

УДК 0004.04:616.07

В.Г. Адамов, доцент, канд. техн. наук,

В.В. Каира, аспирант,

Е.В. Бодня

Донецкий национальный технический Университет

ул. Артема 58, г. Донецк, Украина

E-mail: kayira@yandex.ru

ИССЛЕДОВАНИЕ И ВЫБОР НЕЙРОСЕТЕВОГО КЛАССИФИКАТОРА ПРИЗНАКОВ ИЗОБРАЖЕНИЯ ПРИ ОЦЕНКЕ СОСТОЯНИЯ И ПРОГНОЗИРОВАНИИ СРОКОВ СОЗРЕВАНИЯ КЕРАТИНОЦИТОВ

Рассмотрена проблема классификации признаков изображения при оценке состояния и прогнозировании сроков созревания кератиноцитов. Проведен сравнительный анализ показателей точности и быстродействия нейросетевых классификаторов при решении поставленной проблемы. На основании полученных данных многослойная нейронная сеть определена как наиболее подходящая для использования в компьютерной системе оценки состояния и прогнозирования сроков созревания кератиноцитов.

Введение. Задача оценки состояния и прогнозирования сроков созревания кератиноцитов была поставлена в работе [1]. Кератиноциты – культура клеток кожи, пересаживаемых пациентам на пораженные участки. Показано, что существуют стандартные модели роста клеточных популяций [2]. В то же время кератиноциты, как клетки человека, очень сложны в культивировании и применение стандартной модели роста невозможно. Для большей вероятности удачной пересадки и приживания участков кожи, культивируются клетки, которые берутся у самого пациента с непораженных участков. На рост культуры влияют генетические факторы, которые пока невозможно контролировать. В [1] предложено контролировать начальный этап роста культуры, регистрируя скорость роста на этом этапе и на основании полученных данных и существующих моделей производить прогноз сроков созревания. В работах [1, 3] показано, что контролировать рост культуры без лабораторного вмешательства, которое негативно влияет на процесс роста, возможно используя анализ изображений матраса (прозрачная основа, на которой растут клетки), получаемых с помощью инверсионного микроскопа на увеличении $\times 100$. Для определения количества клеток на матрасе и их жизнеспособность при анализе изображений было рекомендовано использовать радиальные признаки Фурье [3, 4].

Постановка задачи. Для повышения точности классификации снимков в подсистеме контроля качества культуры (рисунок 1) рекомендовано использовать классификатор признаков изображения [1]. Целью статьи является выбор классификатора, который должен обеспечить достаточно высокую точность системы оценки качества и прогнозирования роста культуры кератиноцитов в целом.




Рисунок 1 – Функциональная схема подсистемы контроля качества выращиваемой культуры

Серое изображение матраса $I(x, y)$, где x и y – координаты пикселей изображения, после выхода из блока предварительной обработки изображения поступает на блок получения двумерного спектра изображения, на выходе блока получаем

$$F(w_x, w_y) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} I(x, y) \exp\{-i(w_x x + w_y y)\}, \quad (1)$$

где $F(w_x, w_y)$ – спектр изображения; $w_x = \frac{2\pi}{N} n_x$ и $w_y = \frac{2\pi}{M} n_y$, $n_x = 0, \dots, N-1$, $n_y = 0, \dots, M-1$, N, M – линейные размеры изображения.

На практике при анализе комплексной функции $F(w_x, w_y)$ целесообразно принимать во внимание модуль её значения

$$M(w_x, w_y) = |F(w_x, w_y)|. \quad (2)$$

Для обеспечения инвариантности к вращению применяется радиальная функция признаков Фурье

$$Rf(\rho) = \int_0^{2\pi} M(\rho, \theta) d\theta, \quad (3)$$

где $\theta = \arctg(w_y/w_x)$ и $\rho^2 = w_x^2 + w_y^2$.

Зависимость скорости роста клеточной культуры на начальной стадии при успешном посеве зависит в основном от возраста донора. Для аппроксимации роста количества клеток предложено использовать классическое уравнение Мальтуса [2, 3]

$$\frac{dN}{dt} = \mu N, \quad (4)$$

где N – число клеток; t – время; μ – удельная скорость пролиферации.

Это уравнение описывает неограниченный экспоненциальный рост численности клеток. Однако при этом необходимо учитывать замедление скорости деления клеток из-за уменьшения концентрации питательных веществ. Зависимость скорости роста от концентрации лимитирующего вещества описывается уравнением Моно

$$\mu(S) = \mu_{\max} \frac{S}{K_s + S}, \quad (5)$$

где S – характеристика питательной среды; $\mu_{\max}$ – максимальная скорость пролиферации (определяется лабораторно); K_s – константа связывания вещества (определяется лабораторно).

Поскольку питательная среда используется на поддержание жизнедеятельности всех живых клеток относительно равномерно, скорость падения её концентрации пропорциональна числу клеток

$$\frac{dS}{dt} = -NG_s, \quad (6)$$

где G_s – мгновенная скорость синтеза субстрата (определяется лабораторно).

Константы в этих уравнениях определяются после проведения лабораторных опытов. Также в лабораторных условиях необходимо учесть инерционность клетки при смене среды, которая замедляет рост

$$\frac{d\mu}{dt} = \frac{\mu_{cm} - \mu}{T}, \quad (7)$$

где μ_{cm} – стационарное значение скорости пролиферации; T – время установления стационарного состояния скорости деления (определяется лабораторно).

Данная модель роста подлежит уточнению в дальнейших исследованиях, на данном этапе моделирования делается допущение, что процессом отмирания при культивировании кератиноцитов можно пренебречь. Тогда считая начальные концентрации питательных веществ при смене среды одинаковыми, прогноз о количестве клеток может быть получен следующим образом.

1. При каждой смене питательной среды необходимо [1] производить ряд снимков матраса с растущей культурой и регистрировать дату и время съемки.

Для каждого снимка культуры согласно выражениям (1) – (3) следует выделить признаки изображения [3] и с помощью классификатора признаков определить процент заполнения снимка.

2. Зная посевную концентрацию клеток N_0 , зарегистрировав изменение заполнения матраса клетками dN/dt , считая площадь отдельных клеток одинаковой, согласно выражению (4) нужно определить скорость пролиферации для данной культуры и считать её как $\mu_{\max}$.

3. Учесть уменьшение скорости пролиферации [2] из-за большего количества клеток и более быстрого падения концентрации питательных веществ согласно выражениям (5) – (7).

4. Оценивая качество роста культуры [1], по выражению (4) определить период времени dt , необходимый для получения нужного количества клеток.

Использование в предложенной системе прогнозирования роста классификатора накладывает определенные требования на его реализацию, а именно:

1) на вход классификатора необходимо подавать признак изображения в виде вещественного вектора значений – радиальных признаков Фурье;

2) значение, получаемое на выходе классификатора, должно соответствовать процентному заполнению культурального матраса клетками;

3) если выходом классификатора являются только целые числа, то он должен быть способен классифицировать большое число классов культуры, которые соответствуют разным диапазонам заполнения матраса клетками.

Второе требование подразумевает аппроксимацию многомерной функции, в то время как третье требование допускает решение задачи как определение принадлежности к заданному классу. Для решения данной задачи представляется наиболее целесообразным использование классификатора на основе нейронных сетей. Использование такого классификатора позволяет получить необходимую надежность и скорость обработки данных.

Решение задачи. Для решения поставленной задачи необходимо провести сравнительный анализ существующих нейронных сетей, которые соответствуют требованиям к классификатору, для определения лучшей. В данной работе предполагается рассмотреть скорость обучения и точность классификации снимков кератиноцитов [1, 3]. С целью выбора наиболее часто используемых классификаторов для классификации в подобных задачах и отобраны следующие нейронные сети: многослойная нейронная сеть с обратным распространением ошибки, сеть Кохонена, нейронная сеть встречного распространения, радиально-базисная нейронная сеть, вероятностная нейронная сеть, обобщенно-регрессионная нейронная сеть, нейронная сеть Элмана.

Многослойные нейронные сети были предложены и исследованы Розенблаттом, Минским и другими авторами [4]. Область применения таких сетей весьма широка: аппроксимация функций, классификация, распознавание образов, контроль и адаптивное управление, прогнозирование и др. Многослойная сеть с сигмоидальными передаточными функциями – наиболее общая, с универсальной сетевой структурой. Существует несколько различных структур многослойных сетей: с последовательными, перекрестными, и обратными связями, с фиксированной и переменной структурой.

Многослойные сети с последовательными связями имеют следующую общую структуру: на вход каждого её нейрона подаются выходные сигналы со всех нейронов предыдущего слоя. Входной сигнал – целые или действительные числа, определяется в зависимости от принятой передаточной функции нейронов. Нейроны выполняют суммирование входных сигналов с соответствующими весами. К полученной сумме добавляют смещение нейрона. Над результатом суммирования выполняется нелинейное преобразование – функция активация нейрона. Двух слоев нейронов достаточно для того, чтобы аппроксимировать любую непрерывную функцию с необходимой точностью. Многослойные сети являются универсальными аппроксиматорами. Для решения поставленной задачи, в соответствие каждому многомерному входному вектору ставится один выход – значение заполнения матраса клетками; данные сети не требуют дополнительных преобразований или интерпретации своего выхода при использовании в компьютерной системе [1]. Многослойные сети с задержкой по входам отличаются от обычных многослойных сетей тем, что их выход зависит от одного или нескольких предыдущих входных векторов. Скорость обучения многослойной нейронной сети показана на рисунке 2, а.

Сети, называемые картами Кохонена, – это разновидность нейронных сетей, но эти сети принципиально отличаются от других, поскольку у них неконтролируемое обучение [4]. Основной принцип работы такой сети состоит в том, что при обучении нейрона он получает информацию относительно своего расположения. Карты Кохонена используют для решения следующих задач: моделирование, прогнозирование, поиск закономерностей в больших массивах данных, выявление наборов независимых признаков и сжатие информации. Чаще всего сеть Кохонена используют для решения задачи классификации без учителя, т.е. кластеризации. Сеть Кохонена очень проста; она состоит из двух слоев: входного и выходного. Сеть обучается методом последовательных приближений. Особенность сети Кохонена в том, что в процессе обучения на входы подаются данные, но при этом сеть подстраивается не под эталонное значение выхода, а под закономерности во входных данных. Достоинством является то, что сеть по своей структуре очень проста. Недостатком – то, что разбиение на классы происходит произвольно, что для решения поставленной задачи является критическим фактором: задача по нахождению оптимального количества нейронов такой сети для получения требуемого разбиения на классы значительно усложняется.

Сеть встречного распространения была разработана Робертом Хехт-Нильсеном, она включает в себя слой Кохонена и выходной слой [4]. Сеть используют при решении задач со сложной классификацией, при этом минимизируется время обучения сети и уменьшается количество нейронов. Однонаправленная сеть встречного распространения включает три слоя: входной слой, самоорганизующаяся карта Кохонена и выходной слой. Такая сеть лишена недостатка обычной сети Кохонена при решении поставленной задачи. Зависимость ошибки на выходе сети от количества эпох обучения нейросетей изображена на рисунке 2, б. К недостаткам сети встречного распространения можно отнести то, что сеть не дает возможности построения точной аппроксимации, сеть уступает в

этом сетям с обратным распространением ошибки. К недостаткам также можно отнести слабый базис модификации. К преимуществам относится то, что сеть встречного распространения проста, дает возможность получение статистических свойств из множества входных сигналов, быстро обучается, превосходит однослойный персептрон, пригодна для быстрой начальной аппроксимации.

Под термином радиально-базисной сети (RBF) понимается двухслойная нейронная сеть без обратной связи, которая содержит скрытый слой радиально-симметричных скрытых нейронов (шаблонный слой) [4]. Скорость обучения такой сети достаточно велика, график скорости обучения сети показан на рисунке 2, в. Сети RBF имеют преимущества над другими сетями. Они моделируют произвольную нелинейную функцию с помощью всего одного промежуточного слоя, что избавляет от решения вопроса о числе слоев. Параметры линейной комбинации в выходном слое можно полностью оптимизировать с помощью хорошо известных методов линейной оптимизации, эти методы работают быстро и не испытывают трудностей с локальными минимумами, возникающими при обучении с использованием алгоритма обратного распространения ошибки. Недостатком сетей RBF является то, что данные сети обладают плохими экстраполирующими свойствами и получаются весьма громоздкими при большой размерности вектора входов, подобно решаемой задаче.

Вероятностную нейронную сеть используют при решении вероятностных задач и задач классификации [4]. Структура сети основывается на структуре радиально-базисной сети, с заменой второго слоя на конкурирующий слой, который считает вероятность принадлежности входного вектора к определенному классу, результат сопоставляется с тем классом, вероятность принадлежности к которому выше. К преимуществам сети можно отнести то, что выходное значение имеет вероятностный смысл, а также высокую скорость обучения, во время обучения сети на вход подается обучающая выборка, на это и затрачивается основное время, поэтому сеть обучается настолько быстро, насколько это возможно. Недостатком таких сетей является их объем, поскольку включает в себя практически все данные, что значительно замедляет скорость работы сети.

Обобщенно-регрессионная сеть (GRNN) строится аналогично вероятностной нейронной сети [4], но её используют для решения задач регрессии. Обобщенно-регрессионная сеть копирует внутрь себя все обучающие наблюдения и использует их для оценки отклика в произвольной точке. Конечный выход сети получается как взвешенное среднее выходов по всем обучающим наблюдениям, где величины весов показывают расстояние от этих наблюдений до той точки, в которой производится оценивание. Сеть состоит из двух слоев. Первый слой состоит из радиальных элементов. Второй – из элементов, которые помогают оценить взвешенное среднее, т.е. число элементов во втором слое на единицу больше, чем в выходном слое. Чаще всего в задачах регрессии требуется оценить одно выходное значение, следовательно, второй промежуточный слой содержит два элемента. Достоинства и недостатки таких сетей в основном такие же, как и у вероятностных нейронных сетей. Отличие заключается в том что, обобщенно-регрессионная сеть используется в задачах регрессии, а вероятностную используют в задачах классификации. Недостатком при решении поставленной задачи является то, что обобщенно-регрессионная сеть не может экстраполировать данные.


Нейронная сеть Элмана [4] – рекуррентная нейронная сеть с обратной связью от скрытого слоя ко входному. Сеть Элмана включает дополнительный блок, в котором хранится информация о предыдущих входах. Этот блок может быть интерпретирован, как блок долговременной памяти нейронной сети. Нейроны скрытого слоя сети Элмана содержат функцию активации $f(x)=1/(1+\exp(-x))$, тогда как нейроны выходного слоя обладают линейной функцией активации. Такие вариации с функциями активации позволяют аппроксимировать любую функцию с конечным числом разрывов с заданной точностью. Скорость обучения сети показана на рисунке 2, г. Сеть Элмана предназначена для определения и имитации нелинейных динамических систем, применяется для аппроксимации функций, классификации, прогнозирования. Недостатком этой сети является длительное время обучения и сложность дополнительного обучения.

Результаты исследований. С целью выбора оптимальной нейронной сети для использования в предложенной компьютерной системе [1], были проведены эксперименты по определению точности классификации радиальных признаков Фурье снимков кератиноцитов с помощью Neuro Toolbox пакета Matlab 6.5.


В процессе выращивания наблюдались 5 различных культур кератиноцитов. При каждой смене питательной среды производилась съемка различных участков культурального матраса [1] с разрешением 512×512 пикселей. По каждому снимку экспертом ставилось число – процентное заполнение снимка изображением живых и растущих клеток. Заполнение снимка определялось как отношение площади (количество пикселей) всех клеток кератиноцитов на снимке, которая определялась ручным выделением контура областей с клетками, к площади всего снимка. Для сетей, которые могут определять только принадлежность к классу, набор снимков был разбит на 7 классов, которые

соответствуют диапазонам процентного заполнения матраца клетками (1-й класс – от 0 % до 15 %, 2-й – от 16 % до 30 % и т.д.).


С помощью программного обеспечения, написанного на языке программирования C++ [1], для каждого снимка определялся радиальный признак Фурье, значения с 5-го по 45-ое подавались на вход нейросетей. Для обучения нейросетей были отобраны 30 эталонных векторов входных значений, соответствующих различному заполнению культурального матраца клетками. В сетях, обучение которых происходит с учителем, во время обучения на выход подавалось соответствующее значение процентного заполнения снимка, определенное экспертом; для сетей, определяющих принадлежность к классу – целое число, соответствующее одному из семи классов изображений. На рисунке 2 показаны графики зависимости ошибки обучения от количества эпох.




а) изменение ошибки обучения многослойной сети



б) изменение ошибки обучения сети встречного распространения



в) изменение ошибки обучения сети RBF




г) изменение ошибки обучения сети Элмана

Рисунок 2 – Зависимость величины ошибки выхода нейросетей от количества эпох обучения (входной вектор – 40 значений радиального признака Фурье снимков кератиноцитов)


Для определения точности работы нейросетей на их входы подавались 30 тестовых векторов – радиальных признаков Фурье, соответствующих различному заполнению матраца клетками кератиноцитов. Точность определялась как отношение количества правильно определенных классов тестовых входных векторов (либо как попадание выхода сети в интервал равный значению, определенному экспертом, ± 7 включительно) к общему количеству тестовых входных векторов.

Для каждой сети с целью получения максимальной точности в эксперименте изменялось количество нейронов в скрытом слое. Так, для многослойной сети с обратным распространением ошибки число нейронов в скрытом слое изменялось от 2 до 150. Для сети Кохонена количество нейронов изменялось от 2 до 100; для сети встречного распространения и сети Элмана – от 2 до 200. Графики зависимости точности классификации снимков кератиноцитов по радиальному признаку Фурье от количества нейронов в скрытом слое изображены на рисунке 3.


В результате 3 сети: многослойная, встречного распространения и сеть Элмана показали одинаковую точность 90 %. Данная точность получена при классификации 7 диапазонов значений. Точность, полученная без использования классификатора на основе нейронных сетей [1], составляет 83 % при классификации всего 3 диапазонов значений. Высокая точность в данном эксперименте требует уточнения и статистической проверки при проведении дополнительных экспериментов. В то же время, данный эксперимент иллюстрирует целесообразность применения классификатора на основе нейронных сетей в компьютерной системе оценки качества и прогнозирования сроков созревания кератиноцитов.




а) Многослойная сеть с обратным распространением ошибки



б) Сеть Кохонена



в) Сеть встречного распространения



г) Сеть Элмана

Рисунок 3 – Зависимость точности классификации снимков кератиноцитов по радиальному признаку Фурье от количества нейронов в скрытом слое

Результаты экспериментов по определению точности классификации снимков кератиноцитов представлены в таблице 1. Анализ свойств сетей с наилучшими показателями точности демонстрирует, что сеть встречного распространения уступает двум другим сетям в силу малой возможности модификации структуры и дополнительного обучения; сеть Элмана показала наиболее стабильную точность независимую от количества нейронов в скрытом слое, однако сеть занимает большой объем памяти, возникает сложность дополнительного обучения; многослойная сеть является наиболее простой в реализации и использовании. Если дополнительные эксперименты не дифференцируют показатели точности этих сетей, то оптимальной для применения в компьютерной системе определения качества и прогнозирования сроков созревания кератиноцитов является многослойная сеть.

Выводы. В исследовании был выполнен анализ возможного применения в компьютерных системах прогнозирования сроков созревания кератиноцитов различных нейронных сетей в качестве классификатора радиальных признаков Фурье. Проведены эксперименты по определению оптимального количества нейронов в скрытом слое нейросетей. Сравнительный анализ предложенных сетей показал, что для компьютерных систем прогнозирования сроков созревания кератиноцитов наиболее

целесообразным является использование многослойной сети. Показано также, что использование многослойной сети способно увеличить точность распознавания снимков кератиноцитов по отношению к использованию разделения на классы на основе доверительных интервалов [1].

Таблица 1 – Точность классификации снимков кератиноцитов по радиальному признаку Фурье различных нейронных сетей

Тип нейронной сети	Точность, %
Линейная сеть	53
Многослойная сеть	90
Многослойная сеть с задержкой	90
Сеть Кохонена	53
Сеть встречного распространения	90
RBF сеть	63
Вероятностная сеть	77
Обобщенно-регрессионная сеть	□□□
Сеть Элмана	90

В направлении дальнейшего развития исследования предполагается разработка и проверка адекватности модели роста культуры кератиноцитов, параметрами которой являются выходные значения рекомендованной нейронной сети. Также следует проверить возможность повышения точности системы за счет использования для классификации дополнительных признаков изображения, таких как фрактальная размерность [3].

Библиографический список

1. Адамов В.Г. Компьютерная система прогнозирования сроков созревания кератиноцитов / В.Г. Адамов, В.В. Каира // Моделювання та керування станом еколого-економічних систем регіону. — К: Міжнар. наук.-навч. центр інформаційних технологій та систем НАН України та МОН України. — 2006. — Вип. 3. — С. 3 – 13.
2. Романовский Ю.М. Математическая биофизика / Ю.М. Романовский, Н.В. Степанова, Д.С. Чернавский. — М.: Наука, 1984. — 304 с.
3. Каира В.В. Исследование и выбор метода выделения признаков изображения при прогнозировании сроков созревания кератиноцитов / В.В. Каира // Наук. пр. ДонНТУ, Сер. Обчислювальна техніка. — Донецк: ДонНТУ. — 2007. — Вип. 12(118). — С. 83 – 91.
4. Pratt W.K. Digital Image Processing: PIKS Inside, Third Edition / William K. Pratt. — John Wiley & Sons Inc., 2001. — 735 p.

Поступила в редакцию 05.12.2006 г.