



УДК 681.5

И. И. Суляев
Норильский индустриальный институт

Нейромодель технологического процесса подготовки кислородно-воздушной смеси как объекта управления

Рассматривается задача построения статической математической модели процесса смешения кислорода и воздуха для окислирования сульфидного медно-никелевого сырья в металлургической печи на основе кластерного анализа и теории искусственных нейронных сетей.

Нейромодель, печь Ванюкова, смеситель, нейронная сеть, кластерный анализ, режим

Примером многофакторного объекта цветной металлургии с трудноформализуемыми возмущениями является автогенная плавильная печь Ванюкова (ПВ), предназначенная для переработки медного концентрата и руды, обеднения жидких конвертерных шлаков [1]. В штейно-шлаковой ванне ПВ осуществляется пирометаллургическое разделение шихты, которая интенсивно барботи-

руется кислородно-воздушной смесью (КВС). Недостаток тепла экзотермических окислительных реакций для плавления сырья компенсируется за счет процесса горения подаваемого в печь природного газа. Плавление медно-никелевого сырья относится к процессам со сложной природой физико-химических явлений и структурой связей.

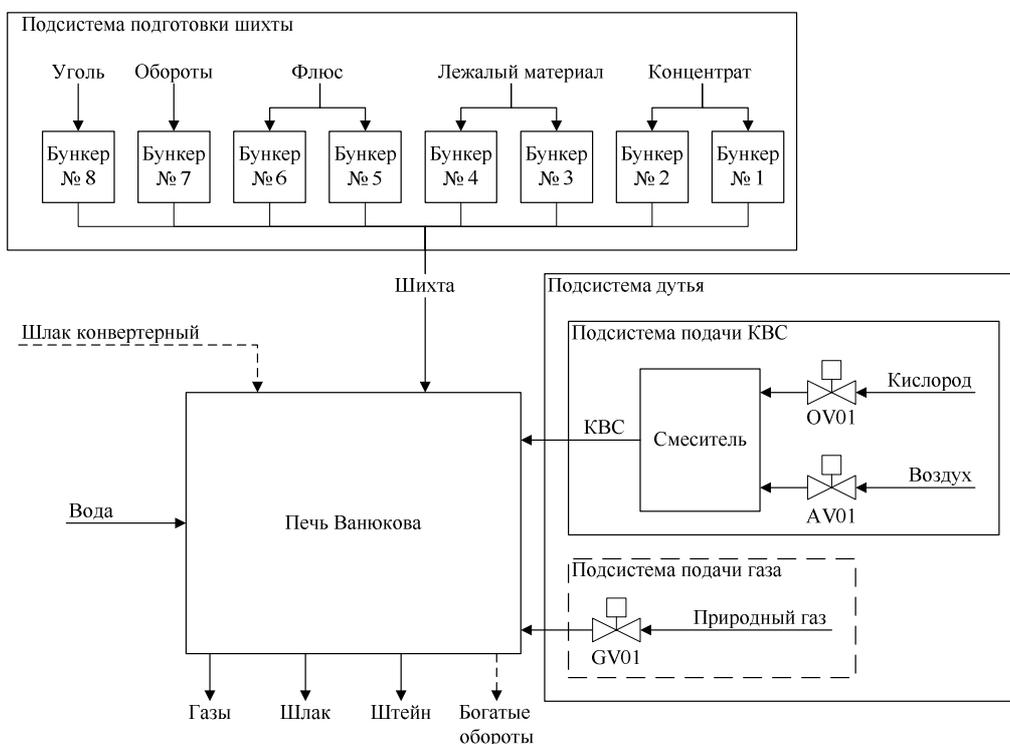


Рис. 1

Конечными продуктами плавки в ПВ являются: жидкий штейн с высокой концентрацией меди (не менее 50 %); бедные по содержанию цветных металлов жидкие отвальные шлаки (объемная доля менее 1 %); богатые по диоксиду серы отходящие газы (объемная доля до 70 %). Качественным показателем ведения процесса Ванюкова является содержание меди в штейне, которое зависит от количества и качества загружаемого материала, расхода энергоресурсов [2].

Схема материальных потоков процесса плавки медно-никелевого сырья в ПВ приведена на рис. 1.

Технологическим узлом печи, отвечающим за подачу КВС, является смеситель, задача которого – подача в печь кислорода и воздуха в заданном соотношении. В смесителе происходит интенсивное перемешивание воздуха и технологического кислорода, при этом на выходе образуется КВС с содержанием кислорода 60–80 %. Окислительное дутье через боковые фурмы печи подается непосредственно в расплав, где участвует в процессах оксидирования шихты.

Необходимые условия устойчивой работы печи: непрерывная загрузка шихты заданного состава; бесперебойная подача дутья фиксированного объема; непрерывный выпуск продуктов плавки в сифоны; постоянство уровней шлаковой и штейновой ванны в плавильной зоне [1]–[3]. Цель управления ПВ – поддержание оптимального химического состава продуктов плавки с минимальными затратами энергии и материальных ресурсов.

Цель статьи – описать разработанную нейросетевую модель смесителя ПВ как объекта управления.

Основным режимным параметром ПВ является расход технологического кислорода, задаваемый в зависимости от остатков концентрата обогатительных фабрик, поступающих на плавку (табл. 1).

Таблица 1

Остатки концентрата, т	Расход кислорода, нм ³ /ч
800...500	12 000
450...300	10 000
300...250	10 000 или остановка печи на 8 ч

На рис. 2 приведены основные переменные, характеризующие процесс перемешивания: вектор управляемых переменных $Y \in \mathbb{R}^4$ (y_1 – давление КВС; y_2 – расход КВС; y_3 – содержание

кислорода в КВС; y_4 – температура КВС); управляющие воздействия $U \in \mathbb{R}^2$ (u_1 – расход технологического кислорода; u_2 – давление воздуха); возмущающие воздействия $F \in \mathbb{R}^5$ (f_1 – расход воздуха; f_2 – давление кислорода; f_3 – температура воздуха; f_4 – содержание кислорода в технологическом кислороде; f_5 – температура кислорода).

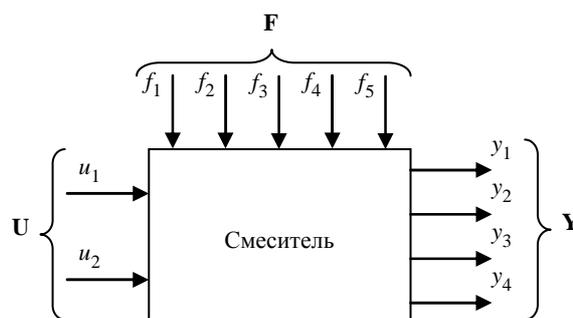


Рис. 2

Корреляционный анализ данных по каналам вход-выход выявляет линейную взаимосвязь между переменными: расход кислорода u_1 – содержание кислорода в КВС y_3 ; давление воздуха u_2 – давление КВС y_1 (табл. 2).

Таблица 2

Входные переменные	Выходные переменные			
	y_1	y_2	y_3	y_4
u_1	0,17	0,71	0,98	-0,92
u_2	0,99	0,50	0,13	-0,05
f_1	0,16	-0,16	-0,83	0,87
f_2	0,98	0,58	0,29	-0,21
f_3	0,12	-0,14	-0,71	0,85
f_4	-0,05	0,07	0,27	-0,28
f_5	-0,19	-0,27	-0,11	0,21

Как видно из анализа коэффициентов корреляции, рассчитанных на всем объеме выборки, содержание кислорода в КВС f_4 и температура технологического кислорода f_5 не являются существенными возмущающими воздействиями для смесителя (табл. 2).

Введем обозначение входных $X = (u_{1j} \ u_{2j} \ f_{1j} \ f_{2j} \ f_{3j})^T$ и выходных $Y = (y_{1j} \ y_{2j} \ y_{3j} \ y_{4j})^T$ данных смесителя, где $j = 1 \dots 100\ 000$. Данные дискретизованы во времени с периодичностью 1 мин.

Смеситель как многорежимный объект управления не удастся описать линейными моделями.

Многомерный нелинейный объект может быть описан, например, в виде полиномов высокой степени, являющихся частным случаем обобщенного полинома Колмогорова–Габора [4], [5]:

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_i a_j x_i x_j + \dots + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_i a_j a_k x_i x_j x_k + \dots$$

Число членов полного полинома равно C_{m+q}^q , где m – число переменных, q – степень полинома, и уже при $n = q = 7$ достигает 3600. В связи с этим основная задача моделирования сложных систем с использованием регрессионных уравнений заключается в том, чтобы исключить в полиноме подмножество «лишних» неинформативных коэффициентов.

Нелинейную статическую модель смесителя предлагается построить на базе искусственной нейронной сети (ИНС) – прямого нейроэмулятора. Достоинствами ИНС являются: высокая эффективность в условиях влияния помех; функционирование с заданной ошибкой прогноза при неполноте входной информации; параллельная обработка данных; отказоустойчивость в случае аппаратной реализации [6].

Решение задачи аппроксимации в нейросетевом логическом базисе предполагает выполнение следующих этапов [7], [8]: сбор и предобработка данных измерений; формирование обучающих последовательностей; выбор архитектуры и алгоритма обучения ИНС. Цель предварительной обработки и кластеризации – формирование представительных обучающих выборок небольшой

размерности. В работах [3], [9] рассматриваются основные этапы препроцессирования обучающих множеств для нейросети: выделение полезного сигнала и удаление недостоверных значений; кластерный анализ; нормирование данных; разбиение данных на обучающее, контрольное и тестовое множества.

Гистограммы частот по расходу технологического кислорода показывают, что объем выборки в 10 000 значений выявляет 2 дутьевых режима (рис. 3, а), а выборка в 100 000 значений – 3 (рис. 3, б). При дальнейшем росте объема выборки количество дутьевых режимов не увеличивается.

В результате предварительной обработки данных (табл. 3) получены выборки X и Y , содержащие 99 750 значений по каждой переменной входа и выхода.

Таблица 3

№	Этапы	Операции
1	Заполнение пропущенных значений	Метод линейной интерполяции
2	Фильтрация	Метод скользящей медианной
3	Удаление выбросов	Правило трех сигм
4	Понижение размерности	Алгоритм k -средних, FCM или сеть Кохонена
5	Нормирование	Приведение к диапазону (0;1)
6	Разбиение на множества	Объем обучающего множества – 70 % от исходного массива, контрольного – 30 %

Кластеризация данных. Большой объем данных отрицательно сказывается на скорости и ошибке обучения сети [7]. Один из выходов – понижение размерности обучающих массивов при сохранении их репрезентативности посредством

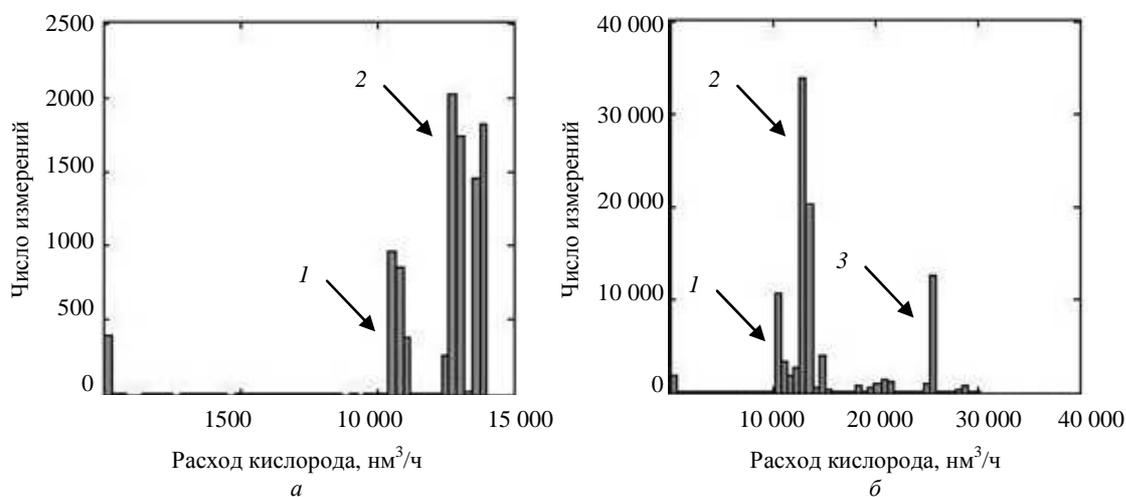


Рис. 3

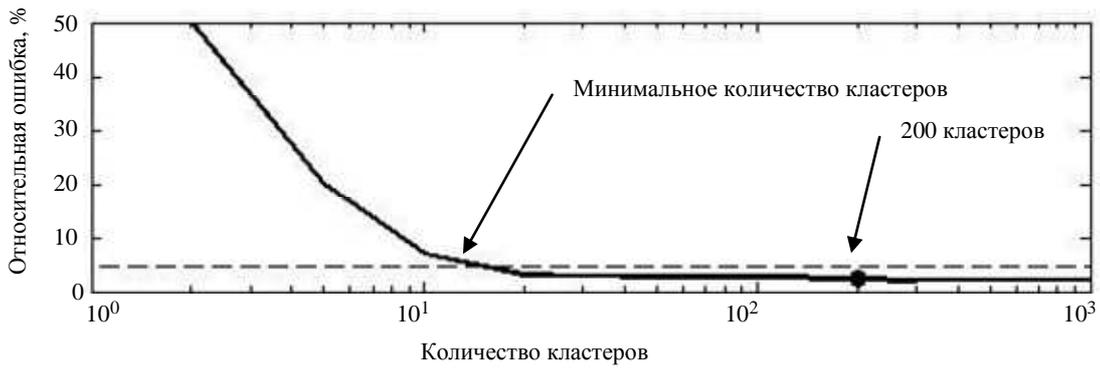


Рис. 4

выделения из них групп (кластеров). Многомерная статистическая процедура компрессии данных позволит упростить структуру и уменьшить время обучения нейроэмулятора.

В качестве методов понижения размерности выбрано 3 алгоритма: k -средних, алгоритм нечеткой кластеризации FCM, сеть Кохонена. Данные алгоритмы кластеризации разбивают множество элементов векторного пространства на заранее известное число кластеров. Количество кластеров выбрано 200, так как при дальнейшем увеличении числа кластерных групп относительная ошибка нейронной сети заданной архитектуры на тестовом множестве уменьшается незначительно. Минимальное количество кластеров определяется при достижении построенной кривой относительной ошибки в 5 %, которая характеризует ошибку измерения параметров датчиками (рис. 4).

Наиболее быстрым является алгоритм k -средних, выделяющий 200 кластеров из исходных данных менее чем за 1 мин. На рис. 5 приведена двумерная кластерная структура нормализованных данных нейроэмулятора при использо-

вании алгоритма k -средних в факторном пространстве – расход технологического кислорода и расход КВС.

Заметим, что скопления кластеров соответствуют трем дутьевым режимам работы печи (рис. 5), что согласуется с гистограммами на рис. 3. Кластеры, расположенные вне указанных групп, характеризуют переходные режимы. Режимы 1 и 2 соответствуют нормальному ходу технологического процесса. Режим 3 отражает работу печи только на технологическом кислороде с целью повышения скорости оксидирования сульфидов в расплаве и максимального извлечения серы из шихты в отходящие газы.

После кластеризации объем данных, используемых для обучения сети, уменьшается в 500 раз.

Обучение нейроэмулятора. Главный недостаток ИНС – отсутствие алгоритма по выбору архитектуры нейронной сети [7]. При выборе числа синаптических весов L_W и нейронов L в скрытых слоях однородных ИНС с сигмоидальными функциями активации можно пользоваться оценочными формулами, которые являются следствием теорем Арнольда–Колмогорова–Хехт-Нильсена [10]:

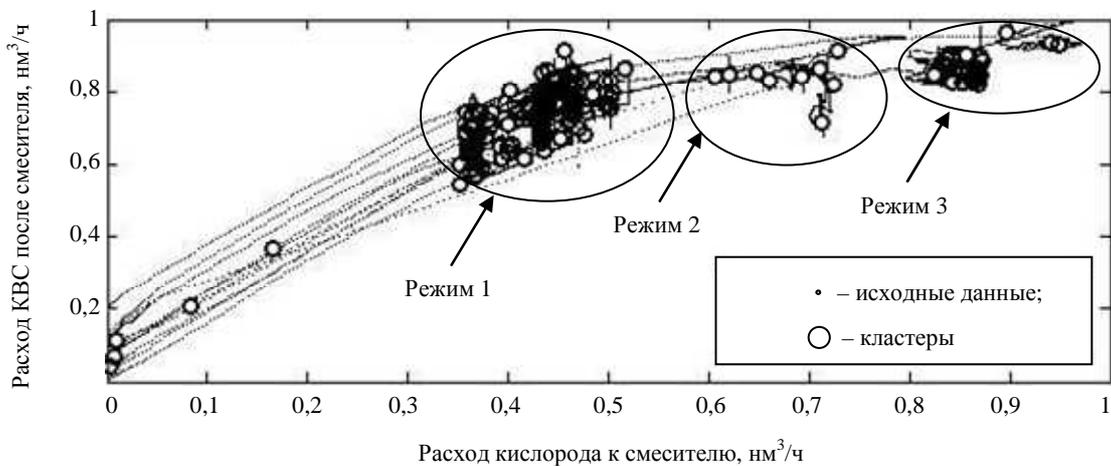


Рис. 5

$$\frac{mN}{1+\log_2 N} \leq L_W \leq m \left(\frac{N}{m} + 1 \right) (n+m+1) + m,$$

$$L = \frac{L_W}{n+m},$$

где n – размерность входного сигнала; m – размерность выходного сигнала; N – число элементов обучающей выборки. При обучении сети на исходной выборке и минимальном количестве синаптических весов потребуется более 2000 нейронов, при обучении на кластеризованных данных – всего 8 нейронов.

Для обучения статической нейромодели массивы \mathbf{X} и \mathbf{Y} , содержащие 200 кластеризованных значений по каждому параметру, разбиваются на 2 подмножества: обучающее и контрольное.

Число нейронов в скрытом слое сети подбирается экспериментально. Количество нейронов при фиксированном объеме обучающего множества является рациональным, если при дальнейшем увеличении числа нейронов относительная ошибка моделирования на тестовом множестве уменьшается несущественно (табл. 4).

Таблица 4

Параметр	Номер эксперимента								
	1	2	3	4	5	6	7	8	9
Количество нейронов	2	3	4	5	6	7	8	9	10
Относительная ошибка, %	6	3	2,5	2	1,5	1,4	1,2	1,2	1,1

Для настройки параметров нейронной сети выбран алгоритм Левенберга–Марквардта. Алгоритм отличается высокой скоростью сходимости,

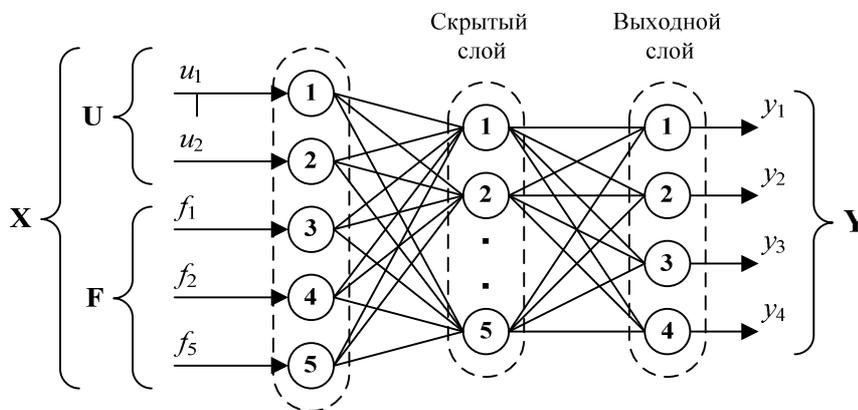


Рис. 6

В качестве нейроэмулятора выбран трехслойный перцептрон с логистическими функциями активаций (рис. 6). Математическая модель выполнена на базе архитектуры многослойного перцептрона Розенблатта [7], [8], [10] с одним скрытым слоем, которая аппроксимирует многомерную нелинейную функцию регрессии $\mathbf{Y} = \Phi(\mathbf{X})$.

но малоэффективен для обучения больших нейросетей, так как требует памяти порядка W^2 , где W – количество синаптических весов [7]. Время обучения сети на обучающем множестве составило 2 с при 20 эпохах и среднеквадратичной ошибке 0,0001. Результаты обучения сети представляют собой матрицы весов и смещений:

$$\mathbf{W}_1 = \begin{bmatrix} 0,3764 & 1,7960 & 0,6404 & -3,3280 & -0,3184 \\ 1,2106 & 8,2101 & -0,1101 & -0,2457 & -8,4412 \\ 0,8218 & -6,2851 & 0,7241 & 0,0672 & 3,9089 \\ -2,7934 & -18,0470 & 0,1238 & 0,5610 & 18,4937 \\ -0,2510 & -0,3423 & -0,0815 & 0,0324 & 0,3029 \end{bmatrix}; \mathbf{B}_1 = \begin{bmatrix} -16,1957 \\ -1,0588 \\ 4,9343 \\ 1,0199 \\ 0,6199 \end{bmatrix};$$

$$\mathbf{W}_2 = \begin{bmatrix} -4,8228 & 5,4683 & -117,4023 & 6,7185 & -64,2372 \\ -0,6146 & -24,8664 & 31,8201 & -2,7324 & -140,8641 \\ 1,7405 & 441,8108 & -12,0477 & 179,9799 & -176,4959 \\ 1,0545 & -158,1036 & 10,8440 & -53,3126 & 8,8541 \end{bmatrix}; \mathbf{B}_2 = \begin{bmatrix} 149,8788 \\ 64,8677 \\ -120,3691 \\ 63,0738 \end{bmatrix}.$$

Для проверки степени адекватности модели на входы персептрона подаем нормированный массив данных за месяц работы печи (тестовое множество). Полученный вектор значений с выхода модели переводим в реальный диапазон изменения параметров. Средняя относительная ошибка на тестовом множестве для каждого выходного параметра смесителя не превышает 4 %.

Таким образом, разработана статическая нейромодель смесителя печи Ванюкова как объекта управления, которая учитывает возможные дутьевые режимы работы металлургического агрегата.

Предобработка данных, корреляционный и кластерный анализ существенно упрощают структуру модели и уменьшают время обучения. Простая архитектура модели позволит реализовать ее программно в контроллерах промышленного назначения. Вместе с тем, анализ реакции сети на тестовые последовательности выявляет сдвиг во времени между теоретическими и экспериментальными данными. Можно сделать вывод о том, что для идентификации смесителя как объекта управления целесообразно использовать динамические модели.

СПИСОК ЛИТЕРАТУРЫ

1. Ванюков А. В., Быстров В. П., Васкевич А. Д. Плавка в жидкой ванне. М.: Металлургия, 1988. 208 с.
2. Спесивцев А. В. Металлургический процесс как объект изучения: новые концепции, системность, практика. СПб.: Изд-во Политехн. ун-та, 2004. 307 с.
3. Суляев И. И., Писарев А. И. Нейроэмулятор температурного режима плавки медно-никелевого сырья в печи Ванюкова // Науч.-техн. ведомости СПбГПУ. 2013. № 4 (176). С. 55–65.
4. Эйкхофф П. Основы идентификации систем управления. М.: Мир, 1975. 683 с.
5. Gabor D., Wilby W. P. L., Woodcock R. A Universal Nonlinear Filter, Predictor and Simulator which Optimizes Itself by a Learning Process // Proc. IEE. 1961. 108B. P. 422–438.
6. Чернодуб А. Н., Дзюба Д. А. Обзор методов нейроуправления // Проблемы программирования. 2011. № 2. С. 79–94.
7. Нейронные сети: STATISTICA Neural Networks: Методология и технологии современного анализа данных / под ред. В. П. Боровикова. 2-е изд., перераб. и доп. М.: Горячая линия-Телеком, 2008. 392 с.
8. Тимошенко А. С., Ясницкий Л. Н. Препроцессинг, построение и выбор оптимальных нейросетевых моделей в прогнозировании временных рядов // Автоматизация и современные технологии. 2010. № 6. С. 16–22.
9. Костин Е. В. Подготовка статистических данных для построения нейросетевой модели процесса плавки в печах Ванюкова // Науч. вестн. Норильского индустриального ин-та. 2011. Вып. 8. С. 45–49.
10. Круглов В. В., Дли М. И., Голунов Р. Ю. Нечеткая логика и искусственные нейронные сети. М.: Физматлит, 2001. 224 с.

I. I. Sulyaev
Norilsk Industrial Institute

TECHNOLOGICAL PROCESS NEUROMODEL OF OXYGEN-AIR MIXTURE PREPARATION AS CONTROL OBJECT

The article deals with the static mathematical model construction task of oxygen and air mixing process for sulfide copper-nickel raw materials oxidation in metallurgical furnace based on cluster analysis and artificial neural networks theory.

Neuromodel, Vanyukov furnace, mixer, neural network, cluster analysis, mode