

СРАВНИТЕЛЬНЫЙ АНАЛИЗ РАБОТЫ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОЦЕНКИ СОСТОЯНИЯ ТКАНЕЙ ОРГАНА ПО ИЗОБРАЖЕНИЯМ

Работа посвящена анализу эффективности работы нейронных сетей для оценки состояния тканей шейки матки по изображениям. Приведен метод диагностики, в котором нейронные сети используются для прогнозирования процентного содержания разных типов тканей на органе.

Ключевые слова: нейронные сети, сегментация, диагностика.

Введение

В данной работе рассмотрена возможность классификации типов тканей по мультиспектральному изображению шейки матки. Такая задача продиктована необходимостью ранней диагностики заболевания, используя компьютерную систему, которая поможет врачу определить области с большим риском возникновения раковой трансформации ткани.

Нами выполнена работа с изображениями, полученными при кольпоскопических тестированиях, применяя различные фильтры. В качестве исходных данных собрана информация о 185 пациентках. Каждая из них проходила кольпоскопическое обследование, и каждой была сделана биопсия в 1-4 местах. Место где была проведена биопсия отмечено на изображении. Результатом биопсии является процентное содержание эпителия. Для каждой пациентки есть 16- канальное изображение органа.[1].

Всего на шейке матки может быть 6 типов тканей. 3 из них считаются безопасными (нормальными) и присутствуют на нормальном здоровом органе. Squamous-плоский эпителий и Columnar-колойцитный, Metaplasia- доброкачественные изменения тканей. Однако, есть еще 3 типа ткани, которые являются опасными и могут быть либо предшественниками ракового заболевания, либо свидетельствовать о его наличии (CIN1 - дисплазия легкой степени, CIN2 - дисплазия умеренной степени, CIN3 - интраэпителиальная неоплазия тяжелой степени, понятие объединяет тяжелую дисплазию и внутри-эпителиальный рак)[2].

Постановка задачи

Схожие типы тканей имеют схожие оптические свойства. Отличие между разными типами тканей более существенно, чем отличие между одинаковыми тканями у разных пациентов. Таким образом, имея 16-канальные изображения можно точнее определить схожие оптические свойства тканей.

На первом этапе работы необходимо сформировать исходные данные. В месте, в котором была сделана биопсия выделяется область размером 20×20 пикселей, таким образом, захватывается текстура ткани с места, где была сделана биопсия. Для каждого случая формируем $16 \times 20 \times 20 = 6400$ входных переменных. Для уменьшения размерности данных использован МГК (который дал возможность получить 14 главных компонент которые отвечают за 95% вариаций переменных)

Затем проводится обучение нейронных сетей на полученных данных.

Далее проводится сегментация изображений при помощи самоорганизующихся карт Кохонена и алгоритма к-средних.

После сегментации изображений выделяем на каждом сегменте область 20×20 пикселей и трансформируем при помощи МГК (используя ту же матрицу трансформаций, что и на начальном этапе)

Далее проверяем каждый сегмент при помощи ранее обученных нейронных сетей.

Методы

Основные идеи метода обратного распространения ошибок.

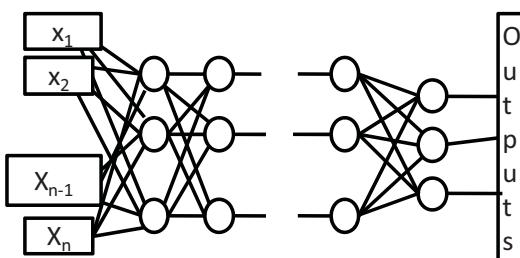


Рисунок 1 – Нейронная сеть

На рис.1 изображена нейронная сеть. У сети есть входы x_1, \dots, x_n , выходы *Outputs* и внутренние узлы. Перенумеруем все узлы (включая входы и выходы) числами от 1 до N . Обозначим через $w_{i,j}$ вес, стоящий на ребре, соединяющем i -й и j -й узлы, а через o_i — выход i -го

узла. Для m тестовых примеров с целевыми значениями выходов $\{t_k^d\}$ $d = 1..m, k \in Outputs$ функция ошибки выглядит так:

$$E(\{w_{i,j}\}) = \frac{1}{2} \sum_{d=1} \sum_{k \in Outputs} (t_k^d - o_k(x_1^d, \dots, x_n^d))^2.$$

Для модификации весов реализовывается стохастический градиентный спуск, то есть подправляются веса после каждого тестового примера. Нужно двигаться в сторону, противоположную градиенту, то есть добавлять к каждому весу $w_{i,j}$ $\Delta w_{i,j} = -\eta \frac{\partial E^d}{\partial w_{i,j}}$, где

$$E^d(\{w_{i,j}\}) = \frac{1}{2} \sum_{k \in Outputs} (t_k^d - o_k^d)^2 [3].$$

Структура RBF сети (Radial Basis Function Network)

RBF сети- сети с радиально-симметричными функциями в однослойных сетях, имеющих структуру, представленную на рисунке 2.

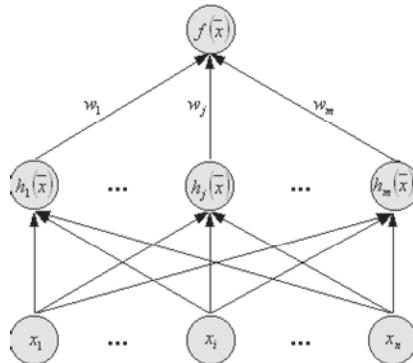


Рисунок 2 – Структура RBF сети

То есть, каждый из n компонентов входного вектора подается на вход m базисных функций и их выходы линейно суммируются с весами:

$$f(\bar{x}) = \sum_{j=1}^m w_j h_j(\bar{x})$$

Каждый нейрон скрытого слоя вычисляет гауссову функцию преобразования

$$h(\bar{x}) = \left(-\frac{\|\bar{x} - \bar{c}\|^2}{r^2} \right)$$

Таким образом, выход RBF сети является линейной комбинацией некоторого набора базисных функций:

$$f(\bar{x}) = \sum_{j=1}^m w_j h_j(\bar{x})$$

Радиально-базисная сеть характеризуется тремя особенностями:

1. Единственный скрытый слой
2. Только нейроны скрытого слоя имеют нелинейную активационную функцию
3. Синаптические веса связей входного и скрытого слоев равны единице[4].

Каскадные нейронные сети

Начинается с входного и выходного слоев, строится иерархия скрытых нейронов: Feed-forward network - n входов, m выходов, h скрытых

Нейроны скрытого слоя расположены горизонтально: входы подаются с входного слоя и со всех предшествующих скрытых нейронов и i -й нейрон имеет $n + (i-1)$ входов

Выходные нейроны связаны со всеми входами и нейронами скрытого слоя

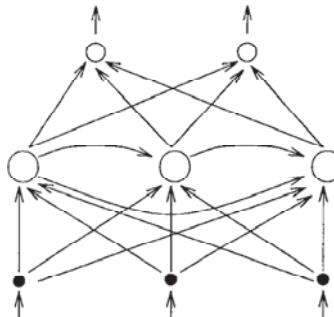


Рисунок 3 – Структура каскадной нейронной сети

Выходное значение i -го нейрона скрытого слоя:

$$z_i = \sigma \left(\sum_{j=0}^n w_{ij} x_j + \sum_{j=1}^{i-1} w_{i(n+j)} z_j \right), \text{ для } i=1 \dots h$$

выходов: $y_i = \sigma \left(\sum_{j=0}^{n+h} v_{ij} z_j \right)$, для $i=1, \dots, m$

Начинают с минимальной конфигурации сети ($h = 0$). Работа сети выполняется, пока не будет удовлетворять следующие условия:

- инициализируется набор кандидатов для нового скрытого нейрона, то есть соединить их с входными нейронами;
- адаптируются их веса для того, чтобы максимизировать корреляцию между их выходами и ошибкой нейронной сети;
- выбор лучшего кандидата и соединение его с выходами;
- адаптируются веса выходных нейронов[5].

Карты Кохонена

Сети, называемые картами Кохонена, - это нейронные сети которые используют при неконтролируемом обучении.

Самоорганизующаяся сеть подразумевает использование упорядоченной структуры нейронов. Обычно используются одно и двумерные сетки. При этом каждый нейрон представляет собой n -мерный вектор-столбец

$$w = w_1, w_2, \dots, w_n,$$

где n определяется размерностью исходного пространства (размерностью входных векторов), w_i вес i -го нейрона.

Начальная инициализация карты

1. Инициализация случайными значениями, когда всем весам даются малые случайные величины.
2. Инициализация примерами, когда в качестве начальных значений задаются значения случайно выбранных примеров из обучающей выборки
3. Линейная инициализация. В этом случае веса инициируются значениями векторов, линейно упорядоченных вдоль линейного подпространства, проходящего между двумя главными собственными векторами исходного набора данных. Собственные векторы могут быть найдены, например, при помощи процедуры Грамма-Шмидта[6].

Обучение состоит из последовательности коррекций векторов, представляющих собой нейроны. На каждом шаге обучения из исходного набора данным 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. Если обозначить нейрон-победитель как c , то вес i -го нейрона $|x - w_c| = \min\{|x - w_i|\}$.

Для модификации весовых коэффициентов используется формула:

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

где t обозначает номер эпохи . 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. Обычно применяется такие функции: Гауссова функция $h(d, t) = e^{-\frac{d^2}{2\sigma^2(t)}}$ также могут

использоваться усеченная Гауссова $h(d, t) = e^{-\frac{d^2}{2\sigma^2(t)}} \mathbf{1}(\sigma(t) - d)$ и колокообразная $h(d, t) = \begin{cases} \alpha(t), & d \leq \sigma(t) \\ 0, & d > \sigma(t) \end{cases}$, $\sigma(t)$ – радиус функции соседства в период времени t , d – расстояние между нейронами сетки, $\alpha(t)$ – темп обучения[7].

Алгоритм К-средних

Работа алгоритма изображена на рисунке 4. Работа заключается в том, чтобы минимизировать дисперсию на точках каждого кластера:

где k - число кластеров, S_i - полученные кластеры, $i=1,2,\dots,k$ и μ_i - центры масс векторов [8].

Результаты работы

В Таблице 1 приведены результаты прогнозирования процентного содержания разных типов тканей. Качество решения задачи оценки состояния эпителия определяется средней ошибкой между прогнозированным и выявленным доктором после биопсии. Проводилось 3 эксперимента. В первом прогнозировалось процентное содержание 6 типов эпителия, во втором прогнозировалось процентное содержание трансформированного эпителия до обучения, и в третьем процентное содержание трансформированного эпителия после обучения.

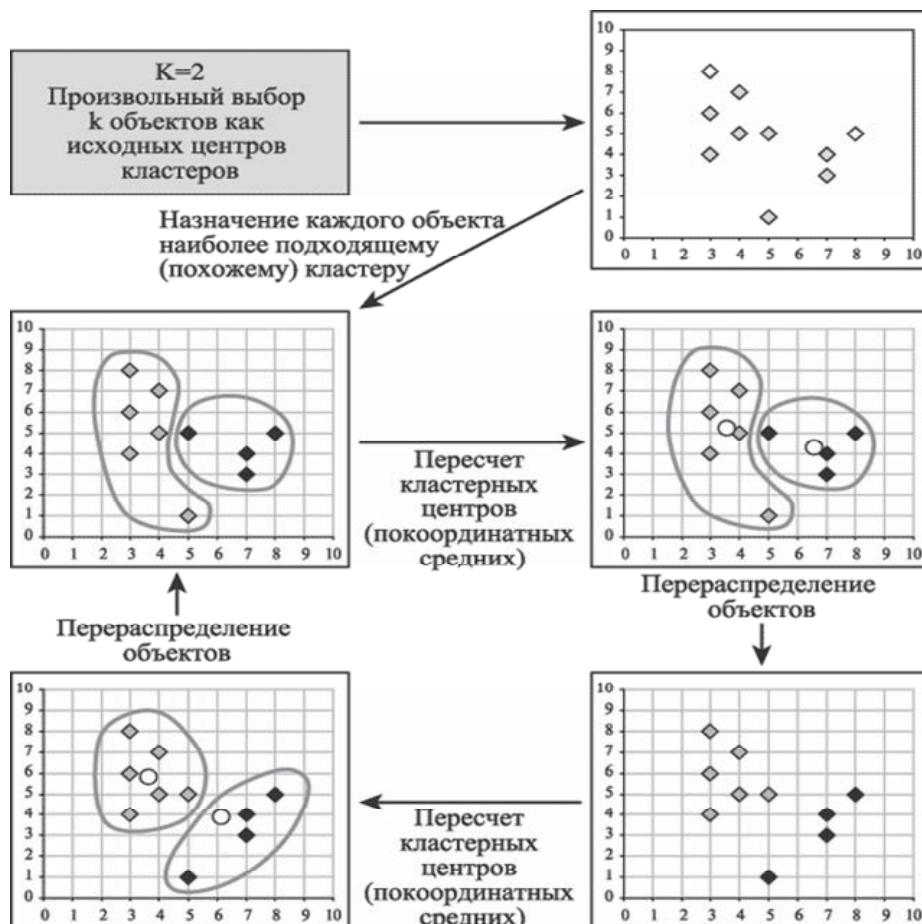


Рисунок 4 – Алгоритм К-средних

Таблица 1

Результаты прогнозирования состояния эпителия (средняя ошибка)

	Каскадная нейронная сеть	Нейронная сеть с алгоритмом обучения Back Propagation	Сеть RBF
6 типов тканей	0.0479	0.0584	0.0610
CIN1+CIN2+CIN3 (до обучения)	0.0768	0.0865	0.0446
CIN1+CIN2+CIN3 (после обучения)	0.0724	0.0837	0.0659

Из Таблицы 1 видно, что сети радиального базиса дают наилучший результат. Каскадные нейронные сети и сеть с обратным распространением ошибки дают, приблизительно, одинаковый результат.

Таблица 2

Результаты классификации состояния эпителия по 6 типам (4 класса)

	Каскадная нейронная сеть	Нейронная сеть с алго- ритмом обучения Back Propogation	Сеть RBF
Ложно- отрицательные	0.0854	0.0987	0.0833
Ложно- положительные	0.0508	0.0417	0.0433
корректные	0.8713	0.8596	0.8458

В Таблице 2 приведены результаты классификации. В качестве критерия эффективности классификации используется ошибка первого и второго рода. В эксперименте проводится классификация (по процентному содержанию) каждого из 6 типов состояния эпителия на 4 класса (1 класс – [0.0, 0.25], 2 класс – (0.25, 0.50], 3 класс – (0.50, 0.75], 4 класс – (0.75, 1.00]).

Далее на рисунке 5 показана сегментация изображений при помощи Карт Кохонена (первая строка) и алгоритма К-средних (вторая строка).

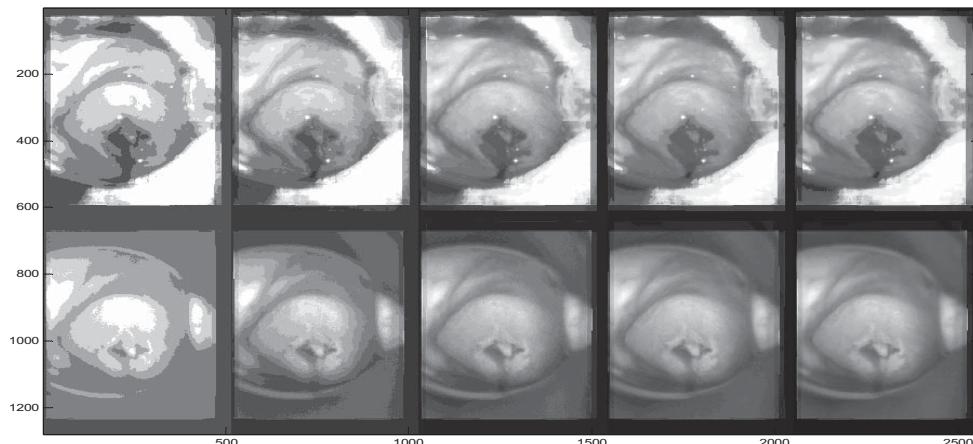


Рисунок 5 – Сегментация изображений используя Карты Кохонена и Алгоритм К-средних

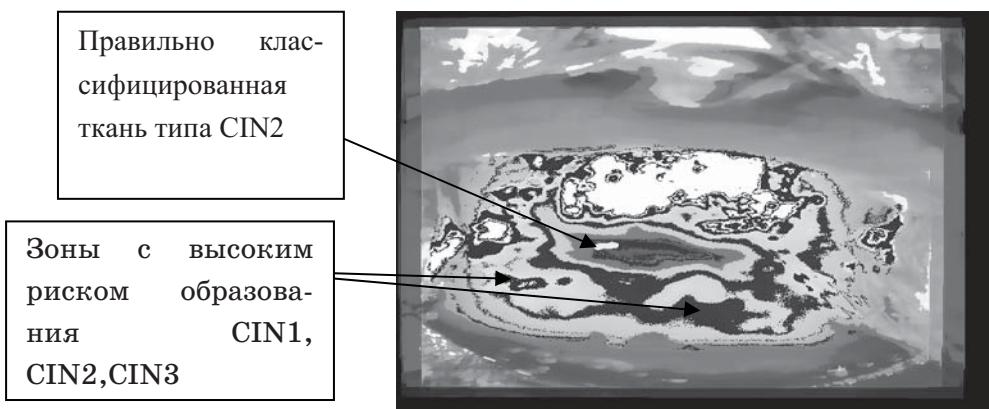


Рисунок 6 – Пример правильного прогноза типа ткани

На рисунке 6 показан результат прогноза типа ткани по биопсии путем проверки каждого сегмента при помощи ранее обученных нейронных сетей.

Выводы

В работе было исследовано применение нейронных сетей для задачи классификации типов тканей шейки матки по мультиспектральным изображениям

- Проведенные исследования показали целесообразность использования нейронных сетей для решения поставленной задачи. При этом сети радиального базиса всегда дают значительно лучшие результаты, чем другие, представленные в работе.
- Использование разных способов предварительной обработки данных дают значительное улучшение результатов работы. Выделение квадрата в месте, где была сделана биопсия является более эффективным чем просто вычисление среднего значения по области, так как таким образом учитывается структура ткани.
- Для сегментации изображений лучше использовать самоорганизующиеся карты Кохонена, так как они более точно выделяют разные типы тканей

ЛИТЕРАТУРА

1. Schoonmaker J. et al. Automatic Segmentation of Uterine Cervix for in vivo Localization and Identification of Cervical Intraepithelial Neoplasia // Apogen Technologies 2007
2. Koss L.G. The complex test for cervical cancer detection. In: The Journal of the American Medical Association. – 1989

3. Зайченко Ю.П. Основи проектування інтелектуальних систем. Навчальний посібник – К.: Видавничий Дім «Слово», 2004
4. Domagoj Kovacevic, Sven Loncaric Radial Basis Function-based Image Segmentation using a Receptive Field //Computer-Based Medical Systems. – 1997. Proceedings., Tenth IEEE Symposium – 126-130
5. Scott E. Fahlman, Christian Lebiere: The Cascade-Correlation Learning Architecture. NIPS 1989: 524-532
6. Kohonen T. 1997 "Self-Organizing Maps"(2-nd edition), Springer, 1997.
7. Старикив А. 2000 BaseGroup 2000.
8. Чубукова И.А. Data Mining // БИНОМ. Лаборатория знаний, 2008 г., 384 стр.