

УДК 621.397

МОДИФИКАЦИЯ АЛГОРИТМА КЛАССИФИКАЦИИ ШУМОВ НА ИЗОБРАЖЕНИЯХ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННОЙ СЕТИ ОБРАТНОГО РАСПРОСТРАНЕНИЯ ОШИБКИ

В. Т. Дмитриев, д.т.н., доцент, заведующий кафедрой РУС РГРТУ, Рязань, Россия;
orcid.org/0000-0001-5521-6886, e-mail: vol77@rambler.ru

Е. С. Черентаева, аспирант РГРТУ, Рязань, Россия;
orcid.org/0000-0002-5580-3033, e-mail: culikoa4199@yandex.ru

М. А. Черентаев, аспирант РГРТУ, Рязань, Россия;
orcid.org/0000-0002-0282-7250, e-mail: cherentaev.mikhail@gmail.com

Разработана модификация алгоритма классификации шумов на изображениях с использованием нейронной сети обратного распространения ошибки. Целью работы является классификация шумов с помощью нейронной сети с модификацией предварительного алгоритма обработки с увеличением количества слоев нейронной сети, а также проверка полученного классификатора на наборе реальных спутниковых изображений. Разработан алгоритм предварительной обработки данных для обучения нейронной сети. Получены значения вероятностей верного определения вида шума, проведено их сравнение со значениями для других известных методов классификации. Показано, что модифицированная нейронная сеть обеспечивает лучшую классификацию для мультипликативного и гауссовского шумов по сравнению с известными алгоритмами.

Ключевые слова: классификация шумов на изображениях, модели шумов, шумоподавление изображений, фильтрация изображений, статистический момент, многослойная нейронная сеть, метод обратного распространения ошибки, градиентный спуск.

DOI: 10.21667/1995-4565-2024-90-22-31

Введение

При передаче и обработке изображения подвергаются воздействию шумов, которые создают искажения полезной информации на изображении. Подавление шума можно осуществлять с помощью различных алгоритмов фильтрации [1-5]. Выбор эффективного алгоритма обработки изображения зависит от параметров шума, поэтому необходима разработка алгоритма, который осуществляет идентификацию шума из ряда возможных.

Известно несколько методов автоматической идентификации шума: метод, основанный на анализе локальных гистограмм [6]; методы, использующие критерий максимального правдоподобия для выбора наиболее однородных масок, из которых вычисляются значения локальных стандартных отклонений [3-5]; неконтролируемая вариационная классификация с помощью метода многопорогового определения [7] и другие.

Активное применение для классификации шумов на изображениях нашли методы на основе анализа локальных гистограмм и методы, использующие критерий максимального правдоподобия для выбора наиболее однородных масок. Данные методы широко применяются в области обработки изображений, поскольку они позволяют эффективно оценивать характеристики шумов и выделять участки с различной степенью шумности, что обеспечит успешную классификацию.

Метод анализа локальных гистограмм позволяет исследовать распределение значений интенсивности пикселей в локальных областях изображения, что помогает определить присутствие шумов. Методы, основанные на критерии максимального правдоподобия, используются для оценки вероятностей принадлежности пикселей к различным классам (например, шум или не шум) и нахождения наиболее однородных масок, что также эффективно для классификации шумов.

Неконтролируемая вариационная классификация с многопороговым определением также имеет свою область применения, но на практике часто встречаются первые два метода, которые более прямолинейны в подходе к классификации шумов. В общем, выбор метода может зависеть от конкретной задачи, требований к производительности и доступности данных для тестирования.

В настоящее время перспективный класс алгоритмов обработки – нейронные сети. Данный класс алгоритмов нашел применение в различных областях, в частности в задачах обработки изображений, в том числе в задачах классификации [8, 9]. Преимущества нейронных сетей перед вышеперечисленными алгоритмами – в возможности объединить в себе их основные достоинства и при этом решать большее количество задач одновременно. Одной из главных причин использования нейронных сетей для классификации шумов является способность этого класса алгоритмов выделять довольно сложные неявные зависимости между признаками объектов и их действительным классом, то есть выполнять классификацию в линейно неразделимых случаях.

Цель данной работы – разработка алгоритма классификации различных шумов как аддитивных (импульсный, равномерный, гауссовский), так и мультипликативных (спекл-шум) на основе многослойной нейронной сети обратного распространения ошибки, тестирование разработанного алгоритма на наборе спутниковых снимков поверхности из открытого архива материалов дистанционного зондирования Земли EarthExplorer, а также сравнение результатов с вышеупомянутыми методами автоматической идентификации шума. В качестве базового использовался алгоритм, представленный в [8], основанный на нейронной сети с одним полностью связанным скрытым слоем из 10 нейронов.

Модели исследуемого шума

Исходное изображение описывается функцией $f(x, y)$, где (x, y) – пространственные координаты, f – интенсивность (яркость) в точке (x, y) . Зашумленное изображение и шум соответственно задаются функциями $g(x, y)$ и $n(x, y)$.

Существует три основные шумовые модели [10], которые характеризуют большинство шумов, встречающихся на изображениях: аддитивный шум, мультипликативный шум и импульсный шум. Аддитивный шум задается следующим выражением:

$$g(x, y) = f(x, y) + n(x, y). \quad (1)$$

Шумы, описанные формулой (1), не зависят от значения яркости пикселей исходного изображения и обычно симметричны относительно нулевого значения яркости, при небольших отклонениях от которого будут изменяться только элементы изображения наибольшей и наименьшей яркости. Аддитивная шумовая модель характеризует тепловой шум, шум зернистости фотопленки, шум квантования, флуктуационный шум в радиотехнических приборах и некоторые другие.

Мультипликативный шум (спекл-шум) является сигнально-зависимым, выражение для него можно представить в следующем виде:

$$g(x, y) = f(x, y) + n(x, y) \cdot f(x, y) \quad (2)$$

или в виде следующего выражения:

$$g(x, y) = f(x, y) \cdot [1 + n(x, y)].$$

Импульсный шум возникает при повреждении пикселей изображения из-за ошибок в канале связи, физического несовершенства устройства, проявляется как случайные изолированные пиксели с существенно отличающимися значениями. В англоязычной литературе называется шумом «соли и перца» из-за характерных случайных пикселей черного и белого цвета в черно-белых изображениях.

В работе рассмотрены четыре наиболее распространенных вида шумов, два из которых имеют аддитивную природу – равномерный белый, гауссовский, один описывается мультипликативной моделью – спекл-шум и один – импульсный шум.

В таблице 1 приведены характеристики для рассматриваемых шумов, такие как теоретическое распределение шума, дисперсия σ^2 и среднее значение шума μ . Для импульсного и равномерного распределения случайная величина интенсивности пикселей накладываемого шума $n(x, y)$ ограничена a и b – минимальным и максимальным значениями интенсивности, другие рассмотренные распределения не ограничены. P_a и P_b – вероятности замены пикселей пикселями с минимальным или максимальным значениями яркости соответственно. В разработанном алгоритме использовалась модель спекл-шума на основе распределения Релея.

Интенсивность импульсного шума определяется вероятностями замены пикселя. Рассматриваемый равномерный белый шум – стационарный, и его интенсивность постоянна. Для гауссовского и спекл-шума интенсивность характеризуется дисперсией (таблица 1).

Таблица 1 – Характеристики рассматриваемых шумов
Table 1 – Characteristics of noises

Шум	Теоретическое распределение шума $p(n)$	Среднее значение μ	Дисперсия σ^2
Импульсный	$\begin{cases} P_a & \text{для } n = a, \\ P_b & \text{для } n = b, \\ 1 - P_a - P_b & \text{для } n \neq a, n \neq b \end{cases}$	-	-
Равномерный белый	$\frac{1}{b-a} \quad \text{для } a \leq n \leq b$	$\frac{1}{2}(a+b)$	$\frac{(b-a)^2}{12}$.
Гауссовский	$\frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(n-m)^2}{2\sigma^2}\right)$	m	σ^2
Спекл-шум	$\begin{cases} \frac{n}{\sigma^2} \exp\left(-\frac{n^2}{2\sigma^2}\right) & \text{если } n \geq 0, \\ 0 & \text{если } n < 0 \end{cases}$	$\sqrt{\frac{\pi}{2}}\sigma$	$\left(2 - \frac{\pi}{2}\right)\sigma^2$.

При непосредственном добавлении шума к цифровому изображению его интенсивность ограничивается дискретными случайными значениями $i = 0, 1, \dots, L-1$, где L – число возможных значений интенсивности.

Статистические характеристики шума, используемые в эксперименте

В качестве признаков шума используют статистические функции [8], такие как среднее значение, медиана, стандартное отклонение и другие. Среднее значение и дисперсия представляют информацию о местоположении и изменчивости (разброс, дисперсия) набора чисел и тем самым позволяют получить некоторую информацию о внешнем виде распределения. Среднее значение и дисперсия являются первыми двумя статистическими моментами, а третий и четвертый моменты также предоставляют информацию о форме распределения.

Пусть $i = 0, 1, \dots, L-1$ – дискретная случайная величина, которая обозначает уровни интенсивности на изображении, где L – число возможных значений интенсивности; $p(i)$ – вероятность возникновения случайной величины i ; K – порядок центрального статистического момента. Функция центрального момента [8] определяется следующей формулой (3):

$$\mu_K = \sum_{i=0}^{L-1} (i-m)^K p(i). \quad (3)$$

Математическое ожидание – начальный момент первого порядка вычисляется по следующей формуле (4):

$$m = \sum_{i=0}^{L-1} ip(i). \quad (4)$$

Стандартное отклонение – второй центральный момент функции распределения вычисляется по формуле (5):

$$\sigma = \sqrt{\mu_2} = \sqrt{\sigma^2}. \quad (5)$$

Третий центральный момент характеризует асимметрию функции распределения (6):

$$\mu_3 = \sum_{i=0}^{L-1} (i-m)^3 p(i). \quad (6)$$

Четвертый центральный момент определяется по формуле (7) и влияет на величину эксцесса ($E = \frac{\mu_4}{\sigma^4} - 3$), который измеряет остроту распределения относительно гауссовского распределения. Отрицательный эксцесс означает, что пик шире гауссовского. Положительный эксцесс означает, что распределение острее гауссовского. Нулевой эксцесс характерен для гауссовского распределения ($\frac{\mu_4}{\sigma^4} = 3$).

$$\mu_4 = \sum_{i=0}^{L-1} (i-m)^4 p(i). \quad (7)$$

Пятый центральный момент позволяет дополнительно оценить асимметрию распределения и определяется следующим выражением:

$$\mu_5 = \sum_{i=0}^{L-1} (i-m)^5 p(i). \quad (8)$$

Алгоритм предварительной обработки изображений

Для обучения нейронных сетей необходим большой объём данных с заранее определёнными целевой переменной и признаками объекта, по которым будет происходить классификация. Для решения задачи классификации шума на изображении в качестве признаков шума выбраны математическое ожидание и центральные статистические моменты (от 2-го до 5-го порядка), так как они довольно полно описывают поведение ФПРВ случайной величины. Взаимосвязь значения центральных статистических моментов выше 5-го порядка и вида ФПРВ в литературе не описана. В качестве целевой переменной выбран вид шума.

Для получения вышеописанного набора данных для обучения нейронной сети разработан алгоритм предварительной обработки изображения (рисунок 1), который включает в себя следующие этапы [11-14].

1. Кадрирование изображения: приведение к одному размеру, выбор только информативной части.

2. Перевод изображения в оттенки серого.

3. Наложения шумов в соответствии с описанными в таблице 1 функциями описания шума (равномерного, гауссовского, импульсного или спекл-шума) и в соответствии с формулами (1) и (2).

4. Фильтрация шума проводилась последовательно усредняющим и медианным фильтрами. Кроме того, на том же наборе данных использовался гауссовский фильтр. Маски фильтров выбраны размером 3x3 в связи с малым размером локальных областей искажённых шумом пикселей.

5. Получение шаблона шума путем вычитания из значений пикселей зашумленного изображения значений пикселей после фильтрации.

6. Для полученных шаблонов шума осуществляется вычисление статистических моментов в соответствии с выражениями (4) – (8).

Модифицированный алгоритм предварительной обработки изображений улучшен по сравнению с базовым алгоритмом [8], в котором на обрабатываемом наборе данных отдельно использовались медианный и усредняющий фильтры, введением дополнительной ступени фильтрации, а именно последовательным применением усредняющего и медианного фильтров, и отдельным применением гауссовской фильтрации. Представленная модификация позволяет лучше выделять шумы, тем самым позволяя нейронной сети лучше обучаться на полученном наборе данных.

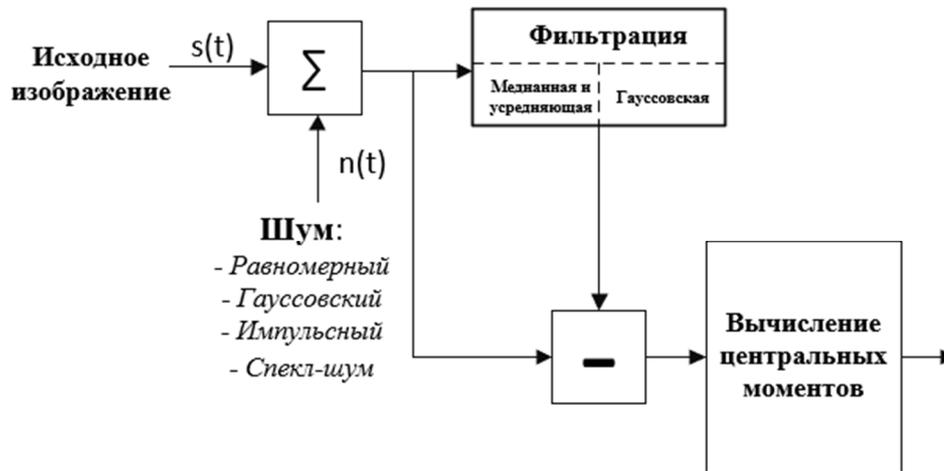


Рисунок 1 – Алгоритм предварительной обработки изображения
Figure 1 – Image preprocessing algorithm

Полученный в результате работы алгоритма набор данных в дальнейшем используется для обучения и тестирования нейронной сети, причем 70 % набора данных выделяют для обучения, 30 % – для тестирования [15].

Обучение нейронной сети методом обратного распространения ошибки

Для классификации шумов по вычисленным пяти статистическим моментам использовалась классическая полносвязная нейронная сеть прямого распространения [15, 16], состоящая из четырех слоев (рисунок 2), а именно: входной слой, представленный пятью нейронами по количеству входных признаков; два скрытых полносвязных слоя с 14-ю нейронами в каждом; выходной слой из четырех нейронов – по одному нейрону на каждый класс шума. Пять нейронов входного слоя кодируются пятью статистическими моментами.

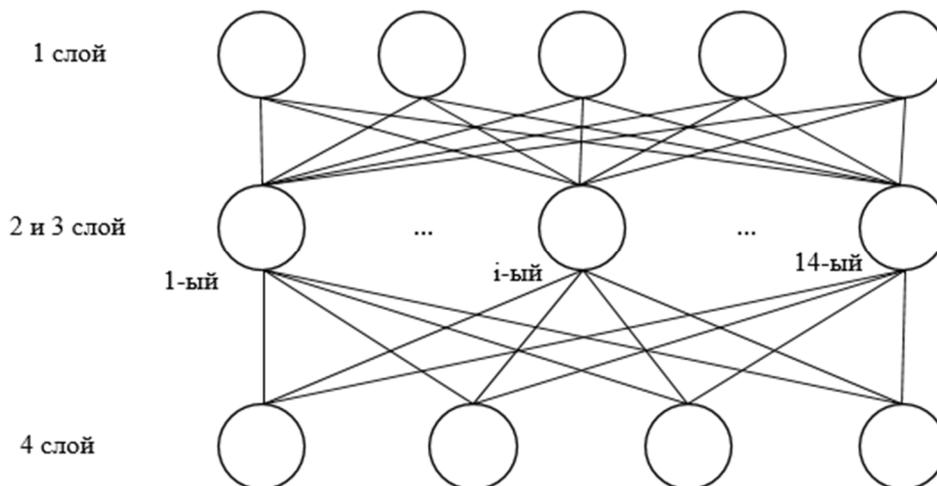


Рисунок 2 – Представление слоев нейронной сети
Figure 2 – Representation of neural network layers

Структуру нейронной сети также можно представить в виде цепочки, показанной на рисунке 3.

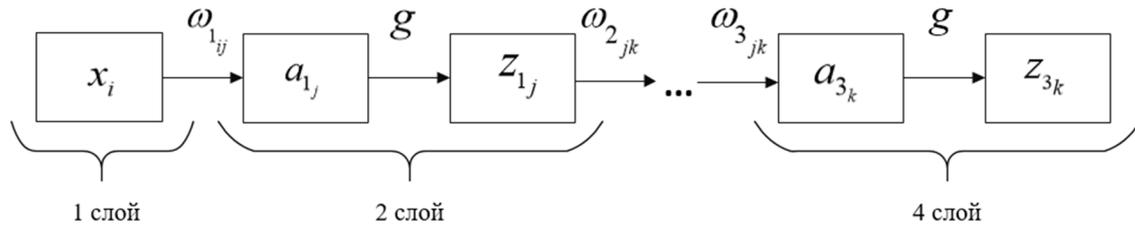


Рисунок 3 – Структура нейронной сети
Figure 3 – Structure of neural network

На рисунке 3 введены следующие обозначения: $i = 1, 2, \dots, 5$, $j = 1, 2, \dots, 14$, $k = 1, 2, \dots, 4$, x_i – входное значение i -го нейрона сети, a_{1_j} и a_{3_k} – j -я и k -я взвешенные суммы входных значений, $\omega_{1_{ij}}$ – синаптические весовые коэффициенты между i -ми и j -ми нейронами после первого слоя, z_{1_j} и z_{3_k} – результаты применения функции активации (значения слоев), g – функция активации. В соответствии с рисунками 2 и 3 результаты работы слоёв нейронной сети можно представить в виде следующих выражений:

$$a_{1_j} = \sum_i x_i \omega_{1_{ij}}, z_{1_j} = g(a_{1_j}), \tag{9}$$

$$a_{2_k} = \sum_j z_{1_j} \omega_{2_{jk}}, z_{2_k} = g(a_{2_k}). \tag{10}$$

В качестве функции активации в 1 – 3-м слоях использовалась функция ReLU (rectified linear) – формула (11), которая преобразует отрицательные значения в 0, в то время как положительные значения оставляет без изменений, что способствует быстрой сходимости, ускоряет обучение сети и улучшает ее производительность. Но ReLU плохо подходит для последнего слоя с множественными классами, так как не имеет возможности моделировать вероятностные распределения, поэтому также использовалась многопеременная логистическая функция активации SoftMax – формула (11).

$$f(x) = x^+ = \max(0, x) = \frac{x + |x|}{2} = \begin{cases} x & \text{если } x > 0, \\ 0 & \text{если } x \leq 0. \end{cases} \tag{11}$$

$$\sigma(z)_i = e^{z_i} / \sum_{k=1}^4 e^{z_k}. \tag{12}$$

Для вычисления ошибки необходимо вычислить градиент функции потерь для нейронной сети, представленной на рисунке 3 по следующей формуле:

$$\frac{\partial \delta}{\partial \omega_{i,j}} = \frac{\partial \delta}{\partial a_j} \frac{\partial a_j}{\partial \omega_{i,j}} = x_i \frac{\partial \delta}{\partial a_j},$$

где δ – функция потерь нейронной сети.

Функция потерь для 4-х классов классификации определяется по формуле:

$$\delta = - \sum_{i=1}^4 y_i \ln(z_i), \tag{13}$$

где l – число нейронов в слое, y_i - истинное значение вероятности данного класса.

Обновление весовых коэффициентов нейронной сети осуществлялось в соответствии с выражением:

$$\omega' = \omega - \eta \delta \frac{dg(x)}{dx} z, \tag{14}$$

где ω' – обновленное значение весового коэффициента, ω – предыдущее значение весового коэффициента, η – скорость обучения, x – входная информация, z – выходное значение

слоя, $g(x)$ – функция активации. Для обучения нейронной сети использовался метод обратного распространения ошибки по следующему алгоритму.

1. Инициализация весовых коэффициентов нейронной сети осуществлялась случайным образом.

2. Прямой проход нейронной сети: вычисление взвешенных сумм каждого слоя и применение к рассчитанным значениям функций активаций в соответствии с выражениями (9) – (12).

3. Вычисление градиента функции потерь – использована функция потерь перекрестной энтропии, значения которой вычисляются по формуле (13).

4. Корректировка весовых коэффициентов нейронной сети осуществляется в соответствии с формулой (14).

5. Повтор шагов 2...4 по всему объему обучающей выборки с учетом выбранного количества эпох N .

6. Проверка нейронной сети на тестовой выборке: расчет точности предсказания - вычисление соотношения изображений с правильно классифицированными шумами к общему числу тестовых изображений.

Результаты экспериментальных исследований предложенного алгоритма

В качестве исходного набора данных для обработки использовано 2 000 изображений. Далее каждое изображение преобразовано по вышеописанному алгоритму предварительной обработки, и получен набор данных из 8 000 снимков (по 2 000 на каждый класс шума), в котором каждому изображению соответствуют пять статистических моментов. Случайным образом полученный набор данных разделен в соотношении 70 % к 30 % соответственно для обучения и тестирования нейронной сети. Число эпох обучения $N = 4000$.

В таблице 2 приведены частоты верного и ошибочного определения вида шума (в скобках указаны значения полученные, с помощью базового алгоритма): импульсный шум в 93 % случаях обнаружен верно, в 6 % определится как равномерный и в 1 % – как гауссовский; равномерный белый определяется верно в 90% случаях; гауссовский – 97 %; спекл-шум – 96 %.

Таблица 2 - Частота определения вида шума для разработанной нейронной сети
Table 2 – Frequency of determining the noise class for the developed neural network

	Импульсный	Равномерный белый	Гауссовский	Спекл-шум
Импульсный	0,93 (0,9)	0,06 (0,05)	0,01 (0,04)	0 (0,01)
Равномерный белый	0,02 (0,04)	0,9 (0,88)	0,05 (0,06)	0,03 (0,02)
Гауссовский	0 (0)	0,02 (0,03)	0,97 (0,94)	0,01 (0,03)
Спекл-шум	0,01 (0,02)	0,015 (0,03)	0,015 (0,01)	0,96 (0,94)

В качестве метрики для оценки качества работы нейронной сети выбрана точность предсказания ε , показывающая соотношение правильных ответов к общему числу ответов. Общая точность предсказания класса шума, присутствующего на изображении, разработанной нейронной сети, составляет 94 %. На рисунке 4 представлены графики зависимостей показателя точности предсказания ε во время обучения нейронной сети (а), а также значение функции потерь δ во время обучения (б).

Таким образом, модификация алгоритма классификации шумов [8] путём изменения блока фильтрации обеспечивает выигрыш $\Delta\varepsilon$ в классификации для гауссовского и импульсного шума – 3 %, для равномерного и спекл-шума – 2 %, а дополнительное увеличение глубины нейронной сети и добавление нейронов в скрытые слои позволяют улучшить результаты на 0,1 – 0,5 %.

Особенностью данного алгоритма, как и всех нейронных сетей, является необходимость подготовки набора данных для обучения и тестирования сети, поэтому дальнейшее увеличе-

ние показателей качества работы предложенного алгоритма видится в лучшем отборе изображений и в улучшении алгоритма предварительной обработки изображений либо в построении нейронной сети с использованием более сложных архитектур, таких как сверточные нейронные сети, моделей трансформеров, ансамблей моделей различных видов, таких как «случайный лес».

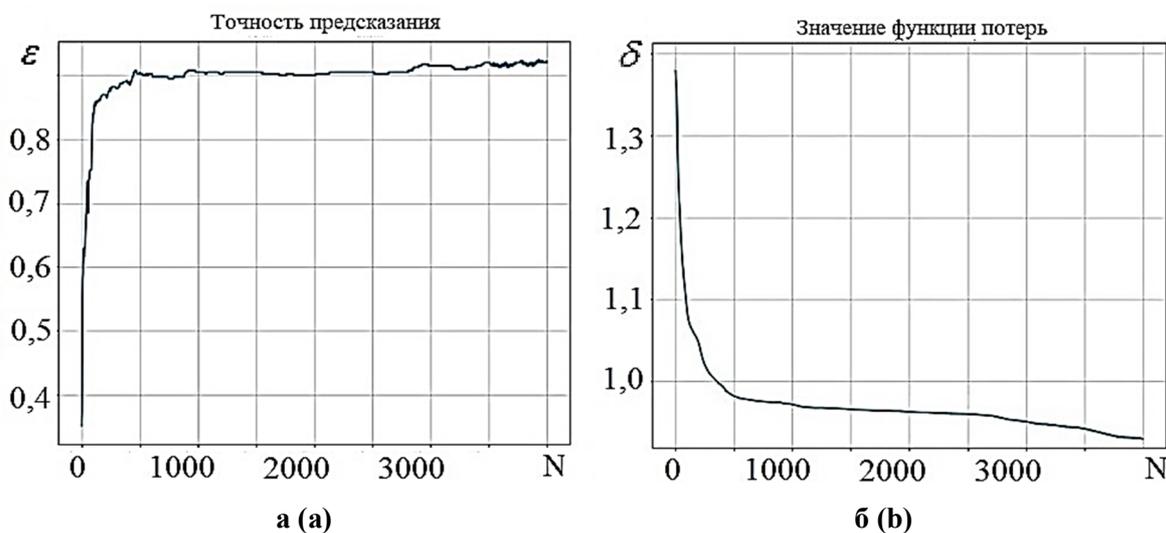


Рисунок 4 – Характеристики точности предсказания (а) и функции потерь нейронной сети (б)
Figure 4 – Characteristics of prediction accuracy (a) and loss function (b) of neural network

Заключение

Предложена модификация алгоритма классификации шумов на изображениях с использованием нейронной сети обратного распространения ошибки. Разработан классификатор на основе нейронной сети на полносвязных слоях. Проведено обучение нейронной сети методом обратного распространения ошибки. Результаты тестирования полученного алгоритма показывают высокую общую точность классификации шумов на уровне 94 %, для импульсного, равномерного белого, гауссовского и спекл-шума точность классификации составила соответственно 93 %, 90 %, 97 %, 96 %. Таким образом, в результате применения предложенного алгоритма выигрыш в точности классификации наиболее распространенных гауссовского и импульсного шума составила 3 %, для равномерного и спекл-шума – 2 % по сравнению с использованием базового алгоритма, представленного в [8], на том же наборе данных. Преимуществом разработанного алгоритма является повышение точности классификации шумов за счет предложенной модификации.

Библиографический список

1. Сафонов А.А. Подавление шумов на изображениях с использованием пространственной и частотной фильтрации // Вестник науки. 2024. Т. 1. № 7(76). С. 593-598.
2. Каламбет Ю.А., Козьмин Ю.П., Самохин А.С. Фильтрация шумов. Сравнительный анализ методов // Аналитика. 2017. Т. 36. № 5. С. 88-101.
3. Nagao M. and Matsuyama T. Edge preserving smoothing // Computer graphics and image processing. 1979, no 9, pp. 394-407.
4. Jong-Sen Lee. Digital image smoothing and the sigma filter // Computer Vision, Graphics, and Image Processing. 1983, vol. 24, is. 2, pp. 255-269.
5. Jong-Sen Lee. Speckle analysis and smoothing of synthetic aperture radar images // Computer Graphics and Image Processing. 1981, vol. 17, is. 1, pp. 24-32.
6. L. Beaureper, K. Chehdi, B. Vozel. Identification of the nature of noise and estimation of its statistical parameters by analyzing local histograms // IEEE International Conference on Acoustics, Speech and Signal Processing. 1997, vol. 4, pp. 2805-2808.

7. **Benoit Vozel, Kacem Chehdi, Luc Klaine, Lukin V.V., Abramov S.K.** Noise Identification and Estimation of its Statistical Parameters by Using Unsupervised Variational Classification // IEEE International Conference on Acoustics Speech and Signal Processing. 2006, pp. 841-844.
8. **Tiwari, Shamik & Singh, Ajay & Shukla, Vidya Prasad.** Statistical Moments based Noise Classification using Feed Forward Back Propagation Neural Network // International Journal of Computer Applications. 2011, vol. 18, no. 2, pp. 36-40.
9. **Santhanam T., Radhika S.** A Novel Approach to Classify Noises in Images Using Artificial Neural Network // Journal of Computer Science. 2010, vol. 6(5), pp. 506-510.
10. **Гонсалес Р.** Цифровая обработка изображений. М.: Техносфера, 2012. 1104 с.
11. **Дмитриев В.Т., Сконников П.Н.** Сравнительный анализ алгоритмов комплексирования изображений различных спектральных диапазонов // Вестник Рязанского государственного радиотехнического университета. 2021. № 78. С.29-37.
12. **Дмитриев В.Т., Бауков А.А.** Многокритериальный синтез алгоритма обнаружения частиц дождя на видеоизображениях в цифровых системах телевидения // Вестник Рязанского государственного радиотехнического университета. 2022. № 79. С. 20-30.
13. **Дмитриев В.Т., Бауков А.А.** Разработка алгоритма улучшения контраста видеоизображений для применения в системах цифрового телевидения // Вестник Рязанского государственного радиотехнического университета. 2023. № 84. С.77-87.
14. **Кириллов С.Н., Сконников П.Н.** Процедура определения размеров окон для алгоритма локального весового суммирования мультиспектральных изображений // Вестник Рязанского государственного радиотехнического университета. 2020. № 73. С.3-9.
15. **Szeliski R.** Computer vision: algorithms and applications // Springer Nature, 2022, pp. 925.
16. **Bochkovskiy A., Wang C.Y., Liao H.Y.M.** Yolov4: Optimal speed and accuracy of object detection // arXiv preprint arXiv:2004.10934, 2020.

UDC 621.397

MODIFICATION OF THE ALGORITHM FOR CLASSIFYING NOISES ON IMAGES USING A BACK PROPAGATION NEURAL NETWORK

V. T. Dmitriev, Dr. Sc. (Tech.), associate professor, department of radio control and communication, Head of the Department, RSREU, Ryazan, Russia;

orcid.org/0000-0001-5521-6886, e-mail: vol77@rambler.ru

E. S. Cherentaeva, post-graduate student, RSREU, Ryazan, Russia;

orcid.org/0000-0002-5580-3033, e-mail: culikoa4199@yandex.ru

M. A. Cherentaev, post-graduate student, RSREU, Ryazan, Russia;

orcid.org/0000-0002-0282-7250, e-mail: cherentaev.mikhail@gmail.com

A modification of image noise classification algorithm using back propagation neural network has been developed. The aim of the work is software implementation of noise classification neural network with the modification of preliminary processing algorithm with an increase in the number of neural network layers, as well as testing the resulting classifier on a set of real satellite images. An algorithm for preliminary data processing for training the neural network has been developed. The probabilities of correctly determining the type of noise have been obtained and compared with the values for other known classification methods. The authors have shown that the modified neural network provides better classification for multiplicative and Gaussian noise compared to known algorithms.

Keywords: image noise classification, noise models, image denoising, image filtering, statistical moment, multilayer neural network, back propagation method, gradient descent.

DOI: 10.21667/1995-4565-2024-90-22-31

References

1. **Safonov A.A.** Podavlenie shumov na izobrazheniyah s ispol'zovaniem prostranstvennoj i chastotnoj fil'tracii. *Vestnik nauki*. 2024, no. 7 (76), vol. 1, pp. 593-598. (in Russian).
2. **Kalambet Yu.A., Koz'min Yu.P., Samohin A.C.** Fil'traciya shumov. Sravnitel'nyj analiz metodov. *Analitika*. 2017, vol. 36, no. 5, pp. 88-101. (in Russian).
3. **Nagao M. and Matsuyama T.** Edge preserving smoothing. *Computer graphics and image processing*. 1979, no. 9, pp. 394-407.
4. **Jong-Sen Lee.** Digital image smoothing and the sigma filter. *Computer Vision, Graphics, and Image Processing*. 1983, vol. 24, iss. 2, pp. 255-269.
5. **Jong-Sen Lee.** Speckle analysis and smoothing of synthetic aperture radar images. *Computer Graphics and Image Processing*. 1981, vol. 17, is. 1, pp. 24-32.
6. **L. Beaureper, K. Chehdi, B. Vozel.** Identification of the nature of noise and estimation of its statistical parameters by analyzing local histograms. *IEEE International Conference on Acoustics, Speech and Signal Processing*. 1997, vol. 4, pp. 2805-2808.
7. **Benoit Vozel, Kacem Chehdi, Luc Klaine, Lukin V.V., Abramov S.K.** Noise Identification and Estimation of its Statistical Parameters by Using Unsupervised Variational Classification. *IEEE International Conference on Acoustics Speech and Signal Processing*. 2006, pp. 841-844.
8. **Tiwari, Shamik & Singh, Ajay & Shukla, Vidya Prasad.** Statistical Moments based Noise Classification using Feed Forward Back Propagation Neural Network. *International Journal of Computer Applications*. 2011, vol. 18, no. 2, pp. 36-40.
9. **Santhanam T. & Radhika S.** A Novel Approach to Classify Noises in Images Using Artificial Neural Network. *Journal of Computer Science*. 2010, vol. 6(5), pp. 506-510.
10. **Gonsales R.** *Cifrovaya obrabotka izobrazhenij* (Digital image processing). Moscow: Tekhnosfera. 2012. 1104 p. (in Russian).
11. **Dmitriev V.T., Skonnikov P.N.** Sravnitel'nyj analiz algoritmov kompleksirovaniya izobrazhenij razlichnyh spektral'nyh diapazonov. *Vestnik Rjazanskogo gosudarstvennogo radiotekhnicheskogo universiteta*. 2021. no. 78, pp. 29-37. (in Russian).
12. **Dmitriev V.T., Baukov A.A.** Mnogokriterial'nyj sintez algoritma obnaruzhenija chastic dozdja na videoizobrazhenijah v cifrovyyh sistemah televidenija. *Vestnik Rjazanskogo gosudarstvennogo radiotekhnicheskogo universiteta*. 2022, no. 79, pp. 20-30. (in Russian).
13. **Dmitriev V.T., Baukov A.A.** Razrabotka algoritma uluchsheniya kontrasta videoizobrazhenij dlja primeneniya v sistemah cifrovogo televidenija. *Vestnik Rjazanskogo gosudarstvennogo radiotekhnicheskogo universiteta*. 2023, no. 84, pp. 77-87. (in Russian).
14. **Kirillov S.N., Skonnikov P.N.** Procedure for determining window sizes for the algorithm for local weight summation of multispectral images. *Vestnik Rjazanskogo gosudarstvennogo radiotekhnicheskogo universiteta*. 2020, no. 73, pp. 3-9. (in Russian).
15. **Szeliski R.** Computer vision: algorithms and applications. *Springer Nature*. 2022, pp. 925.
16. **Bochkovskiy A., Wang C. Y., Liao H. Y. M.** Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*, 2020.