

коэффициентов можно ввести дополнительное условие

$$\sum_{i=1}^m \alpha_i = 1. \quad (11)$$

Величина штрафа π_i зависит от сущности правил и может принимать как дискретные значения (0 или 1), так и непрерывные (от 0 до 1). Так, по правилу необратимости штраф является дискретной функцией (налагается при несоответствии требованию и отсутствует, если правило удовлетворяется). Для других правил штраф может монотонно увеличиваться при удалении от некоторой границы X_p

$$\pi_i = \frac{X_i - X_p}{X_{\max} - X_{\min}}, \quad (12)$$

где X_{\min} , X_{\max} - границы изменения параметра X . Таким образом, решением задачи является точка факторного пространства, обеспечивающая удовлетворительную невязку уравнений модели Δ_k и имеющая минимальное значение штрафной оценочной функции π_k среди остальных точек. Алгоритм легко реализуется с помощью вычислительных средств.

Использование описанных управляющих процедур позволяет строить системы искусственного интеллекта для диагностики сложных технических объектов. Набор представленных метаправил далеко не полон и может пополняться другими аналогичными конструкциями, базирующимися на априорных сведениях о конкретном объекте и базе данных, включающей наблюдения за объектом в процессе его эксплуатации. Данные правила позволяют существенно упростить процедуру диагноза при одновременном сохранении достаточной точности полученного решения.

ЛИТЕРАТУРА

1. Ефимов Е.И. Решатели интеллектуальных задач. – М.: Наука, 1982. – 320 с. 2. Змитрович А.И. Интеллектуальные информационные системы. – Мн.: НТООО «ТетраСистемс», 1997. – 368 с.

УДК 681.322 + 519.28

Е.В. Полюнкова, А.А. Примако

НЕЙРОСЕТЕВАЯ ТЕХНОЛОГИЯ СЕНСОРНЫХ СИСТЕМ ОБОБЩЕНИЯ

*Белорусский национальный технический университет
Минск, Беларусь*

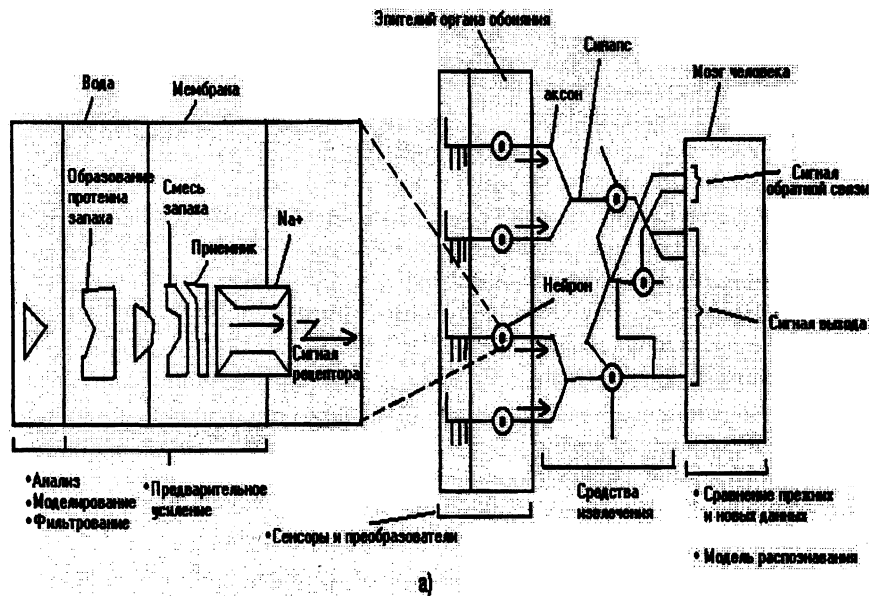
Применение нейросетевых технологий в рамках различного рода сенсорных систем как средства интеллектуализации сенсоров и преобразования информации является весьма актуальным. Широкое применение находят сенсорные

микросистемы-идентификаторы, посредством которых осуществляется оперативный анализ тех или иных сред по качественным признакам. Это сенсорные микросистемы типа: “Электронный нос”, “Электронный язык”, “Электронный глаз”, “Электронный слух”, принципы построения которых в значительной степени базируются на нейросетевом подходе.

Идентификация ароматов или запахов позволяет из специфических комбинаций многих летучих молекул выбирать одну, которая отличается своей концентрацией. Например, запах кофе, содержащий сотни разнообразных ароматических молекул и других химических компонентов (79 пирозинов, 108 дуринов, 44 фенола, 74 пириола, 28 альдегида, 26 тиоденов, 20 оксидов, 28 оксазолов и др.), который проще всего распознается и безошибочно оценивается человеческим носом, благодаря совместным взаимодействиям всех компонентов кофе.

В порядке оценки функционирования технические сенсорные системы обоняния целесообразно сравнивать с органами системы обоняния человека (рис. 1).

Техника предварительной обработки сигнала служит, насколько это возможно, уменьшению влияния шумов и помех при изменении. Затем сигнал усиливается, повышая эффективность чувствительности и селективности систем.



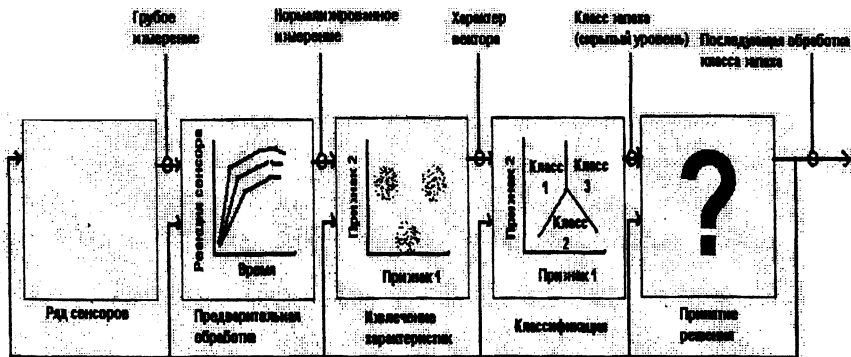


Рис.1 Сенсорная система обоняния человека (а) и техническая (б)

На третьем этапе определения человеком запахов его орган обоняния посылает сигнал в мозг, а кора головного мозга классифицирует и запоминает запахи. Процесс происходящий в электронной системе обоняния эквивалентен этому третьему этапу и представлен программным обеспечением модели распознавания.

В процессе проектирования и построения сенсорных систем обоняния возникают следующие задачи:

1. Определение полного перечня признаков (параметров), характеризующих объекты или технологии, для распознавания которых разрабатывается данная сенсорная система.
2. Первоначальная классификация распознаваемых объектов или технологий, составление априорного набора классов.
3. Составление априорного словаря (набора) признаков, которые будут использоваться при функционировании сенсорной системы (на основе решения задачи 1).
4. Описание всех классов на языке признаков включенных в априорный словарь.
5. Определение границ между областями значений признаков соответствующих различным классам. Эти границы называются решающими границами, а их математические уравнения – решающими функциями.
6. Выбор алгоритмов распознавания, обеспечивающих отнесение распознаваемого объекта к какому-либо классу. Эти алгоритмы обычно основаны на сравнении близости (сходства) распознаваемых объектов с каждым из классов.
7. Определение рабочего набора классов и признаков. Такой набор строится с учетом ограничений (временных, точностных, финансовых и т.д.) на

реализацию системы распознавания. Он должен обеспечить экстремальное значение показателя эффективности системы управления, принимающей решения на основе результатов распознавания.

8. Выбор критерия качества функционирования системы распознавания (например, вероятность правильного распознавания, среднее время распознавания, затраты на распознавание и др.) и разработка алгоритмов управления рабочей системы с целью обеспечения экстремума этого критерия.
9. Оценка качества системы на основе выбранного критерия и ее экономическая эффективность.

Все признаки объектов, используемых для их распознавания, могут быть разделены на 5 групп.

1. Детерминированные признаки – признаки, принимающие конкретные числовые значения, например при технической диагностике.
2. Вероятностные признаки – признаки, случайные значения которых распределены по всем классам объектов, а объект может (с различными вероятностями) относиться к различным классам.
3. Логические признаки – элементарные высказывания, принимающие одно из двух значений (да – нет, истина – ложь) с полной определенностью.
4. Лингвистические (структурные) признаки – производные элементы структуры объекта.
5. Комбинированные признаки – алгоритмы вычисления оценок на основе таблиц объектов, принадлежащих разным классам и значений признаков объектов.

В зависимости от количества первоначальной информации о распознаваемых объектах системы распознавания можно разделить на системы без обучения, обучающиеся и самообучающиеся.

В системах без обучения заранее известны классы, к которым могут относиться распознаваемые объекты, и критерии отнесения объекта к каждому из классов. Для обучения используется определенный набор классов, называемый обучающим множеством, который уже разделен на классы. В этом случае задача обучения состоит в построении алгоритма, позволяющего отнести предъявленный системе объект к одному из известных классов.

В самообучающихся системах исходная информация представлена в виде обучающего множества, не разделенного на классы, т.е. заранее не известны ни характеристики классов, ни их количество.

Для примера проанализируем “электронный нос” на основе сенсоров с использованием чувствительных редкоземельных рецепторов.

Исследуемый образец помещался в измерительную ячейку, расход газов регулировался ротаметрами, которыми оснащен генератор газовой смеси. По показаниям вольтметра снимался исходный (нулевой) сигнал. Затем в измерительную ячейку подавался исследуемый газ определенной концентрации, задаваемой системой генератора. Все измерения проводились в потоке искусственного воздуха: 21% O₂ и 79% N₂. Содержание паров воды не более 0,02 г/м³. Искусственный воздух в данном случае выполнял роль газа-разбавителя. После проведения измерений реакции сенсора на исследуемый газ, измерительная ячейка вновь продувалась искусственным воздухом до установления на выходе нулевого сигнала. Выходной сигнал от сенсора при наличии в атмосфере анализируемого газа – это результат установившегося адсорбционно-десорбционного процесса. Каждый газ характеризуется энергией взаимодействия с поверхностью чувствительного рецептора сенсора и с хемосорбированным на ней кислородом. Другими словами, величина сигнала и время срабатывания сенсора существенным образом зависят от температуры и имеет, как показывают исследования, экстремальные значения [1]. Относительная влажность воздуха в испытательной камере емкостью 1,5 л. менялась от 60% до 98%, водяной раствор аммиака (25%) и ацетон вводились в объеме 0,5 мл., дым образовывался поджиганием и помещением в камеру ваты объемом 0,5 см³. Результаты исследования пленок окислов редкоземельных металлов (РЗМ) (толщина ≈ 0,2+0,3 мкм) сведены в табл. 1.

Таблица 1

Чувствительные рецепторы на основе окислов РЗМ

Оксиды	Исходное сопротивление, Ом	Измененное сопротивление, Ом			
		Влажность	Пары аммиака	Пары ацетона	Дым
Ho ₂ O ₃	2·10 ⁹	10 ⁶	10 ⁸	-	5·10 ⁷
Gd ₂ O ₃	2·10 ⁹	10 ⁶	4·10 ⁷	2·10 ⁸	10 ⁸
Nd ₂ O ₃	2·10 ⁹	3·10 ⁶	3·10 ⁸	3·10 ⁸	7·10 ⁷
Sm ₂ O ₃	2·10 ⁹	10 ⁶	1,5·10 ⁷	2,5·10 ⁸	3·10 ⁸
Dy ₂ O ₃	2·10 ⁹	10 ⁶	1,1·10 ⁸	-	2,5·10 ⁸
(Dy-Nd) ₂ O ₃	2·10 ⁹	10 ⁶	1,5·10 ⁸	10 ⁸	7·10 ⁸
(Dy-Gd) ₂ O ₃	2·10 ⁹	10 ⁶	0,5·10 ⁸	1,5·10 ⁸	7·10 ⁷
(Er Nd) ₂ O ₃	2·10 ⁹	10 ⁶	2,5·10 ⁷	2·10 ⁷	1·10 ⁹
(Er Gd) ₂ O ₃	2·10 ⁹	1,7·10 ⁶	0,4·10 ⁸	10 ⁸	2·10 ⁷

По результатам данной таблицы можно (исходя из значений измененных сопротивлений) построить нейронную сеть способную по значениям таких

параметров, как: влажность, пары аммиака, пары ацетона и дым классифицировать чувствительные рецепторы на основе пленок окислов.

Статистическая обработка данных и построение нейронной сети проведено в программе STATISTICA Neural Network 4.0 и MATLAB Neural Network ToolBox [2].

Нейронная сеть будет иметь топологию MLP (Multilayer Perceptron), RBF (Radial Basis Function), Linear и GRNN (Generalized Regression Neural Network).

Приступая к работе в среде ST и MATLAB, занесем входы сети (рис.2) и проведем обучение сети с помощью обучающего алгоритма Кохонена для ST, в MATLAB с помощью функций.

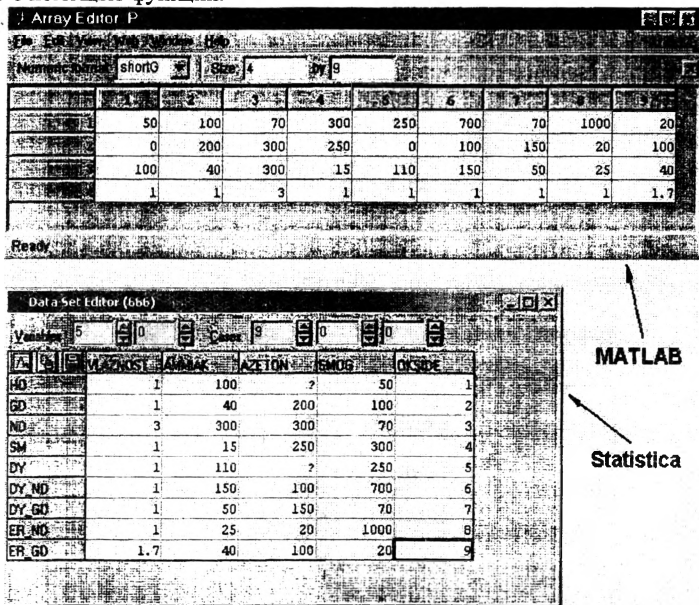


Рис.2. Матрицы обучающих алгоритмов

Значения элементов матрицы были взяты из табл. 1 и сокращены на 10^6 . В данной матрице каждый столбец представляет из себя реакцию определенного оксида РЗМ на внешние параметры (влажность, пары аммиака, пары ацетона, дым). Таким образом, чтобы сопоставить каждому столбцу свое значение оксида РЗМ, присвоим столбцам (слева на право) численные значения:

Численный эквивалент	1	2	3	4	5	6	7	8	9
Оксид	Ho_2O_3	Gd_2O_3	Nd_2O_3	Sm_2O_3	Dy_2O_3	$(\text{Dy-Nd})_2\text{O}_3$	$(\text{Dy-Gd})_2\text{O}_3$	$(\text{Er Nd})_2\text{O}_3$	$(\text{Er Gd})_2\text{O}_3$

То есть сформируем матрицу $T_c = [1\ 2\ 3\ 4\ 5\ 6\ 7\ 8\ 9]$. С целью классификации, чтобы представить выходные данные, полученные с помощью программ ST и MATLAB в виде кластеров (рис.3). После того, как была создана и обучена сеть, для проверки занесем новый вектор $P = [200; 300; 400; 500]$ – объект 10, и полученный результат выведем в виде (рис.3). Видно, что новые данные (объект 10), поступившие на вход были отнесены сетью ближе к 6 классу, т.е. к $(Dy-Nd)_2O_3$.




Рис.3. Результат нейросетевого обучения электронного обоняния

После преобразования матриц и инициализации сети, полученная сеть будет выглядеть следующим образом (рис.4).

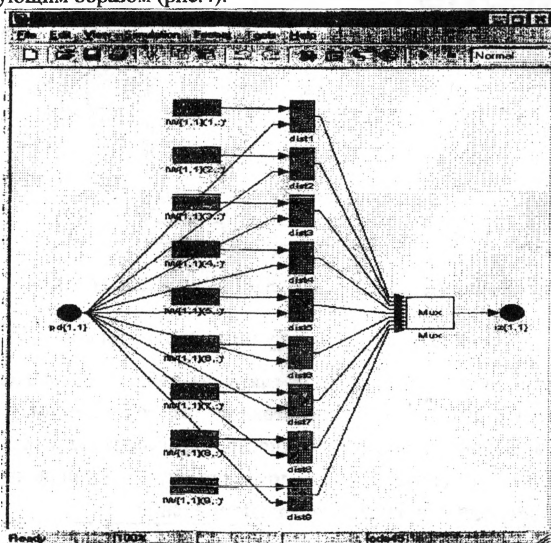


Рис.4. Нейронная сеть сенсорной системы обоняния

Очевидно, что построенная нейронная сеть на основе предыдущей выборки данных способна “анализировать” поданные на вход новые данные и классифицировать их как определенный класс.

Подводя итог вышесказанному, можно отметить, что нейросетевой подход особенно эффективен в задачах экспертной оценки по той причине, что он сочетает в себе способность компьютера к обработке чисел и способность мозга к обобщению и распознаванию.

ЛИТЕРАТУРА

1. Колешко В.М., Таратын И.А., Сергейченко А.В. Интегральные микросенсоры – основные элементы “электронного носа” для мониторинга газовых сред // Машиностроение.- Мн., 2001. – Вып.17.- С. 443-445.
2. “Нейронные сети. STATISTICA Neural Networks”/ Пер. с англ. – М.: Горячая линия – Телеком, 2000.
3. MATLAB – “Electronic manual”, MathWorks, Inc., 2000.