

Диагностика хронического пылевого бронхита по данным акустической спирометрии с применением блочных нейронных сетей

А.В. Хомич*, И.В. Степанян**, А.В. Карпишук**

* Сибирский Государственный Технологический Университет

** Московский Государственный Горный Университет

supremum76@rambler.ru, webmaster@sirsensor.com, al_phoenix@mail.ru

Поступила в редколлегию 31.10.2005

Аннотация—В последние десятилетия интенсивно развивается прикладная область математики, специализирующаяся на искусственных нейронных сетях (ИНС). ИНС является упрощенной моделью мозга и представляет собой новую парадигму развития теории распознавания образов, аппроксимации функционалов, прогнозирования и классификации. ИНС широко и успешно применяются в решении трудно формализуемых задач, в том числе медицинских [3]. В работе описывается нейросетевая технология экспресс-диагностирования хронического пылевого бронхита при помощи акустического спироанализатора. Диагноз ставится на основе данных, полученных методами акустической спирометрии. Для диагностирования используются многослойные блочные нейронные сети с учителем.

1. ВВЕДЕНИЕ

Для выявления признаков профессиональных заболеваний органов дыхания у горнорабочих на кафедре Электротехники Московского Государственного Горного Университета был разработан акустический спироанализатор, датчик которого представляет собой цилиндрический волновод-воздуховод с вмонтированными в стенки пьезоэлектрическими кольцевыми электроакустическими преобразователями. Волновод помещают в поток таким образом, чтобы его ось совпадала с направлением потока, преобразователи попеременно включаются как источник и приемник акустической волны, и по разности фаз акустических сигналов, распространяющихся по потоку и против потока, определяется скорость потока. Спироанализатор измеряет скорость воздушного потока в диапазоне 0,1–1,0 м/с с погрешностью не более 5 %, и в диапазоне 1,0–20,0 м/с с погрешностью не более 1 % [1]. Поскольку прибор не создает препятствий измеряемому потоку и безынерционен, на основании данных измерений можно построить спектры дыхательных расходов с высокой точностью. Эти спектры несут в себе информацию о характере поражения органов дыхания.

С помощью прибора было обследовано 90 человек, среди которых 44 имеют диагноз “хронический пылевой бронхит” различной степени тяжести и было

получено несколько десятков кривых форсированного выдоха. Анализ кривых показал, что в высокочастотной области спектра выдоха содержится информация, требующая дополнительного исследования.

Идея предлагаемого подхода экспресс-диагностирования хронического пылевого бронхита состоит в том, чтобы классифицировать спектральные паттерны выдоха по заведомо установленным нарушениям и обучить нейронную сеть выявлять эти признаки. Полученная нейронная сеть может быть применена к диагностике пылевого бронхита на ранней стадии развития.



Рис. 1. Акустический спироанализатор.

2. ПОСТАНОВКА ЗАДАЧИ

Известно, что спирограмма форсированного выдоха при помощи двух интегральных показателей и их отношения (ФЖЕЛ, ОВФ1, ОВФ1%) позволяет диагностировать наличие нарушений бронхиальной проходимости, к которым относится хронический пылевой бронхит, имеющих у обследуемых больных. Акустический спироанализатор позволяет измерить не только эти интегральные показатели, но и спектр изменения объемной скорости форсированного выдоха. Прибор позволяет строить эти спектры в диапазоне частот от 0 до 150 Гц. Для применения нейронной сети каждый спектр кодируется в виде матрицы-строки состоящей из 250 элементов, таким образом, исходные данные представляют собой набор векторов в 250-мерном пространстве.

Каждому вектору сопоставлен класс (диагноз), к которому он принадлежит. Задачей является обучение нейронной сети на множестве векторов, являющихся обучающим множеством, сопоставленных соответствующим классам. Поскольку исходных данных явно не достаточно для исследования всех представленных профессиональных заболеваний (различные степени тяжести хронического пылевого бронхита), спектры были поделены условно на два класса: “здоровые (признаков пылевого бронхита не обнаружено)” и “больные (признаки пылевого бронхита обнаружены)”. Для решения задачи диагностики используются многослойные блочные сети с учителем.

3. ОПИСАНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ

Для описания алгоритмов и устройств в нейроинформатике выработана специальная “схемотехника”, в которой элементарные устройства – сумматоры, синапсы, нейроны и т.п. объединяются в сети, предназначенные для решения задач [2]. Адаптивный сумматор вычисляет скалярное произведение вектора входного сигнала x на вектор параметров α . На схемах будем обозначать его так, как показано на рис. 2. Адаптивным называем его из-за наличия вектора настраиваемых параметров α . Для многих задач полезно иметь неоднородную линейную функцию выходных сигналов. Ее вычисление также можно представить с помощью адаптивного сумматора, имеющего $n+1$ вход и получающего на 0-й вход постоянный единичный сигнал, который часто называют смещением (рис. 3).




Fig. 2. Адаптивный сумматор.




Fig. 3. Неоднородный адаптивный сумматор.




Fig. 4. Нелинейный преобразователь сигнала.




Fig. 5. Точка ветвления.

Нелинейный преобразователь сигнала изображен на рис. 4. Он получает скалярный входной сигнал x и переводит его в $\varphi(x)$. Точка ветвления служит для рассылки одного сигнала по нескольким адресам (рис. 5). Она получает скалярный входной сигнал x и передает его всем своим выходам. Формальный нейрон составлен из входного сумматора, нелинейного преобразователя и точки ветвления на выходе (рис. 7). Линейная связь синапс отдельно от сумматоров не встречается, однако для некоторых рассуждений бывает удобно выделить этот элемент (рис. 6). Он умножает входной сигнал x на “вес синапса” α . Также бывает полезно “присоединить” связи не к входному сумматору, а к точке ветвления. В результате получаем элемент, двойственный адаптивному сумматору и называемый “выходная звезда”. Его выходные связи производят умножение сигнала на свои веса.

В нейроинформатике важный класс архитектур ИНС составляют слоистые нейронные сети [2][3]. Нейроны расположены в нескольких слоях (рис. 8). Нейроны первого слоя получают входные сигналы, преобразуют их и через точки ветвления передают нейронам второго слоя. Далее срабатывает второй слой и т.д. до k -го слоя, который выдает выходные сигналы. Если не оговорено противное, то каждый выходной сигнал i -го слоя подается на вход всех нейронов $i+1$ -го. Число нейронов в каждом слое может быть любым и никак заранее не связано с количеством нейронов в других слоях. Общепринятый способ подачи входных сигналов заключается в том, что все нейроны первого слоя получают каждый входной сигнал, причем количество нейронов первого слоя равно количеству элементов вектора входа, кодирующего входной сигнал.

4. АКТУАЛЬНОСТЬ ВВЕДЕНИЯ БЛОЧНОСТИ

Рассмотрим задачу обучения многослойных ИНС с учителем [2]. Под обучением в данном случае понимают процесс настройки весов синапса с целью минимизировать рассогласование выхода сети с требуемыми значениями. Ошибка рассогласования выражается через функцию ошибки. Допустим для простоты, что мы достаточно близки к искомому минимуму и мо-




Рис. 6. Синапс.




Рис. 7. Формальный нейрон.

жем вблизи этого минимума аппроксимировать функцию ошибки квадратичным выражением $E = (w - w_*)^T H (w - w_*)$. Здесь $H = W \times W$ матрица вторых производных в точке минимума w_* . Оценив эту матрицу по локальной информации, для чего потребуется $\sim N * W^2$ (N – число обучающих примеров) операций метода back-propagation, можно попасть из любой точки в минимум за один шаг. На этой стратегии построены методы второго порядка [4]. Альтернативная стратегия – найти требуемые $\sim N * W^2$ параметров за $\sim W$ шагов метода первого порядка, затратив на каждом шаге $N * W$ операций. Именно такую скорость сходимости имеют лучшие алгоритмы первого порядка [4] (например, метод сопряженного градиента). В обоих случаях оптимистическая оценка сложности обучения сети (т.к. она получена для простейшего из всех возможных – квадратичного рельефа) составляет $\sim N * W^2$ операций. Эта оценка получена в предположении, что начальные веса достаточно близки к оптимальному значению и можем вблизи этого оптимума аппроксимировать функцию ошибки квадратичной функцией. В общем случае начальные веса далеки от оптимальных значений. Поэтому для более полного анализа сложности обучения необходимо привести более пессимистические оценки, опирающиеся на комбинаторный анализ. Пусть в нейронной сети W синапсов и их веса могут принимать K значений. Тогда возможно K^W вариантов настроек весов синапсов. С ростом числа возможных вариантов растет сложность обучения. Отметим, что значительно проще обучить две сети имеющих $W/2$ синапсов каждая, чем одну сеть с числом синапсов равным W . Действительно, условие $K^W > 2 * K^{W/2}$ выполняется, если $K^{W/2} > 2$, что фактически всегда выполняется.

Очевидно, что в большинстве практически важных задач полный перебор неосуществим. Применяемые более эффективные градиентные методы также не всегда находят или ищут долго удовлетворительные решения из-за сложности рельефа поверхности функции ошибки. С ростом числа настроечных параметров ИНС растет сложность поверхности функции ошибки. Проблема сложности обучения усугубляется необходимостью оптимизации структуры сети. Для оценки оптимальности структуры необходимо обучить нейронную сеть обладающую ей. В данной работе структура сети оптимизируется с помощью генетических алгоритмов [5-9], что требует перебора большого количества вариантов структур нейронных сетей.

В основе генетического алгоритма лежит метод случайного поиска с использованием правил, открытых при изучении эволюции и происхождения видов. Как известно, в процессе эволюции выживают наиболее приспособленные особи. Эволюция приводит к тому, что приспособленность популяции возрастает, позволяя ей лучше выживать в изменяющихся условиях.




Рис. 8. Слоистая сеть.

Впервые подобный алгоритм был предложен в 1975 году Джоном Холландом (John Holland) в Мичиганском университете [10]. Этот алгоритм получил название “репродуктивный план Холланда” и лег в основу многих вариантов генетических алгоритмов.

Из теории эволюции известно, что важную роль играет то, каким образом признаки родителей передаются потомкам. В генетических алгоритмах пространством поиска является пространство строк. Каждая строка кодирует соответствующую нейросетевую структуру (особь). Передачу признаков родителей потомкам выполняет операция, называемая скрещиванием (кроссовером). Кроссовер действует следующим образом:

- из популяции выбираются две особи, которые будут родителями;
- определяется (обычно случайным образом) точка разрыва;
- потомок определяется как конкатенация части первого и второго родителя.

из популяции выбираются две особи, которые будут родителями;

определяется (обычно случайным образом) точка разрыва;

потомок определяется как конкатенация части первого и второго родителя.

В данной работе, в реализации операции кроссовера, была учтена специфика решаемой задачи оптимизации структуры ИНС. Потомок формировался как конкатенация целых строк первого и второго родителя. Таким образом, поиск осуществлялся среди строк нефиксированной длины.

Как средство снижения сложности обучения предлагается проводить декомпозицию исходной задачи обучения на ряд более простых подзадач [11][12]. Сложность решения этих задач в совокупности меньше сложности прямого решения исходной задачи. В терминах нейронных сетей предлагается представлять нейронную сеть в виде совместно функционирующих блоков. Каждый блок также представляет собой нейронную сеть. Каждый блок обучается полностью или частично независимо от других блоков.

В работе предлагается использовать объединение независимо обученных ИНС в коллектив с повторным обучением. Из-за случайности в выборе начальных значений синаптических весов, предсказания сетей, обученных на одной и той же выборке, будут, вообще говоря, различаться. Этот недостаток (элемент неопределенности) можно превратить в достоинство, организовав коллектив нейро-экспертов, состоящий из различных ИНС. Легко показать, что среднее значений коллектива должно давать лучшие предсказания, чем средний эксперт из этого же коллектива. Пусть ошибка i -ого эксперта для значения входа $\mathbf{x}$ равна $\varepsilon_i(\mathbf{x})$.

Средняя ошибка коллектива всегда меньше среднеквадратичной ошибки отдельных экспертов в силу неравенства Коши:

$$\left(\frac{1}{L}\sum_{i=1}^L \varepsilon_i\right)^2 \leq \frac{1}{L}\sum_{i=1}^L \varepsilon_i^2.$$

Причем, снижение ошибки может быть довольно заметным. Так, если ошибки отдельных экспертов не коррелируют друг с другом, т.е. $(\varepsilon_i \varepsilon_j) = (\varepsilon_i^2) \delta_{ij}$, то среднеквадратичная ошибка комитета из L экспертов в $\sqrt{L}$ раз меньше, чем средняя индивидуальная ошибка одного эксперта.

$$E_L^2 \equiv \left(\frac{1}{L}\sum_{i=1}^L \varepsilon_i\right)^2 = \frac{1}{L^2} \left(\sum_{i=1}^L \varepsilon_i^2 + \sum_{i \neq j} \varepsilon_i \varepsilon_j\right) = \frac{1}{L^2} \sum_{i=1}^L \varepsilon_i^2 = \frac{1}{L} E_1^2.$$

Поэтому, в предсказаниях всегда лучше опираться на средние значения всего коллектива. Можно вместо среднего использовать взвешенное мнение сетей-экспертов. Веса выбираются адаптивно максимизируя предсказательную способность коллектива на обучающей выборке. В итоге, хуже обученные сети из коллектива вносят меньший вклад и не портят предсказания. Можно пойти еще дальше, объединив коллектив ИНС в единую сеть направив выходы нейро-экспертов на вход общих выходных нейронов. Полученную сеть обучают повторно, используя в качестве начальных весов, веса нейро-экспертов. В ходе обучения эксперты получают информацию о других экспертах через обратный сигнал ошибки. Происходит подстройка отдельных экспертов на максимизацию качества работы всего коллектива.

5. ЭВОЛЮЦИОННЫЙ АЛГОРИТМ СИНТЕЗА БЛОЧНОЙ СЕТИ

Для синтеза нейронной сети использовался нейроимитатор Neurogenesis. Дадим краткое описание алгоритма реализованного в Neurogenesis. Операция кроссовера в этой программе реализована как объединение двух независимо обученных ИНС с повторным обучением. Более подробную информацию по алгоритму можно найти в работе [6].

Создается начальная популяция ИНС со случайно выбранной структурой и параметрами;

В текущей популяции отыскивается ИНС с наименьшей ошибкой на кросс-тесте

[13]. ИНС запоминается, если ее ошибка ниже, чем ошибка ранее запомненной ИНС. Если ошибка запомненной ИНС не выше требуемой ошибки, работа алгоритма прекращается;

Для каждой ИНС из текущей популяции вычисляется разность между ее значением ошибки и значением ошибки родительской ИНС (той, которая путем мутации или кроссовера породила выбранную ИНС). Пропорционально этой разнице назначается количество выполнения генетических операций над выбранной ИНС;

Над каждой ИНС из текущей популяции выполняется назначенное на шаге 3 количество генетических операций. Порожденные ИНС, имеющие ошибку на кросс-тесте ниже, чем у родительской ИНС переходят в новую популяцию;

Новая популяция становится текущей. Если популяция пуста, то алгоритм прекращает свою работу, иначе переходим на шаг 2.

6. МЕТОДИКА ПРОВЕДЕНИЯ И РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЙ

В ходе эволюционной оптимизации было перебрано свыше 10^4 вариантов структур нейронных сетей. Варианты структур содержали не более 250 настроечных параметров. Ошибка сети на одном примере определялась после того, как она обучалась на всех остальных примерах (кросс-тестирование).

Сеть оценивалась по сумме ошибок на всех примерах. Среди рассмотренных вариантов была отобрана сеть с наименьшей ошибкой на примерах. Сеть использует не все элементы




Рис. 9. Нейронная сеть, выполняющая классификацию. В рецепторном (входном) слое указаны номера нейронов, соответствующие номерам элементов 250-мерного вектора, кодирующего спектр.

векторов, описывающих спектры. Источнику сигнала с i -м номером, при $i < 235$, соответствует $i+15$ номер элемента спектра (нумерация от 0). Сигналу с номером 235 соответствует константный единичный сигнал. Нейроны с номерами 236, 237 и 238 скрытые. Нейрон с номером 239 выходной. Положительный выход сети интерпретируется как отнесение спектра к классу “больные”. Структура этой сети представлена на рисунке 9.

Верность классификации при кросс-тестировании составила 99%. Из 90 примеров всего лишь один спектр был ошибочно отнесен к классу “признаки профессиональных заболеваний обнаружены”. Эти данные позволяют оценить вероятность точности диагностики для каждого класса спектров, которые не были исследованы, если предположить, что исследованные спектры являются типичными. Таблица 1 описывает связи полученной ИНС. Функция нелинейного преобразования скрытых нейронов определена как $F(x) = x / (|x| + C)$. Коэффициент C

зависит от нейрона, и был подобран в ходе эволюционного поиска (рис. 9). Выходной нейрон реализует неоднородный адаптивный сумматор.

Поскольку у каждой особи начальной популяции в первом (признаковом) слое (так же как в остальных слоях) случайным образом задано количество и расположение нейронов, то обучающее множество так же участвует в эволюции в неявном виде. Так как полученная в ходе эволюционной оптимизации нейронная сеть использует не все элементы вектора, кодирующего спектр, можно предположить, что те частоты спектра, которые сеть использует для диагностики, содержат в себе признаки наличия или отсутствия хронического пылевого бронхита. Зная нумерацию нейронов и учитывая, что по данным акустического спирометра можно построить спектры в диапазоне от 0 до 150 Гц, можно вычислить эти частоты. Это следующие частоты: 9 12,6 13,8 15,6 18 19,2 21,6 24,6 30 32,4 33,6 36,6 37,2 42 42,6 43,2 44,4 51 52,2 55,8 63 64,2 66,6 67,8 70,2 73,8 74,4 80,4 83,4 84,6 88,8 90 91,8 96 97,2 99,6 106,2 107,4 115,8 117,6 121,2 123 123,6 124,2 127,2 129,6 130,8 133,2 133,8 134,4 135,6 138,6 139,2 141 141,6 142,8 147 Гц.

Таблица 1 – Структура и веса синаптических связей			Продолжение таблицы 1			Продолжение таблицы 1		
Источник	Приемник	Вес	Источник	Приемник	Вес	Источник	Приемник	Вес
0	239	-0.0984	108	239	-0.9966	209	237	0.9168
6	239	0.5618	109	239	0.3891	211	239	-0.81
8	239	-0.481	119	236	-0.48	216	239	-0.052
11	239	0.0778	124	239	0.207	217	239	-0.034
15	237	0.3263	126	236	-0.0652	220	237	0.6494
17	237	1.0004	129	238	0.0137	221	239	-0.558
21	239	-0.1436	133	237	-0.8652	223	239	-0.57
26	236	0.9336	133	239	0.2322	230	237	-0.081
26	237	0.1583	135	236	0.3083	235	236	0.261
35	237	-0.5551	138	237	-0.3281	235	237	0.142
39	238	0.1166	145	239	-0.3206	235	239	0.0167
41	239	-0.1399	147	236	-0.7518	236	239	0.1497
46	239	-0.0271	151	239	-0.33	237	239	-0.13
47	239	-0.0824	162	236	0.4194	238	239	-0.32
55	239	0.0171	164	236	-0.7875			
56	239	0.1509	178	239	-0.1866			
57	239	0.1743	181	236	-0.8873			
59	239	0.0021	187	239	0.5124			
70	237	-0.9155	190	236	-0.4268			
72	239	-0.6695	191	239	0.3373			
78	236	0.579	192	239	0.8904			
90	236	0.3352	197	239	-0.53			
92	239	0.0022	201	239	-0.3106			
96	239	0.1485	203	239	-0.1169			
98	239	-0.1856	207	239	0.1559			
102	237	-0.8033	208	237	0.2301			

В ходе исследования был опробован и другой подход к синтезу блочной сети: тестовая выборка состояла из 40 примеров. Состав тестовой выборки менялся в процессе поиска оптимальной структуры сети. Из всего множества сетей выбрано 5 с наименьшей ошибкой на тестовых примерах. Точность на всех примерах составила 82%, 82%, 80%, 80%, 81%. Точность коллектива на всех примерах составила 86% (91%, - для здоровых, 81%.- для больных).

7. ЗАКЛЮЧЕНИЕ

Описано создание нейросетевого классификатора, позволяющего по результатам спектрального анализа выдоха диагностировать заболевание “хронический пылевой бронхит”. Расчет

спектра выдоха осуществляется с помощью акустического спироанализатора [1]. Введено и обосновано понятие блочности нейросетевой структуры. На основе предложенного эволюционного алгоритма синтеза блочной сети была получена сеть, точность нейросетевого диагностирования которой составила 99% на 44 примерах спектров больных и 46 здоровых человек. При кросс-тестировании только один пример был ошибочно классифицирован как “больной”. Исходя из свойств синтезированной блочной нейронной сети, был вычислен набор частот, несущий в себе информацию о наличии или отсутствии профессиональных заболеваний исследованных больных.

СПИСОК ЛИТЕРАТУРЫ

1. Шкундин С.З., Румянцева В.А. Повышение точности измерения скорости воздушного потока акустическим анемометром. *Измерительная техника*, 2001, 1, С. 54–57.
2. *Нейроинформатика*. Горбань А.Н., Дунин-Барковский В.Л., Кирдин А.Н. и др. – Новосибирск: Наука. Сибирское предприятие РАН, 1998.
3. Горбань А.Н., Россиев Д.А. *Нейронные сети на персональных компьютерах*. Н.: Наука, 1996.
4. Гилл Ф., Мюррей У., Райт М. *Практическая оптимизация*. Пер. с англ.-М.: Мир, 1985.
5. Хомич А.В., Жуков Л.А. Оптимизация топологии рекуррентных и многослойных нейронных сетей с применением генетических алгоритмов. *Нейроинформатика-2004: Сборник научных трудов*. -Ч. 2. М.: МИФИ, 2004. С. 68–74.
6. Хомич А.В., Жуков Л.А. Оптимизация на основе эволюции с отбором по величине приращения приспособленности. *Моделирование неравновесных систем: Материалы VII Всероссийского семинара*, 8–10 октября 2004 г. ИВМ СО РАН, Красноярск, 2004. С. 180–183.
7. Balakrishnan K., Honavar V. Evolutionary Design of Neural Architectures – A Preliminary Taxonomy and Guide to Literature. *Iowa State University*, CS TR #95-01, 1995.
8. Stanley K., Miikkulainen R. Evolving Neural Topologies through Augmenting Topologies, *Evolutionary Computation* 10(2): 99–127, The MIT Press, 2002.
9. X. Yao. Evolving artificial neural networks. *Proceedings of the IEEE*, 87(9):1423–1447, 1999.
10. John Holland, Genetic Algorithms, *Scientific American*, July 1992, Vol. 267, No. 1.
11. Хомич А.В., Жуков Л.А. Декомпозиция задачи обучения нейронной сети с учителем методом кластеризации множества обучающих примеров. *Нейроинформатика и ее приложения: Материалы XII Всероссийского семинара*, 2004. С. 140–141
12. Хомич А.В., Жуков Л.А. Декомпозиция задачи обучения нейронной сети с учителем методом дихотомии области ответов. *Нейроинформатика и ее приложения: Материалы XII Всероссийского семинара*, 2004. С. 142–144.
13. *Обучение нейронных сетей: Методы, алгоритмы, тестовые испытания, примеры приложения*. С.Е. Гилев, Дисс. канд. физ.-мат.наук. Красноярск: КГТУ, 1997.