

11. Ларичев О. И., Мечитов А. И., Мошкович Е. М., Фуремс Е. М. Выявление экспертных знаний.— М: Наука, 1989.— 128 с.

12. Larichev O. A. Study on the Internal Organization of Expert Knowledge // Pattern Recognition and Image Analysis.— 1995.— Vol. 5, № 1.— P. 57–63.

13. Ларичев О. И., Болотов А. А.

ДИФКЛАСС — компьютерная система построения полных баз знаний в задачах дифференциальной диагностики (в этом выпуске).

14. Кузнецова В. П., Брук Э. И. Тромбоземболия легочной артерии / Методологическое пособие Российской Медицинской Академии Постдипломного Обучения (в печати).

УДК 025.4:[002.53:007::159.955].001.37

О. И. Ларичев, А. А. Болотов

Система ДИФКЛАСС: построение полных и непротиворечивых баз экспертных знаний в задачах дифференциальной классификации*

Рассматривается новый способ построения полных и непротиворечивых баз экспертных знаний в задачах дифференциальной классификации. Предложены и обоснованы эффективные эвристики, позволяющие существенно увеличить скорость построения баз знаний, точно имитирующих экспертные решения. Приведен практический пример применения предложенного способа.

1. ВВЕДЕНИЕ

Задачи экспертной классификации, когда эксперт относит объект, характеризующий совокупностью значений признаков, к одному из нескольких классов решений, широко распространены на практике. Мы встречаем эти задачи в медицине, геологии, технике: именно в этих областях имеются высококвалифицированные эксперты, знания (или умения) которых пытаются перенести в компьютерные экспертные системы. Проблемы переноса экспертных знаний в компьютер — это основные проблемы в появившемся в последние годы направлении исследований — “инженерии знаний”. По своей направленности это направление является междисциплинарным.

Появление компьютерной системы КЛАСС [1, 2] определило новое направление в инженерии знаний. Принципиально важные особенности этой системы заключаются в следующем:

1. Строится полная база экспертных знаний. Если эксперт определил совокупность классификационных признаков, характеризующих объекты в области его профессиональной деятельности, то ставится задача найти класс решений для каждого сочетания значений этих признаков. Эта задача решается системой КЛАСС путем получения от эксперта знаний в интерактивном режиме. Полная база экспертных знаний позволяет сделать экспертную систему действительно “знающей”, готовой дать ответ на любой вопрос.

2. Так как полные базы экспертных знаний включают тысячи и десятки тысяч продукций, то их нельзя получить от эксперта поштучно. При получении экспертных знаний в системе КЛАСС ис-

пользуется гипотеза “доминирования по характерности”. В соответствии с этой гипотезой решение эксперта об отнесении объекта O_i (сочетания значений признаков) к классу L означает, что к этому же классу относятся и подмножество объектов, которые получаются из O_i путем следующего преобразования: значения одного или нескольких признаков заменяются на более характерные для класса L . Иначе говоря, к классу L относятся все объекты, доминирующие над O_i по “типичности” принадлежности к классу L .

Исследование отношения доминирования по характерности, впервые предложенного в [1], позволяет быстро и эффективно строить базы экспертных знаний. Так, система КЛАСС за неделю строит базы из двух-четырёх тыс. продукций.

3. Основные знания (или умения) эксперта хранятся на подсознательном уровне [3]. Следовательно, мы не можем получить от эксперта решающие правила в явном виде, а можем только выявить их, анализируя его решение. Система КЛАСС предъявляет эксперту на экране компьютера одно за другим описания объектов (сочетания значений признаков). Она задает ему привычные вопросы на привычном для него языке. Эксперт делает заключение, относит объект к одному из классов решений. Затем система выбирает максимально информативный вопрос, максимизируя среднее значение ожидаемой информации. После получения ответа эксперта следует новый вопрос и т. д. до построения полной базы знаний. Никто не пытается “выспросить” у эксперта правила, по которым он принимает решения. Подчеркнем еще раз, что эти правила подсознательны. Однако совокупность экс-

* Исследования частично поддержаны грантом Российского Фонда Фундаментальных Исследований 95-01-00450 и грантом ИНТАС № 94-4040

пертных решений позволяет получить в явном виде подсознательные экспертные правила [4].

4. В процессе диалога "эксперт-компьютер" некоторые ответы эксперта могут оказаться ошибочными. Чем бы ни вызывалась конкретная ошибка: сложностью ли вопроса, усталостью ли эксперта и т. п., — но не делающих ошибок экспертов не бывает. Следовательно, нужна система для нахождения ошибок и их предъявления эксперту. В системе КЛАСС имеется функция контроля за возможными ошибками эксперта. Этот контроль осуществляется путем повторной классификации ряда объектов.

Все эти черты позволили с помощью системы КЛАСС разработать экспертные системы высокого уровня качества. Так, экспертная система "Острый живот" по диагностике 14 заболеваний, начинающихся с боли в животе, полтора года использовалась в военно-морском госпитале и показала высокую эффективность в диагностике (94–97% верных решений [5]).

Однако использование системы КЛАСС выявило ряд ее недостатков.

Во-первых, — это вычислительная трудоемкость определения максимально информативных вопросов к эксперту, зависящая от размерности решаемой задачи, которая определяется мощностью множества возможных состояний и числа классов решений.

В [5] показано, что трудоемкость вычисления максимально информативного объекта равна $|A|^2 * L$, а трудоемкость распространения по доминированию по характеристности — $|A| * L$, где $|A|$ мощность множества состояний объекта исследования, L — число классов. Мы можем сделать вывод, что решаемая проблема является NP-трудной. Это означает, что при определенной размерности задачи, интервал времени между двумя последовательно предъявляемыми эксперту состояниями возрастает до нескольких минут, что делает диалог невозможным. Работа с системой показала, что она удовлетворительно справляется с задачами экспертной классификации, если число возможных состояний, не превышает 10 тыс. [5].

Хотя это количество существенно превосходит число продуктов, собираемых "вручную" когнитологом при традиционном подходе к построению экспертных систем, оно не является достаточным. По оценкам Г. Саймона [6], база знаний экспертов в различных профессиональных областях составляет в среднем 50 тыс. продуктов и может отличаться в четыре раза от среднего значения (от 12,5 до 200 тыс. продуктов).

Во-вторых, — это трудности с выявлением внутренней когнитивной структуры экспертных знаний. Хотя система КЛАСС позволяет с высокой степенью надежности (что проверялось при повторных предъявлениях объектов [1]) строить базы экспертных знаний, она не дает возможности найти структуры этих знаний. В системе КЛАСС знания хранятся в виде совокупности объектов, находящихся на границе классов решений. Объект считается граничным, если изменение оценки по одному из признаков переводит его в другой класс решений. Так как число граничных объектов достаточно велико, трудно предположить, что эксперт использует их перечень при классификации.

Вероятно, существуют более общие правила представления и использования знаний.

Для преодоления этих недостатков была разработана новая система построения полных и непротиворечивых баз экспертных знаний — система ДИФКЛАСС. В ней используются основные идеи системы КЛАСС: распространение по доминированию, поиск и устранение противоречий, но преодолены отмеченные выше недостатки. В то же время система ДИФКЛАСС является более узкой по своей направленности: она предназначена для решения задач дифференциальной классификации. Далее излагаются основные идеи системы ДИФКЛАСС.

2. ЗАДАЧА ДИФФЕРЕНЦИАЛЬНОЙ КЛАССИФИКАЦИИ

Одна из задач искусственного интеллекта заключается в построении в компьютере точной копии экспертных суждений.

Два основных препятствия на пути решения этой задачи состоят в подсознательном характере экспертного знания и в необходимости создания для эксперта психологически привычных условий демонстрации своего искусства. С точки зрения последнего фактора задачи разделения объектов на два класса (дифференциальная классификация) занимают особое положение.

Согласно широко распространенным представлениям [7], человеческая система переработки информации функционирует при принятии решений последовательно во времени, а не параллельно. Можно предположить, что эксперты при определении класса решений последовательно исключают некоторые классы решений, производя каждый раз деление на две-три группы. Так, в беседах врачи охотно признают, что самое главное и трудное в постановке диагноза — исключение близких по симптоматике заболеваний.

Следовательно, наиболее естественная задача для эксперта — разделение объектов на два-три класса решений.

Наряду с этим было обнаружено, что эксперты-врачи стремятся использовать при диагностике двоичные шкалы диагностических признаков, учитывать четко различимые противоположные значения, например: кожа пациента — сухая или влажная; дыхание — патологическое или нормальное [8].

Представляется, что задачи дифференциальной классификации с двоичными шкалами признаков наиболее естественны для экспертов. Можно ожидать, что искусство эксперта наиболее четко проявляется в таких задачах.

Подсознательный характер экспертных знаний заставляет отказаться от попыток получить от эксперта решающие правила и выбрать как основную стратегию извлечения знаний предъявление эксперту описаний объектов (как это сделано в системе КЛАСС).

Задача построения полной и непротиворечивой базы знаний при дифференциальной диагностике ставится следующим образом.

Дано: два основных класса решений — А и В. Даны N двоичных признаков, описывающих объекты в области профессиональной деятельности эксперта. Одно из значений каждого признака наиболее характерно для А, другое для В.

В общем случае к двум основным может быть добавлена часть дополнительных классов решений (либо все):

- C (A и B вместе),
- D (ни A ни B),
- E (нужны дополнительные признаки).

Для дополнительных классов значения каждого из отдельных признаков равно характерны.

Декартово произведение шкал признаков образует полное множество S возможных объектов. Количество объектов в S равно 2^N .

Требуется: отнести каждый объект множества S (вектор V_i) к одному из классов решений.

3. ЭВРИСТИКА "СРЕДНИХ" ОБЪЕКТОВ И ЕЕ ЭФФЕКТИВНОЕ ИСПОЛЬЗОВАНИЕ

Введем особый порядок на множестве S объектов (N -мерных векторов с бинарными значениями компонент). Векторы лексикографически упорядочены в предположении, что i -й признак важнее $i+1$ (нумерация справа налево).

При двух признаках этот порядок имеет вид: $(1,1) - (1,2) - (2,1) - (2,2)$.

Номер вектора в порядке вычисляется по формуле:

$$n_j = \sum_{i=1}^{i=N} k_j 2^{i-1} + 1, \quad (1)$$

где $k_j = \begin{cases} 0, & \text{если значение признака равно 1;} \\ 1, & \text{если значение признака равно 2.} \end{cases}$

Для классов A и B сохраняется свойство монотонности на множестве векторов, т. е. имеется возможность распространения по характеристикам.

Если вектор с номером n принадлежит A , то A принадлежат все вектора с номерами n_i , которые получаются вычитанием из n_j всех отдельных составляющих суммы (1) и всех их возможных частичных сумм.

Если вектор с номером n'_j принадлежит B , то B принадлежат все вектора с номерами n'_i , которые получаются из n'_j прибавлением всех отдельных составляющих суммы (2) и всех их возможных частичных сумм, где

$$n'_j = \sum_{i=1}^{i=N} k'_j 2^{i-1}, \quad (2)$$

при этом

$k'_j = \begin{cases} 1, & \text{если значение признака равно 1;} \\ 0, & \text{если значение признака равно 2.} \end{cases}$

Проверку на непротиворечивость для классов A и B можно осуществлять, исходя из определенных:

$P_A(V_i, V_j)$ противоречиво, если $V_i \in B$; $V_j \in A$ и P_A — отношение доминирования по характеристикам для класса A ;

$P_B(V_i, V_j)$ противоречиво, если $V_i \in A$; $V_j \in B$ и P_B — отношение доминирования по характеристикам для класса B ;

При обнаружении противоречия компьютер предъявляет эксперту противоречивую ситуацию и просит изменить один из ответов (как это предложено в системе КЛАСС).

Основная идея предлагаемого алгоритма состоит в выделении, так называемых "средних" объектов и в их использовании для эффективного заполнения базы решающих правил. Далее будем использовать обозначение:

$$R(0, 5N) = \begin{cases} 0, 5N - \text{при четном } N; \\ 0, 5(N+1) - \text{при нечетном } N. \end{cases}$$

Определение: назовем средними объектами векторы V_{cp} из множества S , имеющие $R(0, 5N)$ первых оценок и остальные вторые оценки. Номера средних объектов в списке, определяемом (1), задаются формулой:

$$n_{cp} = (2^i + 2^j + \dots + 2^k) + 1,$$

где число членов в скобке равно $R(0, 5N)$. Для степеней двоек выполняется:

$$0 \leq i \leq j \leq k \leq N - 1.$$

Общее число средних объектов равно $C_N^{R(0, 5N)}$.

Является естественным разбиение векторов V по слоям, соответствующих количеству компонент, имеющих первые оценки. Будем считать первым слоем те векторы, которые имеют первую оценку для одной из компонент (их число равно C_N^1).

Средние объекты принадлежат среднему слою или одному из двух средних слоев.

В системе ДИФКЛАСС не используется поиск наиболее информативного объекта на каждом шаге диалога с экспертом. Вместо этого эксперт классифицирует средние объекты, предъявляемые ему в заранее определенной последовательности. Таким образом, первый этап построения полной базы экспертных знаний состоит в следующем:

1) берутся средние объекты по очереди в порядке возрастания номеров в списке;

2) если принадлежность очередного среднего объекта к классу решений неизвестна, то он предъявляется эксперту. После каждого предъявления следуют операции распространения по характеристикам и проверки на непротиворечивость.

При двух классах решений (A и B) классификация средних объектов позволяет эффективно использовать отношение доминирования по характеристикам. При любом ответе эксперта (назначении среднему объекту того или иного класса) достаточно большое количество объектов будет классифицировано с помощью отношения доминирования по характеристикам.

Предположим, что граница между классами решений проходит по среднему слою. Это самая сложная и длинная граница среди всех возможных [9]. Получим для нее ряд оценок, характеризующих процедуру опроса эксперта.

При двух классах решений и N двоичных признаках справедлива следующая:

Лемма 1. Классификация экспертом не более $2N/(N^2-4)$ части средних объектов позволяет косвенно классифицировать все доминирующие по характеристикам объекты.

Доказательство этой леммы приведено в Приложении 1.

Для иллюстрации полученных результатов в табл. 1 приведен ряд вычислений для числа при-

знаков от 4 до 12. В последней колонке указана эффективность алгоритма, выраженная долей средних объектов, которых достаточно для классификации всех доминирующих по характерности объектов

Таблица 1

Показатели эффективности работы алгоритма (опрос эксперта по объектам среднего слоя) в зависимости от числа признаков

Число признаков	Число объектов в среднем слое	Эффективность алгоритма
4	10	0,67
6	35	0,38
8	126	0,27
10	462	0,21
12	1716	0,17

Из табл. 1 видно, что при увеличении числа признаков эффективность работы по средним объектам увеличивается. Так, при 12 признаках при классификации 17% объектов каждого из двух средних все слои, кроме двух средних слоев, окажутся заполненными. Оставшиеся объекты средних слоев ничего не дают при распространении объектов по доминированию, и база знаний будет заполняться более медленными темпами (фактически по одному объекту). Это означает, что сначала база знаний заполняется быстро, а затем гораздо медленнее

Рассмотрим теперь общий случай, когда граница проходит не по среднему слою, а опрос проводится по средним объектам. По завершении их классификации, значительная часть базы знаний будет построена.

Как показали наши исследования [10], для завершения построения полной базы знаний можно воспользоваться байесовским подходом при поиске граничных объектов, по которым будет осуществляться дальнейший опрос эксперта. В этом случае объекты, принадлежащие границе между классами, определяются из условия максимальной близости значений апостериорной вероятности по какому-либо двум классам. Такой алгоритм не относится к переборным и позволяет резко сократить время вычисления наиболее информативного объекта при опросе эксперта.

Итак, при двух классах решений эвристика средних объектов на первом этапе опроса и алгоритм Байеса — на втором — позволяют существенно снизить вычислительную трудоемкость операций поиска информативных объектов и распространения по характерности. Однако наличие (в общем случае) еще трех номинальных классов (см. выше) существенно осложняет задачу и понижает эффективность использования средних объектов, так как часть их может принадлежать к номинальным классам. В связи с этим был разработан новый алгоритм, также использующий средние объекты.

4. ПОИСК ГРАНИЧНЫХ ОБЪЕКТОВ НА ЦЕПЯХ

Нетрудно убедиться, что каждый средний объект соединяется цепью со всеми первыми (характерными для класса A) и всеми вторыми (ха-

рактерными для класса B) оценками. Существуют алгоритмы покрытия функции цепями, которые используются в вычислительной математике при расшифровке монотонных функций [11].

Идея алгоритма системы ДИФКЛАСС (L -алгоритм) состоит в поиске граничных объектов на цепях, проходящих через средние объекты.

Рассмотрим сначала случай, когда имеется только два основных класса A и B . В N -мерном пространстве векторов V_i проходит граница, отделяющая класс A от класса B .

Пусть средний объект V_{cp} по решению эксперта принадлежит классу A . По определению, половина компонента вектора V_{cp} имеет оценки 2, а половина — оценки 1. Граничный объект расположен в N -мерном пространстве где-то между V_{cp} и вектором V_b , принадлежащим классу B и наиболее для него характерным (все компоненты его имеют вторые оценки). Объявим все компоненты V_{cp} , имеющие вторые оценки, неизменными и будем производить замены оценок только для изменяемых компонент.

Разделим изменяемые оценки V_{cp} пополам при четном $N/2$ (либо на $0,25(N-1)$ и $0,25(N+1)$ — при нечетном). При делении выделяем первые по порядку $0,25N$ изменяемых оценок и остальные. Образуем два вектора V_1 и V_2 , имеющие, соответственно, по $N/4$ (при четном N) разных компонент с первыми оценками из изменяемых оценок V_{cp} . Далее векторы V_1 и V_2 либо предъявляются эксперту (если их принадлежность классу решений еще не известна), либо их принадлежность подтверждается без предъявления, если они уже занесены в список. Если какой-то из этих векторов принадлежит классу A , то снова делим его на два. Теперь мы считаем изменяемой частью компоненты, имевшие первые оценки в данном векторе.

Условия останова L -алгоритма: изменяемая часть содержит одну компоненту вектора.

Очевидно, что если средний объект принадлежит классу B , то алгоритм аналогичен, но изменяемой частью объявляются другие компоненты.

Лемма 2. Алгоритм L позволяет найти все граничные объекты.

Доказательство. Любой граничный объект находится на цепочке элементов, обладающей следующим свойством: один из крайних объектов является средним, а другой — наиболее характерным для одного из классов (A или B), каждый элемент цепочки принадлежит одному из слоев (либо V_{cp} является граничным элементом). Алгоритм L "делением пополам" одновременно строит цепочку и находит граничный объект на этой цепочке. Так как каждый из граничных объектов доминирует хотя бы над одним из средних объектов, то все граничные объекты будут найдены.

Лемма 3. Алгоритм L имеет субоптимальный характер.

Оптимальный, по Шеннону, алгоритм расшифровки монотонных функций имеет следующую оценку числа обращений [5]:

$$K_{opt}(N) = C_N^{R(0,5N)} + C_N^{R(0,5N)+1}. \quad (3)$$

По сути дела, эта оценка равна сумме элементов двух слоев: среднего и соседнего с ним. В случае, если граница проходит по среднему слою, L -алгоритм дает число обращений не больше, чем

$$K_L(N) = C_N^{R(0,5N)} + \sum_{i=1}^{l-1} C_N^{R(0,5N)+i}, \quad (4)$$

где $l = P\{\lg R(0,5N)\}$, и $P(t) > t$ — ближайшее к t целое число.

Формула для K дает оценку сверху, так как при распространении по доминированию (см. выше) многие объекты не предъявляются.

Лемма 4. Отношение числа предъявлений предложенного алгоритма к оптимальному в наиболее сложном случае не превышает:

$$K_L/K_{\text{opt}} \leq 0,5(l+1). \quad (5)$$

Доказательство дано в Приложении 2.

Перейдем теперь к общему случаю, когда средний объект может принадлежать одному из вспомогательных классов.

Если средний объект принадлежит одному из вспомогательных классов (C, D, E), то L -алгоритм состоит в удвоении количества делений: все деления делаются в предположении, что средний объект принадлежит A , а затем все деления — в предположении, что он принадлежит B . Иными словами, из объекта, принадлежащего дополнительному классу, строятся цепочки “вверх” и “вниз”.

Объекты дополнительных классов просто заносятся в списки.

Для исследования эффективности L -алгоритма было проведено также статистическое моделирование методом Монте-Карло для ряда задач, различающихся размерностью и сложностью границы.


Были исследованы три границы между классами решений для задач классификации с четырьмя, шестью и восемью бинарными признаками:

- 1) граница типа “отсечка”, когда по значению некоторого признака случайным образом назначался тот или иной класс решений, при этом остальные объекты относились к другому классу;
- 2) случайная граница, когда для каждого случайно выбранного объекта случайным образом назначался класс решений с использованием дальнейшего распространения по доминированию на объекты с неизвестной классификацией;
- 3) детерминированная граница, которая проходит по среднему слою. Это самая длинная граница. Она интересна тем, что для нее уже получены некоторые оценки эффективности (см. выше).


Результаты такого моделирования приведены на рисунке. По оси ординат отложено относительное заполнение базы решающих правил (в %), а по оси абсцисс — число объектов, которые предлагались для классификации (итерации). Из рисунка видно, что для границы 3 число итераций больше, чем для двух других, причем зависимость близка к

линейной. В случае границы 3 имеем подтверждение оценки (4).


Заполнение базы знаний для четырех признаков (в %)



Заполнение базы знаний для шести признаков (в %)



Заполнение базы знаний для восьми признаков (в %)



Результаты моделирования для трех границ (при 4, 6 и 8 признаках)

5. ВЫЯВЛЕНИЕ КЛАССИФИКАЦИОННЫХ ПОДПРАВИЛ ЭКСПЕРТА НА ЕГО ПОСЛЕДОВАТЕЛЬНЫХ РЕШЕНИЯХ

Другим преимуществом, возникающим при использовании средних объектов, оказывается возможность выявления некоторых закономерностей в решениях эксперта (подправил), которые позволяют значительно ускорить построение базы знаний. Рассмотрим следующий пример. Допустим, что эксперту предъявляется такая последовательность средних объектов, заданная векторами для шести бинарных признаков:

- 1) 1 2 1 1 2 2,
- 2) 1 2 1 2 1 2,
- 3) 1 2 1 2 2 1.

Допустим, что эти три объекта эксперт отнес к первому классу решений. Общим свойством этих объектов является наличие комбинации первых трех признаков: 1 2 1, а также наличие первой оценки для одного из трех последних признаков. Тогда можно сформулировать следующие подправила отнесения ряда объектов к первому классу:

- 1 * 1 1 * *,
- 1 * 1 * 1 *,
- 1 * 1 * * 1.

Здесь символом * обозначен факт возможного наличия любой оценки того или иного признака. Их можно записать в виде одного подправила:

наличие первой оценки по первому и третьему признаку плюс первая оценка по любому из трех последующих признаков определяет объекты первого класса. Задавая это подправило, мы определяем класс для всех объектов, удовлетворяющих этим условиям.

Таким образом, можно выявлять по частям решающие правила эксперта. Последовательное предъявление средних объектов позволяет быстрее найти основу таких правил.

При последовательном предъявлении средних объектов каждый объект отличается от другого значениями двух признаков. Это позволяет продвигаться по среднему слою с минимальными изменениями в признаках. Поэтому при наличии каких-либо устойчивых причинно-следственных отношений между признаками они достаточно легко подмечаются экспертом.

Таким образом, методика выявления решающих правил эксперта состоит в следующем:

1) эксперту на экране дисплея последовательно предъявляются описания случаев, представленных средними объектами;

2) при обнаружении закономерностей в решениях эксперта вырабатывается обобщенное подправило, которое записывается в специальный файл в таком виде: класс решений + соответствующее сочетание признаков в виде вектора признаков, где несущественные значения тех или иных признаков помечены символом *;

3) это правило предъявляется эксперту в расшифрованном виде и при его согласии передается на проверку;

4) осуществляется проверка на противоречивость, и при отсутствии противоречий заполняется база знаний. При наличии противоречий указываются объекты в базе знаний, с которыми это правило несовместно. При этом эксперт анализирует возникшие противоречия и корректирует свои решения.

5. ПРАКТИЧЕСКИЙ ПРИМЕР

Система ДИФКЛАСС использовалась не менее 20 раз при построении баз экспертных знаний в задачах различной размерности.

Опыт показал, что за реальное время — до четырех недель — можно построить базы знаний, содержащие до 25 тыс. продукций. Приведем описание одной из практических задач.

Строилась полная и непротиворечивая база знаний для дифференциальной диагностики острого аппендицита и почечной колики. Для описания состояния пациента использовалось 14 бинарных признаков.

В этой задаче присутствовал и третий класс, класс *D* (ни *A*, ни *B*). Особенность этого класса — отсутствие отношения доминирования признаков по характерности. Экспертом был ведущий хирург 32-го Центрального Военно-морского клинического госпиталя (32 ЦВМКГ). Небольшая часть правил была извлечена из имевшейся базы фактографических данных.

Приведем основные характеристики полной и непротиворечивой базы знаний, построенной для дифференциальной диагностики острого аппендицита и почечной колики:

общее число объектов в базе знаний	16384
число объектов, классифицированных на основе предыстории (из базы данных)	75
число объектов, непосредственно классифицированных экспертом	284
число объектов, класс которых назначен из объектов базы данных с использованием отношения доминирования по характерности	1071
число объектов, класс которых назначен с использованием этого же отношения после ответов эксперта	1339
число объектов, сформированных из подправил эксперта	13615

В табл. 2 приведено распределение правил по трем классам решений и всей базе знаний для различных источников порождения правил.

Из таблицы видно, что значительная часть правил получена с использованием выявленных подправил эксперта, поскольку они имеют большую обобщающую способность. Основная масса таких правил принадлежит вспомогательному третьему классу.

Представляет интерес оценка "чистого" времени работы эксперта при создании такой базы знаний. Это ~57 000 с (или ~9050 мин — 16 ч). Повторный (уточняющий) опрос занял еще около 200 мин. В итоге "чистое" время, затраченное экспертом, составило 19–20 ч. Следует заметить, что это очень высокая скорость извлечения знаний.

В данном эксперименте было 3442 "средних" объектов. Из них на границу между первым и вторым классами попало 83. К третьему, вспомогательному классу, было отнесено 2580 объектов. Всего эксперту было предъявлено 215 "средних" объектов.

Таблица 2

Распределение правил базы знаний по пяти источникам их порождения

Источник порождения правила	1 класс	2 класс	3 класс	Всего
1. База фактографических данных (ВД)	28	47		75
2. Обобщение из базы данных	42	1029		1071
3. Эксперт	70	21		284
4. Обобщение эксперта	1015	324		1339
5. Подправила эксперта	3229	652		13615
Всего	4464	2053	9927	16384

Таким образом, анализируя данные по средним объектам можно сказать, что представлять их эксперту, в первую очередь, целесообразно при большом количестве объектов в базе знаний.

7. ЗАКЛЮЧЕНИЕ

Система ДИФКЛАСС существенно расширяет возможности построения баз знаний, точно имитирующих суждения эксперта. Тем самым, мы приближаемся к решению одной из основных задач искусственного интеллекта: сохранение для будущих поколений "слепков" знаний (умений) лучших современных специалистов (врачей, геологов, инженеров).

СПИСОК ЛИТЕРАТУРЫ

1. Ларичев О. И., Мечитов А. И., Мошковиц Е. М., Фуремс Е. М. Выявление экспертных знаний.— М.: Наука, 1989.— 128 с.
2. Larichev Oleg I., Moshkovich Helen M., Furems Eugene M., Mechitov Alexander I., Morgoev Vladimir K. Knowledge acquisition for the construction of the full and contradiction free knowledge bases // Iec ProGAMMA, P. O. Box 841 9700 AV Croningen.— The Netherlands, 1991.— 240 p.
3. Kilstiom J. The cognitive unconscious // Science.— 1987.— Vol. 237.— P. 1445-1451.
4. Ларичев О. И. Структуры экспертных знаний. // Психологический журнал.— 1995.— Т. 16, № 3.
5. Денисов Г. Ф., Ларичев О. И., Фуремс Е. М. Когнитивное моделирование как средство построения больших баз экспертных знаний // Вестн. всеохоп. об-ва информатики и вычислительной техники.— М.: ВИ-МИ.— 1991.— № 1.— С. 26-34.
6. Simon H. A. Problem formulation and alternative generation in the decision making process // Ed. A. Chikan. Progress in decision, utility and risk theory.— Boston, MA: Kluwer, 1991.— P. 77-84.
7. Simon H. Reason in human affairs.— Standford: University Press, 1983.— 115 p.
8. Lemieux M., Bordage G. Professional versus structural semantic analysis of medical diagnostic thinking // Cognitive Science.— 1992.— Vol. 16.— P. 198-204.
9. Соколов Н. А. Оптимальная расшифровка монотонных булевых функций // Ж. вычисл. матем. и матем. физ.— 1987.— Т. 27, № 12.— С. 1878-1887.
10. Болотов А. А., Ларичев О. А. Сравнение методов распознавания образов по точности аппроксимации разделяющих гиперплоскостей // Автоматика и телемеханика.— 1995.— № 7.— С. 116-123.
11. Ансель Ж. О числе монотонных булевых функций n переменных // Кибернетический сборник.— М.: Мир.— 1968.— № 5.— С. 53-58.

ПРИЛОЖЕНИЕ 1

Лемма 1.

Классификация экспертом не более $2N/(N^2 - 4)$ части средних объектов позволяет косвенно классифицировать все доминирующие их по характеристности объекты.

Доказательство.

Число объектов среднего слоя $(N/2)$ определяется формулой:

$$C_N^{N/2} = \frac{N!}{(N/2)!(N/2)!} \quad \text{— для четных } N,$$

$$C_N^{N/2} = \frac{N!}{([N/2]!([N/2] + 1)!)} \quad \text{— для нечетных } N,$$

тогда число элементов предшествующего слоя

$$C_N^{N/2-1} = \frac{N!}{(N/2 + 1)!(N/2 - 1)!} \quad \text{— для четных } N,$$

$$C_N^{N/2-1} = \frac{N!}{([N/2 - 1]!(N - [N/2] + 1)!)} \quad \text{—}$$

для нечетных N .

Точка, относящаяся к среднему слою $(N/2)$ вторых оценок в векторе признаков, доминирует над d объектами предшествующего слоя.

Найдем нижнюю оценку числа предъявлений, которые достаточны для классификации предшествующего $(N/2 - 1)$ слоя, а затем сравним их с числом точек среднего слоя.

Максимальная оценка числа предъявлений объектов среднего слоя для того, чтобы заполнить предшествующий и последующие слои, находится из условия предъявления объектов, для которых отношение доминирования признаков по характеристности позволяет косвенно назначить класс наименьшему числу объектов. Это означает, что такая последовательность средних объектов имеет максимум общих оценок в векторах признаков. В этом случае один средний объект доминирует над d объектами предшествующего слоя:

$$d = C_{N/2}^{N/2-1} - 1 = (N - 2)/2.$$

При этом t :

$$t = C_{N/2}^{N/2-1} / d = \frac{N!2}{(N/2 + 1)!(N/2 - 1)!(N - 2)},$$

Тогда отношение B :

$$B = C_N^{N/2-1} / t = \frac{N!(N/2 + 1)!(N/2 - 1)!(N - 2)}{(N/2)!(N/2)!2} = \frac{N}{2} - \frac{2}{N},$$

что и требовалось доказать.

Для четного N граница будет проходить по двум слоям, которые имеют разное число объектов. Но в этом случае число объектов предшествующего и последующего слоев также разное, поэтому отношение B оказывается очень близким для случая, когда N — нечетно.

ПРИЛОЖЕНИЕ 2

Лемма 4.

Доказательство. Преобразуем выражения для K_{opt} и K_L . При этом получим:

$$\frac{K_L}{C_N^{0,5N}} = 1 + \sum_{i=1}^{i=l} \frac{(0,5N)!(0,5N)!}{(0,5N)!(0,5N)!};$$

$$\frac{K_{\text{opt}}}{C_N^{0,5N}} = 1 + \frac{0,5N}{0,5N+1};$$

$$K_L / K_{\text{opt}} =$$

$$= \left(1 + \sum_{i=1}^{i=l} \frac{0,5N+1-i}{0,5N+1} \right) / \left(1 + \frac{0,5N}{0,5N+1} \right) =$$

$$= \left(1 + \frac{0,5N}{0,5N+1} + \sum_{i=1}^{i=l} \frac{0,5N+1-i}{0,5N+1} \right) /$$

$$/ \left(1 + \frac{0,5N}{0,5N+1} \right).$$

Но:

$$\left(\sum_{i=1}^{i=l} \frac{0,5N+1-i}{0,5N+1} \right) / \left(1 + \frac{0,5N}{0,5N+1} \right) < \frac{l-1}{2}.$$

Следовательно: $K_L / K_{\text{opt}} \leq 0,5(l + 1)$.