

АДАПТИВНЫЙ ПАРАМЕТРИЗОВАННЫЙ ПРЕДСКАЗАТЕЛЬ ДЛЯ ДИФФЕРЕНЦИАЛЬНОЙ КОМПРЕССИИ ИЗОБРАЖЕНИЙ

М.В. Гашников, С.А. Муллина

Самарский государственный аэрокосмический университет им. академика С.П. Королёва
(национально исследовательский университет)

В работе описывается модификация адаптивного параметризованного предсказателя для дифференциальных методов компрессии изображений. Предсказатель способен автоматически использовать различные способы расчета в зависимости от гладкости локального участка изображения. Параметры предсказателя настраиваются автоматически с помощью простой рекуррентной схемы. Проведено исследование предложенного алгоритма на Waterloo-наборе изображений и сравнение с методом компрессии JPEG.

Дифференциальные методы компрессии изображений [1], которые также называют методами дифференциальной импульсно-кодовой модуляции (ДИКМ), обладают целым рядом важных достоинств: низкой вычислительной и структурной сложностью, возможностью управления коэффициентом компрессии без использования буферной памяти и т.д. Дифференциальные методы применяются для компрессии данных дистанционного зондирования Земли [2,3] и входят в состав других, более сложных методов сжатия, например JPEG [4]. В настоящее время задача совершенствования таких методов по-прежнему является актуальной.

При ДИКМ-компрессии изображение $x(n_1, n_2)$ просматривается в режиме построчной развёртки]. Для каждого отсчета $x(n_1, n_2)$ на основе уже обработанных отсчетов вычисляется предсказанное значение $\hat{x}(n_1, n_2)$, которое затем вычитается из исходного значения $x(n_1, n_2)$ для получения разностного сигнала. Затем разностный сигнал квантуется [1] и кодируется («упаковывается» в архивный файл либо канал связи). Выбирая различные предсказатели, квантователи и «упаковщики», можно получать дифференциальные методы с принципиально различными характеристиками.

Предсказатель является центральным элементом метода ДИКМ и во многом определяет его эффективность. Часто в качестве предсказанных значений используют один из ближайших уже обработанных отсчетов или их полусумму:

$$\hat{x}^{(0)}(n_1, n_2) = \bar{x}(n_1 - 1, n_2), \quad \hat{x}^{(1)}(n_1, n_2) = \frac{\bar{x}(n_1 - 1, n_2) + \bar{x}(n_1, n_2 - 1)}{2},$$
$$\hat{x}^{(2)}(n_1, n_2) = \bar{x}(n_1, n_2 - 1),$$

где $\bar{x}(n_1, n_2)$ – отсчеты, уже прошедшие обработку и восстановление.

Известны также нелинейные предсказатели, например предсказатель Грэхема [1], который предсказывает (см. рис. 1) «вдоль» вертикального либо горизонтального контура:

$$\hat{x}^G(n_1, n_2) = \begin{cases} \hat{x}^{(0)}(n_1, n_2), & \text{если } A(n_1, n_2) < B(n_1, n_2), \\ \hat{x}^{(2)}(n_1, n_2), & \text{если } A(n_1, n_2) \geq B(n_1, n_2), \end{cases}$$

где

$$A(n_1, n_2) = |\bar{x}(n_1, n_2 - 1) - \bar{x}(n_1 - 1, n_2 - 1)|, \quad B(n_1, n_2) = |\bar{x}(n_1 - 1, n_2) - \bar{x}(n_1 - 1, n_2 - 1)|.$$

Усредняющий предсказатель $\hat{x}^{(1)}$ точнее на ровных участках изображения, предсказатель Грэхема \hat{x}^G эффективнее на контурах. В данной работе предлагается адаптивный параметризованный предсказатель, который в каждой точке изображения может автоматически переключаться между этими двумя предсказателями, в зависимости от гладкости текущего участка изображения. Идея такого предсказателя была предложена

в [5] для другого метода компрессии, основанного на иерархической сеточной интерполяции [6,7]. В данной работе такой предсказатель модифицирован для использования в методе ДИКМ:

$$\hat{x}^A(n_1, n_2) = \begin{cases} \hat{x}^{(0)}(n_1, n_2), & \text{если } \mu(n_1, n_2) \leq \alpha^{(-)}, \\ \hat{x}^{(1)}(n_1, n_2), & \text{если } \alpha^{(-)} < \mu(n_1, n_2) < \alpha^{(+)}, \\ \hat{x}^{(2)}(n_1, n_2), & \text{если } \mu(n_1, n_2) \geq \alpha^{(+)}, \end{cases}$$

где $\mu(n_1, n_2) = B(n_1, n_2) - A(n_1, n_2)$ признак наличия контура в данной точке,

а $\alpha^{(-)}, \alpha^{(+)}$ – автоматически вычисляемые границы переключения между предсказателем Грэхема и усредняющим предсказателем. Нетрудно видеть, что при нулевых значениях параметров адаптивный предсказатель \hat{x}^A превращается в предсказатель Грэхема \hat{x}^G , а при достаточно больших значениях параметров – в усредняющий предсказатель $\bar{x}^{(1)}$.




Рисунок 1 – Предсказатель Грэхема. Утолщенными линиями выделены анализируемые разности отсчётов $A(n_1, n_2), B(n_1, n_2)$; стрелками – возможный выбор отсчётов в качестве предсказанного значения

Параметры $\alpha^{(+)}$ и $\alpha^{(-)}$ вычисляются однократно и автоматически исходя из минимизации суммарной погрешности предсказания:

$$\varepsilon(\alpha^{(+)}, \alpha^{(-)}) = \sum_{n_1, n_2} |x(n_1, n_2) - \hat{x}(n_1, n_2)| \rightarrow \min_{\alpha^{(-)}, \alpha^{(+)}}.$$

Рассмотрим величину:

$$\varepsilon^{(+)}(\alpha^{(+)}) = \sum_{(n_1, n_2) \in I^{(+)}} |x(n_1, n_2) - \hat{x}(n_1, n_2)|,$$

где $I^{(+)}$ – множество индексов отсчётов изображения, для которых значение признака $\mu(n_1, n_2)$ больше нуля. Соответственно, величина $\varepsilon^{(+)}(\alpha^{(+)})$ представляет собой суммарную погрешность, вычисленную по тем отсчетам изображения, где значение признака $\mu(n_1, n_2)$ положительно. Данная величина зависит только от $\alpha^{(+)}$ и не зависит от $\alpha^{(-)}$. Аналогичным образом введём зависящую только от $\alpha^{(-)}$ величину $\varepsilon^{(-)}(\alpha^{(-)})$, которая соответствует отсчетам с отрицательным значением признака $\mu(n_1, n_2)$. Теперь общая суммарная погрешность предсказания отсчётов может быть представлена в виде:

$$\varepsilon(\alpha^{(+)}, \alpha^{(-)}) = \varepsilon^{(+)}(\alpha^{(+)}) + \varepsilon^{(0)} + \varepsilon^{(-)}(\alpha^{(-)}),$$

где $\varepsilon^{(0)}$ – не зависящая от параметров $\alpha^{(-)}, \alpha^{(+)}$ величина, соответствующая нулевым значениям признака $\mu(n_1, n_2)$.

Таким образом, двухпараметрическую задачу поиска минимума функции $\varepsilon(\alpha^{(+)}, \alpha^{(-)})$ можно разбить на две независимые однопараметрические задачи:

$$\alpha^{(+)} = \arg \min_{\alpha} \varepsilon^{(+)}(\alpha), \quad \alpha^{(-)} = \arg \min_{\alpha} \varepsilon^{(-)}(\alpha)$$

Рассмотрим алгоритм решения первой задачи, т.е. поиск параметра $\alpha^{(+)}$. Пусть количество возможных значений, принимаемых параметром, равно M (для байтовых изображений $M = 256$). Для нахождения параметра $\alpha^{(+)}$ при первом проходе по изображению заполняем два одномерных массива E^0 и E^1 длины M :

$$E_{\mu}^{(i)} = \sum_{(n_1, n_2) \in I^{\mu}} |x(n_1, n_2) - \tilde{x}^{(i)}(n_1, n_2)|, \quad i = 0, 1,$$

где I^{μ} – множество индексов отсчётов, значение признака для которых равно μ . Далее производится вычисление суммарной погрешности $\mathcal{E}^{(+)}(\alpha^{(+)})$ при каждом $\alpha^{(+)}$. Для этого используются следующее рекуррентное выражение, позволяющее существенно сократить вычислительную сложность решения по сравнению с полным перебором:

$$\mathcal{E}^{(+)}(0) = \sum_{\mu=0}^{M-1} E_{\mu}^{(0)}, \quad \mathcal{E}^{(+)}(\alpha+1) = \mathcal{E}^{(+)}(\alpha) - E_{\alpha}^{(0)} + E_{\alpha}^{(1)}.$$

Затем оптимальное значение параметра $\alpha^{(+)}$ ищется простым перебором в одномерном массиве $\mathcal{E}^{(+)}(\alpha^{(+)})$ длины M . На этом описание предсказателя завершено.

В рамках выполнения работы была проведена программная реализация всех рассмотренных алгоритмов на языке С#. С помощью разработанной программной реализации были проведены вычислительные эксперименты на Waterloo-наборе [8] полутоновых изображений, который является одним из общепринятых стандартных наборов при исследовании алгоритмов компрессии изображений. В качестве меры погрешности между исходным изображением $\bar{x}(n_1, n_2)$ и восстановленным изображением $\tilde{x}(n_1, n_2)$, уже прошедшим компрессию и декомпрессию, использовались относительная квадратичная погрешность $\mathcal{E}_{\text{отн}}$ [9] и максимальная погрешность \mathcal{E}_{max} [10]:

$$\mathcal{E}_{\text{отн}} = \frac{1}{D_x} \sum_{n_1, n_2} (x(n_1, n_2) - \tilde{x}(n_1, n_2))^2, \quad \mathcal{E}_{\text{max}} = \max_{n_1, n_2} |x(n_1, n_2) - \tilde{x}(n_1, n_2)|,$$

где D_x – оценка дисперсии исходного изображения. Некоторые результаты, усредненные по всем изображениям Ватерлоо-набора, показаны на рисунке 2. Как видно из рисунка 2а, предлагаемый адаптивный предсказатель \tilde{x}^A заметное преимущество над усредняющим предсказателем $\tilde{x}^{(1)}(n_1, n_2)$ (до 7%) и над предсказателем Грэхема \tilde{x}^G (до 4%) по коэффициенту сжатия.




Рисунок 2 – Исследование ДИКМ:

- (а) - Зависимость относительной квадратичной погрешности $\mathcal{E}_{\text{отн}}$ от коэффициента сжатия $K_{\text{сж}}$ при использовании квантователя со шкалой Макса для различных предсказателей
 (б) - Зависимость максимальной погрешности \mathcal{E}_{max} от коэффициента сжатия $K_{\text{сж}}$ при использовании квантователя с равномерной шкалой

Кроме того, было произведено сравнение метода ДИКМ с предлагаемым адаптивным предсказателем с методом сжатия JPEG [4]. Как видно из рисунка 2б, рассматриваемая реализация метода ДИКМ имеет заметное преимущество (до двух раз) над JPEG по максимальной погрешности.

Таким образом, предложенная модификация адаптивного параметризованного предсказателя является перспективной для повышения эффективности метода компрессии ДИКМ.

Литература

1. Salomon D. Data Compression. The Complete Reference. Springer-Verlag, 4ed, 2007.
2. Chein-I C. Hyperspectral Data Processing: Algorithm Design and Analysis. Wiley Press, 2013.
3. Borengasser, M. Hyperspectral Remote Sensing – Principles and Applications. CRC Press, 128 p, 2004.
4. Wallace G. The JPEG Still Picture Compression Standard // Communications of the ACM. – 1991. – V. 34, Issue 4. – P. 30-44.
5. Гашников М.В., Глумов Н.И., Сергеев В.В. Адаптивный алгоритм интерполяции для иерархической компрессии изображений // Компьютерная оптика, 2002. Т. 23. – С.89-93.
6. Гашников, М.В. Иерархическая сеточная интерполяция при сжатии гиперспектральных изображений / М.В. Гашников, Н.И. Глумов // Компьютерная оптика. – 2014. – Т. 38, № 1. – С. 87-93.
7. Гашников М.В., Глумов Н.И. Иерархическая компрессия в задаче хранения гиперспектральных изображений // Компьютерная оптика. – 2014. – Т. 38, №3. – С. 482-488.
8. Waterloo Grey Set. – University of Waterloo Fractal coding and analysis group: Mayer Gregory Image Repository, 2009. [<http://links.uwaterloo.ca/Repository.htm>]
9. Методы компьютерной обработки изображений/ под ред. Сойфера В. А. – М.: Физматлит. – 2003. –784. с.
10. Pratt W. Digital image processing. Wiley, 4ed, 2007.