

СЕГМЕНТАЦИЯ АНОМАЛЬНЫХ ОБЛАСТЕЙ НА МУЛЬТИСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЯХ ШЕЙКИ МАТКИ

Катерина Малышевская

Аннотация: В работе представлена сегментация мультиспектральных изображений шейки матки. Представлена сеть Кохонена для сегментации изображений и коротко изложена ее суть. Приведены результаты работы, сделан анализ полученных результатов и выводы относительно проведенной работы.

Ключевые слова: сегментация, сеть Кохонена, шейка матки, диагностика.

ACM Classification Keywords: I.5.1 Pattern Recognition - Neural nets

Аннотация: В работе представлена сегментация мультиспектральных изображений шейки матки. Представлена сеть Кохонена для сегментации изображений и коротко изложена ее суть. Приведены результаты работы, сделан анализ полученных результатов и выводы относительно проведенной работы.

Conference: The paper is selected from XVth International Conference “Knowledge-Dialogue-Solution” KDS-2 2009, Kyiv, Ukraine, October, 2009.

Введение

В данной работе рассмотрена возможность сегментации мультиспектрального изображения шейки матки. Такая задача продиктована необходимостью ранней диагностики заболевания с использованием компьютерной системы, которая поможет врачу определить области с большим риском возникновения раковой трансформации ткани. Данная система базируется на утверждении, что оптические свойства здоровой клетки отличаются от свойств больной и это отличие более выражено, чем отличия клеток разных людей. В качестве исходных данных в данной работе мы имеем информацию о 206 пациентках, прошедших диагностику в клинике при помощи новой оптической системы, внедренной в медицинском университете Аризоны (США). Параллельно врач ставил диагноз пациенткам путем классификации типов тканей, взятых на биопсию. Участки, из которых была сделана биопсия, были обозначены на снимке, и результаты биопсии были сопоставлены с указанными участками на изображении [Schoonmaker J. 2007]. Данные о каждой пациентке хранятся в отдельном файле формата MATLAB

Постановка задачи

Существуют следующие аномальные области: SEA (squamous epithelial abnormalities) - доброкачественные изменения плоского эпителия, койлоциты без изменений, позволяющих предположить CIN, Squamous cell changes - изменения плоского эпителия без четких признаков опухоли, CIN-I - дисплазия легкой степени, CIN-II - дисплазия умеренной степени, CIN-III - интраэпителиальная неоплазия тяжелой степени, понятие объединяет тяжелую дисплазию и внутриэпителиальный рак (CIS - carcinoma in situ), рак, подозрительный на инвазию, инвазивный плоскоклеточный рак. [Koss L.G. 1989] Для создания системы, которая поможет распознавать эти аномальные области, на первом этапе необходимо провести сегментацию изображения. Далее, для того чтобы определить тип ткани в каждом сегменте, необходимо классифицировать каждый сегмент используя базу данных содержащую образцы различных тканей полученных по результатам биопсий. В работе [Schoonmaker J. 2007] была проведена классификация

типов тканей по пикселям. Формулы для классификации подбирались эмпирическим путем. Но с увеличением базы пациентов подобранные таким образом формулы могут работать некорректно. Задачей этой работы является автоматизировать работу системы распознавания аномальных областей и приспособить ее для работы с новыми изображениями. Для сегментации изображений используются Карты Кохонена. Использование этой сети обусловлено желанием избежать влияния человеческого фактора при работе с изображениями.

Исходные данные

Технология, с помощью которой были получены электронные изображения тканей, называется «Квадропризменное апертурное разделение» ("Quad-prism Aperture-Splitting", QPAS). Данная технология способна одновременно разделять свет отдельных длин волн и/или поляризаций, фильтровать каждый и затем перепроецировать на отдельные квадранты электронного оптического сенсора. QPAS оснащена четырьмя наборами фильтров, которые собирают:

1. Четыре диапазона отраженного поляризованного света с поляризатором, параллельным источнику света.
2. Четыре диапазона отраженного поляризованного света с поляризатором, перпендикулярным источнику света.
3. Восемь диапазонов флуоресценции, используя источник с длиной волны 365 нм (два набора фильтров).

Таким образом, мы собираем 16 каналов данных, которые и будут использоваться для классификации тканей.

Методы

Для сегментации изображений была разработана программа, в которой использовались готовые библиотеки. Приложения с усеченной Гауссовой и колоколообразной функциями соседства были разработаны самостоятельно для проверки их эффективности.

Карты Кохонена Сети, называемые картами Кохонена, - это нейронные сети которые используют неконтролируемое обучение. Обучающее множество состоит лишь из значений входных переменных, в процессе обучения нет сравнения выходов нейронов с эталонными значениями. Можно сказать, что такая сеть учится понимать структуру данных. Идея сети Кохонена принадлежит финскому ученому Тойво Кохонену (1982 год). Основной принцип работы сетей - введение в правило обучения нейрона информации относительно его расположения [Зайченко Ю.П. 2004].

Самоорганизующаяся сеть подразумевает использование упорядоченной структуры нейронов. Обычно используются одно и двумерные сетки. При этом каждый нейрон представляет собой n -мерный вектор-столбец $w = [w_1, w_2, \dots, w_n]^T$, где n определяется размерностью исходного пространства (размерностью входных векторов), w_i - вес i -го нейрона. Применение одно и двумерных сеток связано с тем, что возникают проблемы при отображении пространственных структур большей размерности.

Обычно нейроны располагаются в узлах двумерной сетки с прямоугольными или шестиугольными ячейками. При этом, как было сказано выше, нейроны также взаимодействуют друг с другом. Величина этого взаимодействия определяется расстоянием между нейронами на карте. На рисунке 1 дан пример расстояния для шестиугольной и четырехугольной сеток.

При этом легко заметить, что для шестиугольной сетки расстояние между нейронами больше совпадает с евклидовым расстоянием, чем для четырехугольной сетки.

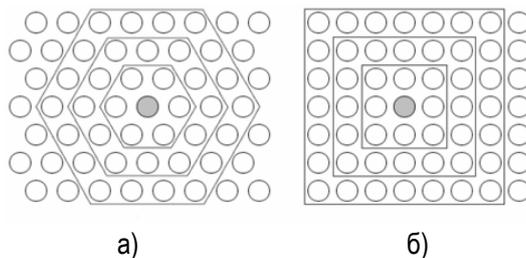


Рис.1. Расстояние между нейронами на карте для шестиугольной (а) и четырехугольной (б) сеток.

При этом количество нейронов в сетке определяет степень детализации результата работы алгоритма, и в конечном счете от этого зависит точность обобщающей способности карты.

Начальная инициализация карты. При реализации алгоритма сети заранее задается конфигурация сетки (прямоугольная или шестиугольная), а также количество нейронов в сети. Некоторые источники рекомендуют использовать максимально возможное количество нейронов в карте. При этом начальный радиус обучения (*neighborhood* в англоязычной литературе) в значительной степени влияет на способность обобщения при помощи полученной карты. В случае, когда количество узлов карты превышает количество примеров в обучающей выборке, то успех использования алгоритма в большой степени зависит от подходящего выбора начального радиуса обучения. Однако, в случае, когда размер карты составляет десятки тысяч нейронов, время, требуемое на обучение карты, обычно бывает слишком велико для решения практических задач. Таким образом необходимо достигать допустимого компромисса при выборе количества узлов.

Перед началом обучения карты необходимо проинициализировать весовые коэффициенты нейронов. Удачно выбранный способ инициализации может существенно ускорить обучение и привести к получению более качественных результатов. Существуют три способа инициирования начальных весов.

Инициализация случайными значениями, когда всем весам даются малые случайные величины.

Инициализация примерами, когда в качестве начальных значений задаются значения случайно выбранных примеров из обучающей выборки

Линейная инициализация. В этом случае веса иницируются значениями векторов, линейно упорядоченных вдоль линейного подпространства, проходящего между двумя главными собственными векторами исходного набора данных. Собственные вектора могут быть найдены, например, при помощи процедуры Грама-Шмидта.

Обучение. Обучение состоит из последовательности коррекций векторов, представляющих собой нейроны. На каждом шаге обучения из исходного набора данных случайно выбирается один из векторов, а затем производится поиск наиболее похожего на него вектора коэффициентов нейронов. При этом выбирается нейрон-победитель, который наиболее похож на вектор входов. Под похожестью в данной задаче понимается расстояние между векторами, обычно вычисляемое в евклидовом пространстве.

Таким образом, если обозначить нейрон-победитель как c , то получим $|x - w_c| = \min_i \{\|x - w_i\|\}$, w_i – вес i -го нейрона.

После того, как найден нейрон-победитель производится корректировка весов нейросети. При этом вектор, описывающий нейрон-победитель и вектора, описывающие его соседей в сетке, перемещаются в направлении входного вектора.

При этом для модификации весовых коэффициентов используется формула:

$$w_i(t+1) = w_i(t) + h_{ci}(t) * [x(t) - w(t)]$$

где t обозначает номер эпохи (дискретное время). При этом вектор $x(t)$ выбирается случайно из обучающей выборки на итерации t , w_i – вес i -го нейрона. Функция $h(t)$ называется функцией соседства нейронов. Эта функция представляет собой невозрастающую функцию от времени и расстояния между

нейроном-победителем и соседними нейронами в сетке. Эта функция разбивается на две части: собственно функцию расстояния и функции скорости обучения от времени. где r определяет положение нейрона в сетке.

Обычно применяются такие функции: Гауссова функция $h(d,t) = e^{-\frac{d^2}{2\sigma^2(t)}}$, также могут использоваться

усеченная Гауссова $h(d,t) = e^{-\frac{d^2}{2\sigma^2(t)}} 1(\sigma(t) - d)$ и колоколообразная $h(d,t) = 1(\sigma(t) - d)$, $\sigma(t)$ – радиус функции соседства в период времени t , а d – расстояние между нейронами сетки. [Kohonen T. 1997].

При этом, как показали дальнейшие эксперименты, лучший результат получается при использовании Гауссовой функции расстояния. При этом является убывающей функцией от времени. Часто эту величину называют радиусом обучения, который выбирается достаточно большим на начальном этапе обучения и постепенно уменьшается так, что в конечном итоге обучается один нейрон-победитель. Наиболее часто используется функция, линейно убывающая от времени.

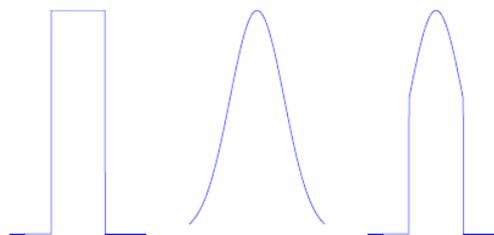


Рис. 2

Рассмотрим теперь функцию скорости обучения $a(t)$. Эта функция также представляет собой функцию, убывающую от времени. Наиболее часто используются два варианта этой функции: линейная и обратно пропорциональная времени – вида $a(t) = \frac{A}{t+B}$ где A и B это константы, t - время. Применение этой функции приводит к тому, что все вектора из обучающей выборки вносят примерно равный вклад в результат обучения.

Обучение состоит из двух основных фаз: на первоначальном этапе выбирается достаточно большое значение скорости обучения и радиуса обучения, что позволяет расположить вектора нейронов в соответствии с распределением примеров в выборке, а затем производится точная подстройка весов, когда значения параметров скорости обучения много меньше начальных. В случае использования линейной инициализации первоначальный этап грубой подстройки может быть пропущен [Стариков А. 2000].

Применение алгоритма. Данную методику можно использовать для поиска и анализа закономерностей в исходных данных. При этом, после того, как нейроны размещены на карте, полученная карта может быть отображена разными цветами.

Результаты сегментации

Ниже приведены результаты сегментации используя различные функции. Различные сегменты выделены разными оттенками серого.

По изображениям видно, что применение всех функций дает приблизительно одинаковый результат, поэтому в дальнейшем будет использоваться только Гауссова функция принадлежности, так как это наиболее стандартная функция.

Далее представлены результаты сегментации на различное количество кластеров 10 (Рис. 4), 20 (Рис. 5) и 50 (Рис. 6) соответственно:

Изображения были разбиты на разное количество сегментов для дальнейшей проверки по базе типов тканей. Оптимальное количество сегментов можно будет определить при дальнейшей работе, хотя уже на данном этапе видно, что 20 сегментов отображают те области, которых не видно при 10 сегментах (отличия обведены для наглядности на рис. 4 и рис. 5). И как видно на рис. 5 и рис. 6, что 20 и 50

сегментов практически не отличаются, хотя проверка 50 сегментов по базе типов тканей может занять значительно больше времени.

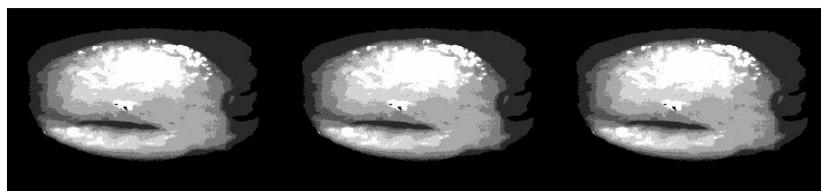


Рис. 3 Сегментация изображения, применяя Гауссову, усеченную Гауссову и колоколообразную функции

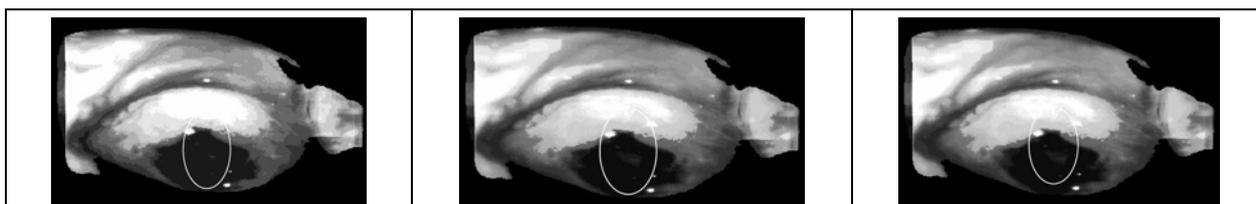


Рис. 4. 10 кластера

Рис. 5. 20 кластера

Рис. 6. 50 кластера

Выводы

- Использование сети Кохонена обусловлено намерением избежать влияния человеческого фактора при сегментации изображения.
- По результатам экспериментов видно, что использование всех функций соседства дает одинаковый результат.
- Были проведены эксперименты по разбиению на разные количества сегментов и уже на данном этапе работы видно, что использование 10 сегментов может быть недостаточным, так как не полностью отображает картину состояния органа.

Благодарности

Работа опубликована при финансовой поддержке проекта **ITHEA XXI** Института информационных теорий и приложений FOI ITHEA Болгария www.ithea.org и Ассоциации создателей и пользователей интеллектуальных систем ADUIS Украина www.aduis.com.ua.

Библиография

- [Kohonen T. 1997] "Self-Organizing Maps"(2-nd edition), Springer, 1997.
- [Koss L.G. 1989] Koss L.G. The complex test for cervical cancer detection. In: The Journal of the American Medical Association. – 1989
- [Schoonmaker J. 2007] Schoonmaker J. et al. Automatic Segmentation of Uterine Cervix for in vivo Localization and Identification of Cervical Intraepithelial Neoplasia // Apogen Technologies 2007
- [Зайченко Ю.П. 2004] Зайченко Ю.П. Основы проектування інтелектуальних систем. Навчальний посібник – К.: Видавничий Дім «Слово», 2004
- [Стариков А. 2000] BaseGroup 2000.

Информация об авторе

Катерина Мальшевская – аспирант Национальный Технический Университет Украины «Киевский Политехнический Институт», Киев, Украина, e-mail: volovik_katya@yahoo.com