

Оценка эффективности машинного обучения при классификации трещин на изображениях литейных изделий*

Кузовов С.С.

Московский Политехнический Университет
г. Москва, Российская Федерация
kss41188@inbox.ru

Смыков А.Ф.

Московский Авиационный Институт
(национальный исследовательский университет)
г. Москва, Российская Федерация
tlp_dsaf@mail.ru

Аннотация. В этой статье представлен анализ эффективности применения методов машинного обучения для классификации трещин на изображениях литейных изделий. Исследование сосредоточено на оценке способности модели адекватно определить уровень угрозы, что имеет решающее значение для обеспечения промышленной безопасности и повышения экономической эффективности производства. Производительность модели была оценена на основе таких метрик, как точность, полнота и F1-мера, а также через анализ ROC-кривых и площади под кривыми (AUC), что позволило подробно изучить её работу в различных условиях. Результаты исследования указывают на высокий потенциал модели для интеграции в производственные линии, хотя для минимизации ложных срабатываний потребуется её дополнительная настройка, включая применение нечеткой логики и интеграцию методов неразрушающего контроля. Предложенные методы и достигнутые результаты могут быть применены при создании систем автоматического контроля качества в машиностроении и других отраслях промышленности для своевременного выявления и предотвращения рисков, связанных с качеством отливок.

Ключевые слова: автоматизация, искусственный интеллект, сверточные нейронные сети (CNN), нечеткая логика, трещины, автоматизация, дефекты.

ВВЕДЕНИЕ

В современной промышленности наблюдается стойкая тенденция к внедрению научных разработок с элементами искусственного интеллекта (ИИ), что существенно облегчает решение сложных трудно формализуемых производственных задач [1]. Эти разработки позволяют автоматизировать процесс принятия решений на многих производственных участках. Особый интерес в этом контексте представляет применение ИИ в литейном производстве фасонных отливок для решения задач классификации дефектов. Помимо надежности традиционных неразрушающих методов контроля качества, которые ценятся за проверенную эффективность и понятность процессов для специалистов [2, 3], важно подчеркнуть их субъективный характер. Экспертные оценки, хотя и базируются на глубоких знаниях специалистов, в случаях ограниченного опыта могут привести к ошибкам в определении природы дефектов и непра-

вильным решениям по их устранению. Современный анализ контроля качества отливок требует новых подходов, которые бы сочетали проверенную надежность традиционных методов с инновационными возможностями ИИ. Сверточные нейронные сети (CNN) стали ключевым инструментом в современной области компьютерного зрения и глубокого обучения благодаря своей способности извлекать и анализировать сложные повторяющиеся элементы в изображениях – паттерны [4]. Обучение на обширных наборах данных позволяет CNN адаптироваться к разнообразным вариациям внешнего вида, размеров или формы дефекта, даже при низком контрасте между трещинами и окружающей средой и на фоне сложных текстур [5]. Архитектура CNN позволяет масштабировать и адаптировать сеть к различным условиям анализа изображений, включая работу с изображениями разного качества и освещенности, что делает её незаменимым инструментом для обнаружения таких видов дефекта, как например трещины в разнообразных производственных условиях [6].

ОСНОВНАЯ ЧАСТЬ

В данной работе параметры обучения модели были тщательно выбраны для оптимизации процесса и качества обучения. Размер батча установлен в 16 единиц для баланса между скоростью обучения и объемом используемой памяти, причем меньший размер мог бы увеличить шумность градиентов, а больший — улучшить стабильность за счет большего расхода памяти [7]. Число классов равно 3 (не опасные, потенциально опасные и опасные дефекты), что соответствует целям классификации дефектов в литых изделиях. Скорость обучения задана на уровне 0,001 для достижения компромисса между скоростью сходимости и риском пропуска минимумов функции потерь, а длительность обучения ограничена 10 эпохами, чтобы избежать переобучения, учитывая сложность модели и объем данных [8].

Для успешного обучения сверточных нейронных сетей критична корректная подготовка входных данных, что в нашем исследовании достигается через ряд трансформаций. Во-первых, все изображения приводятся к размеру 224x224 пикселей через процесс Resize, что необходимо для соответствия требованиям предобученной модели ResNet-50 [5]. Во-вторых, применяется преобразование

* Настоящее исследование проведено при финансовой поддержке Московского Политехнического Университета в рамках гранта имени В.Е. Фортова. Статья публикуется по рекомендации программного комитета Всероссийской научно-практической конференции Индустрия 4.0", <https://smartindustrycon.ru>

ToTensor (), которое конвертирует изображения из форматов PIL или NumPy в тензоры PyTorch, сохраняя информацию о всех трех цветовых каналах (RGB) [9]. Наконец, производится нормализация с параметрами [0,485; 0,456; 0,406] для средних и [0,229; 0,224; 0,225] для стандартных отклонений, что совпадает с параметрами, использованными при тренировке ResNet-50 на ImageNet [10], повышая тем самым обобщающую способность модели и снижая её чувствительность к вариациям освещения и цветовой гаммы. Эти трансформации обеспечивают однородную обработку каждого изображения перед его подачей в нейросеть, что является ключевым для достижения стабильных результатов обучения и валидации.

При работе с компьютерным зрением и машинным обучением, одним из ключевых аспектов является тщательная подготовка и организация данных. Для демонстрации этого принципа рассмотрим процесс создания специализированного датасета для обучения нейронной сети на задаче классификации трещин на изображениях отливок. В качестве основы используется класс Crack Dataset With Augmentation, который является наследником базового класса Dataset в фреймворке PyTorch [11].

Инициализация данного класса датасета происходит с двумя основными параметрами: `root_dir` и `transform`. Параметр `transform` включает в себя настройки предобработки и аугментации изображений, которые применяются к каждому изображению перед его использованием в модели. Это могут быть операции масштабирования, нормализации, поворота и другие типы преобразований, которые не только улучшают качество, но и увеличивают разнообразие данных [12].

Процесс загрузки и трансформации изображений реализован в методе `__getitem__`, который вызывается при каждом обращении к элементу датасета во время итерации. В случае использования библиотеки `albumations`, это может включать в себя аугментации, такие как случайные повороты, изменение яркости и контрастности, что значительно увеличивает обобщающую способность модели и позволяет ей лучше работать с новыми, ранее не виденными данными [13].

При работе с глубоким обучением одним из наиболее эффективных методов является использование предобученных моделей, которые, будучи обученными на обширных и разнообразных наборах данных, могут значительно ускорить процесс обучения и улучшить качество конечной модели за счет трансфера знаний [14]. Примером такой модели служит ResNet-50, архитектура с 50 слоями, разработанная в рамках семейства Residual Networks [5]. Эта сеть хорошо зарекомендовала себя в компьютерном зрении благодаря успешному применению в различных задачах. Загрузка предобученной модели ResNet-50 осуществляется с помощью функции `models.resnet_50 (pretrained=True)`, где параметр `pretrained=True` означает использование модели с весами, полученными в результате обучения на датасете ImageNet, что предоставляет значительные преимущества благодаря глубокому пониманию визуальных признаков [10].

Для адаптации модели под специфику задачи классификации трещин на изображениях отливок, последний полносвязный слой, первоначально настроенный на 1000 классов для ImageNet, модифицируется для вывода трех классов:

неопасные, потенциально опасные и опасные трещины. Также часто применяется стратегия заморозки весов всех слоев, кроме последнего, чтобы сохранить извлеченные признаки и избежать переобучения, особенно когда доступное количество специфических данных ограничено. Это позволяет в процессе дальнейшего обучения модифицировать только новый выходной слой и тонко настроить изменяемые слои, что ускоряет процесс обучения и повышает его эффективность [14].

Включение предобученной модели в тренировочный процесс обеспечивает не только использование общих визуальных признаков, изученных на данных ImageNet, но и специализацию модели на распознавании конкретных характеристик трещин, что важно для задач, требующих высокой точности в классификации сложных образов. Таким образом, применение предобученных моделей значительно повышает потенциал нейронной сети в специализированных приложениях компьютерного зрения.

После адаптации архитектуры модели к конкретной задаче, следующим шагом является настройка параметров оптимизации, которые играют ключевую роль в эффективности и скорости обучения нейронной сети. Оптимизатор Adam часто используется для обновления весов сети в процессе обучения и считается одним из наиболее эффективных методов оптимизации в глубоком обучении [8]. Он сочетает преимущества других адаптивных методов обучения, обеспечивая высокую скорость сходимости и меньшую чувствительность к выбору начального значения скорости обучения. Установленная скорость обучения на уровне 0,001 подходит для начальных этапов тонкой настройки, так как она не слишком велика, чтобы вызвать расхождение процесса обучения, и не слишком мала, чтобы замедлить процесс оптимизации. Кросс-энтропийная потеря является наиболее часто используемой функцией потерь в задачах классификации. Она измеряет разницу между предсказанными вероятностями и фактическими метками классов, обеспечивая быструю обратную связь модели о качестве её предсказаний. Эффективность кросс-энтропии особенно высока в случаях, когда необходимо обучить модель различать несколько классов объектов, что актуально для нашей задачи классификации трещин [15]. Параметры оптимизации и функция потерь интегрируются в обучающий цикл, где каждая итерация обучения включает в себя вычисление потерь на основе выходных данных модели и их сравнение с истинными метками, последующий расчёт градиентов и обновление весов сети. Правильная настройка этих параметров является критически важной для достижения оптимальной производительности модели, так как неправильный выбор может привести к переобучению, недообучению или замедлению процесса обучения.

После завершения обучения модели, следующий критически важный этап – валидация и оценка её производительности. Этот этап необходим для определения способности модели обобщать знания на новых, ранее не виденных данных. Подготовка валидационного набора данных включает подготовку изображений с использованием базовых трансформаций, таких как изменение размера и нормализация, без применения усиленных аугментаций, чтобы точно оценить производительность модели. Загрузчик данных используется для эффективной загрузки валидационного

набора в модель во время оценки, обеспечивая батчевую обработку изображений для быстрого и эффективного тестирования. Процесс валидации начинается с перевода модели в режим оценки, что отключает слои, специфичные для обучения, такие как Dropout, чтобы обеспечить стабильность выходных данных. Во время валидации для каждого батча измеряются потери и точность, что позволяет оценить, насколько предсказания модели соответствуют истинным меткам, и какой процент изображений был классифицирован правильно. По завершении валидации вычисляются средние значения потерь и общая точность по всему валидационному набору, что дает возможность оценить общую эффективность модели. Анализ ошибок помогает определить случаи, где модель допустила ошибки, что указывает на необходимость дополнительной настройки или улучшения. Модель, показавшая наилучшую точность на валидационном наборе, сохраняется для дальнейшего использования в практических приложениях или для дополнительных исследований. Это гарантирует, что в работу или в производство будет внедрена модель, наилучшим образом адаптированная к решению поставленных задач. После валидации модели следует этап её улучшения и настройки, направленный на максимальное повышение точности и обобщающей способности. Регуляризация и настройка гиперпараметров охватывает применение методов регуляризации, таких как Dropout или L2-регуляризация, которые могут помочь снизить переобучение и улучшить способность модели к обобщению на новых данных. Оптимизация гиперпараметров, включая изменение значений скорости обучения, размера батча и архитектурных изменений, также необходима для нахождения наилучших настроек для конкретной задачи. Использование дополнительных данных через аугментацию данных увеличивает разнообразие тренировочного набора, помогая модели лучше обобщать и устойчиво работать в различных условиях. Включение новых изображений или дополнительных классов способствует улучшению точности и робустности модели.

Эти шаги позволяют максимально улучшить модель, обеспечивая её эффективную работу в реальных условиях.

После завершения этапа настройки и улучшения модели для классификации трещин на изображениях отливок, необходимо провести тщательную оценку её производительности с помощью релевантных метрик.

Выбор метрик для оценки играет ключевую роль в адекватной оценке производительности модели. В данной работе основным фокусом были метрики точности (Accuracy), AUC-ROC, точности по классам (Precision), полноты (Recall) и F1-меры [16]. Эти показатели были выбраны для оценки способности модели корректно классифицировать каждый тип трещин, а также её способность балансировать между ложноположительными и ложноотрицательными результатами.

Точность (Precision) важной метрикой в контексте классификации трещин, особенно когда важно минимизировать количество ложноположительных результатов:

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

где TP (True Positives) – это количество трещин, которые были правильно идентифицированы как принадлежащие к категории (например, не опасные); FP (False Positives) – количество трещин, ошибочно классифицированных как принадлежащие к этой же категории (не опасных).

В контексте анализа трещин точность (Precision) помогает оценить, насколько надежно система выявляет действительно опасные трещины. Высокая точность (Precision) означает, что большинство трещин, помеченных как опасные, действительно требуют внимания. Это особенно важно в промышленных условиях, где ложные срабатывания могут приводить к неоправданным затратам на дополнительные проверки и ремонт.

Полнота (Recall), или чувствительность, это метрика, которая показывает, какую долю из всех реальных положительных случаев система смогла правильно классифицировать. Это особенно важно для обеспечения безопасности, поскольку пропуск опасной трещины может иметь серьезные последствия.

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

где FN (False Negatives) — количество трещин, которые действительно принадлежат к данной категории, но были классифицированы моделью как принадлежащие к другой категории. Для исследования трещин полнота помогает определить, упускает ли система потенциально опасные дефекты. Высокая полнота в этом контексте означает, что система эффективно идентифицирует большинство или все опасные трещины, что критично для поддержания безопасности и надежности конструкций.

F1-мера является одним из наиболее важных показателей в задачах классификации, где одинаково важны и точность, и отзыв. В контексте нашего исследования, где классы могут быть несбалансированные (например, опасные трещины могут встречаться реже, чем не опасные), F1-мера предоставляет более полное представление о производительности модели по сравнению с отдельной оценкой точности или отзыва:

$$F_1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

Точность (Accuracy) является фундаментальной метрикой для оценки производительности модели классификации. Она определяется как доля правильно классифицированных примеров от общего числа примеров:

$$Accuracy = \frac{True Positives (TP) + True Negatives (TN)}{Total Number of Samples} \quad (4)$$

Ложноположительные ошибки (False Positives, FP): это случаи, когда модель ошибочно классифицирует дефект в изделии, как положительный (например, классифицирует не опасную трещину как опасную). В контексте промышленной безопасности, такая ошибка может привести к ненужным расходам.

Ложноотрицательные ошибки (False Negatives, FN): это случаи, когда модель отрицает реально опасный дефект, классифицируя его как безопасный. Такие ошибки критичны, так как могут привести к игнорированию действительно опасной трещины, что может стать причиной серьезных аварий или даже катастроф.

В контексте анализа изображений отливок с целью определения степени опасности трещин, точность помогает оценить, насколько эффективно модель справляется с распознаванием трещин различных категорий: не опасных, потенциально опасных и опасных. Особенно важно высокое значение точности (Accuracy) в условиях, где ошибочная классификация может привести к серьезным последствиям, например, пропуск критической трещины может угрожать безопасности конструкции.

Точность (Accuracy) особенно полезна для получения общего представления о надежности модели в рамках исследования, однако она не различает типы ошибок (ложноположительные и ложноотрицательные), что может быть критично в случаях, когда стоимость ошибки в одном классе значительно выше, чем в другом. Точность (Accuracy) не дает информации о том, как часто модель совершает каждый из этих типов ошибок, что делает ее менее полезной в случаях, когда стоимость одного типа ошибок значительно выше другого [4, 16-20].

В рамках оценки производительности модели для классификации трещин на изображениях отливок была построена матрица ошибок (рис. 1). Этот инструмент статистического анализа позволяет визуализировать эффективность модели путём отображения числа правильных и неправильных предсказаний, разделённых по категориям предсказанных и истинных классов. Матрица ошибок обеспечивает ценные сведения о том, как модель справляется с каждым из классов, выявляя, например, склонность модели к определённому типу ошибок, таким как частое возникновение ложноположительных или ложноотрицательных результатов. Эти данные помогают не только оценить общую точность модели, но и детализировать её анализ, что критически важно для последующей настройки и улучшения классификации.



Рис. 1. Матрица ошибок (Confusion Matrix) истинных и ложных классификаций для модели CNN с целью предсказания категории опасности дефекта

Диагональ показывает количество правильных предсказаний для каждого класса (TP). Недиagonальные элементы в строках показывают, как часто каждый класс был неправильно предсказан как другой класс (FP). Недиagonальные

элементы в колонках показывают, сколько раз истинный класс был ошибочно классифицирован как другой (FN). TP (True Positive) - количество случаев, когда класс был верно идентифицирован. FP (False Positive) - количество случаев, когда другие классы были ошибочно идентифицированы как текущий класс. FN (False Negative) - количество случаев, когда текущий класс был ошибочно идентифицирован как другой класс. TN (True Negative) - количество случаев, когда ни один из других классов не был ошибочно идентифицирован как текущий класс.

Для иллюстрации оценки производительности модели на практическом примере рассмотрим датасет из 100 изображений трещин, которые классифицированы на три категории: не опасные, потенциально опасные и опасные. Модель обучена для предсказания категории каждой трещины. Исследование оценивало способность модели классифицировать трещины на не опасные, потенциально опасные и опасные. Наши результаты показали, что модель эффективно идентифицирует опасные трещины, демонстрируя высокий показатель истинно положительных результатов (TP): 30 трещин были правильно классифицированы как не опасные. Тем не менее, модель также проявила тенденцию к ошибкам, с 10 случаями ложно отрицательных результатов (FN) — пять трещин были ошибочно определены как потенциально опасные и пять как опасные, что указывает на переоценку риска.

В категории потенциально опасных трещин модель показала 20 истинно положительных результатов (TP), подтверждая свою способность адекватно оценивать умеренные угрозы. Однако, наблюдалось 7 случаев ложно положительных результатов (FP), когда не опасные трещины классифицировались как потенциально опасные, и 3 случая ложно отрицательных результатов (FN), когда потенциально опасные трещины ошибочно идентифицировались как опасные.

Опасные трещины были точно идентифицированы в 25 случаях, что является примером высокой чувствительности модели к наиболее серьёзным угрозам, отражая хорошие показатели истинно положительных результатов (TP). Вместе с тем, были зафиксированы два случая ложно отрицательных результатов (FN), когда опасные трещины были недооценены как потенциально опасные, что могло бы привести к нежелательным последствиям. AUC-ROC (Area Under the Receiver Operating Characteristics) — это метрика, которая оценивает, насколько хорошо модель может различать два класса. ROC-кривая строится как график, отражающий соотношение между долей истинно положительных классификаций (True Positive Rate, TPR) и долей ложно положительных классификаций (False Positive Rate, FPR) при различных пороговых значениях. AUC, или площадь под ROC-кривой, измеряет общую способность модели отличать классы независимо от выбранного порога. Значение AUC лежит в интервале от 0 до 1, где 1 указывает на идеальную способность модели различать классы, а значение 0,5 говорит о том, что результаты модели не лучше случайных предсказаний. В общем случае, AUC-ROC считается более устойчивой метрикой по сравнению с точностью, особенно в условиях несбалансированных классов, поскольку она дает более полное представление о том, как модель справляется с классификацией на всех уровнях пороговых значений.

На приведенном графике (рис. 2) изображены ROC-кривые для трех категорий трещин: не опасные, потенциально опасные и опасные. AUC (Area Under the Curve) для каждой кривой показывает, насколько хорошо модель может различать каждую категорию от остальных.

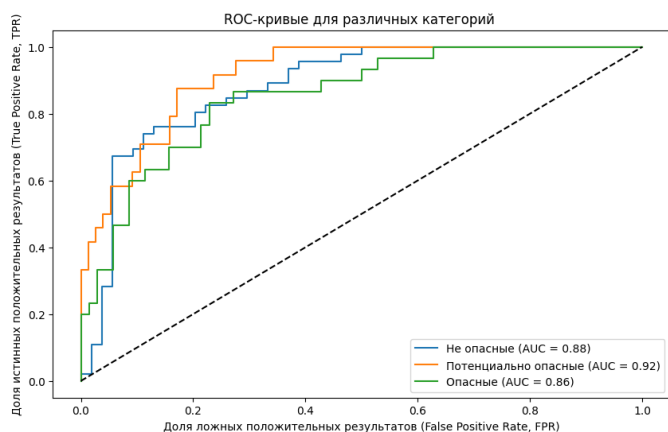


Рис. 2. Графики ROC-кривых по категориям трещин

Использование метрик вместе может дать более полное представление о производительности модели в задачах классификации (табл. 1).

Таблица 1

Сводная таблица метрик оценки производительности модели CNN

Категория	Точность (Precision), %	Полнота (Recall), %	F1-мера, %	AUC-ROC
Не опасные	75	75	75	0,88
Потенциально опасные	74	67	70	0,92
Опасные	76	83	80	0,86

В контексте идентификации трещин на отливках, где классы могут быть определены как не опасные, потенциально опасные и опасные, AUC-ROC предоставляет ценные взгляды на способность модели отличать каждый класс от других. Например, высокое значение AUC при классификации опасных трещин указывает на то, что модель эффективно распознает критические дефекты, что важно для предотвращения возможных сбоев в производственном процессе. Ошибки в классификации не опасных и потенциально опасных трещин могут привести к ненужным дополнительным проверкам, увеличивая операционные расходы.

Эти результаты свидетельствуют о том, что модель в целом справляется с задачей классификации трещин. Для категории не опасные модель показала сбалансированные результаты с точностью, полнотой и F1-мерой по 75%, и AUC-ROC 0,88, что указывает на хорошую способность различать этот тип дефектов. Категория потенциально опасные продемонстрировала ниже ожидаемого полноту в 67% и F1-меру в 70%, несмотря на высокий AUC-ROC в 0,92, что может потребовать дополнительных улучшений. Опасные дефекты классифицировались с точностью 76%,

полнотой 83% и F1-мерой 80%, при AUC-ROC 0,86, подтверждая надёжность модели в обнаружении наиболее критичных дефектов.

ЗАКЛЮЧЕНИЕ (Выводы)

Анализ производительности модели по классификации трещин на изображениях отливок показал, что, хотя модель в целом работает эффективно, есть необходимость в дальнейших улучшениях, чтобы повысить точность и полноту классификации. В этом контексте, применение дополнительных методологических инструментов, таких как нечеткая логика, может значительно способствовать оптимизации процесса распознавания и классификации. Нечеткая логика, благодаря своей способности управлять неопределенностями и размытыми границами между категориями, может улучшить интерпретацию случаев, которые традиционные алгоритмы могут классифицировать некорректно. Это особенно важно для случаев на стыке классификационных категорий, где текущая модель может допускать ошибки.

Кроме того, интеграция методов неразрушающего контроля (НК), таких как ультразвуковое тестирование, визуальный анализ и радиографические методы, предлагает дополнительные возможности для улучшения классификации [21, 22]. Эти методы могут предоставить более глубокое понимание внутреннего состояния материалов, выявляя дефекты, которые могут не быть видны на стандартных изображениях. Например, радиография может обнаружить внутренние трещины или включения в материале, которые визуальный анализ не выявит.

Применение ультразвукового тестирования позволяет анализировать более глубокие слои материала, обеспечивая детектирование дефектов, скрытых от визуального осмотра. Эти методы не только улучшат точность обнаружения трещин, но и помогут минимизировать количество ложноположительных и ложноотрицательных результатов. Таким образом, они способствуют повышению надежности и общей эффективности системы.

Внедрение этих дополнительных методов требует глубокой интеграции с существующими системами обработки данных, что может включать разработку нового программного обеспечения или адаптацию текущих алгоритмов. Это также предполагает дополнительные затраты на оборудование и обучение персонала. Тем не менее, учитывая потенциальное улучшение качества контроля и снижение рисков, связанных с пропуском критических дефектов, такие инвестиции могут быть оправданы.

Подводя итог, можно сказать, что усиление модели классификации трещин путем включения нечеткой логики и методов неразрушающего контроля может значительно улучшить точность и надежность системы, что, в свою очередь, повысит эффективность процессов контроля качества в производстве литых изделий.

ЛИТЕРАТУРА

1. Goodfellow I. Deep Learning / I., Goodfellow Y. Bengio, A. Courville. – MIT Press, 2016. – 775 p.
2. Bishop C.M. Pattern Recognition and Machine Learning. – Springer, 2006. – 738 p.

3. He K. Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 770-778.
4. Powers D.M.W. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation // Journal of Machine Learning Technologies. – 2011. – vol. 2. – P. 37-63.
5. Fawcett T. An introduction to ROC analysis // Pattern Recognition Letters. – 2006. – vol. 27, no. 8. – P. 861-874.
6. ASM International. Nondestructive Evaluation and Quality Control // ASM Handbook, vol. 17, 1999. – 785 p.
7. Hellier C. Handbook of Nondestructive Evaluation. – McGraw-Hill, 2001. – 608 p.
8. Pan S.J. A survey on transfer learning / S.J. Pan, Q. Yang // IEEE Transactions on Knowledge and Data Engineering. – 2010. – vol. 22, no. 10. – P. 1345-1359.
9. Bengio Y. Deep learning of representations for unsupervised and transfer learning // Proceedings of the International Conference on Machine Learning, 2012.
10. Krizhevsky A. ImageNet classification with deep convolutional neural networks / A. Krizhevsky, I. Sutskever, G.E. Hinton // Advances in Neural Information Processing Systems (NIPS). – 2012. – P. 1097-1105.
11. Paszke A. PyTorch: An imperative style, high-performance deep learning library / A. Paszke, et al. // Advances in Neural Information Processing Systems (NIPS). – 2019. – P. 8024-8035.
12. Alumentations Team. Albumentations: Fast and flexible image augmentations // Information Systems, 2020.
13. Simonyan K. Very deep convolutional networks for large-scale image recognition / K. Simonyan, A. Zisserman // arXiv preprint arXiv:1409.1556, 2015.
14. Huang G. Densely connected convolutional networks / G. Huang, et al. // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017. – P. 4700-4708.
15. Zhang H. Mixup: Beyond empirical risk minimization / H. Zhang, et al. // arXiv preprint arXiv:1710.09412, 2018.
16. Chawla N.V. SMOTE: Synthetic minority over-sampling technique / N.V. Chawla, et al. // Journal of Artificial Intelligence Research. 2002. – vol. 16. – P. 321-357.
17. Japkowicz N. Evaluating Learning Algorithms: A Classification Perspective / N. Japkowicz, M. Shah. – Cambridge University Press, 2011.
18. Tan P.N. Introduction to Data Mining / P.N. Tan, M. Steinbach, V. Kumar. – Pearson, 2019. – 839 p.
19. Gama J. Knowledge Discovery from Data Streams. – Chapman & Hall, 2010. – 255 p.
20. Sutton R.S. Reinforcement Learning: An Introduction / R.S. Sutton, A.G. Barto. – MIT Press, 2018. – 552 p.
21. Krautkramer J. Ultrasonic Testing of Materials / J. Krautkramer, H. Krautkramer. – Berlin: Springer-Verlag, 1990. – 677 p.
22. Kuzovov S.S. The Application of Convolutional Neural Networks and Fuzzy Logic in Control and Automation Systems for Recognizing and Assessing the Danger Level of Hot Cracks in the Production of Cast Products / S.S. Kuzovov, A.F. Smykov // International Russian Smart Industry Conference (SmartIndustryCon), 2024, Sochi, Russian Federation, 2024. – P. 984-988. DOI: 10.1109/SmartIndustryCon61328.2024.10515894.

DOI: 10.24892/RIJIE/20260102

Evaluation of Machine Learning Effectiveness in Classifying Cracks on Foundry Product Images

Kuzovov S.S.

Moscow Polytechnic University
Moscow, Russian Federation
kss41188@inbox.ru

Smykov A.F.

Moscow Aviation Institute
(National Research University)
Moscow, Russian Federation
tlp_dsaf@mail.ru

Abstract. This article presents an analysis of the effectiveness of machine learning methods for classifying cracks on foundry product images. The study focuses on evaluating the model's ability to adequately determine the level of risk, which is critical for ensuring industrial safety and improving production efficiency. The model's performance was assessed using metrics such as accuracy, recall, and F1-score, as well as through the analysis of ROC curves and the area under the curves (AUC), providing a detailed examination of its performance under various conditions. The results of the study indicate a high potential for the

model's integration into production lines; however, additional adjustments will be required to minimize false positives, including the application of fuzzy logic and the integration of non-destructive testing methods. The proposed methods and achieved results can be applied to the development of automated quality control systems in mechanical engineering and other industries to timely identify and prevent risks associated with casting quality.

Keywords: Automation, Artificial Intelligence, Convolutional Neural Networks (CNN), Fuzzy Logic, Cracks, Automation, Defects.