

ОПТИМИЗАЦИЯ НЕЙРО-НЕЧЕТКОЙ МОДЕЛИ УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ В МЕТАЛЛУРГИИ

В статье предложен модифицированный метод реализации модуля нейро-нечеткого управления, сочетающий использование субтрактивной кластеризации в качестве способа исходного разбиения пространства переменных и алгоритма на основе конкуренции как средства синтеза нечетких правил. Модель позволит повысить точность структурной и параметрической идентификации. В статье приводятся результаты тестирования модуля на примере управления процессом полимеризации оцинкованного листа.

Многосвязный тепловой объект, нейро-нечеткая модель, алгоритм обратного распространения, субтрактивная кластеризация, агрегат полимерных покрытий.

The article presents the modified method of the module of neuro-fuzzy control, combining the use of subtractive clustering as the means of initial partition of variables and the algorithm based on competition as the means of synthesis of fuzzy rules. The model allows improving the accuracy of structural and parametric identification. The paper presents the results of the module's testing for controlling polymerization process of the galvanized metal sheet.

Multivariable thermal object, neuro-fuzzy model, back-propagation algorithm, subtractive clustering, color coating line.

В сложных технологических процессах в металлургическом производстве, как правило, используются объекты с динамическими характеристиками, нестационарным поведением и неоднозначными свойствами. В частности, к таковым можно отнести многосвязные тепловые объекты. Для них многие процессы производственного цикла нуждаются в адаптивном управлении, так как частое изменение параметров самого объекта управления или внешних возмущений, действующих на него, приводят к постоянному изменению характеристик и структуры регулятора. Обеспечить необходимое интеллектуальное управление способны нейро-нечеткие модели, объединяющие в себе наилучшие свойства нечеткой логики и нейронных сетей.

Сначала опишем один из вариантов реализации нейро-нечеткого модуля. При определенных условиях нечеткая система может быть представлена в форме многослойной сети с прямым распространением сигнала. Знания, составляющие основу корректного функционирования модуля нечеткого управления, записываются в виде правил (1) [3].

$$\begin{aligned} R^k : IF (x_1 \text{ это } A_1^k \text{ AND } x_2 \text{ это } A_2^k \text{ AND } \dots \text{ AND } x_n \text{ это } A_n^k) \\ THEN (y_1 \text{ это } B_1^k \text{ AND } y_2 \text{ это } B_2^k \text{ AND } \dots \text{ AND } y_m \text{ это } B_m^k), \end{aligned} \quad (1)$$

где $A_1^k, \dots, A_n^k, B_1^k, \dots, B_m^k$ – нечеткие множества; $k=1, \dots, n$; $x_1, x_2, \dots, x_n$ – входные переменные модели; $y_1, y_2, \dots, y_m$ – выходные переменные модели.

Во многих технологических процессах выходы $y_1, y_2, \dots, y_m$ взаимно независимы. Поэтому без утраты общности будем рассматривать модели с одним выходом y , т.е. разобьем исходную модель на под-

модели, в которых для выхода y будем иметь набор нечетких множеств B^k .

Нечеткий вывод определяется выражением (2) [3].

$$\mu_{B^k} = \sup_{x \in X} \left\{ \mu_{A^k}(x) * \mu_{A^k \rightarrow B^k}(x, y) \right\}. \quad (2)$$

Пусть теперь Т-норма, нечеткая импликация и декартово произведение в данной формуле имеют тип произведение, а операция введения нечеткости – тип синглетон. В качестве функций принадлежности входных и выходных переменных можно использовать функции Гаусса, определяемые по формулам (3), (4):

$$\mu_{A_i^k}(\bar{x}_i) = \exp \left[- \left(\frac{\bar{x}_i - \bar{x}_i^k}{\sigma_i^k} \right)^2 \right], \quad (3)$$

$$\mu_{B^k}(\bar{y}) = \exp \left[- \left(\frac{\bar{y} - \bar{y}^k}{\sigma^k} \right)^2 \right], \quad (4)$$

где $\bar{x}_i^k, \bar{y}^k$ – центры, а σ_i^k, σ^k – коэффициенты растяжения (сжатия) гауссовских кривых для входных и выходных переменных соответственно.

Тогда модуль нечеткого управления принимает вид (5):

$$\bar{y} = \frac{\sum_{k=1}^N \bar{y}^k \sigma^k \left(\prod_{i=1}^n \exp \left[- \left(\frac{\bar{x}_i - \bar{x}_i^k}{\sigma_i^k} \right)^2 \right] \right)}{\sum_{k=1}^N \sigma^k \left(\prod_{i=1}^n \exp \left[- \left(\frac{\bar{x}_i - \bar{x}_i^k}{\sigma_i^k} \right)^2 \right] \right)}. \quad (5)$$

Теперь каждый элемент этой формулы можно задать в форме функционального блока, что после соответствующего объединения позволяет создать нейроподобную многослойную сеть. А поскольку алгоритм обратного распространения ошибки можно обобщить на любую сеть с прямым распространением сигнала, то данный модуль нечеткого управления можно обучать также как и обычную нейронную сеть. При этом параметры и веса будут модифицироваться в процессе обучения, что позволит улучшать подбор нечетких множеств.

Основные трудности использования полученной структуры для управления технологическими процессами возникают в ходе построения нечетких правил и задания начальных значений параметров функций принадлежности. Это может быть связано с невозможностью получения экспертных знаний или отсутствием специалистов, осуществляющих их формализацию для обработки интеллектуальными системами управления.

Исходя из этого, актуальной является задача построения нечетких правил и формирования функций принадлежности на основе обучающих данных (показатели с контроллеров, датчиков, пирометров и т.д.). Она решается с помощью методов, основанных на самоорганизации. Применительно к функциям принадлежности это означает такое размещение их центров, чтобы они охватывали только те области входных и выходных пространств, в которых находятся данные. Поэтому в данном случае оправданным является использование методов кластеризации. При этом полезным было бы избавление специалиста, работающего с программным обеспечением, от задания количества термов для всех входных и выходных переменных. Будем использовать для разбиения пространства каждой переменной метод субтрактивной кластеризации [4], [6], [7], не требующей задания количества кластеров.

Данный алгоритм предполагает, что каждая точка пространства данных является возможным центром кластера. Чем плотнее в ее окрестности расположены другие объекты, тем выше значение потенциала точки. Потенциал рассчитывается по формуле (6):

$$P(x_i) = \sum_{j=1}^n e^{-\alpha(D(x_i, x_j))^2}, \quad (6)$$

где $x_i, i=1, \dots, n$ – обучающие данные; $D(x_i, x_j)$ – функция, определяющая расстояние от вектора x_i до вектора x_j (мы будем осуществлять кластеризацию для каждой переменной в отдельности, поэтому данное расстояние будет представлять собой модуль разности значений переменных); $\alpha = \frac{4}{r_\alpha^2}$. r_α – положительная постоянная, характеризующая масштаб расстояний между объектами. Ее значение можно принять равным единице, деленной на среднее расстояние между точками.

Далее итерационно выбираются центры кластеров среди точек с максимальными потенциалами. Для этого центром первого кластера назначают объект с наибольшим потенциалом x_1^* . Обычно он окружен несколькими точками с также высокими потенциалами. Поэтому назначение центром следующего кластера точки с максимальным потенциалом среди оставшихся вершин привело бы к выделению большого числа близко расположенных центров кластеров. Чтобы выбрать следующий центр кластера, необходимо вначале исключить влияние только что найденного. Для этого значения потенциалов для оставшихся возможных центров кластеров пересчитываются следующим образом: от текущих значений потенциала вычитают вклад центра только что найденного кластера. Перерасчет потенциалов происходит по формуле (7):

$$P(x_i) = P(x_i) - P(x_1^*) \cdot e^{-\beta(D(x_i, x_1^*))^2}, \quad (7)$$

где $\beta = \frac{4}{r_\beta^2}$. r_β – положительная константа, характеризующая масштаб размера одного кластера. Часто принимают $r_\beta = 1,25 \cdot r_\alpha$ [1], [7].

Центр второго кластера x_2^* определяется как точка с наибольшим значением потенциала $P(x_2^*)$. Далее аналогичным образом пересчитываются значения потенциалов по формуле (8):

$$P(x_i) = P(x_i) - P(x_2^*) \cdot e^{-\beta(D(x_i, x_2^*))^2}. \quad (8)$$

Итерационная процедура пересчета потенциалов и выделения центров кластеров продолжается до тех пор, пока максимальное значение потенциала превышает некоторый порог, зависящий от потенциала $P(x_1^*)$ первого кластера. Часто значение порога полагают равным $0,15 \cdot P(x_1^*)$ [1], [5].

Использование субтрактивной кластеризации, примененной к векторам обучающих данных, позволяет получать нечеткие правила уже на основе найденных центров кластеров [4], [5], [7]. Однако мы здесь будем использовать только тот факт, что в качестве начальных значений центров функций принадлежности входных и выходных переменных можно взять координаты центров кластеров $x_j^*, j=1, \dots, K$, а в качестве начальных значений ширины функций принадлежности – выражение

$$\sigma = \frac{1}{\sqrt{2 \cdot \alpha}}.$$

Перейдем к решению проблемы синтеза нечетких правил. Модифицируем структуру нейро-нечеткой сети, определяемую формулой (5). Используемая схема представлена на рис. 1 [3].




Рис. 1. Структура модуля нейро-нечеткого управления на этапе построения правил

Элементы слоя L1 данной схемы реализуют функции принадлежности входных переменных.

Способ получения выходных значений слоя L2 зависит от выбора типа декартова произведения в формуле (2). В нашем случае на выходах получаем степени активности нечетких правил, определяемые произведением значений степеней принадлежности, рассчитанных на выходе слоя L1. Количество элементов в слое равно количеству правил. Конкретные элементы слоя L2 должны быть связаны с теми выходами слоя L1, которые относятся к нечетким множествам, учитываемым в данном правиле. Так как правила нам неизвестны, то оба слоя соединяются так, чтобы получить все возможные комбинации.

Слой L3 будет передавать сигналы в обратном направлении. Он реализует функции принадлежности нечетких множеств, соответствующих заключениям правил. Сначала все элементы слоя L2 соединяются со всеми элементами слоя L3. Это означает, что выводы правил еще не определены. В процессе обучения суммарное количество правил уменьшается. Остаются лишь те связи, которые соответствуют правильным суждениям и заключениям. В слое L4 в обратном направлении передается эталонный выходной сигнал из обучающей выборки.

Синтез базы правил осуществляется последовательным выполнением этапов фиксации, исключения и объединения правил [3], [8]. Задача этапа фиксации заключается в построении корректных нечетких правил на основе обучающих данных с использованием выполненного нами ранее разделения входного и

выходного пространств, а также предварительного выбора формы функций принадлежности. Данные в сеть будут поступать с обеих сторон, т.е. к элементам первого и последнего слоев с последующим их двунаправленным распространением через L1 и L2 с одной стороны и через L3 и L4 – с другой. Корректные соединения выходов слоев L2 и L3 (т.е. условий и выводов правил) можно установить, используя так называемый алгоритм на основе конкуренции (competitive learning algorithm). Обозначим через $w_{kr}^{(3)}$ ($k=1, \dots, N; r=1, \dots, M$) вес связи между k -м элементом слоя L2 и r -м элементом слоя L3. Для его актуализации применяется зависимость (9) [3]:

$$w_{kr}^{(3)}(t+1) = w_{kr}^{(3)}(t) + \mu_{B'}(d(t)) \cdot (\tau_k - w_{kr}^{(3)}(t)), \quad (9)$$

где τ_k – степень активности k -го правила.

По завершении обучения веса связей слоя L3 определяют существование заключений соответствующих правил. Далее осуществляется исключение некорректных правил. Если некоторый элемент слоя L2 связан с различными элементами слоя L3, то выбирается не более одного соединения с наибольшим весом, а остальные исключаются. Таким образом, конкретному условию правила ставится в соответствие только одно заключение. В случае, когда веса всех связей пренебрежимо малы, они все исключаются и считается, что данное правило не оказывает существенное влияние на выходную переменную.

Далее выполняется уменьшение количества пра-

вил путем их объединения. Критерии для объединения элементов слоя L2 следующие: 1) правила имеют одинаковое заключение, 2) некоторые условия правил совпадают, 3) остальные условия правил образуют полное множество значений какой-либо лингвистической переменной [8]. Если какое-либо множество элементов слоя L2 соответствует этим критериям, то его можно заменить единственным элементом, оставив при этом только общие условия правил.

По окончании объединения будет решена задача построения нечетких правил. Это дает возможность перейти к этапу уточнения параметров функций принадлежности. Сформированная структура, определяемая формулой (5), может быть теперь обучена методом обратного распространения ошибки. Все элементы и связи, созданные на предыдущих этапах, фиксируются и остаются неизменными. Сеть в целом будет распространять сигнал в прямом направлении.

Применительно к металлургическому производству тепловым объектом со сложными связями и непостоянными характеристиками является агрегат полимерных покрытий, который используется для производства горячеоцинкованного проката с лакокрасочным покрытием. Установка имеет в своем составе печь сушки отделочного слоя, которая разделена на 7 печных зон [2].

Для успешного закрепления лака на металле после выхода полосы из печей на ее поверхности должна быть установлена температура, попадающая в интервал допустимых температур полимеризации.

Нагрев осуществляется путем задания температур всех 7 зон печи. Для отвода отработанного взрывоопасного воздуха используются вентиляторы. Для поддержания необходимой для процесса горения воздушно-газовой смеси существует воздуховод, обеспечивающий приток чистого воздуха, температура которого равна 25 °C [9]. С целью повышения качества конечной продукции необходимо автоматизировать процесс полимеризации оцинкованного листа.

Описанный метод построения нейро-нечеткой модели был реализован программно в среде Borland Delphi 7 и протестирован на примере управления агрегатом полимерных покрытий. Были выделены следующие входные переменные: скорость движения полосы, толщина покрытия, мощность вентиляторов, объем отработанного воздуха, объем запирающего воздуха. В качестве выходной переменной выступала каждая из 7 управляющих температур. На рис. 2 представлен график обучения модели для расчета температуры в первой зоне.

Анализ результатов моделирования позволяет сделать вывод о достаточной степени точности модели: на 9499 эпохе ошибка выходного значения температуры в первой зоне печи стала меньше допустимой. Аналогичным образом осуществляется настройка параметров для остальных 6 зон. После этого модель может быть использована в системе управления агрегатом полимерных покрытий.




Рис. 2. Результаты тестирования модели управления процессом полимеризации горячеоцинкованного листа

Применение субтрактивной кластеризации и алгоритма на основе конкуренции позволило построить модифицированный метод проектирования нейро-нечеткого модуля, который был реализован и протестирован на примере управления агрегатом полимерных покрытий.

Литература

1. Леоненков, А.В. Нечеткое моделирование в среде MATLAB и fuzzyTECH / А.В. Леоненков. – СПб., 2005.
2. Максимова, О.Г. Применение компьютерного моделирования для управления процессом сушки лакокрасочного покрытия на поверхности металлического листа / [О.Г. Максимова и др.] // Вестник Череповецкого государственного университета. – 2012. – № 4. – Т. 2. – С. 14 – 16.
3. Рутковская, Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М., 2006.

4. Штовба, С.Д. Проектирование нечетких систем средствами MATLAB / С.Д. Штовба. – М., 2007.

5. Chiu, S. An Efficient Method for Extracting Fuzzy Classification Rules from High Dimensional Data / S. Chiu // Advanced Computational Intelligence. – 1997. – V. 1. – № 1.

6. Chiu, S. Fuzzy model identification based on cluster estimation / S. Chiu // Journal of Intelligent and Fuzzy Systems. – 1994. – V. 2. – P. 267 – 278.

7. Chopra, S. Reduction of Fuzzy Rules and Membership Functions and Its Application to Fuzzy PI and PD Type Controller / S. Chopra, R. Mitra, V. Kumar // IJCAS. – 2006. – V. 4. – № 4. – P. 438 – 447.

8. Lin, C.-T. Neural-network-based fuzzy logic control and decision system / C.-T. Lin, G.C.S. Lee // IEEE Transactions on Computers. – 1991. – V. 40. – № 12. – P. 1320 – 1336.

9. Matamoros, S. Подробное описание печной установки для печи грунтового слоя и печи отделочного слоя и термореактора АПП / S. Matamoros. – Леверкузен, Германия, 2005.

УДК 674.815

А.В. Ерофеев

Научный руководитель: доктор технических наук, профессор В.П. Ярцев

ВЛИЯНИЕ АТМОСФЕРНЫХ ВОЗДЕЙСТВИЙ НА ТВЕРДОСТЬ ДЕКОРАТИВНЫХ ПЛИТ

Изучено влияние различных атмосферных воздействий на твердость декоративных плит. Получена экспериментальная зависимость падения твердости декоративного слоя плиты от количества циклов атмосферных воздействий.

Декоративные плиты, неблагоприятные атмосферные воздействия, твердость декоративного слоя.

The paper studies the influence of different weather conditions on the hardness of decorative plates. The experimental dependence of the hardness decreasing of the decorative layer of plates on the number of cycles of weather conditions is obtained.

Decorative plates, unfavorable atmospheric conditions, hardness of the decorative layer.

После ужесточения требований по теплозащите зданий и сооружений в строительстве стали использовать эффективный утеплитель, который необходимо защищать от действия неблагоприятных атмосферных воздействий. К неблагоприятным атмосферным воздействиям относят попеременный переход через 0 °С в осенне-весенний период, сопровождающийся переходом влаги, содержащейся в материале, из одного агрегатного состояния в другое, воздействие повышенных температур в летний период эксплуатации, а также воздействие солнечного света [3]. В качестве защиты от действия атмосферных воздействий в настоящее время применяют различные виды облицовки, в том числе и декоративные плиты, состоящие из основы, связующего и материала декоративного слоя [1]. В качестве основы рассматриваются несколько видов плит: ЦСП, ДСП, ДВП, фанера. А в качестве связующего – два вида термореактивных смол: полиэфирная и эпоксидная смолы. Применение этих смол обусловлено их высокой конкурентно способностью с точки зрения цена – качество – экологичность. Керамзитовый песок,

древесные опилки и песок применяют в качестве материала декоративного слоя. Рассматриваемые плиты имеют не только защитные функции (защита утеплителя от действия внешних неблагоприятных воздействий), но и декоративные. Таким образом, необходимо исследовать влияние неблагоприятных атмосферных воздействий на твердость декоративных плит, по которой можно судить о долговечности декоративного слоя при работе плиты в реальных условиях эксплуатации. Так как изучить совокупное влияние факторов представляется затруднительным, рассмотрим влияние этих факторов на твердость отдельно друг от друга. Под твердостью понимается способность материала сопротивляться проникновению в него другого тела.

Атмосферные воздействия моделировали климатическими испытаниями: систематический переход температур через 0 °С в осенне-весенний период – циклами замораживания / оттаивания, повышенные температуры в летний период – циклами теплового старения, воздействие солнечного света – циклами ультрафиолетового старения.