

Каждый шаблон может содержать несколько текстовых полей разных типов (текст, число, дата и др.). На основе шаблонов с помощью заполняемых на веб-интерфейсе форм создаются документы. Данные документов хранятся в базе данных, а при скачивании документа переносятся во временно создаваемый документ с помощью библиотеки TemplateEngine.docx.

### Список использованных источников

1. Методы работы с документами Microsoft Word при разработке веб-сервисов / И.А. Гурин, Н.А. Спиринов, В.В. Лавров, Н.И. Декун // Теплотехника и информатика в образовании, науке и производстве: сборник докладов VI Всероссийской научно-практической конференции студентов, аспирантов и молодых учёных (ТИМ'2017) с международным участием (11–12 мая 2017 г.). – Екатеринбург: УрФУ, 2017. С. 199-203.

2. Начало работы с MVC ASP.NET Core [Электронный ресурс] // Microsoft: [web-сайт]. – Режим доступа: <https://docs.microsoft.com/ru-ru/aspnet/core/tutorials/first-mvc-app> (дата обращения 25.04.2021).

3. Документация по ASP.NET [Электронный ресурс] // Microsoft: [web-сайт]. – Режим доступа: <https://docs.microsoft.com/ru-ru/aspnet/core/?view=aspnetcore-3.1> (дата обращения 25.04.2021).

4. Открытая библиотека по работе с шаблонами документов «TemplateEngine.Docx — OpenSource .NET» [Репозиторий GitHub] // Режим доступа: <https://github.com/UNIT6-open/TemplateEngine.Docx> (дата обращения 25.04.2021).

УДК 504.064.36

**А. О. Басистюк**

ФГБОУ ВО «Череповецкий государственный университет», г. Череповец,  
Россия

### ОПТИКО-ЭЛЕКТРОННАЯ СИСТЕМА КОНТРОЛЯ КАЧЕСТВА СМОТКИ ГОРЯЧЕКАТАНЫХ РУЛОНОВ

**Аннотация.** Решение задачи показывает, что использование «ручного» способа осмотра горячекатаных рулонов отделом технического контроля (ОТК) на дефекты смотки, является более затратным и менее эффективным, чем применение оптико-электронной системы контроля качества смотки, которая использует камеры для получения кадров с рулонами, а также современные нейросетевые технологии машинного обучения, позволяющие решить проблемы обнаружения и классификации основных видов дефектов в режиме реального времени. В процессе производственного тестирования выявлено, что при осмотре рулонов ОТК, было зафиксировано на 23 % меньше дефектов, чем разработанной системой, однако суммарная точность решения составляет 96.7 %. Ошибки или же «ложные срабатывания системы», связаны с такими факторами как, большое параметрическое разнообразие выпускаемой продукции (высота, ширина и толщина полотна

рулонов), частые перепады освещенности, блики, засветы камер, и не совершенность имеющегося оптического оборудования (выходное разрешение кадров и частота их обновления). Результатом работы по данной задаче является вывод о том, что разработанная оптико-электронная система контроля качества смотки горячекатаных рулонов позволяет увеличить процент обнаружения дефектов, а также выполнять сбор выходных данных для их дальнейшего анализа, на основе которого будут производиться изменения в технологическом процессе производства продукции.

**Ключевые слова:** нейронные сети, методы, компьютерное зрение, машинное обучение, дефекты, данные.

**Abstract.** *The solution of the problem shows that the use of "manual" method of inspection of hot-rolled coils by the technical control department (TCD) for defects in the coil, is more costly and less effective than the use of optical-electronic system of quality control of coils, which uses cameras to obtain frames with coils, as well as modern neural network technologies of machine learning, allowing to solve problems of detection and classification of the main types of defects in real time. During production testing, it was found that the inspection of TCD coils recorded 23 % fewer defects than the developed system, but the total accuracy of the solution is 96.7 %. Errors or "false responses of the system" are associated with such factors as a large parametric variety of manufactured products (height, width and thickness of the web rolls), frequent lighting differences, glare, backlighting of cameras, and imperfection of available optical equipment (output resolution of frames and frequency of their updating). The result of the work on this problem is the conclusion that the developed opto-electronic system for quality control of hot-rolled coils can increase the percentage of defects detection, as well as to collect the output data for their further analysis, based on which changes in the technological process of production will be made*

**Key words:** *neural networks, methods, computer vision, machine learning, defects, data.*

На данный момент в компании ПАО «Северсталь» проверка продукции перед отгрузкой клиенту производится отделом технического контроля (ОТК), без использования каких-либо систем. Это приводит к тому, что большинство дефектов пропускается и/или не верно классифицируется, что порождает финансовые и репутационные риски для компании.

Целью работы является повышения процента обнаружения и классификации дефектов смотки на горячекатаных рулонах.

Постановка задачи. Необходимо в режиме реального времени отслеживать перемещения ГК рулонов по транспортировочному конвейеру и обнаруживать на них 2 вида дефектов смотки, а именно «Выброс витка» и «Телескоп». Выходную информацию следует передавать в систему слежением за металлом. В случае обнаружения дефектов, которые имеют критические параметры (высота, протяженность, количество) следует незамедлительно подать оповещающий сигнал на пост оператора, для предотвращения дальнейшего продвижения бракованной продукции.

Методы. Для реализации поставленной задачи применялись методы математического моделирования, машинного обучения, а также алгоритмы компьютерной обработки изображений.

Описание дефектов смотки. Дефект «Телескоп» — это дефект формы в виде равномерного выступа витков из внутренней или внешней части рулона (рис. 1).

Дефект «Выброс витков» — это смотки представленный виде выступов отдельных витков от основной части торца рулона (рис. 2) [1].

Любая задача, подразумевающая использование нейросетевых технологий, делится на две основные части, это работа с данными и обучения искусственной

нейронной сети (ИНС). В рамках разработанной системы использовалась сегментационная ИНС, имеющая архитектуру под названием «U-net» [2]. Данная нейронная сеть с высокой точностью справляется с обнаружением и классификацией объектов, имеющих неоднозначный геометрический вид. А выходные данные представляют собой маску (закрашенный определённым цветом полигон), который в дальнейшем можно передать на измерительный анализ. Для обучения данной модели необходимо подготовить набор данных, состоящих из изображения рулона и маски, которая закрашивает место с искомым объектом (рис. 3).




Рис. 1. Дефект смотки «Телескоп»




Рис. 2. Дефект смотки «Выброс витков»




Рис. 3. Пример разметки дефекта «Телескоп»

Метрики. Для оценки точности обучения модели используются «метрики», а именно расчетные параметры, такие как IoU (Intersection over Union) показывающая насколько у двух объектов (размеченной маски и результата работы модели) совпадает внутренний объем (рис. 4).




Рис. 4. Метрика IoU

Для оценки точности классификации объектов используется метрика Precision, которая показывает процент объектов, которые модель правильно распознала и при этом они действительно являются таковыми. Итоговая точность модели рассчитывается метрикой True Positive (TP), которая показывает с каким процентом модель обнаружила объекты и правильно их классифицировала на всем тестовом наборе данных.

Обучение модели. Основное правило при обучении модели с использованием специальных меток (подход «обучение с учителем») это разбиение всего набора данных на три части, а именно обучающую, валидационную и тестовую. Обучающая выборка не должна пересекаться с валидационной и тестовой, иначе это приведет к переобучению модели. Валидационная выборка выступает в роли промежуточной оценки метрик в процессе всего обучения, а тестовая необходима для окончательного расчета точности модели. Для достижения высокой точности был разработан подход итерированного обучения, заключающийся в разбиении выборки не только на три основные составляющие, но и на временные промежутки. При данном подходе модель обучалась не один раз, а восемь в период с (октября 2020 г. по май 2021 г.) с каждым разом увеличиваю суммарную точность.

Такой подход был выбран исходя из переменчивых производственных условий и позволил обучить модель с точностью 96.7 % (рисунок 5).



Рис. 5. Период итерационного обучения модели

Процент временного пересечения выборки составлял 10 % от суммарного объема данных, накопленных за месяц. Процесс обучения и результаты отображен в таблице 1.

Методы измерительного анализа обнаруженных дефектов. Для расчета геометрических параметров такие как площадь, высота и длинна дефекта использовались следующие математические методы и подходы.

Формула Грина как способ расчета площади контура дефекта:

$$\oint_L (x + 2y)dx + (3x - y)dy = \iint_D (3 - 2)dx dy = \iint_D dx dy. \quad (1)$$

Результаты обучения модели

Период	IoU (%)	Precision	TP
Октябрь	73.2%	81.6%	63.4%
Ноябрь	74.6%	85.2%	68.2%
Декабрь	77.8%	89.6%	71.5%
Январь	83.7%	91.5%	76.3%
Февраль	85.9%	93.7%	85.2%
Март	88.4%	94.2%	87.9%
Апрель	97.2%	93.6%	95.3%
Май	98.6%	97.8%	96.7%

В программной реализации формула Грина используется как метод «cv2.contourArea()» из библиотеки компьютерного зрения OpenCV, на вход подается контур маски обнаруженного дефекта, а на выходе получается число эквивалентное его площади.

Для расчета высоты дефекта необходимо получить все точки локализации выбранного дефекта и произвести итерационное вычитание максимальной и минимальной высоты для каждого  $i$ -того шага дефекта (рисунок 6).

$$H_i = \int_i (y_{\max}(y_i) - y_{\min}(y_i)), \quad (2)$$

где  $y_{\max} = \max \int_i (y_i)$ , крайняя верхняя по Y точка;

$y_{\min} = \min \int_i (y_i)$ , крайняя нижняя по Y точка.




Рис. 6. Расчет высоты дефекта

В качестве длины дефекта рассчитывается разница между координатами крайней правой точки дефекта  $x_{\max}(x,y)$  к крайней левой  $x_{\min}(x,y)$  (рис. 7).

$$W = mR(x,y) - mL(x,y) = \sqrt{((mR(x) - mL(x))^2 + ((mR(y) - mL(y))^2)} \quad (3)$$

$mR = \max \int_i (x_i)$ , крайняя правая по X точка;

$mL = \min \int_i (x_i)$ , крайняя левая по X точка;




Рис. 7. Расчет длины дефекта

Итогом работы стала система, которая в режиме реального времени, с точностью 96,7 % обнаруживает и классифицирует два вида дефектов смотки, а также рассчитывает их геометрические параметры для определения их критичности.

## Список использованных источников

1. Классификатор «Повреждений и дефектов формы кромки и товарного вида горячекатаного рулонного проката не допустимых для отгрузки, требующих доработки». 2016 г.

2. Nahian Siddique, Paheding Sidike – U-net and its variants for medical image segmentation: theory and applications. 2020 г. – С. 2-10.

УДК 004.421: 669.162.263

**А. С. Блинков, Н. А. Спириин, И. А. Гуриин**

ФГАОУ ВО «Уральский федеральный университет

имени первого Президента России Б.Н. Ельцина», г. Екатеринбург, Россия

### СТРУКТУРА ИНФОРМАЦИОННО-МОДЕЛИРУЮЩЕЙ СИСТЕМЫ КОНТРОЛЯ ТЕПЛОВЫХ ПОТЕРЬ В ДОМЕННОЙ ПЕЧИ

**Аннотация.** В современных условиях доменной плавки удельный расход кокса определяется развитием теплообменных процессов, протекающих в нижней зоне печи. При этом потери тепла, найденные с использованием теплового баланса нижней зоны печи, в достаточной степени отражают такие технологические показатели, как удельный расход кокса и содержание кремния в чугуна. Представлена структура информационно-моделирующей системы контроля тепловых потерь в доменной печи и её функциональная модель.

**Ключевые слова:** доменный процесс, потери тепла, информационно-моделирующая система, функциональная модель.

**Abstract.** In modern conditions of blast furnace smelting, the specific consumption of coke is determined by the development of heat exchange processes occurring in the lower zone of the furnace. In this case, the heat losses found using the heat balance of the lower zone of the furnace sufficiently reflect such technological indicators as the specific consumption of coke and the silicon content in cast iron. The structure of an information-modeling system for controlling heat losses in a blast furnace and its functional model are presented.

**Key words:** blast furnace process, heat loss, information modeling system, functional model.

**Содержательная постановка задачи.** Основная потери в доменных печах приходится на высокотемпературную зону печи: нижнюю часть шахты, заплечики, фурменную зону, горн и лещадь. Их доля составляет 85-90 % от общих потерь тепла [1]. Согласно теории теплообмена Б.И. Китаева [2, 3], в доменной печи имеется две автономно работающие зоны теплообмена – верхняя и нижняя, разделенные между собой так называемой «резервной зоной» с температурой 900–950 °С. Завершенность процессов теплопередачи в доменной печи, т.е. относительная автономность теплового баланса низа дает возможность использовать его для анализа доменной плавки. При этом влияние теплового состояния верхней части печи на тепловое состояние низа печи может быть с достаточной для практического применения точностью оценено через степень прямого восстановления оксидов железа.