

## МЕТОДЫ СОКРАЩЕНИЯ РАЗМЕРНОСТИ ИЗОБРАЖЕНИЙ В ЗАДАЧАХ АВТОМАТИЗИРОВАННОГО КОНТРОЛЯ КАЧЕСТВА СТЕКЛОТКАНИ

### IMAGE DIMENSION REDUCTION METHODS FOR AUTOMATED FIBERGLASS QUALITY CONTROL

А.А. КАЗНАЧЕЕВА<sup>1</sup>, О.М. ВЛАСЕНКО<sup>1</sup>, С.В. ЗАХАРКИНА<sup>1</sup>, А.А. ЭПОВ<sup>2</sup>

A.A. KAZNACHEEVA<sup>1</sup>, O.M. VLASENKO<sup>1</sup>, S.V. ZAKHARKINA<sup>1</sup>, A.A. EPOV<sup>2</sup>

(<sup>1</sup>Российский государственный университет им. А.Н. Косыгина (Технологии. Дизайн. Искусство),  
(<sup>2</sup>Московский авиационный институт (национальный исследовательский университет))

(<sup>1</sup>The Kosygin State University of Russia)

(<sup>2</sup>Moscow Aviation Institute (National Research University))

E-mail: kaznacheeva-aa@rguk.ru

*В статье рассмотрен вопрос сокращения размерности изображений для обнаружения дефектов стеклоткани на базе методов машинного обучения. Такой подход позволяет уменьшить количество входных переменных или признаков в наборе данных с сохранением наиболее важной информации. Проанализированы линейные и нелинейные алгоритмы, такие как PCA, метод k-средних и UMAP. На основе проведенных исследований установлено, что алгоритм UMAP является наиболее эффективным инструментом извлечения признаков из «сырых» данных, так как позволяет сохранять локальные и глобальные структуры данных, выявлять кластеры и сложные взаимосвязи в данных. Это делает его ценным для решения таких задач, как разведочный анализ данных, распознавание образов и обнаружение аномалий. В рамках создания системы автоматизированного контроля качества применен способ обучения нейросети на основе библиотек TensorFlow и Keras на платформе Google Colab. Предложена методика применения алгоритма UMAP для извлечения признаков в задаче обнаружения дефектов стеклоткани с использованием 3D-визуализации. Полученный результат по точности и вычислительной мощности демонстрирует эффективность данного метода для определения структуры данных и проверки качества признаков при решении задачи обнаружения дефектов стеклоткани и позволяет применить его для других текстильных полотен.*

*The article considers the issue of image dimensionality reduction for fiberglass defect detection based on machine learning methods. This approach allows to reduce the number of input variables or features in the data set while preserving the most important information. Linear and nonlinear algorithms such as PCA, k-means and UMAP are analyzed. Based on the conducted research, it is established that the UMAP algorithm is the most effective tool for extracting features from «raw» data, since it allows preserving local and global data structures, identifying clusters and complex relationships in the data. This makes it valuable for solving problems such as exploratory data analysis, pattern recognition, and anomaly detection. As part of the creation of an automated quality control system, a neural network training method based on the TensorFlow and Keras libraries on the Google Colab platform was used. A method for applying the UMAP algorithm for*

*feature extraction in the problem of detecting defects in fiberglass using 3D visualization is proposed. The obtained result in terms of accuracy and computing power demonstrates the effectiveness of this method for determining the structure of data and checking the quality of features when solving the problem of detecting defects in fiberglass and allows it to be applied to other textile fabrics.*

**Ключевые слова:** методы сокращения размерности, изображение, признаки, машинное обучение, нейросеть, тестирование, функция потерь.

**Keywords:** dimensionality reduction methods, image, features, machine learning, neural network, testing, loss function.

### *Введение*

На сегодняшний день в производстве текстильных полотен специального назначения, в том числе стеклоткани, одним из ключевых этапов является контроль качества получаемого материала, включающий обнаружение и распознавание дефектов. Технологический процесс изготовления стеклоткани является трудоемким и дорогим, что обусловлено сложной структурой материала [1]. В связи с этим для обеспечения требуемого качества и снижения затрат необходима автоматизация производственной линии, которая в свою очередь предполагает создание встроенной эффективной автоматизированной системы контроля качества с применением современных способов обработки изображений посредством нейросетевых технологий и машинного обучения [2, 3].

С помощью методов машинного обучения (machine learning – ML) можно сформировать предсказания на основе аналитических выводов, используя определенные алгоритмы и математические модели для обработки входных данных. При этом «сырые» данные, подаваемые на вход системы, требуют приведения к формату, пригодному для обработки моделью ML. Для этой цели применяют методы сокращения размерности (dimensionality reduction methods), при которых происходит уменьшение количества входных переменных или признаков в наборе данных с сохранением наиболее важной информации [4].

Применение методов сокращения размерности дает такие преимущества, как повышение эффективности алгоритмов за счет снижения вычислительной сложности;

увеличение точности прогнозирования при снижении количества нерелевантных признаков; визуализация и интерпретация многомерных данных [5, 6].

Целью данной работы являлся сравнительный анализ методов сокращенной размерности для решения задачи обнаружения дефектов стеклоткани, а также разработка и реализация методики применения алгоритма UMAP для извлечения признаков из получаемых «сырых» данных от объекта. Это позволило выявлять структуры и сложные взаимосвязи в данных, определять признаки и оценивать их качество, что повысило эффективность системы контроля качества стеклоткани и других текстильных полотен.

### *Методы сокращения размерности*

Методы сокращения размерности по способу работы с данными делят на две группы: к первой группе относят те алгоритмы, которые сохраняют глобальную структуру данных; во второй группе находятся методы, которые используют для работы локальные расстояния между точками [7, 8]. Примером из первой группы является метод анализа главных компонент (principal component analysis – PCA). Это статистический метод, который фокусируется на понятии линейной зависимости, т. е. большинство признаков, называемых главными компонентами, представляют собой линейные комбинации нескольких ключевых признаков. Идея состоит в замене избыточных признаков на несколько новых, которые адекватно обобщают информацию, содержащуюся в исходном пространстве признаков. Такой подход позволяет сократить количество «шума», сжимая многомерные

данные в низкоразмерное линейное пространство [9].

На первом этапе происходит центрирование матрицы данных, где каждая строка представляет собой наблюдение, а каждый столбец – признак:

$$C = X - I \cdot \mu^T, \quad (1)$$

где  $I$  – вектор столбцов, содержащий все единицы;  $\mu$  – вектор столбцов, содержащий среднее значение для строк  $X$ .

Таким образом можно привести данные к нулевому среднему и единичной дисперсии.

Затем осуществляется разложение ковариационной матрицы, которое тесно связано с сингулярным разложением матрицы данных:

$$C = U \cdot Z \cdot V^T, \quad (2)$$

где  $U$  и  $V$  – ортогональные матрицы (то есть  $U^T U$  и  $V^T V = I$ );  $Z$  – диагональная матрица, содержащая сингулярные значения  $X$ , которые могут быть положительными, нулевыми или отрицательными.

На следующем этапе происходит поиск главных компонент. Первые  $k$  главных компонент – это первые  $k$  столбцов матрицы  $V$ , т. е. правые сингулярные векторы, соответствующие наибольшему единичным значениям  $k$ .

На заключительном этапе данные проецируются на новый базис, образованный главными компонентами. В результате главные компоненты представляют собой новые признаки, которые можно использовать в моделях для машинного обучения.

РСА – это широко используемый метод, но у него есть ограничения, такие как высокая вычислительная стоимость и неинтерпретируемый результат. Он полезен в качестве этапа предварительной обработки данных, когда существуют линейные зависимости между объектами.

Метод  $k$ -средних ( $k$ -means) – это алгоритм кластеризации, который относится к нелинейным методам сокращения размерности [10]. Он группирует данные в зависимости от того, как те размещены в пространстве. Идея метода заключается в том,

чтобы выводить метки кластера, основываясь на геометрии самих данных. Алгоритм зависит от параметра – евклидова расстояния между двумя векторами  $x$  и  $y$ . Метод задает жесткую кластеризацию и учится позиционировать кластеры так, чтобы общая сумма евклидова расстояния между каждой точкой данных и центром ее кластера была минимальна.

Целевая функция рассчитывается по формуле:

$$\min_{c_1 \dots c_k, \mu_1 \dots \mu_k} \sum_{i=1}^k \sum_{x \in c_i} \|x - \mu_i\|_2. \quad (3)$$

Каждый кластер  $C_i$  содержит подмножество точек данных. Центр кластера  $i$  равен среднему значению всех точек данных в кластере:

$$\mu_i = \sum_{x \in c_i} x / n_i, \quad (4)$$

где  $n_i$  обозначает количество точек данных в кластере  $i$ .

Применение метода  $k$ -средних для преобразования пространственных данных в объекты – это объединение моделей в стек, где вход для одной модели становится выходом для другой. Идея стекирования – внедрить нелинейности в признаки и использовать в качестве последнего слоя линейную модель. Ее можно обучить в автономном режиме, что позволит снизить большие вычислительные мощности при генерации полезных признаков.

Метод  $k$ -средних обычно используется как метод моделирования без контроля для поиска новых кластеров точек данных в пространстве признаков. При его использовании необязательно задаются метки классов в качестве входных данных. Это помогает находить кластеры, границы которых больше соответствуют границам классов. Однако результат зависит от выбора исходных центров кластеров, их оптимальный выбор неизвестен. Также необходимо знать заранее число кластеров.

Одним из самых молодых алгоритмов сокращения размерности является метод унифицированного аппроксимированного проецирования (uniform approximation and projection – UMAP), который относится к

группе алгоритмов с сохранением локальных расстояний между точками [11]. Основная идея – вычисление нечеткого геометрического представления. Здесь сила притяжения между двумя точками  $a$  и  $b$  с координатами  $x_a$  и  $y_b$  определяется по формуле:

$$F_{пр} = \frac{-2mn\|y_a - y_b\|_2^{2(n-1)}}{1 + \|y_a - y_b\|_2^2} \times z((x_a, x_b))(y_a - y_b), \quad (5)$$

где  $m$  и  $n$  – задаваемые и варьируемые параметры;  $z_{ab}$  – низкоразмерное сходство:

$$z_{ab} = (1 + m\|y_a - y_b\|_2^{2n})^{-1}. \quad (6)$$

Сила отталкивания рассчитывается по формуле:

$$F_{от} = \frac{2n}{(\epsilon + \|y_a - y_b\|_2^2)(1 + m\|y_a - y_b\|_2^{2n})} \times (1 - z((x_a, x_b)))(y_a - y_b), \quad (7)$$

где  $\epsilon = 0.001$ .

Суть этого метода состоит в определении взвешенного графа  $H$ , который строится на основании массива точек  $\{y_a\}$ ,  $a=1..K$ . При этом граф  $H$  должен быть эквивалентен некоторому взвешенному графу  $G$ . Разница между этими графами определяется исходя из общей кросс-энтропии, вычисляемой с учетом всех вероятностей существования ребра [12]. Такой подход позволяет получить максимально точное низкоразмерное представление данных.

Таким образом, UMAP – это нелинейный метод снижения размерности, который направлен на сохранение как локальных, так и глобальных структур данных, что делает его более подходящим для визуализации и исследования сложных взаимосвязей по сравнению с другими методами, требующими линейной зависимости между признаками (РСА) или задающими жесткую кластеризацию без контроля новых точек в пространстве признаков (метод  $k$ -средних). Алгоритм UMAP помогает выявлять структуры, кластеры и взаимосвязи в данных, что делает его ценным для решения таких задач, как разведочный анализ данных, распознавание образов и обнаружение аномалий.

## Прикладное применение алгоритма UMAP

На кафедре автоматики и промышленной электроники РГУ им. А.Н. Косыгина ведутся исследовательские работы по созданию автоматизированной системы обнаружения дефектов стеклоткани на базе методов машинного обучения и нейросетевых технологий с использованием библиотек TensorFlow и Keras [13]. В качестве метода снижения размерности выбран UMAP. Разработка и обучение нейронной сети осуществлялись с применением облачной платформы Google Colab на языке программирования Python.

Методика применения алгоритма UMAP включает несколько этапов.

На первом этапе после загрузки данных формируется словарь классов дефектов. Известны следующие виды [14]: 1) масляное пятно; 2) недосека забоина; 3) слет утка; 4) близна. На рис. 1 изображен словарь классов дефектов и нормальных образцов.

На следующем шаге происходит подготовка данных для обучения нейросети архитектуры ResNet50 [15].

```
[ ] label_to_class = {0: '0. Норма',
                    1: 'Дефект 1. Недосека забоина',
                    2: 'Дефект 2. Масляное пятно',
                    3: 'Дефект 3. Слет утка',
                    4: 'Дефект 4. Близна'}

class_to_label = {v: k for k, v in label_to_class.items()}
```

Рис. 1

Для выявления необходимых признаков для обучения нейросети из входного массива данных применяется функция `get_embedding` [16]. С помощью этой функции все изображения входного набора прогоняются через заранее обученную модель. В результате работы функции формируется вектор признаков, который полностью характеризует изображение.

Таким образом, на заключительном этапе происходит визуализация извлеченных признаков с применением функции `plot_umap`, которая описывает вариант использования алгоритма UMAP для сокращения размерности изображений.

На рис. 2 показана 3D-визуализация точек, характеризующих признаки изображений дефектов стеклоткани. Точками разных цветов показаны обнаруженные на изображении дефекты, которые отнесены к разным классам. На графике хорошо идентифицируются точки, соответствующие нормальному образцам, и точки, отнесенные к дефекту «масляное пятно», тогда как наборы точек из других классов дефектов перекрывают друг друга. Это затрудняет анализ и создает некоторую неопределенность визуализации. Такую разницу в определении дефекта можно объяснить тем, что пятно в силу своей физической природы имеет ярко выраженное цветовое отличие от нормального образца, а остальные дефекты представляют собой различные виды нарушения структуры полотна, и алгоритмы обнаружения, которые хорошо распознают цвет, здесь дают худший результат.

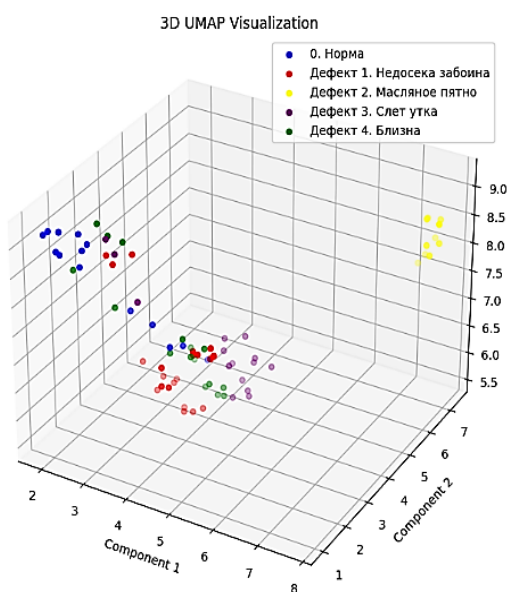


Рис. 2

Для улучшения визуализации использована функция потерь. Ее задача минимизировать расстояние между объектом и прототипом его класса и максимизировать расстояние между объектом и прототипом другого класса [17]. Этот метод дает хороший результат в случаях определения взаимного расположения точек в пространстве признаков с ограниченным количеством данных.

Согласно алгоритму определения функции [17] в программе были заложены предсказанные признаки модели, назначены целевые метки классов и процентное содержание данных (60%). Далее сформировали прототип, определили количество классов и списки для хранения данных, сравнивающих с прототипом. В итоге были проведены вычисления и инициализирована функция потерь.

На рис. 3 приведен результат обучения модели. Время обучения модели составило 30 минут при заданном количестве эпох 20. Точность обучения – 93%.

Анализ полученного результирующего графика позволяет сделать вывод, что при использовании в алгоритме функции потерь точки с разными метками более четко сгруппированы в кластеры. Это говорит о том, что извлеченные признаки позволяют более качественно различать классы дефектов. Как видно на графике, расстояние между классами «Близна» и «Масляное пятно» достаточно велико по сравнению с остальными, что является следствием значительных различий в признаках. С другой стороны, классы «Недосека забоина» и «Слет утка» имеют более сложные структурные дефекты, которые неоднозначно определяются моделью, поэтому на графике классы перекрывают друг друга. Для хорошего распознавания этих дефектов требуется провести процедуру улучшения модели и/или вводить дополнительные данные.




Рис. 3

### Заключение

В результате проведенных исследований методов сокращения размерностей для решения задачи обнаружения дефектов стеклоткани выбран алгоритм UMAP. Предложена методика его применения для извлечения признаков из получаемых данных от объекта с использованием 3D-визуализации.

Проведенные исследования и полученный результат демонстрируют эффективность применения нейронной сети архитектуры ResNet50 для классификации дефектов стеклоткани. Описанный способ предназначен для понимания структуры данных и проверки качества признаков при решении задачи классификации.

Следует отметить, что при использовании в алгоритме функции потерь точки с разными метками извлеченные признаки позволяют более качественно различать классы дефектов. Однако в случае сложных структурных дефектов наблюдается перекрытие классов при визуализации, что требует проведения процедур улучшения модели.

Полученные результаты использования метода сокращения размерности UMAP для извлечения и визуализации признаков изображений дефектов по точности доказывают его эффективность для данного класса прикладных задач и могут быть использованы для применения в системах контроля качества других текстильных полотен.

### ЛИТЕРАТУРА

1. *Казначеева А.А., Власенко О.М., Захаркина С.В., Гончарова Е.Б.* Разработка алгоритма распознавания изображений для автоматизированной системы контроля дефектов стеклоткани на основе методов машинного обучения // Инженерный вестник Дона. 2025, №5. – URL: [ivdon.ru/ru/magazine/archive/n5y2025/10058](http://ivdon.ru/ru/magazine/archive/n5y2025/10058).
2. *Ложкин Н.Д., Рыжкова Е.А.* Особенности разработки системы контроля качества технических тканей // Сборник научных трудов кафедры автоматизации и промышленной электроники Российского государственного университета им. А.Н. Косыгина. М., 2024. С. 109...113.
3. *Бондарева Т.П., Кузнецова А.В.* Исследование технологии выработки стеклоткани с целью снижения ее уровня дефектности // Материалы и технологии. 2018. №1. С. 23...27.

4. *Ступак М.М., Казначеева А.А.* Применение фильтрации изображений для подготовки обучающего набора данных нейронной сети в задачах контроля качества стеклоткани // Сборник научных трудов кафедры автоматизации и промышленной электроники Российского государственного университета им. А.Н. Косыгина. М., 2024. С. 168...173.

5. *Шамкова А.А., Свищёва И.В.* Обработка изображений сверточными нейронными сетями // Моя профессиональная карьера. 2020. № 12. С. 202...205.

6. *Девис Р., Терк М.* Компьютерное зрение. Современные методы и перспективы развития. М.: ДМК Пресс, 2022. 690 с.

7. *Chambolle A.* Total variation minimization and a class of binary mfr models. *Energy Minimization Methods in Computer Vizion and Pattern Recognition.* (2005). P. 136...152.

8. *Пономарев Е.С.* Ускорение, сжатие и усовершенствование нейросетевых алгоритмов классификации и распознавания объектов на изображениях и видеопотоке: дис... канд. техн. наук. М., 2023. 101 с.

9. *Чжен А., Казару А.* Машинное обучение. Конструирование признаков. М.: Бомбора, 2024. 240 с.

10. *Chan T., Vese L.* Active contours without edges. *IEEE Trans. Images Processing*, 10(2): 2001. P. 266...277.

11. *Проневич О.Б., Клокова А.П.* Анализ UMAP – метода снижения размерности исходных данных в машинном обучении для прогнозирования отказов в локомотивном комплексе // Надежность. 2022. Т. 22, №4. С. 53...62.

12. *Farneback G.* Two-frame motion estimation based on polynomial expansion // *Proceddings of the 13<sup>th</sup> Scandinavian Conference on Image Analysis*, 2003. P. 363...370.

13. *Танг Д.* Умные мобильные проекты с TensorFlow. М.: ДМК-Пресс, 2019. 384 с.

14. *Ступак М.М.* Применение методов искусственного интеллекта в задачах автоматизированного контроля качества текстильных материалов // Молодые ученые – инновационному развитию общества (МИР-2022): тез. докл. 74-й внутривуз. науч. конф. М., 2022. Ч. 2. С. 11...12.

15. *Ступак М.М., Казначеева А.А.* Анализ существующих архитектур нейронных сетей // Инновационное развитие техники и технологий в промышленности: сб-к матер. всерос. науч. конф. М., 2023. С. 253...256.

16. *Kolmogorov V., Zabih R.* What energy function can be minimized via graph cuts. *IEEE Transactions on Pattern. Analysis and Machine Intelligence.* 2004. P. 26:65...81.

17. *Tononi G.* Consciousness, information integration, and the brain. 2005. P. 109...126.

### REFERENCES

1. *Kaznacheeva A.A., Vlasenko O.M., Zakharkina S.V., Goncharova E.B.* Development of an image recognition algorithm for an automated system for monitoring fiberglass defects based on machine learning methods // *Inzhenernyj vestnik Dona.* 2025. №5. – URL: [ivdon.ru/ru/magazine/archive/n5y2025/10058](http://ivdon.ru/ru/magazine/archive/n5y2025/10058).

2. *Lozhkin N.D., Ryzhkova E.A.* Features of the development of a quality control system for technical fabrics // *Sbornik nauchnyh trudov kafedry avtomatiki i promyshlennoj elektroniki Rossijskogo gosudarstvennogo universiteta im. A.N. Kosygina. M., 2024. P. 109...113.*
3. *Bondareva T.P., Kuznecova A.V.* Research of glass fabric production technology with the aim of reducing its defect level // *Materialy i tekhnologii. 2018. №1. P. 23...27.*
4. *Stupak M.M., Kaznacheeva A.A.* Application of image filtering to prepare training dataset of neural network in glass fiber quality control tasks // *Sbornik nauchnyh trudov kafedry avtomatiki i promyshlennoj elektroniki Rossijskogo gosudarstvennogo universiteta im. A.N. Kosygina. M., 2024. P. 168...173.*
5. *Shamkova A.A., Svishchyova I.V.* Image processing with convolutional neural networks // *Moya professional'naya kar'era, 2020. № 12. P. 202...205.*
6. *Devis R., Terk M.* *Advanced Methods and Deep Learning in Computer Vision. M.: DMK-Press, 2022. 690 p.*
7. *Chambolle A.* Total variation minimization and a class of binary mfr models. *Energy Minimization Methods in Computer Vision and Pattern Recognition. (2005). P. 136...152.*
8. *Ponomarev E.S.* Acceleration, compression and improvement of neural network algorithms for classification and recognition of objects in images and water. *M., 2023. 101 pp.*
9. *Zheng A., Casari A.* *Machine learning. Feature engineering. M.: Bombora, 2024. 240 pp.*
10. *Chan T., Vese L.* Active contours without edges. *IEEE Trans. Images Processing, 10(2): 2001. P. 266...277.*
11. *Pronevich O.B., Klokova A.P.* Analysis of UMAP – a method for reducing the dimensionality of input data in machine learning for predicting failures in a locomotive complex // *Nadezhnost'. 2022. Volume 22. № 4. P. 53...62.*
12. *Farneback G.* Two-frame motion estimation based on polynomial expansion // *Proceedings of the 13th Scandinavian Conference on Image Analysis, 2003. P. 363...370.*
13. *Tang D.* *Smart Mobile Projects with TensorFlow. DMK-Press, 2019. 384 pp.*
14. *Stupak M.M.* Application of artificial intelligence methods in the tasks of automated quality control of textile materials // *Molodye uchenye – innovacionnomu razvitiyu obshchestva (MIR-2022): tezisy dokladov 74-y vnutrivuzovskoy nauchnoy konferentsii. Moscow, 2022. Part 2. P. 11...12.*
15. *Stupak M.M., Kaznacheeva A.A.* Analysis of existing neural network architectures. // *Innovacionnoe razvitie tekhniki i tekhnologij v promyshlennosti: sbornik materialov Vserossijskoj nauchnoj konferentsii molodyh issledovatelej s mezhdunarodnym uchastiem. Moscow, 2023. P. 253...256.*
16. *Kolmogorov V., Zabih R.* What energy function can be minimized via graph cuts. *IEEE Transactions on Pattern. Analysis and Machine Intelligence. 2004. P. 26:65-81.*
17. *Tononi G.* Consciousness, information integration, and the brain. 2005. P. 109...126.

Рекомендована кафедрой автоматки и промышленной электроники РГУ им. А.Н. Косыгина. Поступила 10.06.25.