

АВТОМАТИЗИРОВАННОЕ УПРАВЛЕНИЕ ПРОЦЕССОМ ТРАВЛЕНИЯ ЛИСТОВОГО ПРОКАТА С ПРИМЕНЕНИЕМ НЕЙРОСЕТЕВОЙ МОДЕЛИ

Рассматривается подход к нейросетевой диагностике состояния технологического оборудования и анализируется влияние диагностических параметров на качество продукции применительно к автоматизации процесса травления на технологической линии холодного проката листовой стали. Дефекты могут вызываться сбоем одного из блоков управления механизмом протяжки, если этот блок не может оперативно отслеживать скорость, задаваемую другим механизмом вращения. При этом длина металлической петли в травильной ванне непрерывно меняется, что влияет на качество продукта. Предлагаемый метод позволяет обнаружить и предотвратить сбой контуров автоматизированного управления на основе нейросетевого анализа данных мониторинга без остановки технологической линии.

Введение

Современные металлургические предприятия характеризуются высоким уровнем сложности технологических процессов и большим числом переменных, регулируемых в замкнутых циклах. Быстрое и точное обнаружение и диагностика возможных неисправностей могут существенно увеличить безопасность производства и сократить производственные затраты. Обнаружение неисправностей и их изоляция особенно сложны в случае применения аналоговых систем управления, не реализующих функцию автоматического мониторинга параметров процесса, а предполагающих лишь их текущий визуальный контроль операторами. В этой ситуации трудно найти зависимость между значимостью некоторого дефекта (или последовательностей дефектов) и возможностью отказа. Обнаружение неисправностей и диагностика многомерных технологических систем является нетривиальной задачей. В общем случае входы и выходы таких систем имеют сложную взаимосвязанную структуру, что осложняет прогнозирование качества и диагностику возможного возникновения дефектов в производственном процессе. Целесообразно рассмотреть решение практической задачи прогнозирования, основанное на адаптивном алгоритме вычисления средних значений и отклонений остатков [1]. Статистические характеристики остатков можно использовать для классификации качества продукции. Остатки определим, как разность между оптимальным и реальным выходами процесса.

Для процесса травления на технологической линии проката листовой стали нормальная и сбойная ситуации могут быть диагностированы с помощью искусственной нейронной сети (ИНС), реализующей модель, которая позволяет классифицировать состояние механизмов вращения. Корреляция между качеством продукта, определяемым соответствующим коэффициентом и остатком, используется для классификации качества. Параметры техпроцесса будем моделировать с применением многослойных ИНС. При этом возникают задачи определения топологии сети и правил настройки ее весовых коэффициентов для наиболее полного отражения зависимостей типа «вход-выход» моделируемого процесса [2].

Обнаружение неисправностей и диагностика (ОНД) основаны на сравнении характеристик, определяемых по измерениям, с ожидаемыми характеристиками. Если отклонение превышает порог, то диагностируется дефект. Такой процесс может быть реализован с помощью двухшаговой процедуры ОНД. Обнаружение нестандартных ситуаций предполагает получение данных от датчиков и их предварительную обработку для выявления и классификации диагностирующих симптомов. Регистрируемая последовательность сигнатурных значений таких симптомов может далее использоваться другой моделью, которая принимает во внимание значимость дефектов и вероятность отказа. Процедура ОНД основана на анализе остатков, которые определяются разностью выходов моделей для нормальных и нестандартных ситуаций. При оценке качества используется метрическое расстояние между

статистическими данными о процессе и их влиянием на качество продукции. Оптимальный режим работы задают для оптимизации качества продукции; корреляция между ними рассчитывается с применением ИНС.

Первый шаг предлагаемой процедуры состоит в определении класса качества продукции в соответствии с выходной динамикой техпроцесса. Высокая стабильность выходных параметров техпроцесса свидетельствует о высоком качестве прокатной продукции. Вторым шагом является построение имитационной модели. Оптимальное качество продукции соответствует минимальному метрическому расстоянию между средним значением оптимального остатка и его фактическим значением. На третьем шаге определяется вид функциональной зависимости между значимостью дефекта, найденной по остаткам, и влиянием дефекта на производственные отказы.

Диагностика отказов

Рассмотрим динамическую систему, описываемую нелинейной ARMA-моделью (NARMA) следующего вида:

$$y(t)=f[y(t-1),\dots,y(t-n),u(t-1),\dots,u(t-m),w(t-1),\dots,w(t-p)], \quad (1)$$

где $y(t)$ – измеряемый сигнал; $u(t)$ – управляющий вход.

При нейросетевом моделировании будем использовать алгоритм обратного распространения ошибки (Back-propagation (BP)) [2]. Обучаемая ИНС состоит из L слоев. Слой k содержит N_k нейронов. Соседние слои связаны взвешенными синапсами. Вес w_{ij}^k соответствует связи между i -м нейроном k -го слоя и j -м нейроном слоя $k+1$. Первый слой содержит входные сигналы сети x , а последний слой – выходы сети y . В качестве активационной функции будем использовать сигмоидальную функцию следующего вида:

$$f_j^k(u_j^k)=\frac{1}{1+e^{-u_j^k}}, \quad (2)$$

здесь

$$u_j^k = \sum_{i=1}^{N_{k-1}+1} z_i^{k-1} w_{ij}^{k-1}. \quad (3)$$

Для обучения сети задается набор обучающих пар, состоящих из p векторных пар вход/выход (x_p, d_p) . Целью обучения является такой выбор весов, который минимизирует среднеквадратичную ошибку между прогнозами y_p и желаемыми значениями выхода d_p , получаемую по всем обучающим парам:

$$\min_w J = \sum_{p=1}^p E_p, \quad (4)$$

где E_p – сумма квадратичных ошибок, соответствующих одной обучающей паре, определяемая следующим образом:

$$E_p = \|y_p - d_p\|^2. \quad (5)$$

На этапе обучения нейронная сеть (многослойный персептрон) инициализируется малыми случайными весами синапсов. Обучающая пара нейросетевой модели выбирается случайным образом, и входной вектор x_p подается на вход сети, после чего вычисляется прогнозируемое значение выхода y_p . Градиент в пространстве весовых коэффициентов нейросетевой модели определяется итерационно по обобщенному дельта-правилу (Generalized Delta Rule (GDR)), в соответствии с которым убывающая последовательность векторов g_p , задающих направление изменения весов синапсов, рассчитывается по данным обучающей выборки [2]. С учетом градиента g_p изменение веса на шаге q определяется по формуле:

$$\Delta_q w = \eta g_p + \alpha \Delta_{q-1} w. \quad (6)$$

В этом выражении константы α, η являются параметрами обучения, которые задают скорость изменения шага и предназначены для предотвращения скачкообразных измене-

ний весов от шага к шагу. После обновления значений весовых коэффициентов выбирается новая обучающая пара, и процедура повторяется до достижения приемлемого уровня критерия качества обучения ИНС (4).

Нейросетевую диагностику будем осуществлять с применением адаптивной процедуры вычисления средних остатков и их отклонений. Последствия возникновения дефектов в смысле их влияния на качество стального проката зависят от динамических изменений остатков, которые коррелированы с коэффициентом качества прокатной продукции.

Процедура локальной диагностики основана на адаптивном методе расчета средних значений остатков и их отклонений. Средние значения каждой суммарной статистики обновляются по следующему правилу:

$$\bar{x}_n = \lambda \bar{x}_{n-1} + (1-\lambda)x_n, \quad (7)$$

где \bar{x}_n – рассчитанное по n точкам среднее значение остатка; x_n – данные для новой точки; λ – фильтрующий коэффициент.

Величина отклонения для каждой суммарной статистики рассчитывается рекурсивно по n точкам как среднеквадратическое отклонение σ_n .

Рассчитанные относительные изменения средних значений остатков и их отклонений будем использовать в качестве входных сигналов нейронной сети при оценивании коэффициента (индекса) качества прогноза и классификации Q_n . Этот коэффициент предлагается вычислять следующим образом:

$$Q_n(t) = F_{\text{инс}}(\sigma_n(t), \bar{x}_n(t)), \quad (8)$$

где $F_{\text{инс}}$ – нейросетевая модель; $\sigma_n(t)$ и $\bar{x}_n(t)$ – соответственно среднеквадратичное отклонение и среднее значение остатка в рабочем окне n .

Практическое приложение. На рис.1 приведена часть схемы процесса травления. Основной задачей автоматизированного управления является сохранение постоянной длины петли между механизмами вращения (протяжки) (1) и (2). Механизму вращения (2) задается постоянная скорость вращения, определяемая производительностью линии [3]. Механизм (1) должен обеспечивать такую скорость вращения, чтобы длина петли оставалась постоянной. Длина петли измеряется оптическим датчиком, сигнал которого используется для коррекции скорости механизма (1).

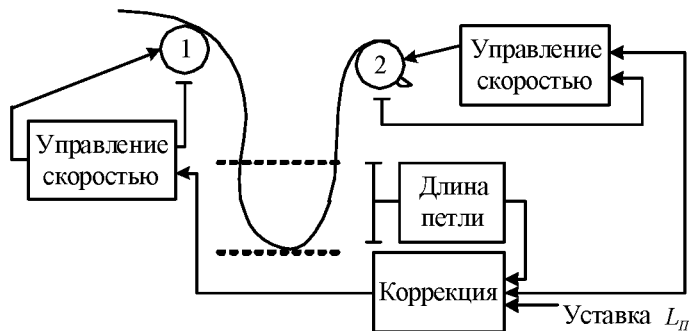


Рис. 1. Схема управления длиной петли в травильной ванне

Сбой в работе блока управления механизмом (1) приводит к изменению его скорости вращения (и, соответственно, к изменению длины петли), вследствие чего длина петли может превысить допустимые значения (максимальное или минимальное), что вызовет остановку технологической линии. Динамические изменения длины петли (в частности, высокочастотные колебания) снижают качество травления и могут вызвать механические деформации ленты проката.

Рис.2 иллюстрирует принцип управления длиной петли.

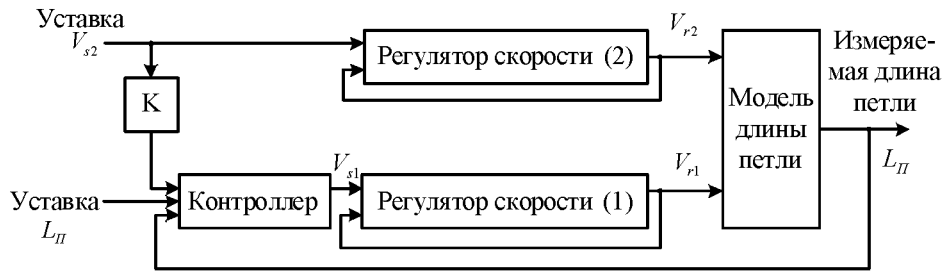


Рис.2. Принцип управления длиной петли

Управление травлением осуществляется путем изменения скорости вращения V_{s1} в соответствии с заданной скоростью V_{s2} . Выходными переменными регуляторов скорости (1) и (2) являются, соответственно, измеряемые скорости вращения V_{r1} и V_{r2} , а выходной переменной всей замкнутой системы управления является измеряемая длина петли $L_{П}$. Анализ данных показывает, что ограниченные возможности управления скоростью вращения механизма (1) не позволяют поддерживать требуемую производительность линии. Целесообразно осуществить моделирование процесса диагностики неисправностей с помощью ИНС, обучаемой на реальных данных техпроцесса. Особый интерес представляет построение динамической модели, отражающей зависимость между измеряемой длиной петли, реальными скоростями и задающими воздействиями для регуляторов скорости механизмов вращения (1) и (2). Рассмотрим следующую структуру такой модели:

$$L_{П}(t) = F_{\text{ИНС}} [L_{П}(t-1), L_{П}(t-2), V_{r1}(t-1), V_{r1}(t-2), V_{r2}(t-1), V_{r2}(t-2), V_{s1}(t), V_{s2}(t)], \quad (9)$$

где $F_{\text{ИНС}}$ – структура ИНС, полученная в процессе обучения по данным для нормальных режимов работы технологической линии [4].

Ошибка работы системы управления длиной петли определяется разностью:

$$\varepsilon(t) = L_{П}(t) - \bar{L}_{П}(t), \quad (10)$$

здесь $L_{П}(t)$ и $\bar{L}_{П}(t)$ – текущие значения реальной и заданной длины петли.

В нормальном режиме $\varepsilon(t) \in D_{\text{норм}}$, $D_{\text{норм}}$ – допустимая область, которая обеспечивает оптимальное качество проката; $\varepsilon(t)$ – нормально распределенная величина, характеризующая средним значением $\bar{\varepsilon}$ и дисперсией σ . Нештатная ситуация характеризуется попаданием величины $\varepsilon(t)$ в недопустимый диапазон $D_{\text{сб}}$, т.е. $\varepsilon(t) \in D_{\text{сб}}$. Переход процесса в такой режим вызывает соответствующие структурные и параметрические изменения рассматриваемой модели, т.е.:

$$\Delta F_{\text{ИНС}} = F_{\text{ИНС}}^{\text{сб}} - F_{\text{ИНС}}, \quad (11)$$

где $F_{\text{ИНС}}^{\text{сб}}$ – модель для нештатных (сбойных) ситуаций.

Если $\lim_{t \rightarrow 0} \Delta F_{\text{ИНС}} \rightarrow 0$, то ошибка является устранимой в установившемся состоянии;

если $\lim_{t \rightarrow 0} \Delta F_{\text{ИНС}} \rightarrow \Delta F_{\text{ИНС}}^0$, то ошибка является статической. Изменения $\Delta F_{\text{ИНС}}$ вызывают эквивалентные изменения остатка, что влияет на качество проката.

Структура и процесс обучения ИНС были заданы при следующих параметрах: размерности вектора входа и вектора выхода – 3 и 1 соответственно; количество слоев – 2; количество нейронов в первом и выходном слоях – 8 и 1 соответственно; импульс – $\alpha=0.65$; скорость обучения – $\eta=0.75$. На рис. 3 показаны входные и выходные данные, использованные для обучения ИНС, а на рис. 4 – динамика измеренных и расчетных выходов.




Рис. 3. Данные по входным и выходным переменным

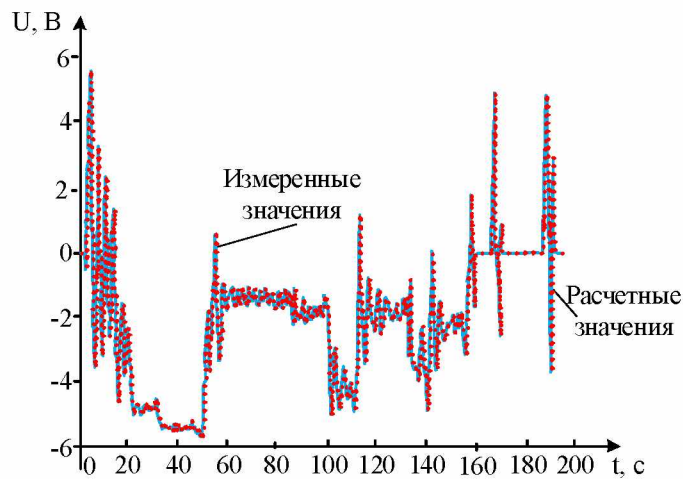


Рис. 4. Расчетные и измеренные выходы

Результаты проведенного тестирования подтверждают возможность применения полученной нейросетевой диагностирующей модели, отражающей зависимость между измеряемой длиной петли, реальными скоростями и задающими воздействиями, для автоматизированного управления технологической линией травления процессами проката листовой стали.

Выводы

Научная новизна полученных результатов заключается в модификации подхода к автоматизации управления процессом травления для технологической линии холодного проката листовой стали с применением нейросетевой диагностирующей модели. Суть предложенной модификации состоит в применении оригинальных моделей регулирования длины петли в травильных ваннах, что позволяет существенно повысить качество конечного продукта. Показана целесообразность применения предложенного индекса качества для классификации локальных дефектов в рабочем окне. Последствия возникновения сбоев оборудования и их влияние на качество продукции были оценены путем анализа исходных данных и результатов моделирования. *Практическая значимость* заключается в теоретическом и экспериментальном подтверждении возможности и целесообразности применения нейросетевой диагностики для создания системы автоматизированного управления технологическим процессом травления полосовой стали. *Перспективным* представляется развитие теоретических и экспериментальных исследований по усовершенствованию компьютерной автоматизированной системы управления технологическим процессом травления путем включения в ее состав предложенных моделей, оперативно обрабатывающих

текущие данные. Полученные зависимости между статистическими характеристиками данных и индексом качества позволяют оценить текущее состояние линии без ее останова, что в итоге сокращает общую стоимость обслуживания рассматриваемого технологического комплекса.

Список литературы: 1. *Li Y., Sundararajan N., Saratchandran P.* Analysis of minimal radial basis function network algorithm for real-time identification of nonlinear dynamic systems // IEEE Proc. Control Theory Appl. 2000. Vol. 147. №4. P. 476 - 484. 2. *Осовский С.* Нейронные сети для обработки информации / М.: Финансы и статистика. 2002. 344 с. 3. *Арсеньева О.П., Люнин О.О., Перевертайленко О.Ю.* Заявка на патент № U2012-09-428 от 2.08.2011 «Пристрій для безперервного травлення прокату листової вуглецевої сталі». 5 с. 4. *Люнин О.О., Шамраев А.А., Удовенко С.Г., Лазарев А.И.* Система нечеткого управления травлением стали с компараторной идентификацией дефектов проката // Системні технології. 2011. №3 (86). С. 151-159.