

М. В. Привалов, Ю. А. Скобцов, А. Г. Кудряшов

**ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ МЕТОДОВ КЛАССИФИКАЦИИ ДЛЯ СЕГМЕНТАЦИИ
КОМПЬЮТЕРНЫХ ТОМОГРАММ**

Введение. Во всём мире, а особенно в промышленных регионах нашей страны, с каждым годом усложняющаяся экологическая ситуация привела к росту количества онкологических заболеваний среди населения. При этом оценка состояния онкологического больного, от которой зависит принятие решения об оперативном лечении, имеет зачастую первостепенную важность. Особую важность имеет выбор стратегии лечения больных, у которых заболевание находится на последней стадии. Исследования [1] показывают, что выполнение операции в одних случаях продлевает жизнь пациенту, а в других – приводит просто к ухудшению качества его жизни или даже к сокращению её срока. Статистика, накопленная в результате операций, показывает, что информация для принятия решения о выборе стратегии лечения может дать соотношение объёма метастатических опухолей к объёму первичной опухоли. При этом объективность и точность выполнения этой оценки во многом определяет качество и продолжительность жизни пациента.

Для диагностики пациентов в больницах, а также в диагностических и противоопухолевых центрах широко используется компьютерная томография (КТ). Обследование человека с применением компьютерного томографа представляет собой получение серии срезов – изображений, полученных методом рентгенографии с помощью одного или нескольких рентгеновских излучателей и массива датчиков. Компьютерная томография внутренних органов человека завоевала свою популярность благодаря информативности, довольно низкой инвазивности и достаточной скорости обследования. При этом большинство современных томографов, имеющихся в медицинских учреждениях, оснащены программным обеспечением, позволяющим выполнять элементарные операции по обработке изображений, по визуализации объектов при обследованиях с применением контрастного вещества. Однако анализ предоставляемых функций показал, что количественная оценка формы и объёма объектов не производится. Такая функция отсутствует даже в программном обеспечении современных томографов известных фирм-производителей, таких как Siemens и General Electric, которыми оснащены крупные лечебные учреждения. При этом данные операции могут выполняться автоматически, и могут быть реализованы на уровне КТ-аппарата либо автоматизированного рабочего места врача. Чтобы получить требуемую для диагностики оценку объёмов первичной и метастатической опухолей необходимо, в первую очередь, выделить эти новообразования и построить их трёхмерные геометрические модели. Для построения трёхмерной модели первичной опухоли с целью дальнейшей оценки её объёма необходимо иметь векторные геометрические модели всех проекций исследуемого объекта на каждый срез. Поэтому первостепенной задачей, которую необходимо решить, является сегментация срезов с целью выделения на каждом из них опухоли и определения координат точек её контура.

Анализ исследований и публикаций по теме. Задача сегментации изображений, полученных методом компьютерной томографии (далее по тексту КТ-изображений), посвящено множество статей, научных работ и книг, а также проведено большое количество исследований. Имеется множество разработок, основанных на градиентных методах с пороговым ограничением, чаще всего встречаются работы, основанные на методе водораздела [2], на использовании деформационных моделей [3], в частности, методе активных контуров.

Однако все эти методы учитывают только способность тканей поглощать рентгеновское излучение, так как они основаны на анализе яркости точек изображения. При этом они очень чувствительны к контрасту и не учитывают отличия в структуре тканей, которые могут быть полезны для отделения на изображении опухоли от здоровых тканей органа при частичном замещении или от других органов. Несмотря на то, что с их помощью можно найти границу объекта, автоматический поиск опухоли на изображении невозможен, так в результате будут выделены границы всех объектов, которые отличаются от фона.

Во многих работах показано, что отличия в структуре тканей приводят к изменению текстуры на их изображении. Из этого следует, что для выполнения сегментации изображения с учетом видоизмененной структуры тканей необходимо использовать текстурные признаки. Такой подход будет актуален для КТ-изображений, полученных в результате диагностики без введения контрастного вещества.

В настоящее время существует достаточно много методов расчёта признаков текстуры. Многие из них основаны на статистическом подходе [4], [5] либо на анализе изображения в частотной области [6], [7] с помощью математического аппарата Фурье или вейвлет-преобразования. При этом многие довольно чувствительны к размеру используемого окна, а те, что основаны на преобразовании Фурье к тому же недостаточно хорошо отражают локальные особенности текстуры изображения. Как показано в [7] вейвлет-анализ позволяет хорошо учитывать локальные особенности изображения, поэтому сегментация

КТ-изображений может быть достаточно эффективно выполнена с его помощью.

Как показано в работе [8], это действительно так, однако имеется ряд трудностей, связанных с невозможностью учесть влияние признаков на конечный результат из-за примененного классификатора с Евклидовой метрикой. Предложенными путями устранения указанных недостатков являются применение более совершенных методов классификации, поиск работающего наилучшим образом материнского вейвлета, а также определение оптимального пространства признаков.

Постановка задачи. Результат вейвлет-преобразования может зависеть от того, насколько удачно выбран материнский вейвлет и тип преобразования, но при этом результат классификации также сильно зависит от применяемого классификатора. Одним из эффективных современных методов классификации, которые могут быть применены для сегментации КТ-срезов, являются нейронные сети. Они имеют разные архитектуры и назначение. Таким образом, для выполнения сегментации требуется решить следующие задачи: выбрать базисный вейвлет и тип преобразования, выбрать архитектуру нейронной сети, которая позволит наиболее точно выполнять классификацию текстур и с целью сегментации изображения. Для этого следует:

- выбрать тип преобразования;
- определить параметры преобразования, такие как материнский вейвлет, размер апертуры и требуемое количество уровней разложения;
- определить множество признаков текстуры для выполнения классификации;
- предложить несколько вариантов нейросетевых классификаторов, с помощью которых предполагается выполнять определение текстур;
- обучить классификаторы и оценить для каждого из них эффективность сегментации тестовых изображений.

Метод решения задачи. Существует несколько видов вейвлет-преобразования: непрерывное, дискретное, диадное (dyadic) и пакетное преобразование. Каждый вид преобразования имеет ряд особенностей, определяющих его область применения. Диадное вейвлет-преобразование, впервые предложенное Маллатом [9], является более быстрым вариантом дискретного преобразования и может быть применено для анализа изображений. Как показано в работе [7] алгоритм вычисления диадного вейвлет-преобразования, предложенный Маллатом может применяться для поиска границ объектов на изображении. При этом на каждом шаге алгоритма вейвлет-преобразование применяется отдельно к строкам и столбцам изображения, по аналогии с вычислением градиента в вертикальном и горизонтальном направлении. В результате будут получены два отфильтрованных изображения $W_s^1 f(x, y)$ и $W_s^2 f(x, y)$, по которым можно рассчитать пространство модулей преобразования

$$M_s f(x, y) = \sqrt{|W_s^1 f(x, y)|^2 + |W_s^2 f(x, y)|^2} \quad (1)$$

и пространство фаз

$$\Theta_s f(x, y) = \arctg \frac{W_s^2 f(x, y)}{W_s^1 f(x, y)}. \quad (2)$$

Согласно [7], точку считают принадлежащей границе объекта, если соответствующее ей значение из пространства модулей больше двух других значений в направлении градиента, которое можно определить исходя из рассчитанного пространства фаз (2).

В [8] проведено исследование возможности применения данного метода к сегментации КТ изображений. Явным недостатком такого подхода является то, что он выявляет не все перепады, а только имеющие высокую амплитуду. В результате граница двух достаточно близких по яркости областей будет потеряна. Для преодоления такого недостатка достаточно обрабатывать не всё изображение, а только область интереса, которую укажет врач. В этом случае предлагаемый способ определения контуров гораздо более эффективен, чем известные градиентные методы, так как ложных контуров будет гораздо меньше. Однако он все же не дает хороших результатов в случаях, когда опухоль частично замещает или вытесняет здоровые ткани, которые незначительно отличаются по плотности, но имеют другую структуру. А так как он не может обеспечивать сегментацию в полностью автоматическом режиме, можно сделать вывод, что для сегментации необходимо задействовать дополнительные признаки.

На основании вышесказанного предлагается использовать для вычисления признаков текстуры два первых уровня вейвлет-разложения исходного изображения. Такое количество выбрано, так как в работе [11] показано, что дальнейшее увеличение количества уровней разложения нецелесообразно в виду незначительного вклада энергий высокочастотных составляющих в признаки текстуры. Таким образом, схема выполнения преобразования исходного изображения будет иметь вид, показанный на рис. 1.




Рис. 1 – Схема выполнения вейвлет-преобразования исходного изображения для расчета признаков текстуры.

На рисунке A_i – низкочастотное пространство разложения, H_i , V_i , D_i – соответственно, горизонтальное, вертикальное и диагональное пространство деталей.

Для вычисления признаков предлагается на начальном этапе рассчитать энергии пространств вейвлет-сигнатур (3), полученных в результате двумерного дискретного преобразования

$$S_i^k = \frac{1}{M^2} \sum_{x=1}^M \sum_{y=1}^M |W_i^k f(x,y)|, \quad (3)$$

где $W_i^k f(x,y)$ - k -е пространство, полученное на i -м уровне разложения. Индекс k определяет, какое из пространств A , H , V или D будет использовано в расчётах. M – размер апертуры.

Уже на основании полученных энергий рассчитываются признаки текстуры изображения. В работе предлагается использовать набор из 9 признаков.

1) Отношение энергии низкочастотного пространства $W_2^1 f$ к сумме энергий высокочастотных пространств $W_1^2 f$, $W_1^3 f$, $W_1^4 f$, $W_2^2 f$, $W_2^3 f$ и $W_2^4 f$:

$$F_1 = \frac{S_2^1}{S_1^2 + S_1^3 + S_1^4 + S_2^2 + S_2^3 + S_2^4}. \quad (4)$$

2) Оценка математического ожидания диагональных высокочастотных пространств $W_1^4 f$ и $W_2^4 f$

$$F_2 = \frac{1}{M^2} \sum_{x=1}^M \sum_{y=1}^M W_1^4 f(x,y), \quad F_3 = \frac{1}{M^2} \sum_{x=1}^M \sum_{y=1}^M W_2^4 f(x,y). \quad (5)$$

3) Оценка дисперсии диагональных высокочастотных пространств $W_1^4 f$ и $W_2^4 f$

$$F_4 = \frac{1}{M^2} \sum_{x=1}^M \sum_{y=1}^M (W_1^4 f(x,y) - F_2)^2, \quad F_5 = \frac{1}{M^2} \sum_{x=1}^M \sum_{y=1}^M (W_2^4 f(x,y) - F_3)^2. \quad (6)$$

4) Оценка Энтропии Шеннона горизонтального и вертикального высокочастотных пространств разложения первого уровня. Так как все вычисления после преобразования исходного изображения производились с вещественными числами, то вместо энтропии использовалась её оценка, вычисляемая по формуле (7):

$$F_6 = -\sum_{x=1}^M \sum_{y=1}^M W_1^2 f(x,y)^2 \log(W_1^2 f(x,y)^2), \quad F_7 = -\sum_{x=1}^M \sum_{y=1}^M W_1^3 f(x,y)^2 \log(W_1^3 f(x,y)^2). \quad (7)$$

5) Оценка математического ожидания низкочастотного пространства первого уровня разложения, $W_1^1 f$

$$F_8 = \frac{1}{M^2} \sum_{x=1}^M \sum_{y=1}^M W_1^1 f(x,y). \quad (8)$$

Признак F_8 несёт в себе информацию о средней интенсивности сплаженного изображения.

С точки зрения врача-диагноста большое количество информации несёт в себе плотность ткани, так как плотность органов колеблется в очень небольших пределах, а выделение границ проекции метастатических опухолей вообще может быть проведено на основании яркости. Поэтому к набору признаков добавлена средняя яркость пикселей в апертуре.

б) Средняя яркость пикселей в апертуре

$$F_9 = \frac{1}{M^2} \sum_{x=1}^M \sum_{y=1}^M f(x, y). \quad (9)$$

Для классификации текстуры по заданным признакам предлагается исследовать нейронные сети с архитектурами, эффективно применяющимися для классификации. К ним относят перцептрон, сеть прямого распространения, рекуррентную сеть Элмана. Выбор именно нейросетевого классификатора обусловлен результатами, полученными в работе [8], где показано, что данный набор, во-первых, является избыточным, а, во-вторых, признаки в различной мере влияют на результат, поэтому необходимо как минимум выполнить взвешивание этих признаков. А, как известно, модель формального нейрона автоматически обеспечивает взвешивание признаков, подаваемых в виде входных векторов. Для выполнения дискретного преобразования, а также для анализа текстуры часто применяют вейвлеты Добеши, волны Хаара, койфлеты и биортогональные фильтры. Таким образом, необходимо провести экспериментальные исследования качества сегментации с использованием указанных выше нейронных сетей и преобразования на основании перечисленных материнских вейвлетов.

Экспериментальные исследования и анализ результатов. Сегментация КТ-изображений с использованием предложенных признаков производилась следующим образом. Отобраны три серии изображений, 131, 42 и 132 снимка, полученные из урологического отделения Донецкого областного противоопухолевого центра и из Института неотложной и восстановительной хирургии АМН Украины им. В.К. Гусака. Исходная информация хранится в формате DICOM, при этом изображения имеют 2054 градации яркости и размер 512x512 пикселей. Для каждого изображения вычислялось дискретное двумерное вейвлет-преобразование с использованием заданного материнского вейвлета и апертуры размером 32x32 пикселя. Пример исходного изображения показан на рис. 2.




Рис. 2 – Пример исходного КТ-изображения

Для формирования обучающей выборки производился расчёт признаков по формулам (3)-(9) для области изображения, которую врач-эксперт выделил на срезе как принадлежащую проекции опухоли, заместившей почку пациента. Таким образом, для каждой точки этой области было получено множество значений признаков $\{F_1, F_2, \dots, F_9\}$. Аналогичный набор признаков был рассчитан для областей, не принадлежащих опухоли. Объем выборки составил по 50 апертур для каждого случая. Так был сформирован набор обучающих входных векторов. Выход кодировался множеством $\{0, 1\}$, где нулевое значение соответствует тканям, которые не являются опухолью, а 1 – опухоли. В итоге получен обучающий набор данных, состоящий из входной матрицы 9x100 (100 векторов по 9 признакам) и выходной 1x100 (100 векторов по 1 значению).

Для исследования влияния материнского вейвлета на результат классификации при проведении экспериментов выполнение вейвлет-преобразования при расчёте множества признаков текстуры осуществлялось с использованием вейвлетов Добеши D^4 , волн Хаара, койфлетов, биортогональных фильтров.

На полученном наборе признаков обучались нейронные сети со следующими архитектурами: прямоточные сети с сигмоидальной активационной функцией выходного слоя и с сигмоидальным гиперболическим тангенсом, сеть Элмана, однослойный и многослойный перцептрон. Более подробные данные об архитектуре исследованных нейронных сетей представлены в таблице.

При обучении для оценки производительности нейронной сети использовалась суммарно-квадратичная функция оценки ошибки (SSE), максимальное число эпох обучения было ограничено значением 5000, целевая ошибка была принята равной 0.1.

Таблица

Архитектура исследованных нейросетевых классификаторов

Архитектура сети	Число нейронов в ассоц. слое	Акт. функция ассоц. слоя	Акт. функция выходного слоя	Функция обучения
Однослойный персептрон	-	-	Пороговое ограничение	Градиентное обратное распространение
Многослойный персептрон	20	Логистическая сигмоидальная	Линейная	Градиентное обратное распространение
Сеть прямого распространения	20	Логистическая сигмоидальная	Логистическая сигмоидальная	Левенберга-Марквардта
Сеть прямого распространения	20	Логистическая сигмоидальная	Сигмоидальный гиперболический тангенс	Левенберга-Марквардта
Сеть Элмана	20	Сигмоидальный гиперболический тангенс	Линейная	Градиентное обратное распространение

После выполнения обучения нейронной сети выполнялся расчёт признаков для тестового изображения и его дальнейшая сегментация с помощью каждой исследуемой нейронной сети. Результаты сегментации показаны ниже на рис. 3.




Рис. 3 – Результаты сегментации тестового изображения а) сетью Элмана; б) сетью прямого распространения с логистической активационной функцией на выходе; в) сетью прямого распространения с гиперболическим тангенсом в входном слое; г) многослойным персептроном; д) персептроном. Сверху вниз базисные функции: биортогональные фильтры, койфлеты, волны Хаара, вейвлеты Добеши D^4 .

На рис. 3 не показаны результат сегментации с помощью однослойного персептрона для биортогональных фильтров и вейвлетов D^4 , так как в данном случае они оказались настолько плохими, что на бинарном изображении не были даже выделены внутренние органы, либо все пиксели изображения оказались отнесёнными к фону.

Анализ результатов эксперимента показал, что сегментация с использованием рекуррентной нейронной сети Элмана (рис. 3а) сформировала бинарные изображения, на котором помимо искомой опухоли выделены объекты, расположенные рядом. Такой результат является неудовлетворительным, так как по нему невозможно выделить контур опухоли. Всё сказанное выше также касается работы многослойного персептрона (рис. 3г). Сегментация с помощью сети прямого распространения с сигмоидальным гиперболическим тангенсом в качестве активационной функции выходного слоя позволила получить бинарные изображения (рис. 3в), на которых уже выделена опухоль, заместившая почку. Однако оказались захваченными соседние органы, отмечен позвоночник и часть здоровой почки.

Лучший результат в данном эксперименте показала сеть прямого распространения с логистической активационной функцией выходного слоя. Как видно из рис. 3б, опухоль выделена, при этом, несмотря на то, что отмечен позвоночник и часть здоровой почки, объекты не слиты вместе, форма области, соответствующей опухоли, близка к ней по размеру и форме

Использование признаков, вычисленных с использованием различных базисных вейвлетов, показало, что лучшие результаты достигаются с применением волн Хаара и вейвлетов Добеши.

Выводы. В работе рассмотрен способ сегментации КТ-изображений, основанный на классификации точек среза с использованием признаков текстуры, рассчитанных по результатам двух уровней вейвлет-разложения фрагмента изображения в окрестности. Предложен и экспериментально исследован набор из девяти признаков текстуры для классификации пикселей. Показано, что на основании предлагаемого набора возможно выделение изображения проекции органа или образования с помощью нейросетевого классификатора. В результате исследования нескольких нейросетевых классификаторов показано, что наилучшие результаты были получены с помощью сети прямого распространения с логистической активационной функцией в выходном слое и вейвлетов Хаара и D^4 .

На основании экспериментально полученных данных выяснено, что уточнённый результат является удовлетворительным, но может использоваться для построения 3D-моделей первичных опухолей и дальнейшей оценки их объёма только после удаления лишних объектов, что является направлением дальнейших исследований.

ЛИТЕРАТУРА:

1. Бондарь Г. В., Кудряшов А. Г., Борота А. В., Анищенко А. А., Осипенков Р. А. Расширение показаний к оперативному лечению больных раком почки // 5 съезд онкологов и радиологов СНГ. Материалы съезда. 14-16 мая 2008г. Ташкент. – С. 358.
2. Pil Un Kim, Yun jung Lee, Youngjin Jung, Jin Ho Cho, Myoung Nam Kim, Liver extraction in the abdominal CT image by watershed segmentation algorithm // World Congress on Medical Physics and Biomedical Engineering 2006: IFMBE Proc. – 2007. – Vol. 14. – pp. 2563-2566.
3. M.S. Atkins and B. Mackiewicz. Automatic Segmentation of the Brain in MRI. Conference on Visualisation in Biomedical Computing 96, Springer-Verlag Lecture Notes in Computer Science, 1131:210-216, Sept. 1996.
4. Haralick R.M., Shanmugan K., Dinstein I.H. Texture features for image classification // IEEE Trans. Syst., Man, Cyber. – 1973. – Vol. SMC-3. – P. 610.
5. Atam P.D., Yateen C., Kaiser-Bonasso C. Analysis of Mammographic Microcalcifications Using Grey-Level Image Structure Features // IEEE Trans. on Medical Imaging. – 1996. – Vol. 15, № 3. – P. 2.
6. Chang T., Jay Kuo C.-C. Texture analysis and classification with tree-structured wavelet transform. // UCS-SIPI Report #198. – 1992. – 75.
7. Jun Li A Wavelet Approach to Edge Detection // Thesis of the degree of Master of Science in the subject of Mathematics. - Sam Houston State University, Huntsville, Texas – 2003. – 80 p.
8. М.В. Привалов, Ю.А. Скобцов, А.Г. Кудряшов «Сегментация компьютерных томограмм на основе вейвлет-преобразования» // Вестник Херсонского государственного технического университета. – Херсон: ХГТУ. – 2009.
9. S. Mallat, S. Zhong, 1992, “Characterization of signals from multiscale edges,” IEEE Trans. Pattern Anal. Machine Intell., vol.14, no.7, P. 710-732.
10. Давыдов А. В. Вейвлетные преобразования сигналов. Курс лекций. Электронный источник. URL: <http://prodav.narod.ru/wavelet/>
11. S. Mallat, A Theory for Multiresolution Signal Decomposition: The Wavelet Representation, IEEE Trans. on PAMI. – 1989. – Vol. 11, No. 7. – P. 674-693.