

INTERNATIONAL SCIENCE REVIEWS



№1 (5) 2024

Natural Sciences and
Technologies series





INTERNATIONAL SCIENCE REVIEWS

Natural Sciences and Technologies series

Has been published since 2020

№1 (5) 2024

Astana

INTERNATIONAL SCIENCE REVIEWS. NATURAL SCIENCES AND TECHNOLOGIES SERIES ЖУРНАЛЫНЫҢ РЕДАКЦИЯСЫ

БАС РЕДАКТОР

Қалимолдаев Мақсат Нұрадилович, техникалық ғылымдар докторы, ҚР ҰҒА академигі, профессор, ҚР ҒЖБМ ҒК «Ақпараттық және есептеу технологиялары институты» бас директорының кеңесшісі, бас ғылыми қызметкері (Қазақстан)

БАС РЕДАКТОРДЫҢ ОРЫНБАСАРЫ

Мырзағалиева Анар Базаровна, биология ғылымдарының докторы, профессор, бірінші вице-президент, Астана халықаралық университеті (Қазақстан);

РЕДАКТОРЛАР:

- **Сейткан Айнура Сейтканқызы**, техника ғылымдарының кандидаты, PhD, жаратылыстану ғылымдары жоғары мектебінің деканы, Астана халықаралық университеті (Қазақстан);

- **Муканова Асель Сериковна**, PhD, Ақпараттық технологиялар және инженерия жоғары мектебінің деканы, Астана халықаралық университеті (Қазақстан);

- **Абдилдаева Асель Асылбековна**, PhD, қауымдастырылған профессор, Әл-Фараби атындағы ҚазҰУ (Қазақстан);

- **Хлахула Иржи** PhD, профессор, Познаньдағы Адам Мицкевич атындағы университет (Польша);

- **Редферн Саймон А.Т.**, PhD, профессор, Наньян технологиялық университеті (Сингапур);

- **Сяолей Фенг**, PhD, Наньян технологиялық университеті (Сингапур);

- **Шуджаул Мулк Хан**, PhD, профессор, Каид-және-Азам университеті (Пакистан);

- **Базарнова Наталья Григорьевна**, химия ғылымдарының докторы, профессор, Химия және химиялық-фармацевтикалық технологиялар институты (Ресей);

- **Черёмушкина Вера Алексеевна**, биология ғылымдарының докторы, профессор, РҒА СБ Орталық Сібір ботаникалық бағы (Ресей);

- **Тасболатұлы Нұрболат**, PhD, Ақпараттық технологиялар және инженерия жоғары мектебі деканының орынбасары, Астана халықаралық университеті (Қазақстан);

- **Байшоланов Сакен Советович**, география ғылымдарының кандидаты, доцент, Астана халықаралық университеті (Қазақстан);

- **Нуркенов Серик Амангельдинович**, PhD, қауымдастырылған профессор, Астана халықаралық университеті (Қазақстан).

**РЕДАКЦИЯ ЖУРНАЛА INTERNATIONAL SCIENCE REVIEWS.
NATURAL SCIENCES AND TECHNOLOGIES SERIES**

ГЛАВНЫЙ РЕДАКТОР

Калимолдаев Максат Нурадилович, доктор технических наук, академик НАН РК, профессор, ГНС, советник генерального директора Института информационных и вычислительных технологий КН МНВО РК (*Казахстан*)

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА

Мырзагалиева Анар Базаровна, доктор биологических наук, профессор, первый вице-президент, Международный университет Астана (*Казахстан*)

РЕДАКТОРЫ:

- **Сейткан Айнур Сейтканкызы**, кандидат технических наук, PhD, декан высшей школы естественных наук, Международный университет Астана (*Казахстан*);

- **Муканова Асель Сериковна**, PhD, декан Высшей школы информационных технологии и инженерии, Международный университет Астана (*Казахстан*);

- **Абдилдаева Асель Асылбековна**, PhD, ассоциированный профессор, Казахский национальный университет имени Аль-Фараби (*Казахстан*);

- **Хлахула Иржи** PhD, профессор, Университет имени Адама Мицкевича в Познани (*Польша*);

- **Редферн Саймон А.Т.**, PhD, профессор, Наньянский технологический университет (*Сингапур*);

- **Фенг Сяoley**, PhD, Наньянский технологический университет (*Сингапур*);

- **Шуджаул Мулк Хан**, PhD, профессор, Университет Каид-и Азама (*Пакистан*);

- **Базарнова Наталья Григорьевна**, доктор химических наук, профессор, Институт химии и химико-фармацевтических технологий (*Россия*);

- **Черёмушкина Вера Алексеевна**, доктор биологических наук, профессор, Центральный Сибирский Ботанический сад СО РАН (*Россия*);

- **Тасболатұлы Нұрболат**, PhD, заместитель декана Высшей школы информационных технологий и инженерии, Международный университет Астана (*Казахстан*);

- **Байшоланов Сакен Советович**, кандидат географических наук, доцент, Международный университет Астана (*Казахстан*);

- **Нуркенов Серик Амангельдинович**, PhD, ассоциированный профессор, Международный университет Астана (*Казахстан*);

**EDITORIAL TEAM OF THE JOURNAL INTERNATIONAL SCIENCE REVIEWS.
NATURAL SCIENCES AND TECHNOLOGIES SERIES**

CHIEF EDITOR

Maksat Kalimoldayev, Doctor of Technical Sciences, Academician of NAS RK, Professor, SRF, CEO's counselor «The Institute of Information and Computational Technologies» CS MSHE RK (Kazakhstan)

DEPUTY CHIEF EDITOR

Anar Myrzagaliyeva, Doctor of Biological Sciences, Professor, First Vice-President, Astana International University (Kazakhstan)

EDITORS:

- **Ainur Seitkan**, Candidate of Technical Sciences, PhD, Dean of the Higher School of Natural Sciences, Astana International University (Kazakhstan);
- **Assel Mukanova**, PhD, Dean of the Higher School of Information Technology and Engineering, Astana International University (Kazakhstan);
- **Assel Abdildayeva**, PhD, Associate Professor, of the Department of Artificial Intelligence and Big Data, Al-Farabi Kazakh National University (Kazakhstan);
- **Jiri Chlachula**, PhD, Dr.Hab., Full Professor, Adam Mickiewicz University, Poznań (Poland);
- **Simon A.T. Redfern**, PhD, Professor, Nanyang Technological University (Singapore);
- **Xiaolei Feng**, PhD, Nanyang Technological University (Singapore);
- **Khan Shujaul Mulk**, PhD, Professor, Quaid-i-Azam University (Pakistan);
- **Natal'ya Bazarnova**, Doctor of Chemical Sciences, Professor, Institute of Chemistry and Chemical-Pharmaceutical Technologies (Russia);
- **Vera Cheryomushkina**, Doctor of Biological Sciences, Professor, Central Siberian Botanical Garden SB RAS (Russia);
- **Nurbolat Tasbolatuly**, PhD, Deputy Dean of the Higher School of Information Technology and Engineering, Astana International University (Kazakhstan);
- **Saken Baisholanov**, Candidate of Geographical Sciences, Associate Professor, Astana International University (Kazakhstan);
- **Serik Nurkenov**, PhD, Associate Professor, Astana International University (Kazakhstan).

Editorial address: 8, Kabanbay Batyr avenue, of.316, Nur-Sultan,
Kazakhstan, 010000

Tel.: (7172) 24-18-52 (ext. 316)

E-mail: natural-sciences@aiu.kz

International Science Reviews NST - 76153

International Science Reviews

Natural Sciences and Technologies series

Owner: Astana International University

Periodicity: quarterly

Circulation: 500 copies

CONTENT

1. А.М.Касымханов, И.В.Притыкин, С.К.Китапбаев, Д.А.Костюченко, С.Е.Базаров ЕРТІС БАССЕЙНІНІҢ ХАЛЫҚАРАЛЫҚ МАҢЫЗЫ БАР БАЛЫҚ ШАРУАШЫЛЫҒЫ СУ АЙДЫҢДАРЫНДАҒЫ ТЫРАНЫҢ (ABRAMIS BRAMA LINNAEUS, 1758) БИОЛОГИЯЛЫҚ КӨРСЕТКІШТЕРІ ЖӘНЕ КӘСІПТІК МАҢЫЗЫ.....	7
2. А.Бериков, Т.Самарханов ПАТРИОТИЧЕСКОЕ ВОСПИТАНИЕ ДЕТЕЙ ШКОЛЬНОГО ВОЗРАСТА НА ПРИМЕРЕ ИСТОРИЧЕСКИХ ЛИЧНОСТЕЙ БАЯНАУЫЛА.....	17
3. Ж.Н. Елемес, Ж.М. Мукатаева ӘРТҮРЛІ ДЕНЕ БЕЛСЕНДІЛІГІМЕН АЙНАЛЫСАТЫН МЕКТЕП ОҚУШЫЛАРЫНЫҢ ФИЗИКАЛЫҚ ДАМУЫ	25
4. Т.Шалбай, Л.Кусепова СЕТЕВАЯ ВИРТУАЛИЗАЦИЯ: ТРАНСФОРМАЦИЯ СОВРЕМЕННЫХ ВОЗМОЖНОСТЕЙ ПОДКЛЮЧЕНИЯ	34
5. Ж.С.Жапарова, Л.Т.Кусепова, А.Е.Назырова ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В СОВРЕМЕННОМ БИЗНЕСЕ: ПРИМЕНЕНИЕ, ТЕНДЕНЦИИ И ВЛИЯНИЕ НА ЭФФЕКТИВНОСТЬ РАБОТЫ ОРГАНИЗАЦИЙ	43
6. Е.Е.Садибек, Л.Т.Кусепова, А.Е.Назырова ОБЕСПЕЧЕНИЕ БЕЗОПАСНОСТИ ОБЛАЧНЫХ СЕРВИСОВ	50
7. А.Е.Назырова, А.С.Муканова, М.Ж.Калдарова, Л.Т.Кусепова МОДЕЛЬНОЕ СТРУКТУРИРОВАНИЕ УЧЕБНОГО ПЛАНА ДЛЯ ДОСТИЖЕНИЯ ЗАРАНЕЕ ОПРЕДЕЛЁННЫХ УЧЕБНЫХ РЕЗУЛЬТАТОВ: ВИЗУАЛИЗАЦИЯ И ОПТИМИЗАЦИЯ ЧЕРЕЗ СЕТЕВУЮ ДИАГРАММУ	57
8. Б.Х.Аллажар, М.Ж.Калдарова, А.Е.Назырова РАСПОЗНАВАНИЕ ИЗОБРАЖЕНИЙ С ПОМОЩЬЮ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ В ПРИСУТСТВИИ ШУМА	63
9. Ермек Төле Би ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ СЕРДЕЧНО-СОСУДИСТЫХ ЗАБОЛЕВАНИЙ НА ОСНОВЕ КЛИНИКО-ДЕМОГРАФИЧЕСКИХ ДАННЫХ ПАЦИЕНТОВ	79
10. Ермек Төле Би ОПРЕДЕЛЕНИЕ СЕРДЕЧНОЙ НЕДОСТАТОЧНОСТИ ЧЕРЕЗ СОВРЕМЕННЫЕ ГАДЖЕТЫ: ПЕРСПЕКТИВЫ И ОГРАНИЧЕНИЯ	87
11. Л.М.Нұрхан, С.С.Байшоланов ГЕОГРАФИЯ ОҚУЛЫҚТАРЫНДА АУА-РАЙЫ ЖӘНЕ КЛИМАТ ТУРАЛЫ БЕРЛІГЕН МӘЛІМЕТТЕР ЖӘНЕ ОЛАРДЫ ТОЛЫҚТЫРУҒА ҰСЫНЫСТАР.....	97
12. Л.М.Нұрхан, С.С.Байшоланов ГЕОГРАФИЯ ОҚУЛЫҚТАРЫНДА КЛИМАТТЫҢ ӨЗГЕРУІ ТУРАЛЫ БЕРЛІГЕН МӘЛІМЕТТЕР ЖӘНЕ ОЛАРДЫ ТОЛЫҚТЫРУҒА ҰСЫНЫСТАР	110

РАСПОЗНАВАНИЕ ИЗОБРАЖЕНИЙ С ПОМОЩЬЮ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ В ПРИСУТСТВИИ ШУМА

Аллажар Б.Х.¹, Калдарова М.Ж.², Назырова А.Е.²

¹Магистрант 1 курса по ОП «Вычислительная техника и программное обеспечение»

²старший преподаватель, магистр
Международный университет Астана

Аннотация: Классификация данных в присутствии шума может привести к гораздо худшим результатам, чем ожидалось для чистых паттернов. В этой статье исследована проблема в случае глубоких сверточных нейронных сетей, чтобы предложить решения, которые могут смягчить влияние шума. Основными вкладами, представленными в этой статье, является экспериментальное исследование влияния различных типов шума на сверточную нейронную сеть, предложение глубокой нейронной сети, работающей в качестве шумоподавителя, исследование обучение глубокой сети с использованием шаблонов, загрязненных шумом, и наконец, анализ добавления шума в процессе обучения глубокой сети, как формы регуляризации. Моими основными выводами являются создание фильтра шумоподавления на основе глубокой сети, который превосходит самые современные решения, а также предложение практического метода глубокого обучения нейронной сети с использованием зашумленных шаблонов для улучшения по сравнению с зашумленными тестовыми шаблонами. Все результаты подкреплены экспериментами, которые показывают высокую эффективность и, возможно, широкое применение предлагаемых решений.

Ключевые слова: Распознавание изображений, глубокие нейронные сети, сверточные нейронные сети, шум, подавление шума изображения, регуляризация.

ВВЕДЕНИЕ

Область исследований компьютерного зрения существенно изменилась за последние годы, в основном благодаря достижениям в области глубокого обучения [1]. В это время глубокие нейронные сети успешно использовались в различных практических приложениях [2,3,4]. В частности, сверточные нейронные сети смогли достичь современных результатов в задаче распознавания изображений [5,6,7], во многих случаях, превосходящих человеческие возможности. Несмотря на значительный объем исследований, проведенных в этой области, большая часть работы вращается вокруг эталонных наборов данных, состоящих из изображений довольно высокого качества. Однако в реальных приложениях, мы часто сталкиваемся с данными низкого качества, искаженными различными типами шума, размытостью изображения при движении, плохим освещением и погодными условиями, низким разрешением или комбинацией этих факторов, и

это лишь некоторые из них. Кроме того, их природа не всегда известна. Таким образом, во многих случаях необходима устойчивость к ранее не встречающимся типам искажений. Влияние качества изображения на производительность алгоритмов компьютерного зрения часто упускается из виду, что, в свою очередь, может привести к нереалистичным ожиданиям в практических приложениях.

В статье, проводятся попытки ответить на вопросы о влиянии присутствия различных типов шума на задачу распознавания изображений с помощью глубоких нейронных сетей. Далее исследуются, насколько серьезно это может повлиять на точность классификации и каковы возможные решения возможного снижения производительности. Наконец, вопрос, можно ли использовать присутствие шума в своих интересах. Чтобы ответить на эти вопросы, было проведено обширное экспериментальное исследование одной из знаковых нейронных архитектур последних лет, модели VGG (предложенной и названной в честь Оксфордской группы визуальной геометрии) [5]. Измерено влияние различных шумовых условий, как с известными, так и с неизвестными распределениями, на эффективность классификации. Проводилась оценка различных возможностей борьбы с этими искажениями, а именно: увеличение обучающих данных вместо применения полного сверточного шумоподавления перед классификацией. Наконец, оценка возможности искусственного создания шума, как формы регуляризации в надежде увидеть повышение производительности. Было показано, что небольшие дозы синтетических искажений, применяемые во время процедуры обучения, эквивалентны определенным формам регуляризации [5,8,9,10]. Однако, это еще больше усложняет связь между уровнями шума, присутствующими в изображениях, и производительностью задачи классификации, особенно с учетом распространенности методов регуляризации, уже используемых в сочетании с моделями глубокого обучения.

ЛИТЕРАТУРНЫЙ ОБЗОР

В последние годы глубокое обучение привлекло внимание исследовательского сообщества, приводя к прорывам в области классификации образов. Увеличение глубины нейронных сетей было сложной задачей, но с появлением мощных GPU и больших наборов данных производительность значительно улучшилась [1,5,6,7].

Однако большинство исследований проводилось в условиях с небольшими искажениями изображений. В реальных приложениях шум часто присутствует повсеместно, и исследование влияния искажений на точность распознавания изображений стало важным направлением [11,12,13,14].

Существует несколько методов работы с данными низкого качества при классификации изображений. Например, использование специальных наборов функций при сложных условиях освещения или трансферное обучение для

изображений с низким разрешением. Некоторые подходы включают оценку качества изображения в процесс классификации.

Другой подход - применение методов восстановления до классификации. Нейронные сети эффективно восстанавливают изображения, даже с шумом или размытием. Автокодировщики, особенно с шумоподавлением, также используются для извлечения полезных представлений из искаженных изображений.

Некоторые исследования рассматривают добавление шума к обучающим изображениям как метод регуляризации, улучшающий эффективность обобщения. Теоретический анализ введения шума также подчеркивает его положительное влияние на обучение и снижение переобучения.

Таким образом, исследования в области воздействия искажений на нейронные архитектуры, методов работы с данными низкого качества и восстановления изображений вносят важный вклад в развитие области глубокого обучения.

Шум – это нежелательный сигнал, который влияет на исходный результат. Это происходит, как эффект некоторых физических явлений, возникающих в процессе приема и передачи сигналов [25]. Шум вносит искажения, которые затрудняют обнаружение и анализ чистой составляющей сигнала. Шум также влияет на классификацию шаблонов, поскольку ухудшение обучающих и тестовых шаблонов шумом также влияет на их статистические свойства. Более того, на практике обычно трудно определить тип шума, который влияет на входные сигналы.

Тепловые эффекты в электронных устройствах, а также явления подсчета фотонов и зернистости пленки приводят к типу шума, который представлен аддитивной моделью шума со случайной величиной, характерной для функции плотности Гаусса. Поэтому этот тип называется гауссовским шумом.

Шум квантования возникает в результате дискретизации непрерывного сигнала в его дискретный аналог. Каждой выборке сигнала присвоено конечное число битов, что неизбежно накладывает ограничение на наименьшее значение, которое может быть представлено без ошибок.

Шум «соль с перцем» возникает в результате битовых ошибок передачи или ошибок аналого-цифрового преобразователя. Его название происходит от характерных белых и черных пятен на изображении, вызванных переворотом обычно самого значимого бита представления пикселя. Процесс генерации шума соли и перца можно интерпретировать как процесс двойного рисования.

МЕТОДЫ И МЕТОДОЛОГИЯ

Борьба с шумом и его использование в распознавании изображений

Учитывая возможное влияние искажений на задачу распознавания изображений с помощью глубоких нейронных сетей, данная работа сосредоточена на трех методах борьбы с шумом, ориентированных на данные: обучение с использованием шаблонов, дополненных шумов, и использование шумоподавления как формы предварительной обработки.

Увеличение данных обучения:

Борьба с шумом в задаче распознавания образов может включать увеличение данных обучения с помощью ожидаемого или синтетического шума. Однако получение большого количества размеченных данных с реальными искажениями может быть дорогостоящим и затруднительным. Синтетический шум может быть альтернативой, но его эффективность зависит от математического описания ожидаемых искажений. Использование неправильного типа или избыточного количества синтетического шума также может отрицательно сказаться на классификации. Кроме того, важно учесть качество модели шума, так как оно влияет на результат увеличения данных.

Предварительное шумоподавление данных:

Альтернативный подход к классификации зашумленных паттернов заключается в обучении модели классификации на неискаженных данных, а затем в применении шумоподавления как формы предварительной обработки. Шумоподавление с помощью нейронных сетей, рассматриваются исключительно по нескольким причинам. Прежде всего, он часто превосходит другие современные методы [26]. Хотя для этого часто необходимы большие объемы данных, эта проблема менее серьезна поскольку данные необходимы для классификации в любом случае. Более того, изображения используемые для обучения модели шумоподавления не должны быть помечены. В этом контексте обучающую модель шумоподавления можно рассматривать, как предварительное обучение окончательного классификатора без присмотра, возможно выполняемое с использованием большего распределения немаркированных данных.

Использование нейронной архитектуры для шумоподавления изображений имеет некоторые дополнительные преимущества. Прежде всего это дает возможность тонкой настройки конечной модели. Во-вторых, поскольку шумоподавление в принципе дает изображения достаточного качества, возможен перенос дальнейших слоев из уже существующих моделей, обученных на неискаженных данных. Это особенно полезно из-за длительного времени обучения классификационных архитектур.

Использование шума, как формы регуляризации:

Регуляризация — хорошо изученная проблема в контексте нейронных сетей. В частности, известно, что применение небольших доз шума во время процедуры

обучения улучшает свойства обобщения сетей [27]. Однако, учитывая обилие других методов регуляризации, таких как снижение веса, отсев и адаптивная регуляризация, сомнительно является ли применение какой-либо другой формы регуляризации полезным.

Более того, возможное негативное влияние применения шума как формы регуляризации также имеет значение. Это имеет особое значение при рассмотрении стратегии увеличения обучающих данных. Если шумовые условия во время оценки модели не определены, я могу дополнить данные слишком серьезными искажениями. В этом контексте, измеряя негативное влияние слишком строгой регуляризации, я исследую как будет вести себя модель если шум увеличения выбран неправильно.

Экспериментальное исследование:

Чтобы оценить влияние шума на задачу распознавания изображений, было проведено обширное экспериментальное исследование. А именно тестирование архитектуры VGG [27] в различных условиях шума, как известных, так и неизвестных. Как уже упоминалось, я оценил два подхода к борьбе с шумом: увеличение обучающих данных и применение шумоподавления. Измерено влияние шума на обучающие данные и его полезность в качестве дополнительной формы регуляризации.

Экспериментальная установка:

Несколько типов моделей синтетического шума, использовались с различными параметрами. Для оценки случая с известными шумовыми условиями использовали модели Гаусса, квантования и шума соли и перца, с соответствующими параметрами принимающими значения из набора {0,05, 0,1, 0,2, 0,5}. Выбор параметров моделей шума был продиктован необходимостью охватить, как менее тяжелые, так и очень тяжелые шумовые условия. При этом количество рассматриваемых параметров пришлось ограничить из-за вычислительных ограничений. С другой стороны, для оценки ситуации, в которой шумовые условия неизвестны, были использованы те же модели шума с параметрами, выбранными равномерно из диапазона от 0,0 до 0,5 на каждой итерации. Был рассмотрен случай, когда сама модель шума, а также интенсивность искажений выбираются случайным образом.

Процедура обучения:

В задаче классификации использовался метод стохастического градиентного спуска для минимизации целевой функции перекрестной энтропии. На протяжении всего обучения использовалась постоянная скорость обучения равная 0,001, с импульсом 0,9. Уменьшение веса было установлено равным 0,0005 и уменьшилось на 0,5 после того, как все скрытые полностью связанные слои были

использованы в качестве формы регуляризации. Выбор гиперпараметров был мотивирован их значениями, указанными в исследованиях [5]. Случайные фрагменты были извлечены из исходных изображений. Прежде всего, изображения были масштабированы так, чтобы их меньший размер стал равен 224 пикселям. Во-вторых, их обрезали до размера 224×224 пикселей. Обрезка выполнялась случайным образом каждый раз при получении изображения. Обучение проводилось в пакетном режиме, пакетами по 50 изображений в каждом. Вся процедура обучения длилась 100 эпох. После обучения я заметил, что точность классификации в большинстве случаев насыщалась раньше часто уже через 50 эпох. Однако дальнейшее обучение не привело к переобучению.

В качестве критерия оптимизации в задаче шумоподавления была выбрана среднеквадратическая ошибка между исходным и искусственно искаженными изображениями. Использовалась та же скорость обучения, импульс и размер пакета, что и в задаче классификации. Однако никакого снижения веса не применялось. Были оценены различные варианты скорости обучения, импульса и снижения веса, но проведенные тесты показали, что ни один из этих параметров не оказывает существенного влияния на эффективность шумоподавления. Перед шумоподавлением изображения были нормализованы в диапазоне от 0 до 1. Во время обучения для ускорения процедуры обучения использовались случайно выбранные участки размером 64×64 . В данном случае обучение длилось 10 эпох.

Наблюдение за точностью шумоподавления после обучения измеренное как пиковое отношение сигнал/шум (PSNR) [25], показало значительное снижение скорости улучшения. Однако оно не достигло полного насыщения что может указывать на возможность достижения небольшого улучшения по сравнению с сообщаемыми результатами. Использование показателя PSNR в этом типе сравнения часто встречается среди исследователей поскольку оно определяется одинаково независимо от содержания изображения.




Рисунок - 1. Графическое представление комбинированных архитектур шумоподавления и классификации.

Шумоподавление:

Экспериментальная оценка началась с оценки производительности предложенной стратегии шумоподавления. Это сравнивается с тремя другими алгоритмами шумоподавления, которые не полагаются на нейронное обучение. Это медианный фильтр [31], двусторонний фильтр [50] и фильтрация BM3D [14]. Дополнительную информацию об этих и других современных методах фильтрации изображений можно получить в [25,31,46]. Параметры базовых алгоритмов были точно настроены для конкретных условий шума. Для медианной фильтрации рассматривались окна размером 3×3 , 5×5 , 7×7 , 9×9 , 11×11 и 13×13 . С другой стороны, для двусторонней фильтрации использовались значения ее управляющих параметров $\sigma_s \in \{0.05, 0.1, 0.2, 0.3, 0.4, 0.5\}$ и $\sigma_t \in \{3, 5, 7\}$, для метода BM3D были использованы значения $\sigma \in \{0.05, 0.1, 0.2, 0.3, 0.4, 0.5\}$.

Сравнение стратегий шумоподавления проводилось на 2000 случайно выбранных изображениях из набора данных ImageNet. Выбранное количество изображений было ограничено из-за вычислительных ограничений. При этом оценка сначала проводилась на 20, затем на 50 и, наконец, на 2000 изображениях. Во всех случаях тенденции были идентичными, тогда как различия между средними значениями PSNR были незначительными. Результаты представлены в таблице 1. Для всех базовых методов был указан только лучший выбор параметров для конкретных шумовых условий. Хорошо видно, что метод глубокого сетевого шумоподавления, предложенный и оцененный в этой статье превзошел каждый из вышеупомянутых эталонных методов. Однако, что интересно, глубокая архитектура особенно эффективна при больших уровнях искажений. С другой стороны, исключением является случаи легкого шума соли и перца. Последний эффект может быть вызван плохой работой сверточных слоев с искаженными таким образом сигналами.

Чтобы оценить статистическую значимость наблюдаемых результатов, я провел знаковый ранговый тест Уилкоксона [23]. Предложенная стратегия шумоподавления основанная на сверточной нейронной сети достигла значительно более высокой производительности чем двусторонняя фильтрация и алгоритм BM3D на уровне значимости $\alpha=0.05$. С другой стороны, нельзя отвергать нулевую гипотезу по сравнению с медиальным фильтром. Однако анализируя результаты в Таблице 1, можно заметить, что их области компетенции дополняют друг друга и медианный фильтр работает лучше всего при обработке шума соли и перца, что неудивительно. Тем не менее результаты статистического анализа дополнительно подтверждают выбор сверточной сети по сравнению с обычными алгоритмами шумоподавления особенно, когда они связаны с процессом классификации как будет представлено в следующем разделе.

Предложенный метод достиг высокой устойчивости к типу и интенсивности шума, а также относительно высокого качества шумоподавления. Особенно

хорошие показатели наблюдались при работе с шумами квантования, а также с наиболее сильными искажениями других типов. Особенно последнее свойство очень обнадеживает (таблица 1).

Таблица 1. Средние значения PSNR для разных типов шума и шумоподавления.

Type of noise	Distortion level	Median	Bilateral	BM3D	CNN (this paper)
Gaussian (0.05)	26.40	26.87 (3)	31.70 (0.05, 3)	31.10 (0.05)	28.04
Gaussian (0.1)	20.60	24.44 (3)	27.50 (0.1, 3)	27.22 (0.1)	25.99
Gaussian (0.2)	15.09	21.98 (7)	23.08 (0.2, 3)	22.97 (0.2)	23.91
Gaussian (0.5)	9.18	18.55 (9)	17.07 (0.4, 7)	16.86 (0.3)	21.32
Quantization (0.05)	31.19	26.53 (3)	29.74 (0.05, 3)	29.44 (0.05)	29.89
Quantization (0.1)	25.24	23.63 (3)	25.53 (0.05, 3)	25.36 (0.05)	28.71
Quantization (0.2)	19.37	19.29 (3)	20.20 (0.05, 3)	20.06 (0.05)	26.74
Quantization (0.5)	12.01	12.40 (3)	12.87 (0.2, 3)	12.76 (0.1)	23.61
Salt & Pepper (0.05)	17.74	28.21 (3)	25.36 (0.2, 5)	25.06 (0.1)	24.79
Salt & Pepper (0.1)	14.73	27.32 (3)	23.38 (0.2, 7)	23.05 (0.2)	23.84
Salt & Pepper (0.2)	11.72	24.66 (3)	20.81 (0.3, 7)	19.93 (0.3)	22.59
Salt & Pepper (0.5)	7.74	20.24 (7)	15.36 (0.5, 7)	14.89 (0.4)	20.42
Random (Gaussian)	15.90	21.31 (7)	21.49 (0.3, 3)	20.75 (0.3)	21.75
Random (Quantization)	20.30	18.73 (3)	19.91 (0.05, 3)	19.60 (0.05)	22.32
Random (Salt & Pepper)	12.27	23.47 (5)	20.00 (0.3, 7)	19.14 (0.3)	20.65
Random (Mixture)	16.13	20.94 (5)	20.06 (0.3, 3)	19.26 (0.3)	20.45

Уровень искажений показан по отношению к исходному изображению. Лучший результат фильтрации выделен жирным шрифтом. Метод, предложенный в этой статье (CNN, сверточная нейронная сеть) сравнивалась с эталонными алгоритмами. Выбранные значения параметров показаны на индекс, а именно: размер окна для медианной фильтрации, σ_s и σ_t для двусторонняя фильтрация и σ для алгоритма BM3D.

Классификация при наличии шума:

Производительность обсуждаемой нейронной сети оценивалась в различных условиях шума присутствующего либо в обучающих данных, либо в тестовых данных, либо в обоих. Метрикой используемой для измерения производительности модели была точность классификации: доля тестовых изображений, для которых метка истинности и прогноз модели совпадали. Оценка началась с измерения точности сети без каких-либо искажений (базовый случай, называемый C2C). После этого было измерено влияние шума в тестовых данных не учтенного в процессе обучения (C2N). Примеры изображений, которые были очищены от шума и зависимость итоговой точности классификации в зависимости от разных типов и уровней шума представлены на рисунках 2 и 3. Даже относительно небольшие искажения существенно влияют на производительность сети.




Рисунок - 2. Образец изображения, испорченного 30% шумом соли и перца, до и после подавления шума.

Наличие шума более высокой интенсивности если его не учитывать не позволяло сети правильно распознавать представленные объекты.




Рисунок - 3. Связь между интенсивностью различных типов шума и точностью классификации.

Были скорректированы стандартное отклонение для гауссовского шума, вероятность переворачивания пикселя для шума соли и перца и диапазон искажений для шума квантования. Перед изменением размера изображений в соответствии с сетью был применен шум. Чтобы уменьшить серьезное влияние искажений на точность классификации были оценены две уже упомянутые стратегии борьбы с шумом. В первом случае, то есть при дополнении обучающих данных изображения искажались во время процедуры обучения тем же типом шума, который позже присутствовал во время оценки. Этот случай был обозначен как N2N. Во второй стратегии, то есть шумоподавлении изображений классификационная сеть обучалась на неискаженных данных. Сеть меньшего размера была специально обучена шумоподавлению изображений перед классификацией. Этот случай был обозначен C2D.

Важно отметить, что обе стратегии борьбы с искажениями могут успешно применяться в случае неизвестных шумовых условий. По сравнению со случаем, когда искажения не учитываются, обе стратегии привели к улучшению точности. Статистическую значимость этого улучшения оценивали с помощью знаково

рангового теста Уилкоксона. На уровне значимости $\alpha=0.05$ обе стратегии оказались существенно лучше, чем в случае, когда искажения не учитываются. Более того, стратегия увеличения данных оказалась значительно лучше, чем применение шумоподавления перед классификацией.

Основываясь на достигнутых результатах, стратегия увеличения данных позволяет добиться более высокой производительности.

Однако следует отметить, что более высокая точность классификации достигается за счет потенциально более длительного времени обучения. При использовании стратегии шумоподавления перенос весов из ранее обученной модели проще, поскольку доступность моделей, обученных распознавать неискаженные данные выше. Кроме того, для увеличения обучающих данных требуется либо возможность искусственно исказить изображения, либо получение большого количества данных с зашумленными метками. Эта проблема менее серьезна при использовании стратегии шумоподавления, поскольку в этом случае, изображения, используемые для обучения, не нуждаются в маркировке.

Шум как форма регуляризации и применение неправильной стратегии борьбы с шумом:

На заключительном этапе проведенного экспериментального исследования, был рассмотрен случай, когда применяется стратегия борьбы с шумом даже при отсутствии искажений при оценке. Прежде всего это служило целью проверки возможности использования шума в качестве еще одной формы регуляризации. Это позволило оценить негативное влияние выбора неправильной модели шума. Рассматривались как увеличение обучающих данных (N2C), так и шумоподавление (D2C), причем первое также соответствовало использованию шума в качестве регуляризатора.

Результаты этой части экспериментального исследования представлены на рисунке 5. Ни в одном случае увеличение тренировочных данных не привело к улучшению производительности по сравнению с базовым случаем. Другие прикладные формы регуляризации, а именно отсев и уменьшение веса были достаточны для обеспечения хороших возможностей обобщения модели. Возможно, вместо них можно будет использовать дополнительные обучающие данные. Однако применение его поверх них привело к снижению производительности вероятно из-за чрезмерной регуляризации.

Обе стратегии привели к значительному падению производительности в случае наиболее серьезных искажений, когда во время оценки шум отсутствовал. Эту проблему можно частично решить, обучив модель шуму случайной интенсивности и в этом случае снижения производительности будет менее значительным. Несмотря на меньший прирост точности в случае C2D, падение

точности в случае D2C было сопоставимо с N2C, а зачастую даже менее значительным. Полагается, что улучшение качества алгоритма шумоподавления может еще больше усилить эту тенденцию, что приведет к тому, что подход к шумоподавлению станет более безопасным из вариантов.

Позволять A_N быть точностью классификации при использовании дополнения обучающих данных, A_C точность без учета шума, A_{N2N} точность искаженных изображений при использовании дополнения обучающих данных, A_{N2C} точность на неискаженных изображениях в том же случае, A_{C2N} точность искаженных изображений без применения стратегии борьбы с шумом и A_{C2C} точность на чистых изображениях в том же случае. Учитывая вероятность искажения изображения p , ожидаемые значения A_N и A_C может быть определен как $E[A_N]$ и $E[A_C]$, соответственно:

$$E[A_N] = p \times A_{N2N} + (1 - p) \times A_{N2C} \quad (7)$$

$$E[A_C] = p \times A_{C2N} + (1 - p) \times A_{C2C} \quad (8)$$

Особый интерес представляет случай, когда использование стратегии увеличения данных приводит к повышению производительности. В таком случае имеет место следующее:

$$E[A_N] \geq E[A_C] \quad (9)$$

Это можно переформулировать чтобы подчеркнуть вероятность искажения входного набора данных, означает, что предлагаемый метод увеличения данных приводит к повышению точности обученной сети. Подставляя (7) и (8) в (9) и решая относительно p , получаем:

$$p \geq \frac{A_{C2C} - A_{N2C}}{A_{C2C} - A_{N2C} + A_{N2N} - A_{C2N}} \quad (10)$$

Аналогичный расчет можно выполнить и для случая, когда используется шумоподавление. Результаты экспериментального анализа представлены на рисунке 4. Повышение точности будет еще больше увеличиваться по мере увеличения доли искаженных изображений.




Рисунок - 4. Точность классификации в зависимости от типа примененного искусственного искажения в четырех различных случаях: без искусственного шума (C2C), с искаженным только тестовым набором (C2N), с искаженным как обучающим, так и тестовым набором (N2N) и с тестовым набором установить искажение и шумоподавление (C2D).

В случае шумоподавления не была указана вероятность шума квантования с интенсивностью 0,05 и 0,1. Это произошло из-за шумоподавления, которое привело к небольшому снижению производительности по сравнению с базовым вариантом. В остальных случаях вероятность искажения достаточная для оправдания применения стратегии борьбы с шумом всегда была меньше при дополнении данных. Это особенно справедливо для типов случайного шума, которые вероятно будут наиболее распространены в практических условиях. Вероятность искажения случайного типа достаточная для обоснования увеличения обучающих данных была близка к 10%. То есть если доля искаженных изображений превышает это значение ожидаемая точность будет выше при использовании увеличения данных чем при отсутствии учета шума⁷ Результаты проведенной оценки представлены на рисунке 5.




Рисунок - 5. Точность классификации после обучения на данных, дополненных шумом (N2C) или очищенных от шума (D2C), когда на тестовых изображениях не было никаких искажений.

Результаты показывают производительность модели, обученной распознавать зашумленные изображения, когда искажений на самом деле нет. Альтернативно, увеличение данных можно рассматривать как применение дополнительной формы регуляризации.

ЗАКЛЮЧЕНИЕ

В этой статье, был проведен тщательный экспериментальный анализ влияния шума на классификацию с помощью глубоких нейронных сетей. Исследована эффективность классификации при различных настройках шума, как с известными, так и с неизвестными моделями шума. Было оценено две возможные стратегии борьбы с шумом, а именно увеличение обучающих данных и шумоподавление перед классификацией. Рассмотрена возможность использования сверточной нейронной сети в качестве отдельного алгоритма шумоподавления. Также, измерено влияние использования этих стратегий при отсутствии шума что также может соответствовать использованию шума как формы регуляризации.

Основные выводы данной статьи заключаются в следующем:

Предлагаемая нейронная сеть с шумоподавлением превосходит по производительности все протестированные эталонные методы (медианная фильтрация, двусторонняя фильтрация и BM3D) в сочетании с шум квантования и сильные шумовые условия других типов, а также Гауссов шум случайной степени тяжести. При этом он дает хорошие результаты в остальных случаях в зависимости от типа и интенсивности шума некоторых эталонных методов;

Экспериментально подтверждены выводы работ, согласно которым, существует связь между интенсивностью шума и ухудшением точности классификации вплоть до того момента, когда правильная классификация становится совершенно невозможной;

Подтверждено, что использование шума, как формы регуляризации поверх других методов регуляризации, а именно уменьшения веса и исключения не улучшает точность классификации;

Оценка двух методов борьбы с шумом на изображениях: увеличение обучающих данных и шумоподавление перед классификацией. Результаты экспериментальной оценки показывают, что оба метода в зависимости от типа и интенсивности шума могут привести к значительному улучшению по сравнению со случаем, когда шум не учитывается.

Два основных направления исследований включают использование более эффективных стратегий шумоподавления и тестирование возможности точной настройки окончательной архитектуры в случае шумоподавления. Основываясь на результатах, представленных в этой статье предполагается, что для достижения более высокой точности, чем в случае увеличения данных потребуются значительно улучшить качество шумоподавления. Однако увеличение обучающих данных связано с более высокой стоимостью обучения и необходимостью иметь большие количества размеченных, зашумленных данных. По этой причине в практических приложениях шумоподавление может оказаться более целесообразным, даже несмотря на более низкую производительность.

СПИСОК ЛИТЕРАТУРЫ

1. Krizhevsky A, Sutskever I, Hinton GE. Классификация ImageNet с использованием глубоких сверточных нейронных сетей. В: Достижения в системах нейронной обработки информации; 2012. стр. 1097–1105.
2. Rafiei MH, Adeli H. Новая модель машинного обучения для оценки продажных цен объектов недвижимости. Журнал строительной инженерии и менеджмента. 2015;142(2):04015066.
3. Ortiz A, Munilla J, Górriz JM, Ramirez J. Ансамбли архитектур глубокого обучения для ранней диагностики болезни Альцгеймера. Международный журнал нейронных систем. 2016;26(07):1650025.
4. Rafiei MH, Khushefati WH, Demirboga R, Adeli H. Контролируемая машина Больцмана с глубоким ограничением для оценки бетона. Журнал ACI Materials. 2017;114(2).
5. Simonyan K, Zisserman A. Очень глубокие сверточные сети для крупномасштабного распознавания изображений. arXiv preprint arXiv:14091556. 2014;

6. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, et al. Углубляемся в извилины. Материалы конференции IEEE по компьютерному зрению и распознаванию образов; 2015. стр. 1–9.
7. He K, Zhang X, Ren S, Sun J. Глубокое остаточное обучение для распознавания изображений. В: Материалы конференции IEEE по компьютерному зрению и распознаванию образов; 2016. стр. 770–778.
8. Wager S, Wang S, Liang PS. Обучение отсеку как адаптивная регуляризация. Достижения в области нейронных систем обработки информации; 2013. стр. 351–359.
9. Xu B, Guo P, Chen C. Адаптивный метод регуляризации для разреженного представления. Интегрированная компьютерная инженерия. 2014;21(1): стр.91–100.
10. Neelakantan A, Vilnis L, Le QV, Sutskever I, Kaiser L, Kurach K, et al. Добавление градиентного шума улучшает обучение для очень глубоких сетей. arXiv preprint arXiv:151106807. 2015;
11. Koziarski M, Cyganek B. Исследование глубоких нейронных сетей при классификации искаженных сигналов. Международная конференция по искусственному интеллекту и мягким вычислениям.; 2016. стр. 680–688.
12. Dodge S, Karam L. Понимание того, как качество изображения влияет на глубокие нейронные сети. arXiv preprint arXiv:160404004. 2016;
13. Vasiljevic I, Chakrabarti A, Shakhnarovich G. Изучение влияния размытия на распознавание сверточными сетями. arXiv preprint arXiv:161105760. 2016;
14. Sanchez A, Moreno AB, Vélez D, Vélez JF. Анализ влияния контраста при крупномасштабном распознавании естественных изображений. Интегрированная компьютерная инженерия. 2016;23(3): стр.221–235.
15. Tan X, Triggs B. Расширенные наборы функций локальной текстуры для распознавания лиц в сложных условиях освещения. Транзакции IEEE по обработке изображений. 2010;19(6):стр.1635–1650.
16. Tirronen V, Neri F, Kärkkäinen T, Majava K, Rossi T. Усовершенствованная меметическая дифференциальная эволюция в конструкции фильтров для обнаружения дефектов при производстве бумаги. Эволюционные вычисления. 2008;16(4): стр.529–555.
17. Peng X, Hoffman J, Yu SX, Saenko K. Передача знаний от мелкого к крупному для классификации изображений с низким разрешением. arXiv preprint arXiv:160506695. 2016;
18. Kryszczuk K, Drygajlo A. Улучшение классификации с помощью независимых от класса показателей качества: Q-stack при проверке лица. В: Международная конференция по биометрии. Springer; 2007. стр. 1124–1133.
19. Abaza A, Harrison MA, Bourlai T, Ross A. Разработка и оценка фотометрических показателей качества изображения для эффективного распознавания лиц. Биометрия IET. 2014;3(4): стр.314–324.

20. Koziarski M, Cyganek B. Глубокое нейронное подавление шума изображения. Международная конференция по компьютерному зрению и графике. Издательство Springer International Publishing; 2016. стр. 163–173.
21. Agostinelli F, Anderson MR, Lee H. Адаптивные многоколоночные глубокие нейронные сети с применением для надежного подавления шума изображений. В: Достижения в системах нейронной обработки информации; 2013. стр. 1493–1501.
22. Jain V, Seung S. Естественное подавление шума изображения с помощью сверточных сетей. В: Достижения в системах нейронной обработки информации; 2009. стр. 769–776.
23. Chakrabarti A. Нейронный подход к устранению размытия движения вслепую. arXiv preprint arXiv:160304771. 2016;
24. Cheema TA, Qureshi IM, Jalil A, Naveed A. Искусственные нейронные сети для идентификации размытия и восстановления нелинейно ухудшенных изображений. Международный журнал нейронных систем. 2001;11(05): стр.455–461.
25. Bovik AC. Основное руководство по обработке видео. 2nd ed. Academic Press; 2009.
26. Schuler CJ, Hirsch M, Harmeling S, Schölkopf B. Учимся устранять помехи. Транзакции IEEE по анализу шаблонов и машинному интеллекту. 2016;38(7): стр.1439–1451.