


Одним из самых популярных и быстрорастущих применений искусственного интеллекта (ИИ) стала обработка изображений, а также анализ и преобразование мультимедиа, что неудивительно, ведь визуальное восприятие информации является нашим основным способом ее получения. Разработка новых инструментов для решения этих задач с привлечением нейросетей стимулирует развитие таких направлений, как диагностическая медицина, образовательные методики, агротехнологии, современные системы безопасности.



**Юрий Вувуньян,**  
профессор кафедры  
системного  
программирования  
и компьютерной  
безопасности ГрГУ,  
доктор физико-  
математических наук



**Светлана Зайкова,**  
доцент кафедры  
системного  
программирования  
и компьютерной  
безопасности ГрГУ,  
кандидат физико-  
математических наук

# Применение вейвлет-нейронных сетей для обработки медицинских изображений

Благодаря наращиванию мощностей и обучению нейронные сети стали способны обрабатывать большие объемы информации и анализировать значительные массивы данных, решая все более сложные задачи с высокой скоростью. Внедрение методов вейвлет-преобразований в технологию разработки новых нейронных сетей позволит расширить рамки их возможностей при работе с изображениями. В этой статье представлен один из вариантов применения вейвлет-нейронных сетей для ускоренной обработки визуальных данных.

Вейвлет-нейронные сети представляют собой сборник инструментов, позволяющих улучшить качество и расширение файлов, их информативность и совершать иные преобразования, необходимые в тех случаях, когда требуется детальная информация об изображении.

Вейвлеты подразумевают под собой функции, которые имеют свойства локализации по временным показателям и по частотам, что отличает их от классических синусоидных функций. Главная особенность вейвлетов – возможность адаптации к любым заданным масштабам и затратам времени, что позволяет быстро и корректно анализировать сигналы, содержащие низкочастотные и высокочастотные потоки. Это весьма эффективный метод для обнаружения и анализа определенных явлений в изображениях, что невозможно было бы реализовать классическим методом Фурье-преобразований [1, 2].

Компактность – одно из самых значимых свойств сетей, основанных на вейвлет-нейронных пре-

образованиях. Из-за того, что вейвлеты не имеют бесконечной волны синусоиды, они через ограниченную деятельность локализуют сигнал. Это свойство позволяет сжимать данные и избавляться от шума, тем самым выявляя и оставляя неизменными обрабатываемые детали. Высокий уровень компрессии делает их важным инструментом в цифровой обработке.

Существует множество разновидностей вейвлетов, их функции – не однообразный алгоритм. Хаар-вейвлеты используются для самых простых задач и базового анализа, более сложно структурированные вейвлеты Добеши – для выполнения многоплановых, объемных заданий. Разнообразие функций дает возможность оптимально подобрать вариант под конкретный случай.

Многоразрешающий анализ позволяет обрабатывать сигналы на разных уровнях разрешения, обеспечивая более четкое и глубокое исследование объекта изучения: начиная от общего сбора информации и до выявления его мельчайших деталей.

Вейвлет-преобразования – весьма надежный и эффективный метод обработки изображений, в основе которого лежит идея разложения сигнала на составляющие, что позволяет более глубоко изучить его сигнатуру, определяя различные особенности [3, 4].

Вейвлеты разделяются на несколько различных видов, каждый из которых имеет свою область применения.

CWT – непрерывное вейвлет-преобразование. Оно дает возможность получать более глубокое и доскональное представление о структуре сигнала. Этот вид удобно использовать для анализа сигналов с непрерывными изменениями частотного содер-

жания. Но сложность вычислений этого метода ограничивает его применение в прикладных задачах. Поэтому было создано дискретное вейвлет-преобразование (DWT), которое, в отличие от CWT, использует дискретные значения по масштабу и смещению. Тем самым затраты на вычисление ощутимо снижаются и делают новый метод более эффективным при практическом применении.

DWT позволяет обрабатывать цифровые сигнатуры, обеспечивая сжатие объема данных без существенной потери в качестве. Это делает его полезным инструментом для преобразования изображений в более компактные параметры (например, стандарт JPEG2000).

WPT – вейвлет-пакетное преобразование, отличается тем, что на каждом уровне разложения сигнала он разделяется как на низкочастотные, так и на высокочастотные составляющие и дает более четкое и подробное представление о высокочастотных компонентах, что весьма полезно для анализа текстур и решения задач обнаружения изображений.

MRA – многоразрешительный анализ – базовая концепция многих вариаций вейвлет-преобразований. Он позволяет просматривать сигнал с различными разрешениями, начиная от общего обзора его структуры до выявления самых мельчайших деталей. Этот подход важен для тщательного изучения сложных сигналов различных масштабов. MRA обеспечивает достойный уровень гибкости и точности, тем самым позволяет адаптировать методы к поставленным задачам и данным [5].

Различные типы вейвлет-преобразований предоставляют большую выборку инструментов для анализа и обработки сигнала.

тур сигналов и обладают набором уникальных преимуществ при работе с изображениями, что делает их незаменимыми в диагностической медицине, в частности при проведении и анализе томографий. Использование этих передовых технологий позволяет повысить детализацию и качество снимков, быстро и точно поставить диагноз [6].

Нейронные сети на основе биометрических процессов – это одно из самых быстрорастущих направлений в области изучения ИИ. Структуру таких сетей составляют слои, собранные из искусственных нейронов. Каждый отдельный нейрон принимает сигналы и при помощи нелинейных функций обрабатывает их. Несколько слоев могут работать над одной задачей в режиме многопоточности.

Подобная архитектура дает возможность смоделировать сложные зависимости и алгоритмы, что обеспечивает их высокую гибкость и мощность. Процесс работы нейронных сетей основан на главном аспекте – обучении сети, которое можно разделить на 2 этапа: прямое и обратное распространение ошибки. При первой процедуре входные данные проходят через все слои и в результате генерируется некий прогноз; на этапе же обратного распространения ошибки проводится корректировка ошибок и другие процессы устранения коллизий и несовпадений.

В настоящее время вейвлет-преобразования предоставляют возможность гибкого и эффективного подхода к обработке и слиянию изображений. Они могут локализовать информацию во времени и частоте и сохраняют важные детали на разных уровнях как для уменьшения, так и увеличения картинки. Этот

метод возможен благодаря разложению исходных снимков на вейвлет-коэффициенты, с помощью комбинирования которых с применением различных правил слияния и последующим обратным вейвлет-преобразованием получается итоговое изображение высокого качества, с сохранением важных деталей и текстур.

Интеграция вейвлет-преобразований с нейронными сетями открывает новые возможности для слияния изображений. Метод реализуется с помощью вейвлет-базисной функции с характеристиками поддержки и среднего нулевого значения, включая дискретное вейвлет-преобразование DWT [7].

В архитектуре DWT входной сигнал разбивается на составляющие различных частотных диапазонов с помощью двух фильтров – верхних и нижних частот. Первый фиксирует подробные характеристики сигнала, второй – грубые. Путем многократного разложения низкочастотных компонентов создается многомасштабная структура. После каждого этапа декомпозиции объем данных уменьшается за счет понижающей дискретизации, и важная информация о сигнале сохраняется. При восстановлении исходного сигнала он воссоздается с помощью обратной фильтрации и повышающей дискретизации, чтобы обеспечить его целостность.

Интеграция моделей глубокого обучения, основанных на вейвлет-преобразовании, таких как сверточные нейронные сети (CNN) и конвертерные модели, расширила возможности обработки сигналов и изображений. Вейвлет-преобразование используется для первоначального выделения признаков, чтобы улучшить способность модели фик-

сировать многомасштабную информацию. Такой подход подерживает отличную производительность в области устранения помех на изображениях, сжатия, анализа текстур и т.д.

Благодаря постоянной оптимизации методов выбора вейвлет-базисной функции и восстановления декомпозиции обеспечивается адаптивность и преимущество в производительности (рис. 1).

Входные сигналы  $x$  проходят через блок с функциями ( $\psi(x)$ ,  $\chi(x)$ ,  $\lambda(x)$ ,  $\theta(x)$ ), которые основаны на вейвлетах и обрабатываются на различных уровнях и слоях. В результате полученные значения объединяются и передаются на полносвязный слой, в котором происходит взвешенное суммирование, необходимое для получения окончательного результата. Архитектура такого типа демонстрирует, что вейвлет-преобразования могут быть интегрированы в нейронную сеть, тем самым улучшая ее способность к анализу и обработке изображений, включая их слияние [7].

Свои собственные характеристики в задачах объединения изображений будут иметь функции различных вейвлетов, их производительность в свою очередь будет зависеть от выбора базовой функции вейвлета и различных характеристик изображения.

Отметим, что благодаря своей простоте и вычислительной эффективности вейвлеты Хаара отлично подходят для обработки в реальном времени и базовых задач слияния изображений, но обладают ограниченной производительностью при захвате деталей. Эксперименты показали: функция ступенчатого базирования приводит к тому, что обработка краев изображений получается недостаточно плавной,

и иногда эффект слияния оставляет желать лучшего.

Вейвлеты Добеши обеспечивают более высокую ортогональность и более длительную поддержку, позволяют фиксировать детали и информацию о текстуре изображения. Увеличенная длина фильтра позволяет более точно выделять объекты и уменьшает ошибки реконструкции. Однако вычислительная сложность в данном случае выше и требует больше времени и ресурсов на обработку.

Вейвлеты Койфлет справляются с сохранением характеристики изображения и его краев для высокоточного слияния. Они обладают превосходными характеристиками локализации в частотно-временной области. Однако вычислительная сложность алгоритма относительно высока и нуждается в оптимизации для повышения эффективности обработки.

Вейвлеты Симлет – это симметричные, с похожими характеристиками вейвлеты Добеши, помогающие уменьшать граничные эффекты и лучше обрабатывать

края изображений, что обеспечивает более естественный эффект перехода при их слиянии и подходит для приложений с высокими требованиями к качеству краев.

## Разработка концепции алгоритма

Процесс вейвлет-слияния начинается с отдельно взятого изображения, которое раскладывается на большое множество коэффициентов, представляющих собой всевозможные уровни детализации или/и приближения, что позволяет выделить самые важные компоненты. Разложение также может включать использование высоких или низких фильтров соответственной частоты, разделяющихся уже на множество поддиапазонов частот для данных изображений, содержащих информацию о таких его аспектах, как структура и/или текстура, делающих их идеальными для следующих слияний.

В конце каскада данных разложений с помощью вейвлет-коэффициентов следует выбор

некоторых, нужных в каждой конкретной ситуации, правил соединения (слияния) этих же коэффициентов. Важно отметить, что применение нейросетей позволяет извлечь разноуровневые (предпочтительнее высокоуровневые) признаки, которые скрыты от обычного использования. Такой подход также можно задействовать для оптимизации слияния и выявления нужных признаков.

Следующий этап нашего исследования – разработка программного решения, включающего в себя комбинацию вейвлет-нейронных преобразований и пользовательских функций. Оптимальным следует считать выбор языка Python, в котором собрано большое количество как готовых решений и библиотек, так и инструментов для самостоятельной разработки проектов. Наиболее подходящей средой является PyCharm, а для обучения нейронной сети подходят функциональные возможности Google Collab.

Создание вейвлет-нейронной сети проводилось на базе архи-

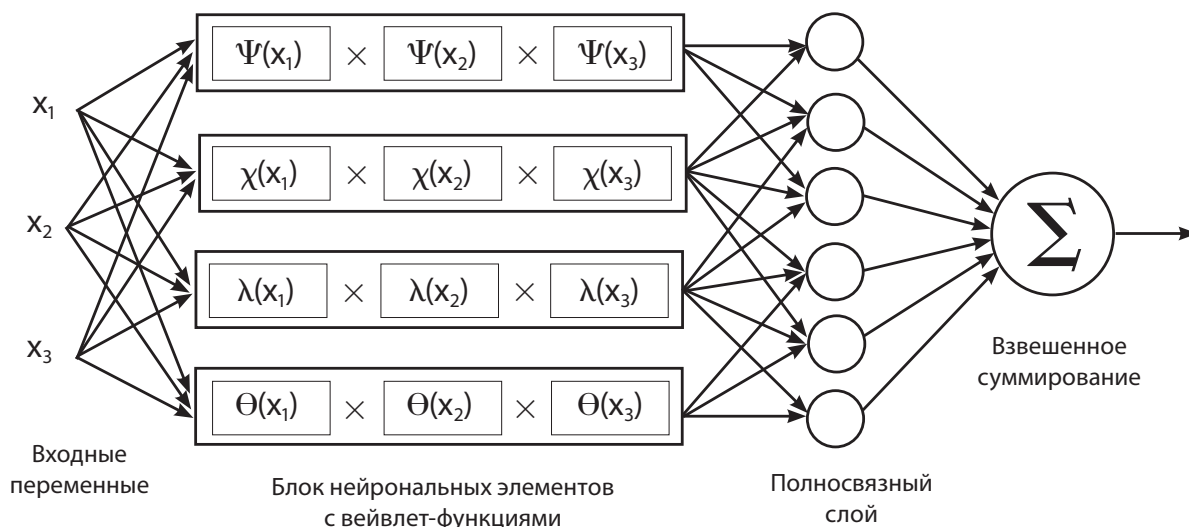


Рис. 1. Модель искусственного вейвлет-нейрона




Рис. 2. Изображение с шумом




Рис. 3. Изображение без шума




Рис. 4. Результат выполнения операции слияния изображений

тектуры U-Net. В каждой эпохе происходило обучение модели на зашумленных данных, затем вычисление функции потерь и обратное распространение ошибки для обновления весов модели, оценка ее на валидационных данных и сохранение, если ошибки уменьшались.

## Обработка медицинских изображений

На основе модели UFocus модифицированной архитектуры U-Net с добавлением блоков внимания удалось эффективно выделять важные области на изображениях и удалять шум. Главное окно программы предоставляет пользователю, специалисту по обработке медицинских изображений, варианты для выбора функционала: слияния изображений и удаления шума. При нажатии на соответствующую кнопку открывается окно интерфейса.

Функция `load_denoising_model` загружает обученную модель из указанного файла и переводит ее в режим оценки (`eval`). Результат работы нейросети – изображения с шумом и после его удаления – представлены на рис. 2, 3.

Разработчики системы предусмотрели возможности выбора настроек типа вейвлета. Это позволило значительно повысить эффективность конечных этапов обработки специализированных медицинских данных и улучшить степень детализации в анализируемом изображении. Результат указанного процесса и успешное выполнение операции слияния представлены на рис. 4.

Проведенное исследование показало, что предложенное авторами программное решение позволило реализовать эффективный инструмент для обработки медицинской информации, а также улучшать детализацию изображений, повысить уровень диагностики.

\*\*\*

Таким образом, новейшие разработки по обучению и использованию нейронных сетей упрощают методы решения сложных, многогранных и ресурсоемких задач. Результаты проведенного эксперимента позволяют выделить вейвлет-преобразования как эффективный инструмент для высокоточной диагностики.

Разработанные методы и новое программное обеспечение имеют потенциал для дальнейшего раз-

вития и внедрения в различные практические приложения. Предложенный подход будет способствовать развитию визуализации не только в медицинской сфере, но и в других областях, например при обработке звуковых сигналов, в финансовой аналитике, что может быть важным инструментом для принятия обоснованных инвестиционных решений. ■

### СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Best Programming Language for Machine Learning // <https://clck.ru/34MecV>.
2. Deep Learning by Goodfellow, Bengio, and Courville // <https://clck.ru/3B54EG>.
3. LeCun Y., Bengio Y., Hinton G. Deep Learning // <https://clck.ru/3B54b9>.
4. Genetic Algorithms vs Neural Networks // <https://clck.ru/3B54ie>.
5. Мюллер А. Введение в машинное обучение с помощью Python: Руководство для специалистов по работе с данными / А. Мюллер, С. Гвидо. – М., 2017.
6. Зайкова С.А. Защита специальных данных пациентов в медицинском центре / С.А. Зайкова // Технические средства защиты информации: тезисы докладов XXII Белорусско-российской науч.-техн. конф., Минск, 12 июня 2024 г. / ред. кол.: Т.В. Борботько. – Минск, 2024. С. 38–39.
7. Вувиукия Ю.М. Математическое моделирование вейвлет-нейронных сетей для обработки изображений / Ю.М. Вувиукия, С.А. Зайкова // 5-я междунар. науч. конф. «Математическое моделирование и дифференциальные уравнения»: мат-лы междунар. науч. конф., Минск, 17–19 декабря 2024 г. – Минск, 2024. С. 9–10.