

ИНТЕЛЛЕКТУАЛЬНЫЕ ТЕХНОЛОГИИ В МАРКЕТИНГОВОМ АНАЛИЗЕ

Г. СЕТЛАК

Описаны процедуры и алгоритмы использования методов искусственного интеллекта для обработки и анализа различных видов знаний. Предлагается интегрировать такие технологии моделирования знаний и процессов принятия решений, как нейронные сети и методы, основанные на нечеткой логике. Нейронная нечеткая система используется для решения задачи идентификации сложных процессов. Рассмотрен пример использования предлагаемого подхода в задачах анализа рынка.

ВВЕДЕНИЕ

В условиях глобализации международного рынка и растущей конкуренции для эффективного управления современным производством необходим широкий спектр знаний. В хозяйственной деятельности любой организации циркулируют огромные потоки разнородной информации, являющиеся источниками знаний о процессах и функциях, необходимых для решения управленческих задач. Такие знания представляют собой огромное количество информации разных видов (количественной, качественной или лингвистической, графической) из различных источников, иногда это сложные объединенные структуры разных видов, неполные, неточные или противоречивые, часто знания очень трудно или вообще невозможно формализовать.

Филипп Котлер отметил [1]: «Если данные не будут преобразованы в информацию, которая станет основой знаний, а знания — источником мудрости, потеряем значительно больше, чем приобретем». Это высказывание всемирно известного специалиста в области маркетинга показывает смысл и необходимость создания современных технологий и систем обработки всех огромных потоков информации с целью извлечения из них знаний, необходимых менеджеру для принятия оптимальных решений в управлении производством.

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 объемов информации. Data Mining иначе еще называется в литературе интеллектуальным анализом данных, что означает процесс обнаружения в «сырых данных» (raw data) ранее неизвестных, практически полезных и доступных интерпретации знаний, закономерностей, полезных для принятия решений в различных сферах человеческой деятельности. Интеллектуальный анализ данных заключается в применении алгоритмов обработки для выявления скрытых тенденций, закономерностей, взаимосвязей и перспектив развития процесса, учет кото-

рых помогает повысить качество принимаемых решений и снизить риск. При этом выделяются пять стандартных типов закономерностей (ассоциация, последовательность, классификация, кластеризация, прогнозирование), которые могут быть выявлены методами Data Mining.

Основой для новой парадигмы современной технологии анализа информации являются последние достижения в области развития методов искусственного интеллекта.

В настоящей статье 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 нечетких множеств и логики (средства формализации естественно-языковых высказываний и нечеткого логического вывода), а также генетические алгоритмы.

Достоинства таких гибридных нейронно-нечетких систем — гибкость, способность к адаптации за счет различных методов обучения, простота реализации, удобство при настройке, а также высокие показатели качества.

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 способности нейронных сетей к самообучению и нечетких систем обрабатывать качественную информацию. Несомненное достоинство гибридной нейронно-нечеткой технологии моделирования и обработки информации заключается в возможности просмотра сформированных правил и придания им содержательной (лингвистической) интерпретации, что позволяет рассматривать аппарат нейронно-нечетких систем как средство извлечения знаний из экспериментальных баз данных. Извлечение знаний из обученных нейронных сетей имеет фундаментальное значение для создания более устойчивых гибридных интеллектуальных систем.

Цель данной работы — оценить возможности использования нечетких нейронных систем для предварительной обработки и анализа информации разного вида, а также для решения задач классификации. Рассматриваются методы и алгоритмы извлечения знаний из нечетких баз данных. Решается практическая задача маркетингового анализа рынка.

Маркетинговый анализ рынков сбыта продукции предоставляет менеджеру существенно важные знания о потенциальных возможностях рынка, характеристиках потребностей, тенденциях формирования цен и эффективности рекламы, а также дает возможность изучить характеристики рынка, каналов распределения и стратегий стимулирования сбыта. Обычно система анализа маркетинговой информации использует такие статистические методы, как регрессионный, корреляционный, дискриминантный и факторный анализы. В настоящей работе анализ рынка выполняется с помощью нейронной нечеткой системы.

НЕЙРОСЕТЕВЫЕ СИСТЕМЫ НЕЧЕТКОЙ КЛАССИФИКАЦИИ

Проблемы классификации — одни из наиболее часто возникаемых и решаемых задач как в повседневной хозяйственной деятельности, так и в экономическом ее анализе в каждой организации. Решение задач классификации

заключается в разработке, конструировании таких правил и закономерностей, которые позволили бы распознать определенные 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 (например, при оценке конкурентоспособности предприятия), тем более, если эти характеристики слабо определены или трудно формализуемы.

Раньше для решения задач классификации использовались так называемые таксономические методы (таксономия — статистическая научная дисциплина, занимающаяся разработкой основ и процедур классификации). Главная трудность во всех стандартных статистических методах заключается в том, что большая часть знаний, используемых для классификации, представляет собой распределение случайных переменных. Особенно большие проблемы появляются при использовании непараметрических методов классификации для многомодальных распределений [2,4]. В последние годы для решения сложных задач классификации все чаще используются искусственные нейронные сети. На основе многочисленных исследований подтверждено, что нейронные сети обеспечивают высокую эффективность распознавания [4 – 6]. При этом они отличаются исключительной устойчивостью перед случайными помехами. Нейронные сети приспособлены для обнаружения сложных зависимостей при отсутствии априорных знаний об исследуемых процессах или объектах и отлично работают со всеми наиболее сложными распределениями данных, поэтому с успехом используются везде, где производится оценивание с помощью статистических методов анализа, таких как регрессионный, кластерный, дискриминантный или временные ряды, в том числе и для решения задач классификации, кластеризации и прогнозирования.

Автор данной статьи исследовал возможности использования нескольких видов искусственных нейронных сетей для решения практических задач классификации. Анализировал и оценивал такие нейронные сети, как рекуррентная Hamminga [8], многослойный персептрон, сеть радиальной базисной функции, вероятностные и сети Кохонена. Анализ производился при решении задачи стратегического менеджмента, состоящей в распределении различных моделей изделий по четырем рынкам сбыта. Результаты анализа показали, что для корректной работы и реального применения нейронных сетей необходимо обучать их на достаточно обширных выборках входных данных, причем, 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 (что возможно при использовании представленных выше нейронных сетей). Еще один, очень важный, недостаток нейросетевой технологии заключается в том, что даже обученная нейронная сеть представляет собой «черный ящик». Знания о решаемой проблеме и сама модель системы неявно определяются в процессе проектирования нейронных сетей. Знания представляются в них в виде синаптических весов

межнейронных связей и совершенно не поддаются анализу и интерпретации человеком, в связи с чем совершенно невозможно объяснить выходной результат. Поэтому возникает необходимость поиска более адекватной технологии для моделирования и анализа знаний разного вида при решении задач стратегического менеджмента. Наиболее обещающее направление в исследованиях и разработке таких интеллектуальных инструментов — это объединение двух независимых интеллектуальных технологий: искусственных нейронных сетей и нечеткой логики.

Теория нечетких множеств и нечеткой логики (Л. Заде) в течение почти сорока лет широко используется как инструмент для моделирования и обработки нечеткой, лингвистической или так называемой качественной информации, моделирования мышления человека, его способности использовать приближенные оценки описания сложных, плохо формализуемых процессов принятия решений в различных областях деятельности [3, 5, 7]. Самое главное достоинство такого подхода состоит в том, что в нечетких системах вывода легко построить объяснение результата в виде протокола рассуждений.

Существенный недостаток нечетких систем: они не способны обучаться и адаптироваться к изменяющейся ситуации, вид и параметры функций принадлежности выбираются в них субъективно и могут не вполне отражать реальную действительность. Поэтому для корректировки параметров функций принадлежности и адаптации нечетких систем в процессе их работы применяются нейронные сети, которые характеризуются, прежде всего, уникальной способностью обучаться и адаптироваться.

Интеграция двух независимых интеллектуальных технологий — искусственных нейронных сетей и систем с нечеткой логикой — представляется наиболее естественным процессом, который позволяет создать новую, более универсальную методологию обработки различных видов знаний и моделирования сложных процессов.

ПОСТАНОВКА ЗАДАЧИ

Исходные данные:

- Входные переменные $X = (x_1, x_2, \dots, x_n)^T$, причем $X \in X_1 \times X_2 \times \dots \times X_n$ — терм-множества 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 нечетким множествам A_i^k , ($i = 1, 2, \dots, n$, $k = 1, 2, \dots, N$).
- Нечеткие предикатные правила зависимостей, связывающих значения входных переменных с одним из возможных значений выходной переменной, разработанные экспертом (так называемая нечеткая база знаний) — логические высказывания типа ЕСЛИ — ТО.

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

Рассмотрим нечетко-нейронную систему (рис. 1).

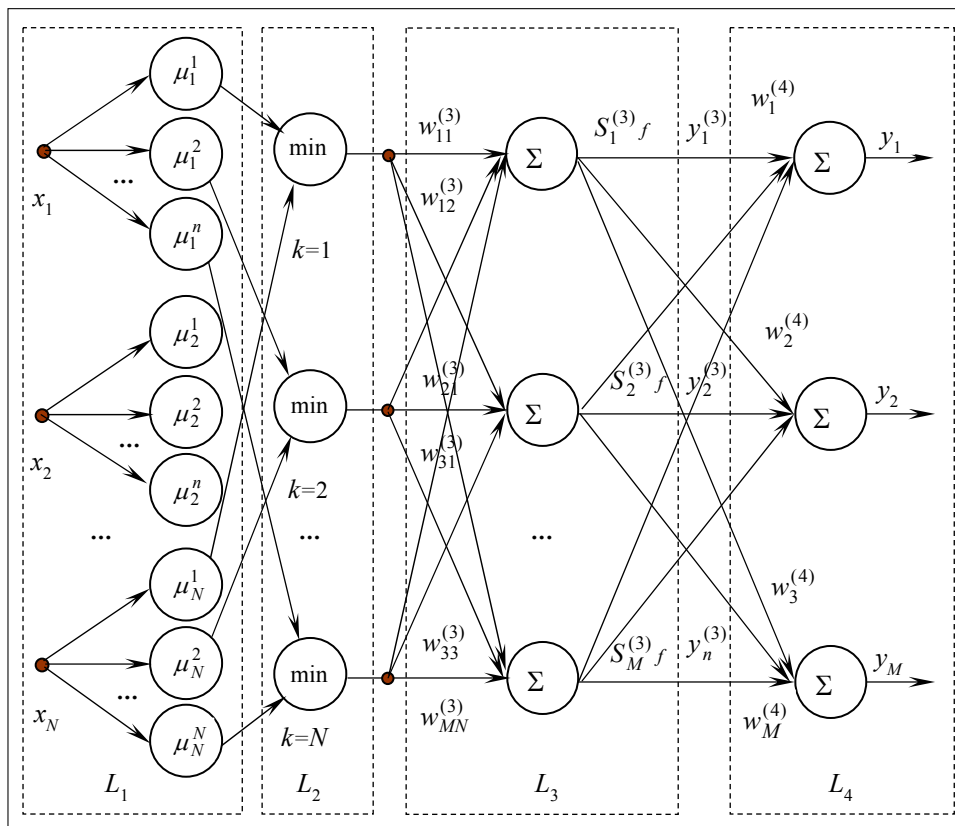


Рис. 1. Нейронная нечеткая система

Определение 1. Нечетко-нейронной системой будем называть многослойную структуру, в состав которой входят следующие элементы:

Система нечеткого вывода, на вход которой подаются лингвистические переменные (термы). В каждую нечеткую систему выводов входят [3, 7]: блок приведения к нечеткости (fuzzification), база правил, содержащая совокупность нечетких правил, механизм выводов и блок приведения к четкости (defuzzification). Нечеткая система обучается оптимизационными методами (модифицированным алгоритмом обратного распространения ошибок Backpropagation или с помощью гибридного метода, основанного на генетическом алгоритме, используемом в нейронных сетях). В выходном слое нечетко-нейронной системы используется нейронная сеть для выполнения операции приведения к четкости.

Определение 2. Нечеткая база знаний представляет собой совокупность правил типа 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

$$R^{(k)}: \text{если } x_1 \text{ есть } A_1^k \text{ и } x_2 \text{ есть } A_2^k \text{ и } \dots \text{ и } x_n \text{ есть } A_n^k, \text{ то } y \text{ is } B^k, \quad (1)$$

в которых N означает число нечетких правил; x_1, x_2, \dots, x_n, y — лингвистические переменные; A_i^k — нечеткие множества предпосылок правил ($i=1, 2, \dots, n, k=1, 2, \dots, N$) и B^k — нечеткое множество заключений.

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

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

В рассматриваемой нейронной нечеткой системе (рис. 1) выполняется операция введения нечеткости (fuzzyfication — фаззификация) типа синглетон (singleton), что означает нахождение степени истинности для предпосылок каждого правила и определение функции принадлежности $\mu_i^k(x)$ нечеткого множества $A_i^k \subseteq X = X_1 \times X_2 \times \dots \times X_n$ на входе системы нечеткого вывода по следующей формуле: $\mu_i^k(x) = \begin{cases} 1, & \text{если } x = x^* \\ 0, & \text{если } x \neq x^* \end{cases}$, 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 нечеткой системы вывода.

В системе элементы в слое L_1 реализуют функции принадлежности (обозначенные μ_i^k) нечетких множеств $A_i^k, i=1, 2, \dots, n, k=1, 2, \dots, N$, где n — количество входов в системе; N — количество нечетких правил. Выходы в L_1 представляют собой функции принадлежности $\mu_{A_i^k}(x)$ для конкретных значений x_i^* , поданных на i -й вход. В качестве функции принадлежности в данных исследованиях использовались функции Гаусса, 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 — наиболее возможное значение переменной x а величина $\bar{\sigma}_i^k$ представляет собой коэффициент концентрации или растяжения функции (рис. 2). Значения этих параметров корректируются в процессе обучения нечеткой нейронной системы.

В системе элементы второго слоя L_2 (обозначенные min) реализуют нечеткий вывод согласно с методом нечеткого вывода Мамдани. В настоящее время в литературе, кроме выше представленных алгоритмов нечеткого вывода, известны такие методы [3, 7]:

- алгоритм Larsena;
- алгоритм Sugeno;
- импликация Yager;
- импликация Zadeh;
- импликация Lukasiewicz;
- алгоритм TSK (Takagi-Sugeno-Kanga) и др.

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

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

Количество элементов в этом слое равно количеству нечетких правил N . Элементами слоев L_3 и L_4 являются обычные нейроны. В этих слоях




Рис. 2. Функции принадлежности Гаусса

выполняются классификация, а затем приведение к четкости (defuzzification). На вход слоя L_3 подаются степени истинности предпосылок нечетких правил τ_k , $k=1, 2, \dots, N$, вычисляемых по формуле (4). В нем имеется M нейронов, где M — количество классов, осуществляющих взвешенное суммирование значений выходов нейронов предыдущего слоя. А их выходы формируются с

использованием активационных функций. В качестве функции активации нейронов используется сигмоидальная функция вида

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

Выходы нейронов в этом слое интерпретируем как степени принадлежности к определенным классам. Следует отметить: нечеткая классификация предполагает, что не всегда можно требовать принадлежности только к одной выбранной категории. Допускается возможность принадлежности данного образца с определенными предпочтениями к двум или трем классам. Необходимо в связи с этим разработать способ определения желаемых значений выходов во время обучения сети, учитывающий эту модификацию.

В работе рассматривалась такая процедура, предложенная Mitra и Pal в работе [6].

Синаптические веса нейронов определяются в процессе обучения сети. Процедуры расчета оптимальных значений синаптических весов выбираем в зависимости от того, какой алгоритм используем для обучения нечеткой нейронной сети. Если используется алгоритм обратного распространения ошибок (Back-propagation), то расчет оптимальных значений синаптических весов определяем следующим образом.

Ошибку на выходе слоя L_4 рассматриваем по формуле

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

где $y_r^{(4)}$ для слоя L_4 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 L_3 . Полный вывод всех процедур и зависимостей в данной работе невозможно представить, поэтому рассмотрим только основные необходимые расчеты. Рекуррентные зависимости, определяющие оптимальные значения синаптических весов в L_4 , в соответствии 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

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

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 нечеткой нейронной системы, выполняем обратный проход алгоритма обучения до первого слоя L_1 . Для этого необходимо рассчитать производную для функции \min (если это система нечеткого вывода по методу Mamdani такая, как и в настоящих исследованиях), которая, как известно, не дифференцируема. В таком случае воспользуемся операцией softmin , т.е. заменим определение \min приближенной операцией, выполняемой по формуле

$$\text{soft min}_{1 \leq i \leq n} = \frac{\sum_{i=1}^n x_i^k e^{-\omega x_i^k}}{\sum_{i=1}^n e^{-\omega x_i^k}}. \quad (10)$$

Тогда нетрудно доказать, что

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

Поэтому для $\chi_i^k = \mu_{A_i^k}(x_i^*)$, $i=1, 2, \dots, n$, $k=1, 2, \dots, N$, обозначив

$$\varphi_k = \frac{\partial}{\partial \mu_{A_i^k}(x_i^*)} \left(\min_{1 \leq j \leq n} \{ \mu_{A_i^k}(x_i^*) \} \right),$$

можем рассчитать необходимую величину

$$\frac{\partial \tau_k}{\partial \mu_{A_i^k}(x_i^*)} = \varphi_k,$$

где τ_k — степени истинности предпосылок каждого нечеткого правила $R^{(k)}$ в системе, вычисляемые по формуле (4). На основе формулы (11) для $\chi_i^k = \mu_{A_i^k}(x_i^*)$ можно записать

$$\varphi_k \approx \frac{e^{-\omega \mu_{A_i^k}(x_i^*)}}{\sum_{j=1}^n e^{-\omega \mu_{A_i^k}(x_i^*)}}. \quad (12)$$

Тогда, если функции принадлежности являются гауссовскими, заданными формулой (3), и ошибка вычисляется по формуле (6), то процедура обучения параметров \bar{x}_i^k , $\bar{\sigma}_i^k$ примет вид

$$\bar{x}_i^k(t+1) = \bar{x}_i^k(t) - 2\eta \left(\sum_{r=1}^M Q_r^{(3)} w_{rk}^{(3)} \right) \frac{(x_i^* - \bar{x}_i^k)^2}{(\sigma_i^k)^2} \varphi_k \exp \left[- \left(\frac{x_i^* - \bar{x}_i^k}{\sigma_i^k} \right)^2 \right] (t), \quad (13)$$

$$\sigma_{x_i^k}(t+1) = \sigma_i^k(t) - 2\eta \left(\sum_{r=1}^M Q_r^{(3)} w_{rk}^{(3)} \right) \frac{(x_i^* - \bar{x}_i^k)^2}{(\sigma_i^k)^2} \varphi_k \exp \left[- \left(\frac{x_i^* - \bar{x}_i^k}{\sigma_i^k} \right)^2 \right] (t), \quad (14)$$

где $w_{rk}^{(3)}$ — синаптические веса в L_3 .

Как отмечается во многих публикациях, описанный алгоритм обучения нечеткой нейронной сети, основанный на алгоритме Back-propagation, не гарантирует достижения глобального экстремума оценки качества. В исследованиях предлагается гибридный подход, разработанный на основе работы [7], применяющий генетический алгоритм для нахождения решений, близких к глобальному оптимуму, используемых потом в качестве начальной

точки для алгоритма обратного распространения ошибок, в результате работы которого находится действительный глобальный экстремум.

Обучение нечеткой нейронной сети с помощью гибридного метода с использованием генетического алгоритма подробно описан автором данной статьи в работе [9].

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЙ

Описанная выше нейронная нечеткая система — составной модуль интеллектуальной системы поддержки принятия решений IDSS (Intelligent Decision Support System) [9] — использовалась для решения задач маркетингового анализа рынка и оценки положения на нем фирмы.

Концепция маркетинга [1] заключается в утверждении, что «залогом достижения цели организации являются определение нужд и потребностей целевых рынков и обеспечение желаемой удовлетворенности более эффективными и более продуктивными, чем у конкурентов способами». Исходный пункт процесса управления маркетингом — анализ рыночных возможностей и отбор целевых рынков.

Таблица 1. Данные о реализации продукции предприятием ХХХ

Год / квартал	Объем продажи, штуки	Затраты на стимулирование сбыта, злотые	Средняя цена, злотые	Затраты на рекламу, злотые
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

Приведем 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 гг. (табл. 1). На основе архивных 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.

На вход нечеткой нейронной системы подаются следующие лингвистические переменные:

X_1 — цена (высокая, умеренная, низкая — В, У, Н).

X_2 — затраты на рекламу (высокие, средние, низкие — В, С, Н).

X_3 — эффективность рекламы (высокая, средняя, низкая — В, С, Н).

Определяется как реакция изменения величины продажи на рекламные издержки (возрастание или убывание).

X_4 — объем продажи (большой, но невозрастающий; средний; маленький — Бнв, С, М).

X_5 — затраты на стимулирование сбыта (высокие, средние, низкие — В, С, Н).

Выходными параметрами классификации являются четыре класса (Y_1, Y_2, Y_3, Y_4), каждый из которых определяет одну из причин уменьшения объема продажи и падение спроса на рынках.

Y_1 — причина1 (ошибочная маркетинговая стратегия) обозначена P_1 .

Y_2 — причина2 (малоэффективный вид рекламы) — P_2 .

Y_3 — причина3 (сезонное падение продажи) — P_3 .

Y_4 — причина4 (ошибочное ценообразование) — P_4 .

Оценивались два варианта классификации.

1. Определялись степени принадлежности входных наборов параметров ко всем четырем классам (причинам). При этом использовалась процедура определения желаемых значений выходов во время обучения сети, предложенная в работе [6].

2. На выходе системы определялся только один класс.

Для моделирования функции принадлежности использовались гауссовы функции, показанные




Рис. 3. Функции принадлежности переменной X_2

вы функции, показанные на рис. 2, заданные формулой (3). На рис. 3 приведены принятые функции принадлежности для переменной X_2 — затраты на рекламу.

На основе нечеткой базы правил, сформированной экспертами, строится нечеткая база знаний и разрабатывается система логического вывода. Структура нечеткого логического вывода приведена на рис. 4.

В качестве обучающей выборки для настройки нечеткой нейронной системы использовались результаты маркетингового анализа, выполненного для предприятия ХХХ фирмой экономического консалтинга в 2002 г., а также полученные в результате этого анализа оценки экспертов.

Исследовались следующие структуры нечетких нейронных систем:

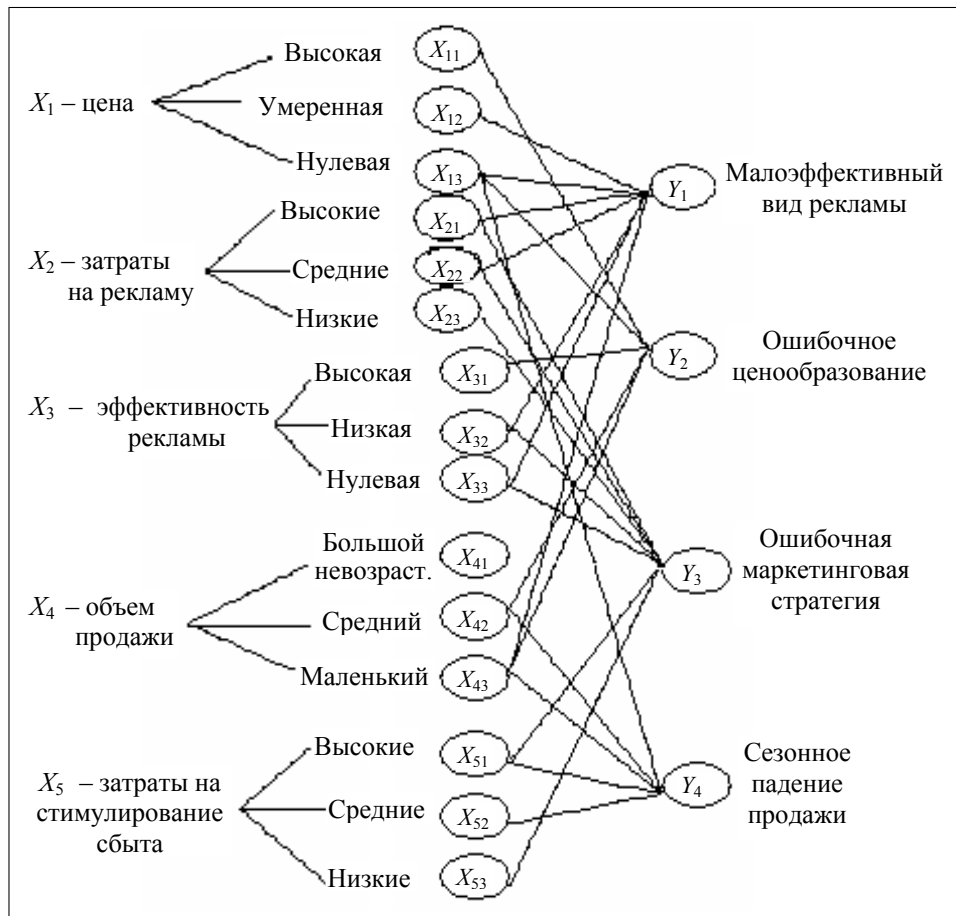


Рис. 4. Структура нечеткого логического вывода

1. Гауссовы функции принадлежности вида (3). Нечеткий вывод выполнялся методом Mamdani (импликация в форме нахождения $\min [\mu_{A_i^k}(x) \mu_{B^k}(y)]$). Параметры функции принадлежности и нечеткая нейронная сеть обучались градиентным методом и гибридным, основанным на совместном использовании генетического алгоритма и Back-propagation [9].

2. Нечеткий вывод выполнялся методом Larsen'a (импликация в форме произведения $\mu_{A_i^k}(x) \mu_{B^k}(y)$). Параметры функции принадлежности и нечеткая нейронная сеть обучались таким же образом, как и в описанной выше структуре.

Общее число нечетких логических высказываний составляет $N = 26$. Практическая реализация и анализ выполнены с использованием программных пакетов NeuroSolutions CS и Genetic Library фирмы NeuroDimension [10]. Нечеткая нейронная сеть моделировалась при помощи FlexTools и Fuzzy Logic Toolbox for MATLAB. Программные модули интерфейса разработаны с использованием MS Visual C++. Полученные результаты работы нечетко-нейронного классификатора приведены в табл. 2.

Таблица 2. Результаты работы нечетко-нейронного классификатора

№	X_1	X_2	X_3	X_4	X_5	y
1	385,65	12000	Убывание	227180	10000	P1
2	397,24	10000	Незначительный рост	235090	6000	P1
3	452,20	10000	Убывание	217340	10000	P4
4	478,92	12000	Незначительный 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	Незначительный рост	156520	4000	P1
9	620,70	5000	Убывание	121280	2000	P1, P2
10	634,56	10000	Убывание	116530	0	P2, P3
11	663,20	2000	Убывание	102160	0	P2, P3
12	672,35	0	∞	112510	0	P1, P2, P3

Следует отметить, что в позициях 5, 7, 9, 10, 11 и 12, т.е. там, где определены две или больше причин падения цен, функции принадлежности к определенным классам были приблизительно равны ($\mu(y_i) \approx 0,5$ или $\mu(y_i) \approx 0,33$). Возможность определения степени принадлежности некоторых переменных к двум или более классам является отличительной особенностью и преимуществом нечетко-нейронной классификации.

ВЫВОДЫ

В данной работе описаны методы и алгоритмы обработки и анализа знаний разного вида (лингвистических, количественных, смешанных), основанных на нейронно-нечетких системах. Разработанная гибридная интеллектуальная система используется для решения задач классификации. Для обучения нечетких 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 нечеткой среде. Решена практическая задача анализа рынка сбыта изделий домашнего хозяйства. В результате оценки ретроспективной информации определяются причины понижения продажи изделий. Оценивается маркетинговая стратегия в фирме и политика ценообразования.

Важной особенностью предложенных алгоритмов, входящих в состав нечеткой нейронной системы, является гибкость в отношении исходных данных для моделирования, способность использовать различные источники знаний.

Рассмотренную систему маркетингового анализа данных IDSS, основанную на нечеткой нейронной сети, можно использовать при планировании цен и затрат для оптимизации объема продажи и прибыли. Так как спрос и условия реализации продукции зависят от времени, рекламы, продвижения продуктов (стимулирования сбыта) и многих других факторов, то и объем производства следует гибко варьировать для оптимального использования ресурсов.

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 реализованы программно и проходят этапы экспериментальной апробации, доработки и модификации.

ЛИТЕРАТУРА

1. *Kotler Ph.* Marketing essentials, Prentice-Hall International, Englewood Cliffs, 1984. — 733 p.
2. *Witkowska D.* Sztuczne sieci neuronowe i metody statystyczne. — Warszawa: Wyd C.H. BECK, 2002. — 201 s.
3. *Bellman R.E., Zadeh L.A.* Decision making in a fuzzy environment. — Management Sciences. — **17**. — 1970. — P. 141–164.
4. *Jang J.S.R., Sun C.T., Mizutani E.* Neurofuzzy and Soft Computing, Prentice-Hall, Upper Saddle River, 1997. — 245 p.
5. *Ротштейн А.П.* Интеллектуальные технологии идентификации. — Винница: УНИВЕРСУМ, 1999. — 300 с.
6. *Pal S., Mitra S.* Multilayered perceptron. Fuzzy sets and classification // IEEE Transactions on Neural Networks. — 1992. — № 5. — P. 683–697.
7. *Rutkowska D.* Inteligentne systemy obliczeniowe, algorytmy genetyczne i Sieci neuronowe w systemach rozmytych. — Warszawa: Akademicka Oficyna Wydawnicza PLJ, 1997. — 304 s.
8. *Сетлак Г.* Нейронные сети в интеллектуальных системах управления производством // Проблемы управления и информатики. — 2000. — № 1. — С. 112–119.
9. *Сетлак Г.* Интеллектуальная система поддержки принятия решений в нечеткой среде. — Искусственный интеллект. — 2002. — № 3. — С. 428–438.
10. *NeuroSolutions.* The neural network simulation environment, Copyright NeuroDimension Inc. — Gainesville. — 2002. — 67 p.

Поступила 23.05.2003