

Интеллектуальный отбор признаков для локализации объектов на изображениях глазного дна на основе анализа цветовых подпространств

Н.Ю. Ильясова^{а,б}, Р.А. Парингер^{а,б}, Н.С. Ушакова^а, А.В. Куприянов^{а,б}

^а Самарский национальный исследовательский университет имени академика С.П. Королева, 443086, Московское шоссе, 34, Самара, Россия

^б Институт систем обработки изображений РАН – филиал ФНИЦ «Кристаллография и фотоника» РАН, 443001, ул. Молодогвардейская, 151, Самара, Россия

Аннотация

В работе представлена технология отбора признаков для локализации объектов на изображениях глазного дна на основе анализа цветовых подпространств, позволяющая проводить интеллектуальный анализ признаков для решения задачи выделения областей интереса при проведении операции лазерной коагуляции. Предложенная технология позволила не только выделить информативные признаки в конкретных цветовых пространствах, но и определить эффективный признак для различия двух определённых классов при конкретном значении окна фрагментации, благодаря использованию различных правил отбора признаков. Технология позволила найти универсальный признак, позволяющий разделять два конкретных исходных класса с минимальной ошибкой кластеризации во всех цветовых подпространствах, а также признак, информативный лишь в одном цветовом подпространстве, но позволяющий разделять большинство классов между собой. Выявлено наиболее информативное цветовое подпространство.

Ключевые слова: изображения глазного дна; лазерная коагуляция; текстурные признаки; интеллектуальный анализ данных; отбор признаков

1. Введение

В настоящее время сахарный диабет является самым распространённым эндокринным заболеванием во всем мире. При диабете происходит изменение кровеносных сосудов сетчатки, которое приводит к нарушению обеспечения сосудов сетчатки кислородом. Такое состояние зрительной системы ведёт к появлению диабетической ретинопатии (ДРП) (рис. 1). Лазерокоагуляция сетчатки является «золотым стандартом» лечения ДРП [1,2].




Рис.1. Пример диагностического изображения глазного дна без патологий (слева) и с патологией (справа).

В ходе лазерного лечения происходит нанесение серии дозированных микроожогов – лазерокоагулятов, в зоне отёка на сетчатке. Наложение коагулятов происходит либо по одному, либо серией коагулятов, расположенных в виде заданной фигуры правильной формы – паттерна, либо с предварительным планированием расположения коагулятов с последующим наложением полученного плана на изображение сетчатки в режиме реального времени [3]. Наиболее предпочтительно оптимальное расположение коагулятов, что подразумевает нахождение их в зоне отёка на максимально равных друг от друга расстояниях и исключения попадания их на сосуды.

Таким образом, разработка информационной технологии отбора признаков для локализации объектов на изображениях глазного дна, с целью последующего автоматического заполнения коагулятами зоны отёка с различным расположением в ней сети сосудов, в настоящее время является актуальной задачей [4].

Для расчёта информативного признакового пространства необходимо провести сегментацию изображения на определённые области интереса, которые характеризуются наличием объектов четырёх классов: экссудаты, толстые сосуды, тонкие сосуды и здоровые участки. Область макулярного отёка определяется скоплением зон экссудации. При проведении лазерной терапии врачи запрещают накладывать коагуляты на толстые сосуды и не рекомендуют затрагивать здоровые участки и тонкие сосуды, чтобы повысить эффективность проведения лазерной операции.

2. Технология выделения областей интереса на основе текстурного анализа биомедицинских изображений в различных подпространствах RGB

Выделение областей интереса планируется осуществлять на основе принятия решения о принадлежности фрагментированных зон к одному из 4 указанных классов объектов. Фрагментация проводилась путём разделения изображения на блоки квадратной формы, классификация которых осуществлялась на основе технологии представленной нами в работе [5,6]. Представленная в данной работе технология основывается на методах кластеризации с использованием текстурных признаков, так как анализ фрагментов исходных изображений показал, что они хорошо различаются своими текстурными свойствами. Текстурные признаки показали хорошие результаты при распознавании биомедицинских изображений и их дальнейшей диагностики [7,8,9]. Для расчёта текстурных признаков нами использовалась известная библиотека MaZda [10,11].

В работе [12] исследуется похожая задача выявления патологий по изображениям клеток крови, на основе анализа текстурных признаков различных классов исходных изображений в разных цветовых подпространствах. Таким образом, в настоящей работе было решено усовершенствовать ранее рассмотренную технологию и сформировать не только выборку фрагментов в исходном цветовом пространстве, но и в отдельных компонентах цветового пространства RGB, а также выборку полутоновых фрагментов изображений для проведения сравнительных экспериментальных исследований на предмет выявления более информативных цветовых пространств и подпространств, а также текстурных признаков различные цветовых подпространств. Таким образом, было сформировано 5 исходных выборок, содержащих вектора признаков, подсчитанных на изображениях в различных комбинациях компонент цветового пространства RGB.

В работе использовался общий и попарный способ отбора признаков. При использовании общего способа отбора признаков, признаковое пространство составляется из числа лучших признаков по значению критерия разделимости дискриминантного анализа [13,14], рассчитываемого для всех 4 классов исследуемых объектов. Наряду с общим, в отличие от работы [5,6] нами использовался также попарный способ отбора признаков, заключающийся в выборе признаков, обладающих наибольшим значением критерия разделимости при различении каждой пары классов и последующем их объединении в единый набор. Для оценки качества полученных наборов, проводилось вычисление ошибки кластеризации для всех исследуемых размеров окна фрагментации. Кластеризация осуществлялась методом K-средних, а в качестве меры сходства использовалось расстояние Махаланобиса [16]. Модернизированная технология отбора эффективных признаков распознавания представлена на рисунке 2.

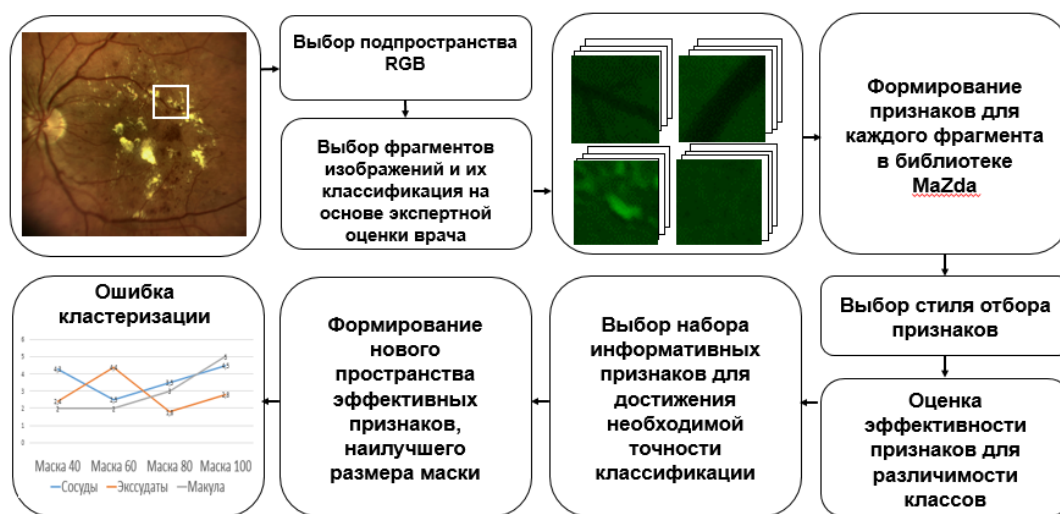


Рис. 2. Модифицированная технология формирования эффективных признаков для идентификации областей интереса изображений глазного дна.

3. Текстурные признаки

Как отмечалось выше, текстурные признаки хорошо себя зарекомендовали для распознавания биомедицинских изображений и их дальнейшей диагностики. Существует большое количество текстурных признаков. Программа «MaZda» [10,11], используемая в данной работе производит расчёт следующих групп признаков текстуры: а) основанные на статистических характеристиках; б) основанные на матрице смежности; в) основанные на градиентных параметрах; г) основанные на групповой матрице (матрице длины серий). Ниже приведены примеры признаков указанных групп, наиболее часто встречающиеся при различных видах отбора в предложенной технологии формирования информативных признаков.

Признаки, основанные на свойствах гистограммы:

- среднее (*Mean*) $\mu = \sum_i^N p(i)$, где $p(i)$ - вектор нормированной гистограммы (т.е. гистограммы, элементы которой

разделены на общее количество пикселей в рассматриваемой области интереса), $i = 0,1,2,\dots, N_g - 1$, N_g - количество уровней интенсивности;

- вариация (*Variance*): $\sigma^2 = \sum_{i=1}^{N_g} (i - \mu)^2 p(i)$;

- асимметрия (*Skewness*): $\mu_3 = \sigma^{-3} \sum_{i=1}^{N_g} (i - \mu)^3 p(i)$;

- эксцесс (*Kurtosis*): $\mu_4 = \sigma^{-4} \sum_{i=1}^{N_g} (i - \mu)^4 p(i) - 3$;

- процентиль- n (*Percentile- n*): i , при $\sum_{k=0}^i p(k) \leq n$, где $n = 0,01; 0,1; 0,5; 0,9; 0,99$.

Признаки, основанные на матрице смежности.

Матрица смежности содержит относительные частоты наличия на изображении соседних элементов $p(i, j)$, расположенных на расстоянии d друг от друга, с яркостями $(i, j) \in G$. Обычно различают горизонтальные $\alpha = 0^\circ$, вертикальные $\alpha = 90^\circ$ и поперечно-диагональные $\alpha = 45^\circ$ и $\alpha = 135^\circ$ пары элементов: $p(i, j) = P(i, j)/M$, где $P(i, j)$ – частота появления двух пикселей в скользящем окне с яркостью i и j под углом α на расстоянии d . M – общее количество пар, примыкающих друг к другу элементов. Признаки на основе матрицы совместной встречаемости вычисляются 20 раз для 4-х направлений $(d, 0)$; $(0, d)$; (d, d) ; $(d, -d)$, где расстояние d может принимать значения от 1 до 5 пикселей). Примеры признаков:

- разностная энтропия (*Difference entropy*):

$$DifEntrp = - \sum_{i=0}^{N-1} p_{x-y}(i) \log(p_{x-y}(i)), \quad p_{x-y}(k) = \sum_{i=1}^N \sum_{j=1}^N p(i, j), \quad |i - j| = k, \quad k = 0, 1, \dots, N-1;$$

- обратный разностный момент или гомогенность (*Inverse difference moment or Homogeneity*):

$$InvDfMom = \sum_{i=1}^N \sum_{j=1}^N (p(i, j) / (1 + (i - j)^2)).$$

Для расчета признаков, основанных на градиентных параметрах, для каждого пикселя изображения $x(i, j)$ определяется его окрестность:

A	B	C	D	E
F	G	H	I	J
K	L	$x(i, j)$	N	O
P	Q	R	S	T
U	V	W	Y	Z

Для каждого пикселя рассчитывается значение градиента ($ABSV(i, j)$) с учетом окрестности рассматриваемого пикселя:

- для окрестности 5x5 пикселей: $ABSV5(i, j) = \sqrt{(W - C)^2 + (O - K)^2}$;

- для окрестности 3x3 пикселей: $ABSV3(i, j) = \sqrt{(R - H)^2 + (N - L)^2}$.

Примеры признаков:

- среднее абсолютного градиента (*Mean absolute gradient*):

$$GrMean = \frac{1}{M} \sum_{i, j \in ROI} ABSV(i, j), \quad \text{где } ABSV - \text{ матрица из } M \text{ элементов, содержащая значения абсолютного градиента}$$

для всех пикселей области интереса;

- дисперсия абсолютного градиента (*Variance of absolute gradient*):

$$GrVariance = \frac{1}{M} \sum_{i, j \in ROI} (ABSV(i, j) - GrMean)^2.$$

Признаки на основе групповых матриц вычисляются 4 раза для каждого фрагмента (для 4-х направлений: горизонтального, вертикального, угла 45° и угла 135°). Групповая матрица $p(i, j)$ определяется заданием направления и подсчетом пикселей матрицы растрового изображения, имеющих один уровень серого и стоящих рядом в заданном направлении, здесь i – индекс, указывающий на определённый уровень серого, j – индекс, указывающий количество пикселей, имеющих один уровень серого и стоящих рядом в заданном направлении. Считается, что матрица на основе пробега длин серий изображения рассчитывает признаки хуже, чем на основе матрицы смежности. Однако показано, что особенности текстуры, извлечённые из матрицы длины пробега дают отличные результаты классификации:

- обратный момент в краткосрочной перспективе (*Short run emphasis inverse moments*):

$$SRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{j^2} = \frac{1}{n_r} \sum_{j=1}^N \frac{P_r(j)}{j^2},$$

где вектор $p_r(j) = \sum_{i=1}^M p(i, j)$ представляет собой сумму всех значений уровней серого с длиной запуска j , коэффициент

$$n_r \text{ рассчитывается как: } n_r = \sum_{i=1}^M \sum_{j=1}^N p(i, j).$$

4. Результаты экспериментальных исследований

Цель экспериментов – продемонстрировать возможности предложенной технологии для проведения интеллектуального анализа пространства признаков при решении конкретной диагностической задачи. Представленная технология позволяет не только выделить информативные признаки в конкретных цветовых пространствах, но и определить эффективный признак для различия двух определённых классов при конкретном значении окна фрагментации, благодаря использованию различных правил отбора признаков.

Экспериментальные исследования проводились на выборках, сформированных при анализе 132600 фрагментов, содержащих различные классы изображений. Для каждой из сформированных выборок по 26520 фрагментов были рассчитаны и отобраны по критерию делимости информативные текстурные признаки. Рассматривались наборы признаков, полученные при объединении от 1 до 6 информативных признаков для каждой пары классов.

При анализе наборов признаков было замечено, что признак «Perc.10%» отбирается для каждого значения окна фрагментации во всех цветовых подпространствах, кроме подпространства зелёной компоненты (рис.3). За вероятность использования признака примем отношение числа фрагментов, в которых он информативен, к общему числу фрагментов. При этом для зелёной компоненты признак оказывается информативным при размерах окна фрагментации от 10 до 21 пикселей. Таким образом, рассматриваемый признак «Perc.10%» является информативным при любом размере окна для каждого из цветовых подпространств, кроме зелёного, начиная с набора из трёх признаков, отбираемых при попарном способе отбора.




Рис.3. График зависимости вероятности использования «Perc.10%» от количества признаков в наборе для выборок каждого цветового подпространства RGB, выборки фрагментов исходного цвета и выборки полутоновых фрагментов.




Рис.4. График зависимости ошибки кластеризации от размера окна для всех пар классов в синем цветовом подпространстве для признака «Mean».

Признак «Perc.10%» не входит в число информативных признаков при общем способе отбора, что свидетельствует о том, что данный признак разделяет два определённых класса. Для поиска разделяемых классов найденным признаком, была подсчитана ошибка кластеризации для каждой пары классов во всех цветовых подпространствах. Проанализировав результаты в синем подпространстве (таблица 1), было сделано предположение что признак информативен для различения классов «толстые сосуды» / «экссудаты» и «толстые сосуды» / «здоровые участки»

(выделены серым). Была проведена оценка ошибки кластеризации для выбранных пар классов во всех исследуемых цветовых подпространствах (таблица 2, таблица 3). Исследования показали, что признак «Perc.10%» является информативным для различения классов «толстые сосуды» / «здоровые участки».

Также, при анализе наборов признаков был найден признак «Mean», информативный только в синем цветовом подпространстве и не являющийся таковым в других подпространствах при попарном и общем способах отбора. Найденный признак, разделяет большинство классов между собой с допустимой ошибкой кластеризации в синем подпространстве (рисунок 4). Для сравнения, на рисунке 5 представлен график ошибки кластеризации для признака «Mean» в красном цветовом подпространстве. Проанализировав графики, можно сделать вывод, что признак «Mean» разделяет классы «толстые сосуды» / «здоровые» участки, а именно в синем подпространстве при малых размерах окна фрагментации ошибка различения этих классов при использовании этого признака минимальна.




Рис.5. График зависимости ошибки кластеризации от размера окна для всех пар классов в красном цветовом подпространстве для признака «Mean».

Таблица 1. Ошибка кластеризации всех классов при использовании признака «Perc.10%» в синем подпространстве для размера окна фрагментации 10x10 пикселей

Разделяемые классы	Значение ошибки кластеризации
Толстые сосуды/Экссудаты	0,058
Экссудаты/Здоровые участки	0,485
Здоровые участки/Тонкие сосуды	0,483
Толстые сосуды/Здоровые участки	0,071
Толстые сосуды/Тонкие сосуды	0,244
Экссудаты/ Тонкие сосуды	0,582

Таблица 2. Ошибка кластеризации классов толстые сосуды/здоровые участки при использовании признака «Perc.10%» для размера окна фрагментации 10x10 пикселей

Цветовое подпространство	Значение ошибки кластеризации
Красное	0
Синее	0,071
Зеленое	0
Полотуновые	0,071
В исходном цвете	0

Таблица 3. Ошибка кластеризации классов толстые сосуды/экссудаты при использовании признака «Perc.10%» для размера окна фрагментации 10x10 пикселей

Цветовое подпространство	Значение ошибки кластеризации
Красное	0,266
Синее	0,058
Зеленое	0,157
Полотуновые	0,255
В исходном цвете	0,314

При проведении экспериментальных исследований было выявлено, что попарный отбор признаков даёт меньшую ошибку кластеризации по сравнению с общим отбором при любом количестве признаков и любом размере окон фрагментации. Анализа информативности цветовых подпространств для набора из 13 признаков при общем способе

отбора (рисунок 6) и для набора из 5 признаков при попарном (рисунок 7) показал, что при использовании попарного способа отбора, ошибка кластеризации существенно меньше. Проанализировав данные графика, приведённого на рисунке 7, можно сделать вывод, о том, что наименьшую ошибку кластеризации и минимальный размер окна сегментации с допустимой минимальной ошибкой (<2,5%) достигается для фрагментов размером 12 пикселей при использовании 5 признаков, отобранных попарным способом отбора в зелёном цветовом подпространстве. Таким образом, зелёное подпространство является наиболее информативным. Вероятность использования признаков зелёного подпространства отображена на рисунке 8 для различных значений окна фрагментации (от 10 до 50).




Рис.6. Зависимость ошибки кластеризации от размера окна фрагментации при использовании меры сходства Махаланобиса и набора из 13 признаков, информативных при общем способе отбора.

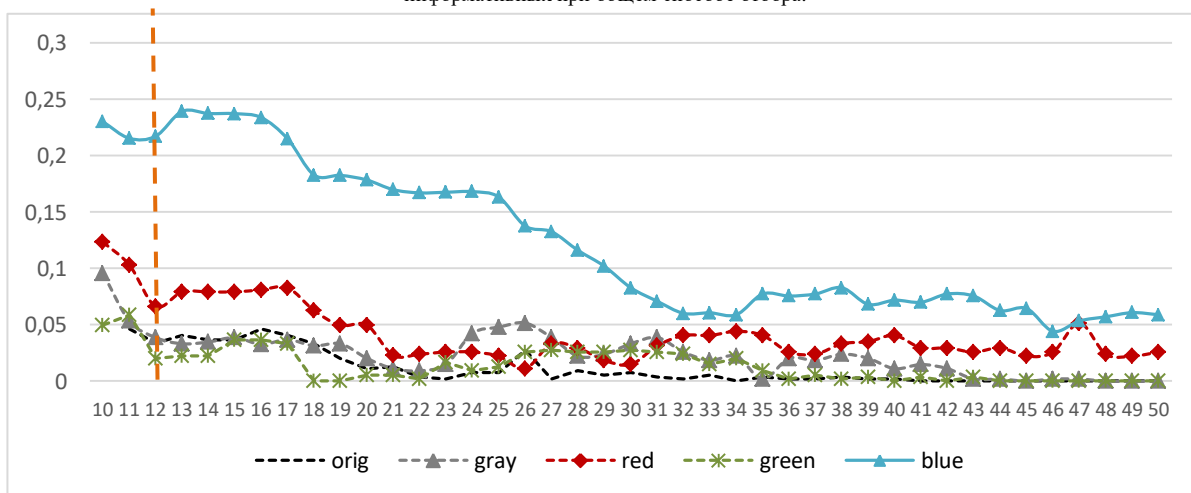


Рис.7. Зависимость ошибки кластеризации от размера окна фрагментации при использовании меры сходства Махаланобиса и набора из 5 признаков, информативных при попарном отборе признаков.




Рис.8. Вероятность появления признаков при попарном отборе признаков в зеленом подпространстве признаков при различных размерах окна фрагментации.

5. Заключение

В работе представлена технология отбора признаков для локализации объектов на изображениях глазного дна на основе анализа цветовых подпространств, позволяющая проводить интеллектуальный анализ признаков для решения задачи выделения областей интереса при проведении операции лазерной коагуляции.

Была проведена серия экспериментов с использованием 132600 фрагментов изображений, содержащих различные классы патоморфологических элементов глазного дна в различных цветовых подпространствах. Цель экспериментов – продемонстрировать возможности предложенной технологии для проведения интеллектуального анализа пространства признаков при решении конкретной диагностической задачи. Представленная технология позволила не только выделить информативные признаки в конкретных цветовых пространствах, но и определить эффективный признак для различия двух определённых классов при конкретном значении окна фрагментации, благодаря использованию различных правил отбора признаков. Технология позволила найти универсальный признак, позволяющий разделять два конкретных исходных класса с минимальной ошибкой кластеризации во всех цветовых подпространствах, а также признак, информативный лишь в одном цветовом подпространстве, но позволяющий разделять большинство классов между собой. Выявлено наиболее информативное цветовое подпространство.

Дальнейшее исследование направлено на совершенствование отдельных этапов представленной технологии, в частности изменение формы окна фрагментации, применение процедуры предварительной обработки изображения, позволяющей подчёркивать необходимые для анализа элементы изображения глазного дна.

Благодарности

Работа выполнена при частичной поддержке Министерства образования и науки РФ в рамках реализации мероприятий Программы повышения конкурентоспособности СГАУ среди ведущих мировых научно-образовательных центров на 2013–2020 годы; грантов РФФИ № 15-29- 03823, № 15-29- 07077, № 16-41- 630761; № 16-29- 11698; 17-01-00972; программы № 6 фундаментальных исследований ОНИТ РАН «Биоинформатика, современные информационные технологии и математические методы в медицине» 2016 -2017 гг.

Литература

- [1] Дога, А.В. Современные аспекты диагностики и лечения диабетического макулярного отека / А.В. Дога, Г.Ф. Качалина, Е.К. Педанова, Д.А. Буряков // ФГБУ Межотраслевой научно-технический комплекс «Микрохирургия глаза» им. акад. С.Н. Федорова, Москва, 2014. – Т. 4. – С. 51-59.
- [2] Астахов, Ю. С. Современные подходы к лечению диабетического макулярного отека / Шадричев Ф. Е., Красавина М. И., Григорьева Н. Н. // Офтальмологические ведомости. – М., 2009. – №4. – С. 59-69.
- [3] Kernt, M. Navigated focal retinal laser therapy using the NAVILAS® sys-tem for diabetic macula edema / Cheuteu R., Liegl R.G., et al. // Ophthalmologie. – 2012. – Vol. 109. – P.692-700.
- [4] HeiShun, Yu. Using texture analyses of contrast enhanced CT to assess hepatic fibrosis / Tischler B., Qureshi M.M., Soto J.A., Anderson S., Dagainawala N., Li B., Buch K. // European Journal of Radiology, 2016. – Vol.85, Issue 3. – P. 511–517.
- [5] Ilyasova, N. The effective features formation for the identification of regions of interest in a fundus images / N. Ilyasova, R. Paringer, A. Kupriyanov, N. Ushakova // CEUR Workshop Proceedings, 2016. – V. 1638. – P. 788-795.
- [6] Ilyasova N., Paringer R., Kupriyanov A. Regions of interest in a fundus image selection technique using the discriminative analysis methods, Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), V. 9972, pp. 408-417, 2016
- [7] Ильясова, Н.Ю. Методы цифрового анализа сосудистой системы человека. Обзор литературы // Компьютерная оптика. – 2013. – Т. 37, № 4. – С. 517-541.
- [8] Acharya, U.R. An integrated index for the identification of diabetic retinopathy stages using texture parameters / Ng E.Y., Tan J.H., Sree S.V., Ng K.H. // Journal of Medical Systems, vol. 36, Issue 3, 2011-2020. (2012).
- [9] HeiShun Yu, Tischler B., Qureshi M.M., Soto J.A., Anderson S., Dagainawala N., Li B., Buch K.: Using texture analyses of contrast enhanced CT to assess hepatic fibrosis. European Journal of Radiology, vol.85, Issue 3, 511–517. (2016)
- [10] Strzelecki, M. A software tool for automatic classification and segmentation of 2D/3D medical images / M. Strzelecki, P. Szczypinski, A. Materka, A. Klepaczko // Nuclear Instruments & Methods In Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment. – 2013. – Vol. 702. – P. 137–140
- [11] Piotr M. Szczypiński, Michał Strzelecki, Andrzej Materka, Artur Klepaczko: MaZda—A software package for image texture analysis, Computer Methods and Programs in Biomedicine, Volume 94, Issue 1, 66-76, (2009)
- [12] Пат. 2385494 Российская Федерация, МПК G 06 T 7/40. Способ распознавания изображения текстуры клеток / Никитаев В.Г.; заявитель и патентообладатель Московский инженерно-физический институт. - № 2008141633/28; заявл. 22.10.2008; опубл. 27.03.2010, Бюл. № 9. – 15 с.
- [13] Ilyasova, N.Yu. The Discriminant Analysis Application to Refine the Diagnostic Features of Blood Vessels Images / N.Yu. Ilyasova, A.V. Kupriyanov, R.A. Paringer // Optical Memory & Neural Networks (Information Optics). – 2015. – Vol. 24, № 4. – P.309-313.
- [14] Ильясова, Н.Ю. Формирование признаков для повышения качества медицинской диагностики на основе методов дискриминантного анализа / Н.Ю. Ильясова, А.В. Куприянов, Р.А. Парингер // Компьютерная оптика. – 2014. – Т. 38, № 4. – С. 851-856. – ISSN 0134-2452
- [16] Введение в статистическую теорию распознавания образов / К. Фукунага. – М.: Наука, 1979. - 270 с.