

СОВРЕМЕННОЕ СОСТОЯНИЕ И ПЕРСПЕКТИВЫ РАЗВИТИЯ МЕТОДОВ КОМПЛЕКСИРОВАНИЯ РАЗНОСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ

Шао Юаньдун¹

Научный руководитель – научный сотрудник, канд. тех. наук, Васильев А. С.¹

¹Университет ИТМО

a_s_vasilev@itmo.ru

Введение

В современном мире комплексирование изображений инфракрасного и видимого диапазонов спектров широко применяется для визуального улучшения изображения и повышения вероятности обнаружения и распознавания объектов. Комплексирование так же эффективно применяется в условиях, когда аппаратные средства приближаются к ограничениям своих физических возможностей, в частности по разрешающей способности, размеру пикселя или чувствительности фотоприемника. Традиционные методы комплексирования [1, 2] отличаются простотой, наглядностью и низкими требованиями к вычислительным мощностям, поскольку правила комплексирования в них задаются путем подбора параметров уравнений. Более новые методы, основанные на глубоком обучении, лучше всего работают при захвате высокоуровневых семантических признаков и сохранении мелких деталей изображения. В работе сравниваются традиционные методы комплексирования изображений на основе пиксельной обработки и новые подходы на основе нейросетевого преобразования и оценивается перспективы их использования в будущем.

Основная часть

Современные методы комплексирования изображений делятся на традиционные и методы на основе глубокого обучения. Основной подход в традиционных методах заключается в реализации соответствующего математического преобразования. Чтобы адаптировать эти методы к различным изображениям и разработать специфические правила объединения, необходимо анализировать значения пикселей в пространственной или частотной областях. В свою очередь, существующие методы на основе глубокого обучения сосредоточены на разработке и улучшении архитектуры алгоритмов для трех этапов: извлечение признаков, их объединение и реконструкция изображения. Оба подхода сталкиваются с рядом проблем, таких как объединение ненормализованных данных, комплексирование изображений с разным пространственным разрешением, работа в режиме реального времени, сохранение информации исходных изображений и определение весов для вклада каждого из них.

Традиционные методы комплексирования изображений, как правило, опираются на извлечение и сопоставление характерных точек. Однако при работе с инфракрасными и видимыми изображениями такие методы часто не позволяют достичь желаемых результатов, поскольку выделение и согласование ключевых точек на разнородных снимках существенно затруднены. С развитием технологий глубокого обучения подходы к сопоставлению и комплексированию изображений, основанные на нейросетях, стали актуальным направлением исследований.

В ходе исследования были проведены сравнительные оценки традиционных методов комплексирования изображений на основе вейвлет-преобразования [2], степенного преобразования [2] и нейросетевого преобразование RFN-Nest (residual fusion network nest) [4]. С целью систематизации критериев выбора метода комплексирования для прикладных задач был проведен анализ архитектур алгоритмов, их

производительности, а также механизмов и результатов комплексирования на парах изображений видимого и инфракрасного диапазонов.

Вейвлет-комплексирование обеспечивает сохранение как общей структуры, так и локальных деталей разномасштабных изображений. Метод демонстрирует баланс между эффективностью и степенью сохранения детализации, однако характеризуется высокой вычислительной сложностью и критичностью к выбору вейвлет-базиса. Метод степенного преобразования повышает контрастность и позволяет проработать тонкие текстуры на низко-контрастных изображениях. Обладая линейной вычислительной сложностью ($O(N)$) и низкими требованиями к памяти, данный подход хорошо подходит для систем реального времени. Однако его существенным ограничением остается чувствительность к пространственному рассогласованию изображений. В отличие от двух рассмотренных выше методов, подходы на основе глубокого обучения обеспечивают одновременное сохранение общего контраста и передачу контуров объектов без усиления шумов.

Для комплексной оценки практической реализуемости рассматриваемых подходов был проведен их сравнительный анализ по двум критериям: возможность для работы в реальном времени и интеграции программного кода на целевое устройство. По критерию быстродействия алгоритм на основе степенного преобразования демонстрирует наилучшие результаты: время обработки составляет единицы миллисекунд при высокой стабильности работы. Вейвлет-преобразование обеспечивает баланс между качеством комплексирования и достоверностью выходных данных. В свою очередь, метод RFN-Nest позволяет достичь максимального визуального качества результирующего изображения, однако его производительность существенно зависит от вычислительной мощности процессора. Кроме того, для применения данного метода требуется подготовка обучающих выборок под каждую конкретную задачу или сценарий. С точки зрения программно-аппаратной реализации традиционные методы имеют преимущество благодаря более простой структуре кода и низким требованиям к вычислительным ресурсам, тогда как метод RFN-Nest опирается на сложные архитектуры глубокого обучения.

Выводы

Результаты системного анализа показали, что степенное преобразование является наиболее быстрым решением. Вейвлет-преобразование, уступая ему по скорости, обеспечивает качество изображения, близкое к нейросетевым методам, и позволяет гибко настраивать коэффициенты для работы с разными масштабами, достигая компромисса между достоверностью и адаптируемостью. Наилучшее качество визуализации (средний прирост показателей более 10 % и максимальная детализация) демонстрирует метод RFN-Nest. Вместе с тем он предъявляет высокие требования к аппаратному обеспечению и характеризуется наибольшей вычислительной задержкой, что в текущих условиях делает его применимым лишь в задачах постобработки или при использовании высокопроизводительных платформ.

Литература

1. Li, Shutao, et al. Pixel-level image fusion: A survey of the state of the art.// Information Fusion 33, 2017, p. 100-112.
2. Vasilev A. S., Korotaev V. V. Research of the fusion methods of the multispectral optoelectronic systems images //Automated Visual Inspection and Machine Vision. – SPIE, 2015. – Т. 9530. – С. 50-58.
3. G. Pajares, J.M. De La Cruz, A wavelet-based image fusion tutorial, PatternRecognit. 37(2004)1855-1872.
4. Li, Hui, Xiao-Jun Wu, and Josef Kittler. "RFN-Nest: An end-to-end residual fusion network for infrared and visible images." Information Fusion 73 (2021): 72-86.