

Конструирование процедуры локальной обработки изображений, основанной на иерархической регрессии, предназначеннной для решения задач обработки космических снимков

В.Н. Копенков

Институт систем обработки изображений РАН, Самара, Россия
E-mail: vkop@smr.ru

Работа посвящена использованию алгоритма автоматического построения вычислительной процедуры локальной нелинейной обработки цифровых сигналов/изображений, для обработки космических снимков. Вычислительная процедура использует для описания изображения признаки, вычисляемые на основе локального дискретного вейвлет преобразования, а для получения результата преобразования – иерархическую древовидную регрессию. Построение процедуры производится на основе анализа прецедентов обработки (пар изображений «исходное» – «результат обработки»), максимизируя качество обработки и обобщающую способность решающего правила и учитывая ограничения по сложности конструируемого преобразования. В работе приведены примеры использования предложенной процедуры обработки для решения различных задач обработки космических снимков.

Ключевые слова: локальная обработка, вейвлет-преобразования, иерархическая регрессия, вычислительная эффективность, космические снимки.

Введение

Задачи обработки и анализа космических снимков находят широкое применение в различных областях человеческой деятельности. При этом различие алгоритмов обработки и обработка больших объемов информации (космические снимки) с учетом требований высокой эффективности ведут к необходимости использования нелинейных локальных преобразований (Сойфер и др., 2003; Haikin, 2006). Один из наиболее распространенных на настоящий момент подходов к построению универсальных нелинейных алгоритмов обработки заключается в реализации кибернетического принципа «черного ящика» (термины других авторов: обработка через распознавание, обработка по прецедентам), когда само преобразование и его параметры определяются на основании анализа входных и выходных сигналов или изображений. Классическим подходом к построению таких процедур обработки, является использование аппарата нейронных сетей (Haikin, 2006). Альтернативным, но существенно менее развитым подходом является использование иерархических вычислительных конструкций, таких как дерево решений и дерево регрессии (Копенков, Мясников, 2012; Breiman, 1984).

В статье предлагается использование алгоритма автоматического построения процедуры локальной обработки изображений на основе иерархической регрессии (Копенков, Мясников, 2012), для автоматизации процесса решения задач обработки космических изображений, позволяющего одновременно учесть такие критерии как: вычислительная сложность процедуры, качество и обобщающая способность решающего правила, а также соответствие ограничениям по достаточности обучающей выборки.

Общая схема локальной обработки изображений

Модель локальной обработки изображений, предполагает разбиение на два этапа: этап формирования признаков и этап вычисления результатов преобразования.

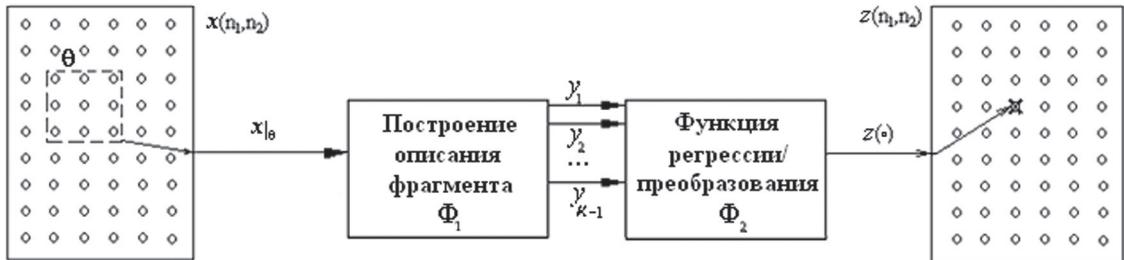


Рис. 1. Схема локальной обработки изображений

На первом этапе из некоторых априорных сведений об объекте (фрагменте изображения X) производится формирование определенного набора признаков $\bar{y} = (y_0, y_1, \dots, y_{K-1})^T, \bar{y} \in \mathbf{R}^K$ на основе преобразования $\Phi_1 : \mathbf{R}^{M_1 \times M_2} \rightarrow \mathbf{R}^K$. Сформированное описание фрагмента изображения на втором этапе используется для вычисления результата преобразования $\Phi_2 : \mathbf{R}^K \rightarrow \mathbf{K}$ построения результирующего изображения Z .

Построение преобразования реализуется на основе прецедентов обработки – набора согласованных пар $\left\{x|_{\theta(n_1, n_2)}, z(n_1, n_2)\right\}_{(n_1, n_2) : \theta(n_1, n_2) \subseteq \Theta}$ с минимизацией ошибки для:

– преобразования с вещественным выходом $\mathbf{K} \equiv \mathbf{R}$ (препарирование, фильтрация, восстановление, и т.д.):

$$\epsilon = \frac{1}{|\Theta|} \sum_{(n_1, n_2)} \left\| z(n_1, n_2) - \Phi_2(\Phi_1(x|_{\theta(n_1, n_2)})) \right\|^2 \rightarrow \min_{\Phi_1, \Phi_2};$$

– преобразования с выходом в виде $\mathbf{K} = \{0, 1, 2, \dots, L-1\}$ (выделения границ, классификация, сегментация):

$$\epsilon = \frac{1}{|\Theta|} \sum_{(n_1, n_2)} I(\Phi_2(\Phi_1(x|_{\theta(n_1, n_2)})), z(n_1, n_2)) \rightarrow \min_{\Phi_1, \Phi_2},$$

где $(n_1, n_2) : \theta(n_1, n_2) \subseteq \Theta, \Theta = \{(n_1, n_2), n_1 = \overline{0, N_1 - 1}, n_2 = \overline{0, N_2 - 1}\}, I(a, b) = \begin{cases} 0, & a = b \\ 1, & a \neq b \end{cases}$.

Составляющие этапов указанной вычислительной процедуры:

- описание фрагмента изображения (отображение Φ_1) – семейство признаков на основе локальных дискретных вейвлет-преобразований (ДВП) сигналов и изображений,
- вычисление результата преобразования (отображения Φ_2) – дерево регрессии.

Построение признаков

Достоинствами семейства признаков на основе локальных ДВП являются:

- наличие эффективных алгоритмов расчета;
- полнота описания исходного сигнала;
- последовательное получение и использование признаков.

Вопросы, связанные с алгоритмами расчета локальных ДВП, а также достоинства признаков для задач локальной обработки изображений, рассмотрены в работах (Korenkov, 2008; Korenkov, Myasnikov, 2010). Предлагается использование различных алгоритмов расчета ЛДВП, в зависимости от типа решаемой задачи обработки:

- на основе рекурсивного алгоритма – для работы с низкочастотной составляющей – задачи классификации объектов на изображениях, сегментации и т.д.;
- на основе модифицированного алгоритма – для работы и с низкочастотной, и с высокочастотной составляющими, что позволяет эффективно решать задачи фильтрации, восстановления, поэлементных преобразований изображений и т.д.

Стандартная схема расчета ЛДВП, основанная на схеме Малла (Mallat, 1999; Haikin, 2006), согласно теории кратно-масштабного анализа, представима в виде:

$$w_{l+1}^+(p) = \sum_{n \in D_h} h(n-2p) \cdot w_l^+(n), \quad w_{l+1}^-(p) = \sum_{n \in D_g} g(n-2p) \cdot w_l^+(n),$$

где $p = \overline{1, N}$, N – длина исходного сигнала, $h(n)$, $g(n)$ – соответствующие фильтры, такие что: $\sum_n h(n) = 1$, $g(n) = (-1)^n h(-n + 2t - 1)$, ($t \in Z$), D_h, D_g – длины фильтров, $l = \overline{0, \log_2 M}$ – уровни вейвлетов, M – размер окна обработки.

При работе с изображениями (двумерными функциями), вычислительная сложность представленных алгоритмов для диапазона уровней $[L_1, L_2]$ при рассмотрении вейвлетов, ограниченных снизу и сверху, составит (Korenkov, 2008):

БВП на основе схемы Малла

$$U_1^*(L_1, L_2) = 8 / 3(2^{2L_2} - 1);$$

модифицированное БВП

$$U_2^*(L_1, L_2) \underset{N \rightarrow \infty}{\approx} 8L_2 - 5L_1 - 5;$$

рекурсивное БВП

$$U_3^*(L_1, L_2) = 13(L_2 - L_1 + 1).$$

Алгоритм преобразования изображения

Дерево регрессии (Копенков, Мясников, 2012; Breiman, 1984) представляет собой иерархическую структуру, нетерминальные вершины которой определяют разбиение пространства признаков, а терминальные – элементарную функцию преобразования значений признаков в значение результата преобразования.

Процесс построения дерева регрессии включает в себя: оценку ошибки в терминальных вершинах; выбор признака и параметров разбиения, оптимальных для разбиения; разбиение выбранных терминальных вершин; построение функции регрессии в терминальных вершинах по всем элементам обучающей выборки, в вершине. После чего проводится анализ обобщающей способности дерева регрессии на основе комбинаторной теории (Воронцов, 2004) и функционала полного скользящего контроля:

$$Q^{st}(\mu(\Omega), \Omega) = \frac{1}{N} \sum_{n=1}^N v(\mu(\Omega_n^s), \Omega_n^t),$$

где Ω – конечный набор объектов для обучения (прецедентов); $\mu(\Omega)$ – алгоритм (метод) обучения на наборе для обучения Ω , (Ω_n^s, Ω_n^t) ; $n = 1, 2, \dots; N$ – все возможные варианты разбиения выборки Ω на обучающую и контрольную выборки. Число всех N разбиений выборки равно C_T^s . $v(\mu(\Omega_n^s), \Omega_n^t)$ – частота ошибок алгоритма $\mu(\Omega_n^s)$, построенного на основе выборки Ω_n^s , проверяемого по выборке Ω_n^t .

Особенности процесса построения алгоритма обработки

Схема алгоритма построения (Копенков, Мясников 2012) приведена на рис. 2.

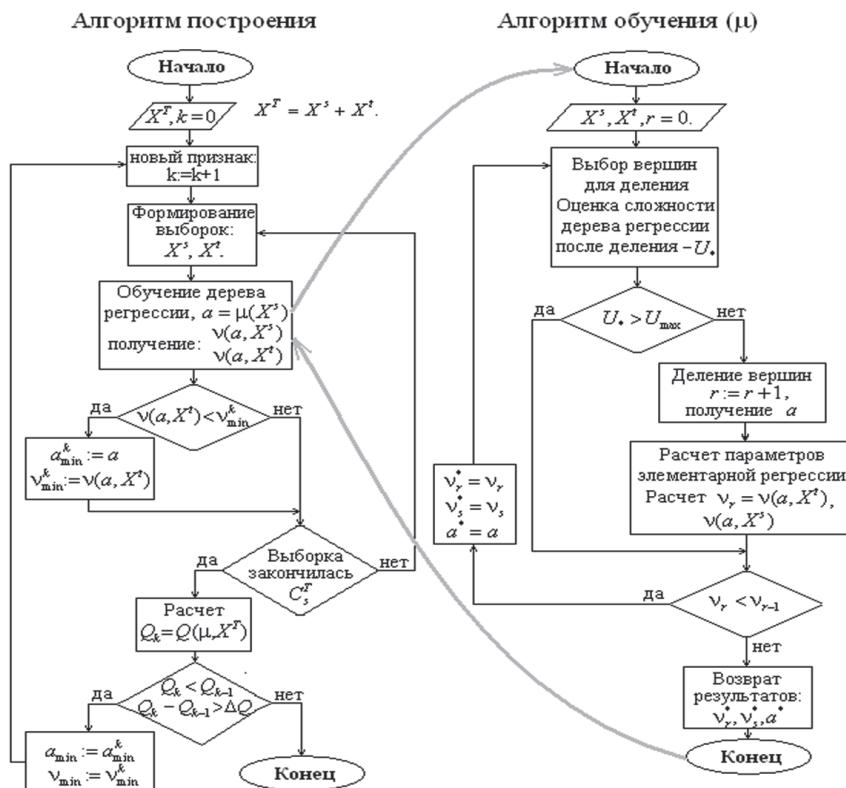


Рис. 2. Алгоритм построения процедуры локальной обработки с ограничениями

Разработанный алгоритм предполагает последовательное наращивание набора признаков (локальных ДВП) до тех пор, пока функционал скользящего контроля убывает (происходит улучшение качества обработки) и вычислительная сложность процедуры локальной обработки на основе дерева регрессии находится в допустимых пределах. Для начала берется один признак и конструируемое дерево регрессии, наращиваясь, производит последовательное разбиение признакового пространства пока ошибка преобразования снижается. После чего производим перемешивание обучающей и контрольной выборок, и ДР перестраивается, пока не будут проверены все варианты сочетаний обучающей и контрольной выборок. Затем добавляется еще один признак и процесс построения повторяется до тех пор, пока не будет выполнено правило остановки.

*Остановка процесса перебора различных сочетаний
обучающей и контрольной выборок*

Решение задачи построения процедуры локальной обработки с учетом всех сочетаний обучающей и контрольной выборок на практике нереализуемо вследствие гигантского перебора по различным сочетаниям выборок. Поэтому в работе предложена решающая процедура, позволяющая определить необходимость завершения или продолжения формирования обучающих и тестовых выборок по их конкретному числу.

При достаточно больших объемах выборки можно предположить, что частота ошибок алгоритма имеет биномиальное распределение с t степенями свободы (длина контрольной выборки) и вероятностью «успеха» – p (качество работы алгоритма на контрольной выборке):

$$v(\mu(\Omega_n^s), \Omega_n^t) = Bin(t, p).$$

Ее функция вероятности задается формулой:

$$p_v(r) = C_t^r p^r (1-p)^{t-r}, \quad r = \overline{0, t}.$$

Тогда распределение функционала полного скользящего контроля оценивается:

$$Q^{st}(\mu(\Omega), \Omega) = \frac{1}{N} \sum_{n=0}^{N-1} v(\mu(\Omega_n^s), \Omega_n^t) \sim Bin(N \cdot t, p).$$

На основе анализа функционалов $Q_1^{st} = Bin(N_1 \cdot t, p_1)$, $Q_2^{st} = Bin(N_2 \cdot t, p_2)$ для различных семейств признаков (в случае когда мы принимаем решение о добавлении нового признака в процедуру обучения дерева регрессии) в предположении $p_2 < p_1$, с достоверностью γ (соответственно, при $p_1 < p_2$, с достоверностью $(1 - \gamma)$) можно принять решение либо о продолжении, либо об остановке процесса генерации сочетаний обучающей и контрольной выборок (и переходе к следующему признаковому семейству).

Тогда качество алгоритма на выборке Ω , соответственно, можно оценить как:

$$v(\mu(\Omega), \Omega^T) = \frac{1}{|\Omega|} \sum_{\omega_i \in \Omega} I(\omega_i, \mu(\omega_i)), \text{ где } I(\omega_i, \mu(\omega_i)) = \begin{cases} 1, & p \\ 0, & 1-p \end{cases}$$

При этом, если $n \gg 1$ (количество объектов) и параметр λ фиксирован, получим распределение Пуассона с параметром λ : $Bin(n, \lambda/n) \approx P(\lambda)$. И в таком случае, для принятия решения об остановке процесса генерации различных сочетаний обучающей и контрольной выборок и переходе к следующему признаковому семейству надо рассчитать доверительные интервалы для математического ожидания распределения Пуассона для функционала полного скользящего контроля по выборкам N_1 и N_2 в виде:

$$\left[\lambda_1 - \tau_{1-\alpha/2} \frac{\sqrt{\lambda_1}}{\sqrt{N_1}}, \lambda_1 + \frac{\sqrt{\lambda_1}}{\sqrt{N_1}} \tau_{1-\alpha/2} \right] \left[\lambda_2 - \tau_{1-\alpha/2} \frac{\sqrt{\lambda_2}}{\sqrt{N_2}}, \lambda_2 + \frac{\sqrt{\lambda_2}}{\sqrt{N_2}} \tau_{1-\alpha/2} \right],$$

где $\tau_{1-\alpha/2}$ – квантиль распределения $N_{0,1}$ уровня $1 - \alpha/2$ ($\alpha = 1 - \gamma$).

Решение о прекращении процесса генерации различных сочетаний выборок и переходе к следующему признаковому семейству принимается в тот момент, когда достигается непересечение рассчитанных доверительных интервалов на соседних шагах.

Иллюстрация процесса работы алгоритма обработки

На рис. 3 представлен пример обучения дерева регрессии, для различного количества признаков ($K = 1, 2, 3, \dots, 12$, с последовательным наращиванием). Приведены графики показывающие коэффициент понижения шума ϵ^2/D_V при увеличении глубины дерева регрессии (H_{cp}). На рис. 4 – статистика построения дерева регрессии на различных сочетаниях обучающей и контрольной выборок (группы точек определенного цвета соответствуют оптимальному значению качества при решении задачи обработки в случае перебора некоторого количества вариантов (Ω_n^s, Ω_n'), $n = 1, 2, \dots, N$ разбиения выборки Ω на обучающую и контрольную для конкретного набора признаков $K = 1, 2, 3, \dots, 12$).

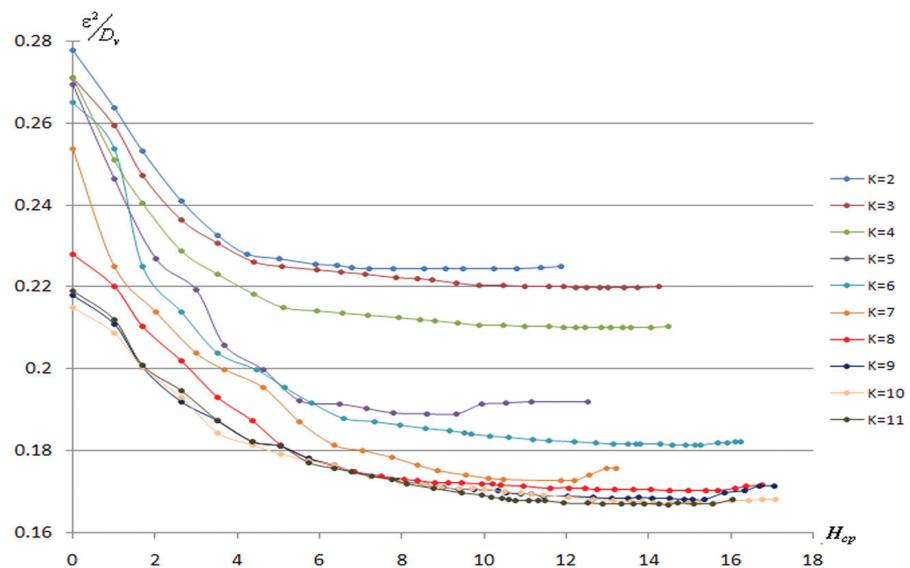


Рис. 3. Процесс обучения ИР при различном количестве признаков

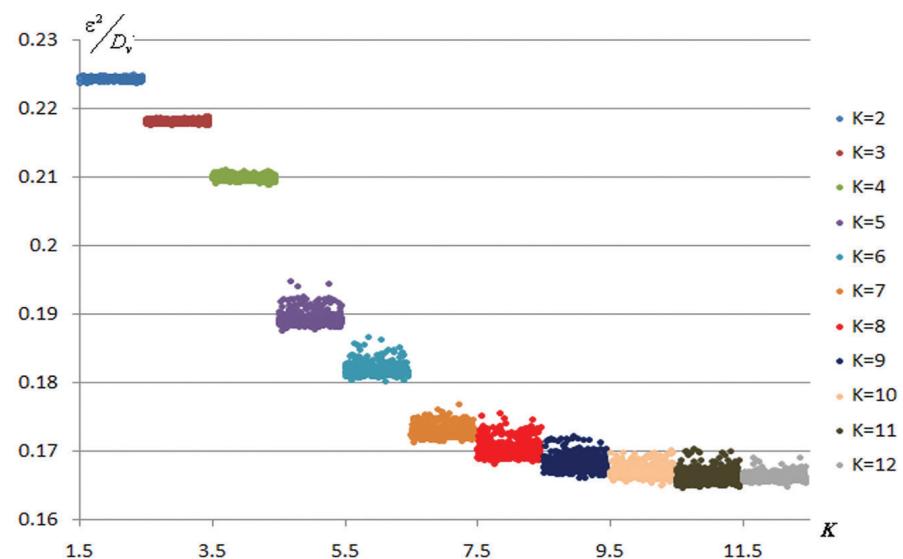


Рис. 4. Статистика качества процедуры для различных сочетаний выборок и признаков

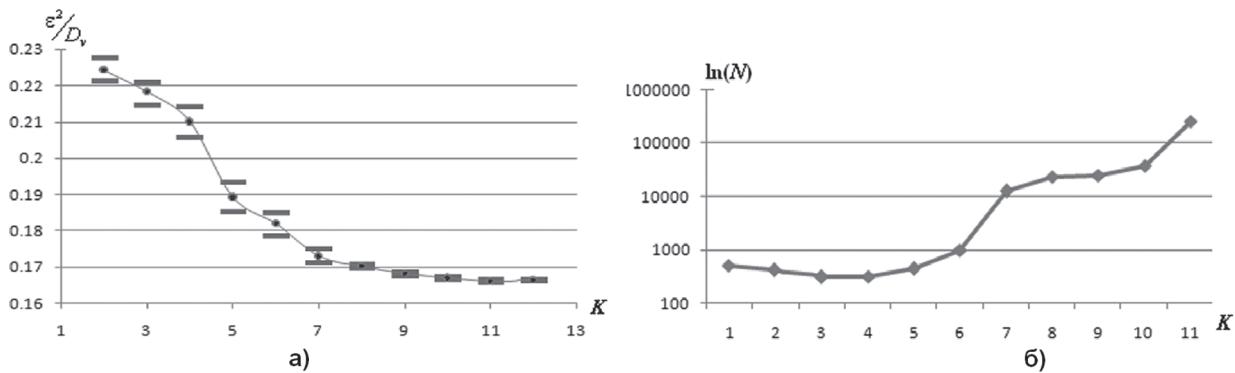


Рис. 5. Построение процедуры обработки с доверительными интервалами

На рис. 5 представлены график процесса построения процедуры локальной обработки изображений (рис. 5а), с доверительными интервалами, для оптимальных значений качества (зависимость коэффициент понижения шума от количества признаков) и расчет необходимого числа сочетаний обучающей/контрольной выборок для принятия решения о переходе к следующему признаковому семейству (количество сочетаний необходимое для непересечения доверительных интервалов на соседних шагах) – рис. 5б.

Применение алгоритма обработки

Исследование зависимости качества фильтрации от вычислительной сложности

При фильтрации изображений возможна ситуация, когда можно указать желаемый результат обработки (в виде согласованной пары изображений – «входное» X и «выходное» Z). Тогда задача фильтрации сводится к задаче аппроксимации функции решения и возможно использование представленной выше 2-этапной технологии на основе дерева регрессии. Процедуры формирования признаков и аппроксимации функции решения, настроенные в итоге обучения на неформально заданное преобразование данных, далее используются при обработке других изображений того же класса. В качестве примера использовались две последовательности согласованных пар «идеальных» и зашумленных изображений с разными реализациями шума (отношение «сигнал / шум» – $D_x/D_v = 5$, где D_x – дисперсия исходного сигнала, D_v – дисперсия шума). Критерий качества – коэффициент понижения шума (ϵ^2/D_v , где ϵ^2 – среднеквадратичное отклонение результата обработки от эталонного изображения, D_v – дисперсия шума). Результаты обработки космических снимков («часть Самары» – рис. 6) представлены на рис. 7. При этом для сравнения были взяты методы с одинаковой вычислительной сложностью процедуры (U) на этапе применения (количество операций на отсчет). В данном эксперименте проводилось сравнение нейронной сети (была взята нейронная сеть с N входами, одним скрытым слоем (L нейронов в скрытом слое) и одним выходом, для обучения которой использовался известный алгоритм обратного распространения ошибки («back propagation»), рассматривались различные варианты активационной функции) и линейной функции элементарной регрессии (КЛА) в терминальных вершинах дерева регрессии.

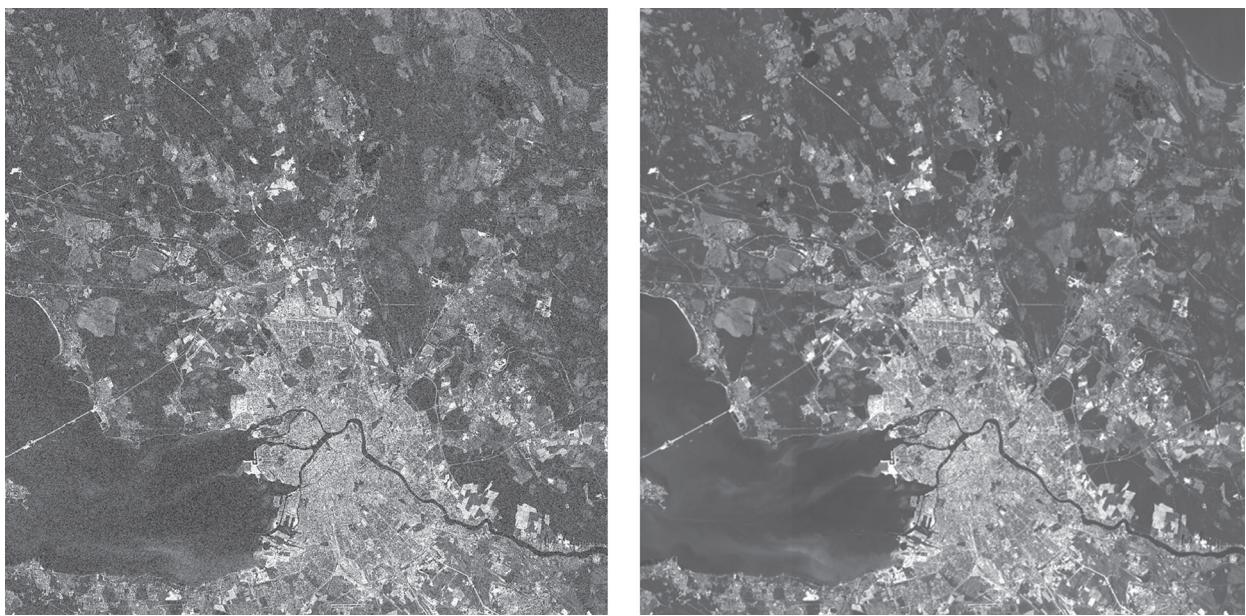


Рис. 6. Пара зашумленное + идеальное изображения

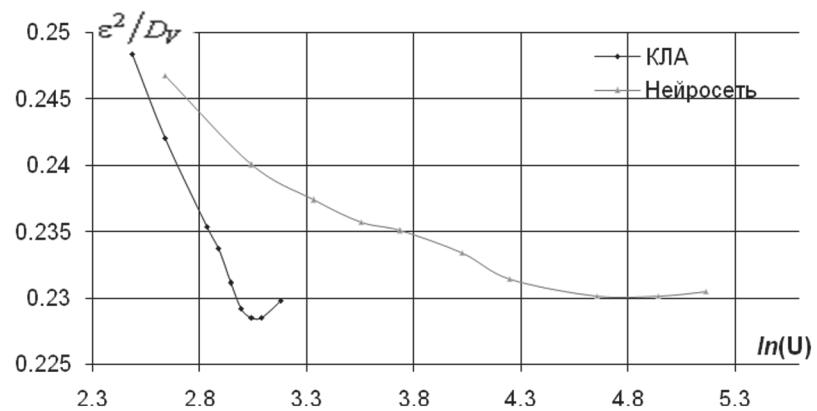


Рис. 7. Сравнение иерархической регрессии и нейронной сети

Представленные графики показывают снижение шумов в результате обработки (чем «глубже» опускается кривая, тем «лучше» результат), а также подтверждают выводы статистической теории о необходимости остановки процесса обучения для алгоритмов, основанных на эмпирических данных, а именно, что не следует добиваться безошибочной работы алгоритма на обучающем материале. Изгибающиеся вверх концы графиков характеризуют то, что процедура обработки старается «максимально адаптироваться» к обучающей выборке и, как следствие, демонстрирует ухудшение результатов на контрольной выборке (других изображениях рассматриваемого класса). При этом метод на основе иерархической регрессии адаптируется (обучается), существенно быстрее нейронной сети, чем и характеризуется более резкий изгиб кривой (применение на контрольной выборке). Аналогичные результаты получены и для задач восстановления изображений (уменьшение расфокусировки, шума, восстановление контуров, повышение резкости).

Классификация отсчетов изображения

При классификации отсчетов изображений технология построения и применения иерархической регрессии аналогична задаче фильтрации изображений с той лишь разницей, что количество выходных классов ограничено. Если представить исходные данные как «входное» изображение X и «выходное» изображение Z , представляющее собой индексное изображение, каждая точка которого соответствует номеру класса, то задача поэлементной классификации сводится к задаче восстановления регрессии, если рассматривать в качестве обучающей выборки отсчеты заданной пары изображений. В работе в качестве «выходного» изображения (желаемого результата классификации) при обучении были использованы отрастированные, с векторных ГИС-карт (с активными слоями, содержащими различные типы растительности), участки территории, соответствующие космоснимкам, после чего обученная процедура была протестирована на соседних участках территории и на космоснимках других периодов (годов съемки).

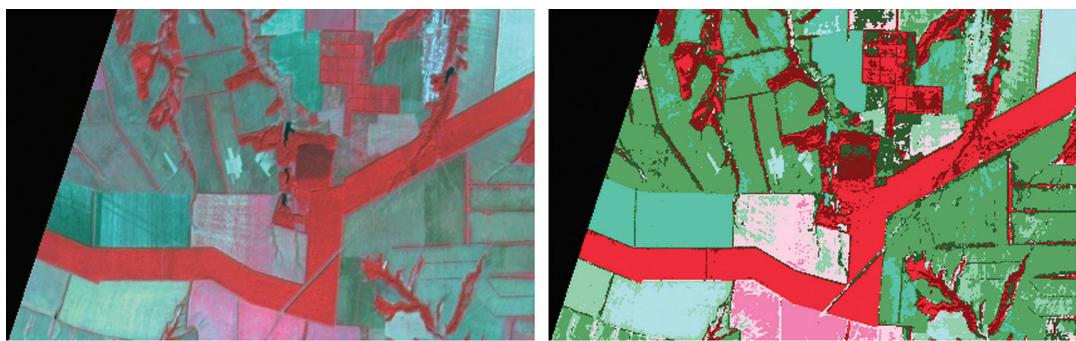


Рис. 8. Фрагмент снимка с КА SPOT-4 на территории Волжского и Красноармейского районов Самарской области и результаты работы алгоритма при разбиении на девять классов



Рис. 9. Исходное изображение и классификация на шесть и двенадцать классов

На рис. 8 и 9 приведены примеры решения задачи классификации. Слева на рисунках представлены исходные изображения в цветовой модели RGB (3 канала с соотв. спутника с разрядностью 8 bit на канал), справа результаты классификации – индексные изображения с количеством различных цветов, равным количеству выходных классов, используемых при классификации.

Выводы и рекомендации

В работе представлен автоматический алгоритм построения вычислительной процедуры, реализующей локальное преобразование цифрового изображения, с ограничениями по сложности, качеству исполнения и обобщающей способности. При этом разработанный алгоритм позволяет избежать проблем переобучения и построить вычислительную процедуру с ограничением по вычислительной сложности ее применения и максимальным качеством. Более того, в отличие от многих известных нелинейных процедур обработки, реализующих схему обучения с учителем, предложенная схема обеспечивает (по построению) возможность детального анализа решающего алгоритма и, более того, активного контроля его параметров на этапе конструирования (автоматического). Основными достоинствами предложенного решения являются:

- автоматическая коррекция «архитектуры» преобразования;
- автоматическая локальная селекция признаков как следствие процесса разбиения;
- конечность процесса построения и настройки (вычислительная эффективность);
- простота параметрической настройки элементарной регрессии.

Это позволяет говорить об автоматической генерации инструмента обработки изображений с «открытым» для исследователя внутренним устройством, имеющим к тому же более высокую вычислительную эффективность (по сравнению, например, с нейронной сетью). В противоположность этому, вопросы анализа, оптимизации и/или изменения архитектуры с последующим полным (и достаточно долгим) переобучением искусственной нейронной сети являются сложными как с формальной, так и с фактической точки зрения, а использование самого аппарата искусственных нейронных сетей оказывается сравнительно более ресурсоемким и менее эффективным подходом по отношению к предложенному методу на рассмотренном классе задач.

Исследование эффективности использования предложенного подхода локальной обработки изображений для решения задач обработки космических изображений позволяет сделать выводы о его применимости (так как он позволяет получать решения сравнимые по качеству с другими нелинейными методами, но превосходящие последние в плане вычислительной эффективности, а также обладающие заранее заданными вычислительной сложностью и надежностью). Кроме того, разработанный подход в силу принципов его построения может быть использован как средство более глубокого анализа космических данных ДЗЗ, открывающего возможности (путем детального исследования структуры пространства признаков, а также вида и параметров конечного преобразования) для выявления общих закономерностей и уточнения, и дополнения существующих физических и математических моделей, на основе которых строятся современные методы обработки данных ДЗЗ.

Благодарности

Работа выполнена при частичной финансовой поддержке грантов РФФИ (проекты 12-07-00021-а, 12-07-00751-а, 13-07-97006-р_поволжье_а, 12-07-31175) и программы фундаментальных исследований Президиума РАН «Фундаментальные проблемы информатики и информационных технологий», проект 2.12.

Литература

1. *Воронцов К.В.* Комбинаторный подход к оценке качества обучаемых алгоритмов // Математические вопросы кибернетики / Под ред. О.Б. Лупанова М.: Физматлит, 2004. Т. 13. С. 5–36.
2. *Копенков В.Н., Мясников В.В.* Алгоритм автоматического построения процедуры локальной нелинейной обработки изображений на основе иерархической регрессии // Компьютерная оптика. 2012. Т. 36. № 2. С. 257–266.
3. *Сойфер В.А.* Методы компьютерной обработки изображений / Под ред. В.А. Сойфера / Гашников М.В., Глумов Н.И., Ильясова Н.Ю., Мясников В.В. и др., под общей редакцией Сойфера В.А. 2-е изд., испр. М.: Физматлит, 2003. 784 с.
4. *Breiman L.* Classification and regression trees / Breiman, L., J. H. Friedman J.H., Olshen R.A., Stone C.J. // Monterey, Calif., U.S.A.: Wadsworth, Inc. 1984.
5. *Haikin S.* Neural Networks: A Comprehensive Foundation. M.: Vilyams, 2006. 1104 p.
6. *Kopenkov V.* Efficient algorithms of local discrete wavelet transform with HAAR-like bases. Pattern Recognition and Image Analysis. Vol. 18. № 4. 2008. P. 654–661.
7. *Kopenkov V.N., Myasnikov V.V.* Research the performance of a recursive algorithm of the local discrete wavelet transform // 20-th International Conference on Pattern Recognition (ICPR-2010). Istanbul, Turkey. August 23–26, 2010. Abstract book. 317 p.
8. *Mallat S.* A wavelet tour of signal processing. M.: Academic Press, 1999. 637 p.

Construction of computational procedure of local image processing on the base of hierarchical regression intended to solve the satellite images processing tasks

V.N. Kopenkov

*Image Processing Systems Institute of RAS
E-mail: vkop@smr.ru*

The article is devoted to the use of an algorithm of automatic construction of computational procedure of local non-linear processing of digital signals/images for satellite images processing. The computational procedure is based on local discrete wavelet transformation of the image used for the preliminary analysis of the image, and hierarchical regression used to obtain the transformation result. The construction procedure is based on training information (pair of images «original» – «the result of processing»), takes into account the restriction on the complexity of the constructed transformation and maximize the processing quality and generalization ability. The paper presents examples of using of the proposed image processing procedure for solving different tasks of satellite images processing.

Keywords: local processing, wavelet transform, a hierarchical regression, computational efficiency, space images.