

Технология Data Mining

Выполнил:
магистрант 1 курса
Ивкин М. С.

Data Mining

Это собирательное название, используемое для обозначения совокупности методов обнаружения в данных ранее неизвестных, нетривиальных, практически полезных и доступных интерпретации знаний, необходимых для принятия решений в различных сферах человеческой деятельности.

Определение. Data Mining - это процесс поддержки принятия решений, основанный на поиске в данных скрытых закономерностей (шаблонов информации).

Классификация задач Data Mining

- классификация,
- кластеризация,
- прогнозирование,
- ассоциация,
- визуализация,
- анализ и обнаружение отклонений,
- оценивание,
- анализ связей.

Основные методы Data mining

- методы классификации, моделирования и прогнозирования, основанные на применении деревьев решений, искусственных нейронных сетей, генетических алгоритмов, эволюционного программирования, ассоциативной памяти, нечёткой логики;
- статистические методы - дескриптивный анализ, корреляционный и регрессионный анализ, факторный анализ, дисперсионный анализ, компонентный анализ, дискриминантный анализ, анализ временных рядов.

Нечеткая логика

- Математическая теория нечетких множеств (fuzzy sets) и нечеткая логика (fuzzy logic) являются обобщениями классической теории множеств и классической формальной логики.
- Данные понятия были впервые предложены американским ученым Лотфи Заде (Lotfi Zadeh) в 1965 г.
- Основной причиной появления новой теории стало наличие нечетких и приближенных рассуждений при описании человеком процессов, систем, объектов.

Периоды развития

- Первый период (конец 60-х–начало 70 гг.) характеризуется развитием теоретического аппарата нечетких множеств (Л. Заде, Э. Мамдани, Беллман).
- Во втором периоде (70–80-е годы) появляются первые практические результаты в области нечеткого управления сложными техническими системами (парогенератор с нечетким управлением).
- Наконец, в третьем периоде, который длится с конца 80-х годов и продолжается в настоящее время, появляются пакеты программ для построения нечетких экспертных систем, а области применения нечеткой логики заметно расширяются.

Математический аппарат

- Характеристикой нечеткого множества выступает функция принадлежности (Membership Function). Обозначим через $MF(x)$ – степень принадлежности к нечеткому множеству C
- Тогда нечетким множеством C называется множество упорядоченных пар вида $C=\{MF_c(x)/x\}$, $MF_c(x) [0,1]$. Значение $MF_c(x)=0$ означает отсутствие принадлежности к множеству, 1 – полную принадлежность.
- Для нечетких множеств, как и для обычных, определены основные логические операции. Самыми основными, необходимыми для расчетов, являются пересечение и объединение.
- Пересечение двух нечетких множеств (нечеткое "И"): $A \cap B$: $MF_{AB}(x)=\min(MF_A(x), MF_B(x))$.
- Объединение двух нечетких множеств (нечеткое "ИЛИ"): $A \cup B$: $MF_{AB}(x)=\max(MF_A(x), MF_B(x))$.

Нечеткая и лингвистическая переменные

- Нечеткая переменная описывается набором (N, X, A) , где N – это название переменной, X – универсальное множество (область рассуждений), A – нечеткое множество на X .
- Значениями лингвистической переменной (N, T, X, G, P) могут быть нечеткие переменные, т.е. лингвистическая переменная находится на более высоком уровне, чем нечеткая переменная.
- Каждая лингвистическая переменная состоит из:
 - названия;
 - множества своих значений, которое также называется базовым терм-множеством T . Элементы базового терм-множества представляют собой названия нечетких переменных;
 - универсального множества X ;
 - синтаксического правила G , по которому генерируются новые термы с применением слов естественного или формального языка;
 - семантического правила P , которое каждому значению лингвистической переменной ставит в соответствие нечеткое подмножество множества X .

Типовые формы кривых для задания функций принадлежности

Существует свыше десятка типовых форм кривых для задания функций принадлежности. Наибольшее распространение получили:

- *треугольная,*
- *трапецеидальная,*
- *гауссова функции принадлежности.*

Треугольная функция принадлежности

Определяется тройкой чисел (a, b, c) , и ее значение в точке x вычисляется согласно выражению:

$$MF(x) = \begin{cases} 1 - \frac{b-x}{b-a}, & a \leq x \leq b \\ 1 - \frac{x-b}{c-b}, & b \leq x \leq c \\ 0, & \text{в остальных случаях.} \end{cases}$$

Трапецеидальная функция принадлежности

Для задания трапецеидальной функции принадлежности необходима четверка чисел (a,b,c,d):

$$MF(x) = \begin{cases} 1 - \frac{b-x}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ 1 - \frac{x-c}{d-c}, & c \leq x \leq d \\ 0, & \text{в остальных случаях.} \end{cases}$$

Гауссова функция принадлежности

Функция принадлежности гауссова типа описывается формулой:

$$MF(x) = \exp\left[-\left(\frac{x - c}{\sigma}\right)^2\right]$$

где c – центра нечеткого множества

Графическое изображение




Рисунок 1. Типовые кусочно-линейные функции принадлежности.




Рисунок 2. Гауссова функция принадлежности.

Формализация неточного понятия «возраст человека»



Рисунок 4. Описание лингвистической переменной «Возраст».

Так, для человека 48 лет степень принадлежности к множеству «Молодой» равна 0, «Средний» – 0,47, «Выше среднего» – 0,20.

!!! Количество термов в лингвистической переменной редко превышает 7.

Механизм логического вывода

В общем случае механизм логического вывода включает четыре этапа: введение нечеткости (фазификация), нечеткий вывод, композиция и приведение к четкости, или дефазификация:




Рисунок 5. Система нечеткого логического вывода.

Интеграция с интеллектуальными парадигмами

Гибридизация методов интеллектуальной обработки информации – девиз, под которым прошли 90-е годы у западных и американских исследователей. В результате объединения нескольких технологий искусственного интеллекта появился специальный термин – "мягкие вычисления" (soft computing), который ввел Л. Заде в 1994 году.

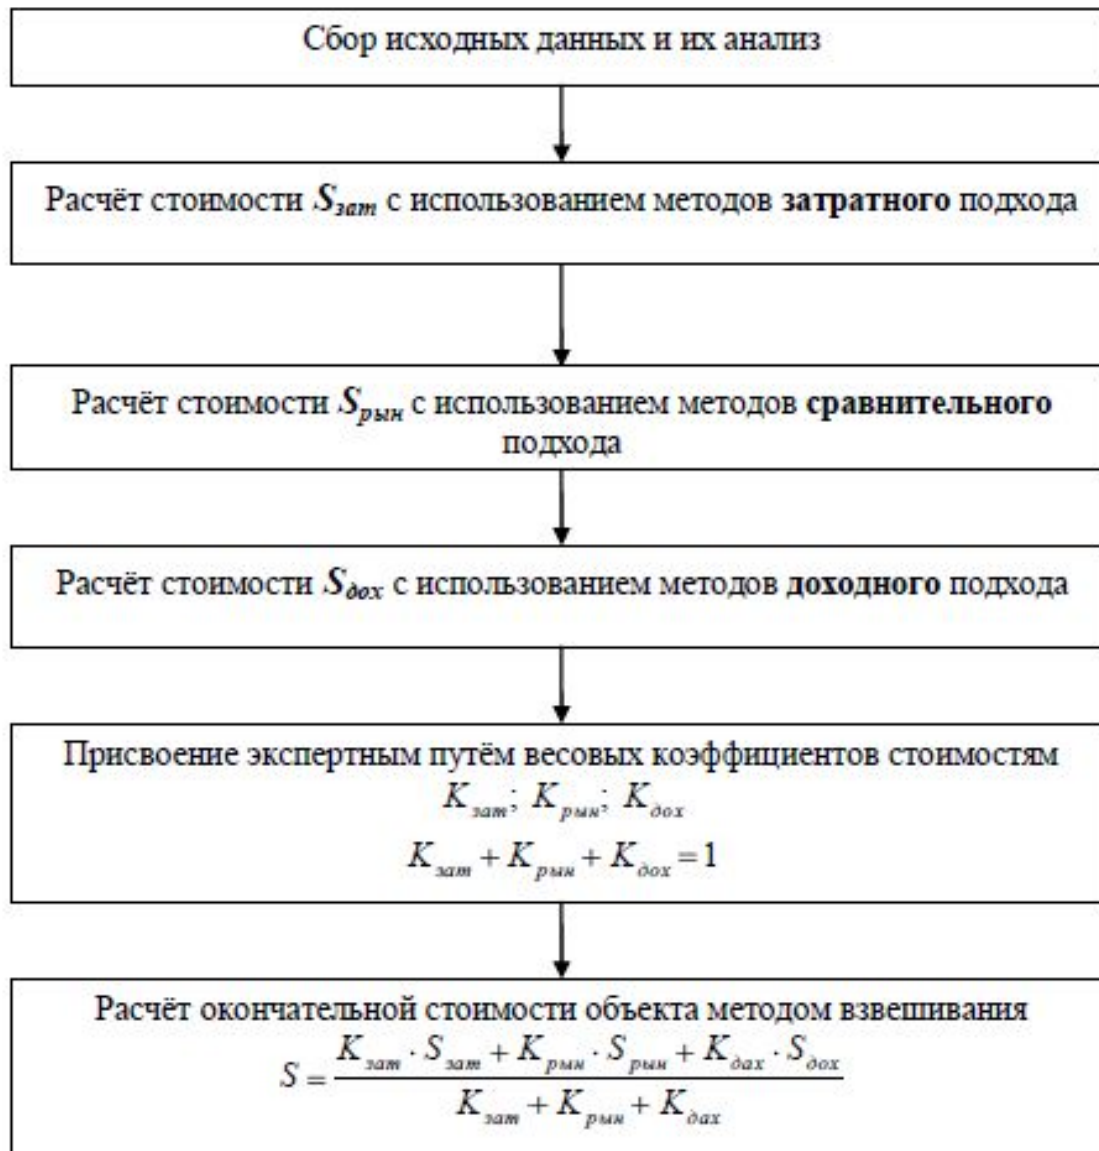
Примеры объединения нескольких технологий

- *Нечеткие нейронные сети,*
- *Адаптивные нечеткие системы,*
- *Нечеткие запросы,*
- *Нечеткие ассоциативные правила,*
- *Нечеткие когнитивные карты,*
- *Нечеткая кластеризация и т. п.*

Применение методов нечеткой логики при оценке информационных ресурсов предприятий

- *Информационные ресурсы организации (ИР)* – ресурсы нового типа, характеризующие интеллектуальный потенциал организации – до сих пор не рассматриваются руководителями и бухгалтерами как объекты финансового учёта.
- Большинство российских организаций на сегодняшний день не решают задач инвентаризации, оценки и коммерциализации информационных ресурсов, что противоречит современным методам управления.
- Идентификация, анализ и оценка информационных ресурсов становится экономической необходимостью для любой организации независимо от её размера и вида деятельности.

Оценка информационных ресурсов



Предположим, что стоимости, полученные тремя основными методами, представляют собой Т – числа и имеют следующие значения (в тыс. руб.):

$S_{\text{зат}}=[100; 250; 450; 650];$

$S_{\text{рын}}=[400; 525; 650; 800];$

$S_{\text{дох}}=[450; 650; 725; 1000]$. Схематическое представление данной оценки ИР в форме лингвистической переменной, включающей в себя три метода оценивания (затратный, рыночный и доходный), представлена на рисунке.

Нечеткая оценка стоимости ИР




Таблица 1

Этапы жизненного цикла ИР	Уровень достоверности методов оценки			Комментарий
	Затр атный	Рыно чный	Дохо дный	
ИР 1. Разработка	1	0,3	0,3	Проектирование, сбор информации, экспериментальное использование
ИР 2. Продвижение на рынок	0,8	0,8	0,8	Ввод в эксплуатацию, утверждение для использования
ИР 3. Рост спроса на ИР	0,6	1	1	Расширение сфер использования ИР
ИР 4. Стандартизация ИР	0,2	1	1	Превращение ИР в отраслевой (ведомственный) стандарт.
ИР 5. Устаревание	1	0,2	0,2	Невозможность или ненужность дальнейшего использования ИР


Таблица 2

Цели оценки ИР	Уровень достоверности методов оценки			Комментарий
	Затратный	Рыночный	Доходный	
1. Продажа (покупка)	0,2	1	1	Включая аренду (в т.ч. лизинг), залог, вклад ИР в уставный капитал
2. Бухгалтерский учёт	1	0,2	0,2	Постановка на баланс, расчёт амортизации, налог на имущество, инвентаризация и т.п.
3. Оценка инвестиций в создаваемый ИР	0,6	1	1	Составление бизнес-планов, финансовая оценка инвестиций
4. Выявление стоимости долей при разделе прав на ИР	0,4	1	0,8	Выход участников из бизнеса или раздел бизнеса, включающего ИР
5. Продажа (покупка) бизнеса, содержащего ИР	0,4	1	0,4	Применяется для определения доли прибыли, приносимой организацией от использования ИР
6. Определение ущерба при порче ИР	1	0,6	0,2	Включая случайную порчу, порчу при форс-мажорных обстоятельствах, злонамеренный ущерб


Таблица 3

Значения ЖЦ_ИР и ЦФО_ИР	Уровень достоверности методов оценки			Комментарий
	Затра тный	Рыно чный	Дохо дный	
Определение ущерба при порче ИР	1	0,6	0,2	Включая случайную порчу, порчу при форс-мажорных обстоятельствах, злонамеренный ущерб
Разработка ИР	1	0,3	0,3	Проектирование, сбор информации, экспериментальное использование

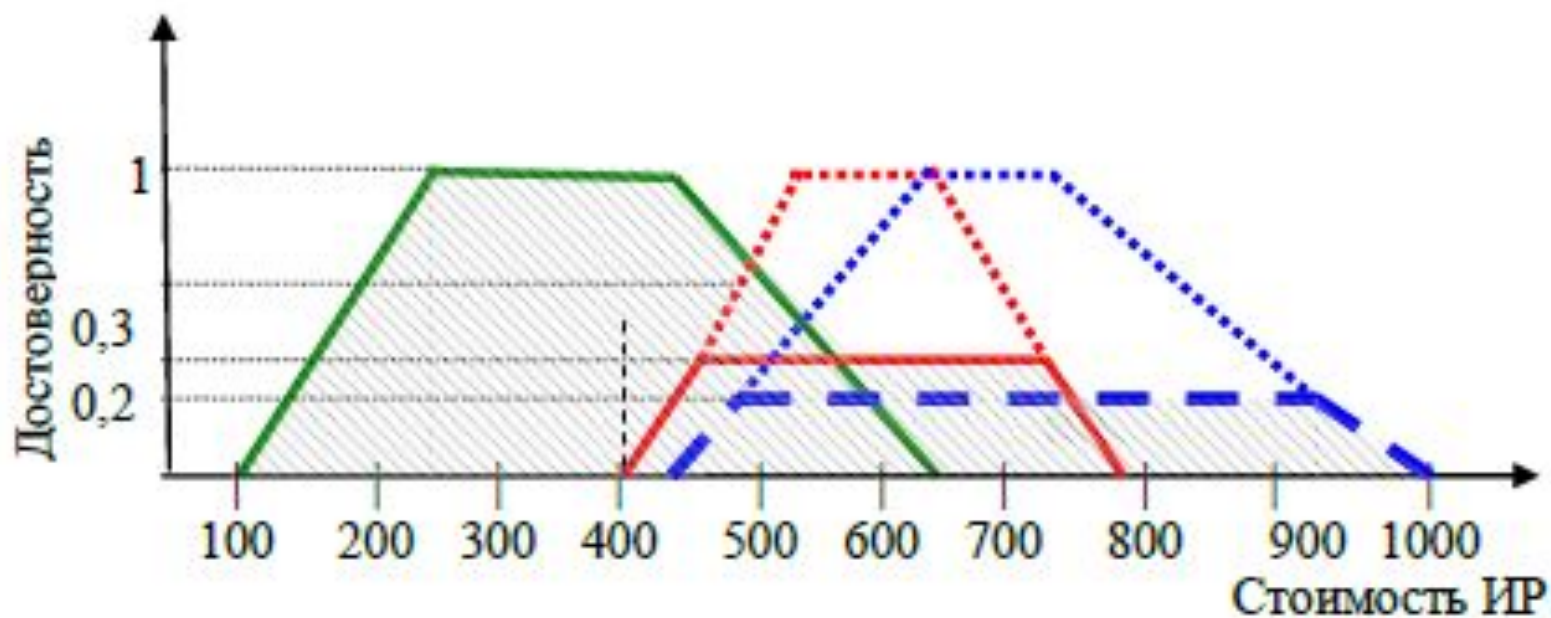
Нечёткая оценка стоимости ИР тремя методами при ЦФО ИР=«Определение ущерба при порче ИР»



Нечёткая оценка стоимости ИР тремя методами при ЖЦ ИР=«Разработка ИР»



Нечёткая оценка стоимости ИР тремя
методами при ЦФО ИР=«Определение
ущерба при порче ИР» и ЖЦ ИР= «Разработка
ИР»



Результат

На основе полученной нечёткой оценки стоимости ИР путём дефаззификации определяется чёткая оценка ИР, равная абсциссе центра тяжести заштрихованной фигуры

$$S = \frac{\int x\mu(x)dx}{\int \mu(x)dx} \approx 400$$

Источники информации

Научная литература

1. Барсегян А.А., Куприянов М.С. и др. Технологии анализа данных. Data Mining, Visual Mining, Text Mining, OLAP. 384 Стр. | ISBN: 5941579918 | Издатель: БХВ-Петербург | Серия: Учебное пособие | 2007
2. Рыбин В.В. Основы теории нечетких множеств и нечеткой логики. М.: МАИ, 2007. - 96 с.
3. Блюмин С.Л., Шуйкова И.А., Сараев П.В., Черпаков И.В. Нечёткая логика: алгебраические основы и приложения. Липецк: Липецкий эколого-гуманитарный институт, 2002.- 111 с.
4. Чубукова И.А. Data Mining. Курс лекций интернет-университета INTUIT. 328 с. , 2006 г.
5. «Информационные Ресурсы России» №6, 2005. Применение методов нечеткой логики при оценке информационных ресурсов предприятий.

Электронные ресурсы

1. <http://www.basegroup.ru/>