



ІНФОРМАЦІЙНІ СИСТЕМИ І ТЕХНОЛОГІЇ

УДК 004.93

МЕТОД ОБУЧЕННЯ НЕЙРО-НЕЧЕТКОЇ СЕТИ РАСПОЗНАВАНІЮ ОБРАЗОВ НА ОСНОВЕ ПРЯМОУГОЛЬНОГО РАЗБИЕНІЯ ПРОСТРАНСТВА ПРИЗНАКОВ

Субботин С.А.

*Запорожский национальный технический университет,
ул. Жуковского, 64, Запорожье, Украина, 69064,
subbotin@zntu.edu.ua*

Введение

Нейро-нечеткие сети [1–4] являются широко применяемым на практике аппаратом для решения задач автоматизации распознавания образов и принятия решений в системах технической диагностики и управления сложными объектами и процессами, характеризующимися многомерностью и нелинейностью.

Большинство традиционно используемых методов синтеза нейро-нечетких сетей предполагает решение задачи обучения на основе итеративных градиентных методов многомерной нелинейной оптимизации [1; 2]. Однако данные методы характеризуются проблемами выбора начальной точки поиска, локальным характером поиска, возможностью попадания в локальные экстремумы функционала обучения, необходимостью расчета производных целевой функции по весам сети и, как следствие, длительностью и нестабильностью процесса обучения.

Поэтому весьма актуальной является разработка методов синтеза нейро-нечетких моделей, свободных от перечисленных недостатков.

Целью данной работы является создание математического обеспечения для построения распознающих моделей на основе нейро-нечетких сетей, способных обеспечивать оценку уверенности принятия решений, а также не требующих расчета производных.

Постановка задачи построения нейро-нечеткой модели

Пусть мы имеем обучающую выборку $\langle x, y \rangle$, где $x = \{x^s\}$, $y = \{y^s\}$, $x^s = \{x_j^s\}$, x_j^s – значение j -го признака s -го экземпляра выборки, y^s – значение выходного признака, сопоставленное s -му экземпляру обучающей выборки, $y^s \in \{k\}$, $k=1, 2, \dots, K$; K – число классов.

Тогда задача построения нейро-нечеткой модели, позволяющей определять расчетный номер класса для предъявляемого на ее входы экземпляра, можно представить как задачу определения структуры и значения параметров модели, что, в свою очередь, предполагает задание пользователем набора признаков, образующих признаковое пространство, и формирование разбиения признакового пространства на кластеры.

Формирование четкого разбиения признакового пространства

Шаг 1. Инициализация. Задать обучающую выборку $\langle x, y \rangle$, где $y = 1, 2, \dots, K$; K – количество классов, на которые разделяются образы.

Шаг 2. Сформировать начальное разбиение признакового пространства на N -мерные прямоугольники на основе одного из следующих способов.

Способ 1. На основе метода "решеток" [2] диапазоны значений всех признаков разбивают на равные количества интервалов, одинаковой длины по каждому признаку.

Границы интервалов значений признаков $\{ \langle a_{jr}, b_{jr} \rangle \}$ рассчитывают как:



$$a_{jr} = \min_{s=1,2,\dots,S} (x_j^s) + \frac{(r-1)}{Z} \left(\max_{s=1,2,\dots,S} (x_j^s) - \min_{s=1,2,\dots,S} (x_j^s) \right),$$

$$b_{jr} = \min_{s=1,2,\dots,S} (x_j^s) + \frac{r}{Z} \left(\max_{s=1,2,\dots,S} (x_j^s) - \min_{s=1,2,\dots,S} (x_j^s) \right), \quad j = 1, 2, \dots, N; r = 1, 2, \dots, N_j.$$

где a_{jr} , b_{jr} – соответственно, левая и правая границы r -го интервала значений j -го признака; N_j – число интервалов значений по j -му признаку. Величина N_j задается пользователем или выбирается автоматически, например, по формуле: $N_j = \text{round}(10 \ln S)$, где round – функция округления числа, $S > 50$.

Далее из этих интервалов формируют прямоугольники. В результате разбиение пространства признаков будет содержать $Q = N_1^{N_j}$ прямоугольников.

Достоинством данного способа является то, что координаты границ прямоугольников-кластеров легко рассчитываются, а недостатками – то, что получаемое разбиение очень грубо аппроксимирует границы классов и может оказаться как чрезмерно избыточным, так и крайне недостаточным по числу выделенных интервалов и кластеров, соответственно, а также требует предварительного задания числа кластеров, которое, как правило, заранее не известно.

Способ 2. На основе метода [6; 7] выделяют интервалы значений $\{<a_{jr}, b_{jr}>\}$ по каждому j -му признаку, куда попадают только экземпляры, принадлежащие к одному и тому же классу. Далее из этих интервалов формируют прямоугольники. В результате разбиение пространства признаков будет содержать $Q = \prod_{j=1}^N N_j$ прямоугольников, где N_j – количество

интервалов, на которые разбивается диапазон значений j -го признака.

Достоинствами данного способа является более точная аппроксимация границ классов, по сравнению с первым способом, учет компактности расположения образов по каждому признаку отдельно, а недостатком – то, что требуется выполнять много операций сортировки для выделения интервалов по каждому признаку.

Способ 3. Количество кластеров задается равным числу экземпляров обучающей выборки, все прямоугольники-кластеры являются точечными, а их левые и правые границы (координаты вершин) по каждому признаку устанавливаются равными координатам экземпляра, помещаемого в соответствующий кластер: $a_j^q = x_j^q$, $b_j^q = x_j^q$, $q = 1, 2, \dots, Q$; $Q = S$.

Достоинством данного подхода является простота определения числа кластеров и их границ, а недостатками – низкий уровень обобщения и выделение избыточного числа кластеров.

Шаг 3. Для каждого q -го прямоугольника-кластера определить количество экземпляров каждого k -го класса, попавших в него N_q^k . Тем прямоугольникам, в которые попали только экземпляры одного k -го класса, присвоить номер этого класса $K_q = k$, а на основе экземпляров соответствующего кластера определить координаты его центра масс

$$C_j^q = \{C_j^q\}, \quad C_j^q = \frac{1}{N_q^k} \sum_{s=1}^S \{x_j^s \mid \forall j: a_j^q \leq x_j^s \leq b_j^q\}, \quad j = 1, 2, \dots, N,$$

где C_j^q – координата центра масс q -го кластера по j -му признаку.

Прямоугольники, в которые не попал ни один экземпляр, обозначить как пустые: $K_q = 0$. Прямоугольники, содержащие экземпляры разных классов, обозначить: $K_q = -1$.

Шаг 4. Объединить смежные прямоугольники, относящиеся к одному и тому же классу. Последовательно для каждых двух прямоугольников-кластеров $\{<a_j^q, b_j^q>\}$ и $\{<a_j^p, b_j^p>\}$, $q \neq p$, $q = 1, 2, \dots, Q$; $p = 1, 2, \dots, Q$ определить возможность их объединения: кластеры-прямоугольники могут быть объединены, если они принадлежат к одному и то-



му же классу ($K_q=K_p$), а прямоугольник, включающий оба объединяемых кластера ($a_j^{(q,p)} = \min(a_j^q, a_j^p)$, $b_j^{(q,p)} = \max(b_j^q, b_j^p)$), будет содержать только экземпляры данного класса ($\{K_{(q,p)} = y^s \mid a_j^{(q,p)} \leq x_j^s \leq b_j^{(q,p)}\}, \forall x^s, s = 1, 2, \dots, S$) и не будет пересекаться с кластерами-прямоугольниками других классов (пересечение с прямоугольниками того же класса при этом не запрещается):

$$\bigcap_{j=1}^N (b_j^q < a_j^r) \cup (a_j^q > b_j^r) = \emptyset, K_p \neq K_q, p \neq q.$$

Из множества допустимых пар прямоугольников-кластеров каждого класса Ω объединяются те два прямоугольника q и p , которые либо являются наиболее близкими друг к другу (критерий наибольшего подобия):

$$\min_{\substack{q \neq p, \\ (q,p) \in \Omega}} \left\{ \sum_{j=1}^N (C_j^q - C_j^p)^2 \right\},$$

либо будут образовывать наибольший по охвату прямоугольник (критерий наибольшего обобщения):

$$\max_{\substack{q \neq p, \\ (q,p) \in \Omega}} \left\{ \prod_{j=1}^N (b_j^{(q,p)} - a_j^{(q,p)}) \right\}.$$

После объединения пары прямоугольников (после чего принимается $Q = Q - 1$ и корректируются соответствующим образом номера кластеров) определить все полностью поглощенные прямоугольники-кластеры того же класса, которые удалить из набора кластеров (при этом также на соответствующие величины изменяются Q и номера кластеров). Прямоугольник q полностью поглощается прямоугольником p , если $\forall j, j = 1, 2, \dots, N : a_j^p \leq a_j^q, b_j^p \geq b_j^q$.

Процедура объединения кластеров завершает свою работу, когда либо число кластеров стало равным числу классов ($Q = K$), либо отсутствуют такие кластеры, которые удовлетворяют условиям объединения.

В результирующем разбиении, полученном на основе данного способа, будет Q прямоугольников-кластеров, которые по каждому j -му признаку будут иметь левую границу с координатой a_j^q и правую границу с координатой b_j^q .

Целью данного шага являются минимизация числа кластеров и повышение обобщающих свойств разбиения.

Шаг 5. Выполнить разбиение прямоугольников, содержащих экземпляры разных классов. Для этого для каждого прямоугольника, содержащего экземпляры разных классов, рекурсивно выполнять шаги 2–4 до тех пор, пока не будет получено такое разбиение, прямоугольники-кластеры которого будут содержать только экземпляры одного класса.

Формирование нечетких термов и нечеткого разбиения пространства признаков

На основе полученного четкого разбиения сформируем нечеткие термы признаков, которые определим на основе интервалов соответствующего признака для каждого кластера. При этом возможно использовать широкий спектр элементарных функций принадлежно-



сти, наиболее подходящей из которых является трапециевидная функция [4], которая в нашем случае может быть упрощена:

$$\mu_{jr}(x_j) = \begin{cases} 0, x_j < a_{jr}; \\ 1, a_{jr} \leq x \leq b_{jr}; \\ 0, b_{jr} < x_j. \end{cases}$$

После формирования нечетких термов признаков зададим способ объединения принадлежности к термам в принадлежности к кластерам-прямоугольникам:

$$\mu^q = \min_{j,r} \{ \max(\alpha_{jr}^q, \mu_{jr}) \},$$

где $\alpha_{jr}^q = 0$, если r -й интервал j -го признака является стороной q -го прямоугольника; $\alpha_{jr}^q = 1$, если r -й интервал j -го признака не является стороной q -го прямоугольника.

Определить значения $\beta_t^q = \alpha_{jr}^q, q=1,2, \dots, Q; t = \sum_{m=1}^{j-1} N_m + r; j=1,2, \dots, N; r=1,2, \dots, N_j$.

Поскольку признаковое пространство может содержать пустоты, в которые не попало ни одного экземпляра обучающей выборки, целесообразно для тех областей пространства, которые лежат вне границ кластеров-прямоугольников с известной классификацией, задать способ определения принадлежности к кластерам:

$$\mu^q = \exp \left(- \sum_{j=1}^N (x_j^s - C_j^q)^2 \right).$$

Нейро-нечеткая сеть для распознавания образов

После формирования нечеткого разбиения и задания способов определения принадлежности распознаваемого экземпляра возможно синтезировать нейро-нечеткую сеть.

Схема нейро-нечеткой сети представлена на рис. 1.

На входы сети поступают значения признаков распознаваемого экземпляра. Нейроны первого слоя сети осуществляют определение принадлежности значений признаков к соответствующим термам-интервалам признаков $\mu_{jr}(x_j)$. Первая половина нейронов второго слоя определяет принадлежность экземпляра к соответствующим кластерам-прямоугольникам на основе трапециевидных функций (на рис. 1 выделены пунктирным прямоугольником), а вторая половина – на основе функций Гаусса (на рис. 1 выделены пунктирным эллипсом). Нейроны третьего слоя определяют принадлежность экземпляра к классам. Первый нейрон четвертого слоя объединяет принадлежность экземпляра к классам и выполняет дефазификацию результата. Второй нейрон четвертого слоя определяет оценку уверенности сети в результате классификации $R(y)$.

Дискриминатные функции нейронов сети будут определяться формулами:

$$\varphi^{(\eta,i)}(w_j^{(\eta,i)}, x_j^{(\eta,i)}) = \max(w_j^{(\eta,i)}, x_j^{(\eta,i)}), \eta = 2, i = 1, 2, \dots, Q, j = 1, 2, \dots, Z, Z = \sum_{j=1}^N N_j;$$



$$\varphi^{(\eta,i)}(w_j^{(\eta,i)}, x_j^{(\eta,i)}) = \sum_{j=1}^N (x_j^{(\eta,i)} - w_j^{(\eta,i)})^2, \eta = 2, i = Q+1, Q+2, \dots, 2Q, j = 1, 2, \dots, Z;$$

$$\varphi^{(\eta,i)}(w_j^{(\eta,i)}, x_j^{(\eta,i)}) = \min(w_j^{(\eta,i)}, x_j^{(\eta,i)}), \eta = 3, i = 1, 2, \dots, K, j = 1, 2, \dots, 2Q;$$

$$\varphi^{(\eta,i)}(x^{(\eta,i)}) = \arg \max_{j=1,2,\dots,K} \{x_j^{(\eta,i)}\}, \eta = 4, i = 1;$$

$$\varphi^{(\eta,i)}(w^{(\eta,i)}, x^{(\eta,i)}) = \sum_{j=1}^Q w_j^{(\eta,i)} x_j^{(\eta,i)} + w_0^{(\eta,i)}, \eta = 4, i = 2.$$

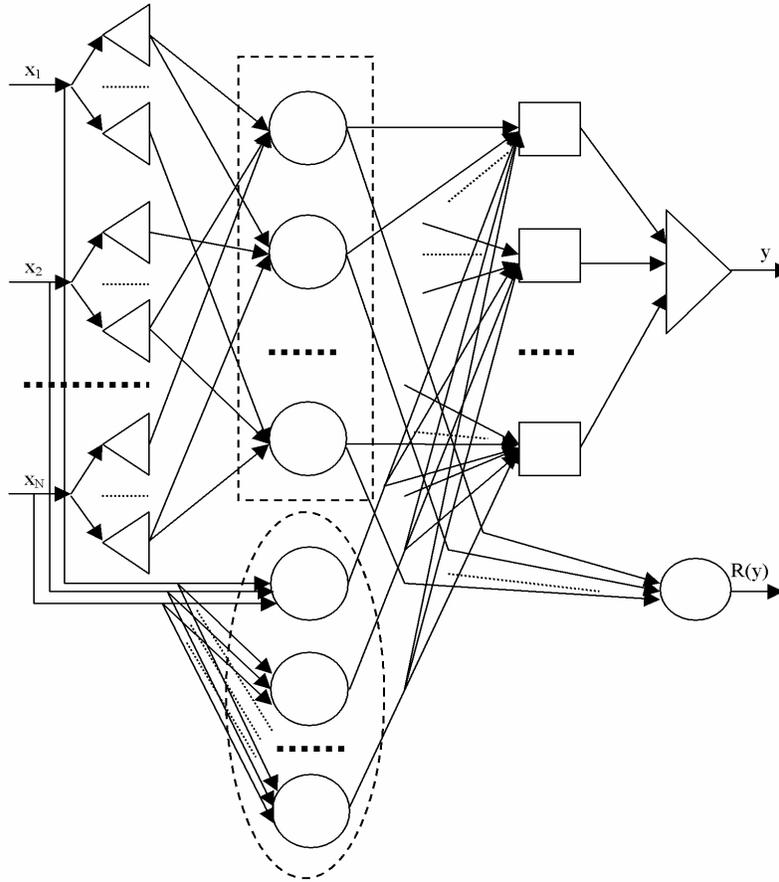


Рис. 1. Схема нейро-нечеткой сети

Функции активации нейронов будут задаваться как:

$$\psi^{(\eta,i)}(\varphi^{(\eta,i)}(w_j^{(\eta,i)}, x_j^{(\eta,i)})) = \min_j \{\varphi^{(\eta,i)}(w_j^{(\eta,i)}, x_j^{(\eta,i)})\}, \eta = 2, i = 1, 2, \dots, Q, j = 1, 2, \dots, Z;$$

$$\psi^{(\eta,i)}(\varphi^{(\eta,i)}) = \exp(-\varphi^{(\eta,i)}), \eta = 2, i = Q+1, Q+2, \dots, 2Q, j = 1, 2, \dots, N;$$

$$\psi^{(\eta,i)}(\varphi^{(\eta,i)}(w_j^{(\eta,i)}, x_j^{(\eta,i)})) = \max_j \{\varphi^{(\eta,i)}(w_j^{(\eta,i)}, x_j^{(\eta,i)})\}, \eta = 3, i = 1, 2, \dots, K, j = 1, 2, \dots, 2Q;$$

$$\psi^{(\eta,i)}(\varphi^{(\eta,i)}) = \varphi^{(\eta,i)}, \eta = 4, i = 1;$$

$$\psi^{(\eta,i)}(\varphi^{(\eta,i)}) = \begin{cases} 0, & \varphi^{(\eta,i)} \leq 0; \\ 1, & \varphi^{(\eta,i)} > 0; \end{cases} \eta = 4, i = 2.$$



Весовые коэффициенты нейроэлементов рассчитываются по формуле:

$$w_j^{(\eta,i)} = \begin{cases} \beta_j^i, \eta = 2, i = 1, 2, \dots, Q, j = 1, 2, \dots, Z; \\ C_j^i, \eta = 3, i = Q + 1, Q + 2, \dots, 2Q, j = 1, 2, \dots, N; \\ 0, \eta = 3, K_j \neq i, i = 1, 2, \dots, K, j = 1, 2, \dots, Q; \\ 1, \eta = 3, K_j = i, i = 1, 2, \dots, K, j = 1, 2, \dots, Q; \\ 1, \eta = 4, i = 2, j = 1, 2, \dots, Q; \\ 0, \eta = 4, i = 2, j = 0. \end{cases}$$

Заключение

С целью автоматизации распознавания образов для принятия решений в системах диагностики в работе решена актуальная задача создания математического обеспечения для синтеза распознающих нейро-нечетких моделей.

Впервые предложена архитектура (модель) нейро-нечеткой сети, обеспечивающая возможность оценки уверенности при распознавании образов, что позволяет в задачах технической и биомедицинской диагностики контролировать достоверность, безопасность и обоснованность принимаемого решения.

Разработан новый метод обучения нейро-нечеткой сети, позволяющий в неитеративном режиме настраивать весовые коэффициенты нейронов, не требующий вычисления производных целевой функции по весам сети, не требующий выбора начальной точки поиска в пространстве весов, не склонный к попаданию в локальные минимумы и заикливание.

Работа выполнена в рамках госбюджетной научно-исследовательской работы "Научно-методические основы и математическое обеспечение для автоматизации и моделирования процессов управления и поддержки принятия решений на основе процедур распознавания и эволюционной оптимизации в нейросетевом и нечеткологическом базисах" (№ гос. регистрации 06U008621).

Литература

1. Jang J.-Sh., Sun Ch.-T., Mizutani E. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. – New York : Prentice-Hall, 1997. – 640 p.
2. Melin P., Castillo O. Hybrid intelligent systems for pattern recognition using soft computing: an evolutionary approach for neural networks and fuzzy systems. – Berlin : Springer-Verlag, 2005. – 272 p.
3. Субботін С.О. Неітеративні, еволюційні та мультиагентні методи синтезу нечіткологічних і нейромережних моделей : монографія / С.О. Субботін, А.О. Олійник, О.О. Олійник ; під заг. ред. С.О. Субботіна. – Запоріжжя : ЗНТУ, 2009. – 375 с.
4. Субботін С.О. Подання й обробка знань у системах штучного інтелекту та підтримки прийняття рішень : навч. посіб. / С.О. Субботін. – Запоріжжя : ЗНТУ, 2008. – 341 с.
5. Субботин С.А. Метод синтеза классифицирующих нейронечетких сетей с учетом значимости термов признаков С.А. Субботин // Информационные технологии. – 2008. – № 7. – С. 31–33.
6. Субботин С.А. Методы синтеза нейро-нечетких классификаторов для случая нескольких классов С.А. Субботин // Информационные технологии. – 2006. – № 11. – С. 31–36.
7. Субботин С.А. Неитеративный синтез и редукция нейро-нечетких моделей С.А. Субботин // Штучний інтелект. – 2006. – № 3. – С. 323–330.