

Следует уточнить, что значения атрибутов *status* и *inf* изменяются в процессе приобретения знаний от удаленных экспертов, поэтому и необходима задержка *delta* между итерациями цикла оценки неопределенности. В случае если на шаге 8 результат сравнения истинен только для одного из коэффициентов, то можно говорить об устранении только одного типа неопределенности (информационной или структурной) и делать вывод о готовности ПрО преждевременно. Вместо этого в контексте разработки модуля адаптации следует запускать механизмы структурной или информационной адаптации ПрО, алгоритмы реализации которых являются предметом следующих исследований.

Заключение. В данной статье рассматривается проблема принятия решений в условиях неопределенности ПрО. Предлагается один из возможных подходов к решению проблемы, основанный на разработке систем поддержки принятия решений с модулем адаптации к изменениям ПрО. Ставится задача разработки метода и соответствующего алгоритма количественной оценки неопределенности, позволяющего вычислять текущий уровень неопределенности ПрО. Проводится классификация неопределенностей. Предлагается уточнение понятия неопределенности, имеющее прикладное значение для ЗПР, которые решаются с привлечением знаний распределенных экспертов. Выделяются значимые с точки зрения ЗПР типы неопределенностей. Предлагается метод количественной оценки текущего уровня неопределенности ПрО. Вводится понятие коэффициента неопределенности, значение которого позволяет определить момент готовности ПрО для принятия решений или сделать вывод о необходимости ее структурной и/или информационной адаптации.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Ткачук, Е.О. Требования к адаптивным системам поддержки принятия управленческих решений / Е.О. Ткачук // Известия ТРТУ. – 2002. – № 2. – С. 248–251.
2. Бочарников, В.П. Fuzzy-технология: Математические основы. Практика моделирования в экономике / В. П. Бочарников. – Санкт-Петербург: «Наука» РАН, 2001. – 328 с.

3. Блюмин, С.Л. Модели и методы принятия решений в условиях неопределенности / С. Л. Блюмин, И. А. Шуйкова. – Липецк: ЛЭГИ, 2001. – 138 с.
4. Вальвачев, А.Н. Алгоритмы и технология для построения систем поддержки оперативного принятия решений в распределенных организациях: автореф. дис. ...канд. техн. наук: 05.13.17 / А.Н. Вальвачев; Белорусский государственный университет. – Минск, 2011. – 22 с.
5. Howe, J. The rise of crowdsourcing forget outsourcing / J.Howe // San Francisco: Wired. – 2006. – №14(6) – P. 176–183.
6. Newmann, M.E.J. The structure of scientific collaboration networks / M.E.J. Newmann // Proceedings of the National Academy of Sciences of the United States of America. – 2001. – Vol. 98, no. 2. – P. 404–409.
7. Вальвачев, А.Н. Алгоритмы и технология для построения систем поддержки оперативного принятия решений в распределенных организациях: дис. ... канд. техн. наук: наук: 05.13.17 / А.Н. Вальвачев. – Минск, 2011. – 111 л.
8. Бурков, В.Н. Введение в теорию управления организационными системами / В.Н. Бурков, Н.А. Коргин, Новиков Д. А.; под ред. Д.А. Новикова. – М.: Либроком, 2009. – 264 с.
9. Бурков, В.Н. Теория активных систем: состояние и перспективы / В.Н. Бурков, Д.А. Новиков. – М.: Синтег, 1999. – 128 с.
10. Карканица, А.В. Онтологический подход к построению моделей динамических предметных областей / А.В. Карканица // Веснік Гродзенскага дзяржаўнага ўніверсітэта імя Янкі Купалы. Сер 2. Матэматыка. Фізіка. Інфарматыка, вылічальная тэхніка і ўпраўленне. Біялогія. – 2010. – № 1(92). – С. 92-97.
11. Карканица, А.В. Метод построения динамических предметных областей на основе стандарта моделирования High Level Architecture / А.В. Карканица // Веснік Гродзенскага дзяржаўнага ўніверсітэта імя Янкі Купалы. Сер 2. Матэматыка. Фізіка. Інфарматыка, вылічальная тэхніка і кіраванне. – 2016. – Т.6. – № 3. – С. 124–132.

Материал поступил в редакцию 09.01.2018

KARKANITSA A.V. Uncertainty estimation in adaptive decision making systems

The problem of decision making under uncertainty is considered. It is pointed out that most significant decisions made in today's complex environment are formulated under a state of uncertainty. The purpose of the research is to develop a method for estimating a subject domain uncertainty. A method and algorithm for the quantitative estimation of the current level of uncertainty is proposed. The method is based on the construction of the state vector of the subject domain and the uncertainty coefficient computation. It is shown that having the value of uncertainty coefficient it is possible to determine the moment of readiness of the subject domain or make a decision on the need for its adaptation.

УДК 004.855.5

Краснопрошин В.В., Родченко В.Г.

АНАЛИЗ ПРОСТРАНСТВ РЕШЕНИЙ В ЗАДАЧАХ ОБУЧЕНИЯ ПО ПРЕЦЕДЕНТАМ

Введение. Разработка новых подходов (и соответствующих средств) для эффективного извлечения практически полезной информации из больших массивов (неструктурированных или слабо структурированных) данных является одним из основных трендов развития и применения информационных технологий в различных сферах человеческой деятельности [1–3].

В частности, одной из актуальных проблем машинного обучения (Machine Learning) и интеллектуального анализа данных (Data Mining) является автоматическое обнаружение скрытых внутри данных и интерпретируемых в рамках предметной области закономерностей [4–6].

Традиционные методы и технологии в обучении по прецедентам ориентированы на построение алгоритмов классификации, на осно-

ве которых в дальнейшем принимаются практически полезные решения [7]. На сегодняшний день в рамках такого подхода эффективно решается большое число прикладных задач. Особые успехи достигнуты в области обработки и распознавания графических изображений с применением искусственных нейронных сетей [8]. Однако “родимым пятном” традиционных методов является то, что любой построенный на их основе алгоритм фактически представляет собой “черный ящик”, результаты работы которого не поддаются интерпретации в терминах предметной области [9, 10].

Альтернативным (к обучению по прецедентам) является подход, который связан с разработкой алгоритмов, направленных на выявление (на основе анализа данных обучающей выборки) признаков пространств, в которых классы не пересекаются. В результате ока-

Краснопрошин Виктор Владимирович, д.т.н., профессор, заведующий кафедрой Белорусского государственного университета.

Беларусь, 220050, г. Минск, пр. Независимости, 4.

Родченко Вадим Григорьевич, к.т.н., доцент кафедры современных технологий программирования Гродненского государственного университета имени Янки Купалы.

Беларусь, 230023, г. Гродно, ул. Э. Ожешки, 22.

зывается возможным не только строить алгоритмы классификации, но и выявлять скрытые внутри наблюдаемых данных закономерности, которые могут быть проинтерпретированы в рамках предметной области [11].

В статье исследуется проблема анализа пространств решений в задачах обучения по прецедентам и предлагается механизм сокращения (при построении пространства принятия решений) полного перебора.

1. Анализ проблемы и постановка задачи. Поиск и реализация эффективных механизмов обучения по прецедентам является центральной проблемой в машинном обучении и интеллектуальном анализе данных. Процесс обучения предусматривает, что интеллектуальной системе в виде обучающей выборки предъявляется конечный набор положительных и отрицательных примеров, связанных с некоторой заранее неизвестной закономерностью, а в результате обучения система должна максимально правильно приближать целевую зависимость не только на объектах конечной выборки, но и на всем их множестве [12].

Анализ работ, связанных с обучением по прецедентам, позволяет говорить о наличии двух подходов к процессу выявления целевой зависимости. Традиционный (часто используемый на практике) подход к обучению сводится к построению решающих правил, обеспечивающих экстремум для некоторого критерия. Предполагается, что априори задано пространство описания объектов, и в нем (в рамках заданного критерия) необходимо построить разделяющую поверхность.

Задача обучения по прецедентам в этом случае формулируется следующим образом. Пусть X – множество описаний объектов и Y – множество допустимых ответов их классификации. Существует неизвестная целевая зависимость $y^* : X \rightarrow Y$, значения $X^m = \{(x_1, y_1), \dots, (x_m, y_m)\}$ которой известны только для объектов обучающей выборки. Необходимо построить алгоритм $a : X \rightarrow Y$, который приближал бы эту целевую зависимость, не только на объектах конечной выборки, но и на всем множестве X .

Класс алгоритмов заранее задается с точностью до параметров, а задача обучения сводится к нахождению их значений, обеспечивающих экстремум для выбранного критерия.

Опыт практического решения задачи обучения по прецедентам в рамках традиционного подхода выявил целый ряд проблемных вопросов. Во-первых, выбор модели алгоритмов $A = \{a : X \rightarrow Y\}$ является нетривиальной задачей, а потому приходится говорить не только о науке, но и об искусстве построения алгоритмов, извлекающих знания из данных. Во-вторых, использование обучающей выборки X^m предполагает поиск решения только в исходном признаком пространстве описания объектов, а вопрос о существовании подпространств, в которых задача могла бы решаться более эффективно, остается открытым. В-третьих, построенный алгоритм $a : X \rightarrow Y$, приближающий неизвестную целевую зависимость, фактически является «черным ящиком», результаты работы которого не поддаются интерпретации. В-четвертых, в силу необходимости выбора модели алгоритмов и последующей настройки ее параметров процесс обучения удается реализовать только в автоматизированном, но не автоматическом режиме.

Указанные выше недостатки традиционного подхода к проблеме обучения удается практически полностью исключить в случае использования альтернативного подхода, который основывается на идее конструирования признакового пространства, в котором паттерны классов не пересекаются, и, как следствие, построение классификатора становится достаточно тривиальной процедурой.

Постановка задачи обучения в этом случае следующая.

Пусть X – множество описаний объектов и Y – множество допустимых ответов их классификации. Существует неизвестная целевая зависимость $y^* : X \rightarrow Y$, значения $X^m = \{(x_1, y_1), \dots, (x_m, y_m)\}$ которой известны только для объектов обучающей выборки. Требуется найти признаковые подпространства, в которых классы не пересекаются [13].

Если предположить, что обучающая выборка $X^m = \{(x_1, y_1), \dots, (x_m, y_m)\}$ сформирована на основе словаря признаков $F = \{f_1, \dots, f_n\}$, и обозначить через $V = \{v_1, \dots, v_q\}$ множество всех непустых подмножеств – всевозможных сочетаний признаков из F , то очевидно, что V содержит $q = \sum_{i=1}^n C_n^i$ подмножеств.

Решение задачи обучения в данной формулировке фактически предполагает выполнение полного перебора на множестве всевозможных сочетаний признаков из исходного словаря $F = \{f_1, \dots, f_n\}$. Очевидно, что уже при относительно небольшом n потребуются значительные вычислительные ресурсы, а потому актуальным является сокращение полного перебора. Предлагается метод, которым предусматривается на основе анализа свойств сочетаний признаков из исходного априорного словаря реализовать оптимизацию полного перебора в задачах обучения по прецедентам.

2. Метод построения пространств решений в обучении по прецедентам. Пусть заданы:

множества описаний объектов X , множество допустимых ответов Y , априорный словарь признаков $F = \{f_1, \dots, f_n\}$ и сформированная на его основе обучающая выборка $X^m = \{(x_1, y_1), \dots, (x_m, y_m)\}$.

Обозначим через $V = \{v_1, \dots, v_q\}$ множество всех непустых подмножеств, образованных всевозможными сочетаниями признаков из словаря F , где $q(n) = \sum_{i=1}^n C_n^i$. Требуется найти такие $v_i \in V$, в которых классы не пересекаются.

Для решения этой задачи воспользуемся гипотезой компактности, которая гласит, что классам соответствуют компактные множества в пространстве признаков [14].

Поиск пространств, в которых на объектах обучающей выборки паттерны классов не пересекаются, можно реализовать полным перебором v_i (где $i = \overline{1, q}$) по следующему алгоритму:

Шаг 1: из множества V выбираем очередной элемент v_i (где $i = \overline{1, q}$) и на основе признаков f_j (где $j = \overline{1, n}$), входящих в v_i и обучающей выборки путем исключения данных о признаках, которые не входят в состав v_i , формируем обучающую выборку $Z^m = \{(z_1, y_1), \dots, (z_m, y_m)\}$.

Шаг 2: на основе $Z^m = \bigcup_{i=1}^k Z_i^{m_i}$, (где k – количество классов,

$Z_i^{m_i}$ – выборка объектов i -го класса, m_i – количество объектов

i -го класса) проверяем условие $\bigcup_{i=1}^k (Z_i^{m_i} \cap Z_j^{m_j}) = \emptyset$,

$\forall i \neq j : j = \overline{1, k}$. Используя выборки объектов $Z_i^{m_i}$ (где $i = \overline{1, k}$), строим паттерны классов в виде кластерных структур [15]. Если в пространстве, образованном на основе признаков из v_i , паттерны классов взаимно не пересекаются, то v_i включаем в результирующее множество V^* .

В результате выполнения предложенного выше алгоритма будет сформировано множество V^* . На основе каждого сочетания признаков v_i из множества V^* формулируем ранее неизвестные и выявленные в процессе обучения закономерности вида: «В пространстве признаков подмножества v_i классы не пересекаются». Поскольку каждое сочетание признаков v_i содержит интерпретируемые в терминах предметной области признаки, то выявленные закономерности также могут быть проинтерпретированы.

Все сочетания признаков v_i из множества V^* будут обладать общим свойством, обеспечивающим возможность построения на их основе пространств решений, в которых можно проводить обоснованную классификацию объектов (например, по правилу «ближайшего соседа»).

Таблица 1 – Значение числа сочетаний q в зависимости от n

n	$q(n)$	n	$q(n)$	n	$q(n)$	n	$q(n)$
1	1	11	2047	21	2097151	31	2147483647
2	3	12	4095	22	4194303	32	4294967295
3	7	13	8191	23	8388607	33	8589934591
4	15	14	16383	24	16777215	34	17179869183
5	31	15	32767	25	33554431	35	34359738367
6	63	16	65535	26	67108863	36	68719476735
7	127	17	131071	27	134217727	37	137438953471
8	255	18	262143	28	268435455	38	274877906943
9	511	19	524287	29	536870911	39	549755813887
10	1023	20	1058575	30	1073741823	40	1099511627775

Число всех сочетаний признаков словаря $F=\{f_1, \dots, f_n\}$ является функцией от n и вычисляется по формуле $q(n) = \sum_{i=1}^n C_n^i = 2^n - 1$.

В таблице 1 представлены значения $q(n)$.

Из таблицы видно, что если при $n=10$ необходимо проанализировать 1023 всевозможных сочетаний признаков, то при $n=20$ число сочетаний (1058575) превышает один миллион, а при $n=30$ число сочетаний (1073741823) уже превышает один миллиард.

Обратим внимание на важное свойство тех сочетаний признаков из множества $V=\{v_1, \dots, v_q\}$, которые (на Шаге 2 алгоритма) удовлетворяют соответствующему условию и включаются в результирующее множество V^* .

Пусть v_j будет одним из таких сочетаний, которые включаются в V^* , и пусть оно состоит из двух признаков априорного словаря. В этом случае паттерны классов не пересекаются в признаковом пространстве, построенном на основе признаков из v_j . Предположим, что для трёх классов распределение объектов в них представлено на рисунке 1.




Рисунок 1 – Пример распределения объектов трёх непересекающихся классов

Границы паттернов трёх классов задаются прямоугольниками, которые не пересекаются в двухмерном признаковом пространстве. Заметим, что если в данном случае добавить еще один признак (или несколько) к уже существующим, то границы паттернов классов будут представлять собой непересекающиеся параллелепипеды (или гиперпараллелепипеды).

Отсюда следует, что при поиске пространств, в которых на объектах обучающей выборки паттерны классов не пересекаются, следует отказаться от полного перебора v_i (где $i=1, q$), выполняя при этом Шаг 1 в следующей редакции:

Шаг 1: из множества V выбираем очередной элемент v_i (где $i=1, q$), который не содержит в себе сочетаний из V^* , и на основе признаков f_j (где $j=1, n$), входящих в v_i и обучающей выборки путем исключения данных о признаках, которые не входят в состав v_i формируем обучающую выборку $Z^m = \{(z_1, y_1), \dots, (z_m, y_m)\}$.

В идеальном случае, когда каждый отдельный признак из априорного словаря $F=\{f_1, \dots, f_n\}$ обладает разделяющим классы свой-

ством, необходимо перебрать только n вариантов, а "эффект экономии" на полном переборе будет составлять $2^n - 1 - n$ вариантов.

Заключение. В статье предложен метод обучения по прецедентам, основанный на выявлении пространств решений, в которых классы не пересекаются. Процедура поиска таких пространств базируется на анализе данных обучающей выборки и свойств сочетаний признаков, формируемых на основе априорного словаря.

Показано, что, исследуя свойства сочетаний признаков, можно не только находить пространства решений, в которых классы не пересекаются, но и выявлять ранее неизвестные скрытые закономерности, которые могут быть проинтерпретированы в рамках предметной области.

На основе n признаков априорного словаря можно сформировать $q=2^n - 1$ различных сочетаний признаков, т. е. полный перебор с целью выявления пространств решений предполагает анализ q вариантов. Предложен механизм, основанный на результатах анализа свойств сочетаний признаков, который позволяет избежать полного их перебора.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Журавлёв, Ю.И. Распознавание. Математические методы. Программная система. Практические применения / Ю.И. Журавлёв, В.В. Рязанов, О.В. Сенько – Москва : Фазис, 2005. – 159 с.
2. Загоруйко, Н.Г. Прикладные методы анализа данных и знаний / Н.Г. Загоруйко. – Новосибирск : ИМ СО РАН, 1999. – 270 с.
3. Вьюгин, В.В. Математические основы теории машинного обучения и прогнозирования / В.В. Вьюгин. – Москва : МЦНМО, 2013. – 390 с.
4. Анализ данных и процессов / А.А. Барсегян [и др.] 3-е изд. – Санкт-Петербург : БХВ-Петербург, 2009. – 512 с.
5. Рассел, С. Искусственный интеллект. Современный подход / С. Рассел, П. Норвиг. - 2-е изд. – Москва : Вильямс, 2007. – 1410 с.
6. Флах, П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / П. Флах. – Москва : ДМК Пресс, 2015. – 402 с.
7. Краснопрошин, В.В. Проблема принятия решений по прецедентности: разрешимость и выбор алгоритмов / В.В. Краснопрошин, В.А. Образцов // Выбр. науч. труды Беларус. дзярж. ун-та. – 2001. – Т.6: Матэматыка. – С. 285–311.
8. Люгер, Дж.Ф. Искусственный интеллект: стратегии и методы решения сложных проблем / Дж.Ф. Люгер. – Москва : Издательский дом "Вильямс", 2005. – 864 с.
9. Бринк, Х. Машинное обучение / Х. Бринк, Дж. Ричардс, М. Феве-рольфф. – Санкт-Петербург : Питер, 2017. – 336 с.
10. Мюллер, А. Введение в машинное обучение с помощью Python / А. Мюллер, С. Гидо – Москва : O'Reilly Media, 2017. – 392 с.
11. Краснопрошин, В.В. Два подхода к обучению в распознавании образов / В.В. Краснопрошин, В.Г. Родченко // Информационные системы и технологии: материалы Международного конгресса по информатике; Минск, РБ, 24-27 октября 2016. – Минск : БГУ, 2016. – С. 952–956.
12. Аверкин, А.Н. Толковый словарь по искусственному интеллекту / А.Н. Аверкин, М.Г. Гаазе-Рапопорт, Д.А. Поспелов. – Москва : Радио и связь, 1992. – 256 с.

13. Краснопрошин В.В. Обучение по прецедентам на основе анализа свойств признаков / В.В.Краснопрошин, В.Г.Родченко // Доклады БГУИР. – 2017. – №6. – С. 35–41.
14. Гипотеза компактности [Электронный ресурс]. – Режим доступа: http://www.machinelearning.ru/wiki/index.php?title=Гипотеза_компактности.
15. Краснопрошин, В.В. Кластерные структуры и их применение в интеллектуальном анализе данных / В.В. Краснопрошин, В.Г. Родченко // Информатика. – 2016. – № 2. – С. 71–77.

Материал поступил в редакцию 08.01.2018

KRASNOPROSHIN V.V., RODCHENKO V.G. The analysis of solutions space in problems of learning by precedents

The study examines the issue of building solution space in problems of learning by precedents. It proposes a method of building solution space where classes do not intersect. A search mechanism based on the research of the properties of feature combinations has been well-grounded. It allows to avoid complete search of solution spaces.

Репозиторий БрГТУ