

Муртин К.В.

*Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23*

Система обнаружения дефектов листового металлопроката на изображениях с использованием глубокой нейронной сверточной сети

В настоящее время наблюдается бурное развитие металлургической промышленности в России, что обуславливает значительный вклад отрасли в ВВП страны (около 4%). На металлургию приходится примерно 12% промышленного производства и 10% экспорта.

Однако, несмотря на очевидные успехи, в отрасли имеется проблема своевременного обнаружения дефектов металлопроката – одна из ключевых проблем российского промышленного комплекса. Применение инновационных подходов и технологий позволит значительно снизить затраты, вызванные несвоевременным обнаружением брака в процессе производства.

В настоящее время известно большое количество видов дефектов листового металлопроката [1-3], для большей части которых разработаны методы их своевременного обнаружения. Большинство поверхностных дефектов удается обнаруживать и классифицировать оптическим методом. Однако в условиях реального производства зачастую это оказывается затруднительно из-за факторов, ухудшающих качество цифровых изображений поверхности металлопроката.

В ходе анализа установлено, что искусственные нейронные сети типовой структуры, которые получили огромное распространение, не позволяют уменьшить влияние факторов реального производства на цифровые дефектоскопические изображения, а качество обнаружения дефектов будет являться достаточно высоким. Но несмотря на это, данный подход имеет потенциал, который возможно раскрыть за счет создания нейронной сети специальной структуры и разработки специализированных алгоритмов, основанных на созданной сети.

Для решения поставленных задач проектируется глубокая сверточная нейронная сеть с чередованием слоев свертки и субдискретизации. Такая архитектура позволяет строить карты признаков из карт признаков. После каждого слоя свертки применяется функция активации GELU, а после субдискретизации – SELU [4].

Классическая структура сверточного слоя не подходит для процесса фильтрации дефектоскопического изображения, поэтому слой свертки модифицируется. А именно, применяемый фильтр должен быть 2×2 с весом 0.5 для каждого соединения карты признаков. Таким образом, для изображения размером 1600×256 , получается 28 слоев свертки. Затем применяется метод удаления фона от дефекта и функция активации GELU [5]. Для уменьшения ошибок в процессе обучения после слоя свертки добавляется модифицированная функция ошибки стохастического градиентного спуска по моментам Adam [6].

Разработанная математическая модель, применяемая в глубокой сверточной нейронной сети для определения дефекта листового металлопроката, показала хорошие результаты при апробации тестовых дефектоскопических изображений, представленных компанией «ООО Северсталь Диджтал» на открытом конкурсе по техническому зрению Kaggle.

В ходе экспериментальных исследований были успешно выделены дефекты листового металлопроката на 89% изображений тестового набора (рисунок 1). Дальнейший анализ обнаруженных объектов показал, что геометрические характеристики дефектов отличаются от значений, полученных квалифицированным оператором-дефектоскопистом не более чем на 7%. Это доказывает возможность использования разработанной сети в практических задачах дефектоскопии.




Рис. 1. Результат выделения дефекта

Литература

1. Бархатов, В.А. Распознавание дефектов с помощью искусственной нейронной сети специального типа. // Дефектоскопия – 2006. – № 2. – с. 28–39.
2. Бархатов, В.А. Обнаружение сигналов и их классификация с помощью распознавания образов. // Дефектоскопия – 2006. – № 4 – с. 14–27.
3. Бархатов, В.А. Распознавание образов класса, заданного параметрически / В.А. Васильев // Дефектоскопия – 2009. – № 2 – с. 3–17.
4. Silver, D., Huang, A., Maddison, C., et al. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587):484–489.
5. Wainberg, M., Alipanahi, B., and Frey, B. J. (2016). Are random forests truly the best classifiers? *Journal of Machine Learning Research*, 17(110):1–5.
6. Kingma, Diederik, and Jimmy Ba. "Adam: A method for stochastic optimization." arXiv preprint arXiv:1412.6980 (2014).