

Г.Ю. Щербакова, канд. техн. наук,
В.Н. Крылов, д-р техн. наук,
О.В. Логвинов, канд. техн. наук

АДАПТИВНИЙ СУБГРАДІЕНТНИЙ МУЛЬТИСТАРТОВИЙ МЕТОД КЛАСТЕРИЗАЦІЇ В ПРОСТРАНСТВЕ ВЕЙВЛЕТ-ПРЕОБРАЗОВАННЯ

Розроблено адаптивний мультистартовий субградієнтний метод кластеризації в просторі вейвлет – перетворення для випадку, коли параметри кластера змінюються лінійно. Досліджено умови збіжності методу в середньоквадратичному змісті на етапі адаптації. Наведено рекомендації щодо вибору кроку. Використання методу дозволить підвищити операцівність діагностування.

Разработан адаптивный мультистартовый субградиентный метод кластеризации в пространстве вейвлет - преобразования (ВП) для случая линейно меняющихся параметров кластера. Исследованы условия сходимости метода в среднеквадратическом смысле на этапе адаптации. Приведены рекомендации по выбору шага. Применение метода позволит повысить оперативность диагностирования.

The adaptive multi-start sub gradient clustering method in the wavelet transformed domain for the case, when cluster parameters are linear function of time, is designed. The convergence of this method in a mean squared sense is proved. The recommendations of step choice are designed. Such method allows operative ness of the diagnostics raise. The operative ness of the diagnostics is raised.

При автоматизации технического диагностирования важной задачей является обеспечение оперативности контрольно-диагностических операций. Один из основных факторов повышения оперативности – применение методов, которые позволяют повысить быстродействие вычислительных процедур при диагностировании и сократить количество контрольно-измерительных операций по сбору данных, необходимых для реализации этих процедур. В таких задачах технической диагностики, как прогнозирование параметров изделий, контроль состояния аппаратуры и процессов производства для разделения объектов на группы по значениям параметров, как правило, применяют классификацию при распознавании образов [12]. Если нет указаний о том, к какой группе (кластеру) относится исследуемый объект, но необходимо определить границы между кластерами, применяется классификация с самообучением, которая включает две процедуры: кластеризацию и собственно классификацию. Кластеризация является одной

из самых продолжительных вычислительных процедур при диагностировании [3].

При кластеризации данные разделяют на группы (кластеры) по признаку компактности так, чтобы был оптимизирован функционал качества. Этот функционал может быть недифференцируемым, может обладать зашумленной поверхностью, поскольку анализ в указанных задачах диагностики производится по малым выборкам исходных данных. Важной проблемой является то, что истинный минимум этого функционала может дрейфовать со временем и (или) под действием каких-либо производственных или эксплуатационных факторов. Это обуславливает необходимость применения адаптивных методов кластеризации.

Существующие методы кластеризации отличаются либо низкой помехоустойчивостью, либо низкой точностью, что снижает достоверность диагностики. Поэтому в качестве базового метода выбран разработанный авторами мультистартовый метод кластеризации в пространстве вейвлет - преобразования, отличающийся повышенными помехоустойчивостью и точностью [10].

Для поиска оптимума в условиях дрейфа истинного минимума функционала разрабо-

таны субградиентные методы нестационарной оптимизации, реализуемые по схеме

$$c[n+1] = c[n] - \gamma[n]g(c[n]), \quad (1)$$

где $c[n]$ - оценка координаты экстремума на итерации n ; $g(c[n])$ - субградиент (заменяющий градиент из метода Ньютона), который «в среднем» должен совпадать с градиентом, и близок к нулю, когда его аргумент стремится к точке экстремума [2]. Эти методы разработаны для различных вариантов дрейфа минимума функционала (затухающего, полиномиального, ограниченного по норме) и различных типов (аддитивных, мультиплекативных) и уровней помех [1]. Однако, как правило, на область их применения налагается ряд ограничений – требуется, чтобы оптимизируемый функционал обладал одним экстремумом, был дифференцируемым, сильно выпуклым в точке минимума и др. [1]. Эти требования при оценке параметров в процессе диагностики часто не выполнимы [9], что обусловлено описанными выше особенностями функционалов при оптимизации.

Для решения задач кластеризации в условиях дрейфа истинного минимума функционала разработан субградиентный мультистартовый метод аддитивной кластеризации в пространстве вейвлет преобразования (ВП), который позволяет проводить кластеризацию в условиях дрейфа параметров кластера [10, 12]. Этот метод аддитивен за счет того, что для последующих временных шагов начальные параметры центров кластеров определяются из анализа на предыдущем шаге. Но метод при оптимизации требует при оценке субградиента [5] (при размерности пространства признаков d и количестве шагов дискретизации длины носителя анализирующего вейвлета N) до $2Nd$ измерений на каждой итерации. Временные и аппаратурные затраты на проведение измерений параметров при диагностировании с помощью этого метода возрастают при дрейфе минимума функционала при кластеризации пропорционально количеству временных шагов, для которых проводится кластеризация.

В ряде случаев, в зависимости от условий хранения или использования, параметры объектов одного из исследуемых кластеров

могут меняться медленно и зависеть от времени (или других факторов) почти линейно [6]. Классификация в случае медленно меняющихся параметров класса на основе метода динамической стохастической аппроксимации при затухающем дрейфе минимума функционала [13] исследована в работе [8]. Применение подобного подхода при кластеризации в случае медленно (линейно или почти линейно) меняющихся параметров кластера позволит сократить временные и аппаратурные затраты на измерение параметров в процессе кластеризации и за счет этого повысить оперативность диагностирования.

Цель работы – разработка и исследование аддитивного мультистартового субградиентного метода кластеризации, если параметры меняются линейно, для повышения быстродействия.

Для достижения поставленной цели решены задачи:

разработан аддитивный мультистартовый субградиентный метод кластеризации в пространстве вейвлет-преобразования (ВП) для случая линейно меняющихся параметров кластера;

исследованы условия его сходимости; приведены рекомендации по выбору шага.

Аддитивный мультистартовый субградиентный метод кластеризации в пространстве вейвлет - преобразования (ВП) для случая линейно меняющихся параметров кластера включает следующие этапы.

Этап 1. Определение количества кластеров в данных об исследуемом объекте одним из известных методов [3,4,11], которое впоследствии остается неизменным. Вопрос содержательной интерпретации классов решается экспертными методами.

Этап 2. Определение параметров кластера в начальный момент времени [10].

При кластеризации определяют оптимальный вектор $\mathbf{c} = c_{opt}$, который, удовлетворяя ограничениям, доставлял бы экстремальное значение $Q(\mathbf{x}, \mathbf{c})$ – функционалу вектора переменных $\mathbf{c} = (c_1, \dots, c_N)$, зависящему от вектора случайных последовательностей $\mathbf{x} = (x_1, \dots, x_M)$.

По показам образов $x \in X$ определяются центры множеств X_k и их границы. При этом

$$Q(\mathbf{x}, c_1, \dots, c_M) = \sum_{k=1}^M \varepsilon_k(\mathbf{x}, c_1, \dots, c_M) F_k(\mathbf{x}, c_1, \dots, c_M) -$$

реализация функционала качества;

$F_k(\mathbf{x}, c_1, \dots, c_M)$ – функция расстояния элементов \mathbf{x} множества X от «центров» \mathbf{c}_k подмножеств X_k (кластеров); $\varepsilon_k(\cdot)$ – характеристические функции

$$\varepsilon_k(\mathbf{x}, c_1, \dots, c_M) = \begin{cases} 1, & \text{если } \mathbf{x} \in X_k, \\ 0, & \text{если } \mathbf{x} \notin X_k. \end{cases}$$

Для двух кластеров поисковый регулярный итеративный алгоритм кластеризации для определения значений центров кластеров c_1^* и c_2^*

$$\begin{aligned} c_1[n] &= c_1[n-1] - \gamma_1[n] \tilde{\nabla}_{c1+} Q(\mathbf{x}[n], c_1[n-1], c_2[n-1]) \\ c_2[n] &= c_2[n-1] - \gamma_2[n] \tilde{\nabla}_{c2+} Q(\mathbf{x}[n], c_1[n-1], c_2[n-1]), \end{aligned}$$

где $\gamma_k[n]$ – величина шага; n – номер итерации; $\tilde{\nabla}_{c1+} Q(\mathbf{x}[n], c_1[n-1], c_2[n-1])$ – оценка градиента реализации для первого кластера; $\tilde{\nabla}_{c2+} Q(\mathbf{x}[n], c_1[n-1], c_2[n-1])$ – оценка градиента реализации для второго кластера; k – номер кластера.

По реализациям функционала качества $Q(\mathbf{x}, \mathbf{c})$ оценивается градиент $\nabla_c Q(\mathbf{x}, \mathbf{c}) = \left(\frac{\partial Q(\mathbf{x}, \mathbf{c})}{\partial c_1}, \frac{\partial Q(\mathbf{x}, \mathbf{c})}{\partial c_2} \right)$. Но, если в

условиях помех оценка градиента проводится разностным методом [5, 9], поисковый регулярный итеративный метод, используемый при кластеризации, также дает низкую помехоустойчивость. Это обусловлено низкой помехоустойчивостью оценки градиента разностным методом.

Для кластеризации в первый момент времени:

инициализируются параметры метода; для каждого из i элементов взвешенной суммы с ВП определяют значение характеристических функций $\varepsilon_i(\mathbf{x}, c_1, c_2)$, $i = 1, 2$, входящих в оценку субградиента. Для этого

по методике, изложенной в работах [9, 10], пары значений

$$c_1[n-1], c_2[n-1]; c_1[n-1] \pm ie_1 a[n], c_2[n-1];$$

$c_1[n-1], c_2[n-1] \pm ie_2 a[n]$ ($i = \overline{1, N}$) при данном $\mathbf{x}[n]$ подставляют в $f(\mathbf{x}, c_1, c_2) = \|\mathbf{x}[n] - c_1\|^2 - \|\mathbf{x}[n] - c_2\|^2$. Здесь N – длина носителя вейвлет-функции; $a[n]$ – скаляр.

Функция $f(\mathbf{x}, c_1, c_2)$ равна нулю на границе между кластерами и имеет различные знаки в различных областях. Поэтому, если значение $f(\mathbf{x}, c_1, c_2)$ отрицательно, $\varepsilon_1 = 1, \varepsilon_2 = 0$, если положительно, $\varepsilon_1 = 0, \varepsilon_2 = 1$ [10].

В качестве базового для оценки градиента был использован градиентный метод [7].

Исходные данные для его работы: начальное значение координаты минимума, начальное значение шага $\gamma = 1$, коэффициент, обуславливающий изменение шага γ вблизи минимума $\beta = 0,5$, точность определения оценки субградиента ε , количество итераций j .

Процедура вычисления минимума при кластеризации включает:

вычисление оценки субградиента;

останов, если значение оценки субградиента меньше заданного значения точности ε ;

вычисление величины шага: задается начальное значение величины шага $\gamma = 1$; вычисляется вспомогательное значение приращения функции Δ , если приращение функции Δ меньше нуля – $\gamma[n] = \gamma$ и переход к следующему этапу, иначе $\gamma[n] = \beta\gamma$ и переход к предыдущему этапу;

расчет координаты минимума на n -ой итерации,

$n = n + 1$ и переход к начальному этапу вычисления минимума при кластеризации.

При вычислении оценки субградиента на каждой итерации на первом этапе вычисляется свертка значений минимизируемого функционала $Q(\mathbf{x}[n], c_1[n-1], c_2[n-1])$ с вейвлет-функцией Хаара. Это позволяет переместить поиск в район экстремума с по-

грешностью, определяемой асимметрией этого функционала.

На втором этапе оценки субградиента при кластеризации вычисляется взвешенная сумма минимизируемого функционала $Q(x[n], c_1[n-1], c_2[n-1])$ с гиперболической функцией $\Psi(i) = \frac{1}{\alpha x}$ при начальном масштабе $\alpha = 0,5$.

$$HWT(c[n]) = Q(x[n], c_1[n-1], c_2[n-1]) * \Psi(i),$$

где $*$ – операция взвешенного суммирования.

Далее, после определения оценки субградиента, определяют приближение к значению координаты центра кластера, используя итеративный алгоритм в пространстве гиперболического ВП по схеме

$$c_l[n+1] = c_l[n] + \gamma[n] HWT(c[n]),$$

где $\gamma[n]$ – шаг; $HWT(c[n])$ – значение взвешенной суммы с вейвлет-функцией в точке $c[n]$.

Если найденная на этом этапе координата оптимума отличается от координаты оптимума, найденной на предыдущем этапе не более, чем на δ , процесс поиска заканчивается. Здесь δ – заданная точность поиска координаты оптимума.

Для оценки субградиента использовано гиперболическое вейвлет-преобразование (ГВП), полученное по лифтинговой схеме [5, 10, 14].

На каждом уровне поиска координаты оптимума значение масштаба α увеличивается в соответствии с $\alpha = \{0,5; 1; 2; 3; 4; 5\}$. Если условие окончания поиска координаты оптимума при значении величины $\alpha = 5$ не достигается, оценка субградиента производится разностным методом. После этого поиск заканчивается.

Этап 3. На этом этапе оценка параметра кластера проводится с помощью динамической (двухэтапной) стохастической аппроксимации [8, 13].

Оценка параметров кластера в случае, если его параметры меняются со временем или под действием других факторов линейно или почти линейно осуществляется с помо-

щью двухступенчатой процедуры аппроксимации, выполняемой на каждом временном шаге. Первая ступень предназначена для корректировки изменений координаты центра кластера под действием влияющего фактора. Вторая ступень производится по схеме (1) на основе данных о параметрах элементов кластера, измеренных на новом шаге измененного влияющего фактора.

Без нарушения общности рассмотрим одномерный случай. Пусть $c[n]$ – координата центра кластера, изменяющаяся со временем

$$c^*[n+1] = (1 + n^{-1})c^*[n] + O(n^{-\mu}), \mu \geq 1. \quad (2)$$

Тогда алгоритм двухступенчатой стохастической аппроксимации для оценки изменения координаты центра кластера будет определяться следующим образом.

Первая ступень:

$$c[n+1] = (1 + n^{-1})c[n] + O(n^{-\mu}), \quad (3)$$

с учетом (3) вторая ступень:

$$c[n+1] = (1 + n^{-1})c[n] + O(n^{-\mu}) + \\ + \gamma[n](x[n+1] - (1 + n^{-1})c[n]), \quad (4)$$

где $x[n+1]$ – значение параметра и $c[n+1]$ – оценка координаты центра кластера на $n+1$ временном шаге; $\gamma[n]$ – последовательность положительных чисел, удовлетворяющих условиям

$$\prod_{n=1}^{\infty} (1 - \gamma[n])(1 + n^{-1}) = 0, \quad (1 - \gamma[n]) > 0, \\ \sum_{n=1}^{\infty} \gamma^2[n] < \infty. \quad (5)$$

Применяя метод Дворецкого аналогично [8, 13] можно показать, что оценка $c[n+1]$ сходится к $c^*[n+1]$ в среднеквадратическом с вероятностью единица. Для этого перепишем (4) следующим образом:

$$c[n+1] = (1 - \gamma[n])(1 + n^{-1})(c[n] + O'(n^{-\mu})) + \\ + \gamma[n]c^*[n+1] + \gamma[n]\eta[n+1], \quad (6)$$

где

$$O'(n^{-\mu}) = (1 + n^{-1})^{-1} O(n^{-\mu}), \quad (7)$$

$$x[n+1] = c^*[n+1] + \eta[n+1]. \quad (8)$$

Величина $\eta[n+1]$ – шумовая составляющая значения измеренного параметра $x[n+1]$, причем

$$E(\eta[n]) = 0 \text{ и } E(\eta^2[n]) = \sigma^2[n]. \quad (9)$$

Уравнение (6), записанное в виде

$$c[n+1] = T(c[1], \dots, c[n]) + \\ + \gamma[n]\eta[n+1], \quad (10)$$

где

$$T(c[1], \dots, c[n]) = (1 - \gamma[n])(1 + n^{-1}) \times \\ \times (c[n] + O'(n^{-\mu})) + \gamma[n]c^*[n+1], \quad (11)$$

представляет собой детерминированное (без помех) преобразование. Из (11) и (2) следует

$$\begin{aligned} & |T(c[1], \dots, c[n]) - c^*[n+1]| = \\ & = |(1 - \gamma[n])(1 + n^{-1})(c[n] + O'(n^{-\mu}))| + \\ & + |\gamma[n]c^*[n+1] - c^*[n+1]| = \quad (12) \\ & = (1 - \gamma[n])(1 + n^{-1})|c[n] - c^*[n]| = \\ & = F[n]|c[n] - c^*[n]|, \end{aligned}$$

где

$$F[n] = (1 - \gamma[n])(1 + n^{-1}). \quad (13)$$

Опустив в (10) случайную составляющую $\gamma[n]\eta[n+1]$, с использованием (10) запишем

$$\begin{aligned} & |c[n+1] - c^*[n+1]| = \\ & = F[n]|c[n] - c^*[n]| = \\ & = F[n]F[n-1]|c[n-1] - c^*[n-1]| = \quad (14) \\ & = \prod_{k=1}^n F[k]|c[1] - c^*[1]|. \end{aligned}$$

С учетом того, что при соответствующем выборе $\gamma[n]$, можно получить

$$\prod_{n=1}^{\infty} F[n] = 0, \text{ то } c[n] \text{ будет сходиться к } c^*[n]$$

при любых конечных значениях $c[1]$ и $c^*[1]$.

Здесь $c[1]$ - оценка координаты центра исследуемого кластера после предыдущего этапа кластеризации.

Тогда, приняв обозначение $z[n] = \gamma[n]\eta[n+1]$ и используя (9), запишем $E(z[n]) = 0$ и $E(z^2[n]) = \gamma^2[n]\sigma^2[n+1]$. Если принять предположение, что дисперсия $\sigma^2[n+1]$ шумовой составляющей величины $x[n+1]$ ограничена при всех n величиной σ^2 , то сумма дисперсий помех конечна, так как

$$\sum_{n=1}^{\infty} E(z^2[n]) \leq \sigma^2 \sum_{n=1}^{\infty} \gamma^2[n] < \infty.$$

После этого, приняв обозначение

$$V^2[n] = E[(c[n] - c^*[n])^2], \quad (15)$$

возведя в квадрат левую и правую части (6) и определив среднее, можно получить рекуррентное соотношение для среднеквадратической ошибки оценок

$$V^2[n+1] \leq F^2[n]V^2[n] + \gamma^2[n]\sigma^2, \quad (16)$$

где оно становится неравенством после подстановки вместо $\sigma^2[n+1]$ верхней границы дисперсии помехи σ^2 . После обозначения $B^2[n] = \gamma^2[n]\sigma^2$ и итерирования выражения (16)

$$\begin{aligned} V^2[n+1] & \leq F^2[n]V^2[n] + B^2[n] \leq F^2[n] \times \\ & \times F^2[n-1] \dots F^2[1]V^2[1] + F^2[n] \times \\ & \times F^2[n-1] \dots F^2[2]B^2[1] + \dots + \quad (17) \\ & + F^2[n]F^2[n-1]B^2[n-2] + F^2[n]B^2[n-1] + \\ & + B^2[n] \leq b^2[n]V^2[1] + \sum_{i=1}^{n-1} B^2[i]b^2[n-i] + B^2[n], \end{aligned}$$

где

$$b[n-i] = \prod_{k=i+1}^n F^2[k]. \quad (18)$$

Если $V^2[1] < \infty$, правая и левая части формулы (17) будут равны при $n \rightarrow \infty$. Следовательно, доказана сходимость

$$\lim_{n \rightarrow \infty} E[(c[n] - c^*[n])^2] = 0. \quad (19)$$

Сходимость $c[n]$ к $c^*[n]$ с вероятностью единица может быть доказана аналогично доказательству Дворецкого для стационарного случая [8].

Преобразовав неравенство (16) по методике [8], можно получить оптимальную последовательность шагов $\gamma[n]$. Для этого перепишем (16)

$$\begin{aligned} V^2[n+1] & \leq [(n+1)/n]^2(1 - \\ & - \gamma[n])^2V^2[n] + \gamma^2[n]\sigma^2. \quad (20) \end{aligned}$$

Минимум правой части неравенства (20) имеет место при

$$\gamma[n] = \frac{V^2[n]}{V^2[n] + \sigma^2[\frac{n}{n+1}]^2}, \quad (21)$$

полученного после приравнивания первой производной по $\gamma[n]$ нулю.

Подставляя выражение $\gamma[n]$ в (20), можно получить рекуррентное соотношение для среднеквадратической ошибки оценок

$$V^2[n+1] \leq \frac{\sigma^2 V^2[n]}{V^2[n] + \sigma^2 \left[\frac{n}{n+1} \right]^2} = \sigma^2 \gamma[n]. \quad (22)$$

Тогда, после введения обозначения $\alpha = \frac{\sigma^2}{V^2[1]}$, и с учетом того, что начальная оценка имела среднеквадратическую ошибку $V^2[1] = E[(c[1] - c^*[1])^2]$, используя (21) и (22), итерируя попеременно $V^2[n]$ и $\gamma[n]$, запишем оптимальную последовательность $\gamma^*[n]$ и минимизированное значение среднеквадратической ошибки $V^{2*}[n+1]$

$$\gamma^*[n] = \frac{(n+1)^2}{\frac{1}{6}(n+1)(n+2)(2n+3) + (\alpha-1)}, \quad (23)$$

$$V^{2*}[n+1] = \sigma^2 \gamma^*[n]. \quad (24)$$

Таким образом, в работе представлен адаптивный мультистартовый субградиентный метод кластеризации в пространстве вейвлет-преобразования для случая линейно меняющихся параметров кластера. Исследованы условия сходимости в среднеквадратическом смысле для этапа адаптации, приведены рекомендации по выбору шага. Вычислительные затраты при оценке параметров кластера на этапе адаптации сокращаются по сравнению с базовым вариантом [10] более чем на порядок. Применение метода при кластеризации в случае медленно (линейно) меняющихся параметров кластера позволит сократить вычислительные, временные и аппаратурные затраты на измерение параметров в процессе кластеризации, за счет чего -- повысить быстродействие, а следовательно, и оперативность диагностирования.

Список использованной литературы

1. Вахитов А.Т. Нестационарная стохастическая оптимизация рандомизированными алгоритмами в случае бесконечной дисперсии неопределенностей [Электронный ресурс] / А.Т. Вахитов. – Режим доступа: <http://www.math.spbu.ru/user/gran/soi5/vakhitov5.pdf>.
2. Вахитов А.Т. Псевдоградиентный метод с возмущением на входе для нестационарной задачи безусловной оптимизации [Электронный ресурс] / А.Т. Вахитов, Л.С. Гуревич. – Режим доступа: http://www.math.spbu.ru/user/gran/soi4/gurevic_h4.pdf.
3. Дорофеюк А.А. Методология эксперто-классификационного анализа в задачах управления и обработки сложноорганизованных данных / А.А. Дорофеюк // Проблемы управления. – 2009. – № 3.1 – С. 19 - 28.
4. Загоруйко Н.Г. Прикладные методы анализа данных и знаний / Н.Г. Загоруйко // – Новосибирск: Изд-во Ин-та математики, 1999. – 270 с.
5. Крилов В.Н. Субградієнтний ітеративний метод оптимізації в просторі вейвлет-перетворення/ В.Н.Крилов, Г.Ю. Щербакова // Збірн. наук. праць Військ. ін-ту Київського нац. ун-ту ім. Т. Шевченка. – 2008. – Вип. 12. – С. 56 - 60.
6. Недоступ Л.А. Технологические методы управления качеством радиоэлектронных измерительных устройств / Л.А Недоступ, Е.Т.Удовиченко, Г.А. Шевцов // – М.: Изд. стандартов, 1976. – 124 с.
7. Полак Э. Численные методы оптимизации / Э.Полак // – М.: Мир, 1976. – 509 с.
8. Фу К. Последовательные методы в распознавании образов и обучении машин / Фу К.; пер. с англ. Э.Ф.Зайцева // – М.: Наука, 1971. – 256 с.
9. Цыпкин Я.З. Адаптация и обучение в автоматических системах / Я.З. Цыпкин // – М.: Наука, 1968. – 400 с.

10. Щербакова Г.Ю. Адаптивная кластеризация в пространстве вейвлет- преобразования / Г.Ю. Щербакова, В.Н.Крылов. // Радіоелектронні і комп'ютерні системи. – 2009. – № 6. – С. 123–127.

11. Щербакова Г.Ю. Определение количества кластеров при прогнозировании состояния ЭА / Г.Ю.Щербакова, В.Н. Крылов, С.Г. Антощук // Электроника и связь. – 2010. – № 3 (56). – С. 91 - 95.

12. Щербакова Г.Ю. Статистический анализ технологических процессов на базе помехоустойчивой кластеризации в пространстве вейвлет–преобразования / Г.Ю.Щербакова, В.Н. Крылов, С.Г. Антощук // Електромашинобудування та електрообладнання. –2009. – Вип.72. – С.55 - 61.

13. Dupac V. A Dynamic Stochastic Approximation Method / V. Dupac. // The Annals of Mathematical Statistics. – 1965. – V.36. – № 6. – P. 1695 - 1702.

14. Krylov V.N. Contour images segmentation in space of wavelet transform with the use of lifting / V.N. Krylov, M.V. Polyakova // Optical-electronic informatively-power technologies. – 2007. – № 2 (12). – P. 48 - 58.



Щербакова
Галина Юрьевна,
канд. техн. наук,
доцент кафедры ЭСИКТ
Одесск.нац.политехн.
ун-та тел.734-8621
Galina_opru@mail.ru



Крылов
Виктор Николаевич,
д-р техн. наук,
проф. каф.
ПМиИТБ
Одесск.нац.политехн.ун-
та тел. 779-7453
Viktor_Krylov@inbox.ru



Логвинов Олег Викторо-
вич, канд. техн. наук, ст.
преп.каф. ЭСИКТ
Одесск.нац.политехн.ун-
та, тел.734-8621

Получено 15.02.2011