
ИНТЕЛЛЕКТУАЛЬНЫЕ ТЕХНОЛОГИИ В МАРКЕТИНГОВОМ АНАЛИЗЕ

Галина Сетлак

Аннотация: Целью данной работы является разработка процедур и алгоритмов использования методов искусственного интеллекта для обработки и анализа различных видов знаний. Предлагается интегрировать такие техники моделирования знаний и процессов принятия решений как нейронные сети и системы нечёткого вывода. Нейронная нечёткая система используется для решения задачи идентификации сложных процессов. Представлен пример применения к задаче классификации в анализе рынка.

Keywords: Data mining, классификация, нейронные сети, нечёткая логика, маркетинг, анализ рынка.

ACM Classification Keywords: 1. Computing Methodologies, 1.2 Artificial Intelligence

Введение

В последнем десятилетии в развитии средств и методов обработки информации появилась новая научная дисциплина, названная Data Mining, что переводится как „добыча” или „извлечение данных”, которая направлена прежде всего на автоматизацию обработки больших объёмов информации. Data Mining иначе ещё называется в литературе интеллектуальным анализом данных. Интеллектуальный анализ данных означает процесс обнаружения в „сырых данных” (raw data) ранее неизвестных, практически полезных и доступных интерпретации знаний, закономерностей, необходимых для принятия решений в различных сферах человеческой деятельности. При этом выделяются пять стандартных типов закономерностей, которые позволяют выявлять методы Data Mining: ассоциация, последовательность, классификация, кластеризация и прогнозирование. Основой для новой парадигмы современной технологии анализа информации являются последние достижения в области развития методов искусственного интеллекта.

В настоящих исследованиях для обработки и анализа информации предлагается интегрировать методы искусственного интеллекта, используемые в таких научных направлениях, как нейронные сети (искусственные аналоги человеческого мозга, моделирующие способность обучаться), теория нечётких множеств и логики – средства формализации естественно-языковых высказываний и нечёткого логического вывода, а также генетические алгоритмы. Достоинством таких гибридных нейронно-нечётких систем является гибкость, способность к адаптации за счет различных методов обучения, простота реализации, удобство при настройке, а также высокие качественные показатели.

Так как нечеткие системы работают со слабо структурированной качественной информацией, а нейронные сети используют только количественную информацию, объединение этих двух методов позволит использовать всю доступную информацию об объекте. Технология, разработанная на этой основе, объединяет соответствующим образом способность нейронных сетей к самообучению и способность нечетких систем обрабатывать качественную информацию. Несомненное достоинство гибридной нейронно-нечёткой технологии моделирования и обработки информации заключается в возможности просмотра сформированных правил и придания им содержательной, (лингвистической) интерпретации, что позволяет рассматривать аппарат нейронно-нечётких систем как средство извлечения знаний из экспериментальных баз данных.

Целью данной работы является оценка возможностей использования нечётких нейронных систем для предварительной обработки и анализа информации разного вида и решения задач классификации. Решается практическая задача маркетингового анализа рынка при помощи нейронной нечёткой системы.

Нейросетевые системы нечёткой классификации

Проблемы классификации являются одними из наиболее часто решаемых задач, как в повседневной хозяйственной деятельности, так и в экономическом анализе этой деятельности каждой организации. Решение задач классификации заключается в разработке, конструкции таких правил и закономерностей, которые позволили бы распознать определённые явления или объекты и определить их принадлежность к каким-то классам (группам, категориям). Задача значительно усложняется, если при определении классов необходимо брать во внимание очень большое количество характеристик исследуемых объектов и явлений, тем более, если эти характеристики слабо определены или трудно формализуемы. В последние годы для решения сложных задач классификации всё чаще используются искусственные нейронные сети.

В работах автора данной статьи ранее исследовались возможности использования нескольких видов искусственных нейронных сетей для решения практических задач классификации. Проанализированы и оценены такие нейронные сети как: рекуррентная сеть Hamminga [Сетлак Г., 2000], многослойный перцептрон, сеть радиальной базисной функции, вероятностные и сети Кохонена в работе [Сетлак Г., 2004]. Результаты анализа показали, что для корректной работы и реального применения нейронных сетей необходимо их обучать на достаточно обширных выборках входных данных, причём, чем больше входных анализируемых признаков, чем выше сложность сети и моделируемой функции, тем больше должна быть выборка. При решении задач классификации в менеджменте, где рассматриваемые экономические показатели характеризуются большим разнообразием и субъективной природой, необходимо также использовать качественные параметры, основанные на психологических особенностях восприятия, а не только численные или логические. Наиболее обещающим направлением в исследованиях и разработке таких интеллектуальных инструментов представляет собой объединение двух независимых интеллектуальных технологий: искусственных нейронных сетей и нечёткой логики [Jang J. S.R., Sun C.T., Mizutani E., 1997], [Grabmeier J., A. Rudolph, 2002], [Rutkowska D., 1997].

Теория нечётких множеств и нечеткой логики согласно с основной идеей Л.Заде в течение почти сорока лет широко используется как инструмент для моделирования и обработки нечёткой, лингвистической или иначе так называемой, качественной информации, для моделирования нечёткости мышления человека, его способности использовать приближённые оценки для описания сложных, плохо формализуемых процессов принятия решений в различных областях деятельности. Интеграция двух независимых интеллектуальных технологий: искусственных нейронных сетей и теории нечётких множеств и логики, таким образом, кажется наиболее естественным процессом, который позволяет создать новую, более универсальную методологию обработки различных видов знаний и моделирования сложных процессов.

Постановка задачи

Принимаем, что известны следующие данные:

- входные переменные $X = (x_1, x_2, \dots, x_n)^T$, причём $X \in X_1 \times X_2 \times \dots \times X_n$ - являются терм-множествами переменной x_i , которые являются характерными признаками классифицируемых объектов.
- множество классов решений $S = \{S_1, S_2, \dots, S_m\}$ соответствующих выходной переменной $y, y \in Y$.

- функции принадлежности $\mu_{A_i^k}(x)$ конкретных значений входных переменных x_i к нечётким множествам A_i^k , ($i=1,2,\dots,n$, $k=1,2,\dots,N$),
- Нечёткие предикатные правила зависимостей, связывающих значения входных переменных с одним из возможных значений выходной переменной, разработанные экспертом или иначе так называемая нечеткая база знаний - логических высказываний типа „ЕСЛИ-ТО”.

Требуется разработать алгоритм, позволяющий определить для вектора входных переменных класс решений, к которому можем его отнести.

Рассмотрим нечётко-нейронную систему, структура которой представлена на рис.1.

Определение 1: нечётко-нейронной системой называем многослойную структуру, в состав которой входят следующие элементы:

- Система нечёткого вывода, на вход которой подаются лингвистические переменные (термы). В состав каждой нечеткой системы выводов входят следующие элементы [Zadeh L.A., Kasprzyk J., 1992] блок введения к нечеткости (fuzzification), база правил, содержащая совокупность нечетких правил, механизм выводов и блок приведения к четкости (defuzzification).
- Нечёткая система обучается оптимизационными методами: модифицированным алгоритмом Обратного распространения ошибок Backpropagation или при помощи гибридного метода основанного на генетическом алгоритме, используемых в нейронных сетях.
- В выходном слое нечётко-нейронной системы используется нейронная сеть для выполнения операции приведения к чёткости.

Определение 2. Нечеткая база знаний представляет собой совокупность правил „ЕСЛИ <входы> ТО <выход>”, которые отображают опыт эксперта (специалиста предметной области) и его понимание причинно-следственных связей, характерных для моделируемого объекта или процесса.

Механизм нечетких выводов рассматриваемой системы использует базу знаний в виде совокупности $R^{(k)}$, ($k=1,2,\dots,N$) нечетких предикатных правил вида:

$$R^{(k)}: \text{IF } x_1 \text{ is } A_1^k \text{ and } x_2 \text{ is } A_2^k \text{ and } \dots \text{ and } x_n \text{ is } A_n^k \text{ THEN } (y \text{ is } B^k), \quad (1)$$

в которых N - означает число нечётких правил, x_1, x_2, \dots, x_n, y - лингвистические переменные, A_i^k - нечёткие множества предпосылок правил ($i=1,2,\dots,n$; $k=1,2,\dots,N$) и B^k – нечёткое множество заключений.

Обозначим также $A^k = A_1^k \times A_2^k \times \dots \times A_n^k$. Символами X_i и Y обозначаем пространства изменений входных и соответственно выходной переменных. Знания эксперта, содержащиеся в (1), отражают нечёткое отношение предпосылки и заключения. Поэтому его можем записать как нечёткую импликацию: $R^{(k)}: A^k \rightarrow B^k$, $k=1,2,\dots,N$ и представить как нечёткое отношение, определённое на множестве $X \times Y$, т.е. $R^{(k)} \subseteq X \times Y$ является нечётким множеством с функцией принадлежности следующего вида:

$$\mu_{R^{(k)}}(x, y) = \mu_{A^k \rightarrow B^k}(x, y). \quad (2)$$

В рассматриваемой нечётко-нейронной системе (представленной на рис.1) выполняется операция введения нечёткости (fuzzyfication) типа синглетон (singleton), что означает нахождение степени истинности для предпосылок каждого правила и определение для этого функции принадлежности $\mu_i^k(x)$

нечёткого множества $A_i^k \subseteq X = X_1 \times X_2 \times \dots \times X_n$ на входе системы нечёткого вывода выполняется по следующей формуле: $\mu_i^k(x) = \begin{cases} 1 & \text{если } x = x_i^* \\ 0 & \text{если } x \neq x_i^* \end{cases}$, где $x = (x_1, x_2, \dots, x_n)^T \in X$, - лингвистические переменные, а $X^* = (x_1^*, x_2^*, \dots, x_n^*)^T$ входные переменные нечёткой системы вывода.




Рисунок 1. Нейронная нечёткая система

В системе элементы в слое L_1 определяют функции принадлежности (обозначенные μ_i^k) нечётких множеств A_i^k , $i=1, 2, \dots, n$, $k=1, 2, \dots, N$, где n - количество входов в системе, N - количество нечётких правил. Выходы в L_1 представляют собой функции принадлежности $\mu_{A_i^k}(x)$ для конкретных значений x_i^* поданных на i -тый вход. В виде функции принадлежности в данных исследованиях использовались функции вида гауссова, определяемые по формуле:

$$\mu_{A_i^k}(x) = \exp \left[- \left(\frac{x_i^* - \bar{x}_i^k}{\sigma_i^k} \right)^2 \right], \quad (3)$$

где \bar{x}_i^k - является наиболее возможным значением переменной x , а величина σ_i^k представляет собой коэффициент концентрации или растяжения функции. Значения этих параметров корректируются в процессе обучения нечёткой нейронной системы.

В системе элементы второго слоя L_2 (обозначенные \min) реализуют нечёткий вывод согласно с методом нечёткого вывода Мамдани. В настоящее время в литературе кроме выше представленного алгоритма нечёткого вывода известны еще такие методы [Zadeh L.A., Kasprzyk J., 1992], [Rutkowska D., 1997]: алгоритм Larsena, алгоритм Sugeno, импликация Yager, импликация Zadeh, импликация Lukasiewicz, алгоритм TSK (Takagi-Sugeno-Kanga) и другие.

На выходах элементов второго слоя L2 получаем степени истинности предпосылок каждого нечёткого правила $R^{(k)}$ в системе, которые вычисляются следующим образом:

$$\tau_k = \min_{1 \leq i \leq n} \left\{ \mu_{A_i^k}(x_i) \right\}. \quad (4)$$

Количество элементов в этом слое равно количеству нечётких правил N. Элементами слоёв L3 и L4 являются обычные нейроны. В этих слоях выполняется классификация, а затем приведение к чёткости (defuzzification). На вход слоя L3 подаются степени истинности предпосылок нечётких правил τ_k , $k=1,2,\dots,N$, вычисляемые по формуле (4). В нем имеется M-нейронов, где M – количество классов, которые осуществляют взвешенное суммирование значений выходов нейронов предыдущего слоя. А их выходы формируются с использованием активационных функций. В качестве функции активации нейронов используется сигмоидальная функция следующего вида:

$$f(\alpha) = \frac{1}{1 + e^{-\alpha}}. \quad (5)$$

Выходы нейронов в этом слое интерпретируем как степени принадлежности к определённым классам. Следует отметить, что нечёткая классификация предполагает, что не всегда можно требовать принадлежность только к одной выбранной категории. Допускается возможность принадлежности данного образца в определённой степени к двум или трём классам. Необходимо в связи с этим разработать такой способ определения желаемых значений выходов во время обучения сети, учитывающий эту модификацию. В работе рассматривалась такая процедура, предложенная *Mitra i Pal*. Синаптические веса нейронов определяются в процессе обучения сети. Процедуры расчёта оптимальных значений синаптических весов выбираем в зависимости от того, какой алгоритм используем для обучения нечёткой нейронной сети. Если используется алгоритм Обратного Распространения Ошибок (*Back-propagation*), то расчёт оптимальных значений синаптических весов определяем следующим образом. Ошибку на выходе слоя L4 определяем по формуле:

$$Q_r = \frac{1}{2}(y_r - d_r)^2 \quad \text{для } r=1,2,3,\dots,M, \quad (6)$$

где $y_r^{(4)}$ для слоя L4 определяем как

$$y_r^{(4)} = f\left(\sum_{r=1}^M w_r^{(4)} y_r^{(3)} + w_0^{(4)}\right), \quad (7)$$

а также аналогично определяем для слоя L3. Полного вывода всех процедур и зависимостей в данной работе представлять нет возможности, поэтому рассмотрим только основные необходимые расчёты. Рекуррентные зависимости определяющие оптимальные значения синаптических весов в L4 согласно с алгоритмом *Backpropagation* представляются такими формулами:

$$w_r^{(4)}(t+1) = w_r^{(4)}(t) - \eta Q_r^{(4)}(t) y_r^{(3)}(t), \quad (8)$$

где $\eta \in (0,1)$, а $Q_r^{(4)}$ рассчитывается по следующей формуле:

$$Q_r^{(4)}(t) = (y_r^{(4)} - d_r) f'(s^{(4)}) | t \quad (9)$$

и означает ошибку в L_4 слое. Аналогично рассчитываются оптимальные значения весов в слое L_3 . Следующим этапом вычислений является определение оптимальных значений параметров функций принадлежности $\mu_{A_i^k}$, $i=1,2,\dots,n$, $k=1,2,\dots,N$, реализуемых в первом слое L_1 .

Чтобы определить процедуру обучения параметров функций принадлежности для представленной нечёткой нейронной системы, выполняем обратный проход алгоритма обучения до первого слоя L_1 . Это приводит к необходимости расчёта производной для функции \min (если это система нечёткого вывода по методу Mamdani, что выполнялось в настоящих исследованиях), которая, как известно, не дифференцируема. В таком случае воспользуемся операцией так называемой softmin , т.е. заменим определение \min приближённой операцией, которая выполняется по следующей формуле:

$$\text{soft min} = \frac{\sum_{i=1}^n \chi_i^k e^{-\varpi \chi_i^k}}{\sum_{i=1}^n e^{-\varpi \chi_i^k}}. \quad (10)$$

Тогда нетрудно доказать, что

$$\frac{\partial}{\partial \chi_i^k} \left(\min_{1 \leq j \leq n} \{ \chi_j^k \} \right) = \frac{e^{-\varpi \chi_i^k}}{\sum_{j=1}^n e^{-\varpi \chi_j^k}}. \quad (11)$$

Как отмечается во многих публикациях, выше представленный алгоритм обучения нечёткой нейронной сети, основанный на алгоритме Back-propagation не гарантирует достижения глобального экстремума оценки качества. В исследованиях предлагается гибридный подход, разработанный на основе [7], применяющий генетический алгоритм для нахождения решений близких глобальному оптимуму, которые потом используются как начальная точка для алгоритма обратного распространения ошибок, в результате работы которого находится действительный глобальный экстремум.

Обучение нечёткой нейронной сети при помощи гибридного метода с использованием генетического алгоритма подробно описан в публикации автора данной статьи [Сетлак Г., 2004].

Результаты исследований

Выше представленная нейронная нечёткая система, которая является составным модулем интеллектуальной системы поддержки принятия решений IDSS (Intelligent Decision Support System) [Сетлак Г., 2004], использовалась для решения задач маркетингового анализа рынка и оценки положения фирмы на нём. В настоящей работе представим анализ рынка сбыта изделий домашнего хозяйства предприятия ХХХ. В качестве анализируемых наблюдений используем информацию о динамике реализации продукции (продаже) изделий, а именно пылесосов за 1999 -2001 года [таблица 1]. На основе исторических данных система обнаруживает сложные зависимости между затратами на рекламу, объемом продажи, ценой изделий, затратами на стимулирование сбыта. В результате оценки этих параметров на выходе системы классификации определяются причины уменьшения объема продажи и падение спроса на рынках.

Таблица 1. Анализируемые данные о реализации продукции предприятием ХХХ

Год/квартал	Объём продажи (штуки)/	Затраты на стимулирование сбыта	Средняя цена (злотые)	Затраты на рекламу (в злотых)
1999 / I	227180	10000	385,65	12000
1999 / II	235090	6000	397,24	10000
1999 / III	217340	10000	452,20	10000
1999 / IV	261280	8000	478,92	12000
2000 / I	184380	5000	493,10	10000
2000 / II	147180	4000	526,35	8000
2000 / III	149300	3000	583,24	5000
2000 / IV	156520	4000	594,93	5000
2001 / I	121280	2000	620,70	5000
2001 / II	116530	0	634,56	10000
2001 / III	102160	0	663,20	2000
2001 / IV	112510	0	672,35	0

На вход нечёткой нейронной системы подаются следующие лингвистическая переменные:

X_1 – Цена (высокая, умеренная, низкая).

X_2 – Затраты на рекламу (высокие, средние, низкие).

X_3 – Эффективность рекламы (высокая, средняя, низкая), определяется как реакция изменения величины продажи к издержкам на рекламу, (возрастание или убывание).

X_4 – объём продажи (большой, но невозрастающий, средний, маленький).

X_5 – Затраты на стимулирование сбыта (высокие, средние, низкие).

Выходными параметрами классификации являются четыре класса, каждый из которых определяет одну из причин уменьшения объёма продажи и падение спроса на рынках:

Y_1 - Причина1 – (ошибочная маркетинговая стратегия), обозначено P1 .

Y_2 - Причина2 – (Мало эффективный вид рекламы), обозначено P2.

Y_3 - Причина3 – (Сезонное падение продажи), обозначено P3.

Y_4 - Причина4 – (Ошибочное ценообразование), обозначено P4.

Для моделирования функции принадлежности использовались гауссовы функции, показанные на рисунке 2, заданные формулой (3). На основе нечёткой базы правил, сформированной экспертами, строится нечёткая база знаний и разрабатывается система логического вывода. В качестве обучающей выборки для настройки нечёткой нейронной системы использовались результаты маркетингового анализа, выполненного для предприятия ХХХ фирмой экономического консалтинга в 2002 году, а также полученные в результате этого анализа оценки экспертов.

Исследовались следующие структуры нечётких нейронных систем:

- В этой структуре использовались гауссовы функции принадлежности вида (3), нечёткий вывод выполнялся методом Mamdani (т.е. импликация в форме нахождения минимум:

$\min[\mu_{A_i^k}(x), \mu_{B^k}(y)]$), параметры функции принадлежности и нечёткая нейронная сеть обучались

градиентным методом и гибридным, основанным на совместном использовании генетического алгоритма и Back-propagation.

- нечёткий вывод выполнялся методом Larsen'a (т.е. импликация в форме произведения $\mu_{A_i^k}(x) \cdot \mu_{B^k}(y)$), параметры функции принадлежности и нечёткая нейронная сеть обучались таким же образом, как и в выше описанной структуре. Общее число нечётких логических высказываний составляет $N = 26$.

Полученные результаты работы нечётко-нейронного классификатора представлены в таблице 2.

Таблица 2. Результаты работы нечётко-нейронного классификатора

N	X ₁	X ₂	X ₃	X ₄	X ₅	y
1	385,65	12000	Убывание	227180	10000	P1
2	397,24	10000	Незнач.рост	235090	6000	P1
3	452,20	10000	Убывание	217340	10000	P4
4	478,92	12000	Незнач.рост	261280	8000	P3
5	493,10	10000	Убывание	184380	5000	P3,P4
6	526,35	8000	Убывание	147180	4000	P2
7	583,24	5000	Убывание	149300	3000	P2,P3
8	594,93	5000	Незнач.рост	156520	4000	P1
9	620,70	5000	Убывание	121280	2000	P1,P2
10	634,56	10000	Убывание	116530	0	P2,P3

Практическая реализация и анализ выполнены с использованием программных пакетов NeuroSolutions CS и Genetic Library фирмы NeuroDimension [NeuroSolutions, 2002], а также нечёткая нейронная сеть моделировалась при помощи Fuzzy Logic Toolbox for MATLAB, программные модули интерфейса разработаны с использованием MS Visual C++.

Следует отметить, что в позициях 5,7,9,10, т.е. там, где определены две или больше причин падения цен, функции принадлежности к определённым классам были приблизительно равны. Возможность определения степени принадлежности некоторых переменных к двум или более классов является отличительной особенностью и преимуществом нечётко-нейронной классификации.

Выводы

В данной работе разработаны и представлены методы и алгоритмы обработки и анализа знаний разного вида (лингвистических, количественных, смешанных), основанные на нейронно-нечётких системах. Разработанная гибридная интеллектуальная система используется для решения задач классификации. Для обучения нечётких нейронных систем классификации используется Алгоритм обратного распространения ошибки (Back-propagation) и гибридный алгоритм, основанный на совместном использовании генетического алгоритма и метода Back-propagation.

Создан программный пакет для решения задач маркетингового анализа рынка и поддержки принятия решений в нечёткой среде. В результате оценки ретроспективной информации определяются причины понижения продажи изделий. Оценивается маркетинговая стратегия в фирме и политика ценообразования.

Важной особенностью представленных алгоритмов, входящих в состав нечёткой нейронной системы, является гибкость в отношении исходных данных для моделирования, способность использовать различные источники знаний. Предложенный подход к извлечению, представлению и обработке знаний, содержащих нечеткость, существенно повышает эффективность методологии автоматизированного построения интеллектуальных систем поддержки принятия решений. Все описанные модели, методы и процедуры программно реализованы и проходят этапы экспериментальной апробации, доработки и модификации.

Литература

- [Jang J. S.R., Sun C.T., Mizutani E.,1997] Jang J. S.R., Sun C.T., Mizutani E.: Neurofuzzy and Soft Computing, Prentice-Hall, Upper Saddle River 1997, p. 245.
- [Grabmeier J., A. Rudolph, 2002] Grabmeier J., A. Rudolph: Techniques of cluster algorithms in data mining, Data Mining and Knowledge Discovery, 2002, nr. 4, 303–360.
- [NeuroSolutions, 2002] NeuroSolutions, The Neural Network Simulation Environment, Copyright NeuroDimension Inc., Gainesville, 2002, 67 pp.
- [Rutkowska D., 1997] Rutkowska D.: Inteligentne systemy obliczeniowe, algorytmy genetyczne i Sieci neuronowe w systemach rozmytych, Akademicka Oficyna Wydawnicza PLJ, Warszawa, 1997r., 304 str.
- [Сетлак Г., 2000] Сетлак Г.: „Нейронные сети в интеллектуальных системах управления производством”, Международный научно-технический журнал «Проблемы управления и информатики», N1, 2000, str.112-119, Киев.
- [Сетлак Г., 2004] Сетлак Г.: Интеллектуальные системы поддержки принятия решений, Изд. ЛОГОС, Киев, 2004, стр.250.
- [Zadeh L.A., Kacprzyk J., 1992] Zadeh L.A., Kacprzyk J.(ed.): Fuzzy logic for the Management of Uncertainty, Wiley, New York, 1992, p. 492.

Информация об авторе

Galina Setlak – Ph.D., D.Sc, Eng., Associate Professor, Rzeszow University of Technology, Department of Computer Science , W. Pola 2 Rzeszow 35-959, Poland, Phone: (48-17)- 86-51-433, gsetlak@prz.edu.pl