

29. Сериков С.В., Устинов И.К., Коржавый А.П. Защита объекта от локального поражения и разрушения. Научные технологии. 2021. Т. 22. №4. С. 12-15.

Устинов Игорь Кириллович, канд. техн. наук, доцент, ustinov_ik@bmstu.ru, Россия, Калуга, Московский государственный технический университет им. Н.Э. Баумана (Калужский филиал),

Горбунов Александр Константинович, канд. техн. наук, профессор, Россия, Калуга, Московский государственный технический университет им. Н.Э. Баумана (Калужский филиал),

Лысенко Андрей Леонидович, канд. техн. наук, доцент, Россия, Калуга, Московский государственный технический университет им. Н.Э. Баумана (Калужский филиал),

Силаева Наталья Альбертовна, канд. техн. наук, Россия, Калуга, Московский государственный технический университет им. Н.Э. Баумана (Калифский филиал),

Сулина Ольга Владимировна, канд. техн. наук, доцент, Россия, Калуга, Московский государственный технический университет им. Н.Э. Баумана (Калужский филиал)

QUANTUM APPROACH TO MATERIAL SELECTION FOR ARMOR PROTECTION BY QUANTUM NUMBERS

I.K. Ustinov, A.K. Gorbunov, A.L. Lysenko, N.A. Silaeva, O.V. Sulina

An assessment of the quantum approach to materials for armor protection structures was carried out, and the following was revealed: The following points should be noted at the basis of the quantum approach to materials for armor protection. Theoretical and experimental data on quantum physics and energy technological processes have been accumulated, which make it possible to supplement the theory of armor protection with quantum dimensionless quantities. The tools of physics in this direction are determined by the fine structure constant and energy-technological parameters of the elements of the periodic table. Quantum quantities for substances of matter (mass), momentum and angular momentum are associated with the parameters of the wave function. New dimensionless complexes are derived from the equations of interaction of substances and represent the ratio of Planck's constant, gravitational constant, speed of light and masses for structural materials in accordance with the periodic table.

Key words: quantum numbers of dimensionless numbers of the material, armor protection, quartz sand, model, energy-technological parameters of the elements of the periodic table of D.I.

Ustinov Igor Kirillovich, candidate of technical sciences, docent, ustinov_ik@bmstu.ru, Russia Kaluga, Bauman Moscow State Technical University(Kalyfa Branch),

Gorbunov Alexander Konstantinovich, candidate of technical sciences, professor, Russia Kaluga, Bauman Moscow State Technical University (Kalyfa Branch),

Lysenko Andrey Leonidovich, candidate of technical sciences, docent, Russia Kaluga, Bauman Moscow State Technical University (Kalyfa Branch),

Silaeva Natalia Albertovna, candidate of technical sciences, Russia, Kaluga, Bauman Moscow State Technical University(Kalyfa Branch),

Sulina Olga Vladimirovna, candidate of technical sciences, docent, Russia Kaluga, Bauman Moscow State Technical University (Kalyfa Branch)

УДК 004.932.2

DOI: 10.24412/2071-6168-2024-3-200-201

ИНФОРМАЦИОННАЯ СИСТЕМА ДЛЯ ОБНАРУЖЕНИЯ И КЛАССИФИКАЦИИ ДЕФЕКТОВ МЕТАЛЛОПРОКАТНОЙ ПРОДУКЦИИ НА БАЗЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

П.С. Филиппов, А.В. Греченева, М.С. Никаноров

Статья посвящена разработке информационной системы на базе нейросети, решающей задачу анализа изображений или видео с целью обнаружения дефектов на поверхности стальных листов. Этот проект направлен на повышение эффективности контроля качества в производстве металлопроката. Проведена разработка нейросети, ее валидация. Выход кода показывает точность на тестовых данных, равную 0.931, что является высоким результатом и подтверждает эффективность модели. Разработан API и пользовательский интерфейс на базе фреймворка Flask.

Ключевые слова: веб-сервис, нейросеть, компьютерное зрение, дефектоскопия, металлопрокат, Flask.

Дефектоскопия является неотъемлемым этапом производства металлопрокатной продукции [1]. Искусственный интеллект, включая машинное обучение (ML) и компьютерное зрение (CV), играет важную роль в промышленности, помогая решать разнообразные задачи. Эти технологии находят применение во многих областях, включая производство металлопроката, где они используются для выявления дефектов, управления качеством и оптимизации производственных процессов.

Производство металлопроката включает несколько этапов, начиная с подготовки сырья и заканчивая отгрузкой готовой продукции. На каждом этапе возможно появление дефектов, таких как трещины, царапины, вмятины или коррозия. Традиционно для выявления таких дефектов используются методы визуального осмотра, однако этот процесс трудоемкий и может не всегда обеспечивать высокую точность [2-4].

Для ускорения процесса контроля качества и повышения его точности было предложено использовать данные с фото/видео устройств, размещенных около прокатных станков, с последующей обработкой с помощью алгоритмов компьютерного зрения. Эти алгоритмы способны анализировать полученные изображения на предмет наличия дефектов, выделяя и классифицируя их типы.

Применение такого подхода позволяет значительно сократить время на контроль качества металлопроката и повысить точность выявления дефектов. Это, в свою очередь, способствует уменьшению количества брака и оптимизации производственных процессов.

Целью статьи является разработка прототипа веб-сервиса, который использует нейронные сети для анализа изображений или видео с целью обнаружения дефектов на поверхности стальных листов. Этот проект направлен на повышение эффективности контроля качества в производстве металлопроката.

Материалы и методы. Предлагаемый веб-сервис построен на основе применения нейронной сети, которая, в ходе применения детекции дефектов металлопроката, выдает заключение о наличии или отсутствии производственного брака. Следовательно, этапы разработки были следующие:

- подготовка и аннотирование датасетов;
- обучение нейросети;
- разработка веб-интерфейса для сервиса.

Для обеспечения эффективного обучения нейронной сети, собранные изображения были разделены на три набора: обучающий, валидационный и тестовый [5]. Каждый набор содержал изображения всех шести классов дефектов, с количеством 276 обучающих, 12 валидационных и 12 тестовых изображений для каждого класса. Данные были подготовлены и аугментированы (рис. 1).

```
# Все изображения будут масштабированы на 1./255.
train_datagen = ImageDataGenerator(
    rescale = 1. / 255, # изменение масштаба
    rotation_range = 8, # случайный поворот изображения (от 0 до 180 градусов)
    zoom_range = 0.1, # случайное масштабирование изображения
    shear_range = 0.3, # сдвиг против часовой стрелки в градусах
    width_shift_range = 0.08, # случайное смещение изображений по горизонтали (по ширине)
    height_shift_range = 0.08, # случайно смещать изображения по вертикали (по высоте)
    vertical_flip = True, # случайный вертикальный поворот изображений
    horizontal_flip = True) # случайный горизонтальный поворот изображений

test_datagen = ImageDataGenerator(rescale = 1. / 255)
```

Рис. 1. Фрагмент кода (аугментация данных)

Эти параметры аугментации были выбраны для имитации возможных вариаций в реальных условиях эксплуатации металлопроката, что позволяет улучшить обобщающую способность модели. Далее используются генераторы данных для создания потоков изображений для обучения и валидации (рис. 2).

```
# Поток «обучающих» изображений партиями по 10 с использованием генератора train_datagen
train_generator = train_datagen.flow_from_directory(
    train_dir,
    target_size = (200, 200),
    batch_size = 10,
    class_mode = 'categorical')

# Поток «валидационных» изображений партиями по 10шт с использованием генератора test_datagen
validation_generator = test_datagen.flow_from_directory(
    val_dir,
    target_size = (200, 200),
    batch_size = 10,
    class_mode = 'categorical')
```

```
Found 1656 images belonging to 6 classes.
Found 72 images belonging to 6 classes.
```

Рис. 2. Фрагмент кода (использование генераторов)

Проанализируем результаты, полученные после обучения сверточной нейронной сети. Используя библиотеку matplotlib, были визуализированы кривые точности и потерь во время обучения и валидации (рис. 3,4).

Точность обучения плавно увеличивается с 0.18 до 0.94, что указывает на эффективное обучение модели. Точность модели на валидационных данных растет рывками от 0.35 до 0.98, показывая, что модель хорошо обобщает на новых данных. Потери обучения плавно уменьшаются с 1.75 до 0.19, что свидетельствует о минимизации ошибки модели во время обучения. Потери модели на валидационных данных снижаются с 1.7268 до 0.0609, что демонстрирует хорошую производительность модели на валидационном наборе данных.

Для оценки производительности модели на тестовом наборе данных используется следующий код (рис.4).



Рис. 3. Точность модели на обучающих и валидационных данных




Рис. 4. Потери модели на обучающих и валидационных данных

```
# Оценка производительности на тестовых данных
evaluation = model.evaluate(x_test, y_test)
print("Test Accuracy:", evaluation[1])
```

```
3/3 [=====] - 2s 179ms/step - loss: 0.1817 - accuracy: 0.9306
Test Accuracy: 0.9305555820465088
```

Рис. 4. Фрагмент кода (точность нейронной сети на тестовых данных)

Выход кода показывает точность на тестовых данных, равную 0.931, что является высоким результатом и подтверждает эффективность модели.

Далее была произведена визуальная оценка точности прогнозов модели путём вывода 16 случайных изображений из тестового набора данных, их предсказанные и истинные классы (рис. 5).

Текст заголовка окрашен в зеленый цвет, если класс предсказан верно, и в красный, если модель ошиблась. В данном случае модель ошиблась в двух прогнозах из шестнадцати, что демонстрирует высокую точность классификации.

Далее был разработан API, используя Python с фреймворком Flask, который обеспечит прием изображений, их обработку и возврат результатов классификации.

Был создан файл `app.py`, включающий следующий код:

```
from flask import Flask, request, jsonify
import tensorflow as tf
from PIL import Image
import io
app = Flask(__name__)
# Загрузка обученной модели
model = tf.keras.models.load_model('model.h5')
```

```

@app.route('/predict', methods=['POST'])
def predict():
    if 'file' not in request.files:
        return jsonify({'error': 'no file'}), 400

    file = request.files['file']

    # Преобразование изображения в формат, подходящий для модели
    image = Image.open(io.BytesIO(file.read())).resize((224, 224))
    image = tf.keras.preprocessing.image.img_to_array(image)
    image = tf.expand_dims(image, 0) # Добавление размерности batch

    predictions = model.predict(image)
    # Преобразование вывода модели в полезную информацию
    predicted_class = tf.argmax(predictions, axis=1).numpy()

    # Возврат результата классификации
    return jsonify({'class': str(predicted_class[0])})

if __name__ == '__main__':
    app.run(debug=True)

```




Рис. 5. Предсказание нейронной сети с изображениями

Этот код создает простое API с одним эндпоинтом /predict, который принимает изображения через POST-запросы. Изображение обрабатывается и подается в модель для предсказания. Результат предсказания возвращается клиенту в формате JSON.




Рис. 6. Веб-сервис

Заключение. В результате, разработанный веб-сервис в сочетании с нейросетью для выявления и классификации дефектов металлопрокатной продукции представляет собой мощный инструмент, демонстрирующий возможности использования технологий искусственного интеллекта в промышленности. Значимость этого проекта

также проявляется в его способности не только обнаруживать дефекты, но и способствовать предотвращению потенциального брака на начальных стадиях производства. Веб-интерфейс сервиса предлагает легкий доступ для пользователей, делая анализ быстрым и продуктивным.

Достигнутые результаты в ходе разработки подтверждают эффективность применения искусственного интеллекта в области контроля качества промышленных изделий. Точность модели в процессе обучения стабильно возрастает с начальных 0.18 до впечатляющих 0.94, свидетельствуя о ее успешном обучении. В то время как точность на валидационном наборе данных увеличивается скачкообразно, начиная с 0.35 и достигая 0.98, что подтверждает ее способность эффективно адаптироваться к новым данным. Значения потерь в процессе обучения последовательно сокращаются с 1.75 до 0.19, указывая на уменьшение ошибок модели по мере ее обучения. Аналогично, потери на валидационных данных уменьшаются с 1.7268 до 0.0609, что подчеркивает высокую эффективность модели при работе с валидационным набором данных. Однако для дальнейшего улучшения точности и надежности системы критически важно продолжать работу по углублению и дополнению обучающих наборов данных, а также по совершенствованию алгоритмов нейросети.

Таким образом, представленный веб-сервис с интегрированной нейросетью является перспективным направлением в использовании искусственного интеллекта для решения задач контроля качества. Это открывает новые горизонты для увеличения производительности процессов и снижения потерь от нестандартной продукции, что является ключевым фактором для достижения устойчивого развития в промышленности.

Список литературы

1. Эдер, А. В. Теоретические аспекты модернизации АПК в условиях перехода к цифровой экономике / А. В. Эдер, В. Т. Водяников // Материалы Международной научной конференции молодых учёных и специалистов, посвящённой 135-летию со дня рождения А.Н. Костякова : сборник статей, Москва, 06–08 июня 2022 года. Том 1. Москва: Российский государственный аграрный университет МСХА им. К.А. Тимирязева, 2022. С. 588-593. EDN RHLQH9.
2. Марукович Е.И., Патук Е.М., Марков А.П., Сергеев С.С., Старовойтов А.Г., Бондарев О.Ю. Спектрально-фотометрическая дефектоскопия поверхностей отливок и проката // Литьё и металлургия. 2014. №4 (77). [Электронный ресурс] URL: <https://cyberleninka.ru/article/n/spektralno-fotometricheskaya-defektoskopiya-poverhnostey-otlivok-i-prokata> (дата обращения: 11.04.2024).
3. ГОСТ Р 52079-2003. Прокат листовой и широкополосный из низколегированной и углеродистой стали для холодного формования. Технические условия. М.: Издательство стандартов, 2004. 15 с.
4. ГОСТ 27809-95. Контроль неразрушающий. Термины и определения. М.: Издательство стандартов, 1996. 12 с.
5. Рашка С., Мирджалили В. Python и машинное обучение: машинное и глубокое обучение с использованием Python, scikit-learn и TensorFlow2. Санкт-Петербург: Диалектика, 2020. 848 с.
6. Flask License — Flask 0.10.1.post20150816 documentation [Электронный ресурс] URL: <http://flask-dev.readthedocs.io> (дата обращения: 15.03.2024).

Филиппов Павел Сергеевич, студент, filimipik@mail.ru, Россия, Москва, Российский государственный аграрный университет - МСХА имени К.А. Тимирязева,

Греченева Анастасия Владимировна, канд. техн. наук, доцент, a.grecheneva@rgau-msha.ru, Россия, Москва, Российский государственный аграрный университет - МСХА имени К.А. Тимирязева,

Никаноров Михаил Сергеевич, старший преподаватель, nikanorov@rgau-msha.ru, Россия, Москва, Москва, Российский государственный аграрный университет - МСХА имени К.А. Тимирязева

INFORMATION SYSTEM FOR DETECTION AND CLASSIFICATION OF DEFECTS IN ROLLED METAL PRODUCTS BASED ON ARTIFICIAL INTELLIGENCE

P.S. Filippov, A.V. Grecheneva, M.S. Nikanorov

The article is dedicated to the development of an information system based on neural networks aimed at analyzing images or videos for the purpose of detecting defects on the surface of steel sheets. This project is aimed at improving the efficiency of quality control in rolled metal product manufacturing. The development and validation of the neural network have been carried out. The output code shows an accuracy on test data equal to 0.931, which is a high result and confirms the efficiency of the model. An API and a user interface based on the Flask framework have been developed.

Key words: web service, neural network, computer vision, defect detection, rolled metal products, Flask.

Filippov Pavel Sergeevich, student, filimipik@mail.ru, Russia, Moscow, Russian State Agrarian University - Moscow State Agricultural Academy named after K.A. Timiryazev,

Grechneva Anastasia Vladimirovna, candidate of technical sciences, docent, a.grecheneva@rgau-msha.ru, Russia, Moscow, Russian State Agrarian University - Moscow State Agricultural Academy named after K.A. Timiryazev,

Nikanorov Mikhail Sergeevich, senior lecturer, nikanorov@rgau-msha.ru, Russia, Moscow, Moscow, Russian State Agrarian University - Moscow State Agricultural Academy named after K.A. Timiryazev