

МЕТОД ОБНАРУЖЕНИЯ ЗАКОНОМЕРНОСТЕЙ И МЕТОД ПРЕДСКАЗАНИЯ

Е.Е.Витнев

1. Формулировка задачи. Многие реальные практические задачи содержат признаки, измеренные в различных шкалах. При решении таких задач все признаки обычно сводят к одной шкале. В случае, когда все признаки сводятся к наиболее бедной шкале, например к шкале наименований, часть информации теряется. В случае, когда все признаки сводятся к наиболее богатой шкале, например шкале отношений, вводится бессмысленная информация, которая может существенно исказить имеющиеся данные. Представляет интерес построение метода обнаружения закономерностей и метода предсказания, которые наиболее полно и без искажений учитывают эмпирическую информацию, содержащуюся в признаках (т.е. методов, работающих с разнотипными признаками), и позволяют, используя эту эмпирическую информацию, предсказывать заданную величину (признак), измеряемую в произвольной шкале, также с наиболее полным учетом той информации, которая в этой шкале содержится. В случае, когда предсказываемый признак измерен в шкале наименований, мы приходим к задаче распознавания образов, где образами являются имена признака. Существуют алгоритмы, предсказывающие величину, измеряемую в шкале отношений, на основании признаков, также измеренных в шкале отношений [8,9].

Относительно признаков может быть известна некоторая априорная информация помимо той, которая определяется типом шкал. Например, информация, которая определяется физическими зависимостями, существующими между признаками. Желательно поэто-

му, чтобы метод предсказания имел возможность учитывать также и такого рода априорную информацию.

Вообще говоря, метод предсказания может быть построен без предварительного нахождения множества закономерностей. Однако предварительное нахождение закономерностей имеет преимущество в том, что хорошо видно, на основании чего получено предсказание. Кроме того, найденные закономерности могут представлять и самостоятельный интерес, например, для специалиста соответствующей области знания.

Относительно множества закономерностей сформулируем следующие пожелания:

- класс рассматриваемых закономерностей должен быть достаточно широк;
- закономерности должны быть устойчивы относительно случайных отклонений значений признаков;
- закономерности должны быть, в некотором смысле, независимы между собой.

Метод обнаружения закономерностей и метод предсказания должны работать с данными, имеющими пробелы.

Цель этой работы заключается в построении метода обнаружения закономерностей и метода предсказания, учитывающих приведенные выше пожелания.

Посмотрим, на основе чего можно было бы удовлетворить всем этим пожеланиям. Возможность общего представления любой шкалы дает теория измерений [7]. Признаки $x_0, x_1, \dots, x_n$, измеренные в каких-то шкалах, можно, согласно теории измерений, адекватно представить в виде набора многоместных отношений R_j^i , $i = 0, 1, \dots, n, j = 1, 2, \dots, n$, и аксиом, записанных в терминах этих отношений. Упомянутую дополнительную априорную информацию также будем записывать в терминах этих отношений. Достаточно общий вид априорной информации будет достигаться за счет того, что будут допускаться любые универсальные формулы, записанные в терминах этих отношений. Шкалы всех признаков, а также дополнительная априорная информация будут представлены в п.2 эмпирической гипотезой [5] H_0 .

Предсказание значения признака x_0 на некотором объекте по известным значениям признаков $x_1, \dots, x_n$ на этом же объекте будет получаться благодаря использованию априорной

информации и предварительно установленного множества закономерностей. Закономерностями являются зависимости между отношениями $P_j^i, i=1,2,\dots,n'; j=1,2,\dots,n_1$, характеризующими признаки $x_1, \dots, x_n$, и отношениями $P_j^0, j=1,2,\dots,n_0$, характеризующими признак x_{n_0} . В качестве закономерностей будут рассматриваться только формулы вида (3). Некоторую гарантию того, что рассматриваемый класс закономерностей достаточно широк, даёт разложение универсальных формул, приведенное в п.2. Согласно этому разложению, любую детерминированную закономерность, представимую в виде универсальной формулы, можно выразить с помощью совокупности формул вида (3). Это же разложение позволяет априорную информацию, записанную в виде совокупности универсальных формул, привести к более простому виду – совокупности формул вида (3).

Устойчивость закономерностей относительно случайных отклонений достигается благодаря определённым вероятностным предположениям (см. пп. 2,3). Независимость закономерностей получается за счет введения понятия сущности отношений в закономерности (см. п.2) и за счет организации самой процедуры обнаружения закономерностей (см. п.3).

Возможность работы с данными, имеющими пробелы, появляется благодаря использованию, помимо значений "истинность" и "ложность", значения "не определено" *) для отношений P_j^i .

Данный метод обнаружения закономерностей и метод предсказания являются дальнейшей разработкой алгоритма эмпирического предсказания [6].

2. Предварительные определения. Опишем в точности, что является входной информацией метода. Набор шкал признаков $x_0, x_1, \dots, x_n$, а также дополнительная априорная информация будут представлены эмпирической гипотезой $H_0 = \langle v_{H_0}, \text{Int}_{H_0}, T_{H_0} \rangle$, где $v_{H_0} = \{P_j^i, i=0,1,\dots,n'; j=1,\dots,n_1\}$, $\text{Int}_{H_0} = \{P_j^i, i=0,\dots,n'; j=1,\dots,n_1\}$, T_{H_0} – тестовый алгоритм [5]. Отношения, или будем говорить предикатные сим-

*) В работе [5] третьим значением является значение "не имеет смысла". Для целей данной работы третье значение будем интерпретировать как значение "не определено".

волы P_j^i , переобозначим для простоты следующим образом: $v_{H_0} = \{P_1, \dots, P_n, P_1^0, \dots, P_{n_0}^0\}$. Аналогично $\text{Int}_{H_0} = \{P_1, \dots, P_n, P_1^0, \dots, P_{n_0}^0\}$. Будем предполагать, что для T_{H_0} всегда найдется такое множество универсальных формул $[I] \alpha_{H_0}$ в словаре v_{H_0} , что $T_{H_0}(pr) = 1$ тогда и только тогда, когда все формулы из α_{H_0} истинны на pr . Определение истинности формулы на pr приведено ниже. Не ограничивая общности, потребуем, чтобы среди формул α_{H_0} не было тождественно-истинных, которые на самом деле не вносят никакого вклада в содержание H_0 .

Фиксируем некоторую гипотезу H_0 и множество объектов U . С помощью некоторого случайного процесса выберем множество $B = \{a_1, \dots, a_m\}$ объектов из генеральной совокупности U . Возьмем в качестве входной информации для метода пару $\langle H_0, pr_0 \rangle$, где H_0 – фиксированная гипотеза, pr_0 – запись результата применения экспериментальных процедур из Int_{H_0} к множеству B . Будем предполагать, что $T_{H_0}(pr_0) = 1$, так как в противном случае гипотеза H_0 опровергнута экспериментом pr_0 и пара $\langle H_0, pr_0 \rangle$ не может быть входной информацией метода.

Построим разложение универсальных формул. Пусть Φ – универсальная, не тождественно-истинная формула $\Phi = \forall x_1, \dots, x_n, A(x_1, \dots, x_n)$, где $A(x_1, \dots, x_n)$ – бескванторная формула. Тогда $A(x_1, \dots, x_n)$ – не тождественно-истинная формула исчисления высказываний, где $P_i(x_1, \dots, x_{n_i})$, входящие в формулу Φ , рассматриваются как булевы переменные. Используем тождества:

$$C_1 \vee C_2 \vee \dots \vee C_n \equiv \bar{C}_2 \& \bar{C}_3 \& \dots \& \bar{C}_n \rightarrow C_1 \equiv \\ \equiv \bar{C}_1 \& \bar{C}_2 \& \dots \& \bar{C}_n \rightarrow C_2 \equiv \dots \equiv \bar{C}_1 \& \bar{C}_2 \& \dots \& \bar{C}_{n-1} \rightarrow C_n, \quad (I)$$

$$\forall x_1, \dots, x_n, B_1 \& B_2 \equiv \forall x_1, \dots, x_n, B_1 \& \forall x_1, \dots, x_n, B_2, \quad (2)$$

где $C_1, \dots, C_n$ – некоторые булевы переменные, B_1, B_2 – произвольные формулы. Так как $A(x_1, \dots, x_n)$ не тождественно-истинна, то её можно привести к сокращенной конъюнктивной нормальной форме [2,3]. В полученной сокращенной конъюнктивной нормальной форме заменим каждый конъюнктивный член на конъюнкцию всех им-

пликаций из (I), тождественных данному конъюнктивному члену. В результате получится конъюнкция вида $C_1^{e_1} \& \dots \& C_n^{e_n}$, где $e = 0(1)$, если переменная берется с отрицанием (или без него). Применяя тождество (2), получим конъюнкцию членов вида

$$\forall x_1, \dots, x_n (P_{i_1}^{e_1}(x_1, \dots, x_{n_{i_1}}) \& \dots \& P_{i_n}^{e_n}(x_1, \dots, x_{n_{i_n}}) \Rightarrow P_{i_0}^{e_0}(x_1, \dots, x_{n_0}). \quad (3)$$

Получим разложение формулы Φ . Обозначим через σ_Φ множество конъюнктивных членов вида (3) разложения Φ .

Определим истинность формулы Φ на pr . Формула Φ - истинна на pr тогда и только тогда, когда на pr истинны все формулы из σ_Φ разложения Φ . Формула ψ из σ_Φ вида (3) истинна на pr тогда и только тогда, когда она истинна на всех наборах $\langle a_1, \dots, a_n \rangle$, $a_i \in V(pr)$ [5], на которых определены все предикатные символы из ψ . При проверке истинности формулы ψ на наборе $\langle a_1, \dots, a_n \rangle$, предикатный символ $P_i(a_{j_1}, \dots, a_{j_{m_i}})$ считается истинным (ложным), если соответственно $P_i(a_{j_1}, \dots, a_{j_{m_i}}) \in pr$ ($\bar{P}_i(a_{j_1}, \dots, a_{j_{m_i}}) \in pr$).

Если формула вида (3) не определена на каждом наборе $\langle a_1, \dots, a_n \rangle$, $a_i \in V(pr)$, то она также считается истинной на pr .

Применим полученное разложение к σ_{H_0} . Это всегда можно сделать, так как $A \in \sigma_{H_0}$ не тождественно-истинна. Каждую формулу $A \in \sigma_{H_0}$ разложим в σ_A . Обозначим объединения полученных множеств $\bigcup_{A \in \sigma_{H_0}} \sigma_A$ через σ_0 . Таким образом, каждая формула $A \in \sigma_0$

имеет вид (3). В дальнейшем ограничимся рассмотрением только формул вида (3) с кванторами или без них.

Множество всех возможных формул вида (3) в словаре $\forall_{H_0}$, взятых без кванторов, обозначим через M . Посылку формулы $A \in M$ обозначим через P_A , а заключение - через C_A .

ОПРЕДЕЛЕНИЕ 1. Для $A \in M$ переменную x_{i_1} , встречающуюся в P_A , назовем связанной с переменной x_{i_n} из C_A , если найдутся переменные $x_{i_2}, \dots, x_{i_{n-1}}$ в A (индексы не обязательно все различны) такие, что каждая пара переменных $\langle x_{i_1}, x_{i_2} \rangle$, $\langle x_{i_2},$

$x_{i_3} \rangle, \dots, \langle x_{i_{n-1}}, x_{i_n} \rangle$ встречается в каком-нибудь одном из предикатных символов, входящих в A .

В дальнейшем ограничимся рассмотрением только таких формул из M , в которых каждая переменная из посылки связана с какой-нибудь переменной из заключения. Множество таких формул обозначим через MC .

Метод обнаружения закономерностей и метод предсказания построены таким образом, что сначала обнаруживаются закономерности, связывающие предикатные символы $P_1, \dots, P_n$ с одним каким-то фиксированным предикатным символом P_0^j . На основании найденных закономерностей предсказывается этот предикатный символ. Повторяя процедуру обнаружения закономерностей и предсказания для остальных предикатных символов из $\{P_1^0, \dots, P_n^0\}$, мы получим соответствующее множество закономерностей и предсказание по нему всех предикатных символов $P_1^0, \dots, P_n^0$. Полученное предсказание будет окончательным, если оно согласуется с гипотезой H_0 .

Опишем сначала метод обнаружения закономерностей и метод предсказания для какого-то одного фиксированного предикатного символа P_0^j , который будем обозначать через P_0 . Обозначим через MC_{P_0} множество формул из MC , в заключении которых стоит P_0 ,

и через σ_{P_0} - множество формул из σ_0 , в заключении которых стоит P_0 , а в посылке встречаются предикатные символы из $\{P_1, \dots, P_n\}$.

Опишем процедуру, которая составляет элементарный акт анализа pr_0 . Зафиксируем какую-нибудь формулу $A \in MC_{P_0}$. Пусть число переменных в A равно k . Выделим из множества $V(pr_0) = \{a_1, \dots, a_n\}$ случайным образом L групп ($L = \lfloor \frac{n}{k} \rfloor$, $\lfloor \cdot \rfloor$ - целая часть числа) по k символов объектов в каждой: $\langle a_1^i, \dots, a_k^i \rangle$, $i = 1, 2, \dots, L$; $a_j^i \in V(pr_0)$. Внутри группы символы объектов расположим в случайном порядке. Сформируем массив целых чисел $M^A [0:1, \dots, 0:1]$ размерности $n+1$, содержащее всех элементов $[i_1, \dots, i_n, i_0]$ которого равно 0, $[i_1, \dots, i_n, i_0] = 0$, $i_j = 0, 1$; $j = 0, 1, \dots, n$, где n - число предикатных символов в P_A . Для каждой из L групп символов объектов сделаем следующее. Сопоставим фиксированной группе с заданным порядком $\langle a_{j_1}^i, \dots, a_{j_k}^i \rangle$ набор переменных $\langle x_1, \dots, x_k \rangle$. Подставим в A символы объектов вместо соответствующих переменных. На наборе $\langle a_{j_1}^i, \dots, a_{j_k}^i \rangle$

предикатные символы $P_1, \dots, P_n, P_0$ из A принимают определенные значения, которые зафиксированы в rg_0 . Если в rg_0 хотя бы один предикатный символ принимает значение "не определено", то переходим к следующей группе символов объектов. Если все значения определены, то переменным $i_j = 0, 1; j=0, 1, \dots, n$ приписываем значение 1 или 0, если соответственно $P_j(a_{j_1}^1, \dots, a_{j_m}^1) \in rg_0$ или $\bar{P}_j(a_{j_1}^1, \dots, a_{j_m}^1) \in rg_0, j = 0, 1, \dots, n$. В значениях переменных $i_j, j = 0, 1, \dots, n$, фиксируются значения истинности предикатных символов из A . Значение элемента массива $[i_1, \dots, i_n, i_0]$ увеличиваем на единицу. Переходим к следующей группе символов объектов. В результате этой процедуры в массиве M^A накопятся числа, сообщающие, сколько раз встретилось определенное сочетание значений предикатных символов из A в rg_0 . Массив M^A и есть результат элементарного акта анализа rg_0 . Очевидно, что для формул A_1 и A_2 , имеющих одни и те же предикатные символы, массивы M^{A_1} и M^{A_2} будут одинаковыми с точностью до перестановки индексов.

Сформулируем критерий, который будет применяться при отборе тех формул, которые выражают некоторую закономерность в rg_0 . Пусть дан массив $M^A [0:1, 0:1], A = (P_1(x_1, \dots, x_n) \Rightarrow P_0(x_1, \dots, x_n))$. Определим $n_{ij} = [i, j], i, j = 0, 1; n = \sum_j n_{ij}$. Пусть $P_{ij}, i, j = 0, 1; \sum_{ij} P_{ij} = 1$, — вероятности соответствующих событий. Сформулируем гипотезу $\mathcal{H}_0$ о двумерной независимости значений P_1 и P_0 , $\mathcal{H}_0: P_{ij} = P_{i.} \times P_{.j}, P_{i.} = P_{i1} + P_{i0}, P_{.j} = P_{1j} + P_{0j}$ против альтернативы $\mathcal{H}_1: P_{ij} \neq P_{i.} \times P_{.j}$. Эта гипотеза является сложной с одним ограничением и двумя степенями свободы [4, стр. 734]. Если $\mathcal{H}_0$ не верна, то значения P_1 и P_2 взаимозависимы, что даёт возможность по значениям P_1 предсказывать значения P_0 .

Предположим, что значения $n_{i.}$ и $n_{.j}$, где $n_{i.} = n_{i0} + n_{i1}, n_{.j} = n_{0j} + n_{1j}$, зафиксированы, а n_{11} и n_{01} — независимые случайные величины. В этом случае сформулированная гипотеза $\mathcal{H}_0$ является гипотезой о равенстве вероятностей в двух совокупностях [4, стр. 741], $\mathcal{H}_0: P_{11}/P_{.1} = P_{01}/P_{.1}$. Если $\mathcal{H}_0$ не верна, то

$P_{11}/P_{.1} \neq P_{01}/P_{.1}$ и либо $P_{11}/P_{.1} > P_{01}/P_{.1}$, либо $P_{11}/P_{.1} < P_{01}/P_{.1}$. Если $P_{11}/P_{.1} > P_{01}/P_{.1}$, то тогда $P_{11}/P_{.1} > P_{01}/P_{.1}, P_{00}/P_{.0} > P_{10}/P_{.0}$, т.е. посылка увеличивает вероятность заключения в формулах:

$$P_1(x_1, \dots, x_{n_1}) \Rightarrow P_0(x_1, \dots, x_{n_0}),$$

$$\bar{P}_1(x_1, \dots, x_{n_1}) \Rightarrow \bar{P}_0(x_1, \dots, x_{n_0}). \quad (4)$$

Если $P_{11}/P_{.1} < P_{01}/P_{.1}$, то $P_{10}/P_{.1} > P_{00}/P_{.0}, P_{01}/P_{.0} > P_{11}/P_{.1}$, т.е. посылка увеличивает вероятность заключения в формулах:

$$P_1(x_1, \dots, x_{n_1}) \Rightarrow \bar{P}_0(x_1, \dots, x_{n_0}),$$

$$\bar{P}_1(x_1, \dots, x_{n_1}) \Rightarrow P_0(x_1, \dots, x_{n_0}). \quad (5)$$

Возьмем для проверки гипотезы $\mathcal{H}_0$ точный критерий независимости, предложенный Фишером [4, стр. 736]. Этот критерий является равномерно наиболее мощным, несмещённым критерием как в случае, если проверяется двумерная независимость, так и в случае, если проверяется равенство вероятностей в двух совокупностях [4, стр. 740]. Таким образом, применив критерий с некоторым уровнем α , мы получим, что либо нужно принять, что значения P_1 и P_0 независимы и P_1 не увеличивает вероятность предсказания P_0 , либо, что P_1 и P_0 зависимы и P_1 можно использовать для предсказания P_0 , используя приведенные формулы, так как, согласно тому же критерию, значения P_1 увеличивают вероятность соответствующих значений P_0 . Если P_1 и P_0 зависимы, то по соотношениям

$$n_{11} > (n_{1.} \times n_{.1})/n,$$

$$n_{11} < (n_{1.} \times n_{.1})/n \quad (6)$$

будем знать, применять ли для предсказания формулы (4) или (5) соответственно. В дальнейшем всегда будем предполагать, что зафиксирован некоторый уровень α , с которым применяется критерий.

Рассмотрим $M^A[0:1, \dots, 0:1]$, $A \in MCR_0$.

$$A = (P_1^{\epsilon_1}(x_1, \dots, x_{n_1}) \& \dots \& P_n^{\epsilon_n}(x_1, \dots, x_{n_n}) \rightarrow P_0^{\epsilon_0}(x_1, \dots, x_{n_0})).$$

Нужно выяснить, все ли предикатные символы $P_1^{\epsilon_1}, \dots, P_n^{\epsilon_n}$ или их совокупности существенны для предсказания $P_0^{\epsilon_0}$. Рассмотрим произвольное, не пустое подмножество $P_{i_1}^{\epsilon_{i_1}}, \dots, P_{i_k}^{\epsilon_{i_k}}$ множества $\{P_1^{\epsilon_1}, \dots, P_n^{\epsilon_n}\}$. Определим массив $M_{i_1, \dots, i_k}^A[i, j]$, $i, j = 0, 1$;

$$M_{i_1, \dots, i_k}^A[1, j] = M^A[\epsilon_1, \dots, \epsilon_n, j],$$

$$M_{i_1, \dots, i_k}^A[0, j] = \sum_{\substack{\epsilon_{i_s} = 0, 1; i_s = i_1, \dots, i_k \\ \epsilon_{i_s} = \epsilon_{i_s}; i_s \neq i_1, \dots, i_k}} M^A[\epsilon_1, \dots, \epsilon_n, j] - M^A[\epsilon_1, \dots, \epsilon_n, j].$$

Этот массив даёт возможность узнать, как влияют предикатные символы $P_{i_1}^{\epsilon_{i_1}}, \dots, P_{i_k}^{\epsilon_{i_k}}$, рассматриваемые как один предикатный символ вида $P_{i_1}^{\epsilon_{i_1}} \& \dots \& P_{i_k}^{\epsilon_{i_k}}$, при фиксированных значениях остальных предикатных символов на увеличение вероятности предсказания $P_0^{\epsilon_0}$.

ОПРЕДЕЛЕНИЕ 2. Подмножество $P_{i_1}^{\epsilon_{i_1}}, \dots, P_{i_k}^{\epsilon_{i_k}}$ существенно в A , если конъюнкция $P_{i_1}^{\epsilon_{i_1}} \& \dots \& P_{i_k}^{\epsilon_{i_k}}$ взаимозависима с $P_0^{\epsilon_0}$ согласно критерию, применённому к $M_{i_1, \dots, i_k}^A$, и значение ϵ_0 согласно с первой формулой из (4) или (5) в соответствии с (6).

ОПРЕДЕЛЕНИЕ 3. Формулу $A \in MCR_0$ назовем неприводимой, если любое не пустое подмножество предикатов из P_A существенно в A .

ОПРЕДЕЛЕНИЕ 4. Формулу $A \in MCR_0$ назовем максимальной неприводимой, если нет неприводимой формулы $A' \in MCR_0$ такой, что $C_A = C_{A'}$, $P_A = P_{A'} \& P_{n+1}^{\epsilon_{n+1}} \& \dots \& P_n^{\epsilon_n}$.

Пусть дана произвольная формула A .

ОПРЕДЕЛЕНИЕ 5 [3]. Простым следствием формулы A называется такая не содержащая повторений и не тождественно-истинная элементарная дизъюнкция, которая, будучи логическим следствием A , не поглощается никаким более сильным следствием того же вида, т.е. после отбрасывания какого-нибудь из её членов, перестаёт быть следствием.

СЛЕДСТВИЕ 1. Сокращённая конъюнктивная нормальная форма формулы A есть конъюнкция всех её простых следствий.

СЛЕДСТВИЕ 2. Любая $A \in P_0$ является такой импликацией, что из P_A нельзя убрать ни один предикат или их совокупность так, чтобы A оставалось следствием σ_{H_0} .

ОПРЕДЕЛЕНИЕ 6. Формулы из σ_{P_0} будем называть априорно максимальными неприводимыми.

3. Метод обнаружения закономерностей. Он заключается в основном в нахождении максимальных неприводимых формул. В результате обучения с уровнем α будет найдено множество F_α формул, которые будем называть закономерностями уровня α на pr_0 . Введем некоторые обозначения:

$$MP_A \stackrel{\text{def}}{=} \{P_1^{\epsilon_1}, \dots, P_n^{\epsilon_n}\}, \text{ где } P_A = P_1^{\epsilon_1} \& \dots \& P_n^{\epsilon_n};$$

$$M_{H_0} \stackrel{\text{def}}{=} \{A' | A' \in MCR_0, A \in \sigma_{P_0}, MP_{A'} \subset MP_A \text{ или } MP_A \subset MP_{A'}\};$$

$$M_{00}^{df} = M_{CP_0} \setminus M_{H_0}, \quad M_{00}^{t, df} = \{ A \mid A \in M_{00}, |MP_A| = t \}.$$

Метод имеет следующие этапы:

$$0. F_\alpha \stackrel{df}{=} \sigma P_0.$$

I. Если $A \in M_{00}^1$ неприводима, то включаем её в F_α .

t. В общем случае t-й этап, $t = 1, 2, \dots$. Если есть $A' \in M^t$, $A \in F_\alpha$, $MP_A \subset MP_{A'}$, и $MP_{A'} \setminus MP_A$ существенно в A' , то формулу A выбрасываем из F_α . Добавляем к F_α все неприводимые формулы $A' \in M_{00}^t$.

Процедура заканчивается на таком этапе t , что ни для одной формулы из M_{00}^t при данном уровне α и при данном обучающем материале rg_0 не может в принципе оказаться, что она неприводима, т.е. F_α в принципе не может быть пополнена.

Поясним процедуру обучения. Если нашлись $A' \in M_{00}^t$, $A \in F_\alpha$, $MP_A \subset MP_{A'}$, и $MP_{A'} \setminus MP_A$ существенно в A' , то это значит, что предсказание формулы A можно уточнить с помощью предикатов из $MP_{A'} \setminus MP_A$. Если при этом A' неприводима, то это уточнение фиксируется в F_α включением A' . Может оказаться, что в A' содержится не вся "полезная" информация, которая есть в A . "Остаток" информации можно записать в виде множества формул:

$$\{A' \mid P_{A'} = P_A \& (P_1^{E_1}), P_1^{E_1} \in MP_{A'} \setminus MP_A \}.$$

Но эти формулы, в свою очередь, также будут рассмотрены. Если A' не окажется неприводимой, то, хотя $MP_{A'} \setminus MP_A$ существенно в A' , тем не менее есть подмножество Q в $MP_{A'}$, не существенное в A' и, значит, "дублирующее" информацию из MP_A . Следовательно, можно ограничиться рассмотрением формулы A'' с $MP_{A''} = MP_{A'} \setminus Q$, которая также рассматривается отдельно.

Для окончания процедуры обучения нужно найти оценки условной вероятности следствия при истинности посылки. Для каждой формулы $A \in F_\alpha$, $A \in \sigma P_0$, используя M^A , можно вычислить с некоторым фиксированным коэффициентом доверия $1 - \beta$, используя один из известных методов доверительных интервалов, нижний доверительный предел D_A^β для вероятности $\mathcal{P}(C_A / P_A)$, $\mathcal{P}(C_A / P_A) \geq D_A^\beta \geq 1 - \beta$. Нем надо, в отличие от приведенного доверитель-

ного предела, вычислить доверительный предел D_A^γ , учитывающий одновременное выполнение аналогичных неравенств для всех формул из $M^{(t)} \stackrel{df}{=} M_{00}^1 \cup \dots \cup M_{00}^t$, где t — последний этап обучения. Пусть $M_{00}^{(t)} = N$. Предположим, что найдены доверительные пределы для всех событий F_i из некоторого множества $F = \{F_i\}$, $i = 1, 2, \dots, N_F$; $\mathcal{P}(\mathcal{P}_{F_i} \geq D_{F_i}^\beta) \geq 1 - \beta$, $i = 1, 2, \dots, N_F$. Тогда, применяя теорему о сложении вероятностей, получим

$$\mathcal{P}((\mathcal{P}_{F_1} < D_{F_1}^\beta) \vee (\mathcal{P}_{F_2} < D_{F_2}^\beta) \vee \dots \vee (\mathcal{P}_{F_{N_F}} < D_{F_{N_F}}^\beta)) < N_F \cdot \beta$$

или, что то же самое,

$$\mathcal{P}((\mathcal{P}_{F_1} \geq D_{F_1}^\beta) \& \dots \& (\mathcal{P}_{F_{N_F}} \geq D_{F_{N_F}}^\beta)) \geq 1 - N_F \cdot \beta.$$

Таким образом, для того чтобы учесть одновременное выполнение неравенств для всех формул из $M_{00}^{(t)}$, достаточно подсчитать доверительный предел D_A^γ для $A \in F_\alpha$, $A \in \sigma P_0$ с уровнем $\gamma = \beta / N$. Для $A \in \sigma P_0$ положим $D_A^\gamma = 1$.

На этом процедура обнаружения закономерностей заканчивается. Результатом является множество формул F_α , для каждой из которых подсчитан предел D_A^γ . Множество F_α — множество закономерностей уровня α — может иметь самостоятельный интерес, помимо использования его в предсказании.

Множество закономерностей F_α ещё не есть общая закономерность для предсказания P_0 . Такую общую закономерность, исходя из множества

$$F_\alpha = \{P_{A_1} \rightarrow P_0, 1 = 1, 2, \dots, l_1\} \cup \{P_{A_2} \rightarrow P_0, j = 1, 2, \dots, l_2\},$$

можно было бы, например, получить, если взять формулу

$$(P_{A_1}^1 \& P_{A_1}^2 \& \dots \& P_{A_1}^{l_1} \rightarrow P_0) \& (P_{A_2}^1 \& P_{A_2}^2 \& \dots \& P_{A_2}^{l_2} \rightarrow P_0),$$

где $D_1^Y = \min_i D_i^Y$, $D_2^Y = \min_j D_j^Y$. Но с помощью такой закономерности можно предсказывать P_0 только с наименьшей оценкой вероятности. Любое подобное обобщение, связанное с уменьшением числа вероятностных характеристик (в данном случае D_j^Y), дает более грубую, хотя, возможно, более простую формулировку обнаруженной закономерности (в данном случае за счет приведения членов в посылке вид закономерности упростится). Поэтому в работе не рассматривается вопрос об общем представлении закономерностей из F_α . Для получения наиболее точного предсказания используется само F_α .

4. Метод предсказания на основании найденных закономерностей. Предположим, что из генеральной совокупности U случайно выбрали объект b . Определим $\text{Int}_{H_0}^i = \text{Int}_{H_0} \setminus \{P_0^0, \dots, P_{n_0}^0\}$; pr_0 - протокол наблюдений объектов $a_1, \dots, a_{n_0}, b$ с помощью интенсивных процедур из $\text{Int}_{H_0}^i$, т.е. будем считать, что относительно символа объекта b нам известны значения всех предикатных символов из $\{P_1, \dots, P_n\}$.

Фиксируем набор $\langle a_{i_1}, \dots, a_{i_{k-1}}, b, a_{i_{k+1}}, \dots, a_{i_{n_0}} \rangle$, $a_{i_j} \in B(\text{pr}_0)$. Опишем метод предсказания значения $P_0(a_{i_1}, \dots, b, \dots, a_{i_{n_0}})$ для этого набора. Для остальных наборов он аналогичен.

Переберём последовательно формулы из F_α . Для $A \in F_\alpha$ посмотрим, есть ли в Π_A переменные, не входящие в C_A . Если есть, то из $B(\text{pr}_0)$ случайно выберем столько символов объектов $\langle a_1, \dots, a_k \rangle$, сколько таких переменных. Подставим в Π_A объекты из наборов $\langle a_1, \dots, a_k \rangle$, $\langle a_{i_1}, \dots, b, \dots, a_{i_{n_0}} \rangle$, объекты из второго набора подставляются вместо $x_1, \dots, x_{n_0}$. Проверим, все ли значения предикатных символов из Π_A имеют смысл и истинна ли Π_A . Если нет, то переходим к следующей формуле. Если да, то делаем предсказание, что $P_0(a_{i_1}, \dots, b, \dots, a_{i_{n_0}})$ истинна, если $\epsilon_0 = 1$, и ложна, если $\epsilon_0 = 0$, с вероятностью большей, либо равной D_A^Y . Переходим к следующей формуле. После пересмотра всех формул нужно принять решение, предсказывать ли значение "истина", "ложь"

или вообще не делать никаких предсказаний - "отказ". Это решение должно определяться теми дополнительными предположениями, которые мы делаем: например, априорными знаниями о характере задачи, признаков, о требуемой надежности предсказания. Мы сделаем предположение о независимости формул из F_α . Две формулы $\Pi_1 \rightarrow P_0$ и $\Pi_2 \rightarrow P_0$ будем считать независимыми, если выполняются следующие два требования:

$$1. \mathcal{P}(\Pi_1 \& \Pi_2) = \mathcal{P}(\Pi_1) \cdot \mathcal{P}(\Pi_2).$$

$$2. \mathcal{P}(\Pi_1 \& \Pi_2 \& \bar{P}_0) = \mathcal{P}(\Pi_1 \& \bar{P}_0) \cdot \mathcal{P}(\Pi_2 \& \bar{P}_0).$$

Из этих условий следует, что

$$\mathcal{P}(P_0 / \Pi_1, \Pi_2) = 1 - (1 - (P_0 / \Pi_1))(1 - (P_0 / \Pi_2)).$$

Пусть на основании формул $A_1, \dots, A_S$ из F_α было сделано предсказание истинности P_0 с вероятностями большими, либо равными $D_{A_1}^Y, \dots, D_{A_S}^Y$. Тогда, используя предположение о независимости, можно оценить вероятность $\mathcal{P}_H$ истинности P_0 :

$$\mathcal{P}_H \geq 1 - \prod_{i=1}^{S_1} (1 - D_{A_i}^Y). \text{ Аналогично можно оценить вероятность } \mathcal{P}_L,$$

используя предсказания ложности P_0 , сделанные на основании каких-то других формул $A_1^{\dagger}, \dots, A_{S_2}^{\dagger}$ из F_α : $\mathcal{P}_L \geq 1 - \prod_{i=1}^{S_2} (1 - D_{A_i^{\dagger}}^Y)$.

В случае, если $D_{A_i}^Y = 1$ для некоторого i , $\mathcal{P}_L$ полагаем равным 0. В случае, если $D_{A_j^{\dagger}}^Y = 1$ для некоторого j , $\mathcal{P}_H$ полагаем равным 0. В обоих случаях предположение о независимости не может быть выполнено. Поэтому значения $\mathcal{P}_H$ и $\mathcal{P}_L$ определяются согласно априорной информации. Используя $\mathcal{P}_H$ и $\mathcal{P}_L$, можно теперь получить окончательное предсказание.

Для $P_0(a_{i_1}, \dots, b, \dots, a_{i_{n_0}})$ предсказывается значение "истина", если $\mathcal{P}_H > \mathcal{P}_L$, и предсказывается значение "ложь", если $\mathcal{P}_L > \mathcal{P}_H$. Если $\mathcal{P}_H = \mathcal{P}_L$ или если не нашлось ни одной формулы, на основании которой можно было бы сделать предсказание, то тогда не делается никакого предсказания - значение "не определено".

Повторяя описанную процедуру предсказания для каждого набора $\langle a_{i_1}, \dots, b, \dots, a_{i_{n_0}} \rangle$, $a_1, \dots, a_{n_0} \in B(\text{pr}_0)$, можно предска-

зять все значения предикатного символа P_0 на наборах, включающих новый объект b , т.е. доопределить P_0 на множестве $\{a_1, \dots, a_m, b\}$.

Итак, мы описали метод обнаружения закономерностей и метод предсказания для одного фиксированного предикатного символа P_0 . Применяя описанный метод ко всем остальным предикатным символам из $\{P_1^0, \dots, P_{n_0}^0\}$, мы доопределим все их на множестве $\{a_1, \dots, a_m, b\}$. Получив такое предсказание, мы ещё не получим в точном смысле предсказания признака x_0 в соответствующей шкале. Доопределённые значения $P_1^0, \dots, P_{n_0}^0$ на $\{a_1, \dots, a_m, b\}$ должны удовлетворять аксиомам из σ_0 , содержащим только предикатные символы из $\{P_1^0, \dots, P_{n_0}^0\}$. Если аксиомы выполняются, то полученное предсказание является окончательным, если нет, то тогда полученное предсказание не удовлетворяет априорным предположениям о свойствах x_0 и не делается никакого предсказания — "отказ".

Автор считает своим приятным долгом выразить благодарность Ю.Г.Косареву, А.А.Москвитину, и К.Ф.Самохвалову за ряд полезных замечаний по работе.

Л и т е р а т у р а

1. МАЛЫЦЕВ А.И. Алгебраические системы, М., "Наука", 1970.
2. Дискретная математика и математические вопросы кибернетики, под ред. С.В.Яблонского, О.Б.Лупанова, т.1, "Наука", 1974.
3. БРОДСКИЙ И.Н. Элементарное введение в символическую логику, 2-е изд., ЛГУ., 1972.
4. КЕНДАЛ М., СТЬЮАРТ А. Статистические выводы в связи, М., "Наука", 1973.
5. САМОХВАЛОВ К.Ф. О теории эмпирических предсказаний. — В кн.: Вычислительные системы. Вып. 55, Новосибирск, 1973, с.3-35.
6. ВИТЧЕВ Е.Е. Алгоритм эмпирического предсказания. — В кн.: Вычислительные системы. Вып. 61, Новосибирск, 1975, с. 28-36.
7. Психологические измерения. Сб. под ред. Л.Д.Мешалкина. М., "Мир", 1967.
8. Нелинейные и линейные методы в распознавании образов. М., "Наука", 1975.
9. ИВАХЕНКО А.Г., ЛАПА В.Г. Предсказание случайных процессов. Киев, "Наукова думка", 1971.

Поступила в ред.-изд.отд.

13 января 1976 года