

Технология интеллектуального отбора признаков для сегментации изображений глазного дна

А.С. Широканев¹, Н.Ю. Ильясова^{1,2}, Р.А. Парингер^{1,2}

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

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

Аннотация. Для сегментации изображений глазного дна перспективно использовать технологию отбора эффективных признаков, которые обеспечивают минимальную ошибку распознавания объектов, используя при этом минимальное количество параметров для сегментации одного фрагмента изображения. Технология позволяет провести интеллектуальный анализ признаков с использованием цветовых подпространств для решения задачи выделения областей интереса. Для повышения эффективности проведения операции лазерной коагуляции задача наиболее точного выделения области интереса является особенно актуальной. Технология ориентирована на текстурный анализ выделенных паттернов изображений и позволяет, используя минимальное количество признаков, демонстрировать достаточно точную сегментацию. Для повышения эффективности сегментации предлагается использовать алгоритмы предобработки изображений, которые обеспечат более чёткое выделение объектов. В работе проводится исследование информативности полученного пространства признаков с использованием дискриминантного анализа данных. Определены наилучшие значения размеров окна фрагментации изображений для проведения сегментации и наборы признаков обеспечивающих необходимую точность идентификации областей интереса при анализе следующих 4 классов изображений: экссудаты, толстые сосуды, тонкие сосуды и здоровые участки.

1. Введение

Самым опасным и распространённым эндокринным заболеванием во всём мире является сахарный диабет. 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) (рисунок 1). Лазерная коагуляция сетчатки является «золотым стандартом» лечения ДРП [1,2]. 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] (рисунок 2). 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, задача отбора

признаков для выделения 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. В алгоритмах сегментации изображений ключевую роль могут играть методы обработки изображений, которые обеспечивает лучшую визуальную отделимость классифицируемых объектов. В настоящей работе предлагается предварительно обрабатывать фрагменты изображений глазного дна непосредственно до вычисления ошибок кластеризации.



Рисунок 1. Пример диагностического изображения глазного дна без патологий (а) и с патологией (б).

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, тонкие сосуды, чтобы повысить эффективность лазерной операции.




Рисунок 2. Примеры наложения коагулятов при проведении лазерной операции (а), примеры паттернов программного средства NAVILAS (б).

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

Для автоматизации процедуры лазерной коагуляции необходимо провести сегментацию изображения на указанные области интереса. Для того чтобы провести более точную сегментацию в работе [4] была предложена технология формирования набора эффективных признаков на основе анализа текстурных свойств указанных классов изображений с использованием дискриминантного анализа. Выделение областей интереса осуществляется на основе принятия решения о принадлежности фрагментированных зон к одному из 4 указанных выше классов объектов: экссудаты, толстые сосуды, тонкие сосуды и здоровые участки. Фрагментация проводилась путём разделения изображения на блоки квадратной формы, классификация которых осуществлялась на основе технологии представленной в [4].

В основе предложенной технологии применяются методы кластеризации с использованием текстурных признаков. Как показал анализ, области интереса исходных изображений хорошо различаются своими текстурными свойствами. Текстурные признаки и ранее показывали хорошие результаты при распознавании биомедицинских изображений и их дальнейшей диагностики [5, 6, 7, 8]. Для расчёта текстурных признаков была использована известная библиотека MaZda [9,10]. В работе [11] исследуется похожая задача выявления патологий по изображениям клеток крови, на основе анализа текстурных признаков различных классов исходных изображений в разных цветовых подпространствах.

В настоящей работе предлагается усовершенствовать ранее рассмотренную технологию и сформировать не только выборку фрагментов в исходном цветовом пространстве, но и в отдельных компонентах цветового пространства RGB и HSL, а также выборку полутоновых фрагментов изображений. Были проведены сравнительные экспериментальные исследования на предмет выявления более информативных цветовых пространств и подпространств, а также более информативных текстурных признаков различных цветовых подпространств.

Таким образом, было сформировано 7 исходных выборок, содержащих вектора признаков, подсчитанных на изображениях в различных комбинациях компонент цветовых пространств RGB и HSL. Кроме того, в отличие от работы [4], было принято решение проводить дополнительную процедуру поворота обучающих фрагментов изображений для получения более объективных результатов при формировании набора эффективных признаков.

В работе использовался общий и попарный отбор признаков. При использовании общего способа отбора признаков, признаковое пространство составляется из числа лучших признаков по значению критерия разделимости дискриминантного анализа [4, 12, 13, 14], рассчитываемого для всех 4 классов исследуемых объектов. Попарный способ отбора признаков заключается 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 Евклида и Махаланобиса [13].

Таким образом, модернизированная технология отбора эффективных признаков содержит следующие глобальные шаги обработки: 1) выбор фрагментов изображений и их классификация на основе экспертной оценки врача; 2) формирование изображений в подпространствах RGB и HSV при помощи поворота и без него; 3) формирование признаков для каждого фрагмента в библиотеке MaZda; 4) выбор способа отбора признаков (попарный и общий); 5) оценка эффективности признаков для различимости классов; 6) отбор информативных признаков для обеспечения требуемой точности классификации; 7) формирование нового пространства эффективных признаков и выбор наилучшего размера маски; 8) сегментация изображений.

3. Текстурные признаки

Текстурные признаки хорошо себя зарекомендовали для распознавания биомедицинских изображений и их дальнейшей диагностики. Существует большое количество текстурных признаков. Программа «MaZda» [9, 10], используемая в данной работе, производит расчёт следующих групп признаков текстуры: а) основанные на статистических характеристиках; б) основанные на градиентных параметрах; в) основанные на матрице смежности; г) основанные на групповой матрице (матрице длины серий) [8] (подробнее см. руководство пользователя MaZda, http://www.eletel.p.lodz.pl/mazda/download/mazda_manual.pdf). Ниже мы приводим наиболее часто встречающиеся признаки при различных размерах блоков фрагментации и различных методах выбора, используемых в предлагаемом методе для информативного выбора признаков.

4. Результаты экспериментальных исследований

Экспериментальные исследования проводились на выборках, сформированных при анализе 256200 фрагментов, содержащих различные классы изображений. Для каждой из сформированных выборок были рассчитаны и отобраны по критерию делимости наиболее информативные текстурные признаки. Рассматривались наборы признаков, полученные при объединении от 1 до 6 информативных признаков для каждой пары классов при попарном отборе и до 30 наиболее информативных признаков по критерию делимости при общем способе отбора признаков. Исследования направлены на выделение наилучшего набора признаков и размера окна фрагментации для идентификации областей интереса с заданной точностью при проведении сегментации изображений глазного дна. При этом специфика анализируемого диагностического изображений накладывает ограничение на размер окна фрагментации. Чем меньше размер окна, тем будет получена более качественная диагностика при проведении лазерной коагуляции. Поэтому анализируя полученные в ходе исследований зависимости выбираем наименьшее значение окна фрагментации, при котором происходит качественный скачок значений ошибки кластеризации и критерия делимости.

На рисунке 3 показана зависимость значений общегруппового критерия делимости от размера окна фрагментации при различном числе отобранных признаков (1-30), которые характеризуются максимальным индивидуальным критерием делимости. На рисунке видно, оптимальное число признаков является 13, так как дальнейшее их увеличение не ведёт к существенному росту общего критерия делимости. При этом качественный скачок на графике наблюдается при размере окна 12, что говорит о предположительно низком значении ошибки кластеризации в данной точке. Это подтверждает график зависимости ошибки кластеризации от размера окна фрагментации при различных мерах сходства (рисунок 4). Качественный скачок изменения ошибки кластеризации происходит при том же значении величины окна фрагментации - 12 (выделено пунктиром), позволяющий получить допустимую ошибку.

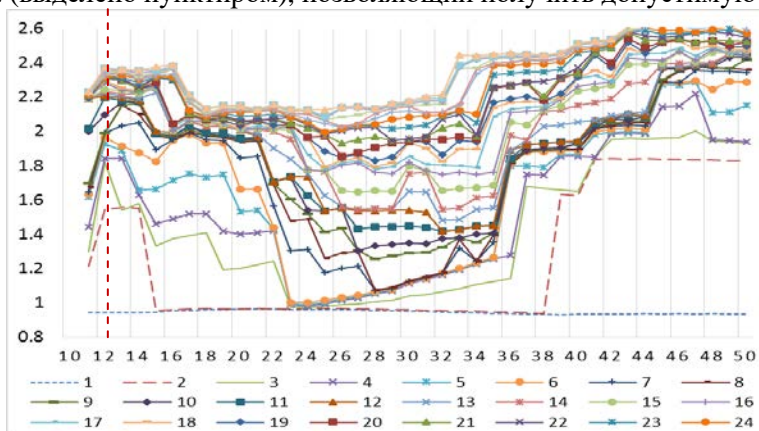


Рисунок 3. Зависимость значений общегруппового критерия делимости от размера окна фрагментации при различном числе выбранных признаков с максимальным критерием делимости.

Также были получены зависимости общегруппового критерия делимости от размера окна фрагментации при различном числе отобранных признаков, но при попарном способе отбора, и выявлено заметное увеличение критерия делимости при аналогичном значении минимального размера окна – 12. Эксперименты показали, что попарный отбор даёт меньшую ошибку кластеризации по сравнению с общим отбором признаков. На рисунке 5 показана зависимость ошибок кластеризации от размеров окна фрагментации для различных цветовых подпространств RGB при использовании меры Махаланобиса и набора, состоящего из 5 признаков, информативных при попарном способе отбора, где видно, что наименьшая ошибка кластеризации при условии минимального размера окна сегментации с допустимой минимальной ошибкой (<2,5%) достигается для фрагментов изображения размером 12 пикселей в зелёном цветовом подпространстве.




Рисунок 4. Зависимость ошибки кластеризации от размера окна фрагментации при различных мерах сходства при использовании 6 признаков, обладающих максимальным критерием разделимости при попарном отборе: а) Евклидово расстояние, исходные признаки; б) Расстояние Махаланобиса, сформированные признаки; с) Евклидово расстояние, исходные признаки; д) Расстояние Махаланобиса, сформированные признаки.

Таким образом, зелёное подпространство является наиболее информативным. Частота отбора признаков зелёного подпространства отображена на рисунке 6 для различных значений окна фрагментации (от 10 до 50). На рисунке 6 можно увидеть признаки, наиболее часто встречаемые при формировании вектора информативных признаков при различных окнах фрагментации, которые оказались нечувствительными к повороту изображений. Было выявлено, что при попарном отборе вышли на первый план статистические признаки и некоторые признаки исчезли, как неинвариантные к повороту.

Эксперименты показали, что наиболее информативными и наиболее вероятными при отборе для различных размеров окон фрагментации оказались следующие признаки: а) при попарном отборе: G_Sigma, H_Perc.99%, B_Perc.10%, B_Perc.01%, B_Perc.99%, G_Skewness, B_GrVariance, H_S(1,0)Correlat, G_S(5,0)Entropy, B_S(5,5)Entropy, Perc.10%, H_S(0,1)Correlat, G_S(5,5)Entropy; б) при общем отборе: G_S(5,-5)Entropy, G_S(5,5)Entropy, B_Perc.99%, G_S(0,5)Entropy, G_S(4,-4)Entropy, G_S(5,0)Entropy, G_S(4,4)Entropy, G_Sigma, G_S(0,1)Entropy, G_S(1,0)Entropy, H_Perc.99%, G_S(0,1)Correlat, G_S(1,0)Correlat. Общими признаками при любом способе отбора оказались признаки: G_S(5,5)Entropy, B_Perc.99%, G_S(5,0)Entropy, G_Sigma, H_Perc.99%. Некоторые наборы признаков, характеризующиеся максимальным критерием разделимости, представлены в таблице 1.




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

Таблица 1. Наборы признаков, характеризующиеся максимальным критерием разделимости.

Общий отбор		Попарный отбор	
Без поворота	С поворотом	Без поворота	С поворотом
B_Perc.99%	B_Perc.99%	Perc.10%	Perc.10%
B_Perc.90%	B_Perc.90%	G_Skewness	S(0,5)Entropy
G_S(1,0)Entropy	G_S(1,0)Entropy	G_S(5,0)Entropy	G_Skewness
G_S(0,1)Entropy	G_S(0,5)Entropy	B_Perc.99%	G_S(0,5)Entropy
H_Perc.90%	G_S(0,3)Entropy	B_GrVariance	B_GrVariance
G_S(0,5)Entropy	G_S(0,4)Entropy	H_Perc.90%	H_Perc.90%

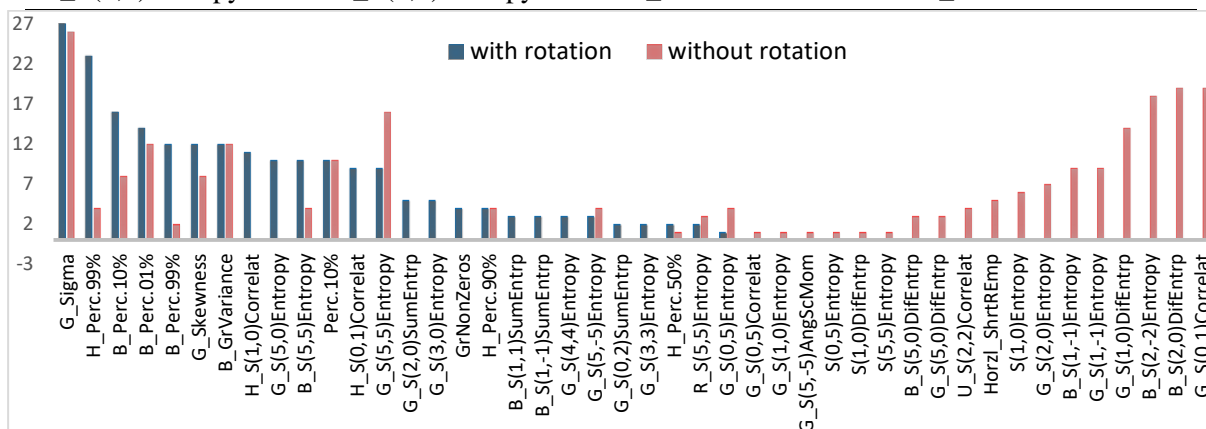


Рисунок 6. Вероятность появления признаков в зеленом подпространстве признаков при различных размерах окна фрагментации при попарном отборе признаков.

5. Результаты предварительной обработки фрагментов изображений глазного дна

Использование предварительной обработки изображений влияет на чёткость выделения объектов на изображении и, как правило, должно приводить к новым эффектам исследуемых признаков. На рисунке 7 представлены результаты ошибки кластеризации при использовании различных методов обработки изображений (линейное контрастирование, эквализация, медианная фильтрация).




Рисунок 7. Зависимость ошибки кластеризации от размера окна фрагментации при различных методах предобработки изображений при использовании 6 признаков, обладающих максимальным критерием разделимости при попарном отборе.

При данном способе кластеризации на фоне остальных выборок эквализация существенно ухудшает результат. Однако наблюдается интересный эффект: ошибка начинает сильно падать при больших размерах окна фрагментации. Такой эффект наблюдается на рисунке 8. В целом,

результат исследования показывает, что эквализация нарушает текстурность изображения. Эквализацию следует использовать при больших окнах фрагментации (18-20).

При использовании 20 признаков при попарном отборе (рисунок 8) линейное контрастирование улучшает результат при окнах фрагментации 13-15. Медианная фильтрация крестом 3x3 позволяет снизить ошибку по сравнению с результатами при отсутствии предобработки.




Рисунок 8. Зависимость ошибки кластеризации от размера окна фрагментации при различных методах предобработки изображений при использовании 20 признаков, обладающих максимальным критерием разделимости при попарном отборе.

При общем отборе линейное контрастирование даёт существенное снижение ошибки при размерах окна фрагментации, начиная с 12 (рисунок 9). По сравнению с результатом, полученным при попарном отборе без предобработки (рисунок 9), где ошибка достигала 5%, линейное контрастирование обеспечивает ошибку примерно 2%.




Рисунок 9. Зависимость ошибки кластеризации от размера окна фрагментации при различных методах предобработки изображений при использовании 13 признаков, обладающих максимальным критерием разделимости при общем отборе.

Таким образом, чтобы улучшить точность сегментации, линейное контрастирование эффективнее использовать при общем отборе признаков, эквализацию – при больших окнах фрагментации, а медианная фильтрация лучше всего работает при попарном отборе признаков. На рисунке 10 представлены результаты сегментации изображения глазного дна с использованием полученного с помощью представленной технологии отбора признаков. Результаты, представленные на рисунке 10, получены с использованием предложенной технологии отбора признаков. Визуальная экспертная оценка специалиста показала, что наилучший результат сегментации представлен на рисунке 10г, и подтвердила выше приведённые результаты экспериментальных исследований.




Рисунок 10. Результаты сегментации изображений глазного дна с использованием полученного с помощью представленной технологии набора признаков: исходное изображение (а); попарный отбор признаков (б), (в), (г), (д); общий отбор признаков (е), (ж), (з), (и); без поворота (б), (в), (д), (е); с поворотом (г), (д), (з), (и); расстояние Махаланобиса (б), (г), (е), (и); Евклидово расстояние (в), (д), (ж), (з).

6. Заключение

Представленная технология отбора эффективных признаков с использованием различных цветовых подпространств для проведения сегментации изображений глазного дна позволила осуществить интеллектуальный анализ признаков для решения задачи выделения областей интереса, содержащих 4 класса объектов (экссудаты, здоровые участки, толстые, тонкие сосуды) для проведения операции лазерной коагуляции. Для оценки эффективности набора признаков была использована процедура кластеризации на основе метода К-средних. В качестве меры сходства были выбраны расстояние Евклида и Махаланобиса. Необходимый размер окна фрагментации и мера сходства выбирались из критерия минимума ошибки кластеризации среди всех наименьших размеров окна фрагментации.

Экспериментальные исследования технологии на серии из 100 изображений (256200 фрагментов, содержащих различные классы элементов глазного дна в различных цветовых подпространствах) позволили выделить наиболее информативные текстурные признаки (13 при общем способе отбора и 6 – при попарном отборе признаков), а также размер окна фрагментации (равного 12 пикселям), для получения наилучшего результата кластеризации. При этом необходимо отметить, что по сравнению с работой [4], использование различных

цветовых подпространств и дополнительного поворота изображений обучающих выборок позволило существенно уменьшить размер окна фрагментации (с 47 до 12 пикселей) при сохранении достоверности кластеризации не меньше 95%, что является важным при проведении операции лазерной коагуляции. Парный способ отбора признаков позволил снизить ошибку кластеризации в 2 раза и более чем в 2 раза уменьшить количество признаков (до 6). В зависимости от различных способов отбора признаков и наличия поворота изображений были получены несколько наборов информативных признаков, обладающих наибольшим критерием разделимости. В результате экспериментальных исследований были получены следующие рекомендации для получения наилучших результатов кластеризации: 1) маска фрагментации – 12 пикселей; 2) парный отбор признаков; 3) использование следующих текстурных признаков: Perc.10%, G_Skewness, G_S(5,0)Entropy, V_Perc.99%, V_GrVariance, H_Perc.90%. Так же следует отметить, что предложенная технология позволила не только выделить информативные признаки в конкретных цветовых пространствах, но и выявить наиболее информативное цветовое подпространство при наилучшем способе отбора признаков.

Полученные результаты экспериментальных исследований при использовании методов предварительной обработки изображений глазного дна демонстрируют эффект снижения ошибки кластеризации при определённых условиях. Линейное контрастирование обеспечивает существенное снижение ошибки при использовании общего отбора признаков; медианная фильтрация позволяет снизить ошибку при использовании парного способа отбора; эквализация нарушает текстурность изображения и может быть эффективна лишь при больших окнах фрагментации.

7. Благодарности

Работа выполнена при поддержке Федерального агентства научных организаций (соглашение № 007-ГЗ/ЧЗ363/26), 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.

8. 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 / Ю.С. Астахов, Ф.Е. Шадричев, М.И. Красавина, Н.Н. Григорьева // 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 / M. Kernt, R. Cheuteu, R.G. Liegl et al. // Ophthalmologie. – 2012. – Vol. 109. – P. 692-700.
- [4] Ilyasova, N. Regions of interest in a fundus image selection technique using the discriminative analysis methods / N. Ilyasova, R. Paringer, A. Kupriyanov // Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). – 2016. – Vol. 9972. – P.408-417.
- [5] HeiShun, Yu. Using texture analyses of contrast enhanced CT to assess hepatic fibrosis / Yu. HeiShun, B. Tischler, M.M. Qureshi, J.A. Soto, S. Anderson, N. Dagainawala, B. Li, K. Buch // European Journal of Radiology. – 2016. – Vol. 85(3). – P. 511-517.
- [6] Gentillon, H. Parameter set for computer-assisted texture analysis of fetal brain / H. Gentillon, L. Stefańczyk, M. Strzelecki, M. Respondek Liberska // BMC Research Notes. – 2016. – Vol. 9. – P. 496.

- [7] Acharya, U.R. An integrated index for the identification of diabetic retinopathy stages using texture parameters / U.R. Acharya, E.Y. Ng, J.H. Tan, S.V. Sree, K.H. Ng // *Journal of Medical Systems*. – 2012. – Vol. 36(3). – P. 2011-2020.
- [8] Hajek, M. Texture Analysis for Magnetic Resonance Imaging / M. Hajek, M. Dezortova, A. Materka, R. Lerski // *Medpublishing*, 2006. – P.234.
- [9] 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 and Methods // Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*. – 2013. – Vol. 702. – P.137-140.
- [10] Szczypiński, M. MaZda – A software package for image texture analysis / M. Szczypiński, M. Strzelecki, A. Materka, A. Klepaczko. *Computer Methods and Programs in Biomedicine*. – 2009. – Vol. 94(1). – P. 66-76.
- [11] Nikitaev, V. Method for recognizing the image of the texture of cells. Patent RF. No.2008141633/28, 2010. – URL: <http://www.freepatent.ru/images/patents/78/2385494/patent-2385494.pdf> (PDF).
- [12] 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 and Neural Networks (Information Optics)*. – 2015. – Vol. 24(4). – P. 309-313.
- [13] Fukunaga, K. Introduction to statistical pattern recognition / K. Fukunaga. – New York and London: Academic Press, 1972. – P. 369.
- [14] Kim, J.-A. Factor, discriminant and cluster analysis / J.-A. Kim, Ch.U. Myuller, W.R. Klekka. – Financy i Statistica Publisher, 1988. – 215 p.

A smart feature selection technique for segmentation of fundus images

A.S. Shirokanev¹, N.U. Ilyasova^{1,2}, R.A. Paringer^{1,2}

¹Samara National Research University, Moskovskoye shosse, 34, Samara, Russia, 443086

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

Abstract. We propose a technique for selecting effective features for fundus image segmentation. The technique has made it possible to conduct smart feature analysis with the aid of color subspaces when solving a problem of selecting the regions of interest. The relevance of the problem is associated with enhancing the effectiveness of laser coagulation surgery. The technique is based on the texture analysis of image patterns. To improve the efficiency of segmentation we propose to use image preprocessing algorithms that will provide a more precise selection of objects. The analysis of the information content of the resulting feature space and selection of most effective features is conducted using the discriminant data analysis. We determine the best size of an image fragmentation block for segmentation the ocular fundus and feature sets enabling the regions of interest to be identified with a required accuracy when analyzing the following four classes of images: exudates, thick vessels, thin vessels, and intact areas. The feature selection technique utilizes K-means-based clustering whereas the Euclidean and Mahalanobis distance is used as a similarity measure. The required minimal size of the fragmentation block and the similarity measure are chosen based on the criterion of the minimal clustering error among all smallest block sizes. The proposed technique enables not only the informative features to be extracted in particular color spaces but also the most informative color subspace to be identified.

Keywords: fundus images, image processing, diagnostic features, laser coagulation, texture analysis.