

## Эксперимент по обучению и тестированию модели компьютерного зрения для определения прогаров сталеразливочной трубы на установке непрерывной разливки стали

*М.Б. Сергеев, Д.Д. Знаменская*

*Санкт-Петербургский государственный университет аэрокосмического приборостроения, Санкт-Петербург*

**Аннотация:** В статье описывается эксперимент по составлению обучающей выборки, обучению и тестированию модели нейронной сети системы компьютерного зрения для распознавания прогаров защитной трубы на установке непрерывной разливки стали. Рассматривается вопрос обоснованности аугментации данных для обучения. Анализируются полученные результаты.

**Ключевые слова:** компьютерное зрение, детекция объектов, датасет, аугментация, сталеплавильное производство, непрерывный разлив стали, прогар защитной трубы.

### Введение

В технологическом процессе непрерывного производства стали одним из самых сложных этапов является ее разливка на установке непрерывной разливки стали (УНРС) [1], схема которой представлена на рис. 1.

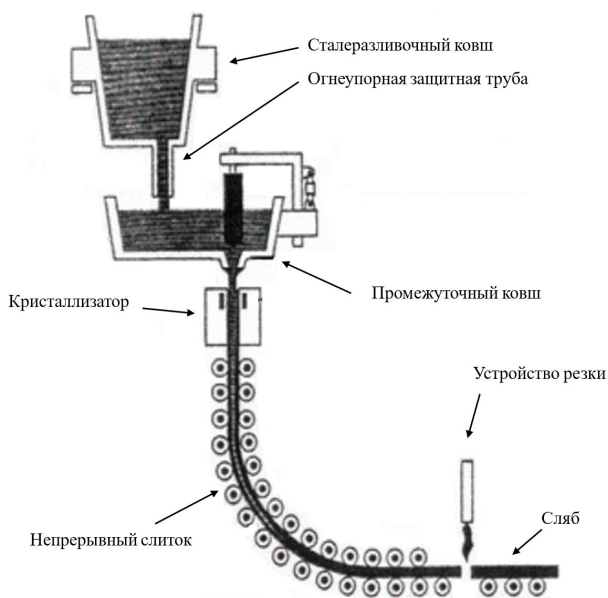


Рис. 1. – Схема установки непрерывной разливки стали

Такой способ разливки стали является прогрессивным и эффективным, позволяющим получать высококачественные заготовки [2]. На УНРС из

сталеразливочного ковша жидкая сталь по специальной огнеупорной защитной трубе попадает в промежуточный ковш. Данная труба защищает сталь от вторичного окисления, которое может привести к изменению химического состава и, впоследствии, ухудшению качества стали – сталь может перестать соответствовать требованиям заказа или возникнуть какие-либо дефекты при прокате, например, плены.

Защитная труба – это закупаемый расходный материал, использование которого рассчитано на определенное количество плавов (гарантированная производителем стойкость), так как под воздействием высоких температур, порядка  $\sim 1500$  °C, он постепенно начинает разрушаться. Поэтому, защитная труба должна быть вовремя заменена на новую, не допустив нарушения технологического процесса. Без защитной трубы сталь разливать нельзя [3].

Однако, в процессе разливки возможно возникновение нештатных ситуаций, в частности, непредвиденного прогара сталеразливочной трубы, что чревато не только внеплановым простоем агрегата и повышением содержания кислорода в стали, но и угрозой жизни работающих в цехе сотрудников.

Традиционные методы контроля за состоянием защитной трубы основаны на визуальном наблюдении за оборудованием вживую и через камеры на посту, что сопряжено с высокой нагрузкой на персонал и необходимостью выполнения ручных операций в случае аварии. Внедрение интеллектуальных систем на основе компьютерного зрения в металлургическом производстве [4, 5] позволяет автоматизировать многие процессы, в том числе мониторинг состояния защитной трубы, и обеспечить оперативное оповещение о прогарах.

Цель настоящей работы – описание эксперимента по составлению обучающей выборки и использованию технологии аугментации для обучения

модели нейронной сети используемой системы мониторинга и результатов его проведения.

### Описание эксперимента

Для решения проблемы обнаружения прогаров защитной трубы использовалась модель YOLO, зарекомендовавшая себя точной и высокоэффективной в задачах детекции объектов [6]. Для оптимального развертывания в условиях ограниченных вычислительных ресурсов промышленного предприятия была выбрана версия v5n.

Прогар защитной трубы – событие редкое, случающееся даже не еженедельно, поэтому при подготовке эксперимента возникли сложности создания датасета для обучения модели. Ввиду того, что на производстве могут использоваться защитные трубы разных конструкций и геометрической формы, в зависимости от условий разливки и требований заказчика, сложность создания датасета существенно возрастает.

В проведенном эксперименте для одного типа трубы на камеры, установленные в производственном цехе, удалось записать интересное нас событие в виде двух видео. Однако анализ сделанных записей показал, что только одно из них удовлетворяло требованиям эксперимента и задачам тестирования модели. Датасет составлялся путем разбиения этого видео на отдельные кадры с удалением идентичных кадров. Всего таким образом было получено 320 изображений с разрешением  $1920 \times 1080$  пикс. Однако, стоило учитывать, что все эти кадры представляют собой изображение одного и того же прогара, но в разные моменты времени – от появления трещины до замены защитной трубы на новую. Два варианта примера изображения прогара защитной трубы представлены далее на рис. 2 и рис. 3.

Очевидно, что полученный таким образом датасет не репрезентативен и для обучения модели его недостаточно. Поэтому в дополнение была использована техника аугментации [7, 8] – искусственного размножения

данных, позволяющая увеличить набор обучающих изображений за счет получения новых путем синтеза и изменения существующих [9, 10].

Продвинутые техники аугментации позволяют увеличить количество данных, повысить скорость разработки и уменьшить ее стоимость. Более того, это способствует уменьшению количества параметров нейронной сети, так как нейронная сеть начинает выделять общие признаки, а не специфичные для конкретного датасета.



Рис. 2. – Прогар трубы (вариант 1)

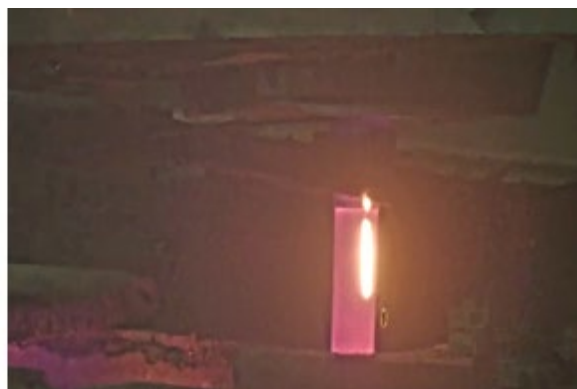


Рис. 3 – Прогар трубы (вариант 2)

Для расширения обучающего набора было принято решение использовать такие методы аугментации [8], как поворот изображения, масштабирование, синтез.

В результате из 800 изображений в датасете для обучения модели 520 – аугментированы, а общее соотношение составило: 29% – синтезированные изображения; 36% – изображения, созданные путём геометрических преобразований из оригинальных изображений; 35% – оригинальные изображения.

Для валидации использовались 100 изображений в аналогичном соотношении исходных и аугментированных данных.

После сбора данных была выполнена их разметка с максимально точным выделением областей прогаров в формате bounding boxes. Затем – настроена конфигурация модели YOLO для обучения в течение 20 эпох для

обеспечения приемлемой ошибки [11]. Параметры, отличающиеся от определенных в модели по умолчанию [6], следующие:

- `imgsz=1920` пикс (для сохранения исходной детализации);
- `deterministic=True` (для воспроизводимости результатов при повторных запусках);
- `task='detect'` (явное указание задачи детекции объекта на изображении);
- `box=4` (выбрано эмпирически для достижения баланса между точностью локализации и классификации);
- `amp=True` (ускорение обучения с минимальными потерями в точности).

Обучение модели с описанной выше конфигурацией заняло приблизительно 22 часа, и по его завершении были получены следующие значения ключевых метрик, представленные на рис. 4.

Интерпретация потерь:

- `train/box_loss` снизилась с 1.03 до 0.51, то есть модель точно позиционирует прогары защитной трубы на известной выборке;
  - `train/cls_loss` уменьшилась с 12.84 до 0.84, что свидетельствует о том, что модель научилась отличать прогары защитной трубы от фона на известной выборке;
  - `val/box_loss` снизилась с 0.85 до 0.59 – к 20 эпохе модель способна достаточно точно определять границы областей прогаров на новых изображениях;
  - `val/cls_loss` уменьшилась с 8.97 до 0.96, то есть модель правильно обнаруживает прогары защитной трубы (отличает от фона) на большинстве изображений валидационной выборки.
-

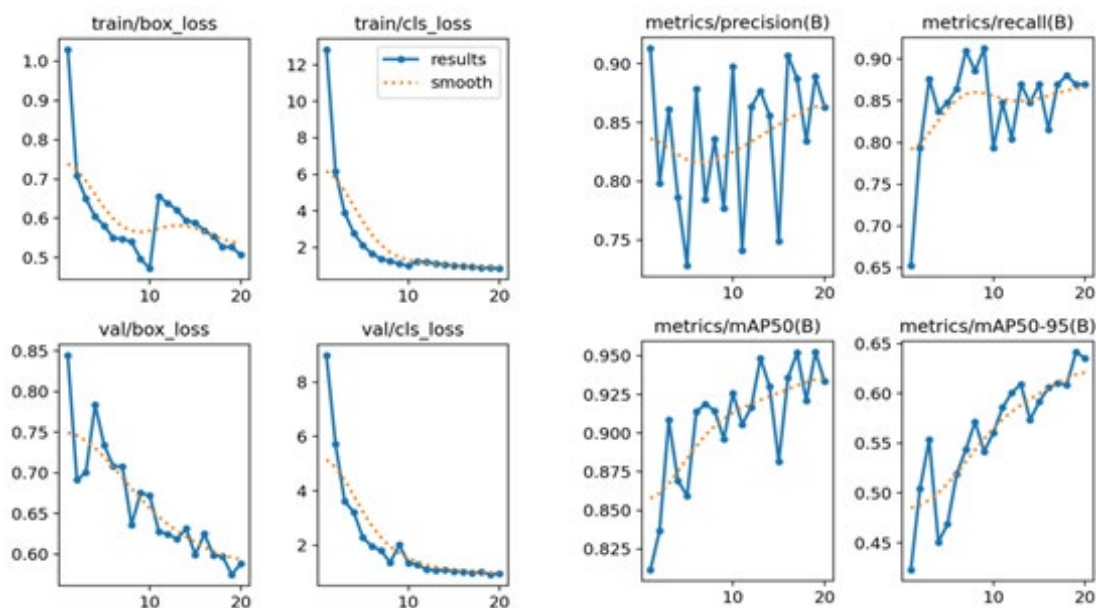


Рис. 4. – Результаты обучения модели

#### Интерпретация метрик:

– точность определения прогаров к 20 эпохе составила 0.86. Иначе говоря, 86% обнаруженных моделью объектов действительно являются прогарами защитной трубы;

– полнота – 0.865, то есть модель обнаруживает 86.5% реальных прогаров на изображении;

–  $mAP@0.5$  и  $mAP@0.5:0.95$  равны 0.93 и 0.64 соответственно, что говорит об эффективности определения областей прогаров.

Несмотря на колебание метрик от эпохи к эпохе, из графиков на рис. 4 видно, что снижение потерь и рост метрик в конечном итоге стабилизировались, а, значит, модель качественно обучилась.

Однако, при тестировании на 173 изображениях, не участвовавших в этапах обучения и валидации, уверенность модели значительно снизилась и варьировалась в интервале от 42% до 60% (примеры представлены на рис. 5 и рис. 6). На трех изображениях (~1.7% от общего числа) прогар не был

определён совсем, а на 23 изображениях (~13.3% от общего числа) – определён ложно.

В условиях реального производственного процесса такой точности недостаточно – понадобится валидация оператора.



Рис. 5. – Определение прогара трубы  
(вариант 1)



Рис. 6 – Определение прогара трубы  
(вариант 2)

### Заключение

На основе проведённого эксперимента для решения задачи детекции прогаров сталеразливочной трубы на установке непрерывной разливки стали можно сделать выводы о том, что, во-первых, требуется дообучение сформированной модели.

Во-вторых, необходимо дополнить обучающую и валидационную выборки большим количеством синтезированных изображений разного масштаба, чтобы модель имела более полное представление о возможных формах и размерах прогаров. Конструкция и геометрическая форма защитной трубы может существенно изменяться в зависимости от условий разливки и требований заказчика.

В-третьих, следует использовать до 30 – 40 эпох обучения с целью дальнейшего снижения классификационных потерь и ошибки локализации области прогара.

## Литература

1. Нисковских В.М., Карлинский С.Е., Беренов А.Д. Машины непрерывного литья слябовых заготовок. – М.: Metallurgy, 1991. 271 с.
2. Кривоносов В.А., Митин А.С. Наблюдаемость и управляемость системы стабилизации уровней расплавленного металла на МНЛЗ // Инженерный вестник Дона. 2013. № 3. URL: [ivdon.ru/uploads/article/pdf/IVD\\_60\\_krivososov.pdf\\_1831.pdf](http://ivdon.ru/uploads/article/pdf/IVD_60_krivososov.pdf_1831.pdf) (дата обращения 06.01.2026)
3. Вдовин К.Н., Точилкин В. В., Умнов В. И., Точилкин В. В. Конструирование систем защиты стали от вторичного окисления при разливке на МНЛЗ // Современные материалы, техника и технологии. 2016. Т. 5. Вып. 8. С. 46-50.
4. ММК внедрил компьютерное зрение для безопасности производства // Новости интернета вещей. URL: [iot.ru/promyshlennost/mmk-vnedrilkompyuternoe-zrenie-dlya-bezopasnosti-proizvodstva](http://iot.ru/promyshlennost/mmk-vnedrilkompyuternoe-zrenie-dlya-bezopasnosti-proizvodstva) (дата обращения 04.11.2025)
5. Сергеев М.Б., Знаменская Д.Д. Преимущества применения систем компьютерного зрения в металлургическом производстве // Обработка, передача и защита информации в компьютерных системах: Пятая Междунар. науч. конф. (СПб., 7–18 апреля 2025): сб. докл. – СПб.: ГУАП, 2025. С. 225 – 228.
6. Обучение моделей с использованием Ultralytics YOLO. URL: [docs.ultralytics.com/ru/modes/train/#resuming-interrupted-trainings](https://docs.ultralytics.com/ru/modes/train/#resuming-interrupted-trainings) (дата обращения 03.12.2025).
7. Shorten C., Khoshgoftaar T.M. A survey on Image Data Augmentation for Deep Learning // Journal of Big Data. 2019. Vol. 6, №1. P. 1–48.

8. Buslaev A., Iglovikov V., Khvedchenya E., Parinov A. Albumentations: Fast and Flexible Image Augmentations // Information. 2020. Vol. 11. Iss. 2. P. 125 - 143.
9. Исаченков А.С., Дмитриенко Д.Б., Фролов Н.В. Подготовка датасета и аугментация данных для решения задачи многоклассовой классификации изображений // Известия Тульского государственного университета. Технические науки. 2023. № 9. С. 241-244.
10. Хафизов А.В., Григорьев М.В. Генерирование синтетических пористых изображений для аугментации данных с целью тренировки алгоритмов машинного обучения // Сенсорные системы. 2021. Т. 35, № 4. С. 340-347.
11. Пучков Е.В. Сравнительный анализ алгоритмов обучения искусственной нейронной сети // Инженерный вестник Дона. 2013. № 4. URL: [ivdon.ru/uploads/article/pdf/R\\_115\\_Puchkov\\_n.pdf\\_2135.pdf](http://ivdon.ru/uploads/article/pdf/R_115_Puchkov_n.pdf_2135.pdf) (дата обращения 06.01.2026)

### References

1. Niskovskikh V.M., Karlinskij S.E., Berenov A.D. Mashiny nepreryvnogo lit'ya slyabovykh zagotovok [Continuous casting machines for slab workpieces]. Moskva: Metallurgiya, 1991. 271 p.
2. Krivonosov V.A., Mitin A.S. Inzhenernyj vestnik Dona. 2013. № 3. URL: [ivdon.ru/uploads/article/pdf/IVD\\_60\\_krivonosov.pdf\\_1831.pdf](http://ivdon.ru/uploads/article/pdf/IVD_60_krivonosov.pdf_1831.pdf) (accessed 06.01.2026)
3. Vdovin K.N., Tochilkin V. V., Umnov V. I., Tochilkin V. V. Sovremennye materialy, tekhnika i tekhnologii. 2016. Vol. 5. № 8. pp. 46-50.
4. MMK vnedril komp'yuternoe zrenie dlya bezopasnosti proizvodstva [MMK has implemented computer vision for production safety]. Novosti interneta veshchej. URL: [iot.ru/promyshlennost/mmk-vnedrilkompyuternoe-zrenie-dlya-bezopasnosti-proizvodstva](http://iot.ru/promyshlennost/mmk-vnedrilkompyuternoe-zrenie-dlya-bezopasnosti-proizvodstva) (accessed 04.11.2025).

5. Sergeev M.B., Znamenskaya D.D. Obrabotka, peredacha i zashchita informacii v komp'yuternykh sistemakh: Pyataya Mezhdunar. nauch. konf. (SPb., 7–18 aprelya 2025): sb. dokl. SPb.: GUAP, 2025. pp. 225 – 228.
6. Obuchenie modelej s ispol'zovaniem Ultralytics YOLO [Model training using Ultralytics YOLO]. URL: docs.ultralytics.com/ru/modes/train/#resuming-interrupted-trainings (accessed 03.12.2025).
7. Shorten C., Khoshgoftaar T.M. Journal of Big Data. 2019. Vol. 6, №1. pp. 1–48.
8. Buslaev A., Iglovikov V., Khvedchenya E., Parinov A. Information. 2020. Vol. 11. Iss. 2. pp. 125 - 143.
9. Isachenkov A.S., Dmitrienko D.B., Frolov N.V. Izvestiya Tul'skogo gosudarstvennogo universiteta. Tekhnicheskie nauki. 2023. № 9. pp. 241-244.
10. Khafizov A.V., Grigor'ev M.V. Sensornye sistemy. 2021. T. 35, № 4. pp. 340-347.
11. Puchkov E.V. Inzhenernyj vestnik Dona. 2013. № 4. URL: ivdon.ru/uploads/article/pdf/R\_115\_Puchkov\_n.pdf\_2135.pdf (accessed 06.01.2026)

**Авторы согласны на обработку и хранение персональных данных.**

**Дата поступления: 13.12.2025**

**Дата публикации: 24.01.2026**