

УДК 004.852:621.791.75
DOI 10.17513/snt.40417

К ВОПРОСУ ОБ АВТОМАТИЗАЦИИ ПРОЦЕССА СВАРКИ С ИСПОЛЬЗОВАНИЕМ ДУГОВОЙ СВАРКИ И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Выборнов И.И., Пиотровский Д.Л.

ФГБОУ ВО «МИРЭА – Российский технологический университет»,
Москва, e-mail: pobinput@gmail.com

Целью работы является получение адекватного автоматического алгоритма дуговой сварки, использующего методы машинного обучения для мониторинга параметров сварки, прогнозирования дефектов шва и автоматической корректировки настроек с целью повышения качества и надежности сварных соединений. Настоящая работа посвящена созданию алгоритма для автоматизации дуговой сварки методом MIG/MAG с применением технологий машинного обучения, в частности модели Random Forest. Разработанная система направлена на непрерывный контроль таких параметров сварки, как температура шва, сила тока, скорость подачи проволоки, расход защитного газа и ширина шва. Основная задача – прогнозирование вероятности дефектов сварного соединения и автоматическая корректировка параметров для их предотвращения, что способствует повышению прочности и долговечности конструкций. Алгоритм реализован на языке Python с использованием библиотек Numpy, Sklearn и Matplotlib и адаптирован для работы в среде Google Colab, что упрощает проведение экспериментов и анализ данных. В ходе тестирования система продемонстрировала высокую точность предсказания дефектов (100%), подтвержденную метриками классификации и анализом ROC-кривой. Предложенный подход обеспечивает оптимизацию сварочных процессов, минимизацию производственных ошибок и открывает перспективы для адаптации к другим видам сварки, что делает его ценным инструментом для промышленного применения.

Ключевые слова: машинное обучение, автоматизация сварки, предсказание дефектов, мониторинг параметров, дуговая сварка, качество шва

ON THE QUESTION OF AUTOMATION OF THE WELDING PROCESS USING ARC WELDING AND MACHINE LEARNING METHODS

Vybornov I.I., Piotrovskiy D.L.

Russian Technological University, Moscow, e-mail: pobinput@gmail.com

The aim of the work is to obtain an adequate automatic arc welding algorithm using machine learning methods to monitor welding parameters, predict weld defects and automatically adjust settings in order to improve the quality and reliability of welded joints. This work is devoted to the creation of an algorithm for automating arc welding by the MIG / MAG method using machine learning technologies, in particular the Random Forest model. The developed system is aimed at continuous monitoring of such welding parameters as weld temperature, current strength, wire feed speed, shielding gas flow rate and weld width. The main task is to predict the probability of welded joint defects and automatically adjust the parameters to prevent them, which helps to increase the strength and durability of structures. The algorithm is implemented in Python using the numpy, sklearn and matplotlib libraries and adapted to work in the Google Colab environment, which simplifies experiments and data analysis. During testing, the system demonstrated high accuracy in predicting defects (100%), confirmed by classification metrics and ROC curve analysis. The proposed approach ensures optimization of welding processes, minimization of production errors and opens up prospects for adaptation to other types of welding, which makes it a valuable tool for industrial applications.

Keywords: arc welding, machine learning, welding automation, defect prediction, parameter monitoring, weld quality

Введение

На сегодняшний день современная авиационная промышленность стремится к повышению качества, эффективности и автоматизации производств. В связи с этим возникает потребность во внедрении методов искусственного интеллекта для управления производственными процессами и увеличения вышеупомянутых показателей [1]. Вследствие этого большого внимания заслуживает автоматизация метода дуговой сварки, поскольку в большинстве случаев полагается на традиционное ведение технологического процесса, которое зависит от квалификации оператора и внешних

производственных факторов. В настоящей статье рассматривается алгоритм автоматической дуговой сварки, который использует метод машинного обучения Random Forest для обеспечения предсказания возможного дефекта и корректировки параметров сварки в режиме реального времени.

Цель исследования – получение адекватного автоматического алгоритма дуговой сварки, использующего методы машинного обучения для мониторинга параметров сварки, прогнозирования дефектов шва и автоматической корректировки настроек с целью повышения качества и надежности сварных соединений.

Материалы и методы исследования

Исследование было проведено в моделируемой среде. Программная реализация представляет собой мониторинговую систему сварочного процесса с функцией предсказания дефектов шва [2]. Основная цель системы – обеспечить контроль параметров сварки (температуры шва, ширины шва, тока, скорости сварки, потока защитного газа) и предсказать вероятность возникновения дефектов шва на основе этих параметров. При обнаружении ошибок система автоматически корректирует параметры сварки для минимизации дефектов в режиме реального времени [3].

Алгоритм построен на основе метода Random Forest и ряда методов, обеспечивающих инициализацию, обработку и корректировку параметров, описание которых приведено далее [4].

Код был написан на языке Python, в котором были использованы библиотеки Numpy для математических операций, Sklearn для создания модели деревьев решений и Matplotlib для создания графиков. Для проверки программы был составлен соответствующий метод, который включает метрики, описанные в соответствующем разделе.

Результаты исследования и их обсуждение

Метод инициализации устанавливает начальные параметры сварки, а именно: значение текущего тока (по умолчанию 160 А), скорости сварки (по умолчанию 6 мм/с), поток защитного газа (по умолчанию 12 л/мин.), значение напряжение (по умолчанию 22 В).

Диапазон 100–220 А типичен для MIG/MAG-сварки стали толщиной 3–6 мм, что соответствует рекомендациям производителей (например, Miller Electric) и исследованию [5], поэтому ток в 160 А был взят как среднее между меньшим значением тока, равным 120 А, и большим – 200 А [6].

Напряжение 20–24 В стандартно для MIG-сварки с постоянным напряжением (GMAW-CV), как указано в общих руководствах (например, EWI.org). Данные значения являются оптимальными для дуговой сварки, в соответствии с исследованием [7]. Таким образом, значение по умолчанию было взято как среднее арифметическое границ диапазона.

Температура шва в MIG-сварке зависит от теплового ввода и обычно находится в диапазоне 500–700 °С, в соответствии с исследованием [8]. Соответственно дефектом будет считаться сварное соединение, сделанное при температуре выше 750 °С.



Рис. 1. Блок-схема метода инициализации
Источник: составлено авторами

Скорость 5–8 мм/с (300–480 мм/мин.) стандартна для автоматизированной MIG-сварки, в соответствии с исследованием [9], а значение в 6 мм/с было взято, как оптимальное.

Поток 12–18 л/мин. типичен для смеси аргона и CO_2 в MIG, в соответствии с [10]. Значение по умолчанию было взято по аналогии с остальными.

Метод определяет два режима контроля (строгий и мягкий) и два режима сварки (высокая и низкая мощность).

В данный метод также входит создание модели машинного обучения Random Forest с параметрами: количество деревьев, начального состояния, весов классов. Использование Random Forest позволяет моделировать нелинейные зависимости между признаками и вероятностью дефекта, что делает модель более устойчивой к шуму по сравнению с линейными методами (например, логистической регрессией).

Блок-схема метода инициализации представлена на рисунке 1.



Рис. 2. Блок-схема алгоритма обучения
Источник: составлено авторами

Метод обучения модели генерирует обучающие данные и обучает модель для предсказания дефектов [11]. Обучающий набор данных формируется с учетом следующих признаков: температуры, ширины шва, тока, скорости и потока газа. Метод генерирует метки на основе заданных условий для обучения модели, а затем нормализует данные и обучает модель из предыдущего метода. Блок-схема метода обучения представлена на рисунке 2.

Метод предсказания вероятности дефекта выполняет предсказание на основе текущих параметров сварки [12]. На вход метод получает значения: температуры, ширины шва, тока, скорости и потока газа.



Рис. 3. Блок-схема метода предсказания вероятности дефекта
Источник: составлено авторами

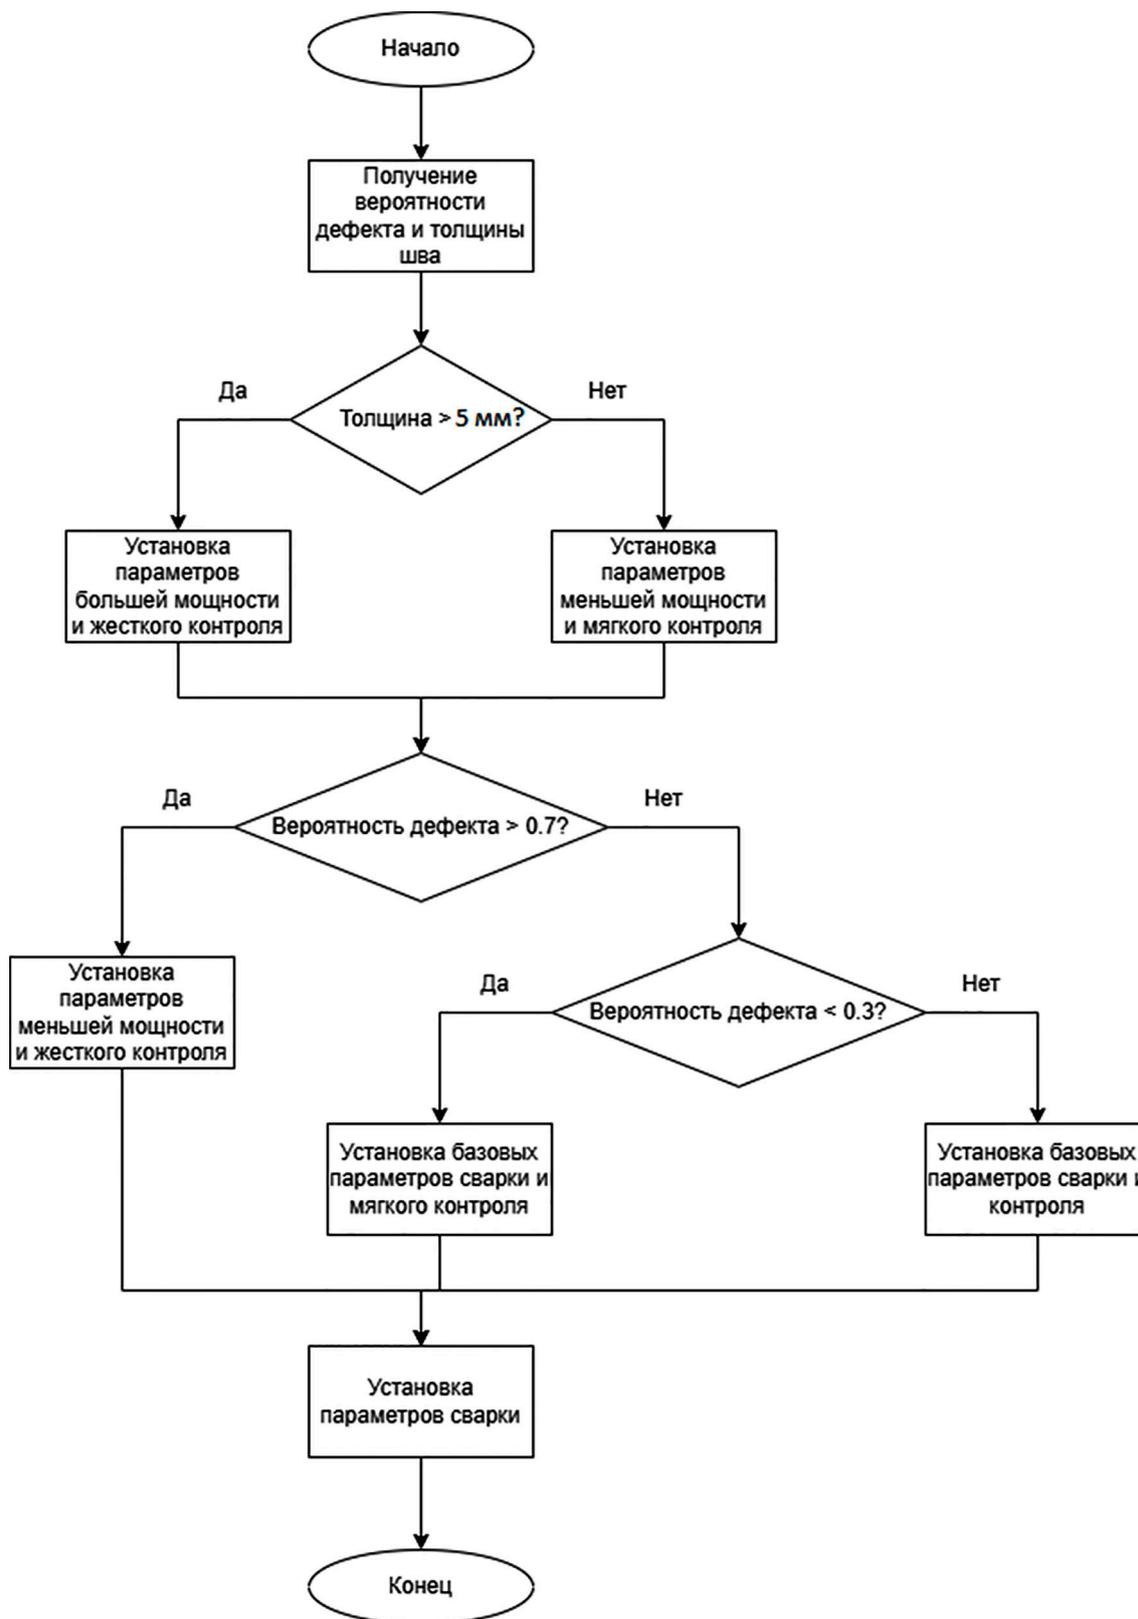


Рис. 4. Блок-схема метода установки режимов сварки и контроля
Источник: составлено авторами

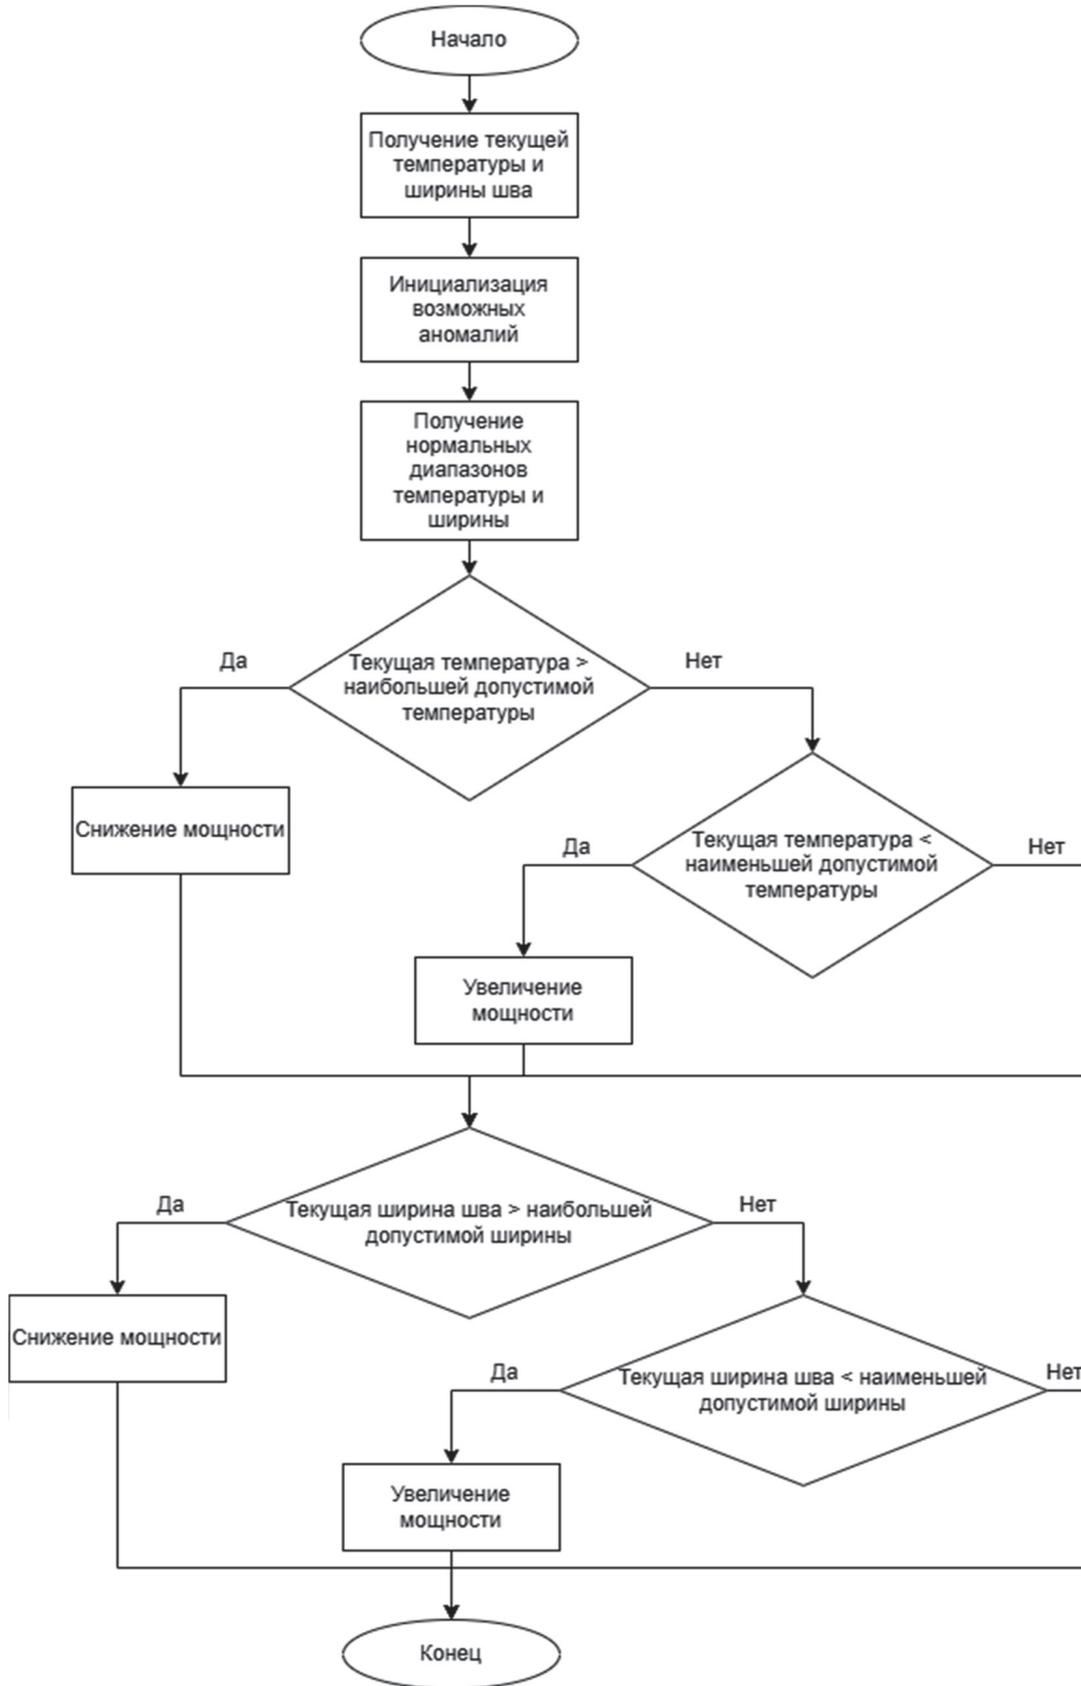


Рис. 5. Блок-схема метода мониторинга параметров сварки и корректировки
 Источник: составлено авторами

Метод создает массив признаков из входных данных, нормализует их и использует обученную модель для предсказания. На выходе модель выдает вероятность возникновения дефекта. Вероятность изменяется от 0 до 1 с точностью до сотых, где 0 – это низкая вероятность возникновения, а 1 – это его высокая вероятность возникновения.

Блок-схема метода предсказания вероятности дефекта представлена на рисунке 3.

Метод установки режимов сварки и контроля необходим для установки режимов сварки и контроля на основе вероятности дефекта и толщины материала [13]. На вход метод получает значения вероятности дефекта и толщины материала. Выходными же данными являются внутренние параметры сварки, а именно: текущий режим сварки, текущий режим контроля, ток, скорость и подача газа.

В соответствии с [14] значение ширины шва, большее 5 мм, считается дефектом, поскольку является индикатором избыточного тепловвода, что может привести к деформации или снижению прочности шва. В любом случае выбранная ширина не противоречит ГОСТ 14771-76.

Блок-схема метода установки режимов сварки и контроля представлена на рисунке 4.

Метод мониторинга параметров сварки и корректировки контролирует параметры сварки и корректирует их при отклонениях [15]. На вход метода поступает текущее значение температуры и ширины шва. Выходными параметрами метода является словарь с текущими параметрами сварки и статусом возможной аномалии.

Блок-схема метода мониторинга параметров сварки и корректировки представлена на рисунке 5.

Полученный алгоритм работает в бесконечном цикле, опрашивая датчики каждые 0,1 с и корректируя поведение рабочего органа на каждом шаге.

Метод тестирования предназначен для тестирования точности предсказания дефектов на тестовом наборе с добавлением шума [16]. Выходными данными метода являются метрики классификации и ROC-кривая.

Блок-схема метода тестирования представлена на рисунке 6.

Несмотря на не слишком большое количество данных для обучения, оценка модели составила 100%. Данные оценки модели представлены на рисунке 7 и 8.

Здесь точность показывает, насколько правильно модель определяет вероятность дефекта, точность класса дефекта – показывает вероятность ложных срабатываний модели, полнота – показывает возможный пропуск дефектов, F1-мера – это гармоничное среднее между точностью класса дефекта и полнотой, ROC-AUC – показывает, насколько хорошо модель разделяет классы. ROC-кривая наглядно демонстрирует способность модели различать дефекты и не дефекты.

Рис. 6. Блок-схема метода тестирования

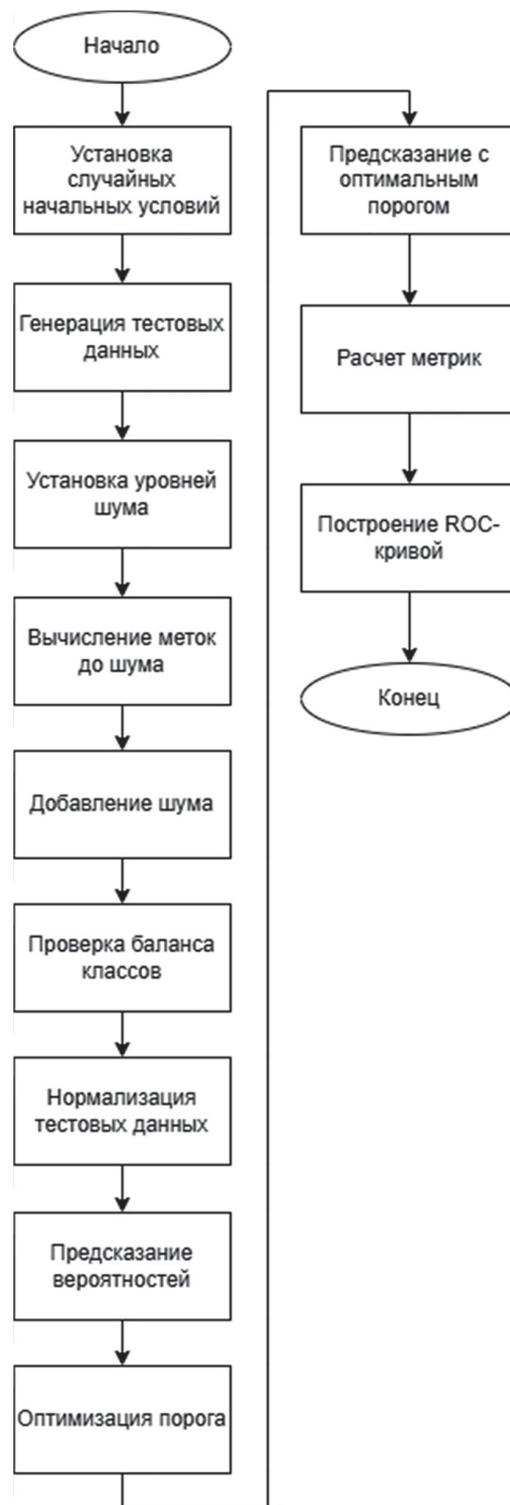


Рис. 6. Блок-схема метода тестирования
Источник: составлено авторами

```

Кросс-валидация (F1-мера): 0.972 (±0.051)
Модель предсказания дефектов обучена
Запуск мониторинга на 10.0 секунд...
Баланс классов: дефекты 335, без дефектов 165
Accuracy: 0.990, Precision: 0.988, Recall: 0.997, F1: 0.993, ROC-AUC: 0.996

```

Рис. 7. Метрики обучения модели
Источник: составлено авторами

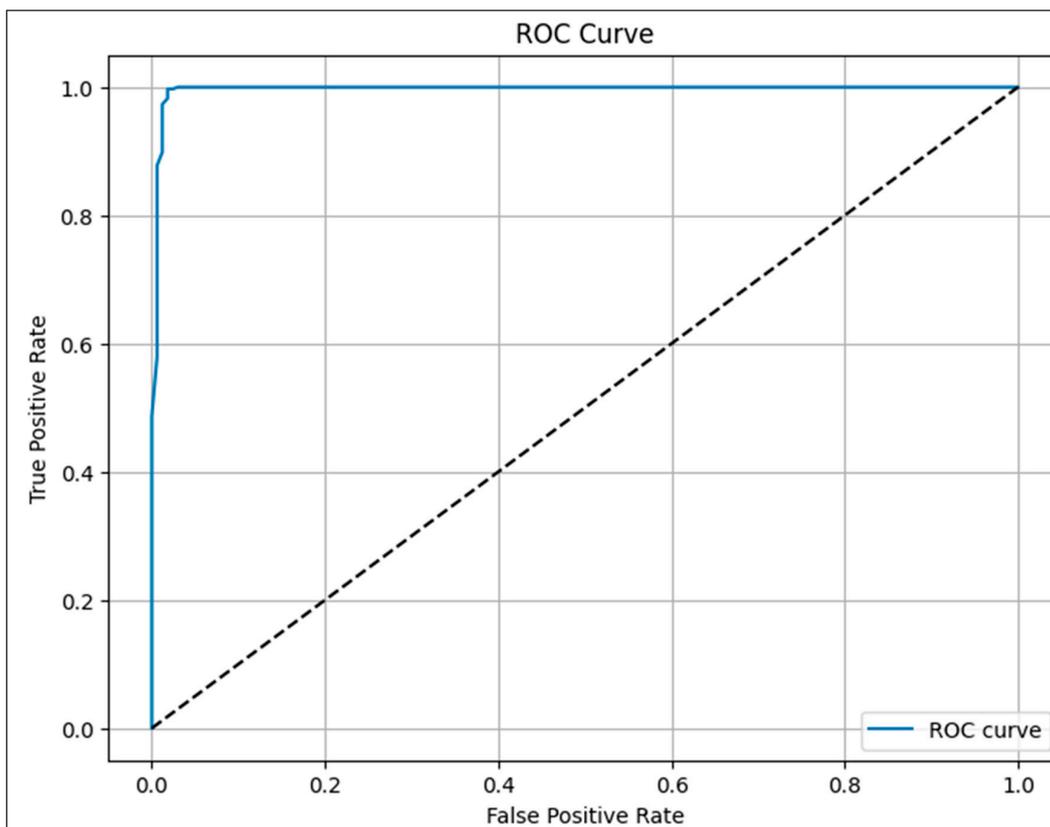


Рис. 8. ROC-кривая
Источник: составлено авторами

Заключение

Разработанный алгоритм автоматизации дуговой сварки, основанный на применении метода Random Forest, показал высокую точность в выявлении и предотвращении дефектов сварного шва. Система мониторинга и автоматической корректировки параметров на основе предсказания достигает точности, близкой к 100%, что было доказано представленными метриками. Разработанная система демонстрирует высокий потенциал внедрения, поскольку позволяет минимизировать ошибки на производстве, повышает надежность сварных соединений и оптимизирует качество технологического процесса создания воздушного судна. В дальнейшем предполагается увеличить объем обучающей выборки, тестирование

на реальных опытных образцах и совмещение метода с другими методами контроля и автоматизации.

Список литературы

1. Jie W., Zhifen Z., Zijian B., Shuai Z., Rui Q., Jing H., Guangrui W. On-line defect recognition of MIG lap welding for stainless steel sheet based on weld image and CMT voltage: Feature fusion and attention weights visualization // Journal of Manufacturing Processes. 2023. Vol. 108. P. 430–444. DOI: 10.1016/j.jmapro.2023.10.081. URL: <https://www.sciencedirect.com/science/article/abs/pii/S1526612523010368> (дата обращения: 15.03.2025).
2. Zhang Z., Wen G., Chen S. Weld image deep learning-based on-line defects detection using convolutional neural networks for Al alloy in robotic arc welding // Journal of Manufacturing Processes. 2019. Vol. 45. P. 208–216. DOI: 10.1016/j.jmapro.2019.06.023. URL: <https://www.sciencedirect.com/science/article/abs/pii/S1526612519301860> (дата обращения: 15.03.2025).

3. Yanxi Z., Deyong Y., Xiangdong G., Seiji K. Monitoring of Welding Status Based on a DBN Model During Laser Welding // *Engineering*. 2019. DOI: 10.1016/j.eng.2019.01.016. URL: https://www.researchgate.net/publication/334277053_Monitoring_of_Welding_Status_Based_on_a_DBN_Model_During_Laser_Welding (дата обращения: 17.03.2025).
4. Li D., Song Y., Ye F. Online monitoring of weld defects for short-circuit gas metal arc welding based on the self-organizing feature map neural networks // *Proceedings of the International Joint Conference on Neural Networks*. 2000. Vol. 5. P. 239–244. DOI: 10.1109/IJCNN.2000.861464. URL: https://www.researchgate.net/publication/3857970_Online_monitoring_of_weld_defects_for_short-circuit_gas_metal_arc_welding_based_on_the_self-organizing_feature_map_neural_networks (дата обращения: 12.03.2025).
5. Thakar H., Chaudhari M., Vora J., Patel V., Das S., Bandhu D., Gupta M., Reddy V. Performance optimization and investigation of metal-cored filler wires for high-strength steel during gas metal arc welding // *High Temperature Materials and Processes*. 2023. DOI: 10.1515/htmp-2022-0305. URL: https://www.researchgate.net/publication/377076428_Performance_optimization_and_investigation_of_metal-cored_filler_wires_for_high-strength_steel_during_gas_metal_arc_welding (дата обращения: 15.03.2025).
6. Wang Z., Li L., Chen H., Lin S., Wu J., Ding T., Tian J., Xu M. Recognition of GTAW weld penetration based on the lightweight model and transfer learning // *Welding in the World*. 2022. Vol. 67. P. 1–14. DOI: 10.1007/s40194-022-01396-0. URL: https://www.researchgate.net/publication/364294769_Recognition_of_GTAW_weld_penetration_based_on_the_lightweight_model_and_transfer_learning (дата обращения: 15.03.2025).
7. Khrais S., Hmoud H., Abdel A., Darabsch T. Impact of Gas Metal Arc Welding Parameters on Bead Geometry and Material Distortion of AISI 316L // *Journal of Manufacturing and Materials Processing*. 2023. Vol. 7. Article 123. DOI: 10.3390/jmmp7040123. URL: https://www.researchgate.net/publication/371969521_Impact_of_Gas_Metal_Arc_Welding_Parameters_on_Bead_Geometry_and_Material_Distortion_of_AISI_316L (дата обращения: 13.03.2025).
8. Kah P., Edigbe G., Ndiwe B., Kubicek R. Assessment of arc stability features for selected gas metal arc welding conditions // *SN Applied Sciences*. 2022. Vol. 4. Article 268. DOI: 10.1007/s42452-022-05150-5. URL: <https://link.springer.com/article/10.1007/s42452-022-05136-7> (дата обращения: 15.03.2025).
9. Haichao L., Yixuan M., Mingrui D., Xin W., Tong C. Defects detection of GMAW process based on convolutional neural network algorithm // *Scientific Reports*. 2023. Vol. 13. DOI: 10.1038/s41598-023-48698-x. URL: https://www.researchgate.net/publication/376146088_Defects_detection_of_GMAW_process_based_on_convolutional_neural_network_algorithm (дата обращения: 17.03.2025).
10. Alnecino N., Francois N. B., Paul K. Optimization of GMAW Process Parameters in Ultra-High-Strength Steel Based on Prediction // *Metals*. 2023. Vol. 13. Article 1447. DOI: 10.3390/met13081447. URL: https://www.researchgate.net/publication/373090987_Optimization_of_GMAW_Process_Parameters_in_Ultra-High-Strength_Steel_Based_on_Prediction (дата обращения: 18.03.2025).
11. Sakthivel R., Venkadeshwaran P., Sridevi R., Meeran R., Kamaraj C. Effect of Welding Current, Arc Voltage and Gas Flow Rate on Depth of Penetration during MIG Welding of AA2014 Plate // *International Journal of Scientific & Engineering Research*. 2015. Vol. 6. URL: https://www.researchgate.net/publication/279920913_Effect_of_Welding_Current_Arc_Voltage_and_Gas_Flow_Rate_on_Depth_of_Penetration_during_MIG_Welding_of_AA2014_Plate (дата обращения: 12.03.2025).
12. Asif K., Zhang L., Derrible S., Indacochea E., Ozevin D., Ziebart B. Machine learning model to predict welding quality using air-coupled acoustic emission and weld inputs // *Journal of Intelligent Manufacturing*. 2022. Vol. 33. P. 1–15. DOI: 10.1007/s10845-020-01667-x. URL: https://www.researchgate.net/publication/346315747_Machine_learning_model_to_predict_welding_quality_using_air-coupled_acoustic_emission_and_weld_inputs (дата обращения: 15.03.2025).
13. Chen G., Sheng B., Luo R., Pengzhen J. A parallel strategy for predicting the quality of welded joints in automotive bodies based on machine learning // *Journal of Manufacturing Systems*. 2022. Vol. 62. P. 636–649. DOI: 10.1016/j.jmsy.2022.01.011. URL: https://www.researchgate.net/publication/358478950_A_parallel_strategy_for_predicting_the_quality_of_welded_joints_in_automotive_bodies_based_on_machine_learning (дата обращения: 15.03.2025).
14. Kumaresan S., Aultrin K., Kumar S.S., Anand M. Transfer Learning With CNN for Classification of Weld Defect // *IEEE Access*. 2021. DOI: 10.1109/ACCESS.2021.3093487. URL: https://www.researchgate.net/publication/352848476_Transfer_Learning_With_CNN_for_Classification_of_Weld_Defect (дата обращения: 12.03.2025).
15. Jinquan L., Jie L., Jinli X., Ding L. Welding quality analysis and prediction based on deep learning // *The International Journal of Advanced Manufacturing Technology*. 2021. P. 405–416. DOI: 10.1109/WCMEIM54377.2021.00045. URL: https://www.researchgate.net/publication/363118146_Welding_quality_analysis_and_prediction_based_on_deep_learning (дата обращения: 15.03.2025).
16. Kim I.-S., Lee M.-G., Jeon Y. Review on Machine Learning Based Welding Quality Improvement // *International Journal of Precision Engineering and Manufacturing-Smart Technology*. 2023. Vol. 1. P. 219–226. DOI: 10.57062/ijpemst.2023.0017. URL: https://www.researchgate.net/publication/372169737_Review_on_Machine_Learning_Based_Welding_Quality_Improvement (дата обращения: 14.03.2025).