

РАЗРАБОТКА АЛГОРИТМОВ УПРАВЛЕНИЯ ПРОКАТНЫМ СТАНОМ НА БАЗЕ САМООРГАНИЗАЦИИ МОДЕЛЕЙ УПРАВЛЕНИЯ И САМОУЛУЧШЕНИЯ ПРОГНОЗОВ

Мокрый Г.В., Борисов А.А., Бойко В. В.

Донецкий национальный технический университет, г. Донецк

Кафедра автоматизированных систем управления

Кафедра автоматики и телекоммуникаций

E-mail: alexbor@fcita.dn.ua

Abstract

Mokry G.V., Borisov A.A., Boyko V.V. Development of algorithms of management of the rolling mill on the basis of self-organizing models of management and improvements of the forecasts. In the article has received further development the algorithm of a top level realizing selforganizing of control model on the basis of a multicriteria estimation of a regulator performance of a technological process of continuous rolling.

Анализ проблемы и постановка задачи. Рассмотренные в [1,4] методы автоматического управления прокатным станом основаны на предложенной модели с определённой степенью адекватности реальным процессам. Дальнейшее совершенствование систем управления прокаткой возможно на базе улучшения адекватности эталонных моделей, однако, следует учитывать, что результаты современных экспериментальных исследований показали наличие некоторых противоречий в теоретических описаниях явлений пластической деформации металла в процессе его прокатки [2]. Необходимо констатировать, что математическое описание процессов в очаге деформации металла и теория прокатки вообще, еще недостаточно совершенны, несмотря на достаточно большой период исследования. Это связано, видимо, с большим количеством факторов, которые влияют на процесс прокатки, и тем самым сложностью восприятия человеком данного процесса и тем более его прогнозирования, особенно при изменении физических свойств прокатываемого металла, изменении сортамента проката и т.п. Поэтому, наряду с дальнейшим совершенствованием теоретических зависимостей прокатки, актуальна задача компьютерного самоулучшения модели управления, которое, уменьшая человеческий фактор, в данном случае может оказаться более эффективным. Данная задача решается параллельно основной задаче управления и незначительно влияет на быстродействие системы автоматического управления. Структура такой системы с учётом изложенного в [1,4] показана на рис. 1.

Для условий прогнозирования факторов, влияющих на процесс прокатки, необходимы не только новые модели, но и новый подход в прогнозировании, обеспечивающий создание модели непосредственно в процессе управления на конкретном стане, для придания ей свойств самоорганизации (самоулучшения), в смысле приспособления к новым условиям и сохранения адекватности, при требуемой степени достоверности прогнозов. Однако, при традиционном подходе к построению регрессионных моделей они становятся чересчур громоздкими, быстро теряют адекватность вследствие нестационарности процессов и оказываются непригодными для практического использования.

Решение задач и результаты исследований. Предлагается подход в основу которого кладётся принцип непротиворечивого целенаправленного эволюционирования единой системы «процесс прокатки - управляющая система». По этому принципу закладывается способность системы к самоорганизации, самоулучшению модели и алгоритма управления и целенаправленного движения к оптимуму на базе непрерывного получения новой информации об изменениях параметров непрерывной прокатки и приспособления алгоритма управления к новым условиям. В соответствии с этим принципом ставится задача разработки опе-

ративных методов машинного формирования моделей и алгоритмов управления непосредственно в конкретных условиях прокатного производства.



Рисунок 1 – Структура системы автоматического управления прокатным станом

Согласно предлагаемому подходу процесс прогнозирования рассматривается как предсказание динамики развития целостной системы с медленными (эволюционными) и быстрыми (революционными) процессами в соответствии с уровнями иерархии. Другими словами, прогнозирование является отображением функционирования реальных составляющих частей иерархической системы в прошлом на будущие периоды. Также как и в управлении иерархическими системами, управляющее воздействие следует с частотой, соответствующей инерционности иерархического уровня, в прогнозировании достоверная оценка показателя эффективности системы (или какого-либо уровня) не может быть получена по частному показателю одного уровня или системы в целом на длительный период. Причиной этому является разная степень нестабильности уровней и взаимовлияние их друг на друга в составе единого целого. Поэтому при данном подходе прогноз представляется в виде иерархического дерева с раздельным (перекрестным) прогнозированием составляющих, на базе разделения движений на “быстрые” и “медленные” и оценкой достоверности с учетом адаптивных “весов” локальных прогнозов. Для этого в прогнозируемом процессе выделяются тренды с наложенными (аддитивными) помехами, спектр частот которых соответствует иерархическому уровню прогноза. При таком подходе имеется возможность использования математического аппарата и методов оптимизации сложных иерархических систем.

Обобщенная структура модели прогнозирования факторов процесса прокатки, базирующаяся на новом подходе, приведена на рис. 2. Исходную базу модели прогнозирования составляет модуль агрегирования основных факторов, обеспечивающих получение всех необходимых агрегирующих факторов подлежащих прогнозированию любых показателей и параметров процесса прокатки. На рис. 2 приведен пример прогнозирования одного показателя f_i^k .

Структура модели включает: массивы факторов $\bar{x}_1 - \bar{x}_3$ процесса прокатки и показателей $f^k[i]$, подлежащих прогнозированию ($i = 1, N$), N – число шагов на интервале наблю-

дения; модуль самоорганизации модели с параметрами $\{A_j\}$; модуль МСМП самоорганизации модели поправок $\{A_j[\omega_j]\}$ к коэффициентам модели $\{A_j\}$; модуль МУП учета поправок коэффициентов A_j при перекрестном прогнозировании процесса f^k и коэффициентов A_j ; модуль МЭП прогнозов компьютера; модуль МСП субъективного прогноза ЛПР на базе прошлого опыта, интуиции, самообучения; модули $e^{k_1P} \div e^{k_3P}$ упреждения, моделирующие сдвиг во времени выработанных прогнозов на интервал прогнозирования ΔT_{Π} для сравнения их с будущими значениями реальных выходных величин f^k процесса (объекта); модуль МАП адаптации прогнозов при рассогласовании прогнозных данных моделей и реальных показателей процессов; модуль МОПЭ обработки и согласования прогнозов компьютера; модуль МОМП обработки математических прогнозов для различных детерминированных основ (трендов) разделенных по частотам (периодам прогнозирования); модуль МСОП совместной обработки прогнозов для выработки общего гибридного прогноза на заданный интервал.

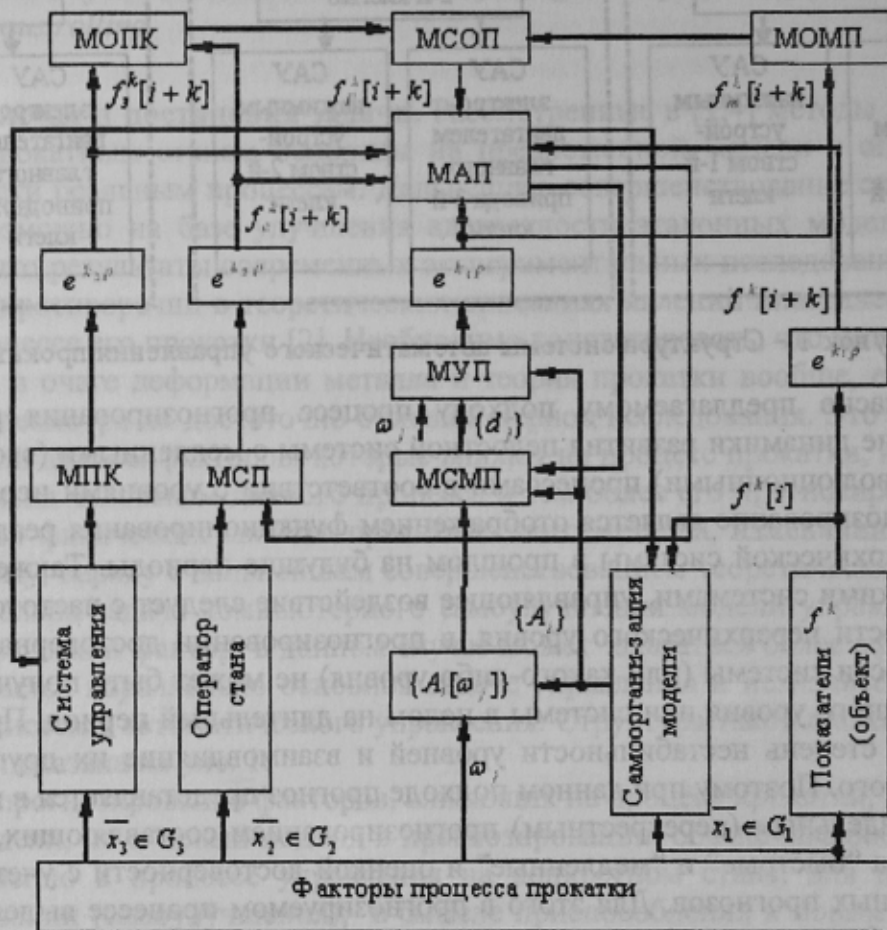


Рисунок 2 - Структура модели раздельного прогнозирования с поправками

На рис.2 приняты обозначения: $\bar{x}_1 \in G_1$ – множество сильно связанных параметров процесса прокатки, определяющих показатель $f^k[i]$ для верхних частот разделения движений; $\bar{x}_2 \in G_2$, $\bar{x}_3 \in G_3$ – тоже для нижних частот (с большими интервалами наблюдения и упреждения); ω_j помехи, вызывающие дрейф коэффициентов A_j моделей (их количество зависит от степени детализации математических моделей описания подпроцессов прокатки); $\{\alpha_j\}$ – множество поправок к коэффициентам моделей $\{A_j\}$, $j = \overline{1, e}$ (число коэффициентов моделей), $f^k[i]$ – значение показателя f^k на i -ом шаге; $f^k[i+k]$ – значение реального пока-

затяга в конце интервала прогнозирования (точное или интервальное); $f_m^k[i+k]$, $f_s^k[i+k]$ и $f_T^k[i+k]$ – математический, эвристический и гибридный прогнозы.

Основными элементами в структуре модели (рис. 2) являются модули самоорганизации модели СМ и выработки поправок (МСМП), используемые при перекрестном прогнозировании многократно.

С учетом предъявленных требований и предложенного подхода задача самоорганизации структуры прогнозной модели формулируется следующим образом. Задан процесс с вектором \bar{U} входных величин и выходной величиной Y . В результате эксперимента или наблюдений динамической системы процесса прокатки имеется выборка с ограниченным объемом реализаций входных U_t и выходной Y_t величины, $t \in T$ (T – период наблюдения).

Отыскивается структура и математическое описание процесса «вход-выход», которое задается в виде:

$$Y_M = A_0 + \sum_{i=0}^k A_i f_i(\bar{U}); \quad f_i(\bar{U}) \in F(\bar{U}), \quad (1)$$

где $F(\bar{U})$ – класс опорных функций для формирования структуры процесса прокатки. В качестве оценки модели используется критерий.

$$\Phi(Y_M - Y_t) \rightarrow \min \quad (2)$$

При выполнении ограничений

$$f_i(\bar{U}) \in F(\bar{U}), \quad k \leq k_0, \quad n < n_0, \quad (3)$$

где k, n – длина и порядок полинома Y_M ,

k_0, n_0 – допустимые значения длины и порядка полинома).

Требуется определить структуру процесса (вид функций $f_i(\bar{U})$, k и n) и значения коэффициентов A_0, A_i модели

$$Y_M = f(A_0, A_i, \bar{U}). \quad (4)$$

При этом значения коэффициентов A_0, A_i должны доставлять минимум заданному критерию качества $\Phi(Y_M^i - Y_t)$.

Идея упрощения моделей с целью придания им свойства адаптивности базируется на использовании метода группирования аргументов и теории самоорганизации [3]. Согласно [3] вводятся обобщенные доминирующие факторы Y : Y_1 – фактор, повышающий эффективность управления; Y_2 – фактор, снижающий эффективность управления; Y_3 – фактор, случайным образом снижающий или повышающий эффективность управления относительно его нормативной величины.

Самоорганизация осуществляется как в нижних рядах многорядного алгоритма агрегирования факторов f^k так и в верхних рядах.

Обозначим: ΔX_i – относительный диапазон изменения i -го параметра; ΔC_i – относительное приращение эффективности по i -му фактору; ∇_i – относительный градиент влияния i -го фактора; $\Delta C n_j$ – полное относительное приращение эффективности по j -й группе параметров.

Тогда

$$\nabla_i = \lim_{\Delta x_i \rightarrow 0} \frac{\Delta C_i}{\Delta x_i}, \quad (5)$$

а полное относительное приращение эффективности будет

$$\Delta C n_j = \sum_{i=1}^n \nabla_i \Delta x_i, \quad (j = 1, 3), \quad (6)$$

где n -число частных параметров в обобщённом доминирующем факторе. Коэффициент удельного влияния i -го параметра имеет вид:

$$k_i = \frac{\nabla_i \Delta x_i}{\Delta C n_j}, \quad (7)$$

а приращение эффективности, выраженное через обобщённый фактор Y_j , будет равно

$$\Delta C n_j = A_j \sum_{i=1}^n \beta_i k_i Y_i, \quad (8)$$

где β_j – доля полного диапазона изменения первого фактора.

Таким образом, в линейной подстановке задачи влияние частного параметра Δx_i сведено к интегральному влиянию определенной доли обобщенного фактора $Y_j=1$. Обобщённая переменная при построении переменной будет иметь вид:

$$U_j = \sum_{i=1}^n \beta_i k_i Y_i. \quad (9)$$

Под обобщённой переменной U_j понимается любой из факторов x^j, f^k , влияющий на принятые показатели оценки управления.

При учете нелинейности и корреляционных зависимостей между факторами принимается, что удельное влияние частных факторов в формировании показателя эффективности сохраняется.

Поставим задачу определения структуры и параметров прогнозирующей модели, задаваемой в общем виде:

$$C(\bar{U}) = A_0 + \sum_{i=1}^k A_i f_i(\bar{U}); f_i(\bar{U}) \in F(\bar{U}) \quad (10)$$

при $k \leq k_0, n \leq n_0, \Phi(C_{mi} - C_i)^2 \rightarrow \min,$

где $f_i(\bar{U})$ – неизвестные функции, формируемые в классе опорных функций $F(\bar{U})$,

k_0 – задаваемая длина полинома модели,

n_0 – степень полинома,

A_i – неизвестные коэффициенты модели, подлежащие определению,

Φ – критерий адекватности при отборе моделей.

Ввиду нестационарности, и многофакторности модели задание ее жесткой структуры не представляется возможным. Модель в этом случае формируются непосредственно в процессе управления путём задания класса опорных функций, степени и длины полинома.

Таким образом, множество опорных функций имеет вид:

$$U_1 U_2 U_3; U_1 U_2, U_1 U_3, U_2 U_3; U_1^2, U_2^2, U_3^2; U_1^2 U_2, U_1^2 U_3, U_2^2 U_1, U_2^2 U_3, U_1 U_3^2 U_2 U_3^2; \quad (11)$$

В классе опорных функций возможно также использование дробных функций. Неопределённая структура модели при этом задаётся в виде:

$$C(\bar{U}) = A_0 + A_1 f_1(U_1, U_2, U_3) + A_2 f_2(U_1, U_2, U_3) + A_3 f_3(U_1, U_2, U_3) \quad (12)$$

Для модели (12) используется комбинаторный алгоритм усложнения моделей с усечённым перебором [3]. Способ формирования моделей путём усечения полинома и использования комбинаторного метода значительно сокращает машинное время, поскольку при оперативной самоорганизации требуется вычисление матриц размером не более 3×3 .

Формирование системы критериев селекции (отбора) моделей базируется на многозначной некорректной математической задаче, включающей этапы формирования содержательных требований к модели, перевода их в формализованные критерии, выбора регулирующих функционалов для получения единственной модели оптимальной сложности [3].

В качестве критерия отбора используется критерий минимума смещения на обучающей и проверочной выборках:

$$\delta_{см}^2 = \sum_{i \in N} (C_i^A - C_i^B) / \sum_{i \in N} C_i^2 \rightarrow \min \quad (13)$$

где $N=N_A+N_B$ – выборка исходных данных, обучающую N_A и проверочную N_B выборки;
 C_i^A, C_i^B – частные модели, полученные на выборках N_A и N_B .

Недостатком данного критерия является малая помехозащищённость. Для повышения помехоустойчивости вводится суммирование при вычислении критериев на интервале экстраполяции, где модели сильнее расходятся [3]:

$$\delta_{смк}^2 = \sum_{\bar{U} \in N} (C_i^A - C_i^B) + \mu \left[\sum_{\bar{U} \in N_A} C_i^A - C_i^2 + \sum_{\bar{U} \in N_B} (C_i^B - C_i)^2 \right] \quad (14)$$

где μ – коэффициент веса, объединяющий критерий минимума смещения и критерий среднеквадратичной ошибки.

В качестве внешнего регуляризирующего критерия используется среднеквадратичное отклонение модели по проверочной выборке:

$$\delta^2(B) = \sum_{\bar{U} \in N_c} (C_i^m - C_e)^2 / \sum_{\bar{U} \in N} C_i^2 \rightarrow \min \quad (15)$$

Критерий (13) удобно использовать при самоорганизации моделей в скользящем режиме, когда модель непрерывно корректируется при небольшом изменении исходных данных в выборках. По критерию (14) уточняется, на какой выборке, N_A или N_B , модель будет лучше.

Заключительным этапом отбора модели из претендентов является проверка её на соответствие требованиям, сформулированным в содержательном описании, на экзаменационной выборке N_C по критерию значимой погрешности:

$$\delta^2(C) = \sum_{i \in N_c} (C_i^m - C_i)^2 / \sum_{i \in N_c} C_i^2 \leq \varepsilon \quad (16)$$

где ε – заданная погрешность модели.

Основной операцией при формировании и самоорганизации модели является параметрическая идентификация, выполняемая многократно на основании пассивного эксперимента с целью определения коэффициентов модели A_i . При использовании многорядных алгоритмов усечённого перебора опорных моделей становится возможным использование для параметрической идентификации нелинейных процессов нелинейного регрессионного анализа [3].

Запишем полином (12) в развёрнутом виде:

$$C(U) = a_1U_1 + a_2U_2 + a_3U_3 + a_4U_1U_2 + a_5U_2U_3 + a_6U_1U_3 + a_7U_1^2 + \dots + a_{10}U_1U_2U_3 + \dots \quad (17)$$

Здесь полный полином сформирован в классе опорных функций (11).

Введём векторы

$$\bar{u} = (U_1U_2U_3, U_1U_2, U_1U_3, U_2U_3, \dots, U_1^2U_2^2U_3^2)^T \text{ и } \bar{A} = (a_1a_2a_3, \dots, a_{10})^T. \quad (18)$$

Тогда уравнение (17) в векторной форме примет вид:

$$C(\bar{U}) = \bar{u}^T \bar{A}, \quad (19)$$

Определим далее вектор \bar{y} и матрицу \bar{u} следующим образом:

$$\bar{y} = [C_{(1)} \dots C_{(2)} \dots C_{(n)}]^T, \quad \bar{U} = \begin{bmatrix} \bar{u}_{(1)}^T \\ \bar{u}_{(r)}^T \\ \bar{u}_{(n)}^T \end{bmatrix} = \begin{bmatrix} U_{1(1)} & U_{2(1)} & U_{3(1)} & U_1U_{2(1)} & U_1U_{3(1)} & \dots & U_1^2U_2^2U_{3(2)}^2 \\ U_{1(r)} & U_{2(r)} & U_{3(r)} & U_1U_{2(r)} & U_1U_{3(r)} & \dots & U_1^2U_2^2U_{3(r)}^2 \\ U_{1(n)} & U_{2(n)} & U_{3(n)} & U_1U_{2(n)} & U_1U_{3(n)} & \dots & U_1^2U_2^2U_{3(n)}^2 \end{bmatrix}, \quad (20)$$

где r обозначает момент измерений C , \bar{u}^T ($r=1,2,\dots,n$).

Следовательно, система уравнений может быть записана в векторной форме:

$$\bar{y} = \bar{U} \hat{A} \quad (21)$$

Если \hat{A} и \hat{y} - оценки вектора параметров и выходной величины, то справедливо равенство

$$\hat{y} = \hat{U} \hat{A} \quad (22)$$

С учётом (21) и (22) сумма S квадратических ошибок оценивания будет

$$S = (\bar{y} - \bar{U} \hat{A})^T (\bar{y} - \bar{U} \hat{A}) = tr \left[(\bar{y} - \bar{U} \hat{A})(\bar{y} - \bar{U} \hat{A})^T \right], \quad (23)$$

где $tr[\dots]$ - след матрицы.

Условие наилучшей оценки вектора искомых параметров \hat{A} удовлетворяет соотношению

$$\frac{\partial S}{\partial \hat{A}_i} = 0, \quad i \in \overline{1, m}, \quad (24)$$

где m — число оцениваемых параметров.

Подставляя (23) в (24) и записывая (24) в векторной форме, будем иметь

$$\frac{\partial S}{\partial \hat{A}} = \frac{\partial tr \left[(\bar{y} - \bar{U} \hat{A})(\bar{y} - \bar{U} \hat{A})^T \right]}{\partial \hat{A}} = \frac{\partial tr (\bar{y} \bar{y}^T + \bar{U} \hat{A} \hat{A}^T \bar{U}^T - \bar{U} \hat{A} \bar{y}^T - \bar{y} \hat{A}^T \bar{U}^T)}{\partial \hat{A}} = 0 \quad (25)$$

Здесь вычисленное значение следа матричной функции (25) определяется выражением

$$\begin{aligned} \frac{\partial tr (\bar{y} \bar{y}^T + \bar{U} \hat{A} \hat{A}^T \bar{U}^T - \bar{U} \hat{A} \bar{y}^T - \bar{y} \hat{A}^T \bar{U}^T)}{\partial \hat{A}} &= 0 + 2 \bar{U}^T \bar{U} \hat{A} - \bar{U}^T \bar{y} - \bar{U}^T \bar{y} = \\ &= 2(\bar{U}^T \bar{U} \hat{A} - \bar{U}^T \bar{y}) = 0 \end{aligned} \quad (26)$$

Из (26) получим наилучшую в смысле наименьших квадратов оценку \hat{A} вектора параметров:

$$\bar{U}^T \bar{U} \hat{A} = \bar{U}^T \bar{y};$$

или

$$\hat{A} = (\bar{U}^T \bar{U})^{-1} \bar{U}^T \bar{y} \quad (27)$$

где $\bar{y} = [C_{(1)} \dots C_{(r)} \dots C_{(n)}]^T$ - вектор выходов (n реализаций),

$$\hat{A} = \begin{bmatrix} \hat{A}_1 \\ \hat{A}_2 \\ \hat{A}_m \end{bmatrix}^T - \text{вектор оценок коэффициентов модели.}$$

При реализации (27) в процедуре параметрической идентификации заложено условие, чтобы число измерений n было больше числа идентифицируемых параметров m , т.е. $n > m$.

Для придания модулю прогнозирования величин $f^k(i+k)$ большей гибкости и адаптивности на конечном интервале k ($k = \overline{1, l}$, где l - количество шагов на интервале прогноза ΔT_M), этим же модулем, путём перекрёстного прогнозирования определяется и вводится поправка ошибок прогноза, связанная с помехой η , которая при классических методах сглаживается и не учитывается (например, линейная фильтрация Колмогорова-Винера, Винера-Рагазини, нелинейная фильтрация Калмана и др.).

При перекрестном прогнозировании, с вводом поправок, параметры модели A_i , определённые методом самоорганизации без учёта помех η , корректируются по действительным ошибкам, оцениваемым при сравнении прогнозных значений $f_{\Pi}^k(i+k)$ с реальным процессом $f^k(i+k)$ в конце интервала прогнозирования ΔT_{Π} . Здесь получается рекуррентная процедура на каждом шаге определения поправки $\Delta A_i(i+k)$ по значениям её на предыдущем шаге $\Delta A_i(i+k-1)$.

Изменение (дрейф) коэффициентов модели может быть представлен выражением полиномиального вида по параметру k , (k – дискретное время):

$$\Delta A[i] = \sum_{j=0}^m b_j k^j + \eta_i, \quad (28)$$

где b_j - коэффициенты полинома, m - порядок полинома, ΔA - поправка к коэффициентам A самоорганизующейся модели. Для адаптивного перекрестного прогнозирования оценок A модели на k интервалов вперёд используются соотношения

$$A[i+k] = M[A[i] + \Delta A[i+k]], \quad (29)$$

$$\Delta A[i+k] = \sum_{j=0}^m b_j k^j + \eta_i. \quad (30)$$

Критерий адаптации в модуле МАП задаётся в неявном, алгоритмическом виде

$$\mathfrak{F}_a = M[A^*[i+k] - F(A^*, \Delta A^*, \{A_i\})]^2 \rightarrow \min \quad (31)$$

Здесь $\{A_i\}$ - набор параметров A_i самоорганизующейся модели, A^* , ΔA^* оптимизирующие параметры, доставляющие функционалу минимум.

Компьютерный и субъективный прогнозы в модулях МЭП и МСП получаются на базе классических методов с дальнейшим согласованием оценок из условия непротиворечивости прогнозов в модуле МОЭП:

$$f_{\mathfrak{D}1}^k(x), f_{\mathfrak{D}2}^k(\bar{x}), \dots, f_{\mathfrak{D}n}^k(\bar{x}) \in \Delta o, \quad (32)$$

где Δo - общий доверительный интервал, при заданной вероятности P . Прогнозы являются непротиворечивыми, если точечные прогнозы принадлежат Δo , а величина области Δo удовлетворяет условию

$$\Delta o / \Delta \min\{1, 2, \dots, n\} \geq k_3, \quad (33)$$

где k_3 - заданное значение доверительного интервала.

Таким же образом производится согласование математических прогнозов в модуле МОМП для различных частот (периодов ΔT_{Π}) прогнозирования.

На последнем этапе в модуле МСОП производится совместная обработка субъективных и математических прогнозов. При совместной обработке учитывается возможность самообучения операторов прокатного стана (повышение квалификации) и совершенствование математических методов прогнозирования. Для индивидуальной (раздельной) оценки оператора стана или метода введено понятие относительной степени доверия d_m методу (оператору), где $0 \leq d_m \leq 1$. Величина может быть установлена для оператора или метода по дисперсии или среднеквадратической ошибке, определённой на $i+k$ интервалах прогнозирования:

$$D = \frac{1}{k} \sum_{i=1}^k (f_{\Pi}^k[i] - f^k[i])^2, \quad (34)$$

$$\delta_{cx} = \sqrt{\frac{1}{k} \sum_{i=1}^k (f_{\Pi}^k[i] - f^k[i])^2}, \quad (35)$$

где D, δ_{cx} дисперсия и среднеквадратическая ошибка соответственно, $f_{п}^k[i], f^k[i]$ - прогнозные и реальные значения процесса (фактора f^k).

Относительная степень доверия будет

$$d_m = \frac{\delta_{cx}}{\frac{1}{k} \sum_{i=1}^k f^k[i]} \quad (36)$$

Величина d_m придаёт процессу прогнозирования адаптивный характер, поскольку может изменяться в результате самообучения и приобретения опыта оператором стана. С учётом (34) в модуле МСПП производится оптимизация адаптивного гибридного прогноза.

Выводы:

В отличие от классических методов, предложенные метод и модель прогнозирования обеспечивают:

- оперативное получение модели непосредственно на самом прокатном стане в процессе управления;

- прогнозирование не только величин f^k , но и самого оператора предсказания, формируя временную последовательность из ошибок предсказания и поправок, учитываемых при очередном прогнозе, что позволяет учесть влияние помех η , вместо их сглаживания (фильтрации);

- получение гибридных прогнозов по независимым прогнозам оператора прокатного стана, с возможностью учёта их совершенствования и самообучения;

- оптимизацию достоверности гибридного прогноза и адаптацию степени доверия методам прогнозирования и опыту оператора стана по результатам совпадения прогнозов с реальными процессами.

Метод и модель пригодны для прогнозирования факторов на любом уровне иерархии сложной системы автоматического управления прокатным станом.

Литература

1. Борисов А.А. Разработка двумерной системы управления клетью непрерывного листопрокатного стана. // Наукові праці Донецького національного технічного університету. Серія: Електротехніка та енергетика, випуск 67. - Донецьк: ДонНТУ, - 2003. - С.195-198.

2. Зильберг Ю.В. О некоторых противоречиях и допущениях теории прокатки // Известия высших учебных заведений. Чёрная металлургия. №11. - 2004. - С.24-25

3. Ивахненко А.Г., Мюллер Й.А. Самоорганизация прогнозирующих моделей. - К.: Техника. - 1985; Берлин: ФЭБ Ферлаг Техник. - 1984. - 223 с

4. Борисов О.О. Автоматичне управління безперервним прокатним станом як багатозв'язним об'єктом // Вісник національного технічного університету «ХПІ», випуск 55. - Харків: НТУ «ХПІ», - 2005. - С. 99-105.