Труды МАИ. 2025. № 141 Trudy MAI. 2025. No. 141. (In Russ.)

Научная статья

УДК 621.396.96

URL: https://trudymai.ru/published.php?ID=184505

EDN: https://www.elibrary.ru/NGNZHD

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ВОССТАНОВЛЕНИЯ ОБЪЕКТОВ НА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЯХ

Михаил Алексеевич Митькин¹, Константин Юрьевич Гаврилов^{2⊠}

^{1,2}Московский авиационный институт (национальный исследовательский университет), Москва, Российская Федерация

¹m-m99@yandex.ru

²gvrk61@mail.ru[⊠]

Аннотация. В работе рассмотрена возможность применения искусственных нейронных сетей (ИНС) для подавления шумов на радиолокационных изображениях (РЛИ). Основной задачей является использование модели нейронной сети для фильтрации шума и восстановления четкости изображения. Для этого разработан и сформирован набор данных, предназначенный для обучения сети с целью ее эффективного применения в реальных условиях.

В качестве ИНС в работе выбрана модель автокодировщика, которая способна создавать компактные представления изображений в скрытом слое. Такая сеть позволяет выделять основные особенности изображений (признаки) и уменьшать размерность данных, что, как показали исследования, оказывается весьма эффективно в задачах фильтрации шума.

Предполагается, что рассматриваемая ИНС будет использована для улучшения визуального восприятия крупноразмерных объектов на радиолокационных изображениях. Во многих практических применениях такие объекты могут быть

1

представлены в виде совокупности связанных друг с другом простых геометрических фигур типа прямоугольников, кругов, треугольников и т.д. Поэтому в качестве тестовых объектов при анализе и сравнении различных алгоритмов фильтрации использованы простые фигуры указанных видов.

В работе проведено сравнение эффективности работы ИНС и классических алгоритмов фильтрации, таких как медианная фильтрация, усредняющий фильтр и фильтр Гаусса. В качестве критериев эффективности при сравнении различных алгоритмов восстановления изображений использованы две метрики — индекс структурного сходства (SSIM — Structural Similarity Index) и пиковое отношение сигнала к шуму (PSNR — Peak Signal-to-Noise Ratio). Описаны принципы вычисления данных метрик для каждой пары изображений — исходного и восстановленного.

Описана методика создания набора данных (изображений), используемого при обучении ИНС и ее тестировании. Приведены примеры удаления шумов при наблюдении полезных объектов в виде простых геометрических фигур — квадрата, круга, треугольника, двух дуг. Восстановленные изображения получены при использовании двух методов — с помощью обученной ИНС и с помощью традиционных фильтров. Приведены результаты расчетов показателей эффективности фильтрации для различных объектов на РЛИ. Расчеты выполнены при фильтрации с помощью ИНС и трех видов фильтров — медианного, усредняющего и фильтра Гаусса.

Результаты расчетов показали, что при использовании ИНС эффективность фильтрации значительно выше: значение метрики SSIM для ИНС превосходит аналогичные значения для фильтров примерно в 7...20 раз; для метрики PSNR — примерно в 1,1...10 раз. Полученные значения выигрышей зависят от формы восстанавливаемого объекта и уровня шума.

Ключевые слова: глубокое обучение, нейронные сети, радиолокационное изображение, фильтрация шума

Для цитирования: Митькин М.А., Гаврилов К.Ю. Применение искусственных нейронных сетей для восстановления объектов на радиолокационных изображениях // Труды МАИ. 2025. № 141. URL: https://trudymai.ru/published.php?ID=184505

Original article

APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR THE RESTORATION OF OBJECTS IN RADAR IMAGES

Mikhail A. Mitkin¹, Konstantin Yu. Gavrilov^{2⊠}

^{1,2}Moscow Aviation Institute (National Research University),

Moscow, Russian Federation

¹m-m99@yandex.ru

²gvrk61@mail.ru[⊠]

Abstract. The paper considers the possibility of using artificial neural networks (ANN) to suppress noise in radar images. The main task is to use a neural network model to filter noise and restore image clarity. For this purpose, a data set has been developed and generated, designed to train the network in order to effectively apply it in real conditions.

The paper uses an autoencoder model as an ANN, which is capable of creating compact representations of images in a hidden layer. Such a network allows you to identify the main features of images (features) and reduce the dimension of data, which, as studies have shown, is very effective in noise filtering tasks.

It is assumed that the ANN in question will be used to improve the visual perception of large-sized objects in radar images. In many practical applications, such objects can be represented as a set of interconnected simple geometric shapes such as rectangles, circles, triangles, etc. Therefore, simple shapes of these types are used as test objects in the analysis and comparison of various filtering algorithms.

The paper compares the efficiency of ANN and classical filtering algorithms, such as median filtering, averaging filter and Gaussian filter. Two metrics were used as performance criteria when comparing different image recovery algorithms – the Structural Similarity Index (SSIM) and the peak Signal—to—Noise Ratio (PSNR). The principles of calculating these metrics for each pair of images – the original and the restored – are described.

The method of creating a dataset (images) used in the training of the ANN and its testing is described. Examples of noise removal when observing useful objects in the form of simple geometric shapes – a square, a circle, a triangle, two arcs – are given. The restored images were obtained using two methods – using a trained ANN and using traditional filters. The results of calculations of filtration efficiency indicators for various objects on the radar are presented. The calculations were performed using ANN filtering and three types of filters – median, averaging, and Gaussian filters.

The calculation results showed that when using ANN, the filtration efficiency is significantly higher: the value of the SSIM metric for ANN exceeds similar values for filters by about 7...20 times; for the PSNR metric – by about 1.1...10 times. The resulting gain values depend on the shape of the object being restored and the noise level.

Keywords: deep learning, neural networks, radar image, noise filtering

For citation: Mitkin M.A., Gavrilov K.Yu. Application of artificial neural networks for the restoration of objects in radar images. *Trudy MAI*. 2025. No. 141. (In Russ.). URL: https://trudymai.ru/eng/published.php?ID=184505

Введение

Современные технологии обработки изображений и компьютерного зрения играют ключевую роль в различных областях, включая обработку радиолокационных изображений (РЛИ). РЛИ, формирующие изображения поверхности земли с помощью радаров с синтезированием апертуры (РСА) или для визуализации объемных структур в подповерхностной радиолокации и дефектоскопии, используются для обнаружения и распознавания различных объектов. При этом объекты интереса могут иметь как простую геометрическую форму (например, штыри арматуры, элементы крепежа и др. в подповерхностной радиолокации), так и сложную форму контура — самолеты, объекты военной техники и др. при дистанционном зондировании земли.

С развитием и совершенствованием технологии получения РЛИ высокого разрешения появились методы распознавания объектов сложной структуры, наблюдаемые на фоне помех различного вида. Эти методы, в основном, используют двухэтапную обработку, включающую процедуры «извлечение признаков» и

«алгоритм классификации». Извлечение признаков начинается с исходного РЛИ и позволяет извлечь информативные признаки объекта, такие как геометрическая форма, распределение серого цвета, контраст и др., основываясь на идее удаления несущественных деталей объекта и сохранения основных его особенностей.

В работах [1-7] для разработки методов распознавания целей использовались геометрические признаки формы, такие как площадь цели (тень) и контур, которые отражали информацию о внешнем виде цели. Однако из-за общих помех и шумов на РЛИ, точность распознавания таких признаков, как области и контуры цели, часто ограничена. Классификаторы, используемые для распознавания целей в РСА, в основном, унаследованы из области оптического распознавания образов или оптимизированы и улучшены в соответствии с характеристиками РЛИ, например, метод К ближайших соседей (K-NN) в [8], машина опорных векторов (SVM) в [9, 10], классификация на основе разреженного представления (SRC) [11-13] и популярная в последнее время свёрточная нейронная сеть (CNN) [14-21].

В отличие от обычных оптических изображений, РЛИ часто страдают от различных видов искажений, таких как аддитивные шумы, спекл-эффект, радиочастотные помехи и другие артефакты, что снижает их качество и усложняет процесс интерпретации. Поэтому перед распознаванием объектов используют обычно методы предварительной обработки РЛИ, которые повышают эффективность последующего распознавания.

В данной работе исследуется применение нейронных сетей для улучшения качества радиолокационных изображений. Целью работы является подавление шумов на изображении и восстановление формы объектов путем применения искусственных нейронных сетей (ИНС), обученных для выполнения соответствующих функций.

Рассмотрена методика обучения ИНС, приведены рекомендации по выбору архитектуры сети, оптимизатора и функции потерь. Проведен анализ результатов работы обученной ИНС, включая визуализацию результатов, и сравнение ее с традиционными методами обработки изображений, основанными на методах фильтрации изображений.

Задача обработки РЛИ заключается в удалении (фильтрации) шума и восстановлении четкости (резкости) изображения. Эта задача решается путем создания, обучения и функционирования ИНС, работа которой затем сравнивается с результатами традиционных алгоритмов фильтрации — медианная фильтрация, усредняющий фильтр и фильтр Гаусса.

Модель нейронной сети обучается на зашумленных радиолокационных изображениях с целью выявления шумовых особенностей и шаблонов. Затем она применяется для фильтрации шума на новых радиолокационных изображениях, восстанавливая их четкость и улучшая качество.

1. Создание, обучение и работа нейронной сети

Работа с ИНС начинается с выбора среды разработки (языка программирования), а также с подготовки исходного набора данных. Для работы с нейросетью выбран язык программирования *Python* с его библиотеками *keras* и *TensorFlow2*. При этом используется предварительная обработка данных, преобразование к необходимому формату и нормализация изображений.

Для работы с исходным набором данных чаще всего используют библиотеку *OpenCV* (Open Source Computer Vision Library), которая загружает изображения из указанных папок и преобразует их в массивы библиотеки *питру* — библиотека *Python*, предназначенная для работы с многомерными массивами данных и выполнения математических операций над ними.

При загрузке изображения рекомендуется использовать режим cv2.IMREAD_GRAYSCALE, чтобы преобразовать изображения в оттенки серого, для упрощения дальнейшей обработки благодаря уменьшению размерности данных. В оттенках серого каждый пиксель представлен одним числовым значением, что уменьшает размерность данных по сравнению с цветными изображениями. После загрузки изображений они преобразуются к формату с плавающей запятой и нормализуются, чтобы значения пикселей находились в диапазоне от 0 до 1 (эти операции предварительной обработки изображений подробно описаны в [22,23]).

Обучение ИНС проводилось путем аугментации (т.е. размножения множества обучающих образов), состоящей в процедуре многократного добавления аддитивного шума к исходным РЛИ. Для генерации шума с заданными параметрами использовалась стандартная в *Python* функция *пр.random.normal*.

После предварительной обработки данных происходит обучение ИНС, в качестве которой выбрана модель автокодировщика (*autoencoder*), состоящая из сверточных слоев, обрабатывающих и выходного слоев. Сверточные слои предназначены для изучения особенностей искаженных изображений (процедура выделения признаков), а слои пулинга (обрабатывающие слои) — для уменьшения размерности данных.

Модель автокодировщика выбрана с учетом ее способности обучаться извлекать компактные представления входных данных в скрытом слое. Это позволяет выделять основные особенности изображений (признаки) и уменьшать размерность данных, что оказывается весьма эффективно в задачах фильтрации шума.

Рассмотрены также и другие модели ИНС, применимые к рассматриваемой задаче — это сверточные нейронные сети (CNN), которые широко используются в обработке изображений и генеративные состязательные сети (GAN), состоящие из моделей генератора и дискриминатора. Заметим, что последние используются для генерации реалистичных изображений, что может быть полезно при создании наборов данных для обучения других ИНС обработки РЛИ.

Структура используемой модели автокодировщика представлена на рис. 1.

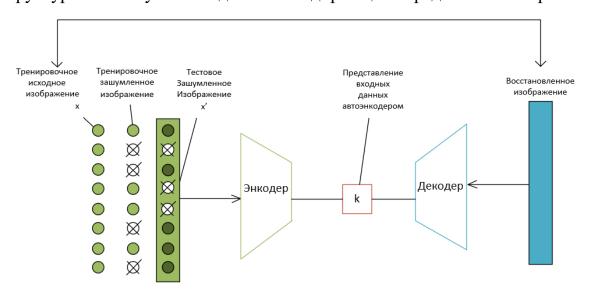


Рис. 1 – Структурная схема автокодировщика

После создания модели она компилируется с использованием оптимизатора «Adam» (команда optimizer='adam') и функции потерь «binary_crossentropy» (команда loss='binary_crossentropy'). Оптимизатор «Adam» выбран в силу хороших показателей в обучении нейронных сетей, который обладает способностью к адаптации скорости обучения для каждого параметра в сети. Он показывает стабильную производительность и эффективен для обучения различных моделей. Заметим, что возможно использование также и классического оптимизатора SGD (Stochastic Gradient Descent), который использует градиентный спуск для обновления параметров модели. Он прост в реализации, но может потребовать тщательной настройки скорости обучения и других параметров.

Для оценки потерь при ошибочном распознавании используют обычно две функции потерь. Функция «*Binary Crossentropy*» используется в задачах бинарной классификации, в том числе при работе с изображениями, где пиксели могут быть интерпретированы как бинарные значения 0 или 1. Она позволяет оценить разницу между предсказанными и истинными значениями пикселей. Другая функция потерь — «Меап Squared Error» (MSE) — измеряет среднеквадратичную ошибку между предсказанными и истинными значениями.

Модель ИНС обучается на РЛИ с помощью алгоритма обратного распространения ошибки (АОРО) (backpropagation) с использованием функции model.fit. При обучении используются как искаженные РЛИ x_train_noisy, так и исходные «чистые» (т.е. неискаженные) изображения x_train в течение заданного числа эпох epochs. Все параметры обучения ИНС задаются в пакете данных batch_size, указанные в аргументах функции fit.

В работе используется один из самых распространенных методов АОРО – градиентный спуск (*Gradient Descent*). Пример обучения сети автокодировщика приведен на рис. 2, где синие кружки представляют ошибку распознавания на обучающем множестве, а красная линия – ошибку обучения не тестовом множестве образов в зависимости от числа эпох обучения.

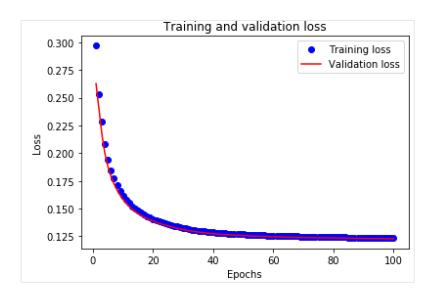


Рис. 2 – График обучения автокодировщика

Зависимость между потерями на обучающем наборе (*training loss*) и потерями на тестовом наборе (*validation loss*) от эпохи обучения — это ключевой показатель эффективности обучения ИНС. Эти метрики очень важны, так как они дают представление о том, насколько хорошо модель обобщает свои знания, а не просто запоминает обучающий набор. По этим графикам можно судить, не является ли сеть переобученной [24-26]. Увеличение потерь на тестовом наборе при уменьшении потерь на обучающем наборе может указывать на переобучение сети (подробнее о выявлении факта переобучения сети см. [24-26]). Синхронное уменьшение обеих метрик свидетельствует о хорошей обобщающей способности сети и отсутствии у нее переобучения.

Для количественного сравнения качества работы ИНС для фильтрации РЛИ по сравнению с классическими алгоритмами фильтрации используются метрики качества SSIM и PSNR [27, 28].

SSIM (Structural Similarity Index — индекс структурного сходства) — это мера сходства между двумя изображениями, которая учитывает не только различия в яркости, но и структурные изменения [27]. Она формирует оценку качества восстановления изображения, учитывая текстурные и структурные характеристики. В основе вычисления параметра SSIM лежит сравнение трех параметров изображения: яркость, контраст и структура. Большое значение SSIM указывает на высокое сходство между двумя изображениями.

Изображения x и y, которые сравниваются, разбиваются на небольшие блоки (обычно размером 8x8 пикселей), для каждого блока вычисляются яркость l, контраст c и структура s по формулам:

$$l(x,y) = \frac{2\mu_x \mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1}, \quad c(x,y) = \frac{2\sigma_x \sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2}, \quad s(x,y) = \frac{\sigma_{xy} + c_3}{\sigma_x \sigma_y + c_3},$$
(1)

где μ_x , μ_y — средние значения яркостей блоков изображений x и y соответственно; σ_x^2 , σ_y^2 — выборочные значения дисперсий блоков изображений x и y соответственно; c_1 , c_2 — константы, выбираемые с учетом размеров блоков изображений; $c_3 = c_2 / 2$. Итоговое значение показателя SSIM вычисляется как произведение значений \overline{l} , \overline{c} , \overline{s} , полученных путем усредения соответствующих параметров по всем блокам изображений x и y.

PSNR (Peak Signal-to-Noise Ratio — пиковое отношение сигнала к шуму) — это мера, используемая для измерения уровня шума в изображении относительно максимально возможного значения яркости [28]. Он измеряет отношение между максимальной яркостью изображения и уровнем шума, представленным среднеквадратичным отклонением (MSE — mean square error) между оригинальным I и восстановленным K изображениями согласно формуле

$$PSNR = 20 \lg \left(\frac{MAX_I}{\sqrt{MSE}} \right), \quad MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} |I(i,j) - K(i,j)|^2,$$
 (2)

где MAX_I — максимальное значение яркости пикселя изображения I; m, n — размеры изображений. Чем выше PSNR, тем меньше искажений в изображении и тем выше его качество.

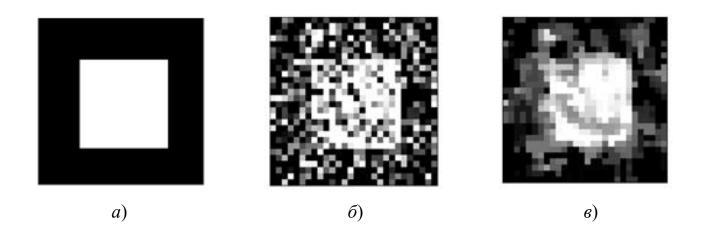
В качестве алгоритмов для сравнения в работе реализованы медианный фильтр, усредняющий фильтр и фильтр Гаусса, подробное описание которых можно найти в [22]. Для всех трех фильтров использованы окна размерами 3х3 пикселя. Размеры всех тестируемых изображений выбраны равными 28 х 28 пикселей.

На рис. 3 отображены исходное изображение (a), зашумленное изображение (δ) и результаты обработки зашумленного изображения с помощью фильтрации (e-d). Исходное изображение представляет собой квадрат с диапазоном яркостей пикселей

[0, 1]. В ходе эксперимента к исходному изображению добавлялся шум с интенсивностью 0,6 (т.е. отношение сигнал-шум меньше единицы), что приводит к значительному искажению и появлению случайных ярких и темных пикселей по всему изображению (см. рис. 3δ).

Затем зашумленное изображение обрабатывается с использованием различных фильтров. Медианный фильтр хорошо справляется с удалением шума типа "соль и перец", восстанавливая при этом общую структуру изображения (рис. 3 г). Несмотря на устранение шума, на изображении возникают некоторые потери в деталях. Усредняющий фильтр сглаживает изображение, уменьшая уровень шума (рис. 3 в). Однако, этот метод слегка размывает края квадрата, что приводит к небольшим искажениям формы. Гауссов фильтр обеспечивает более естественное размытие и эффективное снижение шума (рис. 3 д). Как и в случае с усредняющим фильтром, могут возникают небольшие искажения, но форма квадрата остается узнаваемой.

На последнем этапе изображение обрабатывается с помощью обученной ИНС типа автокодировщик (рис. 3 *e*). ИНС не только удаляет шум, но также и восстанавливает при этом форму и детали изображения с минимальными искажениями. Изображение после обработки с помощью ИНС выглядит практически так же, как исходное, что говорит о высокой способности нейросети к фильтрации шума и восстановлению исходной структуры изображения.



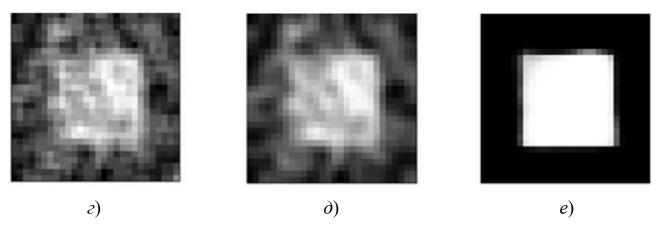


Рис. 3 — Результаты обработки изображения квадрата: a) исходное изображение, δ) зашумленное изображение, ϵ) изображение после обработки усредняющим фильтром, ϵ) изображение после обработки медианным фильтром, δ) изображение после обработки фильтром Гаусса, ϵ) изображение после обработки автокодировщиком

На рис. 4, 5 представлены аналогичные результаты восстановления изображения круга и треугольника. Как видно из рисунков, результаты восстановления фигур практически не зависят от их формы.

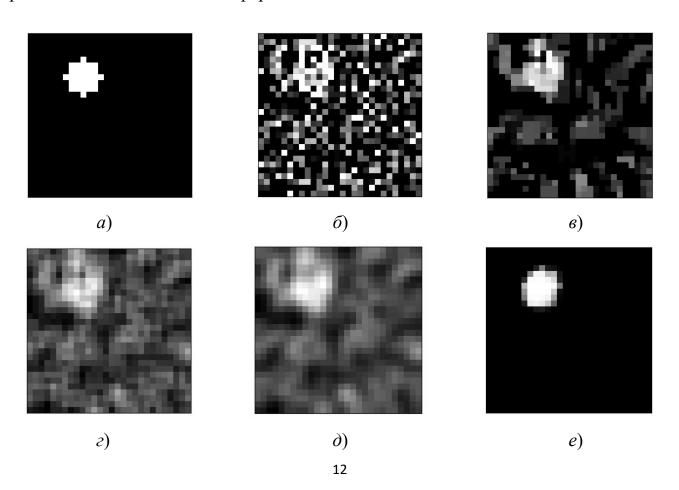


Рис. 4 — Результаты обработки изображения круга: a) исходное изображение, δ) зашумленное изображение, ϵ 0 изображение после обработки усредняющим фильтром, ϵ 2) изображение после обработки медианным фильтром, ϵ 3 изображение после обработки фильтром Гаусса, ϵ 6) изображение после обработки автокодировщиком

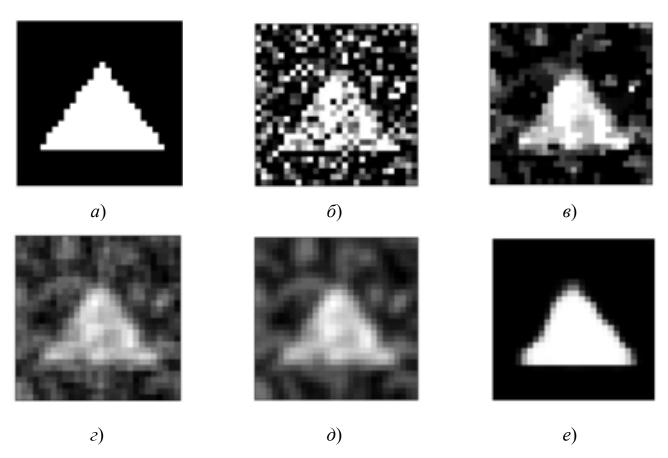


Рис. 5 — Результаты обработки изображения треугольника: a) исходное изображение, δ) зашумленное изображение, \mathbf{B}) изображение после обработки усредняющим фильтром, ϵ) изображение после обработки медианным фильтром, δ) изображение после обработки фильтром Гаусса, ϵ) изображение после обработки автокодировщиком

Исследования восстановления изображений с помощью ИНС вида автокодировщих и при использовании различных фильтров проводились и для других геометрических фигур, а также линий типа дуг и гипербол, имитирующих сигналы на двумерных РЛИ зондирования плоских поверхностей и объемных сред (сечения

трехмерных изображений в подповерхностной радиолокации). Во всех случаях ИНС демонстрировала великолепные результаты восстановления изображений. При этом работа ИНС оказалась инвариантной к масштабу изображения, его повороту и линейному смещению.

В таблице представлены полученные метрики качества работы алгоритмов фильтрации изображений и восстановления изображений с помощью ИНС (заметим, что более высокое качество восстановления изображений соответствует большим значениям показателей SSIM и PSNR). Значение метрики SSIM для изображений, обработанных нейросетью, находится в диапазоне 0,8...0,99, для остальных алгоритмов оно не поднимается выше 0,15. В метрике PSNR также видно явное преимущество обработки нейросетью — 72,08 против 58,54 после фильтра Гаусса для квадрата, 64,61 против 58,71 для круга, 67,06 против 62,43 после медианного фильтра для треугольника.

Таблица — Значения метрик качества обработки изображений разными алгоритмами

Тип фигуры	Зашумленное изображение		После медианной фильтрации		После усредняющего фильтра		После фильтра Гаусса		После обработки НС	
	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR
Квадрат	0,1146	55,94	0,0326	48,48	0,1034	58,39	0,1323	58,54	0,8553	72,08
Круг	0,1159	56,05	0,0240	44,52	0,1207	58,63	0,1481	58,71	0,8	64,61
Треугольник	0,1336	56,36	0,1363	62,43	0,1027	59,07	0,1115	59,21	0,8676	67,06
Две дуги	0,1537	56,20	0,0252	11,59	0,0326	57,96	0,0457	58,26	1,000	113,25

Заключение

Описаны этапы создания, обучения и применения искусственной нейронной сети (ИНС), предназначенной для фильтрации и повышения резкости радиолокационных изображений при наличии шумов. Результаты показали, что модель ИНС в виде автокодировщика качественно и количественно превосходит традиционные методы восстановления изображений, основанные на алгоритмах фильтрации.

Для оценки качества восстановленных изображений были использованы метрики SSIM (Structural Similarity Index) и PSNR (Peak Signal-to-Noise Ratio). Полученные значения метрик подтвердили, что модель способна восстанавливать зашумленные изображения с высоким уровнем точности и детализации. Так для изображений, обработанных нейросетью значение метрики SSIM находится в диапазоне 0,8...0,99, что существенно превышает величину этой же метрики для других алгоритмов, значение которой не превосходит 0,148.

В плане дальнейшего развития исследований и расширения вида рассмотренных моделей предполагается кратное увеличение размеров изображений, использование других видов помех, в том числе мультипликативные помехи, имитирующие спеклшумы на РСА изображениях. Кроме того, предполагается рассмотреть другие виды ИНС, в частности CNN, и тестирование их работы на экспериментальных РЛИ.

Список источников

- 1. El-Darymli K., E. W. Gill, Power D., Moloney C. Automatic target recognition in synthetic aperture radar imagery: a state-of-the-art review // IEEE Access. 2016. V. 4, P. 6014–6058. DOI: 10.1109/ACCESS.2016.2611492
- 2. Amoon M., Rezai-Rad G.A. Automatic target recognition of synthetic aperture radar (SAR) images based onoptimal selection of Zernike moments features // IET Computer Vision. 2014. V. 8, No. 2. P. 77–85. DOI: 10.1049/iet-cvi.2013.0027
- 3. Ding B., Wen G., Ma C. et al. Target recognition in synthetic aperture radar images using binary morphological operations // Journal of Applied Remote Sensing. 2016. V. 10, No. 4. DOI: 10.1117/1.JRS.10.046006
- 4. Shan C., Huang B., Li M. Binary morphological filtering of dominant scattering area residues for SAR target recognition // Computational Intelligence and Neuroscience. 2018. V. 2. DOI: 10.1155/2018/9680465
- 5. Jin L., Chen J., Peng X. Synthetic aperture radar target classification via joint sparse representation of multi-level dominant scattering images // Optik. 2019. V. 186, P. 110–119. DOI: 10.1016/j.ijleo.2019.04.014

- 6. Tan J., Fan X., Wang S. et al. Target recognition of SAR images by partially matching of target outlines // Journal of Electromagnetic Waves and Applications. 2019. V. 33, No. 7. P. 865–881. DOI: 10.1080/09205071.2018.1495580
- 7. Papson S., Narayanan R.M. Classification via the shadow region in SAR imagery // IEEE Transactions on Aerospace and Electronic Systems. 2012.V. 48, No. 2. P. 969–980. DOI: 10.1109/TAES.2012.6178042
- 8. Mishra A.K. Validation of PCA and LDA for SAR ATR // In Proceedings of the IEEE Region 10 Conference TENCON, November 2008, Hyderabad, India. P. 1–6.
- 9. Zhao Q., Principe J.C. Support vector machines for SAR automatic target recognition // IEEE Transactions on Aerospace and Electronic Systems. 2001. V. 37, No. 2. P. 643–654. DOI: 10.1109/7.937475
- 10. Liu H., Li S. Decision fusion of sparse representation and support vector machine for SAR image target recognition // Neurocomputing. 2013. V. 113, P. 97–104. DOI: 10.1016/j.neucom.2013.01.033
- 11. Tiagaraianm J.J., Ramamurthy K.N., Knee P., Spanias A., Berisha V. Sparse representations for automatic target classification in SAR images // In Proceedings of the 4th International Conference on Signal Processing and Communication Systems. March 2010. Limassol, Cyprus. P. 1–4. DOI: 10.1109/ISCCSP.2010.5463416
- 12. Song H., Ji K., Zhang Y. et al. Sparse representation-based SAR image target classification on the 10-class MSTAR data set // Applied Sciences. 2016. V. 6, No. 26. DOI: 10.3390/app6010026
- 13. Ding B., Wen G. Sparsity constraint nearest subspace classifier for target recognition of SAR images // Journal of Visual Communication and Image Representation. 2018. V. 52, P. 170–176. DOI: 10.1016/j.jvcir.2018.02.012
- 14. Kang M., Ji K., Leng X. et al. Synthetic aperture radar target recognition with feature fusion based on a stacked autoencoder // Sensors. 2017. V. 17, No. 1. P. 192. DOI: 10.3390/s17010192
- 15. Morgan D.E. Deep convolutional neural networks for ATR from SAR imagery // Proceedings of the SPIE. 2015. V. 9475, P. 1–13. DOI: 10.1117/12.2176558

- 16. Chen S., Wang H., Xu F. et al. Target classification using the deep convolutional networks for SAR images // IEEE Geoscience and Remote Sensing Letters. 2016. V. 47, No. 6. P. 1685–1697. DOI: 10.1109/TGRS.2016.2551720
- 17. Zhao J., Zhang Z., Yu W. et al. A cascade coupled convolutional neural network guided visual attention method for ship detection from SAR images // IEEE Access. 2018. V. 6, P. 50693–50708. DOI: 10.1109/ACCESS.2018.2869289
- 18. Min R., Lan H., Cao Z. et al. A gradually distilled CNN for SAR target recognition IEEE Access. 2019. V. 7, P. 42190–42200. DOI: 10.1109/ACCESS.2019.2906564
- 19. Олькина Д.С. Алгоритм семантической сегментации изображений для решения задачи позиционирования летательного аппарата на земной поверхности // Труды МАИ. 2023. № 130. URL: https://trudymai.ru/published.php?ID=174617. DOI: 10.34759/trd-2023-130-18
- 20. Черников А.А. Алгоритм обнаружения и классификации объектов на неоднородном фоне для оптико-электронных систем // Труды МАИ. 2023. № 129. URL: https://trudymai.ru/published.php?ID=173039. DOI: 10.34759/trd-2023-129-26
- 21. Коваль Н.А. Сравнительный анализ нейросетевых архитектур в задаче обнаружения и различения сигналов цели и уводящей помехи // Труды МАИ. 2024. № 134. URL: https://trudymai.ru/published.php?ID=178473
- 22. Гаврилов К.Ю., Каменский И.В., Кирдяшкин И.В. Цифровая обработка изображений в Matlab. М.: Горячая линия Телеком. 2025. 160 с.
- 23. Гаврилов К.Ю., Каменский К.В., Малютина О.А. Моделирование траекторного сигнала в радаре с синтезированием апертуры на основе оптических изображений земной поверхности // Труды МАИ. 2021. № 118. URL: https://trudymai.ru/published.php?ID=158252. DOI: 10.34759/trd-2021-118-12
- 24. Николенко С., Кадурин А., Архангельская Е. Глубокое обучение. СПб: Питер, 2018. 480 с.
- 25. Antonio Gulli, Anita Kapoor, Sujit Pal. Deep Learning with TensorFlow2 and Keras. -Birmingham-Mumbai, Packet Publishing, 2019. 646 p.
- 26. Шолле Ф. Глубокое обучение на Python. СПб: Питер, 2018. 576 с.

- 27. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image Quality Assessment: From Error Visibility to Structural Similarity // IEEE Transactions on Image Processing. 2004. V. 13, Issue 4. P. 600-612. DOI: 10.1109/TIP.2003.819861
- 28. Rajiv Kumar Gurjwar, Divya Rishi Sahu, Deepak Singh Tomar. An Approach to Reveal Website Defacement // International Journal of Computer Science and Information Security. June 2013. V. 11, no. 6.

References

- 1. El-Darymli K., E. W. Gill, Power D., Moloney C. Automatic target recognition in synthetic aperture radar imagery: a state-of-the-art review. *IEEE Access*. 2016. V. 4, P. 6014–6058. DOI: 10.1109/ACCESS.2016.2611492
- 2. Amoon M., Rezai-Rad G.A. Automatic target recognition of synthetic aperture radar (SAR) images based onoptimal selection of Zernike moments features. *IET Computer Vision*. 2014. V. 8, No. 2. P. 77–85. DOI: 10.1049/iet-cvi.2013.0027
- 3. Ding B., Wen G., Ma C. et al. Target recognition in synthetic aperture radar images using binary morphological operations. *Journal of Applied Remote Sensing*. 2016. V. 10, No. 4. DOI: 10.1117/1.JRS.10.046006
- 4. Shan C., Huang B., Li M. Binary morphological filtering of dominant scattering area residues for SAR target recognition. *Computational Intelligence and Neuroscience*. 2018. V. 2. DOI: 10.1155/2018/9680465
- 5. Jin L., Chen J., Peng X. Synthetic aperture radar target classification via joint sparse representation of multi-level dominant scattering images. *Optik.* 2019. V. 186, P. 110–119. DOI: 10.1016/j.ijleo.2019.04.014
- 6. Tan J., Fan X., Wang S. et al. Target recognition of SAR images by partially matching of target outlines. *Journal of Electromagnetic Waves and Applications*. 2019. V. 33, No. 7. P. 865–881. DOI: 10.1080/09205071.2018.1495580
- 7. Papson S., Narayanan R.M. Classification via the shadow region in SAR imagery. *IEEE Transactions on Aerospace and Electronic Systems*. 2012.V. 48, No. 2. P. 969–980. DOI: 10.1109/TAES.2012.6178042

- 8. Mishra A.K. Validation of PCA and LDA for SAR ATR. *In Proceedings of the IEEE Region 10 Conference TENCON*, November 2008, Hyderabad, India. P. 1–6.
- 9. Zhao Q., Principe J.C. Support vector machines for SAR automatic target recognition. *IEEE Transactions on Aerospace and Electronic Systems*. 2001. V. 37, No. 2. P. 643–654. DOI: 10.1109/7.937475
- 10. Liu H., Li S. Decision fusion of sparse representation and support vector machine for SAR image target recognition. *Neurocomputing*. 2013. V. 113, P. 97–104. DOI: 10.1016/j.neucom.2013.01.033
- 11. Tiagaraianm J.J., Ramamurthy K.N., Knee P., Spanias A., Berisha V. Sparse representations for automatic target classification in SAR images. In Proceedings of the 4th International Conference on Signal Processing and Communication Systems. March 2010. Limassol, Cyprus. P. 1–4. DOI: 10.1109/ISCCSP.2010.5463416
- 12. Song H., Ji K., Zhang Y. et al. Sparse representation-based SAR image target classification on the 10-class MSTAR data set. *Applied Sciences*. 2016. V. 6, No. 26. DOI: 10.3390/app6010026
- 13. Ding B., Wen G. Sparsity constraint nearest subspace classifier for target recognition of SAR images. *Journal of Visual Communication and Image Representation*. 2018. V. 52, P. 170–176. DOI: 10.1016/j.jvcir.2018.02.012
- 14. Kang M., Ji K., Leng X. et al. Synthetic aperture radar target recognition with feature fusion based on a stacked autoencoder. *Sensors*. 2017. V. 17, No. 1. P. 192. DOI: 10.3390/s17010192
- 15. Morgan D.E. Deep convolutional neural networks for ATR from SAR imagery. *Proceedings of the SPIE*. 2015. V. 9475, P. 1–13. DOI: <u>10.1117/12.2176558</u>
- 16. Chen S., Wang H., Xu F. et al. Target classification using the deep convolutional networks for SAR images. *IEEE Geoscience and Remote Sensing Letters*. 2016. V. 47, No. 6. P. 1685–1697. DOI: 10.1109/TGRS.2016.2551720
- 17. Zhao J., Zhang Z., Yu W. et al. A cascade coupled convolutional neural network guided visual attention method for ship detection from SAR images. *IEEE Access*. 2018. V. 6, P. 50693–50708. DOI: 10.1109/ACCESS.2018.2869289

- 18. Min R., Lan H., Cao Z. et al. A gradually distilled CNN for SAR target recognition. *IEEE Access*. 2019. V. 7, P. 42190–42200. DOI: 10.1109/ACCESS.2019.2906564
- 19. Ol'kina D.S. Algorithm of semantic image segmentation for solving the problem of positionong an aircraft on the Earth's surface. *Trudy MAI*. 2023. No. 130. (In Russ.). URL: https://trudymai.ru/eng/published.php?ID=174617. DOI: 10.34759/trd-2023-130-18
- 20. Chernikov A.A. Algorithm for detecting and classification of objects on a unhomogeneous background for optoelectronic systems. *Trudy MAI*. 2023. No. 129. (In Russ.). URL: https://trudymai.ru/eng/published.php?ID=173039. DOI: 10.34759/trd-2023-129-26
- 21. Koval' N.A. Comparative analysis of neural network architectures in the task of detection and identification of target and velocity jammer signals. *Trudy MAI*. 2024. No. 134. (In Russ.). URL: https://trudymai.ru/eng/published.php?ID=178473
- 22. Gavrilov K.Yu., Kamensky I.V., Kirdyashkin I.V. Digital image processing in Matlab. Moscow: Goryachaya Liniya Telecom Publ., 2025. 160 p.
- 23. Gavrilov K.Yu., Kamenskii K.V., Malyutina O.A. Trajectory signal modelling in the aperture synthesis radar based on optical images of the Earth surface. *Trudy MAI*. 2021. No. 118. (In Russ.). URL: https://trudymai.ru/eng/published.php?ID=158252. DOI:

10.34759/trd-2021-118-12

- 24. Nikolenko S., Kadurin A., Arkhangel'skaya E. *Glubokoe obuchenie* (Deep learning). Saint Petersburg: Piter Publ., 2018. 480 p.
- 25. Antonio Gulli, Anita Kapoor, Sujit Pal. *Deep Learning with TensorFlow2 and Keras*. -Birmingham-Mumbai, Packet Publishing, 2019. 646 p.
- 26. Sholle F. *Glubokoe obuchenie na Python* (Deep Learning in Python). Saint Petersburg: Piter Publ., 2018. 576 p.
- 27. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image Quality Assessment: From Error Visibility to Structural Similarity. *IEEE Transactions on Image Processing*. 2004. V. 13, Issue 4. P. 600-612. DOI: 10.1109/TIP.2003.819861
- 28. Rajiv Kumar Gurjwar, Divya Rishi Sahu, Deepak Singh Tomar. An Approach to Reveal Website Defacement. *International Journal of Computer Science and Information Security*. June 2013. V. 11, no. 6.

Статья поступила в редакцию 20.03.2025

Одобрена после рецензирования 26.03.2025

Принята к публикации 25.04.2025

The article was submitted on 20.03.2025; approved after reviewing on 26.03.2025; accepted for publication on 25.04.2025