-2,03	-13,56	-1,19	0,82	0,78	7,84	1,3	4,46	-2,23	2,6	-1,43	3,08	-0,8
$b$	-6,4	-6,5	4,01	4,24	-7,2	-2	-3,02	-8,7	-0,4	-0,8	1,37	11,8	-5	-3,7	-3,5	2,35	0,21	-6,7

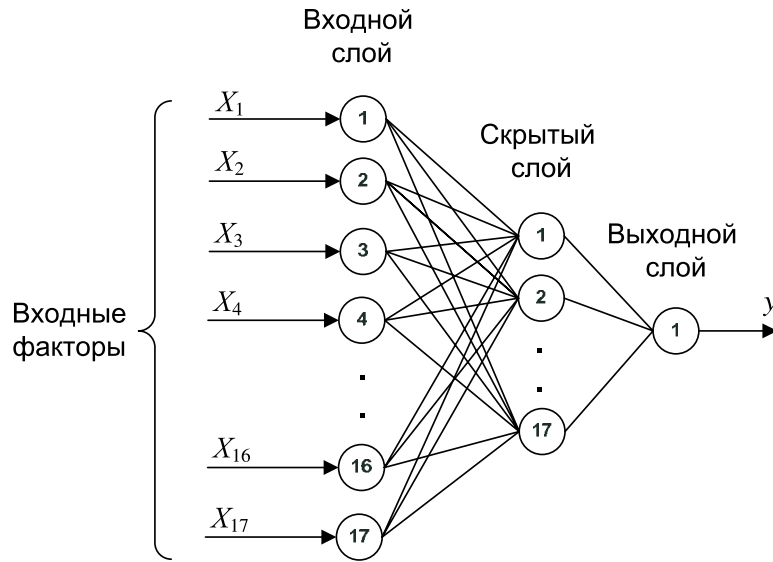


Рис. 5. Внутренняя структура нейроэмулятора

грессии от 17 переменных:  $y_j = f(x_{1j}, x_{2j}, x_{3j}, x_{4j}, \dots, x_{17j})$ .

Время обучения сети на обучающем множестве составило 20 с при 43 эпохах и среднеквадратичной ошибке  $10^{-5}$ . Результаты обучения сети отображены на рис. 4. Отметим совпадение теоретических и экспериментальных данных с заданной ошибкой в широком диапазоне изменения температуры воды на сливе с прикладных кессонов 1, 2 ряда горна печи (от 34 до 40 °С).

В табл. 2 приведены синаптические веса

и смещения нейронов скрытого и выходного слоя сети, полученные в результате обучения. Отметим, что каждый нейрон имеет 17 весовых коэффициентов  $w_{km}$  (где  $k$  – номер нейрона в слое,  $m$  – порядковый номер весового коэффициента нейрона) и одно смещение  $b_k$ , отвечающее за уровень порога активации.

#### Проверка адекватности нейроэмулятора

Структура нейроэмулятора отображена на рис. 5. Математическая модель выпол-




Рис. 6. Экспериментальные и теоретические данные средней температуры воды на сливе с прикладных кессонов 1, 2 ряда горна печи Ванюкова (-----) теоретические данные; (—) экспериментальные данные



нена на базе архитектуры многослойного перцептрона Розенблатта [4] с одним скрытым слоем, в котором количество нейронов равно количеству входных факторов. Нейроны входного слоя сети не участвуют в вычислениях, являясь лишь повторителями сигнала. Весовые коэффициенты таких нейронов равны единице, а смещения – нулю. Выходной слой содержит один нейрон, отвечающий за формирование отклика эмулятора. Нейроны последующего слоя сети связаны с нейронами предыдущего по принципу «каждый с каждым».

Для проверки степени адекватности модели на входы перцептрона подаем нормированный массив данных за один месяц 2010 г. работы ПВ. Полученный вектор значений с выхода модели переводим в реальный диапазон изменения температуры воды на сливе с прикладных кессонов 1, 2 ряда горна ПВ. Экспериментальные  $T_{эi}$  и теоретические данные  $T_{pi}$  показаны на рис. 6. Рассчитанный множественный коэффициент корреляции

$$R^2 = \frac{\sum_{i=1}^N (T_{pi} - \bar{T}_э)^2}{\sum_{i=1}^N (T_{эi} - \bar{T}_э)^2} \approx 0,9$$

( $N = 300$ ) показывает хорошее совпадение экспериментальных и теоретических данных [5, с. 65].

Однако для построения долгосрочного прогноза температуры (к примеру, на 30 мин вперед) необходимо учитывать динамику изменения каждого параметра в отдельности. При этом структура сети значительно усложняется, а время ее обучения увеличивается. Для уменьшения количества весовых коэффициентов сети возможно использование метода редукции, позволяющего исключить синаптические связи между нейронами, которые не влияют на качество прогноза. Это позволит уменьшить время обучения сети, не увеличивая ошибку прогноза.

В результате регрессионного анализа определена степень влияния входных параметров на температурный режим в шахте печи Ванюкова.

Разработан нейроэмулятор теплового режима плавки медно-никелевого сырья в печи Ванюкова.

Проведена экспериментальная проверка адекватности нейроэмулятора.

#### СПИСОК ЛИТЕРАТУРЫ

1. **Ванюков, А.В.** Плавка в жидкой ванне [Текст] / А.В. Ванюков, В.П. Быстров, А.Д. Васкевич. – М.: Металлургия, 1988. – 208 с.
2. **Ванюков, А.В.** Шлаки и штейны цветной металлургии (свойства расплавов и пути снижения потерь металлов со шлаками) [Текст] / А.В. Ванюков, В.Я. Зайцев. – М.: Металлургия, 1969. – 406 с.
3. **Вернигора, А.С.** Влияние технологических режимов плавки медного сульфидного сырья в печи Ванюкова на износ огневой поверхности кессонов: Дис. ... канд. техн. наук [Текст] / А.С. Вернигора. – М., 2009. – 157 с.
4. **Галушкин, А. И.** Нейронные сети: основы применения [Текст] / А.И. Галушкин. – М.: Горячая линия – Телеком, 2012. – 496 с.
5. **Дрейпер, Н.** Прикладной регрессионный анализ [Текст] / Н. Дрейпер, Г. Смит; В 2-х кн. Кн. 1; Пер. с англ. – 2-е изд., перераб. и доп. – М.: Финансы и статистика, 1986. – 366 с.
6. Нейронные сети: STATISTICA Neural Networks: Методология и технологии современного анализа данных [Текст] / Под ред.
- В.П. Боровикова. – 2-е изд., перераб. и доп. – М.: Горячая линия – Телеком, 2008. – 392 с.
7. **Семенова, И.Н.** Разработка системы управления температурным режимом плавки в печи Ванюкова [Текст] / И.Н. Семенова, И.А. Кирпиченков // Цветные металлы. – 2009. – № 5.
8. **Суляев, И.И.** Нейросетевая модель температурного режима плавки медно-никелевого сырья в печи Ванюкова [Текст] / И.И. Суляев, А.И. Писарев // Науч. вестник Норильского индустриального ин-та. – 2013. – Вып. 13.
9. **Тадаусевич, Р.** Элементарное введение в технологию нейронных сетей с примерами программ [Текст] / Р. Тадаусевич, Б. Боровик, Т. Гончаж, Б. Леппер; пер. с польск. И.Д. Рудинского. – М.: Горячая линия – Телеком, 2011. – 418 с.
10. **Тимошенко, А.С.** Препроцессинг, построение и выбор оптимальных нейросетевых моделей в прогнозировании временных рядов [Текст] / А.С. Тимошенко, Л.Н. Ясницкий // Автоматизация и современные технологии.

– 2010. – №6. – С. 16–22.

11. Хайкин, С. Нейронные сети: полный

курс [Текст] / С. Хайкин. – 2-е изд; Пер. с англ.  
– М.: ИД «Вильямс», 2006. – 1104 с.

#### REFERENCES

1. Vaniukov A.V. Plavka v zhidkoi vanne. – Moscow: Metallurgiya, 1988. – 208 s. (rus)
2. Vaniukov A.V. Shlaki i shteyny tsvetnoi metallurgii (svoystva rasplavov i puti snizheniia poter' metallov so shlakami). – Moscow: Metallurgiya, 1969. – 406 s. (rus)
3. Vernigora A.S. Vliianie tekhnologicheskikh rezhimov plavki mednogo sul'fidnogo syr'ia v pechi Vaniukova na iznos ognevoi poverkhnosti kessonov: Dis. ... kand. tekhn. nauk: 05.16.02. – Moscow, 2009. – 157 s. (rus)
4. Galushkin A.I. Neironnye seti: osnovy primeneniia. – Moscow: Goriachaia liniia – Telekom, 2012. – 496 s. (rus)
5. Dreiper N. Prikladnoi regressionnyi analiz. V 2-kh kn. Kn. 1; per. s angl. – 2-e izd., pererab. i dop. – Moscow: Finansy i statistika, 1986. – 366 s. (rus)
6. Neironnye seti: Statistika Neural Networks: Metodologiya i tekhnologii sovremennogo analiza dannykh; pod red. V.P. Borovikova. – 2-e izd., pererab. i dop. – Moscow: Goriachaia liniia – Telekom, 2008. – 392 s. (rus)
7. Semenova I.N. Razrabotka sistemy upravleniia temperaturnym rezhimom plavki v pechi Vaniukova / Tsvetnye metally. – 2009. – № 5. (rus)
8. Suliaev I.I. Neurosetevaia model' temperaturnogo rezhima plavki medno-nikelevogo syr'ia v pechi Vaniukova / Nauchnyi vestnik Noril'skogo industrial'nogo in-ta. – 2013. – Vyp. 13. (rus)
9. Tadausevich R. Elementarnoe vvedenie v tekhnologiiu neironnykh setei s primerami programm; per. s pol'sk. I.D. Rudinskogo. – Moscow: Goriachaia liniia – Telekom, 2011. – 418 s. (rus)
10. Timoshenkov A.S. Preprotssessing, postroenie i vybor optimal'nykh neurosetevykh modelei v prognozirovanii vremennykh riadov / Avtomatizatsiia i sovremennye tekhnologii. – 2010. – № 6. – S. 16–22. (rus)
11. Khaikin S. Neironnye seti: polnyi kurs. – 2-e izd; per. s angl. – Moscow: ID «Vil'iams», 2006. – 1104 s. (rus)

---

**ПИСАРЕВ Александр Иванович** – *заведующий кафедрой электропривода и автоматизации технологических процессов и производств Норильского индустриального института, кандидат технических наук.*

663321, Россия, Норильск, ул. Озерная, д. 21.  
Email: apissarev@yandex.ru

**PISAREV, Alexander I.** *Norilsk Industrial Institute.*  
663321, Ozernaya Str. 21, Norilsk, Russia.  
E-mail: apissarev@yandex.ru

**СУЛЯЕВ Ильгиз Ильгизович** – *аспирант кафедры электропривода и автоматизации технологических процессов и производств Норильского индустриального института.*

663305, Россия, Норильск, ул. Ветеранов, д. 28.  
E-mail: ilgizfinland@mail.ru

**SULYAEV, Ilgiz I.** *Norilsk Industrial Institute.*  
663305, Veteranov Str. 28, Norilsk, Russia.  
E-mail: ilgizfinland@mail.ru