

М. Ю. Рябчиков, канд. техн. наук, доц., mr\_mgn@mail.ru,  
Е. С. Рябчикова, канд. техн. наук, доц., e.ryabchikova@magtu.ru,  
В. С. Новак, студент, vladimir.novak.02@mail.ru,

Магнитогорский государственный технический университет им. Г. И. Носова, г. Магнитогорск

## Гибридная модель для упреждающего управления температурой металла при горячем оцинковании стальной полосы\*

*Предложена гибридная модель для упреждающего управления при возмущениях, приводящих к резкому скачкообразному изменению состояния процесса. Подобные изменения происходят при управлении температурой стальной полосы на агрегатах непрерывного горячего оцинкования. Периодическое изменение сортамента полосы или ее скорости приводит к скачкообразным изменениям температуры стали на выходе из печи для отжига. В такие периоды регулирование по отклонению затруднено, что требует введения допусков, которые ограничивают производительность и приводят к избыточному нагреву металла. Показано, что существующие предложения по управлению температурой стальной полосы недостаточно эффективны при резком изменении состояния процесса. Причинами этого являются неизвестные возмущения, действующие в широком частотном диапазоне и имеющие низкочастотные и трендовые составляющие, а также множество влияющих факторов. Показано, что проблемы представительности исходных накопленных данных затрудняют создание сложных эмпирических моделей, а уровень неопределенности процессов в печи затрудняет создание сложных интерпретируемых моделей. Предложенная гибридная модель предполагает совместное применение двух видов упрощенных интерпретируемых моделей процесса, а также эмпирической модели на основе искусственной нейронной сети. Продемонстрировано, что ошибки интерпретируемых моделей могут эффективно прогнозироваться нейронной сетью при наличии дополнительного сигнала от наблюдателя неизвестных возмущений. Проведенные вычислительные эксперименты на данных одного из агрегатов ПАО «ММК» в России показали, что гибридная модель обеспечивает высокую точность прогноза температуры стальной полосы при технологических возмущениях и не требует частой перенастройки.*

**Ключевые слова:** скачкообразное возмущение, упреждающее управление, искусственная нейронная сеть, неопределенность, отжиг стальной полосы

### Введение

Оцинкованный листовой прокат является одним из основных видов продукции металлургических предприятий. Основными потребителями являются автомобильная и строительная промышленность [1]. Объемы продукции агрегатов непрерывного горячего оцинкования (АНГЦ) выросли в течение последнего десятилетия. Поэтому представляет интерес совершенствование управления производством на уже действующих агрегатах в направлении повышения производительности и снижения затрат топлива.

Особенности управления термической обработкой стали при оцинковании оказывают существенное влияние на затраты, а также могут являться фактором, ограничивающим произ-

водительность. Вследствие множества особенностей технологического процесса решение об использовании того или иного режима часто принимает оператор. Это приводит к тому, что человеческий фактор оказывает существенное влияние на производительность АНГЦ и затраты энергии. В результате для гарантированного выполнения требований термической обработки затрачивается избыточная энергия на нагрев и на последующее охлаждение полосы. Кроме того, персонал может выбрать уже опробованные на практике режимы, что для конкретного сортамента может быть неэффективно.

Одной из причин подобной ситуации является отсутствие эффективной системы прогноза температуры стальной полосы при ее термической обработке. Целью данной работы является изучение этой проблемы и разработка точной и адекватной задаче управления прогнозирующей модели.

\*Исследование выполнено за счет гранта Российского научного фонда № 23-29-10058, <https://rscf.ru/project/23-29-10058/>.

## 1. Известные предложения по управлению температурой стальной полосы

Проведение отжига стали требует обеспечения определенной температуры металла на выходе каждой из секций отделения термической обработки (нагрев, выдержка, охлаждение), зависящей от назначения продукции.

Операции на агрегате осуществляются непрерывно. При изменении сортамента полосы через агрегат проходит сварной шов, соединяющий сталь с разными свойствами. При этом происходит резкое скачкообразное изменение температуры стали в разных секциях. Поскольку температура металла контролируется только между секциями, то это может послужить причиной нарушений требований к термической обработке стали.

В работах [2, 3] при управлении температурой стальной полосы предлагается использование интерпретируемых моделей, которые учитывают множество особенностей теплообмена. Несмотря на это ошибка моделей сохраняется на относительно высоком уровне вследствие наличия неизвестных возмущений. Согласно работе [3] средняя ошибка составила  $8\text{ }^{\circ}\text{C}$  по результатам тестирования в течение 12 ч. Однако при переходных или редких режимах ошибки могут сильно отличаться от указанного уровня. Причинами ошибок являются: неизвестные возмущения; не полное соответствие закономерностей интерпретируемой модели объекту; непостоянство точности в различных режимах. Как следствие, известно много предложений в области самонастройки моделей. Так, в статье [4] авторы предлагают использовать наблюдатель степени черноты полосы на основе фильтра Калмана. В работе [2] фильтр Калмана применяется для прогноза ошибки от интерпретируемой модели. Но использование подобных систем при резком скачкообразном изменении совокупности свойств полосы при смене сортамента затруднено. В такие периоды необходимо обеспечить высокую точность прогноза с применением модели со стационарными параметрами. Данная проблема рассматривается в работе [5]. Указано, что выполнение самонастройки модели под текущий режим может привести к существенному непостоянству точности модели в разных режимах. Перед резким скачкообразным изменением состояния процесса требуется выполнить прогноз для будущего состояния, которое может существенно отличаться от текущего состояния. Поэтому перенастройка модели под текущее состояние может негативно отразиться на качестве прогноза. Статистические свойства ошибки могут различаться при смене сортамента и при стабильном сортаменте. Как следствие, предложе-

ния в работах [2, 4] в большей степени ориентированы на повышение качества регулирования температуры стальной полосы при стабильном сортаменте.

В работе [6] выделяют две компоненты модели, а именно статическую и динамическую. Статическая модель основана на законе теплообмена излучением. Динамическая модель предназначена для прогноза ошибок статической модели. Авторы указывают на необходимость связанной настройки статической и динамической моделей и предлагают для этого итерационную процедуру. Это позволяет снизить влияние неизвестных возмущений на настройку статической модели. Значительное внимание авторы уделяют совершенствованию динамической модели, но не рассматривают вопрос выбора варианта представления неизвестных возмущений. По-видимому, причиной является структурная неопределенность неизвестных возмущений.

Согласно работам [7–9] другим способом снижения влияния неизвестных возмущений является переход на прогноз не самой температуры, а ее скачкообразного изменения при смене сортамента. При этом в работах не рассматривается задача прогноза неизвестных возмущений.

В статьях [9, 10] показано, что точность прогноза потенциально может быть повышена на основе применения в качестве модели искусственной нейронной сети (ИНС). При этом основной проблемой является непостоянство точности прогноза во времени и в зависимости от режима работы объекта. В силу того, что агрегаты часто работают в одних и тех же режимах, трудно разработать адекватную в статистическом плане модель, которая бы оперировала значительным числом входных переменных и имела бы сложную внутреннюю архитектуру.

Таким образом, можно сформулировать две взаимосвязанные проблемы повышения точности прогноза температуры с использованием модели. Первая проблема вызвана тем, что неизвестные возмущения, имеющие низкочастотные и трендовые составляющие, затрудняют привлечение к настройке данных, полученных в разные периоды времени. Как следствие, затруднительно сформировать представительную выборку состояний процесса. Особенно негативно проблемы выборки отражаются на адекватности эмпирических моделей. Второй проблемой являются сложности учета в интерпретируемых моделях всех действующих на систему известных возмущений. Решением могло бы являться использование эмпирических моделей. Однако в силу первой проблемы возможно создание только простых эмпирических моделей, которые могут не иметь преимущества перед интерпретируемыми моделями.

## 2. Особенности применения эмпирических моделей при упреждающем управлении

В работе [11] дана классификация методов использования эмпирических моделей на базе искусственных нейронных сетей при упреждающем управлении, позволяющая выделить три архитектуры:

1. Динамическая коррекция весов ИНС для снижения ошибки ее прогноза.

2. Коррекция прогноза от ИНС с использованием модели временного ряда неизвестных возмущений, определяемых по ошибке прогноза от ИНС.

3. Комбинирование первых двух архитектур.

Обзор в работе [11] демонстрирует, что основным инструментом обеспечения точности прогноза на основе эмпирической модели процесса является ее регулярная перенастройка с учетом новых данных процесса. Простейший вариант перенастройки основан на декомпозиции временного ряда на отдельные периоды во времени. Например, в работе [12] обсуждается группа методов, основанных на обнаружении аномалий временных рядов. Однако при систематических возмущениях данные любого периода могут считаться аномальными относительно других временных периодов. Поэтому может потребоваться перенастройка моделей по недавно полученным данным. При этом данные отдельного непродолжительного периода времени могут быть непредставительны. Причиной является тот факт, что в отдельный период времени могут возникнуть только некоторые из типовых состояний процесса. Как следствие, сложно настроить модели, учитывающие все необходимые особенности.

Решение отмеченной проблемы возможно на основе постепенной модификации выборки. Например, в статье [13] предложен метод *fixed-budget active learning*, позволяющий оперативно модифицировать выборку при ограничениях на ее размер. Метод позволяет дополнять выборку данными по текущему состоянию процесса с учетом неизвестных возмущений и, таким образом, учитывать их влияние при прогнозе. Однако данные о состоянии, в которое планируется перевести процесс, могли быть получены ранее в условиях иных неизвестных возмущений. Поэтому, если состояние процесса изменяется быстро, то переобучение модели может оказаться неэффективным.

В работе [14] указывается, что необходимо создавать точные, но интерпретируемые модели, несмотря на существенные усилия, которые могут потребоваться. Однако форма зависимостей интерпретируемой модели может не соответствовать объекту. Как следствие, с ростом сложности интерпретируемой модели будет ра-

сти и уровень неопределенности ее настроек и результатов ее прогноза. Поэтому эмпирические модели иногда обеспечивают лучшие результаты. Так, в работе [15] дано сравнение различных существенно-нелинейных моделей для прогноза температуры режущих инструментов. Показано преимущество искусственных нейронных сетей.

Согласно статье [16] в последние годы становится все более актуальным развитие методов прогноза, предполагающих создание глобальных моделей и использование больших данных. Глобальной называют модель, которая может эффективно использоваться продолжительное время без перенастройки.

Выбирая вид представления глобальной модели, следует учитывать, что интерпретируемые модели, как правило, упрощают более сложную действительность и могут хуже объяснять вариацию экспериментальных данных, чем эмпирические модели. Однако в силу положенных в основу интерпретируемой модели зависимостей возможен прогноз для состояний процесса, по которым мало или вообще отсутствуют ретроспективные данные. Также интерпретируемые модели позволяют рассмотреть различные варианты структурного представления действия возмущений с учетом специфики объекта.

Учитывая достоинства и недостатки эмпирических и интерпретируемых моделей, целесообразно их комбинирование для создания гибридных моделей.

## 3. Выбор структуры гибридной модели

Гибридные модели в последние годы начинают находить все большее применение. При этом авторы понимают под гибридной моделью объединение компонент, которые:

1) моделируют процессы разных типов (например, непрерывные и дискретные);

2) имеют разную форму представления (например, интерпретируемые, эмпирические или модели с неизвестной структурой);

3) моделируют разные части одного процесса (например, декомпозиция по функциям, структуре или масштабу);

4) моделируют один и тот же процесс, но используются в разных ситуациях или настраиваются по разным данным (набор альтернативных моделей).

В данной работе под гибридной моделью понимается, прежде всего, интеграция интерпретируемых и эмпирических компонент. С учетом этого можно указать возможные структуры гибридной модели.

Гибридная модель может включать компоненты разной формы представления, которые моде-

лируют один и тот же процесс. Например, в работе [17] прогноз качества железорудного агломерата определяется как компромисс между прогнозами от группы моделей. Причиной использования архитектуры является малый объем данных и большое число влияющих факторов. Требования к исходным настроечным данным удается выполнить за счет того, что отдельная модель оперирует только некоторыми из факторов. Структура ориентирована на малый объем ретроспективных данных. В то же время при большом объеме данных повышение точности прогноза потенциально может быть обеспечено за счет увеличения числа факторов, которыми оперирует эмпирическая модель.

Одной из перспективных структур являются суррогатные модели на основе многомасштабной гибридной модели. В таких моделях эмпирические и интерпретируемые компоненты могут моделировать процессы разных масштабов. Проблема структурной декомпозиции процесса для его представления группой моделей обсуждается в статье [18]. Предложены признаки, которые позволяют выбрать для каждой части процесса модель определенного типа. Например, авторами работы [19] предложена гибридная модель для прогноза температуры стали в агрегате печей. ИНС, входящая в состав гибридной модели, обучается косвенным образом по ошибкам на выходе интерпретируемых компонент модели с использованием модифицированного алгоритма кукушки (CS). Эмпирическая компонента повышает точность, а интерпретируемые компоненты обеспечивают адекватность прогноза температуры стали. Структура имеет весомый недостаток, который заключается в сложности настройки модели. Затруднительно применить алгоритм обратного распространения ошибки, если выходы гибридной модели не формируются непосредственно на выходах ИНС.

Учитывая, что алгоритм обратного распространения ошибки являлся фактором расширения прикладной сферы использования ИНС, представляет интерес структура гибридной модели, в которой эмпирическая компонента используется для коррекции результата прогноза от интерпретируемой компоненты.

### 3.1. Структура интерпретируемой компоненты гибридной модели

Одним из преимуществ, которые предоставляют интерпретируемые модели, является возможность структурного представления действия неизвестных возмущений с учетом особенностей работы объекта. Однако часто вместо прогнозирования возмущений решается задача прогноза ошибок модели на основе рекурсивного или пакетного фильтра (рис. 1).

Система на рис. 1 требует разработки модели прогноза ошибки  $e_p$  (модели временного ряда) индивидуально под свойства ошибок  $e_r$ . Однако на практике часто используют распространенные типовые структуры моделей. Вследствие этого более высокая точность может достигаться при прогнозе некоторых неизвестных, но определяемых с помощью наблюдателя возмущений (рис. 2).

Недостатком схемы на рис. 2 является то, что она не учитывает возможное действие неизвестных возмущений  $Z^C$  с момента предыдущего скачкообразного возмущения. Исходя из этого введем дополнительный наблюдатель возмущений (рис. 3). Дополнительный наблюдатель

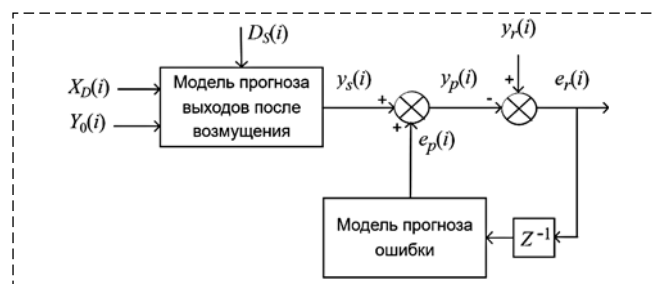


Рис. 1. Прогноз с учетом ошибок прогноза по данным предыдущих скачкообразных возмущений:

$i$  — номер в последовательности скачкообразных возмущений;  $X_D$  — известные значения воздействий на процесс и параметров настройки модели перед возмущением;  $Y_0$  — состояние процесса перед возмущением;  $D_S$  — известные скачкообразные возмущения;  $y_p$ ,  $y_r$  — прогноз и измеренное состояние процесса после возмущения;  $e_p$  — прогноз ошибки

Fig. 1. Prediction taking into account prediction errors based on the data of previous step disturbances:

$i$  — number in the sequence of step disturbances;  $X_D$  — known values of the impacts on the process and the model settings before the disturbance;  $Y_0$  — state of the process before the disturbance;  $D_S$  — known step disturbances;  $y_p$ ,  $y_r$  — prediction and measured state of the process after the disturbance;  $e_p$  — error prediction

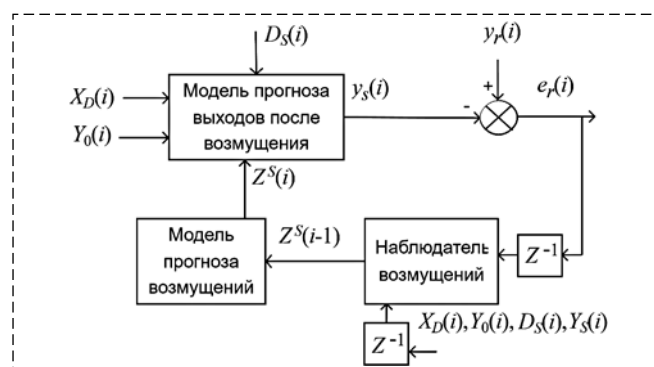


Рис. 2. Прогноз состояния процесса с применением наблюдателя возмущений по данным предыдущих скачкообразных возмущений:

$Z^S(i-1)$  — рассчитанные возмущения, объясняющие появление ошибки  $e_r$ ;  $Z^S(i)$  — прогноз возмущений

Fig. 2. Prediction of the process state using the disturbance observer based on the data of previous step disturbances:

$Z^S(i-1)$  — calculated disturbances that explain the appearance of the error  $e_r$ ;  $Z^S(i)$  — disturbance prediction

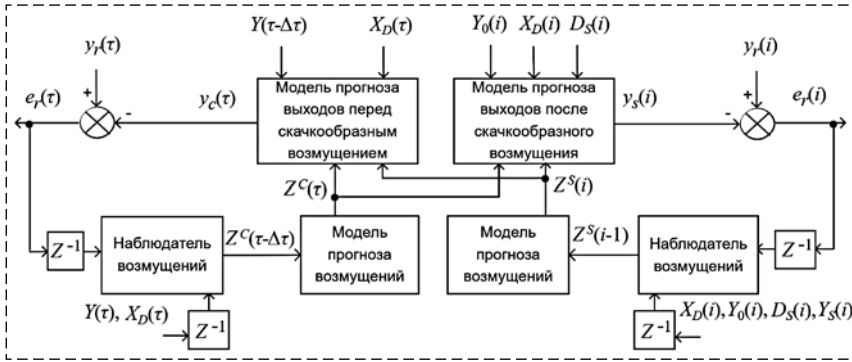


Рис. 3. Прогноз состояния процесса с применением наблюдателя возмущений по данным предыдущих скачкообразных возмущений, а также наблюдателя по данным о состоянии объекта перед скачкообразным возмущением

Fig. 3. Prediction of the process state using the observer of disturbances based on the data of previous step disturbances, as well as the observer based on the data on the state of the object before the step disturbance

датель позволяет объяснить отклонение процесса от его модели перед скачкообразным возмущением действием некоторых неизвестных возмущений  $Z^C$ . При этом учитывается прогноз возмущений  $Z^S$ , полученный по данным о предыдущем скачкообразном возмущении.

Проблема структурно-неопределенных возмущений заключается в выборе одного из возможных вариантов структуры и настроек моделей прогноза, а также основного и дополнительного наблюдателей.

**Типовая модификация модели.** Для случая скачкообразных возмущений может быть предложена распространенная модификация модели, основанная на переходе к приращениям сигналов. Допустим, что в период действия скачкообразного возмущения влияние некоторых неизвестных возмущений на переменные состояния процесса неизменно. Тогда переход к приращениям сигналов при скачкообразном возмущении позволяет частично или полностью устранить влияние подобных возмущений. При этом прогноз  $y_s$  определяется суммой  $y_s$  перед возмущением и прогноза изменения  $\Delta y_s$  (рис. 4).

Согласно рис. 4 модель используется для прогноза изменения значения переменной состояния процесса  $\Delta y_s$  при скачкообразном возмущении. В то же время дополнительный на-




Рис. 4. Прогноз изменения состояния процесса при скачкообразном возмущении:  $\Delta y_s$  — фактическое изменение  $y$

Fig. 4. Prediction of a change in the process state with a step disturbance:  $\Delta y_s$  — actual change in  $y$

блюдатель по-прежнему использует модель прогноза значения переменной состояния  $y_s$ . Это необходимо для учета возмущений по данным о состоянии объекта перед скачкообразным возмущением.

### 3.2. Проблема применения упрощенной модели

К предпосылкам регрессии относятся: выбор верной функциональной формы; присутствие всех необходимых факторов; отсутствие мультиколлинеарности; экзогенность независимых переменных; гомоскедастичность ошибок и др. [20, 21].

Гарантировать выполнение указанных предпосылок может быть сложно. Причиной этого являются проблемы ретроспективных данных, которые получают на основе пассивного эксперимента. Одной из основных проблем является существенный дисбаланс в объеме данных по разным режимам работы объекта. Применение в такой ситуации моделей, не основанных на известных закономерностях, затруднено. В то же время известные общие закономерности могут упрощать действительность, что означает неполное соответствие функциональной формы модели объекту. Иногда закономерности упрощают сознательно с учетом свойств исходных данных или особенностей применения модели. Тем самым нарушается основная предпосылка регрессионного анализа. Рассмотрим последствия этого применительно к принятому варианту структуры прогнозирующей модели.

Согласно рис. 4 при прогнозе изменения выходов объекта  $\Delta y_s$  используются неизвестные возмущения  $Z^C$  и  $Z^S$ , определяемые двумя различными наблюдателями с участием моделей прогноза  $\Delta y_s$  и  $y_s$ . Очевидно, это требует, чтобы прогноз изменения  $\Delta y_s$  осуществлялся с применением той же модели, которая используется дополнительным наблюдателем при прогнозе значений  $y_s$  перед возмущением. Однако настройка модели на минимум ошибки прогноза  $\Delta y_s$  и  $y_s$  может привести к получению двух моделей с разными настройками.

Для этого есть две основные причины. Первая причина связана с тем, что принятая функциональная форма модели ограничивает ее возможности по аппроксимации. Как следствие, вероятно ситуация, что модель будет более точна для режимов, по которым много ретроспективных данных. Таким образом, модель прогноза  $y_s$  более точна при определенных значениях выхода, а модель прогноза  $\Delta y_s$  — при определенных изменениях выхода. Вторая причина связа-

на с тем, что может не выполняться требование экзогенности независимых переменных. При переходе к прогнозу приращений влияние некоторых из неизвестных возмущений  $Z^C$  может быть устранено, но оно сохраняется применительно к дополнительному наблюдателю. Если, например,  $Z^C$  и  $D^C$  коррелируют, то это окажет влияние на настройки упрощенной модели, прогнозирующей  $y_c$ . Поэтому невыполнение требования экзогенности приведет к различию настроек моделей.

Вследствие указанных причин неясно, как интерпретировать величины  $Z^C$ , полученные с использованием дополнительного наблюдателя, и как применить их для прогноза  $\Delta y_s$ . Способом решения этой проблемы является применение для прогноза ошибок  $e_r(i) = \Delta y_r(i) - \Delta y_s(i)$  ИНС, к входам которой относятся  $Z^C$ .

### 3.3. Использование искусственной нейронной сети при прогнозе

Согласно схеме на рис. 5 ИНС используется для прогноза ошибки, которую допускает система прогноза  $\Delta y_s$  с использованием наблюдателя возмущений и упрощенной модели. На входы ИНС может быть подана информация о неизвестных воздействиях перед ступенчатым возмущением, полученная с применением дополнительного наблюдателя. Настройка гибридной модели предполагает выбор настроек интерпретируемых моделей и наблюдателей возмущений с последующим обучением ИНС с использованием алгоритма обратного распространения ошибки.

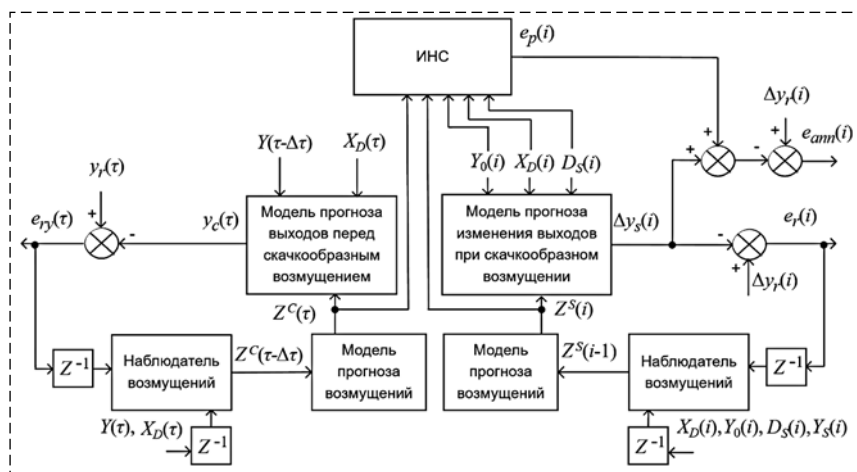


Рис. 5. Прогноз изменения выходов объекта с применением: наблюдателя возмущений по данным предыдущих скачкообразных возмущений; ИНС для прогноза ошибки; наблюдателя по данным о состоянии объекта перед скачкообразным возмущением

Fig. 5. Prediction of changes in object outputs using: disturbance observer based on the data from previous step disturbances; ANN for error prediction; observer based on the data on the state of the object before the step disturbance

## 4. Пример прогноза температуры стальной полосы

### 4.1. Объект управления

Предложенная гибридная модель применена для прогноза температуры стальной полосы на выходе протяжной печи башенного типа АНГЦ № 1 ПАО "ММК". В печи металл нагревается излучением от радиантных труб в защитной атмосфере, внутри которых сжигается природный газ. Система управления предусматривает группировку труб на семь зон. В каждой зоне контролируется температура рабочего пространства. Задачей модели является прогнозирование температуры стальной полосы, которая измеряется пирометром в переходном тамбуре между секцией нагрева и выдержки.

### 4.2. Исходные экспериментальные данные

Были использованы данные за три месяца работы агрегата по 620 изменениям сортамента стальной полосы, при которых толщина полосы  $h$  изменялась не менее чем на 0,2 мм (толщина варьируется от 0,35 до 2 мм). Данные содержат: температуры рабочего пространства в каждой зоне секции нагрева на момент выхода сварного шва из печи; параметры полосы до и после изменения сортамента; скорость  $v$  движения полосы. Для настройки и тестирования гибридной модели данные разделили на две выборки по 310 наборов (выборки № 1 и № 2). Выборки соответствуют двум последовательным периодам работы агрегата.

Для сравнительной оценки эффективности гибридной модели целесообразно предварительно оценить точность прогноза ИНС, которая непосредственно прогнозирует изменение температуры  $\Delta y_s$  (без упрощенных моделей).

### 4.3. ИНС для прогноза изменения температуры полосы

Поскольку увеличение числа входов ИНС может негативно отразиться на адекватности модели, создавали модели двух типов. На входы моделей первого типа поступают: температура в одной из последних по ходу движения металла зон ( $T_{п6}$ , зона № 6); толщины полосы  $h_1, h_2$  до и после изменения сортамента; скорость движения полосы; температура полосы на выходе из печи до изменения сортамента  $T_{M1}$ . На входы моделей второго типа дополнительно пода-

ются температуры рабочего пространства в зонах № 4, 5, 7 ( $T_{п4}$ ,  $T_{п5}$ ,  $T_{п6}$ ,  $T_{п7}$ ). Выходом ИНС является изменение температуры металла при смене сортамента.

Использовали ИНС прямого распространения сигнала с одним скрытым слоем. Варьируемыми параметрами являются число нейронов в скрытом слое и число эпох обучения в алгоритме обратного распространения ошибки (пакетный градиентный спуск).

Для оценки постоянства свойств неизвестных возмущений выполнили настройку ИНС отдельно по выборкам № 1 и № 2. Модели, настроенные по выборке № 1, тестировались по выборке № 2. Ошибки настройки (обучения) этих моделей обозначим  $E_{L1}$ , а ошибки теста (обобщения) —  $E_{T1}$ . Модели, настроенные по выборке № 2, тестировались по выборке № 1 (ошибки настройки —  $E_{L2}$ ; ошибки теста —  $E_{T2}$ ). В табл. 1 представлены результаты настройки.

Из табл. 1 следует, что ошибки настройки  $E_L$  моделей схожей структуры по выборкам № 1 и № 2 значительно различаются, что, предположительно, обусловлено непостоянством свойств неизвестных воздействий. В табл. 1 также представлены нормированные значения ошибки теста  $E_N$ . Для моделей, настроенных по выборке № 1,  $E_{N1} = E_{T1}/E_{L2}$ , где  $E_{T1}$  и  $E_{L2}$  получены для ИНС с одинаковым числом нейронов при равном числе эпох обучения. Для моделей, настроенных по выборке № 2,  $E_{N2} = E_{T2}/E_{L1}$ . Нормированные значения ошибок позволяют оценить степень соответствия ошибок обучения и обобщения в условиях непостоянства свойств неизвестных воздействий.

Значения  $E_N$ , существенно превышающие единицу, показывают, что использование ИНС,

настроенной по данным других периодов работы агрегата, дает увеличение ошибки на 20...100 % (наибольшие значения  $E_N$  характерны для второго типа ИНС моделей). Среди моделей, которые настраивались по выборке № 2, минимальную ошибку теста по выборке № 1 (6,71) имеет ИНС второго типа (10 нейронов, 1000 эпох обучения). Ошибку обучения этой ИНС (7,35) далее использовали для нормирования ошибок обобщения при оценке эффективности прогноза гибридных моделей, которые все настраивались по выборке № 1 и тестировались по выборке № 2.

#### 4.4. Упрощенная интерпретируемая модель нагрева стальной полосы

Выбор вида интерпретируемой модели нагрева стальной полосы может быть основан на различных предположениях. В работах [3, 22, 23], делающих акцент на использовании при управлении комплексных моделей процессов термической обработки полосы, выбор вида модели основан на законах теплообмена. Однако на АНГЦ № 1 "ММК", как и на многих других агрегатах, температура металла контролируется между технологическими секциями. Внутри протяжной печи температура металла не измеряется. Вследствие этого модель, как правило, настраивают по температуре металла на выходе из печи. Неясно, насколько точно отражает динамику нагрева полосы модель, настроенная таким образом. В работе [24] сделан вывод о том, что структура моделей не обязательно должна полностью отражать механизм теплообмена. Выбор структуры может быть ориентирован на упрощение решения прикладных задач. С учетом этого вместо закона радиаци-

Таблица 1  
Table 1

Результаты прогноза изменения температуры полосы с помощью ИНС  
*The results of predicted changes in strip temperature using ANN*

Входы ИНС	Вариант внутренней структуры ИНС	Вариант обучения ИНС	Настройка по выборке 1			Настройка по выборке 2			
			Ошибка настр. $E_{L1}$	Ошибка теста $E_{T1}$ по выборке 2		Ошибка теста $E_{T2}$ по выборке 1		Ошибка настр. $E_{L2}$	
				Абс., °С	Абс., °С	$E_{N1}$ , отн	Абс., °С		$E_{N2}$ , отн
Тип 1	1 нейрон	1000 эпох	4,91	9,27	<b>1,146</b>	7,04	<b>1,434</b>	8,09	
		500 эпох	4,79	9,04	<b>1,179</b>	6,74	<b>1,407</b>	7,67	
	5 нейронов	1000 эпох	4,47	8,94	<b>1,175</b>	6,76	<b>1,512</b>	7,61	
		3000 эпох	4,35	8,99	<b>1,247</b>	7,03	<b>1,616</b>	7,21	
		10 нейронов	1000 эпох	4,61	8,92	<b>1,214</b>	6,71	<b>1,456</b>	7,35
			3000 эпох	4,18	9,20	<b>1,312</b>	6,83	<b>1,634</b>	7,01
Тип 2	5 нейронов	1000 эпох	4,19	8,86	<b>1,215</b>	7,07	<b>1,687</b>	7,29	
		3000 эпох	4,27	8,73	<b>1,244</b>	7,62	<b>1,785</b>	7,02	
	10 нейронов	1000 эпох	4,01	8,85	<b>1,212</b>	7,23	<b>1,803</b>	7,30	
		3000 эпох	3,81	9,02	<b>1,352</b>	7,93	<b>2,081</b>	6,67	

онного теплообмена определим связь между температурой полосы  $T_M$  и температурой рабочего пространства  $T_{\Pi}$  на основе уравнения теплообмена в конвективной форме:

$$\frac{dT_M(\tau)}{d\tau} = a(T_{\Pi} - T_M(\tau)), \quad a = \frac{\alpha}{h}, \quad (1)$$

где  $\alpha$  — настраиваемый коэффициент, характеризующий теплообмен.

Уравнение (1) предполагает допущения: температура рабочего пространства  $T_{\Pi}$  одинакова во всех точках рабочего пространства печи;  $T_{\Pi}$  не изменяется в течение периода времени  $\tau_H$  прохождения металла через печь; равномерность нагрева по толщине полосы. В качестве  $T_{\Pi}$  использовали температуру одной из последних по ходу движения металла зон. Решение (1) относительно температуры металла на выходе из печи имеет вид

$$T_M(\tau_H) = \frac{T_{M0} + a\tau_H T_{\Pi}}{a\tau_H + 1}, \quad \tau_H = \frac{L}{v}, \quad (2)$$

где  $v$  — скорость движения полосы;  $L$  — длина полосы в печи;  $T_{M0}$  — температура металла на входе в печь.

Допуская постоянство  $T_{M0}$ , а также постоянство скорости  $v$  в период прохождения сварного шва через печь, для изменения температуры металла на выходе из печи при смене сортамента можем записать:

$$\Delta T_M(\tau_H) = T_{M2}(\tau_H) - T_{M1}(\tau_H) = \frac{T_{M0} + (\alpha/h_2)\tau_H T_{\Pi}}{(\alpha/h_2)\tau_H + 1} - \frac{T_{M0} + (\alpha/h_1)\tau_H T_{\Pi}}{(\alpha/h_1)\tau_H + 1}, \quad (3)$$

где  $h_1, h_2$  — соответственно толщина полосы до и после изменения сортамента.

#### 4.5. Варианты определения неизвестных воздействий

Задачей наблюдателя является определение неизвестных воздействий  $Z^S$ , которые привели к появлению ошибки  $e_r$  прогноза изменения температуры  $\Delta T_M$ . Исходя из соотношения (3) можно предложить варианты определения  $Z^S$ .

Распространенным вариантом является допущение о непостоянстве  $\alpha$  вследствие изменения степени черноты поверхности полосы, неучтенного изменения тепловой емкости и затрат тепла на рекристаллизацию стали. Решение (3) относительно  $\alpha$  по данным о предыдущем изменении сортамента при известной величине  $\Delta T_M$  имеет вид

$$\alpha = \left[ \sqrt{\Delta h(2\Delta T_M(h_1 + h_2)\Delta T_{\Pi 0} + \Delta h(\Delta T_{\Pi 0}^2 + \Delta T_M^2))} - \Delta h\Delta T_{\Pi 0} - \Delta T_M(h_1 + h_2) \right] / (2\tau_H \Delta T_M), \quad (4)$$

где  $\Delta h = h_2 - h_1$ ;  $\Delta T_{\Pi 0} = T_{\Pi} - T_{M0}$ .

Другим вариантом является допущение о возмущениях по температуре рабочего пространства в печи. Температура в печи контролируется в отдельных точках и не дает полного представления о распределении температур в пространстве. Решение (3) относительно температуры в печи  $T_{\Pi}$  имеет вид

$$T_{\Pi} = \frac{\Delta T_M(\alpha^2 \tau_H^2 + h_1 h_2 + (h_1 + h_2)\alpha \tau_H) - \Delta h \alpha \tau_H T_{M0}}{-\Delta h \alpha \tau_H}. \quad (5)$$

Возмущение по температуре рабочего пространства определяется как отклонение

$$\Delta T_{\Pi} = T_{\Pi} - T_{\Pi i}, \quad (6)$$

где  $T_{\Pi i}$  — измеренная температура рабочего пространства.

Использование соотношения (5) предполагает, что при прогнозе изменения температуры стали фактическая температура в печи корректируется с учетом прогноза величины  $\Delta T_{\Pi}$  по данным о предыдущих изменениях сортамента. Коэффициент  $\alpha$  является параметром настройки для данного варианта наблюдателя.

В качестве последнего варианта примем возмущение по выходной переменной, т. е. по отклонению  $e_r$  прогнозируемого изменения температуры стали при смене сортамента от фактического изменения. Вариант структурно соответствует схеме на рис. 1. Параметром настройки является  $\alpha$ .

#### 4.6. Модель временного ряда для прогноза неизвестных возмущений

Выбор варианта определения неизвестных возмущений предполагает совместный подбор параметров настройки наблюдателя возмущений и модели прогноза возмущений. Прогноз величин  $\alpha$ ,  $\Delta T_{\Pi}$  и  $e_r$  осуществляли с использованием однотипной модели прогноза на основе пакетного фильтра:

$$x(i) = x(i-1) + \frac{1}{k_x}(x(i-1) - x(i-2)), \quad (7)$$

где  $x$  — прогнозируемая переменная;  $k_x$  — параметр настройки.

При прогнозе игнорировали длительности периодов времени между изменениями сортамента.

#### 4.7. Выбор варианта определения неизвестных возмущений

Настройку вариантов наблюдателя возмущений и модели прогноза возмущений проводили совместно по выборке № 1 путем полного перебора комбинаций значений  $\alpha$  и  $k_x$ . Резуль-

Таблица 2  
Table 2

Результаты настройки вариантов определения неизвестных возмущений

Results of tuning observers of unknown disturbances

Вид	Настройка $ e_r  \rightarrow \min$		Тест $ e_r $
	$ e_r $	Параметры	
$\Delta T_{II}$	5,052	$\alpha^* = 0,8; k_x = 250$	8,889
$\alpha, e_p$	5,095	$\alpha^* = 1,8; e_p = 0; k_x \rightarrow \infty$	10,051




Рис. 6. Прогноз  $\Delta T_{II}$  (темная линия) и выход наблюдателя (светлая линия)

Fig. 6. Prediction  $\Delta T_{II}$  (dark line) and observer output (light line)

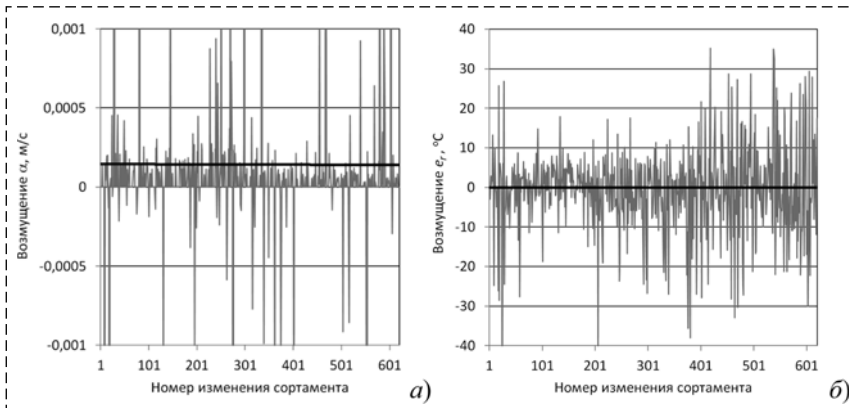


Рис. 7. Прогноз  $\alpha$  (а),  $e_p$  (б) и выходы наблюдателей

Fig. 7. Prediction  $\alpha$  (a),  $e_p$  (b) and observers outputs

Результаты настройки ИНС

ANN tuning results

Тип	Входы ИНС	Вариант внутренней структуры ИНС	Вариант обучения ИНС	Ошибка настр.	Ошибка теста	
					Абс., °C	$E_N$ , отн
1	$h_1, h_2, v, T_{п6}$	10 нейронов	1000 эпох	5,03	8,74	1,189
2	$h_1, h_2, v, T_{п6}, T_{M1}$	10 нейронов		4,52	7,95	1,082
		20 нейронов		4,42	7,79	1,060
3	$h_1, h_2, v, T_{п4}, T_{п5}, T_{п6}, T_{п7}, T_{M1}$	10 нейронов		4,04	8,36	1,137

таты представлены в табл. 2 ( $\alpha = \alpha^* \cdot 10^{-4}$  м/с). Получено, что минимумы критерия настройки (средние значения модуля ошибок  $e_r$ ) схожи для всех трех вариантов с прогнозом  $\alpha$ ,  $\Delta T_{II}$  и  $e_p$ . Для вариантов с прогнозом  $\alpha$  и  $e_p$  минимум критерия достигается при  $k_x \rightarrow \infty$ . При этом варианты эквивалентны, а прогнозы  $\alpha$  и  $e_p$  ( $e_p$  — прогноз  $e_r$ ) определяются их начальными значениями.

На рис. 6 показаны значения  $\Delta T_{II}$  на выходе наблюдателя и модели прогноза в течение обоих периодов. Видно постепенное изменение прогноза  $\Delta T_{II}$  в течение второго периода. На рис. 7 показаны значения  $\alpha$  и  $e_p$  на выходе соответствующих вариантов наблюдателей, а также найденные постоянные значения  $\alpha$  и  $e_p$  при  $k_x \rightarrow \infty$ .

Согласно рис. 7, а для значений  $\alpha$  на выходе наблюдателя характерны периодические возмущения большой амплитуды, что, по-видимому, является одной из причин неэффективности принятой модели прогноза для данного варианта определения неизвестных воздействий. Значения  $e_p$  на выходе наблюдателя не демонстрируют тенденции к смещению среднего, что, предположительно, также обуславливает неэффективность принятой модели прогноза. Варианты определения неизвестных возмущений на основе  $e_r$  и  $\alpha$  требуют использования более сложных моделей прогноза. Применительно к выбранной

модели прогноза возмущений целесообразно использовать вариант определения неизвестных воздействий на основе  $\Delta T_{II}$ .

4.8. Система с наблюдателем скачкообразных возмущений и ИНС

В системе с определением неизвестных возмущений на основе  $\Delta T_{II}$  ИНС используется согласно схеме на рис. 5 для получения прогноза  $e_p$  ошибки  $e_r$ . В табл. 3 показаны результаты настройки при использовании разных вариантов входных сигналов ИНС (три типа) и настройках модели прогноза  $k_x = 250, \alpha^* = 0,8$ . При нормировании ошибки теста приняли  $E_L = 7,35$ .

Из табл. 3 следует, что применение ИНС первого типа для прогноза  $e_p$  не дало значимого роста точности прогноза. ИНС второго типа учитывает температуру металла  $T_{M1}$  на выходе из печи перед возмущением. Минимум ошибки теста для этого типа ИНС достигается при большем числе нейронов. Ошибка теста близка к уровню ошибки настройки по второй выборке

Таблица 3  
Table 3

( $E_L = 7,35$ ), который используется при нормировании. Дополнительный учет температур в прочих зонах печи снижает ошибку обучения, но увеличивает ошибку теста (третий тип ИНС).

Исходя из табл. 3 можно сделать вывод, что росту точности прогноза  $\Delta T_M$  способствует учет состояния объекта непосредственно перед возмущением, что достигается использованием температуры металла  $T_{M1}$  на выходе из печи перед возмущением. Поэтому целесообразно рассмотреть возможность применения дополнительного наблюдателя по данным перед скачкообразным возмущением.

#### 4.9. Система с дополнительным наблюдателем по данным перед скачкообразным возмущением

Наилучшая точность гибридной модели была получена при использовании наблюдателя отклонения фактической температуры в печи от прогнозируемой:

$$\Delta T_{\Pi}(\tau_n) = T_{\Pi} - \left( \frac{T_{M1}(a\tau_n + 1) - T_{M0}}{a\tau_n} \right), \quad (8)$$

где  $T_{\Pi}$  — измеренная температура в последних по ходу металла зонах печи.

Величина  $\Delta T_{\Pi}$  определяется по данным перед текущим скачкообразным возмущением. Прог-




Рис. 8. Вариант представления возмущений на основе  $\Delta T_{\Pi}$  (темная линия —  $\Delta T_{\Pi}$ )

Fig. 8. Disturbance representation variant based on  $\Delta T_{\Pi}$  (dark line —  $\Delta T_{\Pi}$ )

#### Результаты настройки ИНС ANN tuning results

Тип	Входы ИНС	Вариант внутренней структуры ИНС	Вариант обучения ИНС	Ошибка теста	
				Абс., °С	$E_N$ , отн
4	$h_1, h_2, v, T_{п6}, \Delta T_{\Pi} - \Delta T_{пр}$	20 нейронов	1000 эпох	7,56	1,03
5	$h_1, h_2, v, T_{п4}, T_{п5}, T_{п6}, T_{п7}, \Delta T_{\Pi} - \Delta T_{пр}$	20 нейронов		7,50	1,02

ноз  $\Delta T_{пр}$  величины  $\Delta T_{\Pi}$  осуществляется моделью временного ряда (7) с учетом значений  $\Delta T_{\Pi}$  перед предыдущими изменениями сортамента.

Настройку вариантов дополнительного наблюдателя также проводили по выборке № 1. Для наблюдателя  $\Delta T_{\Pi}$  оптимальные значения  $k_x = 40$  и  $\alpha^* = 1,5$ . На рис. 8 показано изменение  $\Delta T_{пр}$  и  $\Delta T_{\Pi}$ . Из рис. 8 и рис. 6 следует отсутствие видимой связи между прогнозами от основного и дополнительного наблюдателей.

Для использования дополнительного наблюдателя на входы ИНС подается величина  $\Delta T_{\Pi} - \Delta T_{пр}$ . В табл. 4 показаны ошибки лучших вариантов ИНС. При нормировании, как и ранее, приняли  $E_L = 7,35$ .

Полученные результаты показывают, что применение дополнительного наблюдателя снизило ошибку теста ИНС по выборке 2, причем ошибка теста вплотную приблизилась к пределу, определяемому ошибкой настройки  $E_L$  по выборке 2 (см. табл. 1). Минимум ошибки обеспечивает ИНС типа 5, на входы которой подаются температуры в нескольких зонах печи. При этом по сравнению с типом 3 (см. табл. 3) увеличилось оптимальное число нейронов.

#### Заключение

Предложенная гибридная модель позволяет повысить точность прогноза температуры стальной полосы за счет учета информации о температуре рабочего пространства в отдельных зонах. Сложность учета этой информации в интерпретируемых моделях обусловлена множеством факторов, влияющих на температуру. Рост точности прогноза возможен вследствие комбинирования эмпирических и интерпретируемых моделей. Использование интерпретируемых моделей позволило выбрать вариант структурного представления неизвестных возмущений, при котором возможен их эффективный прогноз. Показано, что часто используемый прогноз степени черноты поверхности требует существенного усложнения модели временного ряда возмущений. Более эффективным является представление неизвестных возмущений в форме корректора

температуры рабочего пространства в печи. Ошибки интерпретируемых моделей могут эффективно прогнозироваться эмпирической компонентой гибридной модели за счет информации о температуре рабочего пространства в разных точках печи. Однако это возможно только при наличии дополнительного классификатора особенностей подобного влияния. Таким классификатором может

выступать прогноз отклонения фактической и прогнозируемой температур в печи перед сменой сортамента. Гибридная модель может эффективно применяться для прогноза в режимах работы, по которым мало исходных данных. Вследствие этого модель может использоваться в составе систем управления температурой полосы при гибком мелкосерийном производстве оцинкованного листового проката с варьированием производительности.

#### Список литературы

1. Никифоров Б. А., Салганик В. М., Денисов С. В., Стеканов П. А. Освоение производства высокопрочного поката для автомобилестроения в ОАО "ММК" // Вестник Магнитогорского государственного технического университета им. Г. И. Носова. 2006. № 4(16). С. 41—45.
2. Wu H., Speets R., Ozcan G., Ekhart R., Heijke R., Nederlof C., Boeder C. J. Non-linear model predictive control to improve transient production of a hot dip galvanising line // Ironmaking & Steelmaking. 2016. Vol. 43, N. 7. P. 541—549. DOI: 10.1080/03019233.2015.1126687
3. Wu H., Speets R., Heeremans F., Ben Driss O., van Buren R. Nonlinear model predictive control of throughput and strip temperature for continuous annealing line // Ironmaking & Steelmaking. 2015. Vol. 42, N.8. P. 570—578.
4. Strommer S., Niederer M., Steinboeck A., Jadachowski L., Kugit A. Nonlinear observer for temperatures and emissivities in a strip annealing furnace // 2016 IEEE Industry Applications Society Annual Meeting. 2016. DOI: 10.1109/IAS.2016.7731914
5. Ryabchikov M. Y., Ryabchikova E. S. Big Data-Driven Assessment of Proposals to Improve Enterprise Flexibility Through Control Options Untested in Practice // Glob J Flex Syst Manag. 2021. URL: <https://doi.org/10.1007/s40171-021-00287-5>
6. Naoharu Yoshitani, Akihiko Hasegawa. Model-Based Control of Strip Temperature for the Heating Furnace in Continuous Annealing // IEEE transactions on control systems technology. 1998. N. 6. P. 146—156.
7. Ueda I., Hosoda M., Taya K. Strip Temperature Control for a Heating Section in CAL // IECON'91. 1991. P. 1946—1949.
8. Ryabchikov M. Y., Ryabchikova E. S., Shmanev D. E., Korin I. D. Strip cooling control for flexible production of galvanized flat steel // Steel in Translation. 2021. Vol. 7, N. 51. P. 446—455.
9. Рябчиков М. Ю., Рябчикова Е. С. Управление режимом нагрева полосы на агрегате непрерывного горячего цинкования с использованием нейросетевых моделей // Технология машиностроения. 2017. № 2. С. 37—43.
10. Рябчиков М. Ю., Рахманов С. Н., Беляков А. А. Статистические модели нагрева полосы в протяжной печи башенного типа агрегата непрерывного горячего оцинкова-

ния // Автоматизация технологических и производственных процессов в металлургии. 2012. № 4. С. 81—97.

11. Baimore A., Sobowale N. B., Osunleke A. S. et al. Off-set-free neural network-based nonlinear model predictive controller design using parameter adaptation // Neural Comput&Appl. 2021. Vol. 33. P. 10235—10257. Doi: 10.1007/s00521-021-05788-z

12. Longyuan Li, Junchi Yan, Haiyang Wang, Yaohui Jin. Anomaly Detection of Time Series with Smoothness-Inducing Sequential Variational Auto-Encoder // IEEE Transactions on Neural Networks and Learning Systems. 2021. P. 1—15. Doi: 10.1109/TNNLS.2020.2980749

13. Taguchi Y., Hino H., Kameyama K. Pre-Training Acquisition Functions by Deep Reinforcement Learning for Fixed Budget Active Learning // Neural Process Lett 53. 2021. P. 1945—1962. <https://doi.org/10.1007/s11063-021-10476-z>

14. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead // Nat Mach Intell 1. 2019. P. 206—215. Doi: 10.1038/s42256-019-0048-x

15. Hossam Faris, Alaa Sheta. A comparison between parametric and non-parametric soft computing approaches to model the temperature of a metal cutting tool // International Journal of Computer Integrated Manufacturing. 2016. Vol. 29, N.1. P. 64—75. DOI: 10.1080/0951192X.2014.1002809

16. Bandara K., Bergmeir K., Hewamalage H. LSTM-MS-Net: Leveraging Forecasts on Sets of Related Time Series With Multiple Seasonal Patterns // IEEE Transactions on Neural Networks and Learning Systems. 2021. Vol. 32, N. 4. P. 1586—1599. Doi: 10.1109/TNNLS.2020.2985720.

17. Ryabchikov M. Yu. Metallurgical agglomerate quality management with the account of its impact on the blast-furnace process efficiency, The International Journal of Advanced Manufacturing Technology. 2018. Vol. 94, N. 9—12. P. 3785—3794.

18. Борисов В. В., Авраменко Д. Ю. Нечеткое ситуационное управление сложными системами на основе их композиционного гибридного моделирования // Системы управления, связи и безопасности. 2021. № 3. С. 207—237.

19. Yang Q., Fu Y., Zhang J. Molten steel temperature prediction using a hybrid model based on information interaction-enhanced cuckoo search // Neural Comput & Appl 33. 2021. P. 6487—6509. URL: <https://doi.org/10.1007/s00521-020-05413-5>

20. Схведиани А. Е. Основные предпосылки классической линейной регрессии и последствия их нарушений // Инновации и инвестиции. 2020. № 8. С. 38—42.

21. Нуруллаева Ш. Т., Рузметова Н. Ш., Муминова М. А., Сайдуллаева С. А. Гетероскедастичность: что произойдет, если дисперсия ошибки является непостоянной // International Academy Journal Web of Scholar. 2019. № 1(31). С.3—7.

22. Strommer S., Niederer M., Steinboeck A., Kugi A. Hierarchical nonlinear optimization-based controller of a continuous strip annealing furnace // Control Engineering Practice. 2018. Vol. 73. P. 40—55. DOI:10.1016/j.conengprac.2017.12.005

23. Wan Fei, Wang Yong-qin, Qin Shu-ren. Modeling of Strip Heating Process in Vertical Annealing Furnace // Journal of iron and steel research, International. 2012. Vol. 19, N. 5. P. 29—36.

24. Панферов В. И. Адаптивные системы контроля качества нагрева металла в печах // Изв. вузов. Черная металлургия. 1990. № 7. С. 110.

## Hybrid Model for Metal Temperature Control during Hot Dip Galvanizing of Steel Strip

M. Yu. Ryabchikov, [mr\\_mgn@mail.ru](mailto:mr_mgn@mail.ru), E. S. Ryabchikova, [e.ryabchikova@magtu.ru](mailto:e.ryabchikova@magtu.ru),

V. S. Novak, [vladimir.novak.02@mail.ru](mailto:vladimir.novak.02@mail.ru),

<sup>1</sup>Nosov Magnitogorsk State Technical University, Magnitogorsk, 455000, Russian Federation

Corresponding author: Ryabchikov Mikhail Yu., Cand. of Tech. Sc., Associate Professor, Nosov Magnitogorsk State Technical University, Magnitogorsk, 455000, Russian Federation, e-mail: [mr\\_mgn@mail.ru](mailto:mr_mgn@mail.ru)

Accepted on May 15, 2023

#### Abstract

The paper proposes a hybrid model for predictive control under step disturbances that lead to a sharp jump in the state of the process. Similar changes occur when controlling the temperature of the steel strip on continuous hot-dip galvanizing units.

Periodic changes in strip gauge or strip speed result in abrupt changes in the temperature of the steel at the outlet of the annealing furnace. During such periods deviation control is difficult requiring introduction of tolerances that limit productivity and leading to excessive heating of the metal. The paper shows that the existing proposals for controlling the temperature of the steel strip are not effective enough with a sharp change in the state of the process. The reasons for this are unknown disturbances operating in a wide frequency range and having low-frequency and trend components, as well as many influencing factors. It is shown that the problems of representativeness of the initial accumulated data make it difficult to create complex empirical models, and the level of uncertainty of the processes in the furnace makes it difficult to create complex interpretable models. The proposed hybrid model involves combining two types of simplified interpretable process models, as well as an empirical model based on an artificial neural network. The errors of the interpreted models are shown to be effectively predicted by a neural network in the presence of an additional signal from an observer of unknown disturbances. Computational experiments carried out on the data of one of the units of MMK PJSC in Russia showed that the hybrid model provides high accuracy of steel strip temperature prediction during technological disturbances and does not require frequent reconfiguration.

**Keywords:** step disturbance, predictive control, artificial neural network, uncertainty, steel strip annealing

**Acknowledgements:** The study was funded by a Russian Science Foundation grant No 23-29-10058, <https://rscf.ru/project/23-29-10058/>

For citation:

**Ryabchikov M. Yu., Ryabchikova E. S., Novak V. S.** Hybrid Model for Metal Temperature Control during Hot Dip Galvanizing of Steel Strip, *Mekhatronika, Avtomatizatsiya, Upravlenie*, 2023, vol. 24, no. 8, pp. 421–432.

DOI: 10.17587/mau.24.421-432

### References

1. **Nikiforov B. A., Salganik V. M., Denisov S. V., Stekanov P. A.** (2006) Commercial production of high-strength rolled products at MMK JSC for the automotive industry, *Vestnik of Nosov Magnitogorsk State Technical University*, 2006, vol. 4, no. 16, pp. 41–45 (in Russian).
2. **Wu H., Speets R., Ozcan G., Ekhart R., Heijke R., Nederlof C., Boeder C. J.** Non-linear model predictive control to improve transient production of a hot dip galvanising line, *Ironmaking & Steelmaking*, 2016, vol. 43, no. 7, pp. 541–549 DOI: 10.1080/03019233.2015.1126687
3. **Wu H., Speets R., Heeremans F., Ben Driss O., van Buren R.** Nonlinear model predictive control of throughput and strip temperature for continuous annealing line, *Ironmaking & Steelmaking*, 2015, vol. 42, no. 8, pp. 570–578
4. **Strommer S., Niederer M., Steinboeck A., Jadachowski L., Kugi A.** Nonlinear observer for temperatures and emissivities in a strip annealing furnace, *2016 IEEE Industry Applications Society Annual Meeting*, DOI: 10.1109/IAS.2016.7731914
5. **Ryabchikov M. Y., Ryabchikova E. S.** Big Data-Driven Assessment of Proposals to Improve Enterprise Flexibility Through Control Options Untested in Practice, *Glob J Flex Syst Manag.*, 2021, DOI: 10.1007/s40171-021-00287-5
6. **Naoharu Yoshitani, Akihiko Hasegawa.** Model-Based Control of Strip Temperature for the Heating Furnace in Continuous Annealing, *IEEE transactions on control systems technology*, 1998, no. 6, pp. 146–156.
7. **Ueda I., Hosoda M., Taya K.** Strip Temperature Control for a Heating Section in CAL, *IECON'91*, 1991, pp. 1946–1949.
8. **Ryabchikov M. Y., Ryabchikova E. S., Shmanev D. E., Kokorin I. D.** Strip cooling control for flexible production of galvanized flat steel, *Steel in Translation*, 2021, vol. 7, no. 51, pp. 446–455.
9. **Ryabchikov M. Yu., Ryabchikova E. S.** Control of the heating mode of the strip on the unit of continuous hot galvanizing with the use of neural network models, *Mechanical engineering technology*, 2017, no. 2, pp. 37–43 (in Russian).
10. **Ryabchikov M. Yu., Rakhmanov S. N., Belyakov A. A.** Statistical models of strip heating in a tower-type furnace of a continuous hot galvanizing unit, *Automation of technological and production processes in metallurgy*, 2012, no. 4, pp. 81–97 (in Russian).
11. **Bamimore A., Sobowale N. B., Osunleke A. S.** et al. Offset-free neural network-based nonlinear model predictive controller design using parameter adaptation, *Neural Comput&Appl*, 2021, vol. 33, pp. 10235–10257, 10.1007/s00521-021-05788-z
12. **Longyuan Li, Junchi Yan, Haiyang Wang, Yaohui Jin.** Anomaly Detection of Time Series with Smoothness-Inducing Sequential Variational Auto-Encoder, *IEEE Transactions on Neural Networks and Learning Systems*, 2021, pp. 1–15, 10.1109/TNNLS.2020.2980749
13. **Taguchi Y., Hino H., Kameyama K.** Pre-Training Acquisition Functions by Deep Reinforcement Learning for Fixed Budget Active Learning, *Neural Process Lett* 2021, vol. 53, pp. 1945–1962, DOI: 10.1007/s11063-021-10476-z
14. **Rudin C.** Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead, *Nat Mach Intell.*, 2019, no. 1, pp. 206–215, DOI: 10.1038/s42256-019-0048-x
15. **Hossam Faris, Alaa Sheta.** A comparison between parametric and non-parametric soft computing approaches to model the temperature of a metal cutting tool, *International Journal of Computer Integrated Manufacturing*, 2016, vol. 29, no. 1, pp. 64–75, DOI: 10.1080/0951192X.2014.1002809
16. **Bandara K., Bergmeir C., Hewamalage H.** LSTM-MSNet: Leveraging Forecasts on Sets of Related Time Series With Multiple Seasonal Patterns, *IEEE Transactions on Neural Networks and Learning Systems*, 2021, vol. 32, no. 4, pp. 1586–1599.
17. **Ryabchikov M. Yu.** Metallurgical agglomerate quality management with the account of its impact on the blast-furnace process efficiency, *The International Journal of Advanced Manufacturing Technology*, 2018, vol. 94, no. 9–12, pp. 3785–3794.
18. **Borisov V. V., Avramenko D. Yu.** Fuzzy situational control of complex systems based on their composite hybrid modeling. Systems of Control, *Communication and Security*, 2021, no. 3, pp. 207–237 (in Russian).
19. **Yang Q., Fu Y., Zhang J.** Molten steel temperature prediction using a hybrid model based on information interaction-enhanced cuckoo search. *Neural Comput & Applic*, 2021, vol. 33, pp. 6487–6509, DOI: 10.1007/s00521-020-05413-5
20. **Shvediani A. E.** Basic premises of classical linear regression and the consequences of their violations. *Innovation & Investment*, 2020, no. 8, pp. 38–42 (in Russian).
21. **Nurullaeva Sh. T., Ruzmetova N. Sh., Muminova M. A., Saidullaeva S. A.** (2019) Heteroscedasticity: what happens if the error variance is non-constant, *International Academy Journal Web of Scholar*, 2019, no. 1(31), pp. 3–7 (in Russian).
22. **Strommer S., Niederer M., Steinboeck A., Kugi A.** Hierarchical nonlinear optimization-based controller of a continuous strip annealing furnace, *Control Engineering Practice*, 2018, vol. 73, pp. 40–55, DOI:10.1016/j.conengprac.2017.12.005
23. **Wan Fei, Wang Yong-qin, Qin Shu-ren.** Modeling of Strip Heating Process in Vertical Annealing Furnace, *Journal of iron and steel research, International*, 2012, vol. 19, no. 5, pp. 29–36.
24. **Panferov V. I.** Adaptive quality control systems for metal heating in furnaces, *Proceedings of Higher Educational Institutions. Ferrous Metallurgy*, 1990, no. 7, p. 110 (in Russian).