

## Методы согласования полиномиальных признаков текстурных изображений

А.В. Гайдель<sup>1,2</sup>

<sup>1</sup>Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

<sup>2</sup>Институт систем обработки изображений РАН – филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

**Аннотация.** Рассматривается ряд методов автоматической настройки квадратичных признаков цифровых текстурных изображений биологических тканей для повышения качества последующей классификации. В основе предложенных подходов лежат процедуры оптимизации, использующие разнообразные критерии качества признаков пространств в качестве целевых функций. Исследуются методы на базе случайного поиска, генетического алгоритма, имитации отжига, а также оригинальный гибридный алгоритм. Приводятся результаты экспериментальных исследований предложенных алгоритмов на наборах реальных рентгеновских изображений костной ткани и изображений компьютерной томографии лёгких. Показано, что гибридный алгоритм обеспечивает более стабильные результаты вне зависимости от выбранного критерия качества признакового пространства, что выражается в снижении средней доли неверно распознанных изображений по сравнению с использованием конкретных методов оптимизации.

### 1. Введение

Задача автоматической классификации изображений возникает в самых разных областях: начиная с медицинской диагностики и заканчивая геоинформатикой. Программные решения этой задачи используются как в системах машинного зрения, так и в системах поддержки принятия решений различного рода. При этом многие изображения, анализируемые на практике, являются текстурными, то есть не изображают никаких объектов, но несут в себе информацию сами по себе за счёт перепадов яркости [1].

Существует множество решений этой задачи, кардинально отличающихся друг от друга. В последнее время популярным подходом является использование свёрточных нейронных сетей, некоторые из которых впервые были описаны ещё в прошлом веке [2]. Недавние исследования показали, что этот подход крайне эффективен для широкого класса задач, так что теория глубокого обучения сильно разрослась и обзавелась множеством деталей [3]. При этом основным недостатком свёрточных нейронных сетей до сих пор остаётся высокая вычислительная сложность их обучения, не позволяющая в должной мере исследовать эффективность различных конфигураций нейронов и других их параметров [4].

Более классический подход состоит в том, что сначала по заданному изображению вычисляется некоторый набор признаков (числовых характеристик этого изображения), а затем к полученному вектору признаков применяется некоторая процедура классификации. При этом

для вычисления признаков текстурного изображения часто используются матрицы взаимной встречаемости, фильтры Габора, маски Лавса, вейвлет-преобразования, параметры моделей Марковских полей и многое другое [1]. Популярными подходами для классификации векторов признаков являются известные с прошлого века алгоритм  $k$  ближайших соседей и метод опорных векторов [5]. Также для этого, как и для классификации изображений в целом, могут использоваться нейронные сети [6].

При использовании признаков для классификации изображений возникает проблема выбора множества признаков, наилучшим образом описывающих изображения для конкретной задачи. Для этого могут использоваться различные эвристические процедуры, последовательно наращивающие и уменьшающие текущее множество наиболее эффективных признаков [7]. Также часто используются методы, выполняющие оптимальное линейное преобразование исходного признакового пространства с целью снижения его размерности, что также позволяет снизить объём данных, используемых для описания изображений, а также повысить эффективность классификации [8].

В [9] были предложены новые квадратичные признаки монохромных текстурных изображений, отличающиеся возможностью согласования с обучающей выборкой для повышения эффективности решения конкретной задачи классификации. Там же были описаны и исследованы некоторые процедуры их согласования. Эти признаки были успешно использованы для решения прикладной задачи автоматизированной диагностики эмфиземы по изображениям компьютерной томографии лёгких [10].

В настоящей работе развивается идея использования процедур оптимизации для автоматической настройки параметров согласованных квадратичных признаков. Для этого рассматривается ряд методов оптимизации и целевых функций в виде критериев качества признакового пространства. Также предлагается и экспериментально исследуется новый гибридный метод оптимизации для согласования квадратичных признаков. В экспериментальных исследованиях используются три набора данных: фотографии риса, рентгеновские изображения шейки бедра и изображения компьютерной томографии лёгких.

## 2. Методы согласования полиномиальных признаков

### 2.1. Согласованные квадратичные признаки

Пусть имеется монохромное цифровое изображение  $\omega(m, n)$ , представляющее собой функцию, отображающую из области интереса  $D_\omega \subset \mathbf{Z}^2$  в множество  $\mathbf{Q} \subset [0; Q-1] \cap \mathbf{Z}$ , состоящее из  $Q$  уровней яркости. Здесь  $\mathbf{Z}$  – это множество целых чисел.

Полиномиальные признаки строятся, как многочлены на множестве отсчётов изображения. Введём мультииндекс [11] порядка  $q \in [0; +\infty) \cap \mathbf{Z}$  как вектор  $\gamma = (\gamma(1) \ \gamma(2) \ \dots \ \gamma(|D_\omega|))^T$ ,

для которого  $\forall k \in [1; |D_\omega|] \cap \mathbf{Z}: \gamma(k) \in [0; +\infty) \cap \mathbf{Z}$  и  $\sum_{k=1}^{|D_\omega|} \gamma(k) = q$ . Здесь и далее для конечного

множества  $A$  обозначение  $|A|$  соответствует количеству элементов в этом множестве.

Множество всех мультииндексов порядка  $q$  обозначим  $\mathbf{I}_q$ . Кроме того, занумеруем все отсчёты  $(m, n) \in D_\omega$ , чтобы получилась конечная последовательность  $\{(m_k, n_k)\}_{k=1}^{|D_\omega|}$ .

Тогда полиномиальные признаки порядка  $q$  определяются как

$$\Psi(\omega, \theta) = \sum_{p=0}^q \sum_{\gamma \in \mathbf{I}_p} \theta(\gamma) \prod_{k=1}^{|D_\omega|} (\omega(m_k, n_k))^{\gamma(k)}, \quad (1)$$

где  $\theta(\gamma): \mathbf{I}_q \rightarrow (-\infty; +\infty)$  – это некоторые коэффициенты перед соответствующими членами с мультииндексом  $\gamma$ . Набор таких коэффициентов задаёт конкретный полиномиальный признак

изображения. Коэффициенты следует согласовывать с конкретной прикладной задачей, выбирая полиномиальные признаки, наилучшим образом описывающие изображение.

В [9] было показано, что при наложении естественных ограничений на признаки (1), связанные с инвариантностью к сдвигу и некоторым другим преобразованиям, оказывается, что из всего семейства полиномиальных признаков имеет смысл рассматривать только квадратичные признаки в форме

$$\Psi_2(\omega, \theta) = \sum_{(\Delta m, \Delta n) \in W_d} \theta(\Delta m, \Delta n) \hat{R}_\omega(\Delta m, \Delta n), \quad (2)$$

где  $R_\omega(\Delta m, \Delta n)$  – это отсчёты нормированной автокорреляционной функции изображения  $\omega(m, n)$ , то есть

$$\hat{R}_\omega(\Delta m, \Delta n) = \frac{1}{|D_\omega(\Delta m, \Delta n)|} \sum_{(m, n) \in D_\omega(\Delta m, \Delta n)} (\omega(m, n) - \bar{\omega})(\omega(m + \Delta m, n + \Delta n) - \bar{\omega}).$$

Здесь  $W_d = [-d; +d]^2 \cap \mathbf{Z}^2$  – квадратное окно радиусом  $d \in (0; +\infty) \cap \mathbf{Z}$ ,  $D_\omega(\Delta m, \Delta n) = \{(m, n) \in D_\omega \mid (m + \Delta m, n + \Delta n) \in D_\omega\}$  – множество отсчётов  $(m, n)$  из области интереса  $D_\omega$ , такое что соответствующие им сдвинутые на  $(\Delta m, \Delta n)$  отсчёты тоже лежат в области интереса  $D_\omega$ ,  $\bar{\omega}$  – средняя яркость изображения  $\omega(m, n)$ , то есть

$$\bar{\omega} = \frac{1}{|D_\omega|} \sum_{(m, n) \in D_\omega} \omega(m, n).$$

Особенность квадратичных признаков (2) заключается в возможности автоматического согласования с конкретной обучающей выборкой путём выбора оптимальных параметров  $\theta(\Delta m, \Delta n)$ , при которых некоторый функционал качества признакового пространства принимает наибольшее значение. Для этого предлагается использовать методы оптимизации.

## 2.2. Функционалы качества признакового пространства

В задаче бинарной классификации всё множество возможных изображений  $\Omega$  разбито на два класса  $\Omega_1$  и  $\Omega_2$ , так чтобы  $\Omega_1 \cup \Omega_2 = \Omega$  и  $\Omega_1 \cap \Omega_2 = \emptyset$ . Пусть  $\Phi(\omega): \Omega \rightarrow \{\Omega_1, \Omega_2\}$  – идеальный оператор распознавания, переводящий изображение в его класс. Для решения задачи распознавания требуется построить другой оператор  $\tilde{\Phi}(\omega): \Omega \rightarrow \{\Omega_1, \Omega_2\}$ , который принимает решение об отнесении изображения к одному из классов на основе конечной обучающей выборки  $U \subset \Omega$ , в которой для каждого изображения известен его класс. Этот оператор строится, как суперпозиция двух операторов  $\tilde{\Phi}(\omega) = C(\Psi(\omega))$ , где  $\Psi(\omega): \Omega \rightarrow \Xi$  вычисляет по изображению  $\omega(m, n)$  вектор  $x$  из некоторого конечного числа  $K$  квадратичных признаков (2), а  $C(x): \Xi \rightarrow \{\Omega_1, \Omega_2\}$  – это классификатор, принимающий решение об отнесении вектора признаков к одному из классов. Под  $\Xi \subseteq (-\infty; +\infty)^K$  понимается признаковое пространство.

Для заданного набора признаков  $\Psi(\omega)$  можно оценить качество признакового пространства по векторам признаков из обучающей выборки  $\{\Psi(\omega) \mid \omega \in U\}$ . В данной работе исследуются следующие функционалы качества признакового пространства.

1. Доля правильно распознанных изображений, вычисленная методом исключения одного объекта [5] из обучающей выборки  $U$ :

$$\tilde{J} = \frac{1}{|U|} \left| \left\{ \omega \in U \mid \Phi(\omega) = \tilde{\Phi}(\omega) \right\} \right|. \quad (3)$$

2. Расстояние Бхатачария:

$$\mu = \frac{1}{8}(a_1 - a_2)^T \left( \frac{R_1 + R_2}{2} \right)^{-1} (a_1 - a_2) + \frac{1}{2} \ln \left( \frac{1}{2} \frac{|R_1 + R_2|}{\sqrt{|R_1|}|R_2|} \right), \quad (4)$$

где  $a_1$  и  $a_2$  – внутриклассовые математические ожидания,  $R_1$  и  $R_2$  – внутриклассовые корреляционные матрицы:

$$a_l = \frac{1}{|U \cap \Omega_l|} \sum_{\omega \in U \cap \Omega} \Psi(\omega), \quad R_l = \frac{1}{|U \cap \Omega_l|} \sum_{\omega \in U \cap \Omega} (\Psi(\omega) - a_l)(\Psi(\omega) - a_l)^T.$$

3. Четвёртый критерий дискриминантного анализа из [5]:

$$J_4 = \text{tr}^{-1}(R_2) \text{tr}(R), \quad (5)$$

где  $R_2 = 0,5(R_1 + R_2)$  – средняя внутриклассовая корреляционная матрица, а  $R$  – корреляционная матрица смеси распределений:

$$R = \frac{1}{|U|} \sum_{\omega \in U} \left( \Psi(\omega) - \frac{1}{|U|} \sum_{\omega \in U} \Psi(\omega) \right) \left( \Psi(\omega) - \frac{1}{|U|} \sum_{\omega \in U} \Psi(\omega) \right)^T.$$

4. Критерий дискриминантного анализа из работы [12]:

$$J_{SNR} = \frac{\|a_1 - a_2\|}{\text{tr}(R_1) + \text{tr}(R_2)}.$$

Эти функционалы качества используются в качестве целевых функций в процедурах оптимизации параметров квадратичных признаков (2).

### 2.3. Методы оптимизации для согласования квадратичных признаков

Перенумеруем коэффициенты  $\theta(\Delta m, \Delta n)$  и будем считать  $\theta$  вектором. Согласование признаков (2) с обучающей выборкой  $U$  заключается в выборе вектора  $\theta$ , при котором некоторый функционал качества признакового пространства  $J(\theta)$  принимает наибольшее значение. Для этого можно использовать один из следующих методов оптимизации.

1. *Метод случайного выбора.* Случайным образом выбирается  $N$  векторов  $\theta$ , равномерно распределённых в некотором компактном множестве  $\Theta$ . После этого выбирается тот из них, для которого  $J(\theta)$  принимает наибольшее значение.

2. *Алгоритм имитации отжига.* Определим оператор мутации  $\zeta(\theta)$ , как значение гауссовского случайного вектора, с математическим ожиданием  $\theta$  и единичной корреляционной матрицей. Изначально зададим текущий вектор  $\theta$  из нулей. На очередной  $k$ -й итерации будем получать новый вектор  $\theta' = \zeta(\theta)$  и считать его новым текущим вектором  $\theta$ , если  $J(\theta') > J(\theta)$ . Если  $J(\theta') \leq J(\theta)$ , то всё равно будем считать вектор  $\theta'$  новым текущим вектором с вероятностью  $p = \exp(-(J(\theta) - J(\theta'))/t_k)$ , где  $t_k = t_0/k$ , иначе оставим  $\theta$  текущим вектором. Параметр  $t_0$  называется начальной температурой.

3. *Генетический алгоритм.* Определим оператор скрещивания  $c(\theta_1, \theta_2)$ , принимающий значение случайного вектора  $\theta$ ,  $j$ -я компонента которого равномерно распределена на отрезке  $[\min(\theta_1(j), \theta_2(j)); \max(\theta_1(j), \theta_2(j))]$ . Выберем начальную популяцию из  $M$  векторов методом случайного выбора. На каждой итерации будем выполнять скрещивание всех пар векторов из текущей популяции, после которого каждый полученный вектор будем подвергать мутации с вероятностью  $p_{\text{мут}}$ . В конце при переходе на следующую итерацию оставим только  $M$  векторов, для которых функционал качества  $J(\theta)$  принимает наибольшее значение.

3. *Гибридный алгоритм.* Если задуматься об общих принципах работы большинства итерационных алгоритмов глобальной оптимизации, можно заметить, что все они занимают

вычислением значений целевой функции в некоторых точках, а затем просто выбирают точку, для которой вычисленное значение целевой функции было оптимально. Существенные отличия между ними заключаются лишь в способе, которым они выбирают точки для вычисления значений целевой функции. Каждый из имеющихся итерационных алгоритмов обладает своими преимуществами и недостатками. Так алгоритмы случайного поиска лишены проблем с заикливанием на локальном максимуме, но зато мало используют информацию о предыдущих вычисленных значениях функции. Генетический алгоритм и алгоритм имитации отжига значительно более осмысленно осуществляют выбор точки, что повышает точность метода оптимизации, но могут остановиться в локальном максимуме, хотя у них и имеются средства для выхода из него в виде процедуры мутации у генетического алгоритма и перехода к менее оптимальной точке с высокой температурой у алгоритма имитации отжига.

Общая схема итерационного алгоритма глобальной оптимизации целевой функции  $J(\theta)$  в ограничениях  $\theta \in \Theta$  с заданным количеством итераций  $N$  выглядит следующим образом.

```

оптимизировать_функцию(  $J(\theta)$ ,  $\Theta$ ,  $N$  )
1   $A \leftarrow \emptyset$ 
2  для  $i \leftarrow 1:N$ 
3     $\theta \leftarrow$  получить_следующую_точку(  $A$ ,  $\Theta$  )
4     $A \leftarrow A \cup \{\theta\}$ 
5  вернуть  $\arg \max_{\theta \in A} J(\theta)$ 

```

Здесь используется псевдокод, подобный тому, что использовался в [13].

Варьируя способ выбора следующей точки, можно получать различные итерационные алгоритмы глобальной оптимизации. Предлагается на каждой итерации гибридного алгоритма выбирать алгоритм выбора следующей точки равновероятно среди трёх алгоритмов, соответствующих трём методам оптимизации, рассмотренным ранее. Похожая идея была описана в [14] для других алгоритмов оптимизации.

а) Следующая точка выбирается случайно из равномерного распределения на  $\Theta$ . Ранее выбранные точки не учитываются.

б) Следующая точка выбирается, как мутация  $\zeta(\theta)$  от случайной точки  $\theta \in A$ . Точки, для которых  $J(\theta)$  больше, мутируют с большей вероятностью.

в) Следующая точка выбирается, как скрещивание  $c(\theta_1, \theta_2)$  двух случайных точек  $\theta_1$  и  $\theta_2$  из множества  $A$  выбранных ранее точек. Точки, для которых  $J(\theta)$  больше, скрещиваются с большей вероятностью.

### 3. Экспериментальные исследования

Исследование эффективности предложенных методов согласования квадратичных признаков проводилось на следующих трёх наборах изображений.


1. Фотографии риса из открытой базы текстурных изображений Kylberg Texture Dataset [15] (320 изображений,  $576 \times 576$  отсчётов, рис. 1а, 1б).

2. Рентгеновские изображения шейки бедра человека, полученные в клиниках Самарского государственного медицинского университета в ходе клинических исследований (95 изображений,  $1040 \times 860$  отсчётов, рис. 1в, 1г).

3. Двумерные срезы компьютерной томографии лёгких человека, полученные в клиниках Самарского государственного медицинского университета в ходе клинических исследований (160 изображений,  $140 \times 200$  отсчётов, рис. 1д, 1е).

В каждой серии экспериментов фиксировались набор данных, критерий качества признакового пространства и метод оптимизации. Выборка случайным образом разделялась на обучающую выборку  $U$  и контрольную выборку  $\tilde{U}$  примерно пополам, так чтобы в обеих выборках доля изображений каждого класса была примерно одинаковой. Далее выполнялось согласование квадратичных признаков (2) с обучающей выборкой путём решения задачи

оптимизации с использованием выбранного критерия качества признакового пространства в качестве целевой функции. После этого производился отбор признаков с помощью алгоритма, подробно описанного в [16]. Наконец, выполнялось распознавание изображений из контрольной выборки  $\tilde{U}$ , и для этой выборки вычислялась доля неверно классифицированных изображений (3).



**Рисунок 1.** Примеры изображений, на которых проводились эксперименты: обычный белый рис (а), рис сорта арборио (б), шейка бедра здорового человека (в), шейка бедра, поражённая остеопорозом (г), КТ лёгких здорового человека (д), КТ лёгких, поражённых эмфиземой (е).

В качестве алгоритма классификации использовался алгоритм ближайшего соседа [5]. Для векторов признаков проводилась поэлементная нормализация, так чтобы среднее значение признаков в обучающей выборке стало нулевым, а дисперсия стала единичной. Эта процедура детально описана в [16]. Область интереса  $D_o$  на всех изображениях, кроме изображений риса, выбиралась вручную. Конкретные параметры описанных ранее алгоритмов следующие:  $d = 2$  – радиус окна  $W_d$ , в котором вычисляются признаки;  $K = 13$  – изначальное количество признаков;  $N = 200$  – количество шагов в алгоритмах оптимизации;  $M = 10$  – размер популяции в генетическом алгоритме;  $p_{mut} = 0,1$  – вероятность мутации в генетическом алгоритме;  $t_0 = 10$  – начальная температура в алгоритме имитации отжига.

**Таблица 1.** Результаты исследования методов согласования квадратичных признаков.

Метод оптимизации	Рис			Рентген костей			КТ лёгких		
	$J$	Ошибка	$K$	$J$	Ошибка	$K$	$J$	Ошибка	$K$
Случайный выбор	$\tilde{J}$	0.00	1	$\mu$	0.14	2	$\mu$	0.06	6
Имитация отжига	$\tilde{J}$	0.00	1	$J_4$	0.06	4	$J_4$	0.15	7
Генетический алгоритм	$J_{SNR}$	0.00	1	$J_4$	0.06	5	$J_4$	0.12	4

**Таблица 2.** Результаты исследования гибридного алгоритма оптимизации.

Критерий	Рис			Рентген костей			КТ лёгких		
	$J$	Ошибка	$K$	$J$	Ошибка	$K$	$J$	Ошибка	$K$
$\tilde{J}$	1.00	0.00	1	0.89	0.22	1	0.78	0.20	2
$\mu$	1.88	0.00	1	0.40	0.18	2	0.25	0.06	6
$J_4$	4.34	0.00	4	1.43	0.06	4	1.32	0.15	4
$J_{SNR}$	3.82	0.01	3	0.80	0.14	1	0.63	0.17	9

В таблице 1 кратко представлены результаты исследования качества первых трёх методов оптимизации. Для каждого из них и для каждого из трёх наборов данных приведён наилучший критерий качества признакового пространства, обеспечивающий наименьшую вероятность ошибочного распознавания, сама наименьшая вероятность ошибочного распознавания и наименьшее количество признаков  $K$ , оставшихся после процедуры отбора признаков. Видно, что изображения риса распознаются без ошибок, а наилучшие результаты для остальных двух наборов данных достигаются с использованием разных алгоритмов оптимизации и разных целевых функций.

В таблице 2 детально представлены результаты исследования эффективности гибридного алгоритма оптимизации для согласования квадратичных признаков. Для каждого критерия качества признакового пространства и для каждого набора данных приведены наибольшее значение целевой функции, соответствующая вероятность ошибочного распознавания изображений из контрольной выборки, а также количество признаков, оставшихся в результате процедуры отбора признаков. Видно, что изображения риса опять же распознаются без ошибок, а наилучшие результаты для двух других наборов данных совпадают, но теперь они оба получены с использованием одного и того же гибридного алгоритма оптимизации.

Средняя оценка вероятности ошибочного распознавания для различных критериев и методов оптимизации на 17,23 % выше, чем средняя ошибка при использовании гибридного метода оптимизации. Это означает, что вместо использования какого-то конкретного метода оптимизации для построения оптимальных квадратичных признаков (2) можно порекомендовать использовать предложенный гибридный метод.

#### 4. Заключение

В работе исследовались различные методы согласования полиномиальных признаков текстурных изображений. Предложенные подходы отличаются используемым методом оптимизации и целевой функцией. Был разработан оригинальный гибридный алгоритм согласования, сочетающий в себе шаги разных алгоритмов оптимизации.

В ходе экспериментальных исследований на трёх наборах изображений средняя оценка вероятности ошибочного распознавания по всем остальным алгоритмам оптимизации оказалась на 17,23 % выше, чем средняя вероятность ошибочного распознавания при использовании гибридного алгоритма для согласования признаков. Наилучшие результаты, полученные для всех наборов данных с помощью гибридного алгоритма, совпадают с наилучшими результатами, полученными с помощью других различных алгоритмов оптимизации, но при этом они получены с использованием только одного гибридного алгоритма. Таким образом, можно рекомендовать использовать для согласования квадратичных признаков разработанный гибридный алгоритм оптимизации.

Из критериев качества признакового пространства наилучшие результаты демонстрируют расстояние Бхатачария (4) и четвёртый критерий дискриминантного анализа (5). При этом расстояние Бхатачария лучше подходит для согласования признаков в задаче диагностики эмфиземы по изображениям компьютерной томографии лёгких, а четвёртый критерий дискриминантного анализа – в задаче диагностики остеопороза по рентгеновским изображениям шейки бедра. Возможно, комбинирование этих функций могло бы привести к созданию ещё более универсального подхода к согласованию квадратичных признаков.

## 5. Благодарности

Работа выполнена при поддержке Федерального агентства научных организаций (соглашение № 007-ГЗ/ЧЗ363/26) и гранта РФФИ 16-41-630761 р\_а, а также Министерства образования и науки РФ в рамках мероприятий Программы повышения конкурентоспособности Самарского университета среди ведущих мировых научно-образовательных центров на 2013-2020 годы.

## 6. Литература

- [1] Petrou, M. Image processing: Dealing with texture / M. Petrou, P. García Sevilla. – John Wiley & Sons, Ltd, 2006. – 618 p.
- [2] LeCun, Y. Gradient-based learning applied to document recognition / Y. LeCun, L. Bottou, Y. Bengio, P. Haffner // Proceedings of the IEEE. – 1998. – Vol. 86(11). – P. 2278-2324.
- [3] Goodfellow, I. Deep learning / I. Goodfellow, Y. Bengio, A. Courville. – MIT Press, 2016. – 800 p.
- [4] He, K. Convolutional neural networks at constrained time cost / K. He, J. Sun // The IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2015. – P. 5353-5360.
- [5] Fukunaga, K. Introduction to statistical pattern recognition / K. Fukunaga. – Academic Press, 1990. – 592 p.
- [6] Zhang, G.P. Neural networks for classification: a survey / G.P. Zhang // IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews). – 2000. – Vol. 30(4). – P. 451-462.
- [7] Goncharova, E. Feature selection methods for remote sensing images classification / E. Goncharova, A. Gaidel // CEUR Workshop Proceedings. – 2017. – Vol. 1901. – P. 86-91.
- [8] Biryukova, E. Development of the effective set of features construction technology for texture image classes discrimination / E. Biryukova, R. Paringer, A.V. Kupriyanov // CEUR Workshop Proceedings. – 2016. – Vol. 1638. – P. 263-269.
- [9] Гайдель, А.В. Согласованные полиномиальные признаки для анализа полутонных биомедицинских изображений / А.В. Гайдель // Компьютерная оптика. – 2016. – Т. 40, № 2. – С. 232-239.
- [10] Gaidel, A.V. Adjusted polynomial features for analysis of lung CT images / A.V. Gaidel // CEUR Workshop Proceedings. – 2016. – Vol. 1638. – P. 313-319.
- [11] Raymond, X.S. Elementary introduction to the theory of pseudodifferential operators / X.S. Raymond. – CRC Press, 1991. – 120 p.
- [12] Yang, M. Feature selection and construction for the discrimination of neurodegenerative diseases based on gait analysis / M. Yang, H. Zheng, H. Wang, S. McClean // 3<sup>rd</sup> International Conference on Pervasive Computing Technologies for Healthcare: Pervasive Health'09, London, United Kingdom, 1-3 April, 2009. – 7 p.
- [13] Cormen, T.H. Introduction to Algorithms / T.H. Cormen, C.E. Leiserson, R.L. Rivest. – MIT Press and McGraw-Hill, 1990. – 1048 p.
- [14] Wolpert, D.H. Probability collectives in optimization / D.H. Wolpert, S.R. Bieniawski, D.G. Rajnarayan // Handbook of Statistics. – 2013. – Vol. 31. – P. 61-99.
- [15] Kylberg, G. The Kylberg Texture Dataset v. 1.0: External report (Blue series) / G. Kylberg // Centre for Image Analysis, Swedish University of Agricultural Sciences and Uppsala University. – 2011. – Vol. 35. – 5 p.
- [16] Гайдель, А.В. Возможности текстурного анализа компьютерных томограмм в диагностике хронической обструктивной болезни / А.В. Гайдель, П.М. Зельтер, А.В. Капишников, А.Г. Храмов // Компьютерная оптика. – 2014. – Т. 38, № 4. – С. 843-850.



# Methods of polynomial feature adjustment for textual images

A.V. Gaidel<sup>1,2</sup>

<sup>1</sup>Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

<sup>2</sup>Image Processing Systems Institute of RAS - Branch of the FSRC "Crystallography and Photonics" RAS, Molodogvardejskaya street 151, Samara, Russia, 443001

**Abstract.** We consider a number of methods of automatic quadratic features adjustment for digital textural images of biological tissues in order to improve the quality of classification. The proposed approaches are based on optimization procedures that use various quality criteria of a feature space as target functions. We investigate the methods based on random search, genetic algorithm, simulation of annealing, as well as the original hybrid algorithm. The results of experimental studies of the proposed algorithms on sets of real X-ray images of bone tissue and the lung CT images are presented. We show that the hybrid algorithm provides more stable results regardless of the chosen quality criterion of the feature space, which is expressed in the reduction of the average percentage of incorrectly recognized images in comparison with the use of specific optimization methods individually.

**Keywords:** texture analysis, computer-aided diagnosis, polynomial features, genetic algorithm, simulated annealing.