

УДК 004.8.032.26; 504.064.36

**НЕЙРОСЕТЕВОЕ РАСПОЗНАВАНИЕ ОБЪЕКТОВ В РЕАЛЬНОМ ВРЕМЕНИ
С АЛГОРИТМИЗАЦИЕЙ ФОРМИРОВАНИЯ АЛФАВИТА КЛАССОВ**

А.Л. Ляхов, С.П. Алёшин

Полтавский национальный технический университет имени Юрия Кондратюка

e-mail: aleshsp@ukr.net

Введение.

При распознавании состояний сложных объектов системами поддержки решений, в условиях больших массивов входных данных, характеризующихся разнородностью, коррелированностью, информативной неопределенностью, возникает проблема оперативного описания классов этих состояний на языке информативных признаков [1]. Традиционно эта задача решается предметным специалистом на основе экспертного анализа [2]. Однако, в условиях высокой динамики исследуемых объектов и текущих процессов в них, а также жестких временных ограничений на принятие решений, этот способ становится малопродуктивным. Преодолеть эти трудности можно путем автоматизации процесса группировки входного множества на основе алгоритмического анализа степени близости признаков к классам. Для этого необходимо обосновать и задать условия репрезентативности выборки, число классов, метрику степени близости признаков, способ стандартизации разнородных данных, вид решающего правила их селекции, критерии состоятельности полученного решения. Эти процедуры, на наш взгляд, могут быть реализованы на основе инейросетевых технологий в среде современных нейроэмуляторов [3,4]. Если формализовать указанные процедуры, построить алгоритмы их реализации во взаимодействии, обеспечить контроль над критериями их эффективности и построить информационно-аналитическую модель классификатора, то возникает необходимый инструментарий для синтеза самостоятельных программных приложений в распознающих автоматах для СППР разных предметных областей. Поэтому нейросетевое распознавание объектов в многомерном пространстве признаков различной природы с применением автоматического описания классов на языке их информативных признаков для поддержки принятия решений является актуальной задачей не только с научной, но и с практической точки зрения [5].

Постановка задачи и формализация решающего правила.

В условиях многомерности входных факторов, неполноты данных о их взаимном влиянии, неопределенности исходной информации целевые критерии для решения задач распознавания в системах поддержки принятия решений, как правило, формализуются в виде лингвистических переменных или в виде правил логического вывода относительно эффективности функционирования объекта. Массив выборок $X^n = \{x_1, x_2, \dots, x_n\} \subset X$ совместно с соответствующим массивом классов $\vec{K} = (k_1, \dots, k_j) \in K$ используется для обучения в задаче распознавания актуальных состояний объекта исследования. Эту процедуру можно выразить в требовании: оптимизировать функционал процесса распознавания текущего состояния объекта:

$$\Psi[d(\Omega_p); D(\Omega_p, \Omega_g); L(\omega, \{\omega_g\})] \Rightarrow \text{Sup} \quad (1)$$

$$\text{где} \quad d(\Omega_p) = \sqrt{\frac{1}{k_p} \frac{1}{k_p - 1} \sum_{k=1}^{kp} \sum_{l=1}^{kp-1} \sum_{j=1}^N e_j (x_{pk}^{(j)} - x_{pl}^{(j)})^2}, \quad (2)$$

расстояние между объектами (признаками) внутри класса по заданной метрике;

$$D(\Omega_p, \Omega_g) = \sqrt{\frac{1}{k_p} \frac{1}{k_g} \sum_{k=1}^{kp} \sum_{l=1}^{kg} \sum_{j=1}^N e_j (x_{pk}^{(j)} - x_{gl}^{(j)})^2}, \quad (3)$$

расстояние между объектами (признаками) в разных классах по заданной метрике;

$L(\omega, \{\omega_g\})$ — правило отнесения объекта ω_g к соответствующему классу;

e_j — индикатор наличия (отсутствия) признака ($e_j = 1, 0$);

$\{\omega\}$ — множество объектов в классе (ω_{pk}, ω_{gl}).

Алгоритм описания классов на языке их признаков.

Рассмотрим пространственный вариант набора входных признаков гипотетического исследуемого объекта из m точек $\{x^p\}$ в n -мерном пространстве. Необходимо разбить множество точек $\{x^p\}$ на k однородных (по принятой метрике) подмножеств (кластеров) для выбранной меры близости (например, квадрат евклидова расстояния) и найти k

точек α^l таких, что, $d = \sum_{l=1}^k \sum_{x \in P_l} \|\alpha^l - x\|^2$ — минимально.

1. Зададимся набором начальных точек α^l из исходного множества факторов исследуемой ССТС и разобьем множество точек $\{x^p\}$ на k кластеров по правилу

$$P_l = \{x : \|\alpha^l - x\| < \|\alpha^q - x\|, \forall l \neq q\}$$

2. По полученному разбиению вычислим новые точки α^l из условия минимальности

$$D_l = \sum_{x \in P_l} \|\alpha^l - x\|$$

3. Обозначим число точек в i -ом кластере через $|P_i|$.

4. Запишем решение выбора точек на втором шаге алгоритма в виде

$$\alpha^i = \frac{1}{|P_i|} \sum_{x \in P_i} x \quad (4)$$

5. Выполняем процедуры 1-3 алгоритма до тех пор, пока набор точек α^l не перестанет изменяться.

6. Фиксируем сеть способную для произвольной точки x вычислить квадраты евклидовых расстояний от этой точки до всех точек α^l и отнести ее к одному из k кластеров.

7. Ответом является номер нейрона, выдавшего минимальный сигнал.

Созданные для каждого из кластеров отдельные нейронные сети, позволяют получить физическую модель связи входных факторов с индикаторами состояния объекта. При этом индикаторы могут соответствовать как текущему состоянию так и целевому.

Таким образом, технология формирования компактных, однородных подмножеств во входных данных алгоритмически формализована и может быть реализована существующими инструментальными средствами пакетов технического анализа [4].

После группировки входных данных как компактных множеств в многомерном пространстве на основе выбранной метрики близости, новые наблюдения можно классифицировать по принадлежности к тому или иному кластеру с минимальным значением меры близости. Это эквивалентно, для решаемой задачи, процедуре описания классов на языке их информативных признаков и является существенной, обеспечивающей распознавание, процедурой [6].

Верифицированное заключение (при наличии времени) может быть получено с привлечением предметного специалиста. Следующей процедурой алгоритма распознавания является выбор и формализация решающего правила.

Формализация решающего правила распознавания.

Ограничимся выбором квадратичной метрики $d^2(\omega_{pk}, \omega_{gl}) = \sum_{j=1}^N (x_{pk}^{(j)} - x_{gl}^{(j)})^2$ -

заданная метрика признакового пространства.

Тогда решение (1) достигается минимизацией (2), максимизацией (3) и реализацией преобразования $L(\omega, \{\omega_g\}) \rightarrow \omega_g \in \Omega_k$, согласно решающего правила:

$$\omega_g \in \Omega_k, \text{ если } L(\omega, \{\omega_g\}) = \sup_i L(\omega, \{\omega_i\}) \quad (5)$$

Алгоритмическая реализация решающего правила

1. Полагаем все веса элементов равными нулю.
2. Проводим цикл предъявления примеров. Для каждого примера выполняется следующая процедура:
 - 2.1. Если сеть выдала правильный ответ, то переходим к шагу 2.4.
 - 2.2. Если на выходе персептрона ожидалась единица, а был получен ноль, то веса связей, по которым прошел единичный сигнал, уменьшаем на единицу.
 - 2.3. Если на выходе персептрона ожидался ноль, а была получена единица, то веса связей, по которым прошел единичный сигнал, увеличиваем на единицу.
 - 2.4. Переходим к следующему примеру. Если достигнут конец обучающего множества, то переходим к шагу 3, иначе возвращаемся на шаг 2.1.
3. Если в ходе выполнения второго шага алгоритма хоть один раз выполнялся шаг 2.2 или 2.3 и не произошло заикливания, то переходим к шагу 2. В противном случае обучение завершено.

Результаты эксперимента. В качестве инструмента моделирования использовался модуль Statistika Neural Network пакета технического анализа данных Statistika. Для кластеризации и распознавания состояний объекта исследования на основе массива данных формировалась последовательность примеров максимально возможной размерности, формируя словарь признаков. Работа нейросети в режиме кластеризации позволила сформировать алфавит классов исследуемых объектов на языке этого словаря.

Так как каждому классу соответствует свой набор показателей, то процедура классификации объекта свелась к анализу пространства признаков текущего состояния и сравнения результатов анализа с описаниями выбранных классов. В нейросетевом формате задача распознавания классов текущего состояния исследуемого субъекта решалась с использованием известного правила (например, дельта - правила [1]). При наличии двух классов состояний объектов формирование обучающего множества не вызвало затруднений. Реализована технология моделирования в среде нейроэмуляторов по методике [3,4], что позволило получить ансамбль моделей (Рис.4,5).





Рис.4. График обучения модели (Вариант 1) Рис.5. График обучения модели (Вариант 2)

Производительность моделей (характер динамики обучения) имеет устойчивый вид асимптотических кривых, зависящих от репрезентативности (представительности) обучающего множества (Варианты 1,2), что позволяет улучшать модели при пополнении базы данных. Как видно из графиков, применение предлагаемой технологии, сокращает время адаптации нейросетевых моделей исследуемых процессов при сохранении их адекватности в допустимых границах и позволило получить устойчивую сходимость итерационного процесса модификации синаптического пространства. Число эпох не превышает нескольких сотен, что в пересчете на общие временные затраты соответствует нескольким десяткам секунд.

Выводы. 1. Нейросетевой базис для построения однородных подмножеств, как классов состояний объектов на языке их информативных признаков, позволяет автоматизировать реализацию базовых функций распознавания: формирование словаря признаков и алфавита классов, реализацию решающего правила в режиме реального времени. 2. Инструментальная процедура распознавания возможна и целесообразна с применением стандартных нейроэмуляторов существующих и перспективных пакетов технического анализа данных.

Список литературы

1. Барабаш Ю.Л. Коллективные статистические решения при распознавании. - М.: Радио и связь, 1983.- 224с.
2. Бусленко Н.П. Моделирование сложных систем. 2 – изд. – М.: Наука, 1978. – 400 с.
3. Хайкин С. Нейронные сети: полный курс, 2-е издание. Пер. с англ. - М.: Издательский дом «Вильямс», 2006 г. -1104 с.
4. Боровиков В.П. STATISTICA NN - Техническое описание. М.: Мир, 1999. – 239 с.
5. Морозов А.А. Состояние и перспективы нейросетевого моделирования СППР в сложных социотехнических системах / В.П. Клименко, А.Л. Ляхов, С.П. Алёшин // Математичні машини і системи. – 2010. - № 1.- С. 127 – 149.
6. Алёшин С.П. Ситуационные центры быстрого реагирования: принятие решений в среде нейроэмуляторов / С.П. Алёшин // Системы управления, навигации и связи – 2011. – № 1 (17). – С. 240 – 247.