

УДК 004.932

ПРИМЕНЕНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ ФРАКТАЛЬНОГО СЖАТИЯ ИЗОБРАЖЕНИЙ

Колмыков М. В., аспирант Рязанского Государственного Университета им. С. А. Есенина,
e-mail: m.kolmikov@rsu.edu.ru

Ручкин В. Н., д.т.н., профессор кафедры ИВТ Рязанского Государственного Университета им. С. А. Есенина

Несмотря на наличие различных алгоритмов компрессии/декомпрессии, с появлением новых технических средств вопрос сжатия остается актуальным, поскольку эти средства позволяют оценить возможности уже существующего математического аппарата, применяемого для сжатия изображений.

К алгоритмам сжатия предъявляют следующие основные критерии оценки:

1. степень компрессии;
2. класс изображений, на который ориентирован алгоритм (монохромные, фотореалистичные изображения или деловая графика и т. д.);
3. симметричность (характеризует ресурсоемкость процессов кодирования и декодирования, в частности по времени – отношение времени кодирования ко времени декодирования).

Примерами эффективных методов сжатия видеoinформации являются наиболее распространенные: классические дискретные косинусные преобразования (ДКП), вейвлет- и фрактальные преобразования [1,2]. Они используются международными стандартами MPEG [3] и JPEG.

Основной идеей фрактального сжатия, впервые предложенного Майклом Барнсли и Аланом Слоуном, является представление исходного изображения как неподвижной точки некоторого сжимающего оператора, действующего на множестве изображений [4]. При этом используется подобие между фрагментами сжимаемого изображения. Коэффициенты сжатия изображений фрактальными алгоритмами находятся в пределах 2-2000. Преимущество фрактального анализа обеспечивает получение более структурируемого представления информации, что позволяет увеличить коэффициент сжатия при сохраняющемся качестве изображения и дополнительно осуществить многомасштабный анализ (Zoom) изображений. Основным недостатком данного алгоритма является то, что требуются значительные вычислительные ресурсы, но разархивация проходит достаточно быстро. Значительные ресурсы требуются для того, чтобы подобрать для каждого блока изображения максимально подобный ему (с точностью до аффинного преобразования). Для сокращения и ускорения полного перебора всех участков изображения разработано много методов.

Кратко методы ускорения можно классифицировать как основанные на:

1. аппаратном распараллеливании и ускорении вычислений (использование в вычислительном устройстве нескольких процессоров);
2. уменьшении количества сравнений одного блока с другими (путем задания критериев, определяющих количество сравнений);

Рассмотрен алгоритм фрактального сжатия изображений на основе метода Барнсли. Предложен подход повышения эффективности фрактального метода сжатия, основанный на применении самоорганизующейся нейронной сети. Приведены результаты реализации алгоритма на нейропроцессоре NM6403.

3. изменении алгоритма (построение гибридных алгоритмов сжатия).

Одним из методов сокращения времени кодирования фрактальным алгоритмом является метод, основанный на самоорганизующихся картах Кохонена [5]. При обучении данных сетей используется метод без использования учителя, то есть результат обучения зависит только от структуры входных данных. Нейронные сети данного типа часто применяются для решения самых различных задач.

Самоорганизующаяся карта характеризуется решеткой узлов, представляющих собой нейроны – n -мерные вектор-столбцы $f = [f_1, f_2, \dots, f_n]^T$, где n определяется размерностью исходного пространства (размерностью входных векторов). Решетка узлов, как правило, состоит из квадратных или шестиугольных ячеек. От количества нейронов зависит степень детализации результата работы алгоритма.

Вначале при обучении карты весовые коэффициенты нейронов инициализируются случайными значениями. Затем в сеть поступает входной вектор характеристик, и осуществляется поиск весового вектора, наиболее близкого к входному вектору. При этом находится нейрон-победитель, который наиболее похож на вектор входа. Затем производится корректировка весов нейросети, при этом вектор, описывающий нейрон-победитель и вектора, описывающие его соседей в сетке перемещаются в направлении входного вектора.

Схема предлагаемого алгоритма

Компрессия изображений состоит из трех этапов.

1. *Классификация доменных блоков.* После обучения нейросети доменные блоки для данного изображения классифицируются путем сопоставления каждому из них весового вектора, самого близкого к нему в пространстве характеристик. Таким образом, каждый узел решетки имеет весовой вектор и связанный с ним список доменных блоков. Этот список доменных блоков принадлежит «классу», сопоставленному этому весовому вектору. Класс – это множество всех изображений, более близких в пространстве характеристик к данному весовому вектору, чем к какому-либо другому вектору в решетке.

2. *Классификация ранговых блоков.* Когда вектор характеристик рангового блока поступает в сеть, ему тоже сопоставляется весовой вектор сети.

3. *Сопоставление ранговых и доменных блоков.* На этом этапе ранговый блок сравнивается с доменами, которые сопоставлены данному весовому вектору, а также с доменами, сопоставленными весовым векторам из окрестности данного вектора в сети. Отслеживается минимальная разность между характеристиками.

Данный алгоритм имеет некоторые вычислительные издержки, связанные с поиском весового вектора, ближайшего к характеристическому вектору рангового блока. Значение этих издержек уменьшается с увеличением общего количества доменов.

Декомпрессии не требуется карта, она осуществляется на основе применения аффинных преобразований к произвольному изображению заданного числа итераций.

Для реализации нейросистем наиболее часто применяются цифровые сигнальные процессоры (DSP). Однако возможности DSP не полностью соответствуют задачам, которые возникают при моделировании нейронных систем. Кроме того, нейропроцессоры являются наиболее быстродействующим средством для построения нейросистем. Ядро нейросигнальных процессоров представляет собой типовой сигнальный процессор, а реализованная на кристалле логика обеспечивает выполнение нейросетевых операций. Примером нейропроцессоров является серия NM640x, реализующая архитектуру NeuroMatrix, аппаратная структура которой адаптирована для решения задачи создания нейросистем. Также процессоры семейства NeuroMatrix отличаются высокой производительностью при обработке больших потоков данных, требуют меньших аппаратных затрат, чем универсальные векторно-конвейерные процессоры, и как следствие, более экономичны. Рассматриваемый алгоритм фрактального сжатия был реализован в программном комплексе ImCo (C++, wxWidgets) [6]. В нем имеется возможность производить компрессию и декомпрессию изображений как на процессоре семейства x86, так и на нейропроцессоре NM6403. Выбор процессора представляется как опция. При реализации фрактального алгоритма на выходе формируется файл с расширением .frac, в котором отображается система итерируемых функций для входных изображений. На вход декомпрессора, соответственно, поступает .frac-файл, а на выходе формируется изображение в указанном формате.

Применение данного метода сжатия позволило получить следующие результаты: тестовое изображение Lena.raw (рис. 1) размером 256x256 пикселей в 256 градаций серого за 63 секунд было сжато с 70 до 20 кб с показателем PSNR 28.4 дБ. Использование метода прямого перебора или метода Фишера (метода классификации доменных и ранговых блоков) в процессе сжатия рассмотренного тестового изображения характеризуется существенно более высокими затратами времени на сжатие и худшими показателями PSNR.

Таким образом, для классификации доменных и ранговых областей в данной работе была рассмотрена самоорганизующаяся нейронная сеть Кохонена, обучающаяся на данных векторов характеристик, полученных для доменных блоков некоторого стандартного изображения. Преимущество использования самоорганизующейся сети в том, что не нужно решать, какой класс должен быть выбран при классификации. Сеть самоорганизуется в кластеры, представляющие классы изображений, которые определяются содержащимися в них данными изображения.



a)



б)

Рис. 1. *Lenna.raw* – исходное изображение для тестирования алгоритмов сжатия –а); декодированное изображение *Lena.frac* –б)

Изображение, используемое при обучении, может не быть подобным тому изображению, которое должно быть закодировано. Следовательно, время обучения сети не входит в общее время кодирования. Если количество доменов велико, то использование нейросети дает значительный выигрыш во времени, и к тому же обеспечивается высокое качество декодируемого изображения.

Литература

1. Нейрокомпьютеры в системах обработки изображений. Кн. 7: Коллективная монография / Общая ред. А. И. Галушкина. – Радиотехника, 2003.- 192 с.: ил.
2. Ватолин Д., Ратушняк А., Смирнов М., Юкин В. Методы сжатия данных. Устройство архиваторов, сжатие изображений и видео. - М.: ДИАЛОГ-МИФИ, 2002. 384 с.
3. Стандарт MPEG-<http://www.pskovsat.ru/standarts/mpeg2.html>.
4. Barnsley, M., Hurd, L., Fractal Image Compression, AK Peters, Wellesley, 1993.
5. Kohonen, T., Self-Organizing Maps, Berlin - New York: Springer-Verlag. Third extended edition 2001.
6. Колмыков М. В., Ручкин В.Н, Романчук В.А. «Возможности программного комплекса Nm model для разработки и отладки программ обработки изображений» Вестник РГПУ №2 (выпуск 24) 2008 год стр. 83-85

APPLICATION OF SELF-ORGANIZING NEURAL NETWORK FOR FRACTAL IMAGE COMPRESSION.

Kolmykov M. V., Ruchkin V. N.

The algorithm of fractal image compression based on the method of Barnsley. An approach efficiency of fractal compression method based on the use of self-organizing neural network. The results of the implementation of the algorithm on neyroprocessor NM6403.