

УДК 004.896

Н.А. ГОЛОВКО, аспирант, ФГБОУ ВПО "МГТУ им. Г.И. Носова",
Магнитогорск,

О.С. ЛОГУНОВА, д-р техн. наук, проф., ФГБОУ ВПО "МГТУ
им. Г.И. Носова", Магнитогорск

ОЦЕНКА АРХИТЕКТУРЫ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ МОДЕЛИРОВАНИЯ ПРОЦЕССА НАГРЕВА СТАЛЬНОЙ ПОЛОСЫ НА АГРЕГАТЕ НЕПРЕРЫВНОГО ГОРЯЧЕГО ЦИНКОВАНИЯ

В работе приведены результаты построения имитационной модели, описывающей процесс нагрева стальной полосы в отделении нагрева агрегата непрерывного горячего цинкования (АНГЦ). Для построения модели использована технология искусственных нейронных систем. Предложенная модель позволит учесть многозонную структуру агрегата и сложные нелинейные зависимости между параметрами зоны. Ил.: 3. Табл.: 1. Библиогр.: 8 назв.

Ключевые слова: агрегат непрерывного горячего цинкования, процесс нагрева, искусственная нейронная сеть, имитационная модель.

Анализ литературы и постановка проблемы. За последние 10 лет отмечено снижение срока службы стальных изделий во всех сферах применения, обусловленное повышенной коррозионной активностью сред, в которых они эксплуатируются. Процесс горячего цинкования приводит к расширению области применения металлических изделий в активных средах. По этой причине наблюдается увеличение спроса на оцинкованные изделия до 7 млн. т в год. В условиях ОАО "Магнитогорский металлургический комбинат" (ОАО "ММК") процесс цинкования осуществляется на агрегатах непрерывного горячего цинкования (АНГЦ).

В основе процесса горячего оцинкования лежит принцип распределенной во времени и пространстве термической обработки изделий. Качество получаемой продукции и эффективность технологических процессов определяются стабильностью поддержания параметров нагрева изделия: скорость протягивания полосы и температурный режим в зонах. Для решения задач выбора и поддержания рационального режима работы АНГЦ требуется создание математической модели, способной адекватно в реальном времени описывать протекающие в печи и на агрегате динамические процессы. Так как многозонные печи являются тепловыми объектами с распределенными параметрами, то модель динамики должна отражать изменение температуры во времени в каждой точке печи.

Частным случаям создания математических моделей посвящено множество работ: Аптермана В.Н., Еринова А.Е., Иванова И.А., Гельмана Г.А., Лисовского С.И. [1 – 5]. Так в работе Г.А. Гельмана [4] изложена методика построения математической модели тепловой работы протяжной печи. В основу модели положены уравнения теплового баланса зон камеры нагрева. Предложенная модель лишена свойств адаптации для учёта и компенсации возмущений. Подробный анализ модели, приведенной в [5, 6], показывает, что недостаточная изученность процесса теплопереноса движущихся тел, сложность получающихся систем дифференциальных уравнений и систем эмпирических взаимосвязанных уравнений, имеющих высокую размерность, вынуждает исследователя прибегать к абстрагированию и упрощать математическую формулировку задачи [5], теряя конструктивные особенности агрегатов. В связи с этим до настоящего времени остаются актуальными следующие проблемы:

- существующее математическое описание процесса не учитывает многозонную конструкцию построения агрегатов;

- настройка и регулирование процесса отжига на агрегате производится оператором на основании субъективных знаний технологов о протекании процесса оцинкования полосы.

Указанные проблемы определили цель научного исследования.

Цель научного исследования – уменьшение доли некондиционной продукции горячего цинкования в условиях энергосберегающего режима протекания процесса термохимического отжига за счет создания для системы управления имитационной модели, описывающей процесс нагрева полосы и учитывающей зональную конструкцию АНГЦ на основе системы искусственных нейронных сетей.

Описание структура агрегата АНГЦ и задач моделирования. Агрегат цинкования, функционирующий в условиях ОАО "ММК", имеет многозонную структуру (рис. 1). Для учета сложной структуры агрегата предлагается использовать математическое описание, основанное на ИНС, которое позволяет осуществить многопараметрический прогноз, выполнять оперативное прогнозирование в течение 5 минут (при полном времени цикла 30 – 40 минут), решать слабо формализованные задачи, выполнять дообучение, самоадаптацию, обобщение на основе ранее полученных знаний и учитывать температурную историю предыдущих зон.

Сравнительный анализ нейросетевых архитектур показал, что целесообразно в решении поставленной задачи использовать полносвязную нейронную сеть прямого распространения – *Multi Layer*

Perceptron (MLP). Предложено каждый из участков протяжной печи представить в виде отдельно взятой нейронной сети. На вход каждой из ИНС подаются средние значения технологически параметров в зоне за N отрезков времени, на выходе сети снимается прогноз по температуре.

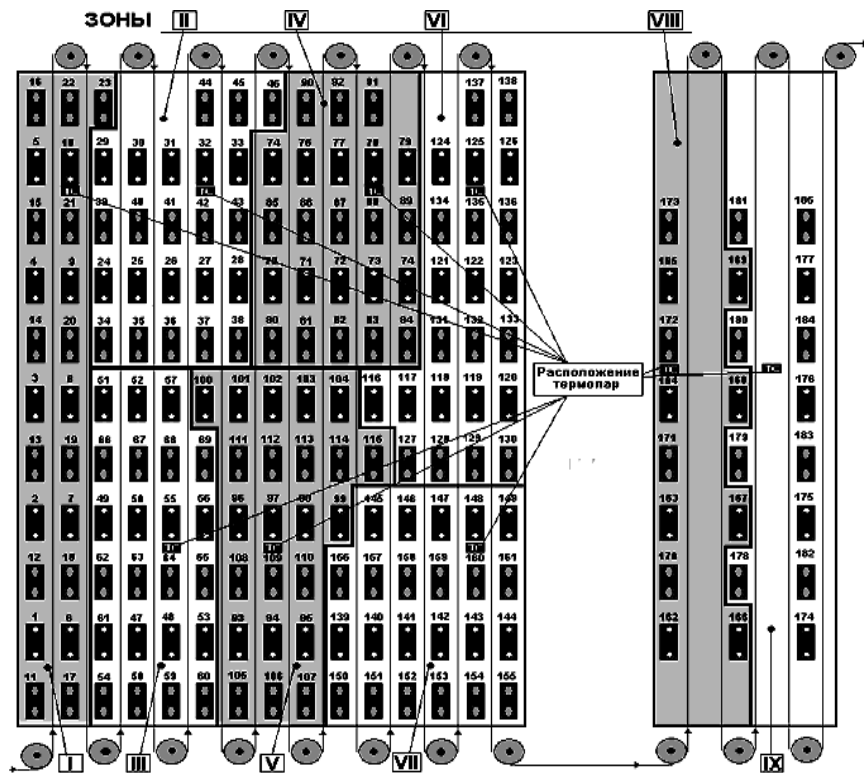


Рис. 1. Схема расположения технологических зон отжига полосы и термопар по металлургической длине АНГЦ

Разработка и практическая реализация нейросетевой модели.

Для обучения модели на основе промышленных данных за два года после обработки была получена равномерная выборка данных за 227 дней. В итоге была получена обучающая выборка из 32768 наборов. Для целей обучения и тестирования данная выборка была разделена на две части по 16384 набора в каждой.

Эмпирическим путем было выявлено, что целесообразно использовать для нейросетевой модели входной вектор размерностью 20

элементов – 7 средних температур за 10 и 20 мин, средние скорости за 5, 10, 15 мин и средняя толщина и ширина за 15 мин, и марка стали.

Для определения оптимальной внутренней структуры ИНС был применен алгоритм *Optimal Brain Damage (OBD)* редукции сети, где в качестве меры значимости веса используется показатель асимметрии, определяемый выражением:

$$S_{ij} = \frac{1}{2} \frac{\partial^2 E}{\partial w_{ij}^2} w_{ij}^2, \quad (1)$$

где S_{ij} – показатель асимметрии веса нейрона с номером i в слое j ; E – целевая функция (функция погрешности), к минимизации которой стремится тот или иной алгоритм обучения; w_{ij} – значение веса.

В соответствии с данной методикой синтезируется искусственная нейронная сеть с заданым числом нейронов в скрытых слоях, затем размерность слоев понижается путем отбрасывания нейронов с наименьшими показателями асимметрии.

На основании редукции были получены принципиально две архитектуры сетей – 20-26-1 (20 нейронов во входном слое, 26 – нейронов в скрытом слое и 1 – в выходном слое) и 20-32-8-1 (20 нейронов во входном слое, 32 – в первом скрытом слое, 8 – во втором скрытом слое и 1 – в выходном слое).

Синтезированные сети обучались методом модифицированного обратного распространения ошибки – *RPROP (resilient backpropagation)*, основанном на поведении градиентов целевой функции ошибки обучения сети. Приращение для каждого веса вычисляется индивидуально на каждом шаге итерации по (2) в соответствии с убыванием градиента целевой функции ошибки обучения сети:

$$\Delta_{ij}^t = \begin{cases} \min(\Delta_{ij}^t \times S^+, \Delta_{\max}), & \text{если } \frac{\partial \varepsilon^{t-1}}{\partial w_{ij}} \times \frac{\partial \varepsilon^t}{\partial w_{ij}} > 0; \\ \max(\Delta_{ij}^t \times S^-, \Delta_{\min}), & \text{если } \frac{\partial \varepsilon^{t-1}}{\partial w_{ij}} \times \frac{\partial \varepsilon^t}{\partial w_{ij}} < 0; \\ \Delta_{ij}^t, & \text{если } \frac{\partial \varepsilon^{t-1}}{\partial w_{ij}} \times \frac{\partial \varepsilon^t}{\partial w_{ij}} = 0, \end{cases} \quad (2)$$

где Δ_{ij}^t – величина приращения веса для нейрона с номером i в слое j ; S^- – усиливающий фактор $0 < S^- (= 0,5) < 1 < S^+ (= 1, 2)$, $\partial \varepsilon^{t-1}$ – приращение

ошибки обучения на предыдущем шаге, $\partial \varepsilon^t$ – приращение ошибки обучения на текущем шаге, ∂w_{ij} – приращение веса нейрона i в слое j .

Величина приращения усиливается фактором, когда алгоритм сходится к минимуму и производная не меняет знак. Это ускоряет процесс на плоских участках и замедляет в случае пропуска локального минимума. Значение весов модифицируется в соответствии с направлением убывания градиента по (3):

$$\Delta w_{ij}^t = \begin{cases} \Delta_{ij}^t \times \text{sign} \left[\frac{\partial \varepsilon^t}{\partial w_{ij}} \right] \times \eta \times o_i, & \text{если } \frac{\partial \varepsilon^t}{\partial w_{ij}} \times \frac{\partial \varepsilon^{t-1}}{\partial w_{ij}} \geq 0; \\ -\Delta_{ij}^t \times \eta \times o_i, & \text{если } \frac{\partial \varepsilon^t}{\partial w_{ij}} \times \frac{\partial \varepsilon^{t-1}}{\partial w_{ij}} = 0, \end{cases} \quad (3)$$

где η – параметр, определяющий скорость обучения; o_i – значение на выходе i -го нейрона.

Если производная ошибки изменяет знак, то происходит возврат к предыдущему значению веса. Результаты обучения представлены на рис. 2, 3 и в табл. Анализ результатов показал высокое качество получаемого прогноза и соответствие опытных данных и данных с модели ИНС участка нагрева. Значения коэффициентов корреляции являются значимыми на 5 % уровне по критерию Стьюдента.

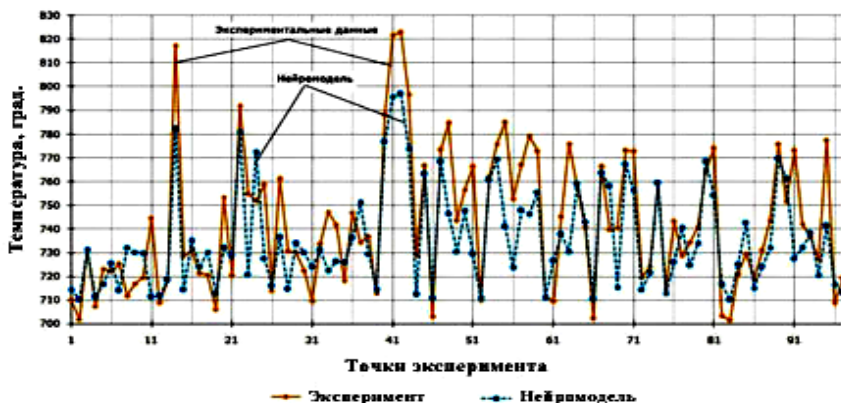


Рис. 2. Результаты обучения нейросетевой модели 20–26–1

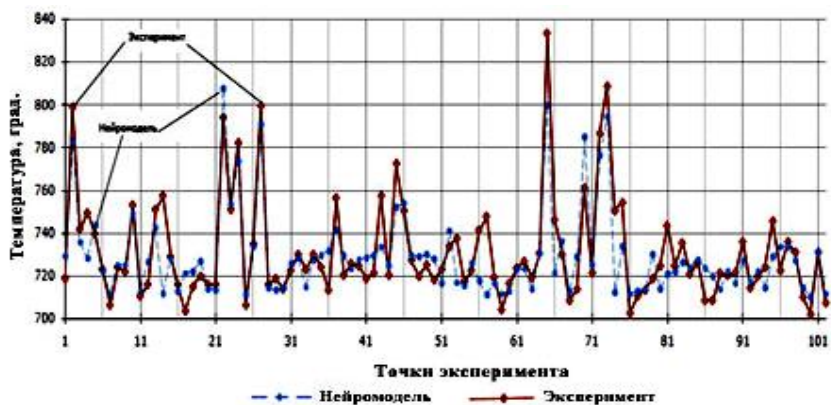


Рис. 3. Результаты обучения нейросетевой модели 20-32-8-1

Таблица

Оценка результатов обучения нейронных сетей 20-26-1 и 20-32-8-1

Эпохи	Показатели	Архитектура сти	
		20-26-1	20-32-8-1
5000	Средняя квадратическая ошибка, °С	20,38	21,44
	Коэффициент корреляции	0,89	0,82
	Средняя относительная ошибка аппроксимации, %	2,03	2,15
6000	Средняя квадратическая ошибка, °С	20,04	20,56
	Коэффициент корреляции	0,90	0,88
	Средняя относительная ошибка аппроксимации, %	2	2,06
7000	Средняя квадратическая ошибка, °С	20,47	20,98
	Коэффициент корреляции	0,90	0,89
	Средняя относительная ошибка аппроксимации, %	2,05	2,1

Выводы. Таким образом, полученные характеристики нейронных сетей позволили определить рациональную архитектуру нейросетевой модели протяжной печи, достаточную для описания процесса нагрева стальной полосы с учетом многозонной структуры агрегата и наличия многосвязных зависимостей и имеющую наибольшее быстродействие при прогнозировании температуры на выходе участка нагрева протяжной печи агрегата непрерывного горячего цинкования.

Список литературы: 1. Антерман В.Н. Протяжные печи / В.Н.Антерман, В.М. Тымчак. – М.: Металлургия, 2000. – 320 с. 2. Еринов А.Е. Промышленные печи с радиационными трубами / А.Е. Еринов, А.М. Семернин. – М.: Металлургия, 2001. – 280 с. 3. Гельман Г.А. Автоматизация тепловых режимов протяжных печей / Г.А. Гельман. – М.: Металлургия, 2000. – 112 с. 4. Иванов И.А. Регулирование тепловых металлургических процессов

/ И.А Иванов, С.И. Лисовский. – М.: Металлургия, 2001. – 300 с. 5. Хайкин С. Нейронные сети: полный курс. Пер. с англ. / С. Хайкин. – М.: ООО И.Д. Вильямс, 2006. – 1104 с. 6. Уоссермен Ф. Нейрокомпьютерная техника / Ф. Уоссермен. – М.: Мир, 2002. – 150 с. 7. Логовский А.С. Применение искусственных нейронных сетей для решения задач управления динамическими объектами / А.С. Логовский. – М.: Финансы и статистика, 2007.– 350 с. 8. Круглов В.В. Искусственные нейронные сети. Теория и практика / В.В. Круглов, В.В. Борисов. – М.: Горячая линия. – Телеком, 2002. – 382 с.

УДК 004.896

Оцінка архітектури штучних нейронних мереж для моделювання процесу нагріву сталевий смуги на агрегати безперервного гарячого цинкування / Головко Н.А., Логунова О.С. // Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2012. – № 62 (968). – С. 33 – 39.

В роботі наведені результати побудови імітаційної моделі, яка описує процес нагріву сталевий смуги у відділенні нагріву агрегату безперервного гарячого цинкування. Для побудови моделі використана технологія, що заснована на використанні штучних нейронних мереж. Запропонована модель дозволить врахувати багатозонну структуру агрегату і складні нелінійні залежності між параметрами зони. Ил.: 3. Табл.: 1. Библиогр.: 8 назв.

Ключові слова: агрегат безперервного гарячого цинкування, процес нагріву, штучна нейронна мережа, імітаційна модель.

UDC 004.896

Evaluation of artificial neural net architecture characteristics for the purpose of modeling the process of steel strip heating during continuous hot galvanizing / Golovko N.A., Logunova O.S. // Herald of the National Technical University "KhPI". Subject issue: Information Science and Modelling. – Kharkov: NTU "KhPI". – 2012. – №. 62 (968). – P. 33 – 39.

Article presents the results of a simulation model describing the process of steel strip heating on the heating department of continuous hot-dip galvanizing. The model is based on the principle of artificial neural systems. The proposed model will take into account the multiband structure of the unit and the complex nonlinear relationship between the parameters of the zone. Figs.: 3. Tabl.: 1. Refs.: 8 titles.

Keywords: department of continuous hot-dip galvanizing, process of steel strip heating, an artificial neural network, a simulation model.

Поступила в редакцію 22.07.2012