

УДК 621.771; 004.89

ИССЛЕДОВАНИЕ ВОЗНИКОВЕНИЯ ДРОССА НА ЛИНИИ ГОРЯЧЕГО ЦИНКОВАНИЯ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

© С. С. Абдуракипов, Е. Б. Бутаков

*Институт теплофизики им. С. С. Кутателадзе СО РАН,
630090, г. Новосибирск, просп. Академика Лаврентьева, 1
E-mail: s.s.abdurakipov@gmail.com*

Представлена модель машинного обучения на основе градиентного бустинга, разработанная для прогнозирования возникновения дефектов (дроссов) на оцинкованных стальных листах, применяемых в автомобильной промышленности. Проведён анализ влияния технологических параметров на возникновение дефектов, что позволило определить ключевые факторы, влияющие на качество покрытия: скорость прокатки, удлинение и усилие в дрессировочной клети, толщина цинка сверху, температура цинкования и температура в носке печи. Разработан цифровой помощник для оценки рулонов в режиме реального времени, обеспечивающий симуляцию процесса принятия решений и помогающий оперативно управлять технологическим процессом.

Ключевые слова: машинное обучение, градиентный бустинг, дефекты покрытия, дросс, цифровой помощник.

DOI: 10.15372/AUT20250203

EDN: HGPSVY

Введение. Оцинкованный листовой прокат является основным видом продукции агрегатов непрерывного горячего цинкования (АНГЦ). Горячее цинкование металла — наиболее распространённый метод защиты листа, который даёт возможность значительно улучшить его эксплуатационные свойства [1]. Важным фактором при определении качества оцинкованной стали является оценка внешнего вида металлического листа. Горячее цинкование холоднокатаной стали заключается в погружении очищенного от масел, окислов и окалины стального листа в печь с цинковым расплавом. Процессы горячего покрытия листовой стали сопровождаются образованием побочного продукта — дrossса, представляющего собой соединения цветных металлов с железом, которые загрязняют рабочий расплав и полосу, уменьшают рабочий объём ванны, поэтому требуется их периодическое удаление [2]. Наличие дrossса существенно ухудшает качество покрытия [3].

Наиболее важным параметром в процессе горячего цинкования является толщина покрытия, которую контролируют разными методами. Существует взаимосвязь между количеством дrossса и толщиной покрытия. Разные бригады, обслуживающие АНГЦ, подходят к выбору температурно-скоростных режимов индивидуально. Когда в печь поступает новый рулон, который отличается от предыдущего толщиной или маркой стали, требуется изменение скорости транспорта полосы и температурного режима. Как оказалось, одни бригады перестраиваются оптимальнее других. Оператор может запоздать, и полоса какое-то время продолжит двигаться на прежней, более низкой скорости. Разработан сервис, который подсказывает бригаде, какую скорость полосы следует задать на каждом рулоне. Одним из важных факторов является контроль содержания алюминия в ванне [4], что было показано на основе данных численного моделирования и суррогатной модели на базе машинного обучения. В [5] представлено приложение, основанное на сочетании генетических алгоритмов и нейронных сетей, используемое для улучшения процесса отжига

линии горячего цинкования со стальными рулонами. Разработана модель с целью определения оптимальных настроек печи для уменьшения погрешности между фактической температурой полосы и ожидаемой температурой для каждого рулона. Также разработана модель толщины цинкового покрытия на основе нейронной сети как важный компонент системы горячего цинкования стальной полосы [6]. Наибольшее влияние на толщину покрытия оказали следующие параметры: скорость полосы, давление воздушного ножа, расстояние между воздушным ножом и полосой и высота воздушного ножа системы горячего цинкования.

Цель данного исследования состояла в исследовании возникновения дефектов покрытия ленты из-за дrossса в процессе горячего цинкования с применением машинного обучения; определении факторов, влияющих на возникновение дrossса; создании рабочего стола инженера на базе статистической модели, позволяющей сократить появление дефектов рулона посредством управления ключевыми параметрами технологического процесса.

В табл. 1 представлен список обозначений параметров и их описание.

Описание эксперимента. Современные агрегаты непрерывного горячего цинкования предназначены для двухстороннего нанесения на поверхность стальной полосы цинкового и железоцинкового покрытий, а также покрытий на основе цинкового и алюминиевого расплавов (рис. 1). Лист стали очищается, нагревается и погружается в ванну, где его покрывает тонкий цинковый слой. Получение цинкового покрытия протекает в четыре этапа: подготовка, сушка, горячее цинкование и охлаждение листа. В свою очередь, в

Таблица 1
Список обозначений параметров

Параметры	Описание
h_t	Толщина покрытия цинком сверху
h_b	Толщина покрытия цинком снизу
V	Скорость прокатки рулона
T_s	Температура в носке печи
T_{p1}	Температура цинкования в гальванизационной ванне № 1
T_{p2}	Температура цинкования в гальванизационной ванне № 2
F_{spm}	Усилие в дрессировочной клети
L_{spm}	Удлинение в дрессировочной клети
S_c	Площадь рулона
N_d	Число дефектов рулона
PDF	Функция плотности вероятности
Sh _{val}	Значение Шепли

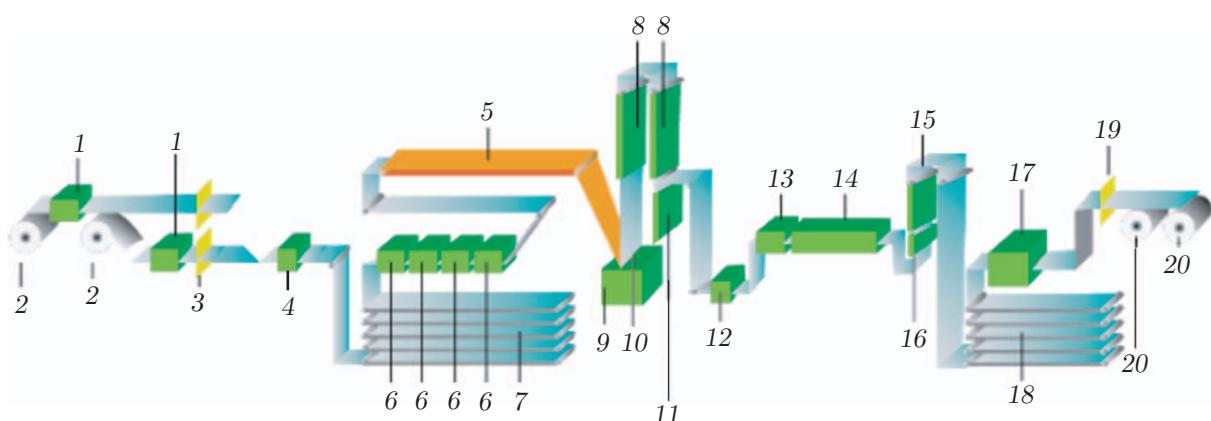


Рис. 1. Основные технологические узлы линии непрерывного горячего цинкования

подготовительный этап входят: обезжикивание, промывка, травление, повторная промывка и флюсование изделий. Основные технологические узлы линии непрерывного горячего цинкования, представленные на рис. 1, включают в себя: 1 — правильные машины, 2 — размыватели, 3 — гильотинные ножницы, 4 — сварочную машину, 5 — печь отжига, 6 — секции очистки, 7 — входное петлевое устройство, 8 — секции принудительного воздушного охлаждения, 9 — ванну цинкования, 10 — газовый нож, 11 — ванну водяного охлаждения, 12 — устройство для измерения толщины цинкового покрытия, 13 — прессировочную клеть, 14 — правильно-растяжную машину, 15 — печь сушки, 16 — химкоутер, 17 — кромкообразные ножницы, 18 — выходное петлевое устройство, 19 — гильотинные ножи, 20 — моталки.

Температура плавления цинка составляет $419,5^{\circ}\text{C}$, при этом для эффективного процесса оцинковки температура расплава цинка в ванне должна поддерживаться на уровне $460 \pm 10^{\circ}\text{C}$. При температуре ниже 490 и выше 520°C на стали образуются плотные, однородные железоцинковые слои, прочно прилегающие к поверхности. Однако в диапазоне температур от 490 до 520°C формируются пористые слои, которые плохо склеиваются со сталью, что может оказывать негативное влияние на качество покрытия.

Подготовка металлического листа перед погружением в цинковую ванну играет ключевую роль в формировании качественного покрытия. Каждая марка стали требует индивидуального режима обработки, включая оптимальную скорость движения полосы. Например, режим отжига полосы зависит от скорости и марки стали: сталь толщиной более 1 mm обрабатывают при скорости до 120 m/min , тогда как более тонкие марки стали проходят процесс при более высоких скоростях. Для определения оптимальной скорости необходимо учитывать параметры полосы и более 100 других факторов, влияющих на качество готового покрытия. Большая часть оборудования в установке направлена на достижение требуемых параметров листа.

Металлическая полоса шириной от $0,9$ до $1,8\text{ m}$ и длиной до $6,5\text{ km}$ проходит этапы термической обработки, затем погружается в ванну с расплавленным цинком и проходит многоступенчатый технологический процесс. После этого полоса охлаждается, разрезается и наматывается в рулоны.

Каждый рулон поступает в оцинковочный агрегат, где проходит через цинковую ванну (рис. 2). В начале и конце обработки каждого рулона к нему приваривается новый,

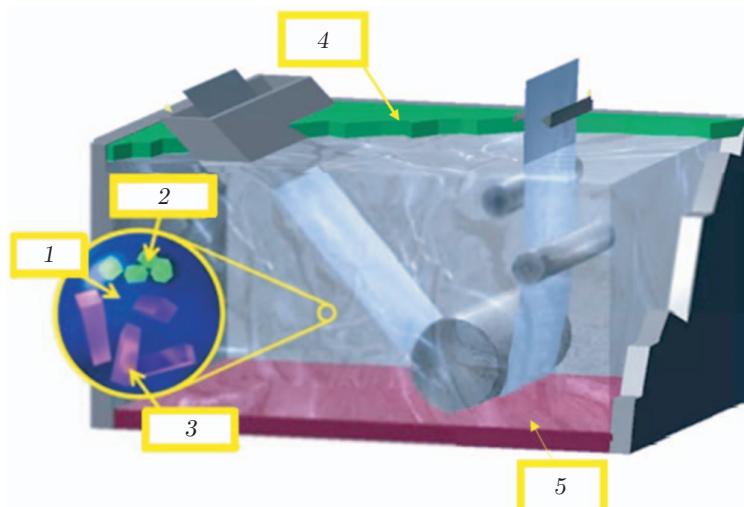


Рис. 2. Процесс горячего покрытия листовой стали методом погружения в ванну цинкования с формированием двух типов дrossса: 1 — $\text{Zn}(\text{Al}, \text{Fe})$, 2 — Fe_2Al_5 , 3 — FeZn_7 , 4 — поверхностный дросс, 5 — донный дросс

что обеспечивает непрерывное движение полосы через оцинковочную ванну. Температура ванны, поддерживаемая индукторами, варьируется от 450 до 470 °С, что позволяет создавать расплав цинк-алюминиевого сплава. По мере его истощения в ванну добавляют новые слитки цинк-алюминиевого сплава для поддержания необходимого состава.

На агрегаты горячего цинкования поступает предварительно прошедшая стадию травления и смотанная в рулон сталь, обработанная на участке подготовки холоднокатанных рулонов. В АНГЦ металл проходит стадии очистки, термической обработки, нанесения и охлаждения покрытия, результатом которых является оцинкованная сталь. Конечно, оптимизировать работу агрегата можно на каждом этапе, но самый большой потенциальный эффект, в свою очередь, достигается за счёт изменения концентрации алюминия в ванне.

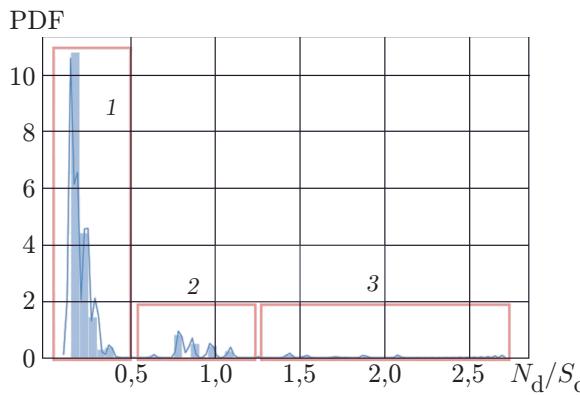
Процесс горячего покрытия листовой стали методом погружения в цинкосодержащий расплав сопровождается образованием побочных продуктов — дроссов. Например, дросс с меньшей плотностью всплывает на поверхность ванны, а с большей плотностью (гартцинк) оседает на дне. Во всех случаях дросс загрязняет рабочий расплав и полосу, тем самым уменьшая рабочий объём ванны, поэтому требуется их периодическое удаление. При концентрации от 0,18 до 0,3 % наступает оптимум, количество дrossa становится меньше, а покрытие получается наиболее равномерным, пластичным, прочным, блестящим, качественным.

Автоматизированная система управления АНГЦ включает в себя: 1) автоматизированный ввод заданий на обработку рулонов и слежение за сварным швом в линии агрегата; 2) сбор технологических параметров при обработке полосы и передачу их в цеховую систему слежения за металлом для учёта, анализа и архивации; 3) последовательные логические операции по транспортировке полосы; 4) управление механизмами входной, средней и выходной частей агрегата, а также выбор и регулирование режимов технологического процесса обработки полосы в агрегате, включая режимы изменения цикла нагрева, заданной поверхностной плотности цинкового покрытия, размеров полосы, марок стали.

Далее использовались данные с датчиков производства (из системы сбора технологических параметров) за четыре месяца, которые содержали более десяти различных параметров, отражающих состояние процесса оцинковки. Собирались следующие данные: толщина металла, толщина цинка сверху и снизу, скорость прокатки рулона, температура в носке печи и ванне цинкования, позиция воздушного ножа, усилие и удлинение в дрессировочной клети, смена и бригада производства. Данные предоставлены по определённой интересующей толщине металла — 0,65 мм. В наборе данных было 134 материнских рулона и 212 дочерних, получено 430 000 строк с различными значениями параметров для каждого метра рулона, из которых фактов дrossa 4181 (меньше 1 %). На коммерческих листах дросс фиксируется всегда из-за особенности покрытия тонкого металла, поэтому в итоговой выборке рассматриваются только автолисты.

Между параметрами рулона стали и количеством дrossa есть прямая зависимость: чем больше площадь стали, тем больше вероятность появления дефекта. В связи с этим выбрана целевая переменная — количество дефектов, скорректированное на площадь рулона (плотность дефектов). Разработана модель классификации, состоящая из четырёх групп (рис. 3): в секторе рулона нет дефектов (48,3 %), удельное число дефектов <1 (28,2 %), удельное число дефектов $1\text{--}1,75$ (15,7 %), удельное число дефектов $>1,75$ (7,8 %).

Описание инструментария. Для изучения факторов, оказывающих влияние на формирование дrossa, использовались методы статистического анализа данных и машинного обучения, что позволило углубить анализ процессов и определить значимые параметры. В рамках статистического анализа применены методы построения гистограмм и функций плотности вероятности, что помогло визуализировать распределение данных и выявить их ключевые особенности. Эти статистические подходы послужили основой для



Rus. 3. Функция плотности вероятности (PDF, probability density function) удельного количества дrossса на $1 \text{ м}^2 N_d/S_c$. Цифры над прямоугольными областями обозначают диапазоны значений, соответствующие различным дефектам: 1 — удельное число дефектов < 1 ; 2 — удельное число дефектов $1-1,75$; 3 — удельное число дефектов $> 1,75$

последующего применения алгоритмов машинного обучения, направленных на классификацию и оценку влияющих факторов.

Для решения задач бинарной и многоклассовой классификации удельного количества дrossса (на 1 м^2 проката листа) проведён сравнительный анализ различных алгоритмов машинного обучения, начиная с простых линейных моделей и заканчивая более сложными методами, такими как градиентный бустинг. Некоторые семейства алгоритмов, обладающие слабой интерпретируемостью (например, нейронных сетей), намеренно не рассматриваются, чтобы сохранить прозрачность и доступность интерпретации результатов.

Создание дополнительных признаков выполнялось с применением библиотеки TSFresh, которая позволяет автоматизировать процесс поиска статистических функций, наиболее значимых для анализа данных [7]. Эта библиотека помогает автоматизировать извлечение признаков и обогатить набор данных новыми показателями, что способствует повышению качества модели и выявлению важных паттернов.

Подготовленный датасет разделён на тренировочную и отложенную выборки в соотношении 80 на 20 %, где тренировочная выборка использовалась для кросс-валидации, а финальное тестирование проводилось на отложенной выборке. Кросс-валидация обеспечивала устойчивость модели и предотвращала переобучение, что критически важно для корректной оценки результатов. Подбор гиперпараметров моделей производился с помощью фреймворка Optuna, который предоставляет мощные инструменты для автоматического поиска параметров, обеспечивающих наилучшую производительность модели [8]. Авторы апробировали данный подход при решении ряда теплофизических и гидродинамических задач. Детали методов описаны в работах [9, 10].

Результаты моделирования. Показано, что алгоритм градиентного бустинга демонстрирует наиболее точные результаты прогноза на отложенной выборке, при этом является интерпретируемой моделью из-за свойств базовой модели — дерева решений [11].

Сравнение метрик моделей представлено в табл. 2. Стекинг SVM, модели « k ближайших соседей» и Catboost лишь на 1 % превосходят Catboost по полноте, но значительно усложняют модель, снижая интерпретируемость и усложняя внедрение. Поэтому для анализа и интерпретации выбрана модель Catboost. В рамках процедуры подбора получены основные гиперпараметры модели: число деревьев 150, скорость обучения 0,05, максимальная глубина дерева 3, логистическая функция потерь, доля от общего числа признаков для построения дерева 0,8, доля выборки для обучения одного дерева 0,85.

Таблица 2

Сравнение моделей бинарной классификации

Алгоритмы	Модели	Метрики			
		Precision	Recall	F ₁	AUC ROC
SC	Stacking Classifiers (SVM + KNN + CB)	0,93	0,51	0,64	0,89
CB	CatBoost Classifier	0,93	0,50	0,64	0,89
LGB	Light Gradient Boosting Machine	0,91	0,48	0,63	0,88
GB	Gradient Boosting Classifier	0,90	0,47	0,62	0,88
SVM	Support Vector Machines	0,71	0,52	0,6	0,87
ADA	AdaBoost Classifier	0,82	0,41	0,55	0,85
RF	Random Forest Classifier	0,82	0,39	0,53	0,84
ET	Extra Trees Classifier	0,81	0,38	0,52	0,84
KNN	K Neighbors Classifier	0,51	0,48	0,49	0,81
DT	Decision Tree	0,50	0,20	0,29	0,77
LR	Logistic Regression	0,51	0,15	0,23	0,75
Ridge	Ridge Classifier	0,48	0,14	0,22	0,74
NB	Naive Bayes Classifier	0,38	0,12	0,18	0,72

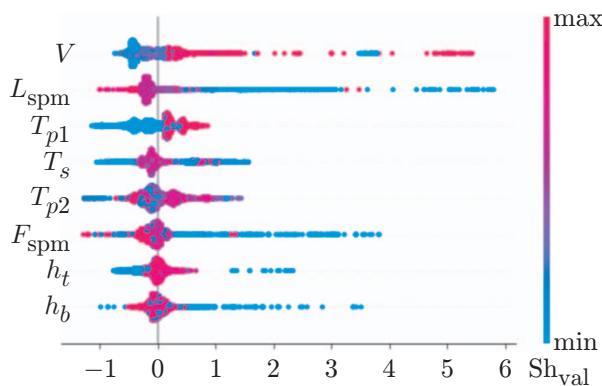


Рис. 4. Зависимость значений Шепли Sh_{val} (выход модели) для наиболее значимых параметров, влияющих на процесс образования дросса. Красные точки соответствуют большим значениям признаков, а синие — меньшим

В работе использованы значения Шепли (подход из теории игр) для интерпретации моделей машинного обучения, которые объясняют вклад каждого признака в предсказание конкретного наблюдения [12]. Значением Шепли признака является среднее маржинальное вкладов этого признака в предсказание модели по всем возможным комбинациям других признаков.

Из полученных 13 параметров во время построения модели удалены неинформативные признаки. В конечную модель вошли восемь параметров (рис. 4). В результате моделирования между фактом наличия дrossса и параметрами высоты ножей, типа стали, бригады и смены в существующих данных не установлена сильная связь. Из модели исключены 45, 46, 47, 48-ая недели 2019 г. из-за аномально малого числа дrossсов. В данных, соответствующих моментам без дrossсов, удалено 25 % аномальных данных, исходя из результатов кросс-валидации модели. Для оценки качества модели мы использовали следующие метрики: матрицу ошибок (табл. 3, 4), Precision (точность), Recall (полнота), F₁ (F-мера) и AUC ROC (Area Under Curve of Receiver Operating Characteristic) (см. табл. 1). Прогноз-

Таблица 3
Матрица ошибок бинарной классификации
(t — истинные ответы, p — прогноз модели)

t/p	0	1
0	2843	394
1	347	602

Таблица 4
Матрица ошибок многоклассовой классификации
(t — истинные ответы, p — прогноз модели)

t/p	1	2	3	4
1	4359	130	45	4
2	357	285	59	6
3	31	27	22	4
4	2	1	6	6

ная модель основана на классификаторе Catboost. Точность модели составляет более 90 %, полнота более 50 %, AUC ROC = 0,89, F₁ = 0,64, Precision = 0,93, Recall = 0,5.

В результате показано, что наиболее важными параметрами, которые необходимо контролировать при прокате, являются скорость прокатки листа, удлинение в дрессировочной клети, температура в ванне цинкования, температура в носке печи. На рис. 5 выделены области значений признаков, в которых наблюдается наибольшее влияние на вероятность возникновения дrossса. На рис. 5, e видно, например, что большие значения температуры в ванне цинкования увеличивают вероятность возникновения дrossса. Маленькие значения удлинения в клети также сильно влияют на возникновение дrossса (рис. 5, a). Анализ значимых признаков показывает, что большие значения удлинения уменьшают вероятность дrossса.

Между параметрами рулона стали и количеством дrossса есть прямая зависимость — чем больше площадь стали, тем больше вероятность возникновения дrossса. В связи с этим выбрана удельная целевая переменная — сумма дrossсов, скорректированная на величину площади рулона.

На основе модели многоклассовой классификации сделаны следующие выводы. Низкая температура в носке печи повышает вероятность класса 1 (удельное число дефектов <1). Высокая скорость увеличивает вероятность класса 1. Низкое значение удлинения в дрессировочной клети повышает вероятность класса 1. Низкая температура в носке печи и высокое усилие в дрессировочной клети (удельное число дефектов 1–1,75), низкое удлинение в дрессировочной клети и высокое усилие в дрессировочной клети повышают вероятность класса 2. Большая толщина цинка сверху и высокая температура в ванне цинкования (удельное число дефектов > 1,75) повышают вероятность класса 3.

Высокое усилие в дрессировочной клети повышает вероятность класса 3. Установлено, что высокая скорость увеличивает вероятность возникновения дrossса для всех классов (рис. 5, d). Маленькое удлинение в дрессировочной клети увеличивает вероятность возникновения дrossса для всех классов (см. рис. 5, a). Высокая температура в ванне цинкования увеличивает вероятность возникновения дrossса для всех классов (см. рис. 5, e). Низкая температура в носке печи увеличивает вероятность возникновения дrossса для всех классов (рис. 5, f).

Цифровой помощник. В рамках предлагаемого исследования разработан и протестирован цифровой помощник, основанный на использовании модели машинного обучения.

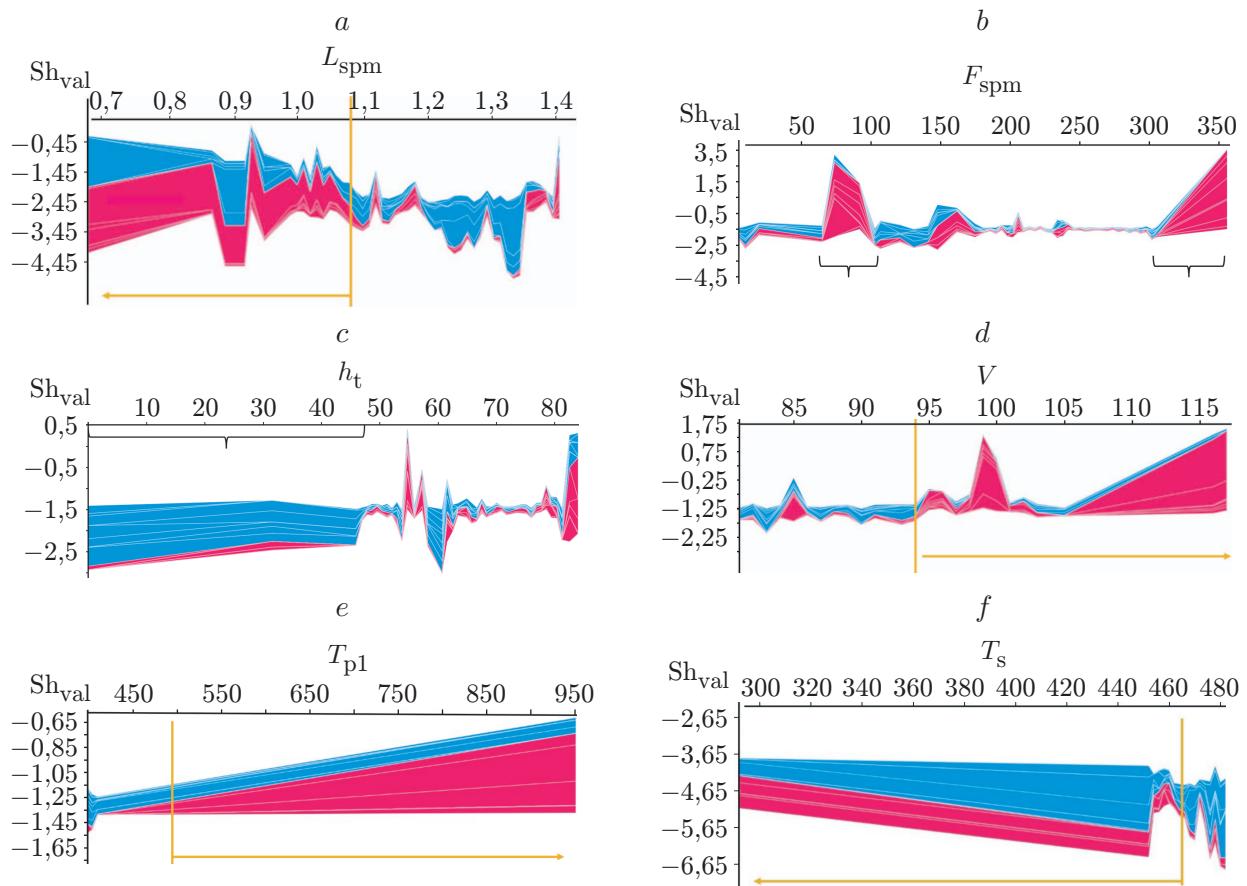


Рис. 5. Зависимость значений Шепли (выход модели) от значений основных параметров процесса: *a* — удлинение в дрессировочной клети *L_{spm}*; *b* — усилие в дрессировочной клети *F_{spm}*; *c* — толщина цинка сверху *h_t*; *d* — скорость прокатки рулона *V*; *e* — температура в ванне цинкования *T_{p1}*; *f* — температура в носке печи *T_s*. Стрелками и фигурными скобками показаны области значений признаков, в которых наблюдается наибольшее влияние на вероятность возникновения дrossса

Прототип представлен в виде вычислительной системы, объединяющей базы данных, вычислительный бэкенд и пользовательский интерфейс.

Для хранения данных применяется реляционная база данных PostgreSQL, обеспечивающая надёжное хранение и быстрый доступ к данным, связанным с параметрами прокатки и прогнозами вероятности возникновения дросса.

Логика обработки данных и взаимодействия модели машинного обучения с пользовательским интерфейсом реализована с применением фреймворка FastAPI. Данный инструмент выбран благодаря его высокой производительности, поддержке асинхронного ввода-вывода и удобной интеграции с внешними сервисами.

Интерфейс разработан на базе фреймворка Kivy и интегрирован в систему контроля качества производства в виде дополнительного виджета, который позволяет операторам визуализировать и интерпретировать ключевые производственные показатели и их влияние на вероятность возникновения дросса.

К функциональным возможностям интерфейса относятся: ввод параметров прокатки, прогноз вероятности возникновения дросса, анализ факторов и визуализация данных.

Операторы могут использовать слайдеры внутри виджета для ручной установки текущих параметров технологического процесса. Система выводит расчётное значение вероятности на основе текущих данных. Виджет обеспечивает возможность анализа влияния отдельных признаков на прогнозируемую вероятность с применением значений Шепли. Пользователи могут исследовать графики распределений параметров и взаимосвязей между ними.

Прототип реализован на языке программирования Python и дополнен вычислительным графом для симуляции влияния изменения технологических параметров на формирование дросса. Это позволяет моделировать сценарии производственного процесса и анализировать эффекты изменения отдельных характеристик. Цифровой помощник интегрирован с системой сбора данных в режиме реального времени, при котором параметры текущего рулона могут поступать непосредственно в бэкенд, где производится оценка вероятности возникновения дросса.

Таким образом, разработанный цифровой помощник представляет собой комплексное решение, которое объединяет современные технологии анализа данных, интерактивные визуализации и инструменты поддержки принятия решений.

Заключение. В работе проведено исследование влияния параметров процесса на возникновение дефектов поверхности листа (дроссов). На основе данных системы сбора параметров процесса разработаны модели бинарной классификации, прогнозирующие вероятность возникновения дросса, и многоклассовой классификации для прогнозирования удельного количества дросса (по диапазонам).

Результаты показали, что наиболее важными параметрами, которые необходимо контролировать при прокате, являются скорость прокатки листа, удлинение в дрессировочной клети, температура в ванне цинкования и температура в носке печи. Также реализован алгоритм автоматической оценки рулонов стали на основе ансамбля моделей градиентного бустинга, а результаты представлены в виде аналитической панели, которая позволяет наглядно визуализировать и интерпретировать конкретные ситуации возникновения дефектов.

Для оценки рулона разработан цифровой помощник, позволяющий симулировать процесс управления для анализа влияния параметров на возникновение дросса в конкретный момент времени. Разработанные модели могут применяться в реальном времени для оценки рулонов стали, а также дообучаться по мере поступления новых данных, что позволяет учитывать новые случаи и закономерности.

Предложенные модели могут быть использованы на различных этапах производственного процесса: для автоматизации сертификации продукции, прогнозирования дефектов во время производства и анализа причин их возникновения.

Финансирование. Работа выполнена в рамках государственного задания Института теплофизики СО РАН (регистрационный номер 121031800229-1).

СПИСОК ЛИТЕРАТУРЫ

1. Gupta A. K., Kumar D. R. Formability of galvanized interstitial-free steel sheets // Journ. Mater. Processing Technol. 2006. **172**, Iss. 2. P. 225–237.
2. Song G. M., Vystavel T., van der Pers N. et al. Relation between microstructure and adhesion of hot dip galvanized zinc coatings on dual phase steel // Acta Materialia. 2012. **60**, Iss. 6–7. P. 2973–2981.
3. Azimi A., Ashrafizadeh F., Toroghinejad M. R., Shahriari F. Metallurgical analysis of pimples and their influence on the properties of hot dip galvanized steel sheet // Eng. Failure Analysis. 2012. **26**. P. 81–88.

4. Reiss G., Eßl W., Trasca R. A. et al. Development of a Dross Build-Up Growth Process Model for Hot-Dip Galvanizing Considering Surface Reaction Kinetics // Metallurgical and Mater. Trans. B. 2023. **55**, Iss. 1. P. 53–63.
5. Martínez-de-Pisón F. J., Alba-Elías F., Castejón-Limas M., González-Rodríguez J. A. Improvement and optimisation of hot dip galvanising line using neural networks and genetic algorithms // Ironmaking & Steelmaking. 2006. **33**, N 4. P. 344–352.
6. Mao K., Yang Y.-L., Huang Z., Yang D.-Y. Coating Thickness Modeling and Prediction for Hot-dip Galvanized Steel Strip Based on GA-BP Neural Network // Proc. of the 32nd Chinese Control And Decision Conference (CCDC). Hefei, China, 22–24 Aug., 2020. P. 3484–3489.
7. Christ M., Braun N., Neuffer J., Kempa-Liehr A. W. Time Series FeatuRe Extraction on basis of Scalable Hypothesis tests (tsfresh — A Python package) // Neurocomputing. 2018. **307**. P. 72–77.
8. Akiba T., Sano S., Yanase T. et al. Optuna: A Next-generation Hyperparameter Optimization Framework // Proc. of the 25th ACM SIGKDD Int. Conf. Knowledge Discovery & Data Mining (KDD). Anchorage, USA, 4–8 Aug., 2019. P. 2623–2631.
9. Абдуракипов С. С., Бутаков Е. Б. Сравнительный анализ алгоритмов машинного обучения для определения предотказных и аварийных состояний авиадвигателей // Автометрия. 2020. **56**, № 6. С. 34–48. DOI: 10.15372/AUT20200605.
10. Абдуракипов С. С., Токарев М. П., Первунин К. С., Дулин В. М. Моделирование характеристик тонального шума методами машинного обучения при обтекании гидропрофиля // Автометрия. 2019. **55**, № 2. С. 123–131. DOI: 10.15372/AUT20190213.
11. Alpaydin E. Machine Learning. Cambridge: MIT Press, 2021. Ch. 4. Neural Networks and Deep Learning. P. 105–141.
12. Sundararajan M., Najmi A. The Many Shapley Values for Model Explanation // Proc. of the 37th Int. Conf. Machine Learning (PMLR). Online, 13–18 July, 2020. **119**. P. 9269–9278.

Поступила в редакцию 20.12.2024

После доработки 27.01.2025

Принята к публикации 17.03.2025
