

МЕТОД ПОИСКА ДЕФЕКТОВ ЛОПАТОК ГАЗОТУРБИННОГО ДВИГАТЕЛЯ ПОД ВИДИМЫМ СВЕТОМ С ИСПОЛЬЗОВАНИЕМ СЕТИ U-NET

© 2025

- Е. А. Алексеев** директор по цифровой трансформации;
ПАО «ОДК-Сатурн», г. Рыбинск;
evgeny.alekseev@uec-saturn.ru
- А. Н. Ломанов** кандидат технических наук, доцент, директор института
информационных технологий и систем управления;
Рыбинский государственный авиационный технический
университет имени П.А. Соловьёва;
frei@rsatu.ru

При производстве деталей авиационных двигателей на операциях контроля широко применяются методы, позволяющие обнаруживать поверхностные несплошности материала. Одним из таких методов является капиллярный метод неразрушающего контроля. Для решения одной из частных задач – выявления загрязнений на обследуемой поверхности, представлено описание метода поиска дефектов на поверхностях лопаток газотурбинного двигателя под видимым светом. В основе решения задачи поиска загрязнений при осмотре поверхностей лопатки лежит сегментация изображения с помощью свёрточной нейронной сети U-NET. Приведены результаты использования обученной модели на лопатках в производственных подразделениях ПАО «ОДК-Сатурн».

Неразрушающий контроль; машинное зрение; поиск загрязнений; нейронная сеть

Цитирование: Алексеев Е.А., Ломанов А.Н. Метод поиска дефектов лопаток газотурбинного двигателя под видимым светом с использованием сети U-NET // Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение. 2025. Т. 24, № 1. С. 85-93. DOI: 10.18287/2541-7533-2025-24-1-85-93

Введение

В отечественной литературе недостаточно изучен вопрос автоматизации капиллярного метода контроля деталей. Большинство работ, например [1; 2], описывают только способы цифровой обработки изображений для поиска индикаторных следов, причём основное внимание уделяется только поиску единичных индикаций, расчёту их размеров на изображении (в пикселях). В работах игнорируются такие важные вопросы, как расчёт остальных характеристик свечения (ориентация, положение, расположение относительно друг друга) и фильтрация излишков пенетранта на поверхности детали.

При анализе авторы чаще всего используют различные фильтры для подготовки изображения, а затем выполняют бинаризацию, чтобы оставить на изображении только индикаторные следы. Данный подход позволяет точно определить индикаторные следы на изображении, но у него есть ряд недостатков:

- очень часто, помимо индикаторных следов от дефектов, на инспектируемой поверхности остаются несмытые остатки пенетранта, которые можно спутать с реальным дефектом;

- для корректной работы метода необходимо равномерное освещение по всей инспектируемой поверхности;

- для сложнопрофильных поверхностей, таких как лопатка газотурбинного двигателя (ГТД), необходимо перемещение объекта контроля (или видеокамеры), обеспечивающее получение изображения под углом, близким к нормали по отношению к контролируемой поверхности.

В рассмотренных работах авторы анализируют поверхности простых деталей, например, пластин, кубиков и т.д. Перед анализом измеряются реальные размеры поверхности детали в миллиметрах, а затем размеры на изображении – в пикселях. При этом определение физических размеров дефектов рассчитывается как отношение количества пикселей дефекта к количеству пикселей поверхности, умноженное на реальный размер поверхности. Использование такого подхода возможно только на простых поверхностях, не имеющих сложных форм, например, изгибов.

В работах зарубежных авторов капиллярный метод контроля рассмотрен в большом количестве работ, но также только со стороны обработки цифрового изображения. В отличие от отечественных, в работах зарубежных авторов для поиска индикаторных следов чаще всего используются различные алгоритмы машинного обучения.

Например, в работе [3] авторы используют алгоритм Random forest для анализа поверхности титановой пластины размером 100×50×4 мм. Набор данных для обучения сети представляет 36 изображений различных пластин с 124 уникальными дефектами. Все дефекты в наборе представляют из себя трещины. Авторам удалось добиться точности нахождения дефектов 76%, т. е. был пропущен каждый пятый дефект. Кроме того, данный метод позволяет только детектировать дефекты на поверхности, без расчёта их характеристик.

В других работах авторы также используют различные алгоритмы машинного обучения, такие, например, как модели ResNets [4], сеть прямого распространения с полносвязными слоями [5], а также различные статистические методы [6]. Данные подходы, по сравнению с детерминированными методами, имеют большую устойчивость к ложным индикаторным следам (остаткам пенетранта на поверхности детали), но одновременно с этим у них увеличен шанс пропустить индикаторный след реального дефекта.

Реализация модели U-NET для поиска загрязнений при видимом свете

Для решения задачи поиска загрязнений на поверхности лопатки под видимым светом в данной работе предлагается использовать подход, в который входят следующие этапы:

- съёмка поверхности лопатки;
- предобработка полученных изображений;
- сегментация изображения с помощью свёрточной нейронной сети *U-NET*;
- выделение на поверхности лопатки обнаруженных загрязнений.

Загрязнения, выявляемые при данном типе контроля, имеют характер тёмного пятна различной формы (зачастую схожую с эллипсом). Чаще всего такие загрязнения имеют большие размеры, более 5 мм. Это связано с тем, что изначально загрязнение имеет жидкую форму и при попадании на поверхность равномерно растекается по ней. Пример загрязнения под видимым светом представлен на рис. 1.

С точки зрения захвата изображения метод имеет аналогичный алгоритм, а именно:

- лопатка крепится сначала одной стороной в оснастке;
- считывается и распознаётся её идентификационный номер;
- выполняется вращение и съёмка лопатки.

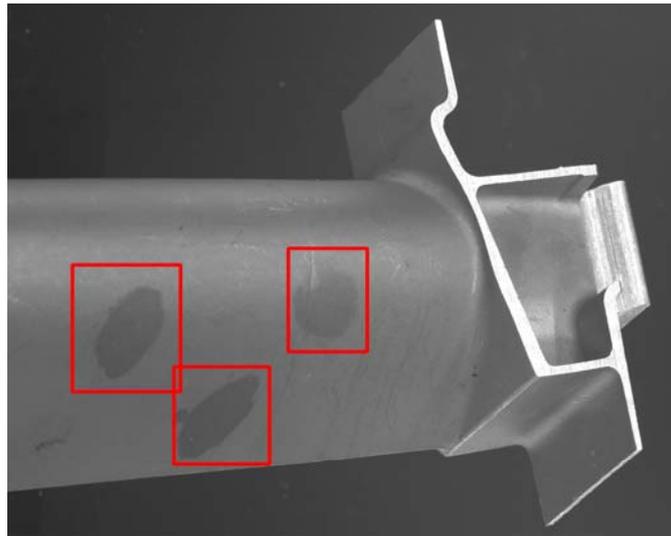


Рис. 1. Пример загрязнения под видимым светом

Одним из наиболее широко используемых инструментов для анализа изображений являются нейронные сети. Как уже упоминалось ранее, в данном случае для поиска загрязнений применялась архитектура, основанная на использовании свёрточной нейронной сети U-NET. Данная архитектура была выбрана по нескольким причинам, а именно:

– изначально данная архитектура была разработана для биомедицинских приложений, для сегментации аномальных областей на снимках различной природы, задача поиска загрязнений схожа с основной задачей архитектуры;

– для достижения хороших результатов требуются относительно небольшие наборы данных.

В табл. 1 представлена архитектура сети с характеристиками каждого слоя. Размеры слоёв подбирались эмпирически, исходя из результатов обучения.

Для обучения сети был подготовлен набор данных, состоящий из 900 размеченных изображений. Для подготовки набора данных были получены 37 изображений с лопатками разных типов. На каждую лопатку был нанесён масляный след. После съёмки всех лопаток изображения были размечены путём создания маски с выделенными областями загрязнений. Так как набор данных имеет очень маленький размер, к каждому изображению были применены аугментации, чтобы увеличить количество данных. Вместе с оригинальным изображением аналогичные аугментации применялись и к его маске. Пример данных из обучающей выборки представлен на рис. 2, причём на рис. 2, а представлено аугментированное изображение, а на рис. 2, б – его маска. В результате всех преобразований был подготовлен обучающий набор, причём под обучающую часть было отдано 80% данных, а под валидационную – 20%.

По результатам обучения был подготовлен график, на котором показано изменение функции потерь на тренировочных и валидационных данных. График функции потерь представлен на рис. 3, где эпоха представляет собой один полный цикл обучения нейронной сети на всём наборе обучающих данных. Функция потерь определяет ошибку между реальными и полученными ответами. Из представленного графика можно сделать вывод, что обучение прошло успешно, отсутствует переобучение и недообучение модели.

После обучения модели она была интегрирована в программное обеспечение стенда.

Таблица 1. Описание слоёв реализованной нейронной сети

Тип слоя	Размеры выходного слоя	Количество параметров слоя	Связан со слоями
input_1 (InputLayer)	[(None, 256, 256, 3)]	0	
lambda (Lambda)	(None, 256, 256, 3)	0	input_1[0][0]
conv2d (Conv2D)	(None, 256, 256, 16)	448	lambda[0][0]
dropout (Dropout)	(None, 256, 256, 16)	0	conv2d[0][0]
conv2d_1 (Conv2D)	(None, 256, 256, 16)	2320	dropout [0][0]
max_pooling2d (MaxPooling2D)	(None, 128, 128, 16)	0	conv2d_1[0][0]
conv2d_2 (Conv2D)	(None, 128, 128, 32)	4640	max_pooling2d [0][0]
dropout_1 (Dropout)	(None, 128, 128, 32)	0	conv2d_2[0][0]
conv2d_3 (Conv2D)	(None, 128, 128, 64)	9248	dropout_1[0][0]
max_pooling2d_1 (MaxPooling2D)	(None, 64, 64, 64)	0	conv2d_3[0][0]
conv2d_4 (Conv2D)	(None, 64, 64, 64)	18496	max_pooling2d_1[0][0]
dropout_2 (Dropout)	(None, 64, 64, 64)	0	conv2d_4 (Conv2D)
conv2d_5 (Conv2D)	(None, 64, 64, 64)	36928	dropout_2[0][0]
max_pooling2d_2 (MaxPooling2D)	(None, 32, 32, 64)	0	conv2d_5[0][0]
conv2d_6 (Conv2D)	(None, 32, 32, 128)	73856	max_pooling2d_2[0][0]
dropout_3 (Dropout)	(None, 32, 32, 64)	0	conv2d_6[0][0]
conv2d_7 (Conv2D)	(None, 32, 32, 128)	147584	dropout_3[0][0]
max_pooling2d_3 (MaxPooling2D)	(None, 16, 16, 128)	0	conv2d_7 [0][0]
conv2d_8 (Conv2D)	(None, 16, 16, 256)	295168	max_pooling2d_3 [0][0]
dropout_4 (Dropout)	(None, 16, 16, 256)	0	conv2d_8 [0][0]
conv2d_9 (Conv2D)	(None, 16, 16, 256)	590080	dropout_4 [0][0]
conv2d_transpose (Conv2DTrans)	(None, 32, 32, 128)	131200	conv2d_9[0][0]
concatenate (Concatenate)	(None, 32, 32, 256)	0	conv2d_transpose [0][0] conv2d_7[0][0]
conv2d_10 (Conv2D)	(None, 32, 32, 128)	295040	concatenate [0][0]
dropout_5 (Dropout)	(None, 32, 32, 128)	0	conv2d_10 [0][0]
conv2d_11 (Conv2D)	(None, 32, 32, 128)	147584	dropout_5 [0][0]
conv2d_transpose_1 (Conv2DTrans)	(None, 64, 64, 64)	32832	conv2d_11[0][0]
concatenate_1 (Concatenate)	(None, 64, 64, 128)	0	conv2d_transpose_1 [0][0] conv2d_5[0][0]
conv2d_12 (Conv2D)	(None, 64, 64, 64)	73792	concatenate_1[0][0]
dropout_6 (Dropout)	(None, 64, 64, 64)	0	conv2d_12[0][0]
conv2d_13 (Conv2D)	(None, 64, 64, 64)	36832	dropout_6[0][0]
conv2d_transpose_2 (Conv2DTrans)	(None, 128, 128, 32)	8224	conv2d_13[0][0]
concatenate_2 (Concatenate)	(None, 128, 128, 64)	0	conv2d_transpose_2 [0][0] conv2d_3[0][0]
conv2d_14 (Conv2D)	(None, 128, 128, 32)	18464	concatenate_2 [0][0]
dropout_7 (Dropout)	(None, 128, 128, 32)	0	conv2d_14 [0][0]
conv2d_15 (Conv2D)	(None, 128, 128, 32)	9248	dropout_7[0][0]
conv2d_transpose_3 (Conv2DTrans)	(None, 256, 256, 16)	2064	conv2d_15 [0][0]
concatenate_3 (Concatenate)	(None, 256, 256, 32)	0	conv2d_transpose_3 [0][0] conv2d_1[0][0]
conv2d_16 (Conv2D)	(None, 256, 256, 16)	4624	concatenate_3[0][0]
dropout_8 (Dropout)	(None, 256, 256, 16)	0	conv2d_16 [0][0]
conv2d_17 (Conv2D)	(None, 256, 256, 16)	2320	dropout_8 [0][0]
conv2d_18 (Conv2D)	(None, 256, 256, 1)	17	conv2d_17 [0][0]

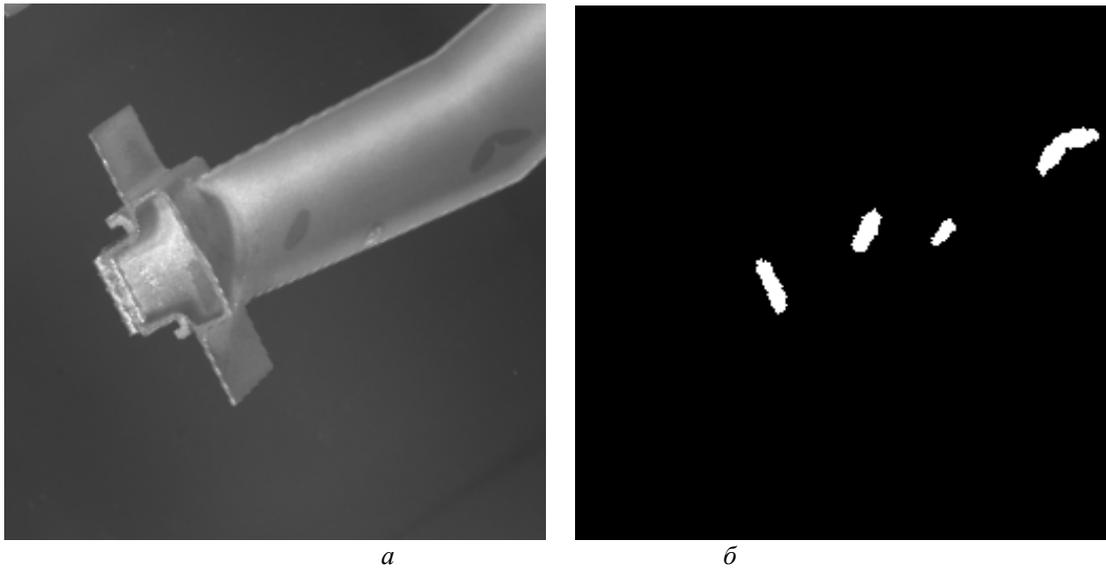


Рис. 2. Пример данных из обучающей выборки:
а – аугментированное изображение; б – маска загрязнений

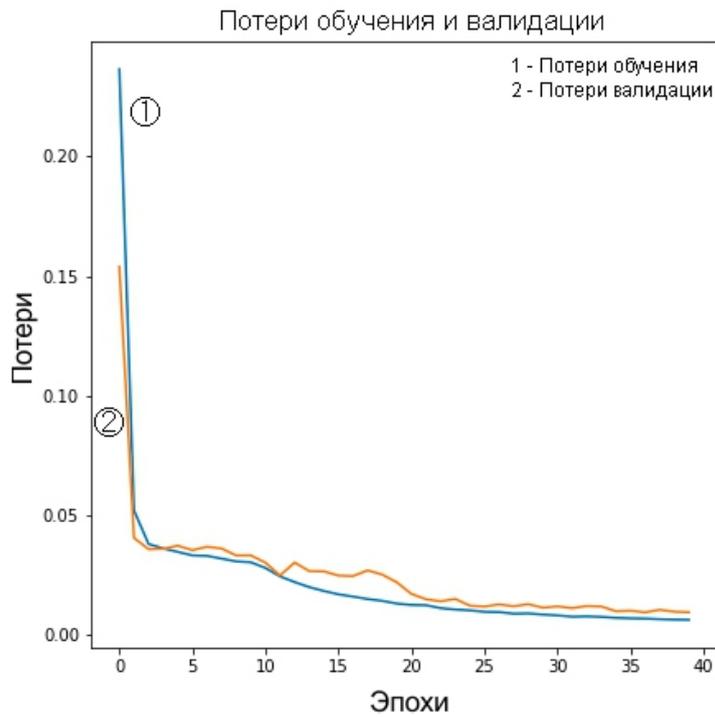


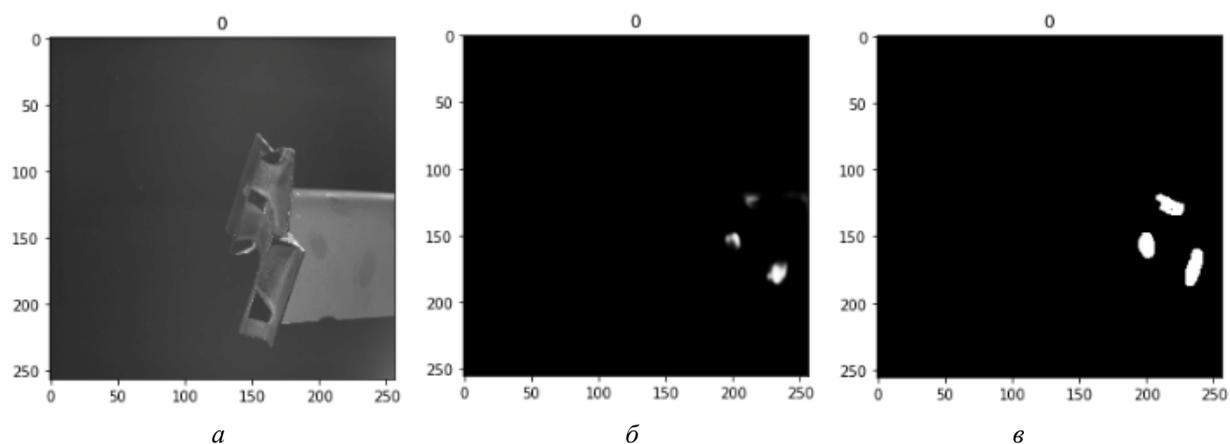
Рис. 3. График функции потерь

Результаты использования обученной модели для поиска загрязнений при видимом свете

После интеграции обученной модели в программное обеспечение был разработан и реализован алгоритм, который подготавливает данные для нейросети, а также обрабатывает полученные результаты для дальнейшего отображения оператору.

При подготовке изображение масштабируется до размеров 256×256 пикселей, а также изменяется его цветовая модель на оттенки серого. Данное изображение подаётся на вход нейросети.

На выходе нейросеть возвращает сегментированное изображение 256×256 пикселей, на котором белым цветом выделены загрязнённые области, а всё остальное заполнено чёрным цветом. Пример сегментированного изображения представлен на рис. 4.



*Рис. 4. Пример сегментированного изображения:
а – оригинальное изображение; б – результат сегментации; в – требуемый результат*

Сегментированная область выделяется прямоугольником, который масштабируется до размеров оригинального изображения (3000×4000 пикселей) и накладывается на него. Таким образом, получается результирующее изображение с выделенными областями загрязнений.

Испытания реализованной модели для поиска загрязнений на поверхностях лопаток при видимом свете выполнялись в производственных условиях на ПАО «ОДК-Сатурн». Для испытаний использовалось 30 лопаток 3-х разных типов, из них 24 лопатки (80%) имели загрязнения, а 6 лопаток (20%) были чистые и не имели загрязнения. Исследования реализованной модели показали высокую точность определения загрязнений. Основными недостатками оказались:

- иногда в качестве загрязнения распознаётся тень, отбрасываемая от элементов лопатки на её же поверхность;
- скорость работы алгоритма выше требуемой примерно в 4 раза (~43 секунды на 1 лопатку).

В остальном разработанный алгоритм показал требуемые результаты, не пропустив ни одного загрязнения на поверхности лопаток. Протокол испытаний представлен в табл. 2.

Таблица 2. Протокол испытаний стенда по распознаванию дефектов под белым светом

Номер лопатки	Тип лопатки	Наличие загрязнений (реальное)	Наличие загрязнений (результат стенда)	Примечание
HJ608 966-P	Ступень 2	Присутствуют	Присутствуют	
HJ608 155-H	Ступень 2	Присутствуют	Присутствуют	
HJ608 226-2	Ступень 2	Присутствуют	Присутствуют	
HJ608 189-C	Ступень 2	Отсутствуют	Отсутствуют	
HJ608 223-5	Ступень 2	Присутствуют	Присутствуют	
HJ608 958-7	Ступень 2	Присутствуют	Присутствуют	
HJ608 249-D	Ступень 2	Отсутствуют	Отсутствуют	
HJ608 233-K	Ступень 2	Присутствуют	Присутствуют	
HJ608 150-N	Ступень 2	Присутствуют	Присутствуют	
HJ608 266-0	Ступень 2	Присутствуют	Присутствуют	
HJ608 275-F	Ступень 2	Присутствуют	Присутствуют	
HJ608 127-2	Ступень 2	Присутствуют	Присутствуют	
HJ608 196-Y	Ступень 2	Отсутствуют	Отсутствуют	
HJ608 373-G	Ступень 2	Присутствуют	Присутствуют	
HJ608 212-M	Ступень 2	Присутствуют	Присутствуют	
HJ608 814-E	Ступень 2	Присутствуют	Присутствуют	
HJ608 389-6	Ступень 3	Присутствуют	Присутствуют	
HJ608 496-A	Ступень 3	Отсутствуют	Отсутствуют	
HJ608 338-8	Ступень 3	Присутствуют	Присутствуют	
HJ608 436-F	Ступень 3	Присутствуют	Присутствуют	
HJ608 526-1	Ступень 3	Присутствуют	Присутствуют	
HJ608 831-W	Ступень 3	Присутствуют	Присутствуют	
HJ608 457-7	Ступень 3	Присутствуют	Присутствуют	
HJ608 827-Y	Ступень 3	Отсутствуют	Присутствуют	Распознана тень, как дефект
HJ608 138-2	Ступень 3	Присутствуют	Присутствуют	
HJ608 788-9	Ступень 3	Присутствуют	Присутствуют	
HJ608 792-3	Ступень 3	Присутствуют	Присутствуют	
HJ608 527-4	Ступень 3	Присутствуют	Присутствуют	
HJ608 330-5	Ступень 3	Присутствуют	Присутствуют	
HJ608 395-C	Ступень 4	Отсутствуют	Отсутствуют	

Заключение

По результатам проведённых фактических испытаний разработанного алгоритма можно сделать вывод, что выбранный метод поиска дефектов лопаток газотурбинного двигателя под видимым светом при помощи сверхточной нейронной сети U-NET является эффективным и обеспечивает высокую точность.

Разработанный метод может быть использован в составе экспериментальных и промышленных установок (оборудования) по выявлению дефектов при помощи машинного зрения.

Библиографический список

1. Ермаков А.А. Методы и алгоритмы обработки и анализа снимков в капиллярной дефектоскопии. Дис. канд. техн. наук. Владимир, 2009. 129 с.
2. Бобков А.В. Выделение отрезков на изображении в задаче ориентации по визуальной информации // Вестник Московского государственного технического университета им. Н.Э. Баумана. Серия Приборостроение. 2002. № 3 (48). С. 45-54.

3. Shipway N.J., Barden T.J., Huthwaite P., Lowe M.J.S. Automated defect detection for Fluorescent Penetrant Inspection using random forest // *NDT and E International*. 2019. V. 101. P.113-123. DOI: 10.1016/j.ndteint.2018.10.008

4. Shipway N.J., Huthwaite P., Lowe M.J.S., Barden T.J. Using ResNets to perform automated defect detection for Fluorescent Penetrant Inspection // *NDT and E International*. 2021. V. 119. DOI: 10.1016/j.ndteint.2020.102400

5. Nicolai A., Caputo D., Chieco L., Grimaccia F., Mussetta M. Machine learning-based detection technique for NDT in industrial manufacturing // *Mathematics*. 2021. V. 9, Iss. 11. DOI: 10.3390/math9111251

6. Tout K. Automatic vision system for surface inspection and monitoring: Application to wheel inspection. Signal and image processing. Université de Technologie de Troyes – UTT, 2018. <https://theses.hal.science/tel-01801803/document>

METHOD FOR SEARCHING DEFECTS IN GAS TURBINE ENGINE BLADES UNDER VISIBLE LIGHT USING THE U-NET MODEL

© 2025

E. A. Alekseev Director for Digital Transformation;
Public Joint-Stock Company UEC-Saturn, Rybinsk, Russian Federation;
evgeny.alekseev@uec-saturn.ru

A. N. Lomanov Candidate of Science (Engineering), Associate Professor,
Director of the Institute of Information Technologies
and Management Systems;
Rybinsk State Aviation Technical University named after P.A. Solovyov,
Rybinsk, Russian Federation;
frei@rsatu.ru

In the production of aircraft engine parts, methods that allow detecting surface discontinuities in the material are widely used in testing operations. One of these methods is the capillary method of non-destructive testing. To solve one of the specific tasks – detection of contamination on the inspected surface, a description of the method for searching for defects on the surfaces of gas turbine engine blades under visible light is presented. The solution to the problem of searching for contamination during inspection of blade surfaces is based on image segmentation using the U-NET convolutional neural network. The results of using the trained model on blades in the production units of PJSC “UEC-Saturn” are presented.

Non-destructive control; machine vision; search for contamination; neural network

Citation: Alekseev E.A., Lomanov A.N. Method for searching defects in gas turbine engine blades under visible light using the U-NET model. *Vestnik of Samara University. Aerospace and Mechanical Engineering*. 2025. V. 24, no. 1. P. 85-93. DOI: 10.18287/2541-7533-2025-24-1-85-93

References

1. Ermakov A.A. *Metody i algoritmy obrabotki i analiza snimkov v kapillyarnoy defektoskopii. Dis. kand. tekhn. nauk* [Methods and algorithms of image processing and analysis in capillary flaw detection. Thesis for a Candidate Degree in Science (Engineering)]. Vladimir, 2009. 129 p.

2. Bobkov A.V. Intercepting image in problem of orientation by visual information. *Herald of the Bauman Moscow State Technical University, Series Instrument Engineering*. 2002. No. 3 (48). P. 45-54. (In Russ.)

3. Shipway N.J., Barden T.J., Huthwaite P., Lowe M.J.S. Automated defect detection for Fluorescent Penetrant Inspection using random forest. *NDT and E International*. 2019. V. 101. P. 113-123. DOI: 10.1016/j.ndteint.2018.10.008

4. Shipway N.J., Huthwaite P., Lowe M.J.S., Barden T.J. Using ResNets to perform automated defect detection for Fluorescent Penetrant Inspection. *NDT and E International*. 2021. V. 119. DOI: 10.1016/j.ndteint.2020.102400

5. Niccolai A., Caputo D., Chieco L., Grimaccia F., Mussetta M. Machine learning-based detection technique for NDT in industrial manufacturing. *Mathematics*. 2021. V. 9, Iss. 11. DOI: 10.3390/math9111251

6. Tout K. Automatic vision system for surface inspection and monitoring: Application to wheel inspection. Signal and image processing. Université de Technologie de Troyes – UTT, 2018. Available at: <https://theses.hal.science/tel-01801803/document>