

Математическое моделирование и программная реализация искусственного интеллекта для идентификации биологических микроскопических объектов

Е.А. Корчевская*, В.М. МIRONENKO, С.С. Маевская***

**Учреждение образования «Витебский государственный университет
имени П.М. Машерова»*

***Учреждение образования «Витебская ордена “Знак Почета”
государственная академия ветеринарной медицины»*

При построении систем диагностики, предназначенных для работы с данными клинических функциональных исследований, в частности таких, как микроскопические исследования, возникает задача синтеза алгоритмов, позволяющих автоматизировать процесс принятия решения о принадлежности цифрового изображения объекта тому или иному классу, соответствующему тем или иным состояниям исследуемой внутренней системы организма. В представленной статье разработано признаковое пространство для распознавания микроскопических биологических объектов. Предложен эффективный способ, помогающий надежно идентифицировать микро- и нанообъекты, основанный на разработанном признаковом пространстве и методах искусственного интеллекта.

Создана интеллектуальная система на языке программирования C++ в среде разработки C++ Builder, позволяющая по цифровому изображению, поступающему на вход, производить идентификацию объекта.

Ключевые слова: *методы искусственного интеллекта, признаковое пространство, распознавание образов.*

Mathematical Modeling and Program Implementation of Artificial Intellect for Identification of Biological Microscopic Objects

A.A. Karcheuskaya*, V.M. Mironenko, S.S. Maevskaya***

**Educational establishment «Vitebsk State P.M. Masherov University»*

***Educational establishment «Vitebsk Order of Honor State Academy of Veterinary Medicine»*

In the construction of diagnostic systems for working with data of clinical functional researches, in particular, such as microscopic examinations, the problem of synthesis of algorithms that automate the process of deciding the ownership of digital images of an object to a particular class, which corresponds to various states of the studied internal systems of the body, occurs. In the present article feature space for recognition of microscopic biological objects is designed. An effective method, which allows reliable identification of micro and nano objects, based on the developed feature space and on the methods of artificial intelligence is proposed. The intellectual system in the programming language of C++ in integrated development environment C++ Builder is developed, which allows digital image at the input to produce identification of the object.

Key words: *artificial intelligence techniques, the feature space, pattern recognition.*

Современные системы поддержки принятия решений, ориентированные на самые различные предметные области, содержат в качестве необходимой составляющей подсистемы, связанные с решением задач распознавания образов. Результаты работы таких подсистем затем используются при дальнейшей логико-интеллектуальной обработке информации.

Широкое разнообразие методов анализа изображений объективно обусловлено большим количеством предметных областей, в которых эти методы применяются. Изображения в разных пред-

метных областях могут варьироваться как по своему содержанию, для описания которого может оказаться эффективным то или иное представление изображений, так и по степени изменчивости изображений (типичными причинами изменчивости изображений являются смена ракурса съемки, освещения, типа камеры, а также собственная изменчивость объектов). В узких предметных областях наиболее практичными могут оказаться признаковые методы. Глобальные признаки позволяют осуществлять быструю категоризацию изображений или распознавание изолированных объектов.

Для изображений микроскопических биологических объектов достаточно информативным является контур объекта. Контурный анализ – совокупность методов выделения, описания и преобразования контуров изображения. Это важный этап обработки изображений и распознавания зрительных образов. Контур целиком определяет форму изображения и содержит всю необходимую информацию для распознавания изображений по их форме. Подобный подход позволяет не рассматривать внутренние точки изображения и тем самым сократить объем обрабатываемой информации. Как следствие, это может обеспечить работу системы распознавания в реальном времени. Также данный подход способствует сокращению объема запоминающих устройств системы распознавания.

Аргументы в пользу привлечения контуров:

- 1) контур является концентратором информации в изображении;
- 2) контур полностью характеризует форму объектов на изображении;
- 3) контуры объекта, в отличие от его остальных точек, устойчивы на изображениях, полученных в разное время, разных ракурсах и при смене датчика;
- 4) контурные точки составляют незначительную часть всех точек изображения, поэтому работа с ними позволяет резко сократить объем вычислений.

Будем использовать следующую модель задачи классификации. Ω – множество объектов распознавания (пространство образов). $\omega: \omega \in \Omega$ – объект распознавания (образ). $g(\omega): \Omega \rightarrow M$, $M = \{1, 2, \dots, m\}$ – индикаторная функция, разбивающая пространство образов Ω на m непересекающихся классов $\Omega_1, \Omega_2, \dots, \Omega_m$. Индикаторная функция неизвестна наблюдателю. X – пространство наблюдений, воспринимаемых наблюдателем (пространство признаков). $x(\omega): \Omega \rightarrow X$ – функция, ставящая в соответствие каждому объекту ω точку $x(\omega)$ в пространстве признаков. Вектор $x(\omega)$ – это образ объекта, воспринимаемый наблюдателем. В пространстве признаков определены непересекающиеся множества точек $K_i \in X$, $i = 1, 2, \dots, m$, соответствующих образам одного класса. $\tilde{g}(x): X \rightarrow M$ – решающее правило – оценка для $g(\omega)$ на основании $x(\omega)$, т.е. $\tilde{g}(x) = \tilde{g}(x(\omega))$. Пусть $x_j = x(\omega_j)$, $j = 1, 2, \dots, N$ – доступная наблюдателю информация о функциях $g(\omega)$ и $x(\omega)$, но сами эти функции наблюдателю неизвестны. Тогда (g_j, x_j) , $j = 1, 2, \dots, N$ есть множество прецедентов.

Цель работы заключается в построении такого решающего правила $\tilde{g}(x)$, чтобы распознавание проводилось с минимальным числом ошибок.

Обычный случай – считать пространство признаков евклидовым, т.е. $X = R^l$. Качество решающего правила измеряют частотой появления правильных решений. Обычно его оценивают, наделяя множество объектов Ω некоторой вероятностной мерой. Тогда задача записывается в виде $\min P \{ \tilde{g}(x(\omega)) \neq g(\omega) \}$.

Для достижения цели необходимо решить следующие задачи:

1. Разработать признаки для распознавания микроскопических биологических объектов.
2. Обучить на примере тестировочной коллекции.
3. Создать интеллектуальную систему для распознавания объектов на основе карт Кохонена.

Материал и методы. Выделяют 4 группы методов распознавания [1–2]:

- сравнение с образцом;
- статистические методы;
- нейронные сети;
- структурные и синтаксические методы.

В представленной работе использованы два метода: сравнение с образцом и нейронные сети. Метод сравнения с образцом заключается в получении численных значений эталона с помощью тренировочной коллекции, то есть объектов, для которых заранее известно, к какому виду они относятся.

Нейронные сети – это раздел искусственного интеллекта, в котором для обработки сигналов используются явления, аналогичные происходящим в нейронах живых существ [2]. Важнейшая особенность сети, свидетельствующая о ее широких возможностях и огромном потенциале, состоит в параллельной обработке информации всеми звеньями, что позволяет значительно ускорить процесс обработки информации. Кроме того, при большом числе межнейронных соединений сеть приобретает устойчивость к ошибкам, возникающим на некоторых линиях. Другое не менее важное свойство – способность к обучению и обобщению накопленных знаний. Нейронная сеть обладает чертами искусственного интеллекта. Натренированная на ограниченном множестве данных сеть способна обобщать полученную информацию и показывать хорошие результаты на данных, не использовавшихся при ее обучении.

Основные этапы решения задачи идентификации представлены на рис. 1.




Рис. 1. Последовательность этапов работы электронной системы идентификации микроскопических биологических объектов.



Рис. 2. Использование метода Отца с разным параметром.

Результаты и их обсуждение. Исходными данными для электронной системы идентификации биологических объектов являются цифровые изображения микроскопических биологических объектов, а результатом работы всей системы – решение об идентификации микрообъекта.

Процесс бинаризации изображения основан на сравнении яркости каждого пикселя $B(x,y)$ с пороговым значением яркости $B_T(x,y)$; если значение яркости пикселя выше значения яркости порога, то на бинарном изображении соответствующий пиксель будет «белым», или «черным» в противном случае. Необходимость устранения большого числа ошибок процесса бинаризации повлекла за собой появление большого числа методов бинаризации, которые делятся на две группы по принципу построения пороговой поверхности: методы глобальной и локальной бинаризации. Пороговой поверхностью является матрица размерностью $M \times N$, соответствующей размерности исходного изображения, каждая

ячейка матрицы задает порог яркости бинаризации для соответствующего пикселя на исходном изображении. В методах глобальной бинаризации пороговая поверхность является плоскостью с постоянным значением пороговой яркости, а в методах локальной бинаризации значение пороговой яркости меняется от точки к точке изображения и рассчитывается на основе некоторых локальных признаков в окрестности пикселя. На рис. 2 приведены изображения, полученные после бинаризации микрообъектов методом Отца с различными параметрами. Слева параметр бинаризации равен 141, справа – 118.

Цифровой шум – дефект изображения, вносимый фотосенсорами и электроникой устройств, которые их используют (цифровой фотоаппарат, видеокамеры). Цифровой шум проявляется в виде случайным образом расположенных элементов раstra (точек), имеющих размеры, близкие к размеру пикселя. Цифровой шум отличается от изображения более светлым

или темным оттенком серого цвета (яркостной шум) и по цвету (хроматический шум). В разработанной электронной системе идентификации микрообъектов реализованы фильтр для устранения шума типа «соль и перец» и медианный фильтр. После этого происходит непосредственный процесс выделения контура.

В процессе разработки признакового пространства необходимо определить, какие измерения на входном объекте могут играть роль признаков. Отметим, что признаки могут иметь различную природу и значимость для задачи классификации, поэтому отбор признаков и их упорядочение основываются на важности этих признаков для характеристики образов или на влиянии данных признаков на качество распознавания. Опора на большое количество признаков, используемых в процессе распознавания, ведет к повышению интеллектуальности и надежности распознающих систем. Однако размерность признакового пространства N обычно стремятся сделать как можно меньше, поскольку при этом сокращается количество требуемых измерений, упрощаются вычисления, формирующие и реализующие решающие правила, повышается статистическая устойчивость результатов распознавания. Вместе с тем уменьшение N , вообще говоря, ведет к росту риска потерь. Поэтому формирование признакового пространства является компромиссной задачей. Важно формировать признаки с заданными свойствами. Например, весьма важным свойством является инвариантность признаков по отношению к движению (перемещению, повороту) и линейным деформациям объекта (в частности, масштабным изменениям). Инвариантность важна для независимости результата распознавания от движений и линейных деформаций объектов, то есть в конечном итоге для достижения высокой надежности распознавания. В связи с этим возникает важный вопрос о сохранении свойств инвариантности признаков распознавания при сканировании изображений.

В работе создано пространство признаков, включающее в себя множество инвариантных показателей, которые удовлетворяют отдельным требованиям, например, устойчивости к масштабированию, сдвигу, повороту. Среди них следующие идентификационные показатели: «отношение ширины объекта к длине», «произведение отношений длины объекта к ширине и наибольшего к наименьшему радиусу кривизны полюсов объектов», «компактность», «от-

ношение действительных и мнимых частей коэффициентов ряда Фурье», «некруглость формы», «энергия изгиба», «отношение главных моментов», «отношение площадей вписанного прямоугольника к описанному» и другие.

Для реализации указанных параметров необходимо получить аналитическую функцию $f(x)$, описывающую границу объекта. Для этого следует решить задачу интерполирования, которая состоит в том, чтобы по значениям функции $f(x)$ в нескольких точках отрезка восстановить ее значения в остальных точках этого отрезка. Задача интерполирования возникает, например, в том случае, когда известны результаты измерения $y_k = f(x_k)$ некоторой физической величины $f(x)$ в точках x_k и требуется определить ее значения в других точках.

Для вычисления производных, входящих в формулу радиуса кривизны контура объекта, были использованы конечноразностные соотношения второго порядка точности. Расчет идентификационного показателя «компактность» включает в себя вычисление интеграла. Значение интеграла находится с помощью квадратурных формул, которые основываются на замене интеграла конечной суммой. В процессе реализации признака «отношение действительных и мнимых частей коэффициентов ряда Фурье» использовалось Фурье-описание границы в поле комплексных чисел.

Сеть Кохонена, предложенная Тойво Кохоненом в 1984 году, представляет собой самоорганизующуюся нейронную сеть, предназначенную для разделения векторов входных сигналов на подгруппы. Основу обучения самоорганизующихся нейронных сетей составляет конкуренция между нейронами. Как правило, это однослойные сети, в которых каждый нейрон соединен со всеми компонентами N -мерного выходного вектора x [3].

Самоорганизующиеся структуры, используемые для задач распознавания образов, классифицируют образы, представленные векторными величинами, в которых каждый компонент вектора соответствует численному значению разработанного признака. Алгоритмы Кохонена основываются на технике обучения без учителя. После обучения подача входного вектора из данного класса будет приводить к выработке возбуждающего уровня в каждом выходном нейроне; нейрон с максимальным возбуждением представляет классификацию. Так как

обучение проводится без указания целевого вектора, то нет возможности определять заранее, какой нейрон будет соответствовать данному классу входных векторов. Тем не менее, это планирование легко проводится путем тестирования сети после обучения.

Алгоритм трактует набор из n входных весов нейрона как вектор в n -мерном пространстве. Перед обучением каждый компонент этого вектора весов инициализируется в случайную величину. Затем каждый вектор нормализуется в вектор с единичной длиной в пространстве весов. Это делается делением каждого случайного веса на квадратный корень из суммы квадратов компонент этого весового вектора [4].

Все входные векторы обучающего набора также нормализуются, и сеть обучается согласно следующему алгоритму:

1. Вектор $\mathbf{X}$ подается на вход сети.

2. Определяются расстояния D_j (в n -мерном пространстве) между $\mathbf{X}$ и весовыми векторами $\mathbf{W}_j$ каждого нейрона. В евклидовом пространстве это расстояние вычисляется по следующей формуле:

$$D_j = \sqrt{\sum_i (x_i - w_{ij})^2},$$

где x_i – компонента i входного вектора $\mathbf{X}$, w_{ij} – вес входа i нейрона j .

3. Нейрон, который имеет весовой вектор, самый близкий к $\mathbf{X}$, объявляется победителем. Этот весовой вектор, называемый $\mathbf{W}_c$, становится основным в группе весовых векторов, которые лежат в пределах расстояния D от $\mathbf{W}_c$.

4. Группа весовых векторов настраивается в соответствии со следующим выражением:

$$\mathbf{W}_j(t+1) = \mathbf{W}_j(t) + \eta[\mathbf{X} - \mathbf{W}_j(t)]$$

для всех весовых векторов в пределах расстояния D от $\mathbf{W}_c$.

5. Повторяются шаги с 1 по 4 для каждого входного вектора.

В процессе обучения нейронной сети значения D и η постепенно уменьшаются. Автор [5] рекомендует, чтобы коэффициент η в начале обучения устанавливался приблизительно равным 1 и уменьшался в процессе обучения до 0, в то время как D может в начале обучения равняться максимальному расстоянию между весовыми векторами и в конце обучения стать настолько маленьким, что будет обучаться только один нейрон.

В соответствии с существующей точкой зрения, точность классификации будет улучшаться при дополнительном обучении. Согласно рекомендации Кохонена, для получения хорошей статистической точности количество обучающих циклов должно быть, по крайней мере, в 500 раз больше количества выходных нейронов.

Обучающий алгоритм настраивает весовые векторы в окрестности возбужденного нейрона таким образом, чтобы они были более похожими на входной вектор. Так как все векторы нормализуются в векторы с единичной длиной, они могут рассматриваться как точки на поверхности единичной гиперболы. В процессе обучения группа соседних весовых точек перемещается ближе к точке входного вектора. Предполагается, что входные векторы фактически группируются в классы в соответствии с их положением в векторном пространстве. Определенный класс будет ассоциироваться с определенным нейроном, перемещая его весовой вектор в направлении центра класса и способствуя его возбуждению при появлении на входе любого вектора данного класса.

После обучения классификация выполняется посредством подачи на вход сети испытуемого вектора, вычисления возбуждения для каждого нейрона с последующим выбором нейрона с наивысшим возбуждением как индикатора правильной классификации.

Сеть Кохонена, адаптированная для распознавания микро- и нанообъектов, содержит 25 нейронов. Размерность входного пространства варьируется от трех до десяти, так как каждый из контуров микрообъектов может быть охарактеризован с помощью десятимерного вектора. Информация об объектах, предназначенных для кластеризации, поступает на вход сети в виде текстового файла, содержащего n -мерные векторы ($n=3...10$). Каждый вектор составлен из значений идентификационных показателей, найденных для конкретного контура.

В случае если размерность входного пространства равна 3, можно выполнить привязку каждого из параметров входного вектора к одному из компонентов цветовой модели RGB, что позволяет представить результаты работы программы в наглядной форме.

Закключение. В результате работы создано признаковое пространство для распознавания микроскопических биологических объектов, в частности паразитологических. На основании

карт Кохонена разработаны методика для идентификации объектов и интеллектуальная система, позволяющая по входному цифровому изображению объекта производить распознавание. Предложенная нами система позволит достигнуть значительного социального эффекта за счет снижения заболеваемости людей, а также высокого экономического эффекта за счет предотвращения потерь, связанных со снижением продуктивности и с гибелью животных от заболеваний, вызываемых микрообъектами.

ЛИТЕРАТУРА

1. Абламейко, С.В. Обработка изображений: технология, методы, применение / С.В. Абламейко, Д.М. Лагуновский. – Минск: Амалфея, 2000. – 304 с.
2. Бодянский, Е.В. Искусственные нейронные сети: архитектуры, обучение, применения / Е.В. Бодянский, О.Г. Руденко. – М.: ТЕЛТЕХ, 2004. – 355 с.
3. Галушкин, А.И. Нейронные сети. Основы теории / А.И. Галушкин. – М.: Горячая Линия – Телеком, 2010. – 496 с.
4. Галушкин, А.И. Синтез многослойных систем распознавания образов / А.И. Галушкин. – М.: Энергия, 1974. – 368 с.
5. Уоссермен, Ф. Нейрокомпьютерная техника: теория и практика / Ф. Уоссермен. – М.: Мир, 1992. – 184 с.

Поступила в редакцию 31.05.2013. Принята в печать 22.08.2013

Адрес для корреспонденции: e-mail: korchevskaya.elena@tut.by – Корчевская Е.А.