

С.В. ЕНДИЯРОВ,
С.Ю. ПЕТРУШЕНКО

**Комплексный подход к
прогнозированию качественных
показателей агломерата**

УДК 004.89, 519.2, 519.85

Уральский
государственный
горный университет,
г. Екатеринбург

Рассмотрен комплексный подход к прогнозированию основных качественных показателей агломерата. Рассматриваются модели авторегрессии и нейро-нечеткие сети типа Такаги-Сугено. Исследованы структуры моделей.

Рассматривается проблема разработки прогнозных моделей при априорной неопределенности их параметров и структуры. Построение моделей будем производить на основе экспериментальных данных. Источниками экспериментальных данных являются результаты наблюдения за реальным объектом (комплексом производства агломерата). Наблюдения проводились в ходе обычной эксплуатации. При этом использовались данные полученные за месяц работы аглофабрики.

В работе [1] предлагается подход к прогнозированию основности агломерата на основе уравнения балансовой основности шихты и модели экспоненциального сглаживания:

$$M_j = \frac{\sum_{i=1}^K Q_j^i \cdot \left(\frac{1 - W_j^i}{100} \right) \cdot \frac{CaO_j^i}{100}}{\sum_{i=1}^K Q_j^i \cdot \left(\frac{1 - W_j^i}{100} \right) \cdot \frac{SiO_2^i}{100}}, \quad (1)$$

где $i = 1, \dots, N$ – порядковый номер компонента шихты (включая все возвратные продукты); Q_j^i – весовые расходы компонентов шихты, т/ч; W_j^i – влажность в i -м компоненте шихты, %; CaO_j^i – содержание CaO в i -м компоненте шихты, %; SiO_2^i – содержание SiO_2 в i -м компоненте шихты, %.

Эта модель позволяет определить влияние расходов и химического состава компонентов шихты на основность.

Кратко рассмотрим подход предлагаемый авторами. В качестве основы для прогноза основности агломерата в j -й дискретный момент времени используется балансовая модель основности аглошхты. Расчет основности по балансовой модели производится по мере поступления информации о результатах опробования материальных потоков, а также в случае существенного изменения расходов компонентов шихты.

При этом за период дискретности ΔT между поступлением результатов опробования фактической основности агломерата, рассчитывается m значений основности агломерата с периодом $\Delta t \approx 10-15$ мин., где $m = \Delta T / \Delta t$.

Расчетное значение основности агломерата за i -й дискретный интервал времени рассчитывается по формуле:

$$\overline{M}_k = \frac{1}{m} \sum_{j=1}^m M_{kj}. \quad (2)$$

Результаты расчета основности за период дискретности ΔT сравниваются с фактической основностью агломерата, получаемой с периодом 2-4 часа и определяемой по 5-8 частным пробам за заданный интервал времени:

$$\delta M_k = M_{\phi k} - \overline{M}_k, \quad (3)$$

где ϕ – индекс фактического значения основности.

Невязки расчетных и фактических значений основности образуют временной ряд, для которого строится модель прогноза. Прогноз невязки расчетных и фактических значений на интервале времени $k+1$ осуществляется с использованием процедуры экспоненциального сглаживания:

$$\delta \hat{M}_{k+1} = \alpha_k \delta M_k + \alpha_{k-1} \delta M_{k-1}, \quad (4)$$

где α_k, α_{k-1} коэффициенты, подбираемые из условия минимизации погрешности прогнозирования.

Окончательно прогноз основности рассчитывается по балансовой модели с учетом прогнозируемой невязки. Прогнозируемое значение основности агломерата на интервал времени ΔT рассчитывается по формуле:

$$\hat{M}_{k+1} = M_k + \delta \hat{M}_{k+1}. \quad (5)$$

В статье [2] для прогнозирования содержания FeO агломерата предлагается использовать авторегрессионную модель вида:

$$FeO^A = f(FeO^{III}, C^{III}, M_{3AD}^{III}, \Pi_c), \quad (6)$$

где C^{III} – содержание углерода в шихте, %;

FeO^{III} – содержание монооксида железа в шихте, %;

M_{3AD}^{III} – заданная основность агломерата, ед;

Π_c – параметры процесса спекания.

Для дальнейшего сравнения моделей необходимо произвести построение рассмотренных моделей и расчета погрешностей прогноза для каждой модели. При этом для прогнозирования основности будем использовать модель (4), однако вместо процедуры экспоненциального сглаживания будем использовать адаптивную авторегрессионную модель [3]. А для прогнозирования содержания FeO и Fe агломерата будем использовать модели вида:

$$\begin{aligned} Fe^A &= f(Fe^{III}, Fe_{t-\tau}^A, C^{III}, M^{III}) \\ FeO^A &= f(FeO^{III}, FeO_{t-\tau}^A, C^{III}, M^{III}), \end{aligned} \quad (7)$$

где M^{III} – текущее значение основности аглошихты рассчитанное по балансовой модели, а $Fe_{t-\tau}^A$ и $FeO_{t-\tau}^A$ – содержание железа и монооксида железа в агломерате по результатам последнего опробования. Для оценки коэффициентов авторегрессионных моделей использовался адаптивный метод наименьших квадратов. Для сравнения моделей будем использовать оценку СКО ошибки прогнозирования [3]. Вследствие ограниченности выборки точность моделей проверялась на обучающей выборке. В таблице 1 представлены результаты работы рассмотренных моделей на данных ОАО «Северсталь».

Таблица 1

Исследование прогнозирования качественных показателей агломерата

Модель	Ошибка модели
$Fe^A = f(Fe^{III}, Fe_{t-\tau}^A, C^{III}, M^{III})$	0.286
$FeO^A = f(FeO^{III}, FeO_{t-\tau}^A, C^{III}, M^{III})$	0.669
$\hat{M}_{k+1} = M_k + \delta \hat{M}_{k+1}$	0.0306

Видно, что наименьшую погрешность прогнозирования имеет основность агломерата. Модель для прогнозирования основности

(5) содержит в левой части слагаемое, позволяющее учитывать нелинейную связь между характеристиками шихты и основности агломерата. Поэтому ожидается, что данная модель способна прогнозировать основность агломерата с низким значением погрешности.

Модели (7) не способны учитывать нелинейную зависимость между входом и выходом объекта, поэтому для прогнозирования данных показателей в данной работе предлагается использовать нейро-нечеткие сети. На рисунке 1 представлена классическая структура нечеткой модели с n входами и одним выходом.

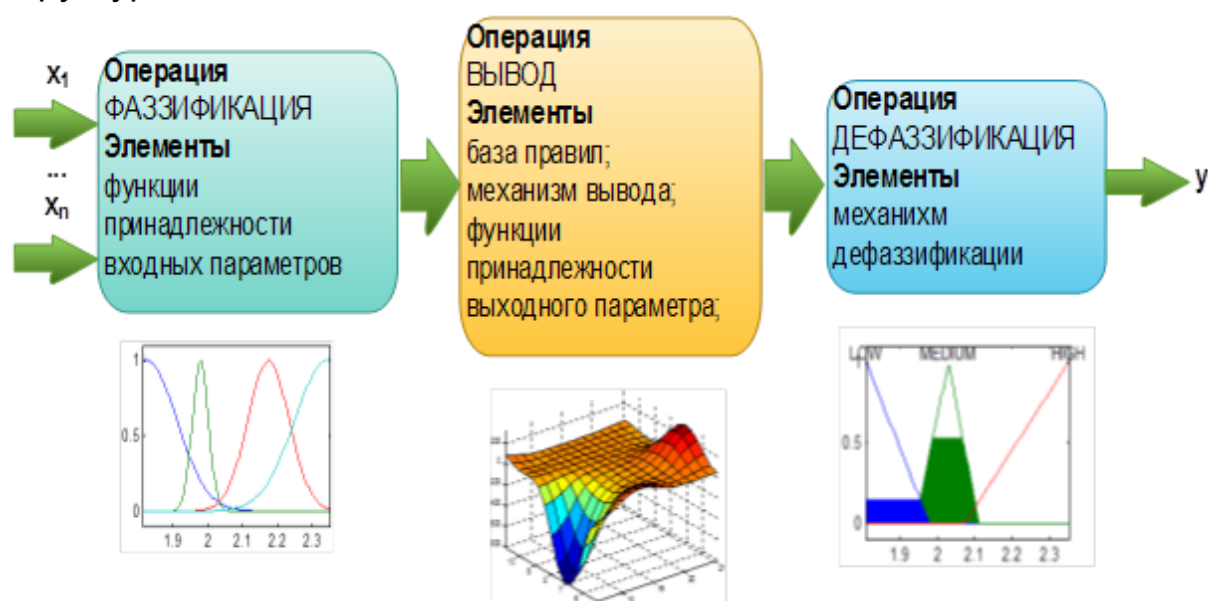


Рис. 1. Структура нечеткой модели системы с n входами и выходом

Кратко функционирование такой модели можно описать следующим образом [4]:

1) В первом блоке происходит фаззификация переменных x_1, \dots, x_n , т.е. происходит вычисление степени принадлежности этих переменных входным нечетким множествам A_j^1, \dots, D_j^n ;

2) Во втором блоке происходит вычисление результирующей функции принадлежности, которая вычисляется на основе операции вывода. Существуют различные операции вывода;

3) В третьем блоке на основе результирующей функции вычисляется четкое числовое значение, данная операция выполняется посредством механизма дефаззификации.

Для прогнозирования качественных показателей агломерата предлагается использовать нечеткие модели Такаги-Сугено. От

моделей Мамдани данный тип отличается формой правил. Правила моделей Мамдани имеют следующий вид:

$$\text{ЕСЛИ } (x \text{ есть } A) \text{ ТО } (y \text{ есть } B) . \quad (8)$$

А в случае моделей Такаги-Сугено:

$$\text{ЕСЛИ } (x \text{ есть } A) \text{ ТО } (y = f(x)) . \quad (9)$$

Общая структура нейро-нечеткой сети представлена на рисунке 2.




Рис. 2. Структура нейро-нечеткой сети

Преимуществами моделей Такаги-Сугено являются [5]:

1) Для построения модели требуется меньшее количество правил, чем в моделях Мамдани;

2) Сложные нелинейные поверхности можно аппроксимировать с помощью множества плоских линейных сегментов. Каждый такой сегмент задается одним правилом модели;

3) Данные модели сочетают в себе описание системы на основе лингвистических правил с традиционным функциональным представлением процесса ее функционирования, которое является привычным для нас.

Применение в качестве прогнозной модели именно нейро-нечеткой сети объясняется ее лучшей обучаемостью [5] и возмож-

ностью ее трактования как базы знаний [6] в отличие от классических нейронных сетей, которые описывают процесс как «черный ящик». Разбиение входного пространства на интервалы позволяет сделать сеть робастной по отношению к шумам присутствующим в данных. Кроме того структура такой сети выбирается на основе проблемной ситуации, а не на основе перебора вариантов.

Исследование методов прогнозирования, с целью сравнения, происходило с использованием моделей различной структуры (см. таблицу 2). Как и прежде в качестве критерия сравнения будем использовать оценку СКО ошибки прогнозирования. Для обучения нейро-нечеткой сети был использован гибридный алгоритм, описанный в [5]. На первом этапе происходит подбор параметров слоя дефаззификации, с сохранением значений параметров входных функций принадлежности. Далее происходит настройка параметров слоя фаззификации, с сохранением значений параметров слоя дефаззификации. Авторы [5] отмечают, что данный алгоритм менее подвержен эффекту появления локальных минимумов функции ошибки в ходе обучения, поскольку каждый цикл обучения связан с настройкой только определенных параметров модели. Кроме того процесс обучения заканчивается быстрее.

Таблица 2

Различные структуры моделей, используемые в ходе проверки методов прогнозирования

Номер модели	Модель
1, 2, 3	$Y = f(X_{t-\tau}^A, C^M, M^M), Y = f(X^M, C^M, M^M), Y = f(X^M, X_{t-\tau}^A, C^M)$
4, 5, 6	$Y = f(X^M, X_{t-\tau}^A, M^M), Y = f(X^M, X_{t-\tau}^A), Y = f(X^M, M^M)$
7, 8, 9	$Y = f(X^M, C^M), Y = f(X_{t-\tau}^A, C^M), Y = f(X_{t-\tau}^A, M^M)$
10, 11	$Y = f(C^M, M^M), Y = f(X^M, X_{t-\tau}^A, C^M, M^M)$

На рисунках 3 и 4 представлены результаты сопоставления погрешностей прогнозирования различных моделей (см. таблицу 2).

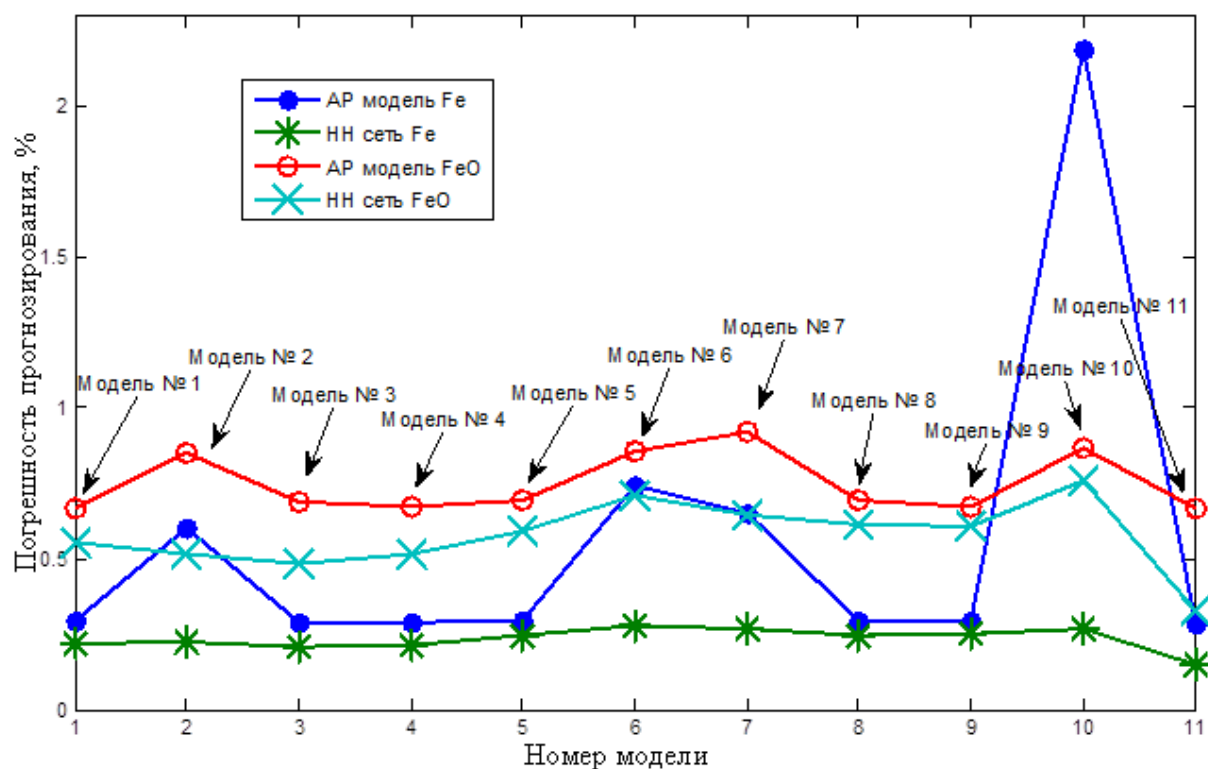


Рис. 3. Погрешности моделей авторегрессии и нейро-нечетких сетей для прогнозирования содержания Fe и FeO




Рис. 4. Погрешности моделей авторегрессии и нейро-нечетких сетей для прогнозирования содержания Fe и FeO

Из рисунков 3 и 4 следует, что использование нейро-нечетких сетей позволяет значительно снизить погрешность прогнозирования по сравнению с авторегрессионными моделями. Результаты моделей обладающих наименьшей дисперсией прогноза сведены в таблицу 3.

Таблица 3

Исследование прогнозирования качественных показателей агломерата с помощью нейро-нечеткой сети

Модель	Ошибка модели	Число ф. п.	Тип функции принадлежности	Тип заключения
$Fe^A = f(Fe^{III}, Fe_{t-\tau}^A, C^{III}, M^{III})$	0.147	3	Треугольная	Линейное
$FeO^A = f(FeO^{III}, FeO_{t-\tau}^A, C^{III}, M^{III})$	0.324	3	Гауссова	Линейное

Проведенные исследования прогнозирования качественных показателей агломерата с использованием нейро-нечетких сетей показывают, что ошибку прогноза содержания Fe и FeO удалось снизить почти в два раза (см. таблицу 3). На рисунке 5 показано использование нейро-нечеткой сети для прогнозирования FeO агломерата.




Рис. 5. Пример прогнозирования FeO агломерата нейро-нечеткой сетью с 3 и 4 входными функциями принадлежности

На рисунке 6 изображены функции принадлежности для нейро-нечеткой сети с тремя входными функциями принадлежности для каждой переменной. Видно, что изменениям подверглась лишь основность шихты.

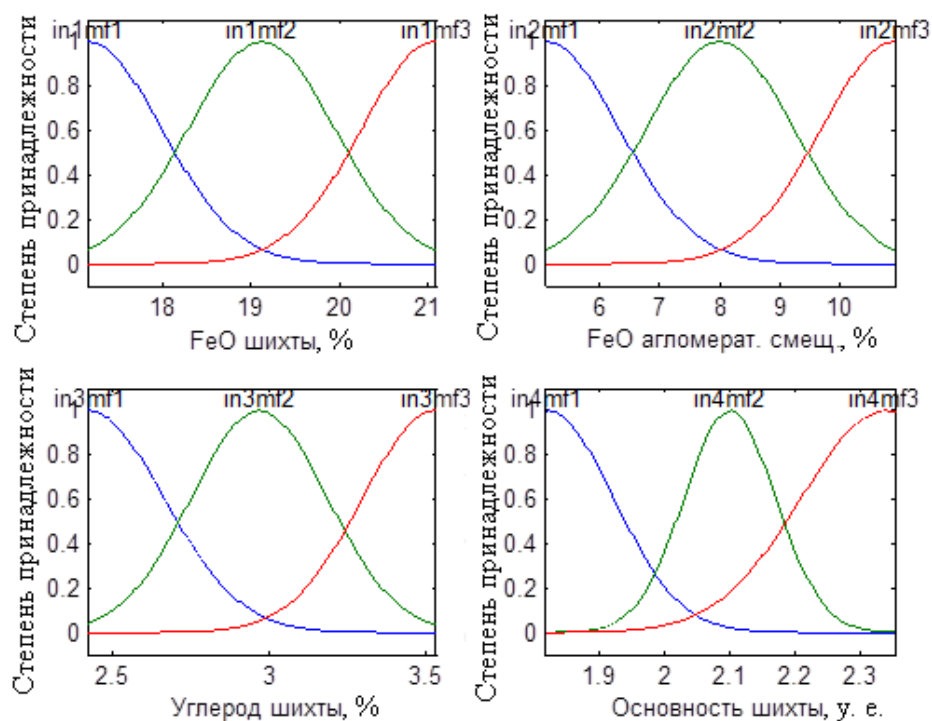


Рис. 6. Входные функции принадлежности модели прогнозирования FeO агломерата

Для иллюстрации работы нейро-нечеткой сети на рисунке 7 представлены зависимости входов и выходов для моделей FeO и Fe.

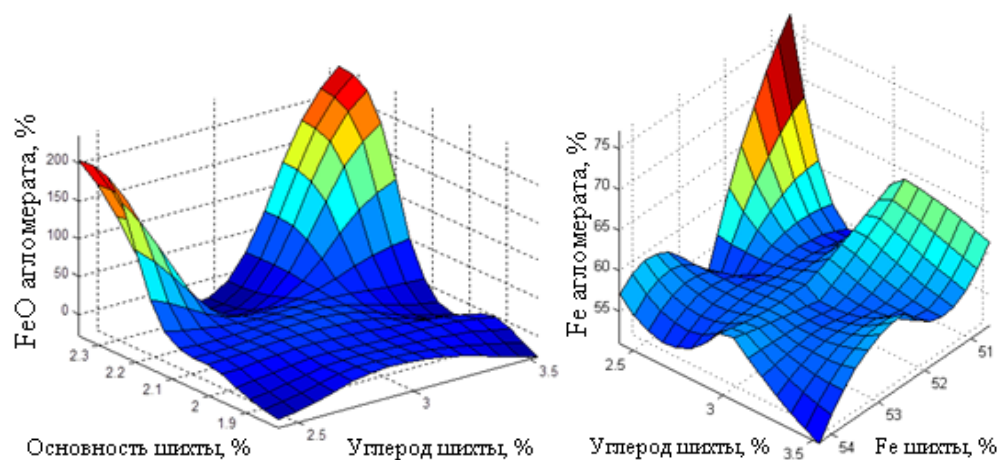


Рис. 7 – Поверхности, отражающие зависимости, построенные нейро-нечеткой сетью (слева – зависимость FeO агломерата от углерода и основности; справа – зависимость Fe агломерата от углерода и Fe шихты)

В научной литературе, посвященной прогнозированию качественных показателей агломерата, не упоминалось использование периодических составляющих для улучшения качества прогнозирования.

Однако как показывают исследования, проведенные в предыдущей главе, сигналы, характеризующие химический состав шихты, содержат низкочастотные периодические составляющие. Данное обстоятельство может быть использовано для повышения точности алгоритмов прогнозирования качественных показателей агломерата. С этой целью в выражения (7) вводятся соответствующие низкочастотные компоненты.

Таблица 4

Исследование добавления низкочастотной составляющей сигнала в прогнозную модель для улучшения качества прогнозирования

Модель	Ошибка модели	Число ф. п.	Тип функции принадлежности	Тип заключения
$Fe^A = f(Fe^{III}, Fe_{t-20}^{III}, Fe_{t-\tau}^A, C^{III}, M^{III})$	0.064	3	Треугольная	Линейное
$FeO^A = f(FeO^{III}, FeO_{t-\tau}^A, FeO_{t-24}^{III}, C^{III}, M^{III})$	0.147	3	Гауссова	Линейное

Из таблицы 4 следует, что при включении в модель низкочастотных составляющих сигнала позволило уменьшить погрешность прогнозирования еще приблизительно в 2 раза.

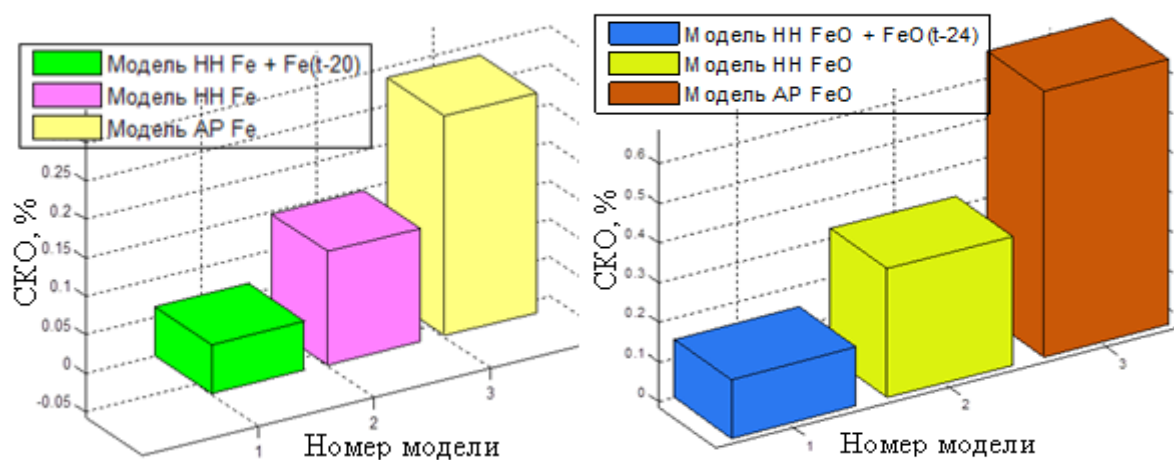


Рис. 8. Сравнение методов прогнозирования

На рисунке 8 изображено сравнение алгоритмов прогнозирования с использованием периодическими составляющими и без них. Таким образом, видно, что использование низкочастотных составляющих позволяет значительно повысить качество прогнозирования.

На рисунке 9 представлена форма программы, производящая прогнозирование основных качественных показателей агломерата.

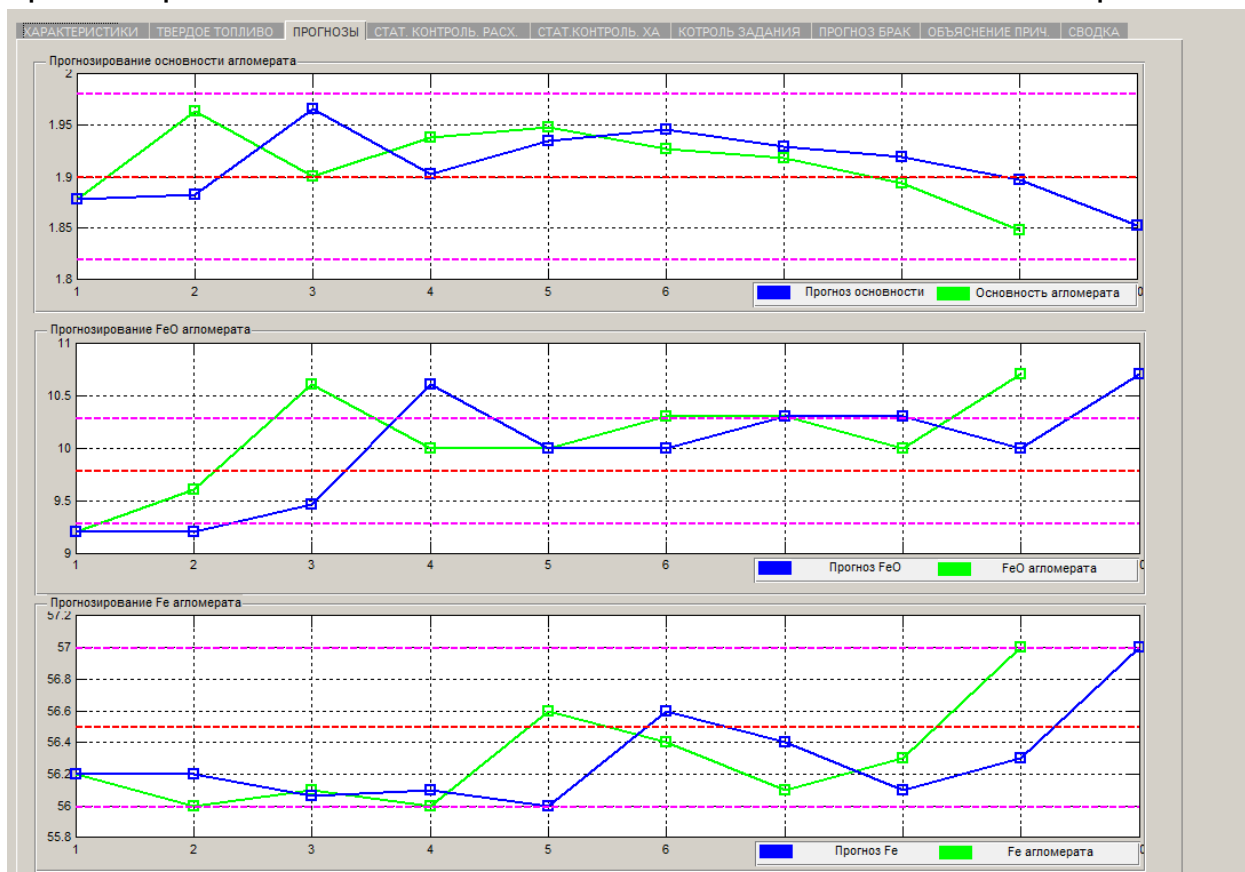


Рис. 9. Форма прогнозирования основных качественных показателей агломерата

Литература

1. Зобнин Б. Б., Головырин С.С., Катаев Р.Л. Прогнозирование основности агломерата в условиях ОАО «Северсталь» // Прогрессивные процессы и оборудование металлургического производства. Материалы IV Международной конференции, Череповец, 2003, с. 301-303.

2. Малыгин А.В., Зобнин Б.Б., Головырин С.С., Сурин А.А., Невраев В.П., Гуркин М.А., Катаев Р.Л. Система управления качеством агломерата // Сталь, N 1, 2005.

3. Математическая статистика: Учебник/Иванова В.М., Калинина В. Н., Нешумова Л. А. и др. – 2-е изд, перераб. и доп. – М.: Высш. школа, 1981. – 371 с., ил.

4. Пегат А. Нечеткое моделирование и управление / А. Пегат ; пер. с англ. — М. : БИНОМ. Лаборатория знаний, 2009. — 798 с. :ил. — (Адаптивные и интеллектуальные системы).

5. Graupe D. Principles of artificial neural networks (2nd Edition), World Scientific Publishing, Chicago, USA, 2007, pp. 320.

6. Kulkarni A.D., Cavanaugh C. Fuzzy Neural Network Models for Classification // Applied Intelligence, USA, vol. 18, N. 3, March, 2000, pp. 207-215.

E-MAIL: ENDEYAROV@OLYMPUS.RU

E-MAIL: VETRODUB@GMAIL.COM