УДК 622.7: 681.51

А.И. КУПИН, канд. техн. наук, Криворожский технический университет, г. Кривой Рог

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ ПОКАЗАТЕЛЕЙ ОБОГАЩЕНИЯ МАГНЕТИТОВЫХ КВАРЦИТОВ

На підставі сучасної технології нейромережевої емуляції проведено побудову однокрокових та багатокрокових предикторів у базисі моделей NNARX, NNOE. Проведено ідентифікацію залежностей зміни базових параметрів окремих стадій технологічного процесу збагачення магнетитових кварцитів. Наведено результати прогнозування якісних показників збагачення.

On the basis of modern technology of neural network emulation construction single-step and multistage predictors in basis of models NNARX, NNOE is made. Approximation of dependences of change of base parameters of separate stages of technological process of enrichment quartzites of magnetite is made. Results of forecasting of quality indicators of enrichment are resulted.

В условиях сегодняшнего энергетического кризиса в Украине довольно актуальной проблемой остается высокая энергоемкость технологических процессов (ТП) при добыче полезных ископаемых и их переделе (обогащении). При этом качество конечной продукции (концентрата, агломерата, окатышей) отечественных горно-обогатительных комбинатов (ГОКов) пока что ниже, чем даже у ближайших конкурентов (России, Швеции и др.), а потери передела несколько выше [1]. Например, содержание основного полезного компонента (железа общего) в концентрате ГОКов Кривбасса составляет в среднем 64 – 66 % (аналогичный показатель у конкурентов не ниже 68 – 69 %). Все эти факторы отрицательно влияют на конкурентоспособность отечественных предприятий, особенно на международном рынке.

Анализ причин такого явления свидетельствует, что одним из наиболее влиятельных факторов является сравнительно более низкий уровень автоматизации, мониторинга и информатизации основных технологических процессов отечественных обогатительных фабрик и производства в целом. Сказывается отсутствие (либо чрезвычайная дороговизна) современных приборов необходимой точности и дискретности (прежде всего спектрального типа) для измерения состава полезного компонента в пульпе, исходной руде и хвостах, определения грансостава, а также плотномеров, бесконтактных уровнемеров и т.д. Это затрудняет оперативность принятия решений, прежде всего со сто-

роны технологов и обогатителей. В связи с этим, усовершенствование информационного обеспечения процессов обогащения остается достаточно перспективным вектором инновационного развития предприятий ГМК Украины. И в первую очередь это касается решений, которые не требуют значительных первичных капиталовложений. По мнению автора здесь следует обратить внимание на необходимость внедрения информационных компьютеризированных систем прогнозирования основных показателей локальных процессов обогащения, в частности, с использованием регрессионных моделей, технологий искусственного интеллекта (например, нейро-нечетких [2] и др.).

На начальных этапах автоматизации это может быть создание и внедрение систем поддержки принятия решений (СППР), которые позволяют с достаточной точностью прогнозировать изменение качественных показателей обогащения в зависимости от априорной и управляющей информации. Практика показывает, что такие системы достаточно эффективно реализуются на основе современных информационных технологий. Создание достоверных прогнозирующих моделей является также первым шагом при синтезе более сложных регуляторов для автоматизированных систем управления технологическими процессами (АСУТП) обогащения.

Среди исследований подобных интеллектуальных систем известны разработки Л.П. Шупова 80-х гг. (т.н. «советчики технолога») и системы прогнозирования технологических показателей (например, на основе регрессионных моделей – работы А.Н. Марюты, Е.В. Кочуры, Ю.Г. Качана, В.А. Воронова, Н.Е. Бойцун, М.В. Назаренко и др.) [3 – 5]. Однако, в силу разных причин, данные разработки до сих пор не нашли должного применения на практике.

Известно, что технологические процессы обогащения магнетитовых кварцитов являются достаточно сложными объектами для формализации и идентификации. Это обусловлено их стохастическими свойствами, нестационарностью, большим временным запаздыванием и рядом других факторов. В связи с этим усложняются этапы формализации ТП и построения математического описания (идентификационной модели) объекта.

Многими исследованиями доказано, что наиболее качественная идентификация производственных и технологических систем обеспечивается использованием статистических методов (например, функций автокорреляции и авторегрессии [3 – 5 и др.]). Безусловными преимуществами их является простота реализации, а также то, что проверка их адекватности довольно легко может осуществляться путем исследования частотных характеристик и спек-

трального анализа. Вместе с этим, как указано в [3], использование статистических подходов не всегда обеспечивает точность идентификации моделей сложных нелинейных объектов. Известной альтернативой этому есть применение нейро-нечетких (интеллектуальных) методов.

Учитывая указанные факторы, для идентификации ТП обогащения и прогнозирования в условиях рудообогатительных фабрик ГОКов был выбран нейросетевой подход, который, согласно предварительному анализу, должен обеспечить необходимое качество модели.

В соответствие с этой схемой будем рассматривать ТП обогащения как многомерную дискретную систему типа:

$$Z^P = \{[u(k), y(k)], \quad k = \overline{1, N}\}, \tag{1}$$

где P – порядок системы; $u(k)$ – вектор сигналов управления на входе; $y(k)$ – вектор сигналов на выходе системы; N – максимальное количество дискретных отсчетов наблюдения.

Согласно [2] в процессе обогащения магнетитовых кварцитов в условиях современных рудообогатительных фабрик необходимо контролировать такое множество факторов:

$$Z^P = \{\overline{\sim}, \overline{¶}, \bar{g}, d_0, Q_0, \overline{Q}, \bar{d}, \overline{P}_m, \overline{°}_к, \overline{°}_c, \overline{\ }_{пп}, \overline{\ }_{хв}, \ \ _к, \overline{¥}, \overline{¥}_к, \overline{£}, \overline{£}_к\},$$

где $\overline{\sim} = \{\sim_i\}, \quad i = 1...N_r$ - содержание полезного компонента в исходной руде (шихте); N_r - количество промышленных разновидностей в шихте; $\overline{¶} = \{¶_i\}$ - плотность соответствующих разновидностей; $\bar{g} = \{g_i\}$ - доли (соотношение) разновидностей в шихте; d_0 – усредненная крупность руды перед обогащением; Q_0 – подача руды на 1-й стадии обогащения; $\overline{Q} = \{Q_j\}, \quad j = 1...N_s$ - переработка на каждой стадии обогащения; N_s – количество стадий обогащения; $\bar{d} = \{d_j\}$ - усредненная крупность продукта после каждой (j-й) стадии обогащения; $\overline{P}_m = \{P_{m\,j}\}$ - содержание твердого при измельчении; $\overline{°}_к = \{°_{к\,j}\}$ - плотность пульпы перед классификацией; $\overline{°}_c = \{°_{c\,j}\}$ - плотность пульпы перед магнитной сепарацией; $\overline{\ }_{пп} = \{\ _{пп\,j}\}$ - постадийное содержание полезного в промышленном продукте; $\overline{\ }_{хв} = \{\ _{хв\,j}\}$ - потери полезного в хвостах; $\ _к$ - качество концентрата; $\overline{¥} = \{¥_j\}$ - выход полезного в

промпродукте; ¥$_к$ - выход полезного в концентрате; £ = {£$_j$} - извлечение полезного в промпродукте; £$_к$ - извлечение полезного в концентрате.

В общем случае математические модели (иначе аппроксиматоры, предикторы или регрессоры), основанные на искусственных нейронных сетях (нейроэмуляторах – рис.1), представляются нелинейным уравнением типа:

$$\hat{y}(k+1) = NN\big(y(k), y(k-1),..., y(k-l_1), u(k), u(k-1),..., u(k-l_2)\big), \qquad (2)$$

где $\hat{y}$ – вектор сигналов на выходе идентификационной модели; $NN(\cdot)$ – результирующее преобразование типа „вход-выход", которое выполняется нейросетью; l_1 – глубина задержки обратной связи на выходе модели; l_2 – глубина задержки на входе.

Это простейший одношаговый предиктор или NNARX – модель (Neural Network based AutoRegressive eXogenous signal - нейросетевая авторегрессионная модель, экзогенный тип сигналов). Такой предиктор позволяет делать прогноз на один шаг вперед (рис. 1).

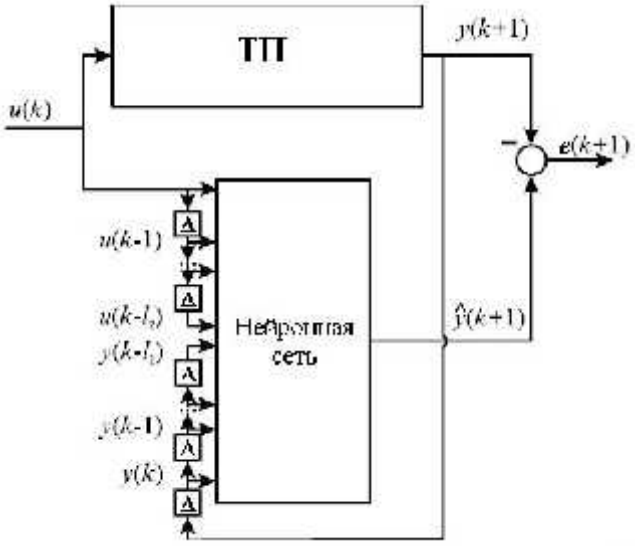

Рис. 1. Структурная схема одношагового нейроэмулятора типа NNARX[6]

Различают также модели нейронных регрессоров [6 – 7], позволяющие делать многошаговые прогнозы (краткосрочные предикторы, см. рис. 2).

Одной из таких моделей является NNOE (Neural Network Output Error – нейросетевая модель ошибки выхода), которая представляется рекурсивным уравнением вида:

$$\hat{y}(k+1) = NN\big(\hat{y}(k), \hat{y}(k-1),..., \hat{y}(k-l_1), u(k), u(k-1),..., u(k-l_2)\big). \qquad (3)$$

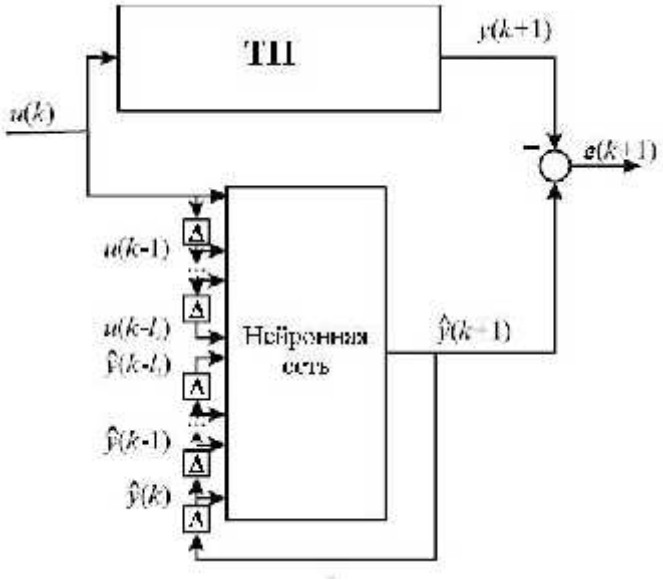

Рис. 2. Структурная схема краткосрочного предиктора типа NNOE[6]

Разновидностью NNARX-модели, предназначенной для идентификации объектов с высоким уровнем шумов, являются модели семейства NNARMAX (Neural Network based AutoRegressive, Moving Average, eXogenous signal - нейросетевая авторегрессионная модель скользящего среднего, экзогенный тип сигналов). Уравнение этой модели имеет вид:

$$\hat{y}(k+1) = NN\big(y(k), y(k-1),..., y(k-l_1), u(k),..., u(k-l_2), \text{£}(t),..., \text{£}(k-l_3)\big),$$

где $\text{£}(k) = y(k) - \hat{y}(k)$ - ошибка прогнозирования; l_3 – глубина задержки по ошибке.

Наибольшее распространение в настоящее время получили NNARX и NNOE модели. Согласно [7] их рекомендуется применять в случае ограниченного набора входной статистики (например, при создании АСУТП).

В качестве модельной структуры аппроксиматора будем рассматривать такие альтернативы (рис. 3):

1) сеть прямого распространения с одним скрытым слоем;

2) сеть радиально-базисной структуры;

3) полносвязная рекуррентная сеть.

Согласно предпосылкам, изложенным в [6, 7], именно эти нейросетевые структуры являются довольно эффективными для моделирования ТП.

Прямонаправленные многослойные и полносвязные рекуррентные сети реализуют простейшую модель нейрона (рис. 4).

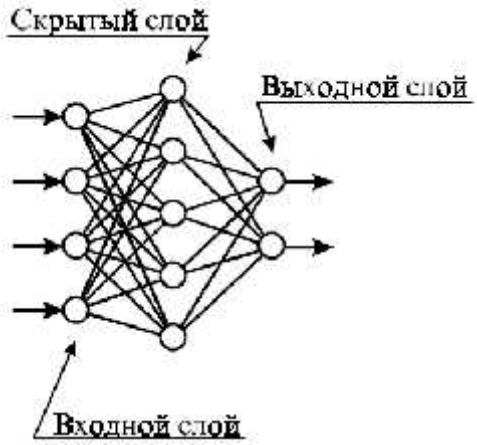

а)

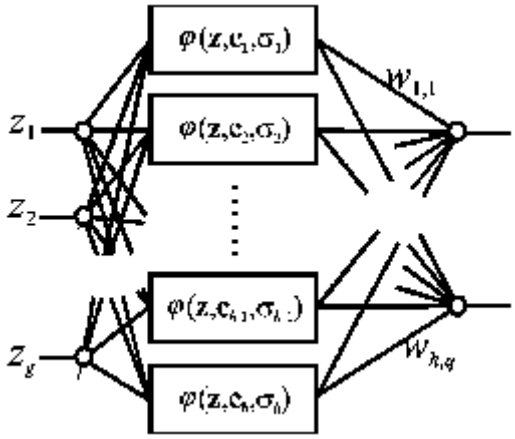

б)

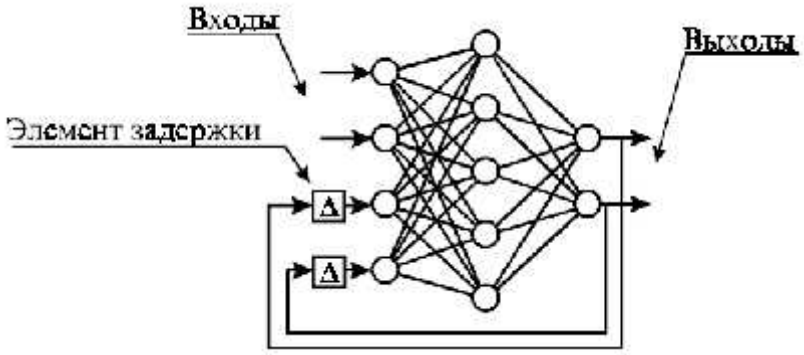

в)

Рис. 3. Анализируемые структуры нейросетей:
а) прямого распространения; б) РБФ; в) полносвязная рекуррентная.

$$\begin{cases} s_k = \sum_{j=1}^{l} w_{jk} z_j + b_k \\ y_k = \ddot{}(s_k) = \ddot{}\left(\sum_{j=1}^{l} w_{jk} z_j + b_k \right) \end{cases}$$

где z – вектор входных сигналов; $w_{1k}, w_{2k}, \ldots, w_{lk}$ – синаптические веса k-го нейрона; s_k – выход линейного сумматора; b_k – сдвиг; $\varphi(\cdot)$ - активационная функция (гиперболическая, сигмоидальная и др. [6, 7]); y_k – выходной сигнал нейрона.

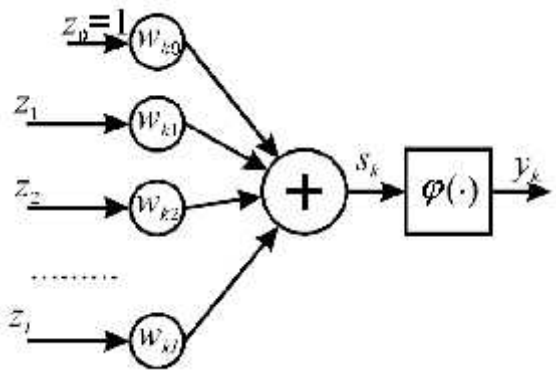

Рис. 4. Модель обычного нейрона

В РБФ-сетях в качестве активационных функций используются функции Гаусса типа

$$\ddot{}(s) = Exp\left(-\frac{s^2}{\pm^2}\right).$$

Аргумент функции рассчитывается на основе зависимости:

$$s = \|z - c\|,$$

где c – вектор координат цента окна активационной функции; σ – длина окна; норма $\|\cdot\|$ - эвклидово расстояние.

Для параметризации (обучения) моделей типа (2-3) необходимое наличие определенного количества статистической информации - шаблонов данных типа „вход-выход”. Последние представляются в виде множества:

$$\Xi\{z_i, d_i\}, \quad i = \overline{1, M}, \tag{4}$$

где z – входной шаблон; d – выходной шаблон; M – обозначенное количество шаблонов.

Тогда, в соответствии (1 – 4), вектор сигналов на входе системы будет определяться как

$$z = \big(y(k), y(k-1), ..., y(k-l_1), u(k), u(k-1), ..., u(k-l_2)\big),$$

а результирующий вектор на выходе $d = y(k+1)$.

Наилучшая модель регрессора должна обеспечить приемлемую скорость обучения, свойства обобщения, а с другой стороны - необходима надлежащая точность прогнозирования.

Для оценки адекватности полученной нейросетевой модели рационально использовать выражение:

$$\|\hat{y} - y\| \le £,$$

где ||·|| – определенная норма; ε - погрешность аппроксимации.

Традиционным критерием здесь есть среднеквадратическая ошибка прогнозирования (квадратичная норма) вида:

$$MSE = \frac{1}{2M}\sum_{t=1}^{M}\left(y(t) - \hat{y}(t)\right)^2 = \frac{1}{2M}\sum_{t=1}^{M}£^2(t).$$

В таблице и на рис. 5 приведены результаты прогнозирования показателей ТП обогащения магнетитовых кварцитов.

Таблица

Показатели качества и адекватности математических моделей

Базисы/Показатели	СПР	РБФ	ПНС
MSE (максимальный)	2,62	3,08	2,58
Скорость обучения (в эпохах)	588	176	893

Моделирование проводилось на основе описанной методики с помощью пакета Neuro Solution. Использовалась выборка показателей Южного ГОКа (г. Кривой Рог, Украина).

На основании результатов моделирования были сделаны такие выводы:

1. Для прогнозирования показателей ТП обогащения достаточно эффективно применение нейросетевых моделей NNARX и NNOE.

2. Прогнозирование на базе сети прямого распространения (СПР) обеспечивает хорошее качество модели при приемлемом времени обучения.

3. Использование сети радиального базиса обеспечивает самое быстрое обучение системе. При этом точность прогнозирования самая низкая.

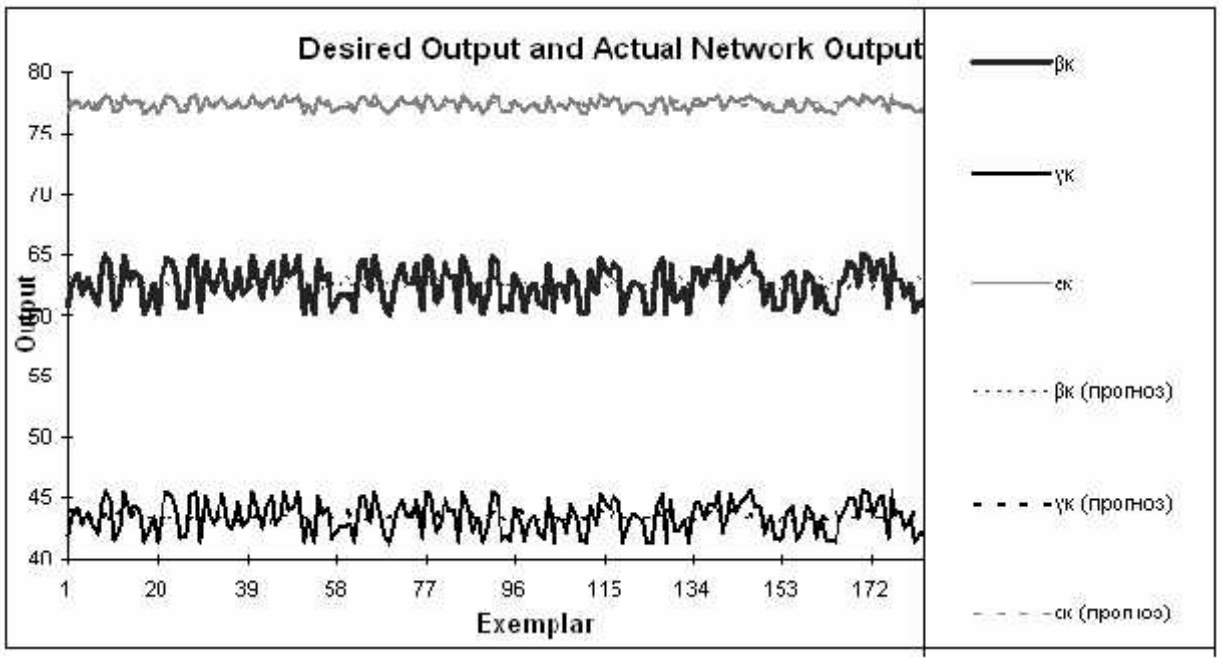

Рис. 5. Пример прогнозирования качественных показателей ТП обогащения (модель NNOE, базис – полносвязная рекуррентная сеть)

4. Применение полносвязной нейросети (ПНС) дает максимальную точность прогнозирования при наибольшем времени обучения.

Список литературы: **1**. *Купін А.І.* Узагальнений алгоритм нейромережевої ідентифікації ТП збагачення залізної руди // Вісник КТУ.-Вип.13.-Кривий Ріг: КТУ.-2006.- С.147-150. **2**. *Купін А.І.* Обґрунтування використання технологій штучного інтелекту для управління технологічним процесом збагачення магнетитових кварцитів // Вісник КТУ.-Вип.1.-Кривий Ріг: КТУ.-2003.- С.51-55. **3**. *Марюта О.М., Бойцун Н.Є.* Статистичні методи і моделі в економіці.- Дніпропетровськ: Пороги, 2002.- 384с. **4**. *Марюта А.Н., Качан Ю.Г., Бунько В.А.* Автоматическое управление технологическими процессами обогатительных фабрик.- М.: Недра, 1983.-277с. **5**. *Назаренко М.В.* Система оптимального управління технологічним процесом видобутку і переробки корисних копалин на залізорудном гірничозбагачувальному комбінаті // Матеріали 5-ї міжн.конф."Контроль і управління в складних систем"(КУСС-99).-Том.3.- Вінниця: "УНІВЕРСУМ-Вінниця", 1999.- С.52-55. **6.** *Махотило К.В.* Разработка методик эволюционного синтеза нейросетевых компонентов систем управления: Дис…. канд. техн. наук: 05.13.06.- Харьков, 1998.- 179с. **7**. Методы робастного, нейронечеткого и адаптивного управления / Под.ред. *Н.Д.Егупова*.- М.: МГТУ им. Н.Э.Баумана, 2002.- 744с.

Поступила в редколлегию 10.08.06