

УДК 616-073.75:681.3:004.8

*Сагирова А.Р., Осипов Е.А.*

*Казанский (Приволжский) федеральный университет, Казань, Россия*

## **Влияние шума «соль и перец» на точность классификации рентгеновских снимков легких нейронными сетями**

**Аннотация:** В статье представлены результаты исследования влияния шума «соль и перец» на точность результатов задачи классификации рентгеновских снимков легких с использованием нейронных сетей. Цель проведенного исследования – определение влияния импульсного шума разной интенсивности на точность классификации снимков здоровых легких, а также снимков легких с бактериальной или вирусной пневмонией. Были использованы два метода предварительной обработки данных: строгое сжатие и пропорциональное масштабирование. Оба метода продемонстрировали снижение точности с увеличением процента шума, что связано с потерей детализации на зашумленных изображениях.

**Ключевые слова:** здоровые легкие, бактериальная пневмония, вирусная пневмония, нейронная сеть, классификация, предобработка изображений, шум «соль и перец», точность и чувствительность.

*Sagirova A.R., Osipov E.A.*

## **The effect of "salt and pepper" noise on the accuracy of classification of lung x-rays by neural networks**

**Abstract:** The article examines the effect of "salt and pepper" noise on the accuracy of classification of lung X-rays performed using neural networks. The aim of the study was to study how noise of different intensity (1,5,10 and 15%) affects the accuracy of classification of healthy lungs, as well as lungs with bacterial and viral pneumonia. Two methods of data preprocessing were used: strict compression and proportional scaling. Both methods demonstrated a decrease in accuracy with an increase in the percentage of noise, which is associated with the loss of details important for classification.

**Keywords:** healthy lungs, bacterial pneumonia, viral pneumonia, neural networks, classification, image preprocessing, salt and pepper noise, accuracy and sensitivity.

### **Введение**

В условиях растущей нагрузки на медицинские учреждения и дефицита квалифицированных специалистов, вопрос применения автоматизированных систем диагностики в медицине стал весьма актуален. Такие системы способны обрабатывать огромные объемы данных и выявлять патологии с высокой точностью. Например, выявление патологий заболеваний лёгких, где раннее обнаружение недуга может существенно повысить шансы на успешное лечение.

Тем не менее, с автоматизацией диагностики возникают и серьёзные вызовы. Одним из наиболее значительных является наличие шума типа «соль и перец» на медицинских данных [1, 2], которые могут исказить результаты анализа и привести к неверным заключениям. Этот вид шума особенно опасен, так как он может имитировать патологии, что ставит под угрозу точность диагностики [3].

Несмотря на значительные достижения в области глубокого обучения, устойчивость свёрточных нейронных сетей к различным видам шума остаётся недостаточно изученной. Исследование влияния шума типа «соль и перец» на производительность нейронных сетей может привести к созданию более надёжных и устойчивых алгоритмов, способных обеспечивать высокую точность диагностики. Данное исследование не только актуально, но и необходимо для дальнейшего развития автоматизированной медицины.

Целью данного исследования является изучение влияния шума типа «соль и перец» на точность классификации рентгеновских снимков легких нейронными сетями с использованием двух методов предварительной обработки данных: строгое сжатие и пропорциональное масштабирование.

Результаты исследования позволят расширить знания о влиянии шумов на классификацию рентгеновских снимков легких.

## Методы и инструменты обработки изображений и обучения нейронных сетей

Для проведения эксперимента были применены рентгеновские снимки легких из набора данных Curated Dataset for COVID-19 Posterior-Anterior Chest Radiography Images (X-Rays). В работу были взяты 7593 снимка легких, которые состояли из трех групп: здоровые легкие, а также пораженные вирусной и бактериальной пневмонией.

Перед обучением изображения были подготовлены для подачи в нейросеть двумя разными способами.

Первый вариант обработки медицинских снимков. Изображение преобразовывалось в оттенки серого, что позволило упростить структуру данных и снизить вычислительную нагрузку. Затем размеры изображений строго уменьшались до формата  $227 \times 227$  пикселей, обеспечивая стандартизацию входных данных для последующей обработки и обучения модели. Следующим этапом было преобразование изображений в тензоры, что делает возможным эффективное использование библиотек глубокого обучения, таких как PyTorch. Завершающим шагом являлась нормализация значений пикселей, что способствует ускорению процесса обучения и улучшению качества сходимости модели.

Второй вариант обработки медицинских снимков. Второй вариант схож с первым, но размер изменился уменьшением меньшей стороны до

227. Большая соответственно тоже уменьшалась для сохранения пропорции изображения. Например, изображение имеет размер  $(H, W)$ , где  $H$  - высота,  $W$  – ширина. Если  $H > W$ , то новое разрешение будет  $(H * 227 / W, 227)$ , иначе  $(227, W * 227 / H)$ . Далее производится бикубическая интерполяция, который бережно сохраняет качество изображения даже при изменении масштаба. Этот метод аккуратно вычисляет новые цвета промежуточных точек, минимизируя артефакты и сохраняя чёткость контуров объектов. Затем вырезается центральная область изображения размером  $227 \times 227$  пикселей и нормализуется.

В работе использовалась популярная функция потерь CrossEntropyLoss, которая сочетает в себе softmax-активацию и отрицательное лог-правдоподобие (NLL), что делает её удобной для обучения моделей, предсказывающих вероятности классов [4].

Следовательно, рассмотренные подходы и средства предоставляют мощный арсенал для обработки и исследования визуальных данных, способствуя повышению качества обучения нейронных сетей.

## Экспериментальная часть

Обучение проводилось на нейронной сети AlexNet, где классифицировались рентгеновские снимки легких без шума. Оригинальная архитектура была немного модифицирована для адаптации к задаче.

AlexNet, аналогично оригинальной архитектуре, включает восемь обучаемых слоев, из которых пять являются сверточными, а три — полносвязными.

Для первого сверточного слоя AlexNet был установлен входящий канал равный 1, так как изображение переводилось в черно-белый формат. Так же использовалось 64 фильтра, вместо 96, размером  $11 \times 11$ , которые применялись с шагом 4 пикселя. После первого слоя следовал слой подвыборки (max pooling), который уменьшал размер выходных данных и помогал избежать переобучения. Во втором сверточном слое использовалось 256 фильтров размером  $5 \times 5$ , также с последующим слоем подвыборки. Третий, четвертый и пятый сверточные слои использовали 384 и 256 фильтров, соответственно, с меньшими размерами ядер и с уменьшением параметров, что улучшало качество извлечения признаков. После сверточных слоев изображение проходило через три полносвязных слоя. Первый полносвязный слой содержал 4096 нейронов, что позволяло сети обрабатывать сложные комбинации извлеченных признаков. Выходных классов уменьшилось до 3 - нормальные лёгкие, лёгкие с признаками бактериальной и вирусной пневмонии соответственно.

Предварительная обработка изображений включала создание искусственных шумов «соль и перец». Определялись размеры

изображений для подсчёта общего числа пикселей и из этой цифры брался определенный процент пикселей, в нашем случае 1, 5, 10 и 15%, которым рандомным образом присваивался черный или белый цвет (рис.1).

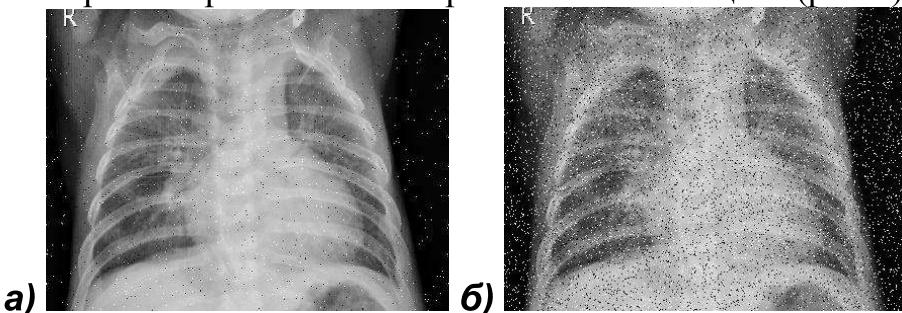


Рисунок 1. Зашумленные рентгеновские снимки разной интенсивностью  
а) применение 1% шума «соль и перец»; б) применение 10% шума «соль и перец»

Процедура тестирования проводилась на изображениях с шумами типа «соль и перец» различной интенсивности, используя ту же предобработку, что и при обучении, с целью оценки влияния различных методов предобработки на качество классификации модели.

### Ключевые показатели эффективности моделей классификации

Рассмотрим основные метрики, позволяющие оценить успешность классификаций.

Accuracy (Точность). Доля правильных предсказаний среди всех прогнозов.

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (1)$$

где TP — истинно положительные, TN — истинно отрицательные, FP — ложно положительные, FN — ложно отрицательные.

Precision (Точность). Доля верно предсказанных положительных случаев среди всех предсказанных положительных.

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

Recall (Чувствительность). Доля верно предсказанных положительных случаев среди всех реальных положительных.

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

F1-Score (Баланс точности и полноты). Комбинирует Precision и Recall в одну метрику.

$$\text{F1} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

### Результаты проводимых экспериментов.

В результате исследования на рисунках 2-5 мы видим, что здоровые снимки легких демонстрируют наибольшую устойчивость к шумовым искажениям среди всех классов заболеваний. Снимки бактериальной пневмонии показывают немного хуже результаты по сравнению со снимками здоровых лёгких, однако значительно превосходят показатели качества классификации при вирусной пневмонии.

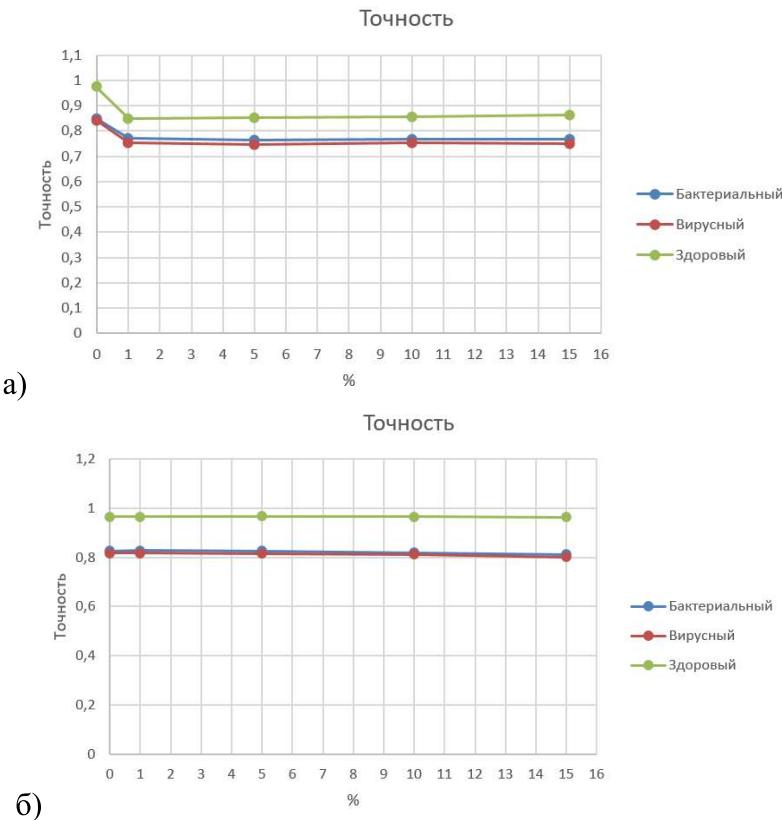
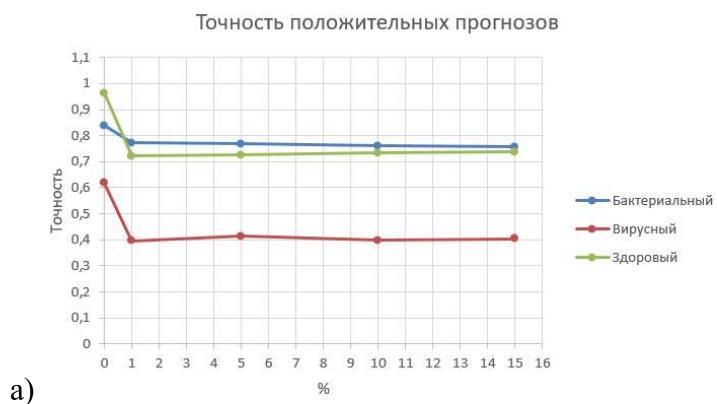


Рисунок 2. Зависимость точности от уровня шума «соль и перец»  
а) первый вариант; б) второй вариант



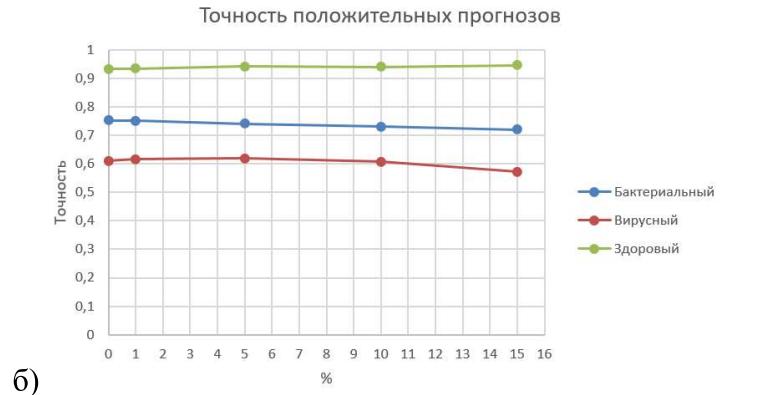


Рисунок 3. Зависимость положительной точности от уровня шума «соль и перец»  
а) первый вариант; б) второй вариант

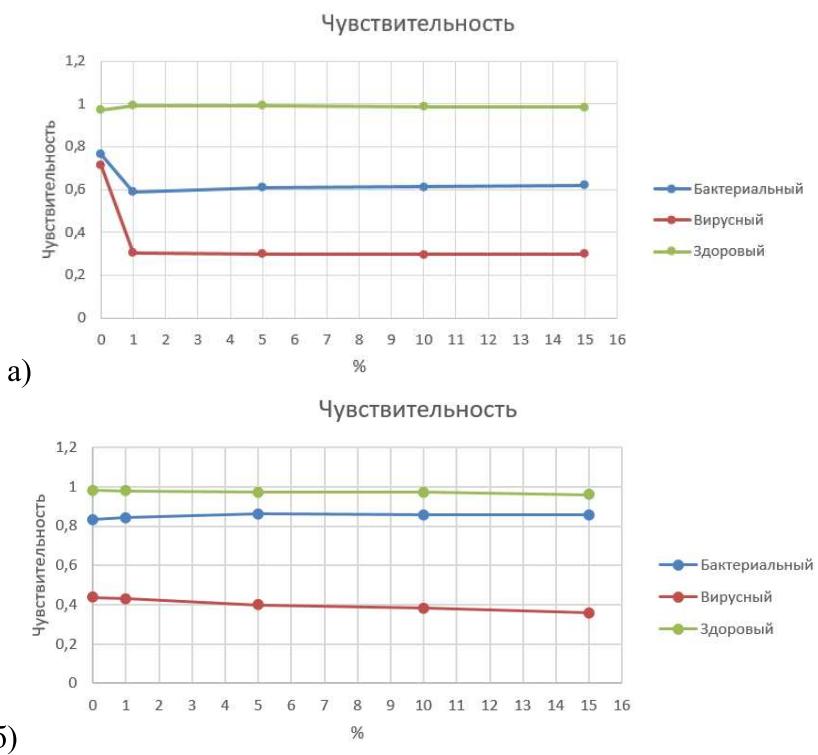
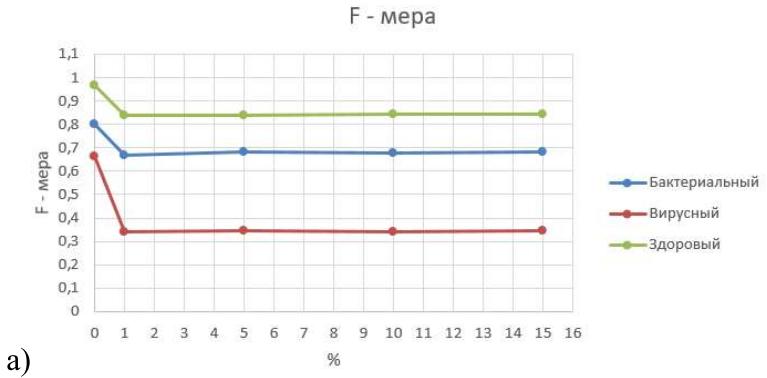


Рисунок 4. Зависимость чувствительности от уровня шума «соль и перец»  
а) первый вариант; б) второй вариант



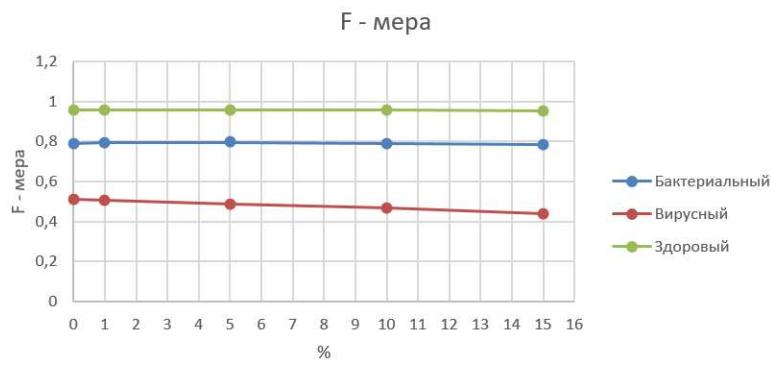


Рисунок 5. Зависимость F-меры от уровня шума «соль и перец»  
а) первый вариант; б) второй вариант

Возможная причина — особенность визуализации очагов заболевания: бактериальная пневмония вызывает локальные изменения структуры тканей, которые могут теряться при высоком уровне зашумленности, тогда как вирусная пневмония характеризуется диффузными изменениями и часто двусторонними поражениями, легко скрываемыми случайными артефактами. Избыточные затемнения от воздействия шума приводят к появлению множества ложноположительных результатов и снижают общую точность модели.

Сравнение двух методов предобработки показывает, что на чистых изображениях лёгких первый метод демонстрирует точность 88,85%, тогда как второй — 86,94%. Однако при увеличении уровня шумов точность первого метода снижается быстрее: при шуме в 15% его точность падает до 79,39%, в то время как второй сохраняет показатель на уровне 85,91%.

## Заключение

Увеличение уровня шума «соль и перец» существенно затрудняет классификацию изображения распознавание здоровых изображений остаётся относительно лёгким вплоть до повышения интенсивности шума до 15%, а идентификация вирусных изображений становится крайне сложной задачей вследствие малозаметных контрастных характеристик, которые эффективно скрываются добавлением шума. Исследование подчеркивает необходимость дальнейшего изучения методов обработки зашумленных изображения для повышения точности распознавания болезней легких.

## Список литературы:

1. Реунов Д.Г., Малышев И.В., Чхало Н.И. Сравнение методов удаления шума на изображении, полученном в зеркальном микроскопе на длине волны 13.84 нм // Институт физики микроструктур РАН. 2022, №12, с. 80-85.
2. Меркуриев С.В. Подавление флуктуационного шума на цифровых рентгенограммах // ЗАО НИПК "Электрон".

3. Косарина Е.И., Михайлова Н.А., Суворов П.В., Демидов А.А. Природа шумов в цифровой радиографии, их моделирование и способы подавления в цифровом радиографическом изображении (обзор) // Труды ВИАМ. 2023. № 6 (124). С. 12.

4. Janocha K., Czarnecki W.M. On Loss Functions for Deep Neural Networks in Classification // Journal of Machine Learning Research (JMLR). – 2017. – Vol. 18. – P. 1–29. – URL: arXiv:1702.05659

---

**Сведения об авторах:**

**Сагирова А.Р.**, магистрант, Казанский (Приволжский) федеральный университет, Казань, Россия

**Осипов Е.А.**, старший преподаватель, Казанский (Приволжский) федеральный университет, Казань, Россия

**Sagirova A.R.**, Master's student Kazan (Volga Region) Federal University Kazan, Russia

**Osipov E.A.**, Senior Lecturer, Kazan (Volga Region) Federal University, Kazan, Russia

---