

УДК 007.001.362; 681.327.12.001.362

И.В. Новосельцев, Н.Г. Аксак, О.Ю. Барковская

*Харьковский национальный университет радиоэлектроники*

## ГИБРИДНЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ РАСПОЗНАВАНИЯ ОБРАЗОВ

*В работе решается задача классификации изображений на примере медицинской диагностики рака кожи. Предложена гибридная модель на базе вероятностной нейронной сети с суммированием результатов экспертов при определении выходного значения, для классификации входных изображений на три класса, позволяющая снизить вычислительные затраты на обучение гибридной нейронной сети и повысить точность классификации входного образа.*

***гибридные нейронные сети, распознавание образов, классификация, эксперт, вероятностные нейронные сети, обучение нейронной сети***

### Введение

С помощью нейронных сетей (НС) успешно решается большой круг задач различного уровня сложности. Однако, сложность выбора оптимальной архитектуры нейронной сети и большие вычислительные затраты при обучении для решения сложных задач, среди которых такие задачи, как прогнозирование и распознавание, сдерживают их массовое применение.

Гибридные системы позволяют решить эти проблемы, повышая точность решения. В настоящее

время принципы построения коллективов нейронных сетей разработаны в основном для задач построения многомерных отображений (аппроксимации многомерных функций) на основе эмпирических данных.

Гибридные нейронные сети (ГНС) играют важную роль при решении различных прикладных задач. Однако, во многих сложных областях существуют проблемы, связанные с отдельными компонентами, каждый из которых может требовать своих методов обработки.

Гибридные нейронные сети представляют собой объединение нескольких нейронных сетей для решения определенных задач. Это позволяет выполнить декомпозицию сложной задачи на более простые подзадачи, а архитектура нейронной сети может быть оптимизирована под конкретную задачу. Еще одним преимуществом гибридных нейронных сетей является то, что при программной реализации быстрое действие может варьироваться в широких пределах в зависимости от выбранной структуры, что позволяет применять их для решения задач реального времени.

Гибридные нейронные сети объединяют несколько возможно различных по структуре и природе экспертов, поэтому каждый из них может генерировать разные ответы для одного и того же входного воздействия. Для формирования общего ответа гибридной нейронной системы чаще всего используются взвешенное суммирование результатов или динамический выбор одной нейронной сети, и использование полученного ею результата в качестве выходного значения. Динамический выбор предусматривает поиск в коллективе лучшего в некотором смысле эксперта.

Известны алгоритмы, которые позволяют подобрать оптимальное число нейронных сетей, правильно их организовать и обучить для решения задач с заданной точностью.

В работе [1] авторы рассматривают проблему классификации раковых опухолей. Они определяют, является ли нейронная сеть обратного распространения наиболее оптимальным классификатором для определения раковых опухолей, чем rTNM (патологическая классификация, основанная на данных, известных до начала лечения, но дополненных или измененных на основании сведений, полученных при хирургическом вмешательстве или исследовании операционного материала.). Система rTNM уже более 40 лет применяется для прогнозирования рака и основана на 3 компонентах:

- T – распространение первичной опухоли;
- N – отсутствие или наличие метастазов в регионарных лимфатических узлах и степень их поражения;
- M – отсутствие или наличие отдаленных метастазов.

При использовании системы rTNM возникают следующие проблемы:

- недостаточная точность классификации;
- точность не может быть улучшена, т.к. прогнозирующие переменные не могут быть добавлены к модели без увеличения ее сложности, а при увеличении сложности модель становится неприменимой в медицине.

В работе производится сравнение точности прогнозируемых моделей на основе:

- rTNM системы;
- компонентного анализа;
- деревьев регрессии;
- логической регрессии;
- каскадной корреляционной нейронной сети;
- нейронной сети обратного распространения;
- вероятностной нейронной сети.

На основе исследований авторы пришли к выводу, что нейронные сети способны значительно улучшить точность предсказания результата рака по сравнению с rTNM системой путем объединения факторов влияющих на постановку диагноза и обнаружением сложных генетических взаимодействий.

В работах [2] и [3] авторами рассмотрено применение нейронных сетей GMDH (Group Method of Data Handling) в медицине для распознавания изображений. Архитектура нейронной сети данного типа основана на автоматической организации, с использованием эвристического метода самоорганизации. При таком подходе в организации архитектуры сети участвуют только полезные комбинации переменных. Поэтому, нейронные сети, организованные таким образом имеют хорошую способность обобщения, даже если характеристика нелинейной системы очень сложна. В работе [2] приводятся доказательства того, что нейронные сети GMDH-типа – точный и полезный метод для распознавания изображений в медицине. В [3] нейронные сети GMDH-типа применяются для распознавания изображений легких.

В такой сложной области как телемедицина, можно выделить две отдельные подзадачи, например, задача распознавания изображения и задача вывода решения, тогда нейронная сеть и экспертная система могут быть использованы соответственно для решения этих задач.

Распознавание образов значительно упрощает постановку диагноза. Особенно в сфере диагностики злокачественных новообразований, таких как меланома кожи, своевременное выявление которой, позволяет предотвратить возникновение рака кожи.

В работе решается задача классификации образов на три класса – меланома, лентиго, невус.

Невус (naevus: лат. родимое пятно) – пигментированное образование нейроэктодермального происхождения на коже, в состав которого входят невусные клетки, содержащие меланин. Это научное название всем известных родинок (рис. 1).

Меланома – опухоль кожи, которая, как и невусы, возникает из меланоцитов, но относится к категории злокачественных (рис. 2). Специалисты отмечают, что для благоприятного прогноза нужна не только своевременная диагностика, но и выявление так называемых предмеланомных процессов. Далеко

не все невусы имеют риск по малигнизации, т. е. трансформации в меланому, фоном для ее возникновения служат лишь некоторые невусы особых гистологических форм.




Рис. 1. Невус




Рис. 2. Меланома

Соотношение меланомоопасных невусов к меланомонеопасным как 1:10. Клиническая оценка невусов необходима для того, чтобы отличить первый тип невуса от второго. Если у пациента подозревается меланомоопасный вид невуса, то необходимо полное его удаление.

Перечислим несколько признаков, перерождения невуса в меланому:

- исчезновение кожного рисунка на поверхности невуса;
- появление блестящей, глянцевой поверхности невуса;
- появление асимметрии или неправильности очертаний (фестончатости) краев невуса, т.е. изменение его формы;
- горизонтальный рост невуса;
- частичное (неравномерное) или полное изменение окраски невуса-меланомы - появление участков так называемой депигментации;
- изъязвление эпидермиса над невусом-меланомой;
- возникновение дочерних пигментированных или розовых образований (саттелитов) в коже вокруг невуса-меланомы.

Лентиго – плоское равномерно пигментированное пятно от коричнево-бурого до черного цвета. По сравнению с веснушками лентиго темнее и рас-

полагаются более редко; кроме того, их окраска не усиливается и число не возрастает под действием солнечного излучения. Лентиго относят к пигментным невусам (рис. 3).



Рис. 3. Лентиго

Клиническая классификация выделяет 3 формы меланомы.

Происхождение меланом:

- меланомы из невусов;
- лентигомеланомы;
- меланомы "de novo" – образовавшиеся на интактной коже, которые развиваются из отдельных нормальных меланоцитов. Часть из них малопигментна или беспигментна [4].

При постановке диагноза большую роль играет своевременное распознавание пораженной области на ранней стадии, т.е. классификация входного образа.

**Постановка задачи.** Имеются изображения кожных трансформаций. Необходимо определить к какому классу относится то или иное изображение. Для решения задачи предлагается использовать гибридную нейронную сеть.

### Основной раздел

Имеется конечный набор обучающих пар  $\{(X_i, Y_i)\}$ , задающих отображение  $F$  множества  $X$  в множество  $Y$  ( $F: X \rightarrow Y$ ), где  $X = [X_1, X_2 \dots X_k]$  – матрица входных сигналов,  $Y$  – выход ГНС (идентификатор класса).

Процедура обучения заключается в минимизации функционала ошибки

$$E(W) = E[\{X_i, Y_i\}, \hat{F}(X_i, W)], \hat{F}(X_i, W) -$$

значение на выходе НС. Каждая нейронная сеть, входящая в состав ГНС и выполняющая вычисление значения функции  $F(X_i)$  для входного вектора  $X_i$  представляет собой эксперта.

В процессе настройки матрицы весовых коэффициентов  $W$  производится минимизация  $F(W)$ . Обучение ГНС представляет собой обучение с учителем [5].

Для решения задачи распознавания образов предложена гибридная нейронная сеть с однопольной архитектурой экспертов, в которой для комбиниро-

вания результатов экспертов используется сумма ответов всех экспертов.

Требуется определить к какому классу относится входное изображение: лентиго, меланома и невус. Для обучения ГНС входное множество обучающих примеров  $X$  разбивается на три подмножества  $X_1, X_2 \dots X_k$ ,  $k < n$ , ( $k = 3$ ), где  $X_1$  – обучающие пары для классификации лентиго,  $X_2$  – меланомы,  $X_3$  – невус,  $X_i = [X_i^{Tj} \cup X_i^{Ej}]$ ,  $i = 1 \div k$ ,  $1 \leq j \leq k$ ,  $X_i^{Tj}$ ,  $X_i^{Ej}$  – подмножества распознанных и нераспознанных образов  $j$  –  $m$  экспертом соответственно. Каждое обучающее множество включает  $c_i$  примеров. Для каждого из полученных подмножеств строится отображение  $X_i^{Ti} \rightarrow Y_i^{Ti}$ ,  $X_i^{Ei} \rightarrow Y_i^{Ei}$ ,  $i = 1 \div k$ . Каждое из подмножеств  $X_i$  представляет собой репрезентативную выборку обучающих примеров. Блочная диаграмма ГНС представлена на рис. 4.

Каждый эксперт генерирует собственный ответ  $Y_i$  для входного воздействия  $X_i$

$$Y_i = \sum_{l=1}^p Y_i^{Tl} + Y_i^{Ep}, \quad (1)$$

где  $1 \leq p \leq c_i$ .

Рассмотрим процесс разбиения множеств обучающих примеров при обучении НС для распознавания меланомы. На вход Эксперта<sub>1</sub><sup>1</sup> поступают последовательно все обучающие примеры представляющие собой меланому. На выходе эксперта получаем результат классификации. Если Эксперт<sub>1</sub><sup>1</sup> правильно классифицирует входной образ, тогда выход

принимает значение  $Y_1^{T1} = 001$ . Если в процессе обучения Эксперта<sub>1</sub><sup>1</sup> часть примеров не удалось правильно распознать, то они поступают на обучение Эксперту<sub>1</sub><sup>2</sup>. Таким образом, формирование экспертов продолжается до тех пор, пока все обучающие примеры не будут правильно классифицированы. Аналогично осуществляется формирование экспертов для распознавания лентиго и невуса.

Таким образом, если в процессе функционирования только один из выходов НС принимает единичное значение, то классификация прошла успешно, иначе нейронной сети не удалось классифицировать входной образ. Например, если выход принял значение 001, то результатом классификации является меланома, аналогично 010 – лентиго, 100 – невус.

Каждый эксперт представляет собой PNN-сеть (Probabilistic Neural Network) с архитектурой, изображенной на рис. 5.

Функционирование сети описывается следующим образом:

$$z_q = \exp\left[\frac{-D_q}{2\sigma^2}\right], \quad (2)$$

где  $D_q = (X_j - u_j)^T (X_j - u_j)$  – это расстояние между входным вектором  $X_j$  и образцовым вектором  $u_j$  из классифицируемой категории;  $\sigma$  – параметр сглаживания. Функция оценки плотности распределения  $f_j(X_j)$  вычисляется по формуле:

$$f_j(X_j) = \frac{1}{(2\pi)^{C/2} \sigma^C n \sum_{q=1}^n z_q}, \quad (3)$$

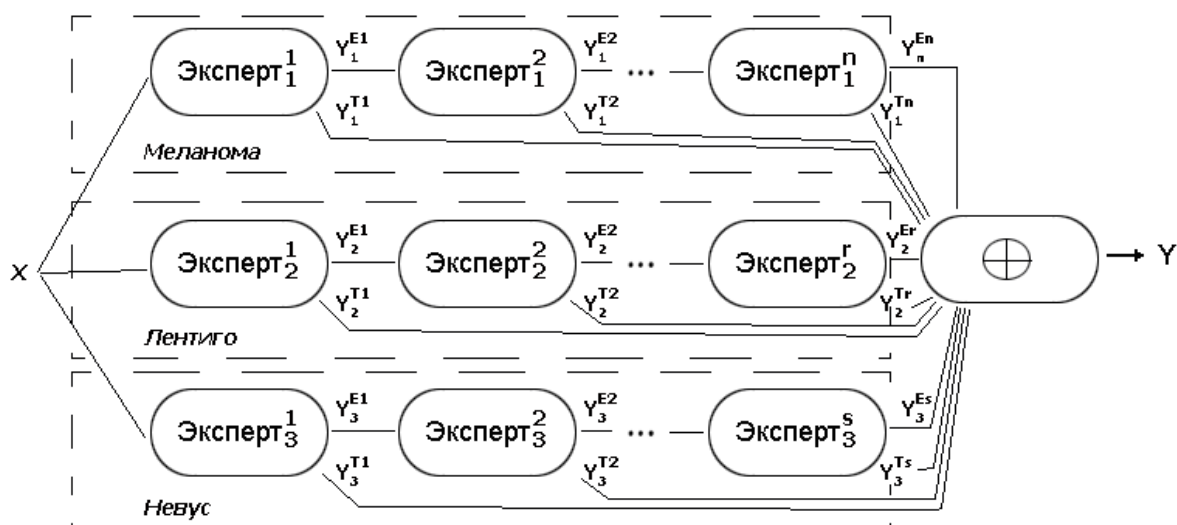


Рис. 4. Блочная диаграмма модели ГН

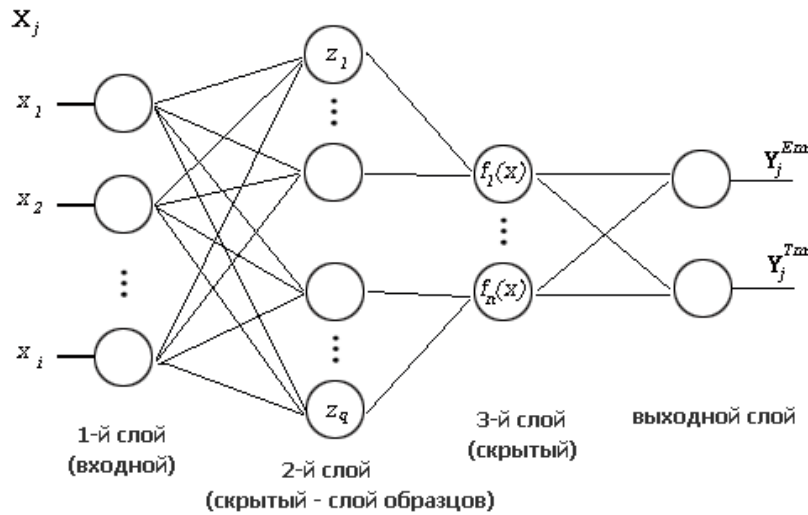


Рис. 5. Архитектура PNN-сети

где  $C = \sum_{i=1}^k c_i$  – количество обучающих пар [6,7].

В процессе тестирования получена оценка ГНС на базе PNN- сети, функционирование которой апробировано на репрезентативной тестовой выборке. Результаты проведенных экспериментов приведены в табл. 1.

Таблица

Результаты тестирования

Номинальный класс	Количество тестовых примеров	Результат распознавания			
		класс			
		1	2	3	4
1	50	49	0	0	1
2	50	0	47	1	2
3	50	0	0	50	0

### Основные результаты и выводы

Научной новизной данной статьи является предложенная гибридная модель на базе вероятностной нейронной сети с суммированием результатов экспертов при определении выходного значения для классификации входных изображений.

Данная модель позволяет:

- значительно снизить вычислительные затраты на обучение гибридной нейронной сети. Снижение затрат достигается за счет того, что каждый эксперт обучается на определенной, заранее выделенной для него, обучающей выборке;
- повысить точность классификации входного образа.

Предлагаемый подход позволит решать широкий класс задач при распознавании образов, например, для облегчения постановки диагноза в телемедицине.

### Список литературы

1. Burke H.B., Rosen D.B., Goodman, P.H. Comparing artificial neural networks to other statistical methods for medical outcome prediction. – *Neural Networks*, 1994. *IEEE World Congress on Computational Intelligence*, 1994 *IEEE International Conference on*, vol. 4. – P. 37-41.
2. Kondo T., Pandya A.S. Medical image recognition by using logistic GMDH-type neural networks – *SICE 2001. Proceedings of the 40th SICE Annual Conference. International Session Papers.* – 240 p.
3. Kondo T., Pandya A.S., Zurada J.M. – *SICE 1999. Proceedings of the 38th SICE Annual Conference. International Session Papers.* – 320 p.
4. Кожные болезни / Гл. ред. А.А. Кубанова. – М.: ГЭОТАР МЕДИЦИНА, 1998. – 340 с.
5. Корнеев В.В., Гареев А.Ф., Васютин С.В., Райх В.В. Базы данных. Интеллектуальная обработка информации. – М.: Издательство Нолидж, 2001. – 360 с.
6. Хайкин С., Нейронные сети: полный курс, 2-е издание. – М.: Издательский дом «Вильямс», 2006. – 240 с.
7. Bride J.S. Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition. – *New York: Springer-Verlag*, 1990. – 350 p.

Поступила в редколлегию 2.02.2007

**Рецензент:** д-р техн. наук, проф. Е.В. Бодянский, Харьковский национальный университет радиоэлектроники, Харьков.