

Детектирование стадии фиброза печени при помощи текстурного анализа ультразвуковых изображений

А. Хвостиков¹, А. Крылов², Ю. Камалов³,

Лаборатория математических методов обработки изображений⁴,

Факультет вычислительной математики и кибернетики

Московский государственный университет им. М. В. Ломоносова, Россия

¹xubiker@gmail.com, ²kryl@cs.msu.ru, ³kamalov53@yandex.ru, ⁴http://imaging.cs.msu.ru

Аннотация

Предложен комплексный текстурный метод анализа ультразвуковых изображений печени для определения стадии фиброза. Разработан алгоритм, основанный на использовании классификаторов Rotation Forest и KNN применительно к текстурным характеристикам. 720 текстурных характеристик получены методами, основанными на применении матрицы смежности, энергетических масок Laws', матрицы равномерности и статистических характеристик изображений. С помощью корреляционного метода произведён выбор 22 существенных признаков. Тестирование метода на изображениях печени 57 пациентов при разделении на 5 стадий фиброза показало 72.7% точность классификации отдельных областей интереса. При классификации целых изображений алгоритм правильно определил стадию фиброза в подавляющем большинстве случаев.

Ключевые слова: текстурный анализ, ультразвуковые изображения, фиброз печени, алгоритмы классификации

1. ВВЕДЕНИЕ

Фиброз печени – заболевание, при котором вследствие хронического воспаления печени происходит постепенное разрастание или уплотнение соединительной ткани. Развитие фиброза приводит к серьёзным последствиям (нарушению процессов обмена между клетками печени и кровью, шунтированию крови, прогрессированию хронического заболевания печени в сторону цирроза, сужению спектра и снижению эффективности лечебных мероприятий). Поэтому диагностика и оценка стадии фиброза представляет собой важную и актуальную задачу.

В силу того, что динамическое наблюдение за фиброзом печени с помощью биопсии затруднено ввиду инвазивности самого метода, наиболее востребованными сейчас являются неинвазивные методы диагностики, например, ультразвуковое исследование. Для определения стадии фиброза печени обычно используются текстурные методы, основанные на энергетических масках Laws'[1], матрицах смежности[2, 3], фрактальных размерностях [3], матрицах равномерности [4].

В данной статье предлагается комплексный подход к определению стадии фиброза печени, сочетающий в себе сразу несколько текстурных методов.

В качестве материала для исследования использовались ультразвуковые снимки печени 57 пациентов с различной подтверждённой стадией фиброза. Изображения имеют разрешение $\sim 770 \times 770$ пикселей и глубину 8 бит. На используемых снимках печень представлена в трёх сечениях: вдоль брюшной средней линии, вдоль правой парастеральной линии и

вдоль правой межключичной линии. В дальнейшем будем именовать эти сечения как $C1$, $C2$ и $C3$.

Для классификации стадии фиброза печени используется 5-уровневая ($F0-F4$) шкала *METAVIR*.

Обучение и классификация проводятся следующим образом:

1. *Обучение.* На каждом изображении из обучающей базы выделяется несколько областей для анализа текстуры. Для областей составляются векторы текстурных признаков, на которых тренируется ансамбль классификаторов.
2. *Классификация.* Для каждого вновь поступившего изображения выделяются области интереса, вычисляются такие же векторы признаков и классифицируются при помощи обученного ансамбля.

2. ВЫБОР ОБЛАСТЕЙ ИНТЕРЕСА

На исходном изображении выбирают области интереса (ROI), представляющие собой квадратные участки фиксированного радиуса. Выбираемые области должны содержать «чистую» текстуру без сосудов, затемнений и других артефактов. Обычно для изображений такого разрешения радиус областей интересов выбирают от 16 до 32 пикселей [1, 3].

Так как информативная часть изображения на ультразвуковом снимке представлена в виде конуса, текстура печени имеет разный угол направленности, зависящий от удаления от оси конуса, что оказывает сильное влияние на значения неустойчивых к повороту текстурных признаков. Для устранения этого эффекта предлагается выбирать ROI с учётом угла поворота текстуры. Выбор областей интереса проводится вручную, поиск оси конуса на изображении и поворот ROI выполняется автоматически.



Рис. 1. Пример выделения ROI с учетом поворота

3. ПРЕДОБРАБОТКА ИЗОБРАЖЕНИЯ

Перед вычислением текстурных характеристик анализируемое изображение нормализуется по яркости. Для этого рас-

смагивается множество пикселей, образующее области интереса:

$$\Omega = \bigcup_{k=1}^n \{i \in ROI_k\}, \text{ где } n - \text{ число выделенных областей.}$$

Для множества Ω вычисляются среднее значение и среднеквадратичное отклонение. После чего линейным преобразованием исходное изображение приводится к изображению со средним значением яркости 128 и среднеквадратичным отклонением 30 (рис. 2).




Рис. 2. Применение нормализации:
а – исходное изображение; б – результат

4. ВЫЧИСЛЕНИЕ ПРИЗНАКОВ

Для каждой ROI нормализованного изображения вычисляются текстурные признаки, позволяющие ёмко охарактеризовать основные параметры текстуры.

4.1. Статистические характеристики

Ряд признаков (среднее значение, среднеквадратичное отклонение, вариация, энергия, асимметрия, эксцесс, энтропия) вычисляется непосредственно для самого изображения.

4.2. Энергетические характеристики Laws'

Из одномерных ядер L5, E5, S5, W5, R5 путём попарного произведения векторов и удаления повторяющихся элементов составляются 15 двумерных масок. Для каждой ROI вычисляются свёртки со всеми полученными масками, причём, в случае несимметричных масок результат усредняется:

$$Laws(ROI, E5L5) = \frac{ROI * E5L5 + ROI * L5E5}{2}.$$

Для каждого отфильтрованного изображения вычисляются коэффициенты среднего значения, среднеквадратичного отклонения, асимметрии, эксцесса и энергии [1].

4.3. Характеристики матрицы смежности

Также используется матрица смежности (GLCM) [5]. Она строится для полутоновых изображений по фиксированному

вектору $d = (dr, dc)$, задающему смещение между пикселем яркостью i и пикселем яркостью j :

$$GLCM(i, j) = |\{(r, c) | I[r, c] = i, I[r + dr, c + dc] = j\}|.$$

Каждая ROI нормализованного изображения постеризуется до 64 градаций яркости, после чего для неё вычисляются матрицы смежности по всем возможным смещениям $dr = 0,9$, $dc = 0,9$.

Для каждой GLCM вычисляются коэффициенты энергии, энтропии, контрастности, однородности, различия и корреляции.

4.4. Характеристики матрицы равномерности

Матрица равномерности (GLRLM) [6] имеет размер $n \times m$, где n - число градаций яркости, m - число, не превышающее длины диагонали изображения. GLRLM строится по фиксированному углу $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$, задающему направление построения матрицы:

$$P[i, j | \theta] = |\omega|,$$

где ω - множество групп из j подряд идущих пикселей яркости i в направлении θ .

Каждая ROI постеризуется до 64 градаций яркости, после чего для неё вычисляются GLRLM по всем четырём направлениям ($0^\circ, 45^\circ, 90^\circ, 135^\circ$).

Для каждой матрицы вычисляются признаки SRE, LRE, LGRE, HGRE, SRLGE, SRHGE, LRLGE, LRHGE, GLNU, RLNU, RPC.

В итоге, для каждой ROI вычисляется вектор текстурных характеристик, состоящий из 720 признаков.

5. ПОСТОБРАБОТКА ПРИЗНАКОВ

На этапе выделения областей интереса иногда возникает ситуация, при которой выделяемая область частично «задевает» какой-либо артефакт, в этом случае значения вычисленных текстурных характеристик этой ROI сильно отличаются от аналогичных значений остальных ROI на изображении. Причём, если такое отклонение имеет место, то отличия заметны сразу на большом количестве признаков.

Для предотвращения этой ситуации в алгоритме предусмотрена возможность исключения выбросов в объёме до 40%.

6. КЛАССИФИКАЦИЯ И РЕЗУЛЬТАТЫ

Для сравнения возможностей различных классификаторов применительно к данной задаче используется ПО с открытым исходным кодом *Weka* [7, 8].

На момент написания статьи база данных содержит снимки 57 пациентов (7 пациентов со стадией F0, 34 пациента со стадией F1, 8 пациентов со стадией F2, 2 пациента со стадией F3, 6 пациентов со стадией F4).

Для балансирования выборки обучающая база данных умственно прореживается так, чтобы число пациентов с разными стадиями фиброза было примерно одинаковым.

Далее изображения разбиваются на три группы по сечению. Внутри каждой группы вычисляются векторы текстурных признаков для всех ROI на всех изображениях, полученные векторы перемешиваются случайным образом. После чего составленный набор векторов длины 720 передаётся класси-

фикатору для обучения. Для каждого типа сечения ($C1$, $C2$, $C3$) используется независимый классификатор.

В ходе поиска наиболее подходящего классификатора были протестированы алгоритмы SVM, MultilayerPerceptron, KNN, K^* [9], RandomForest [10], Rotation Forest [11], CHIRP, Decorate.

Для проверки качества обучения использовался скользящий контроль с разбиением на 10 подвыборок.

Подавляющее большинство классификаторов показали лучший результат на сечении $C1$, что объясняется большей однородностью текстуры на этом сечении.

Лучший результат показал классификатор Random Forest со следующими параметрами: глубина деревьев = 15, количество признаков = 100, количество деревьев = 2000. Точность классификации отдельно взятой области интереса составляет 66.8% для $C1$, 63.6% для $C2$, 64.4% для $C3$.

Далее с помощью корреляционного метода CFS [12] из 720 признаков были выбраны существенные 22 признака для $C1$, 11 признаков для $C2$ и 12 признаков для $C3$. Например, для $C1$ такими признаками являются: среднее квадратичное отклонение и эксцесс для самого изображения, среднее квадратичное отклонение для свертков с масками Laws' LW, EE, SS, RR, RW, WW и энергия для SS, контраст для GLCM(9,1), энтропия для GLCM(1,0) и GLCM(9,6), энергия для GLCM(1,1), однородность для GLCM(2,6) и GLCM(7,9), корреляция для GLCM(5,2), различие для GLCM(7,1) и GLCM(7,2), SRLGE для GLRLM(0), LRE для GKRLM(45), LRLGE для GLRLM(90) и GLNU для GLRLM(135).

На сжатых таким образом данных были еще раз протестированы различные классификаторы. В итоге, для изображений из группы $C1$ была достигнута точность:

- KNN – 72.7%.
- Random Forest – 68.0%.
- Rotation Forest – 69.2%.
- K^* - 70.4%.

Увеличение точности классификации подтверждает правильность выбора существенных признаков.

predicted \ actual	$F0$	$F1$	$F2$	$F3$	$F4$
$F0$	38	4	5	0	1
$F1$	3	25	7	0	3
$F2$	5	5	29	0	4
$F3$	0	0	0	0	0
$F4$	4	4	1	0	31

Матрица ошибок на сечении $C1$ для классификатора KNN

Для окончательной проверки предложенного алгоритма было проведено тестирование в условиях, приближенных к реальным. Именуемая база данных пациентов была разделена на непересекающиеся обучающую и тестовую выборки. Тестовая выборка состояла из 1 пациента с $F0$, 4 пациентов с $F1$, 1 – с $F2$, 1 – с $F4$. Для классификации использовался выбранный ранее Random Forest. Из-за небольшого размера базы

данных подобное разделение проводилось несколько раз с выбором разных пациентов для тестирования.

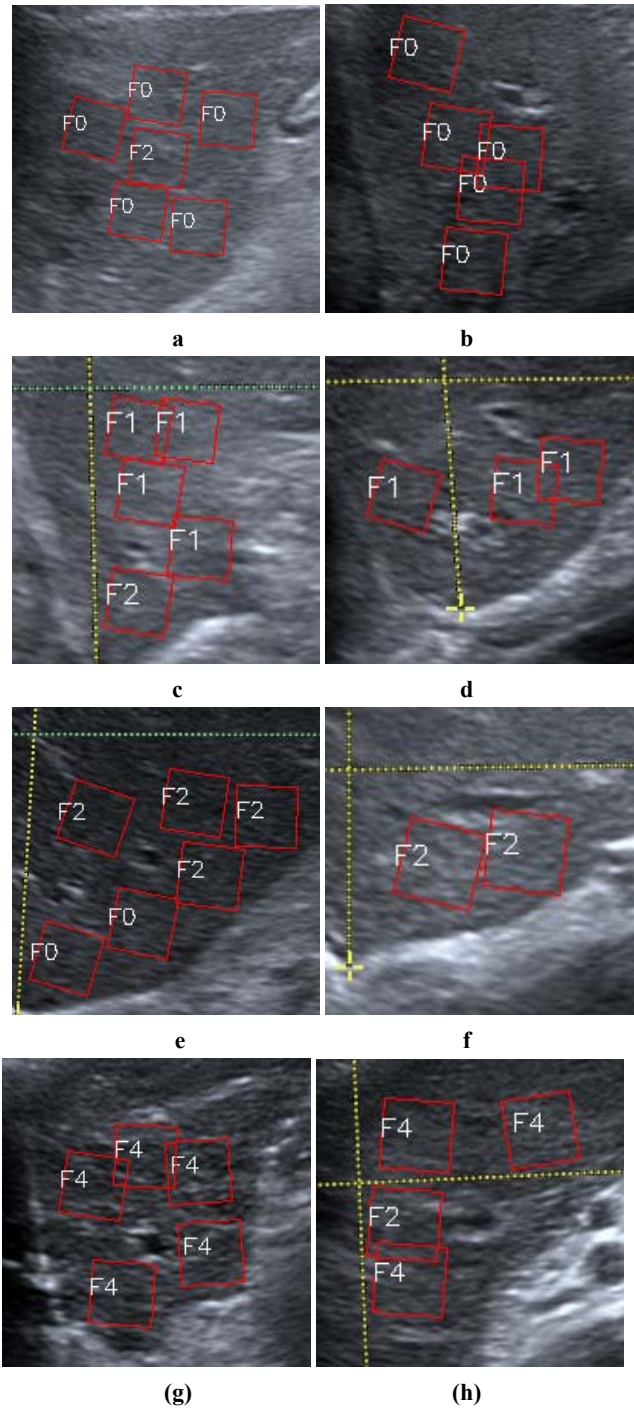


Рис. 3. Примеры тестирования алгоритма. Реальные стадии фиброза: a, b – $F0$, c, d – $F1$, e, f – $F2$, g, h – $F4$

В качестве итогового результата классификации каждого изображения выбирался класс с наибольшим количеством ROI, за него проголосовавших.

Из результатов тестирования (рис.3) можно сделать вывод, что в подавляющем большинстве случаев классификация проводится верно. Предположительно, причиной встречаю-

шихся ошибок классификации является относительно малый объём обучающей выборки и недостаточно эффективная настройка методов обучения.

7. ЗАКЛЮЧЕНИЕ

В статье предложен алгоритм, определяющий стадию фиброза по ультразвуковому изображению печени. Указанный алгоритм был проверен на базе данных пациентов с подтверждённой стадией фиброза. Точность классификации отдельных фрагментов текстуры достигает 72.7%. При обучении и тестировании на данных разных пациентов алгоритм в большинстве случаев правильно определил стадию фиброза.

8. БЛАГОДАРНОСТИ

Работа выполнена при поддержке гранта РФФИ 14-11-00308.

9. ССЫЛКИ

- [1] Virmani J. et al. Prediction of cirrhosis from liver ultrasound B-mode images based on Laws' masks analysis //Image Information Processing (ICIP), 2011 International Conference on. – IEEE, 2011. – С. 1 - 5.
- [2] Гаврилов А.В., Камалов Ю.Р., Парусников А.В., Сандриков В.А., Лопаткина Т.Н., Калайдзидис Я.Л. Первый опыт компьютерного анализа ультразвуковой текстуры паренхимы печени при распознавании ее некоторых диффузных заболеваний // Клиническая физиология, 1998. – С. 128 – 136.
- [3] Cao G., Shi P., Hu B. Liver fibrosis identification based on ultrasound images captured under varied imaging protocols //Journal of Zhejiang University. Science. B. – 2005. – Т. 6. – №. 11. – С. 1107.
- [4] Selvarajah S., Kodituwakku S. R. Analysis and comparison of texture features for content based image retrieval //International Journal of Latest Trends in Computing. – 2011. – Т. 2. – №. 1.
- [5] Хвостиков А.В. Обработка текстовых изображений с использованием матрицы смежности // Труды 15-й международной конференции «Цифровая обработка сигналов и её применение» (DSPA'2013). Т. 2. – С. 41 - 43.
- [6] Xu D. H. et al. Run-length encoding for volumetric texture //Heart. – 2004. – Т. 27. – С. 25.
- [7] Bouckaert R. R. et al. WEKA Manual for Version 3-7-11, 2014.
- [8] Witten I. H., Frank E. Data Mining: Practical machine learning tools and techniques. – Morgan Kaufmann, 2005.
- [9] Cleary J. G. et al. K*: An Instance-based Learner Using an Entropic Distance Measure //ICML. – 1995. – С. 108 - 114.
- [10] Breiman L. Random forests //Machine learning. – 2001. – Т. 45. – №. 1. – С. 5 - 32.
- [11] Rodriguez J. J., Kuncheva L. I., Alonso C. J. Rotation forest: A new classifier ensemble method //Pattern Analysis and Machine Intelligence, IEEE Transactions on. – 2006. – Т. 28. – №. 10. – С. 1619 - 1630.
- [12] Hall M. A. *Correlation-based feature selection for machine learning*: дис. – The University of Waikato, 1999.

Об авторах

Хвостиков Александр – студент факультета ВМК МГУ.

Email: xubiker@gmail.com

Крылов Андрей – проф., д. ф.-м. н., заведующий лабораторией математических методов обработки изображений факультета ВМК МГУ.

Email: kryl@cs.msu.ru

Камалов Юлий – проф., д.м.н., руководитель лаборатории ультразвуковой диагностики РНЦХ им. Петровского РАМН.

Email: kamalov53@yandex.ru

Abstract

In this work, a comprehensive method of texture analysis of B-mode ultrasound images for the determination of the liver fibrosis stage is reported. The algorithm is based on the use of Rotation Forest and KNN classifiers for the texture characteristics. 720 textural characteristics were extracted using methods based on Laws' masks analysis, Co-occurrence Matrix, Gray Level Run Length Matrix and statistical characteristics of the images. An optimal subset of 22 essential features was selected using correlation-based method. Testing the algorithm with liver images of 57 patients divided into 5 stages of fibrosis showed 72.7% classification accuracy for separate regions of interest. Using the entire image classification method the algorithm correctly identified fibrosis stage in the vast majority of cases.

Keywords: texture analysis, ultrasound images, liver fibrosis, classification algorithms