



DOI: <https://doi.org/10.15688/jvolsu1.2016.6.13>

УДК 004.89

ББК 55.6

АЛГОРИТМЫ ПРИНЯТИЯ РЕШЕНИЙ В КОНСУЛЬТАТИВНОЙ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЕ ДИАГНОСТИКИ МОЛОЧНЫХ ЖЕЛЕЗ¹

Андрей Васильевич Зенович

Старший преподаватель кафедры фундаментальной информатики
и оптимального управления,
Волгоградский государственный университет
zenovich@rambler.ru, fiou@volsu.ru
просп. Университетский, 100, 400062 г. Волгоград, Российская Федерация

Виктор Анатольевич Глазунов

Студент института математики и информационных технологий,
Волгоградский государственный университет
borey85@yandex.ru, math@volsu.ru
просп. Университетский, 100, 400062 г. Волгоград, Российская Федерация

Андрей Сергеевич Опарин

Студент института математики и информационных технологий,
Волгоградский государственный университет
androparin@yandex.ru, math@volsu.ru
просп. Университетский, 100, 400062 г. Волгоград, Российская Федерация

Филипп Германович Примаченко

Студент института математики и информационных технологий,
Волгоградский государственный университет
lshadow16@mail.ru, math@volsu.ru
просп. Университетский, 100, 400062 г. Волгоград, Российская Федерация

Аннотация. В последнее время для раннего выявления температурных аномалий молочной железы, являющихся косвенными признаками опухолей,

активно используется метод микроволновой радиотермометрии. Но существующий диагностический комплекс, разработанный на базе этого метода, предназначен для использования врачом-маммологом высокой квалификации, что сужает область применения данного метода и нивелирует его уникальные возможности, особенно связанные с выявлением температурных аномалий на ранних стадиях заболевания. С целью решения указанной проблемы разрабатывается консультативная интеллектуальная система, то есть экспертная система, предлагающая врачу предварительный диагноз и его обоснование на языке, понятном медику.

Работа выполнена в рамках группового проекта, посвященного реализации такой системы. Рассматривается технология создания двух отдельных модулей блока принятия решения проектируемой системы. Данные модули на основе полученного ранее А.Г. Лосевым и В.В. Левшинским набора диагностических признаков реализуют два алгоритма диагностики заболеваний молочной железы. Первый алгоритм проводит диагностику с помощью линейных комбинаций признаков набора, коэффициенты которых подбираются так, чтобы максимизировать эффективность алгоритма. Второй алгоритм основан на использовании нейросетей.

В рамках реализации первого модуля авторами создан алгоритм диагностики на основе параметров, подбираемых генетическими алгоритмами, и выбрана оптимальная конфигурация этих параметров, обеспечившая хороший результат диагностики на тестирующей выборке.

При создании второго модуля авторами реализованы несколько типов нейросетей и проведены многочисленные вычислительные эксперименты с целью подбора оптимальной конфигурации нейросети и алгоритма ее обучения.

Ключевые слова: интеллектуальный анализ данных, микроволновая радиотермометрия, консультативные интеллектуальные системы, маммология, онкология.

Введение

Онкологические заболевания в настоящее время представляет собой медицинскую и социальную проблему чрезвычайной важности. Несмотря на успехи последних лет, достигнутые в диагностике и лечении рака, смертность от онкологических заболеваний остается очень высокой. У женщин самым распространенным видом онкологических заболеваний является рак молочной железы, причем смертность от рака груди у женщин неуклонно растет.

При нынешнем уровне медицины для того, чтобы успешно вылечить опухоль, она должна иметь размер не более 5–7 мм, тогда как средний размер выявляемых на стадии диагностики опухолей в два раза больше (см. [8]). В связи с этим необходима организация периодического (раз в полгода — год) обследования женщин неинвазивными методами, не наносящими вреда их здоровью и позволяющими определить наличие опухоли небольшого размера. Данным требованиям удовлетворяет интенсивно развивающийся в последние годы метод микроволновой радиотермометрии (см., например, [2]).

Основой метода является измерение внутренних и поверхностных температур тканей по интенсивности их теплового излучения. Это позволяет находить температур-

ные аномалии, сопровождающие возникающие опухоли. При этом хорошо выявляются быстрорастущие опухоли, которые с трудом поддаются диагностике другими методами. К сожалению, метод трудно применять при профилактических осмотрах, так как использовать его может только врач-маммолог высокой квалификации.

Решение данной проблемы заключается в создании консультативной интеллектуальной системы, предлагающей врачу общей практики предварительный диагноз и его обоснование на понятном специалисту-медику языке. В данный момент коллективом специалистов ВолГУ проводится создание такой системы, которая сможет информировать медика о найденных температурных аномалиях.

Планируется предусмотреть как возможность автономной работы системы, так и встраивание системы в комплекс РТМ-диагностики.

1. Структура консультативной интеллектуальной системы

На рисунке 1 приведена диаграмма компонентов проектируемой системы. Опишем кратко функции основных блоков системы. Блок ввода обеспечивает сбор информации о пациенте и его температурных данных. Блок хранения представляет собой базу данных, из которой врач при необходимости может черпать информацию о предыдущих обследованиях пациента. Блок вывода обеспечивает описание признаков заболевания на языке, понятном врачу общей практики. Блок управления организует взаимодействие отдельных частей консультативной информационной системы между собой.

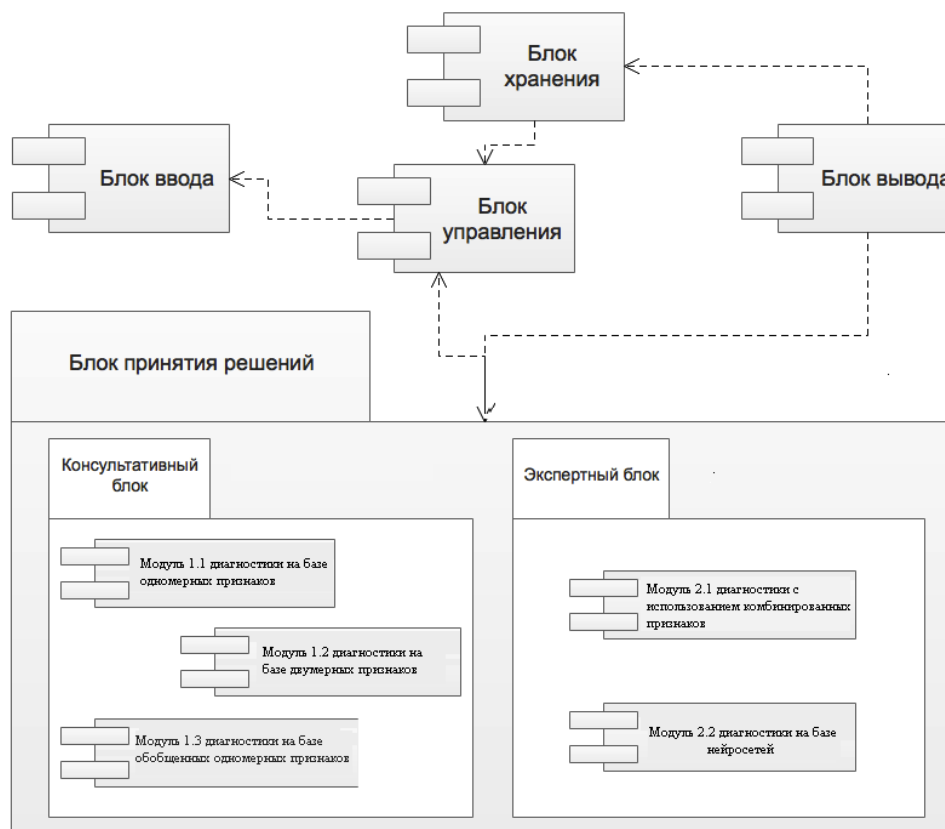


Рис. 1. Диаграмма компонентов консультационно-диагностической системы

Сердцем системы является блок принятия решений, состоящий из пяти независимых модулей, которые реализуют различные алгоритмы диагностики. Решение о предварительном диагнозе принимается методом взвешенного голосования. Три модуля, реализующие алгоритмы, входящие в консультативный блок, наряду с постановкой диагноза выдают медику информацию об аномалиях, послуживших основанием для такого решения. Два оставшихся модуля, входящие в экспертный блок, участвуют в постановке диагноза, но никакой дополнительной информации медику предоставить не могут. Такая архитектура блока принятия решения связана с тем, что алгоритмы, реализованные в двух последних модулях, достаточно хорошо диагностируют пациентов, но принимают решения на основе методов, которые с трудом поддаются содержательной медицинской интерпретации.

Модули 1.1–1.3 реализуют алгоритмы диагностики на основе набора характеристических и высокоинформативных признаков. В связи с тем, что данные признаки сами по себе могут быть интересны медику, предусмотрена возможность вывода их списка с соответствующими пояснениями для врача. Модуль 2.1 реализует алгоритм диагностики на базе линейных комбинаций таких признаков. При этом коэффициенты данных комбинаций подбираются генетическими алгоритмами с целью увеличения комбинированной информативности. Модуль 2.2 проводит диагностику с применением нейросетей.

2. Качественные признаки заболеваний молочной железы. Моделирующие функции

Диагностика пациентки методом комбинированной термометрии начинается с фиксации 44 кожных (диапазон ИК) и глубинных (диапазон РТМ) температур с помощью измерительного комплекса РТМ-01-РЭС. Схема измерений приведена на рисунке 2. Измерения проводятся в сосках правой и левой молочных желез, в восьми точках на окружности каждой железы, в точках левой и правой аксиллярной области, а также в двух опорных точках в центре грудной клетки. Так как измерения в каждой точке проводятся в двух диапазонах, каждому пациенту ставится в соответствие вектор из 44 температур.

На основе анализа полученных температур маммологами выявлены следующие качественные признаки рака молочной железы ([2; 7]):

- повышенная величина термоасимметрии между одноименными точками молочных желез;
- повышенный разброс температур между отдельными точками в пораженной молочной железе;
- повышенная дисперсия разности температур между железами;
- разница температур сосков;
- повышенная температура соска в пораженной молочной железе по сравнению со средней температурой молочной железы с учетом возрастных изменений температуры;
- соотношение кожной и глубинной температур и некоторые другие.

По каждому качественному признаку онкологического заболевания можно построить набор моделирующих функций от температур, значение которых количественно характеризует признак.

В качестве примера приведем несколько функций, моделирующих повышенную величину термоасимметрии между одноименными точками молочных желез.

1) Повышенная разница температур сосков правой и левой молочных желез:

$$|t_{0,пр} - t_{0,л}|.$$

2) Повышенное среднеквадратичное значение разностей температур между одноименными точками правой и левой молочных желез:

$$\sqrt{\sum_{i=0}^8 \frac{(t_{i,пр} - t_{i,л})^2}{9}}.$$

3) Повышенная разница температур в отдельных точках молочной железы

$$|t_{i,пр} - t_{i,л}|,$$

где $i = 1, 2, \dots, 8$.

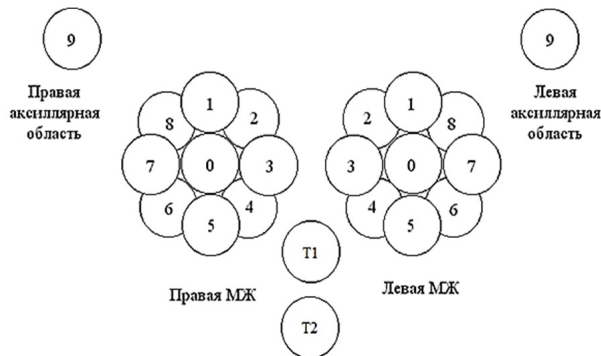


Рис. 2. Схема обследования молочных желез

Очевидно, что набор функций, моделирующий определенный качественный признак, может быть достаточно большим. Данные функции можно использовать для проведения диагностики непосредственно (например, подавая значение соответствующей функции на один из входов нейросети). Но лучше вместо функции рассматривать пару, состоящую из моделирующей функции и некоторого подмножества X ее множества значений. Будем считать, что если значение моделирующей функции некоторого пациента не принадлежит X , то это усиливает вероятность того, что пациент болен. Для оптимального подбора областей X необходим анализ поведения моделирующей функции на обучающей выборке.

Обучающая и тестовая выборка для задачи диагностики сформирована на основе результатов обследования пациентов онкологических центров (см.: [6; 10]). В обучающую выборку входят термометрические данные 74 здоровых и 302 больных пациентов. Можно представить обучающую выборку в виде матрицы:

$$\begin{pmatrix} t_0^1 & \dots & t_{43}^1 \\ \vdots & \ddots & \vdots \\ t_0^k & \dots & t_{43}^k \\ t_0^{k+1} & \dots & t_{43}^{k+1} \\ \vdots & \ddots & \vdots \\ t_0^n & \dots & t_{43}^n \end{pmatrix},$$

где t_i^j при $j = 1, \dots, k$ — температуры здоровых пациентов; t_i^j при $j = k + 1, \dots, n$ — температуры больных пациентов.

Дадим точное определение многомерного характеристического признака [4]. Пусть $f^q = f^q(t_0, t_1, \dots, t_{43})$ — q -я моделирующая функция, рассматриваемая на множестве векторов $\Omega = \{(t_0^j, \dots, t_{43}^j)\}$, где $j = 1, \dots, n$. Обозначим $f_j^q = f^q(\vec{t}_j)$, где $\vec{t}_j = (t_0^j, t_1^j, \dots, t_{43}^j)$, $j = 1, \dots, n$. Рассмотрим вектор-функции $f = (f^{q_1}, \dots, f^{q_m})$.

Характеристическим признаком будем называть пару (f, X) , где $X \subset R^m$ — максимальное (в каком-то смысле) подмножество области изменения вектор-функции f такое, что $(f_j^{q_1}, \dots, f_j^{q_m}) \in X$ для некоторых $j = k + 1, \dots, n$ и $(f_j^{q_1}, \dots, f_j^{q_m}) \in R^m \setminus X$ для всех $j = 1, \dots, k$.

Таким образом, если характеристический признак выполнен для какого-то пациента, то этот пациент болен.

Характеристические признаки обнаруживают только серьезные аномалии температурных полей, поэтому проводить диагностику только с помощью характеристических признаков не удастся. Введем понятие высокоинформативного признака.

Высокоинформативным признаком будем называть тройку (f, V, X) , где f — вектор-функция, моделирующая поведение температурных полей; $V = I(S, f, X)$ — информативность, или вес признака; X — область изменения вектор-функции. Информативность — это количественный параметр, определяющий, насколько хорошо закономерность описывает различия между искомой и отделяемой группами. В качестве $V = I(S, f, X)$ использовались следующие характеристики.

1) Статистическая информативность:

$$SI(f^q, X) = -\ln \frac{C_k^h C_{n-k}^s}{C_n^{h+s}}, \quad (1)$$

где h обозначено количество молочных желез класса «Здоровые», для которых $f \in X$, а s — количество молочных желез класса «Больные», для которых $f \in X$.

2) Эвристическая информативность:

$$HI(f^q, X) = \frac{\max(\frac{k}{h}, \frac{n-k}{s})}{\min(\frac{k}{h}, \frac{n-k}{s})}. \quad (2)$$

3) Комбинированная информативность:

$$CI = \sqrt{SI \cdot HI}. \quad (3)$$

Данные виды информативностей использовались ранее в диагностике заболеваний нижних конечностей [9] и онкологических заболеваний молочных желез [10].

В модулях 1.1–1.3 блока принятия решений для диагностики используются одномерные и двумерные характеристические и высокоинформативные признаки. Технология получения и минимизации наборов таких признаков изложена в [4]. Авторы выражают благодарность А.Г. Лосеву и В.В. Левшинскому за предоставленный минимизированный набор одномерных признаков, которые используются в качестве исходных при разработке модулей экспертного блока. В модуле 2.1 на базе набора одномерных признаков строится новый набор комбинированных признаков, которые являются линейными комбинациями исходных. В некоторых алгоритмах диагностики, реализуемых при разработке модуля 2.2, на входы нейронной сети подаются значения моделирующих функций минимизированного набора.

3. Диагностика с применением комбинированных признаков

Двумя главными параметрами, по которым можно оценивать качество алгоритма медицинской диагностики, являются специфичность P (доля верно диагностированных здоровых) и чувствительность C (доля верно диагностированных больных). Если мы хотим добиться, чтобы обе эти величины имели большие значения, в качестве критерия эффективности алгоритма логично рассматривать их среднее геометрическое $\Delta = \sqrt{P \cdot C}$ (см., например, [10]).

Технология построения комбинированных признаков подробно описана в [3]. Комбинированные признаки представляют собой линейные комбинации одномерных признаков из минимизирующего набора. Коэффициенты этих линейных комбинаций подбираются генетическими алгоритмами таким образом, чтобы признак обладал наибольшей информативностью. Как показано в [3], можно комбинировать моделирующие функции, описывающие один медицинский признак, но лучшие результаты дают комбинации моделирующих функций различных медицинских признаков.

На рисунке 3 приведена схема алгоритма диагностики с помощью набора комбинированных признаков (в дальнейшем будем его называть алгоритмом с весами). Этот алгоритм является модификацией алгоритма без весов из [9] и состоит из следующих шагов.

Шаг 1. Применяем характеристические признаки: если хотя бы один из признаков выполнен, то молочную железу относим к классу «Больные». В противном случае переходим к шагу 2.

Шаг 2. Каждой молочной железе приписываем число

$$S = \sum k_i \cdot c_i, \quad (4)$$

где k_i — весовые коэффициенты; c_i — комбинированные информативности. Суммирование осуществляется по тем признакам, которые выполнены для данного пациента. Переходим к шагу 3.

Шаг 3. Если S больше некоторого порогового значения S_0 , то молочная железа относится к классу «Больные», иначе к классу «Здоровые».

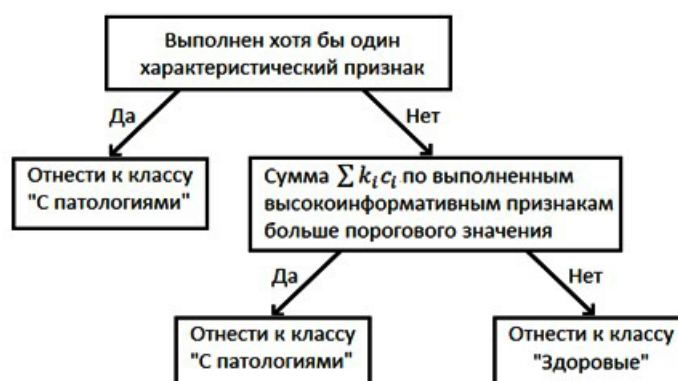


Рис. 3. Общая схема алгоритма диагностики

Весовые коэффициенты k_i и значение S_0 подбираются так, чтобы алгоритм достигал наибольшего значения Δ на обучающей выборке.

Из-за того что количество признаков, используемых для диагностики, достаточно велико, для поиска применяется стандартный генетический алгоритм (Алг1).

Назовем «особью» набор, состоящий из коэффициентов k_i и порогового значения S_0 , которое обеспечивает наибольшее значение Δ . Функцией приспособленности особи будем считать $f = \Delta$. Нормируя функции приспособленности «особей», найдем вероятность k -й особи стать родителем:

$$P_k = \frac{f_k}{\sum_{i=1}^n f_i}, \quad (5)$$

где n — число особей в поколении; f_i — функция приспособленности i -й особи.

Далее формируем поколение «особей» и запускаем эволюционный процесс, выбирая родителей с соответствующими вероятностями. Между родителями устраиваем поэлементное скрещивание, потомок получает каждый свой ген от одного из родителей с равной вероятностью. В процессе скрещивания предусмотрены мутации, при которых один или несколько генов меняются случайным образом. Вероятность мутации при скрещивании — 3 %.

В улучшенной версии алгоритма (Алг2) предприняты усилия для увеличения генетического разнообразия особей: были использованы 2 вида скрещивания, повышена вероятность мутаций, которые стали затрагивать сразу несколько генов, количество раз, которое каждая родительская пара может принять участие в скрещивании, было ограничено. Также осуществлялась параллельная эволюция нескольких популяций с периодическим обменом особями между ними.

Анализировалась возможность последовательного использования для диагностики двух алгоритмов (алгоритма с весами и алгоритма без весов из [1]). Вычислительные эксперименты показали, что новый алгоритм верно диагностирует всех тех, кого правильно классифицирует исходный, следовательно, последовательное применение не даст изменений. Увеличения качества диагностики можно достичь, если сделать так, чтобы новый алгоритм верно диагностировал тех пациентов, которые неверно диагностирует алгоритм без весов. Этого можно добиться изменением функции приспособленности особи. Пусть C' — чувствительность алгоритма с весами по молочным железам класса «Больные», которые неправильно диагностирует алгоритм без весов. Тогда изменим функцию приспособленности следующим образом: $f = (\Delta + C')/2$.

Обозначим данную версию алгоритма Алг3S. Вместо чувствительности можно также использовать специфичность или точность (доля верно диагностированных молочных желез). В первом случае версия алгоритма называется Алг3Н, во втором — Алг3All. В таблице 1 показаны результаты проверки работы различных версий алгоритма.

На основании полученных экспериментальных данных принято решение в качестве основного алгоритма диагностики использовать Алг3Н.

4. Модуль постановки диагноза на основе нейросетей

Для построения диагностирующей нейронной сети необходимо выбрать архитектуру сети, сформировать обучающее и тестовое множество и подобрать алгоритм обучения. С целью оптимального подбора данных параметров были реализованы на языке C++ несколько различных вариантов нейронных сетей, с которыми проводились соответствующие вычислительные эксперименты.

Таблица 1

Проверка работы различных версий алгоритма

Алгоритм	Обучающая выборка			Тестовая выборка		
	$P, \%$	$C, \%$	$\Delta, \%$	$P, \%$	$C, \%$	$\Delta, \%$
Без весов	93,2	68,9	80,1	39,2	62,7	49,6
Алг1	93,2	73,8	83,0	35,1	68,0	48,9
Алг2	93,2	73,5	82,8	36,5	68,0	49,8
Алг3Н	98,6	68,9	82,4	74,3	62,7	68,3
Алг3S	93,2	96,4	94,8	39,2	93,0	60,4
Алг3All	93,3	96,3	94,8	39,2	93,7	60,6

Исследовались показатели многослойной полносвязной нейронной сети с двумя нейронами на выходе, подтвердившей свою применимость в задачах диагностики в медицине (рис. 4). В численных экспериментах варьировалось число скрытых слоев.

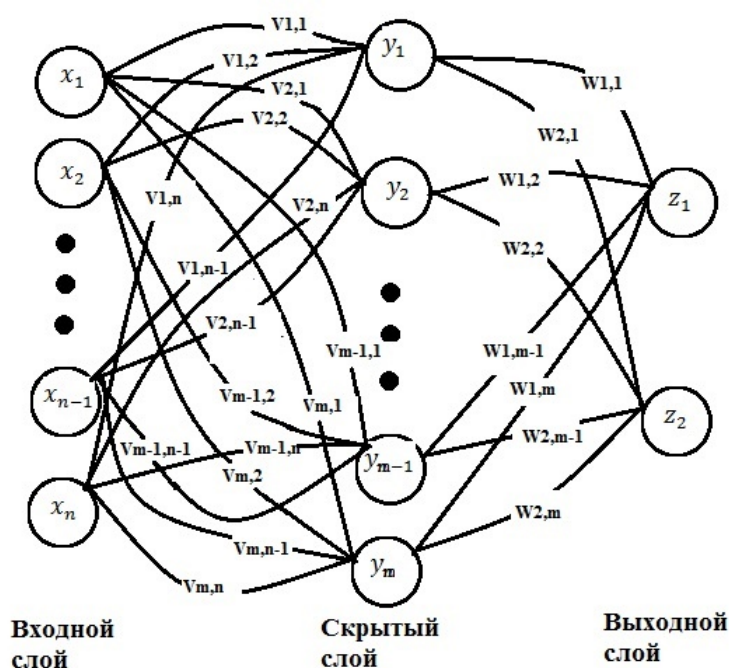


Рис. 4. Многослойная полносвязная нейронная сеть

В качестве альтернативы была опробована нейронная сеть каскадной корреляции, способная в процессе обучения самостоятельно задавать нужное количество нейронов на скрытом слое. Алгоритм построения подобной сети имеет следующий вид:

Шаг 0: построение и обучение стандартного персептрона (см. рис. 5).

Шаг 1: добавление скрытого нейрона и соединение его со входным слоем и всеми скрытыми нейронами, добавленными до этого. Входные веса нейрона настраиваются так, чтобы была достигнута максимальная корреляция между нейроном-кандидатом и ошибкой нейронной сети.

Шаг 2: соединение нейрона-кандидата с выходным слоем и обучение весов выходного слоя. После шагов 1–3 нейронная сеть имеет следующий вид (см. рис. 6).

Шаг 3: если достигнут критерий останова, то добавление скрытых нейронов заканчивается и обучение нейронной сети считается завершенным, иначе происходит возврат

к шагу 1. В качестве критерия останова проводилась проверка точности работы нейронной сети на сторонней (верификационной), не участвующей в обучении, выборке. Если точность диагностики по данной выборке начинала снижаться, обучение заканчивалось.

Были апробированы три различных алгоритма обучения нейронной сети: алгоритм обратного распространения ошибки, метод конфигураций Хука — Дживса и метод имитации отжига (см.: [11, с. 197–198, 228–229]).




Рис. 5. Персептрон без скрытых слоев




Рис. 6. Нейронная сеть каскадной корреляции с 1 скрытым нейроном

На вход нейронной сети подавались различные векторы входных параметров. В результате вычислительных экспериментов были сформированы два варианта входных векторов, дающие хорошие результаты на тестовой выборке. В обоих вариантах на один из нейронов входного слоя подавалась информация о наличии боли у пациента. В первом варианте (вектор температур) на оставшиеся входы подавались 44 температуры. Во втором (вектор функций) на вход подавались значения моделирующих функций признаков из минимизированного набора.

Для ускорения процесса обучения применялись методы распараллеливания вычислений. В процессе обучения одновременно участвовало порядка 30 нейронных сетей одной архитектуры, но с разными начальными весами. Как только все нейронные сети обучались, из их числа выбиралась та, что показала лучшие результаты при обучении. В дальнейшем данная сеть участвовала в тестировании.

В таблице 2 показаны результаты работы исследованных нейросетей на тестовой выборке.

Таблица 2

Результаты работы сетей различного вида на тестовом множестве

Входной вектор	Алгоритм обучения	Архитектура	Специфичность, %	Чувствительность, %	Точность, %
Вектор температур	Обратное распространение	Многослойный персептрон	100	32	56
Вектор значений функций	Обратное распространение	Многослойный персептрон с 1 скрытым слоем	62	67	64
Вектор значений функций	Обратное распространение	Многослойный персептрон с 10 скрытыми слоями	60	52	56
Вектор температур	Конфигурации Хука – Дживса	Многослойный персептрон с 1 скрытым слоем	47	49	48
Вектор значений функций	Конфигурации Хука – Дживса	Многослойный персептрон с 1 скрытым слоем	70	74	72
Вектор температур	Имитация отжига	Многослойный персептрон с 1 скрытым слоем	70	69	69,5
Вектор температур	Имитация отжига	Многослойный персептрон с 10 скрытыми слоями	70	52	61
Вектор температур	Имитация отжига	Каскадная сеть	79	83	81
Вектор значений функций	Имитация отжига	Многослойный персептрон с 1 скрытым слоем	72	74	73

Анализ данных результатов позволяет сделать вывод, что максимальная эффективность диагностики достигается при использовании нейронной сети каскадной корреляции, обученной методами имитации отжига на температурных данных пациента.

ПРИМЕЧАНИЕ

¹ Работа выполнена при финансовой поддержке гранта РФФИ и АВО (проект № 15-47-02475-р_поволжье_а).

СПИСОК ЛИТЕРАТУРЫ

1. Анисимова, Е. В. Интеллектуальный анализ данных и алгоритмы классификации в диагностике венозных заболеваний по данным комбинированной термометрии : автореф. дис. ... канд. техн. наук / Анисимова Екатерина Вячеславовна. — Волгоград, 2013. — 16 с.
2. Веснин, С. Г. Современная микроволновая радиотермометрия молочных желез / С. Г. Веснин, А. М. Каплан, Р. С. Авакян // Медицинский альманах. — 2008. — № 3. — С. 82–87.

3. Глазунов, В. А. Генетические алгоритмы определения высокоинформативных признаков заболеваний молочных желез / В. А. Глазунов, А. В. Зенович, А. Г. Лосев // Вестник Волгоградского государственного университета. Серия 1, Математика. Физика. — 2015. — № 5 (30). — С. 72–83.
4. Интеллектуальный анализ многомерных термометрических данных в медицинской диагностике / А. Г. Лосев, А. В. Зенович, О. А. Бочкарев, В. В. Левшинский // Вестник Волгоградского государственного университета. Серия 1, Математика. Физика. — 2016. — № 5 (36). — С. 149–160.
5. Кобринский, Б. А. Консультативные интеллектуальные медицинские системы: классификация, принципы построения, эффективность / Б. А. Кобринский // Врач и информационные технологии. — 2008. — № 2. — С. 38–47.
6. Лосев, А. Г. О взаимосвязи некоторых признаков РТМ-диагностики заболеваний молочных желез / А. Г. Лосев, Е. А. Мазепа, Х. М. Сулейманова // Вестник Волгоградского государственного университета. Серия 1, Математика. Физика. — 2015. — № 4 (29). — С. 35–51.
7. Лосев, А. Г. О некоторых характерных признаках в диагностике патологии молочных желез по данным микроволновой радиотермометрии / А. Г. Лосев, Е. А. Мазепа, Т. В. Замечник // Современные проблемы науки и образования. — 2014. — № 6. — С. 254–261.
8. Моисеенко, В. М. Кинетические особенности роста рака молочной железы и их значение для раннего выявления опухоли / В. М. Моисеенко, В. Ф. Семиглазов // Маммология. — 1997. — № 3. — С. 3–11.
9. О некоторых характерных признаках в диагностике заболеваний нижних конечностей методом комбинированной термографии / Е. В. Анисимова, Т. В. Замечник, А. Г. Лосев, Е. А. Мазепа // Вестник новых медицинских технологий. — 2011. — № 18 (2). — С. 329–330.
10. Проблемы измерения и моделирования тепловых и радиационных полей в биотканях: анализ данных микроволновой радиотермометрии / А. Г. Лосев, А. В. Хоперсков, А. С. Астахов, Х. М. Сулейманова // Вестник Волгоградского государственного университета. Серия 1, Математика. Физика. — 2015. — № 6 (31). — С. 31–71.
11. Хайкин, С. Нейронные сети. Полный курс / С. Хайкин. — М. : Вильямс, 2006. — 1103 с.

REFERENCES

1. Anisimova E.V. *Intellectualnyy analiz dannykh i algoritmy klassifikatsii v diagnostike venoznykh zbolevaniy po dannym kombinirovannoy termometrii: avtoref. dis. ... kand. tekhn. nauk* [Data Mining and Classification Algorithms in the Diagnosis of Venous Diseases According to the Combination of Thermometry. Abstract of Diss. Cand. of Technical Sciences]. Volgograd, 2013. 16 p.
2. Vesnin S.G., Kaplan A.M., Avakyan R.S. *Sovremennaya mikrovolnovaya radiotermometriya molochnykh zhelez* [Modern Microwave Radiometry of Breast]. *Meditinskiy almanakh*, 2008, no. 3, pp. 82-87.
3. Glazunov V.A., Zenovich A.V., Losev A.G. *Geneticheskie algoritmy opredeleniya vysokoinformativnykh priznakov zbolevaniy molochnykh zhelez* [Genetic Algorithms for Determining Highly Informative Signs of Breast Diseases]. *Vestnik Volgogradskogo gosudarstvennogo universiteta. Seriya 1, Matematika. Fizika* [Science Journal of Volgograd State University. Mathematics. Physics], 2015, no. 5 (30), pp. 72-83.
4. Losev A.G., Zenovich A.V., Bochkarev O.A., Levshinskiy V.V. *Intellectualnyy analiz mnogomernykh termometricheskikh dannykh v meditsinskoj diagnostike* [Multidimensional Thermometric Data Mining in Medical Diagnostics]. *Vestnik Volgogradskogo gosudarstvennogo universiteta. Seriya 1, Matematika. Fizika* [Science Journal of Volgograd State University. Mathematics. Physics], 2016, no. 5 (36), pp. 149-160.

5. Kobrinskiy B.A. Konsultativnye intellektualnye meditsinskie sistemy: klassifikatsiya, printsipy postroeniya, effektivnost [Consulting Intelligent Medical Systems: Classification, Principles of Construction, Efficiency]. *Vrach i informatsionnye tekhnologii*, 2008, no. 2, pp. 38-47.
6. Losev A.G., Mazepa E.A., Suleymanova Kh.M. O vzaimosvyazi nekotorykh priznakov RTM-diagnostiki zabolevaniy molochnykh zhelez [The Relationship Between Some Signs of RTM- Diagnosis of Breast Diseases]. *Vestnik Volgogradskogo gosudarstvennogo universiteta. Seriya 1, Matematika. Fizika* [Science Journal of Volgograd State University. Mathematics. Physics], 2015, no. 4 (29), pp. 35-51.
7. Losev A.G., Mazepa E.A., Zamechnik T.V. O nekotorykh kharakternykh priznakakh v diagnostike patologii molochnykh zhelez po dannym mikrovolnovoy radiotermometrii [Some Typical Symptoms in the Diagnosis of Breast Pathology According Microwave Radiometry]. *Sovremennye problemy nauki i obrazovaniya*, 2014, no. 6, pp. 254-261.
8. Moiseenko V.M., Semiglazov V.F. Kineticheskie osobennosti rosta raka molochnoy zhelezy i ikh znachenie dlya rannego vyyavleniya opukholi [Kinetics of Growth Breast Cancer and Their Significance for the Early Detection of Tumors]. *Mammologiya*, 1997, no. 3, pp. 3-11.
9. Anisimova E.V., Zamechnik T.V., Losev A.G., Mazepa E.A. O nekotorykh kharakternykh priznakakh v diagnostike zabolevaniy nizhnikh konechnostey metodom kombinirovannoy termografii [On Some Characteristic Features in the Diagnosis of Diseases of the Lower Extremities by a Combined Thermography]. *Vestnik novykh meditsinskikh tekhnologiy*, 2011, no. 18 (2), pp. 329-330.
10. Losev A.G., Khoperskov A.V., Astakhov A.S., Suleymanova Kh.M. Problemy izmereniya i modelirovaniya teplovykh i radiatsionnykh poley v biotkanyakh: analiz dannykh mikrovolnovoy radiotermometrii [Problems of Measurement and Modeling of Thermal and Radiation Fields in Biological Tissues: Analysis of Microwave Thermometry Data]. *Vestnik Volgogradskogo gosudarstvennogo universiteta. Seriya 1, Matematika. Fizika* [Science Journal of Volgograd State University. Mathematics. Physics], 2015, no. 6 (31), pp. 31-71.
11. Khaykin S. *Neyronnye seti. Polnyy kurs* [Neural Network. Full Course]. Moscow, Vilyams Publ., 2006. 1103 p.

ALGORITHMS OF DECISION-MAKING IN INTELLIGENT ADVISORY SYSTEM FOR DIAGNOSTICS OF THE MAMMARY GLANDS

Andrey Vasilyevich Zenovich

Senior Lecturer, Department of Fundamental Computer Science and Optimal Control,
Volgograd State University
zenovich@rambler.ru, fiou@volsu.ru
Prosp. Universitetsky, 100, 400062 Volgograd, Russian Federation

Viktor Anatolyevich Glazunov

Student, Institute of Mathematics and Information Technologies,
Volgograd State University
borey85@yandex.ru, math@volsu.ru
Prosp. Universitetsky, 100, 400062 Volgograd, Russian Federation

Andrey Sergeevich Oparin

Student, Institute of Mathematics and Information Technologies,
Volgograd State University
andreoparin@yandex.ru, math@volsu.ru
Prosp. Universitetsky, 100, 400062 Volgograd, Russian Federation

Filipp Germanovich Primachenko

Student, Institute of Mathematics and Information Technologies,
Volgograd State University
lshadow16@mail.ru, math@volsu.ru
Prosp. Universitetsky, 100, 400062 Volgograd, Russian Federation

Abstract. Recently, for early detection of the temperature abnormalities in breast, that are indirect signs of tumors, specialists widely use the method of microwave radiometry. But the current diagnostic system developed on the basis of this method is designed for use by physician-mammologist with high qualifications, which narrows the scope of this method, and eliminates its unique features, especially those related to the identification of temperature anomalies in the early stages of the disease. To solve this problem we are developing intelligent advisory system, i.e. Expert System, that offers physicians a preliminary diagnosis and its rationale in a language understood by the physician.

Our work is the group project on the implementation of such a system. We consider the technology of the creation of two separate modules for decision-making subsystem of the designed system. These modules are based on a previously obtained by A.G. Losev and V.V. Levshinsky set of diagnostic features and implemented two algorithms for diagnosis of breast diseases. The first algorithm diagnoses using linear combinations of a set of signs, the coefficients of which are chosen to maximize the efficiency of the algorithm. The second algorithm is based on the use of neural networks.

As a part of the first module we established the diagnosis algorithm based on the parameters obtained by genetic algorithms and we adjust the optimal configuration of these settings to provide a good diagnostic result on the test sample.

When creating the second module we implemented several types of neural networks and conducted numerous computational experiments in order to select the optimal configuration of the neural network and its training algorithm.

Key words: data mining, microwave radiometry, intelligent advisory systems, mammalogy, oncology.