

УДК 519.237:519.853.4

РЕШЕНИЕ ЗАДАЧИ МНОГООТКЛИКОВОЙ РЕГРЕССИИ
ДЛЯ РАЗНОТИПНЫХ ПРИЗНАКОВ
В КЛАССЕ ЛОГИЧЕСКИХ РЕШАЮЩИХ ПРАВИЛ

Н.Г.Старцева

В в е д е н и е

К настоящему времени наиболее широкое распространение получили регрессии с одномерным откликом [1]. Однако реальные объекты, для описания которых привлекается регрессионный анализ, нередко имеют несколько откликов. В связи с этим представляет интерес многооткликовая регрессия. Появились такие модификации многооткликовой регрессии, как псевдонезависимая модель, модель в виде системы одновременных (синхронных) уравнений. В первом случае речь идет о ряде стохастически связанных между собой одномерных регрессионных уравнений. Во втором - предполагается, что между разными откликами системы существуют линейные связи.

В работе предлагается другой подход к построению многооткликовой регрессии - рассмотрение ее в классе логических решающих правил. При этом допускается разнотипность переменных факторов, т.е. исходная система факторов может одновременно содержать булевы, номинальные, ранговые, количественные факторы. В дальнейшем признаки (факторы): булевы, номинальные, ранговые будем называть дискретными признаками.

Регрессию с одномерным откликом в классе логических решающих правил рассматривал Г.С.Лбов [2]. Класс логических решающих правил обладает рядом достоинств: на его языке предствавимы регрессионные модели различной сложности, модели описываются на языке, близком к естественному языку логических суждений, анализируется разнотипная информация.

§1. Постановка задачи многооткликовой регрессии в случае разнотипных переменных

Пусть для описания каждого наблюдения α из некоторой генеральной совокупности Γ используются признаки $X_1, \dots, X_l, Z_1, \dots, Z_n, Y_1, \dots, Y_k$. Пусть признаки $X_1, \dots, X_l, Z_1, \dots, Z_n$ - независимые переменные (факторы), а Y_1, \dots, Y_k - зависимые переменные (отклики). Пусть признаки $X_1, \dots, X_l, Y_1, \dots, Y_k$ - непрерывные случайные величины, признаки Z_1, \dots, Z_n - дискретные случайные величины, для которых определены условные плотности распределения $P(x, y/z)$ и распределения вероятностей $P(z)$ в многомерной области D , где $x = (X_1(\alpha), \dots, X_l(\alpha))$, $z = (Z_1(\alpha), \dots, Z_n(\alpha))$, $y = (Y_1(\alpha), \dots, Y_k(\alpha))$; $D = D_x \times D_z \times D_y$, $x \in D_x$, $z \in D_z$,

$$y \in D_y, D_x = \prod_{j=1}^l D_{x_j}, D_z = \prod_{j=1}^n D_{z_j}, D_y = \prod_{j=1}^k D_{y_j}. \text{ Здесь}$$

$D_{x_j}, D_{z_j}, D_{y_j}$ - соответственно области значений признаков

X_j, Z_j, Y_j . Рассматривается случай независимых переменных откликов Y_1, \dots, Y_k .

Целью регрессионного анализа является построение правила предсказания, которое позволило бы по описанию x и z предсказать значение y .

Под решающим правилом f из некоторого класса Φ будем понимать отображение $f: D_x \times D_z \rightarrow D_y$.

Прогнозируемый вектор значений признаков $Y_1, \dots, Y_j, \dots, Y_k$ с помощью правила f обозначим через $y' = f(x, z) = (y'_1, \dots, y'_k)$ (прогнозируемые отклики).

Определим условную плотность распределения:

$$p(y/x, z) = \frac{p(y, x/z)}{p(x/z)} = \frac{p(y, x/z)}{\int_{D_y} p(y, x/z) dy}$$

Критерием качества решающего правила f будем считать величину:

$$\begin{aligned} F_f &= M_z M_x M_y \{g(z, x, y)\} = \\ &= \sum_{z \in D_z} P(z) \int_{D_x} p(x/z) \left\{ \int_{D_y} g(z, x, y) p(y/x, z) dy \right\} dx, \end{aligned}$$

где

$$g(z, x, y) = \sum_{j=1}^k \lambda_j (y_j - y'_j)^2,$$

$$M_y \{g(z, x, y)\} = \int_{D_y} g(z, x, y) p(y/x, z) dy,$$

$$M_x M_y \{g(z, x, y)\} = \int_{D_x} p(x/z) [M_y \{g(z, x, y)\}] dx,$$

$$M_z M_x M_y \{g(z, x, y)\} = \sum_{z \in D_z} P(z) M_x M_y \{g(z, x, y)\},$$

λ_j - весовой коэффициент.

Данный критерий является распространением известного критерия наименьших квадратов в случае многооткликовой регрессии от разнотипных признаков. Так как Y_1, \dots, Y_k - независимые переменные, то

$$\begin{aligned}
\int_{D_y} g(z, x, y) p(y/x, z) dy &= \sum_{j=1}^k \int_{D_{y_1}} \dots \int_{D_{y_j}} \dots \int_{D_{y_k}} \lambda_j (y_j - y'_j)^2 \times \\
&\times \prod_{j=1}^k p(y_j/x, z) dy_1 \dots dy_j \dots dy_k = \\
&= \sum_{j=1}^k \int_{D_{y_1}} p(y_1/x, z) dy_1 \dots \int_{D_{y_j}} \lambda_j (y_j - y'_j)^2 p(y_j/x, z) dy_j \dots \\
&\dots \int_{D_{y_k}} p(y_k/x, z) dy_k = \sum_{j=1}^k \lambda_j \int_{D_{y_j}} (y_j - y'_j)^2 p(y_j/x, z) dy_j,
\end{aligned}$$

так как

$$\int_{D_{y_j}} p(y_j/x, z) dy_j = 1, \quad j = \overline{1, k}.$$

Тогда

$$\begin{aligned}
F_{\mathcal{P}} &= \sum_{z \in D_z} P(z) \int_{D_x} p(x/z) \times \\
&\times \left\{ \sum_{j=1}^k \lambda_j \int_{D_{y_j}} (y_j - y'_j)^2 p(y_j/x, z) dy_j \right\} dx.
\end{aligned}$$

Известно [2], что оптимальным решающим правилом, обеспечивающим минимум критерия, является следующее правило:

$$f_0(x, z) = y' = (y'_1, \dots, y'_j, \dots, y'_k),$$

где

$$y'_j = M(y_j/x, z) = \int_{D_{y_j}} y_j p(y_j/x, z) dy_j, \quad j = \overline{1, k}.$$

§2. Решение задачи многооткликовой регрессии
в классе логических решающих правил

Рассмотрим решение задачи в классе логических решающих правил Φ_M (будем аппроксимировать функцию $y' = f(x, z)$ в классе логических решающих правил, $f \in \Phi_M$).

Опишем класс логических решающих правил. Здесь решающим правилом f задается разбиение области $D_x \times D_z$ на M подмножеств $\alpha = \{E^1, \dots, E^t, \dots, E^M\}$, т.е. $D_x \times D_z =$

$$= \bigcup_{t=1}^M E^t, \quad E^t \cap E^1 = \emptyset \quad \text{для } t \neq 1, \quad 2 \leq M < \infty.$$

Отличительной особенностью данного подхода является то, что для описания каждого подмножества E^t используется своя подсистема признаков $\{X_{j_1}, \dots, X_{j_{1_t}}, Z_{j_1}, \dots, Z_{j_{n_t}}\}$, состоящая из l_t непрерывных признаков и из n_t дискретных. Здесь $E^t = E_x^t \times E_z^t$, где

$$E_x^t = \tilde{E}_x^t \times \prod_{j \in I_x^t} D_{X_j}, \quad E_z^t = \tilde{E}_z^t \times \prod_{j \in I_z^t} D_{Z_j},$$

$$I_x^t = \{j_1, \dots, j_{l_t}\}, \quad I_z^t = \{j_1, \dots, j_{n_t}\}.$$

Общее число признаков, используемых для описания разбиения α , будет $m = |I_x| + |I_z|$, где

$$I_x = \bigcup_{t=1}^M I_x^t, \quad I_z = \bigcup_{t=1}^M I_z^t, \quad m \leq n+1.$$

В простейшем случае

$$\tilde{E}_x^t = \prod_{j, \nu \in I_x^t} E_{j, \nu}, \quad \tilde{E}_z^t = \prod_{j, \nu \in I_z^t} E_{j, \nu},$$

где $E_{j, \nu} \subset D_{x_j}$ или $E_{j, \nu} \subset D_{z_j}$ и $E_{j, \nu} \cup \bar{E}_{j, \nu} = D_{x_j}$ или

$E_{j, \nu} \cup \bar{E}_{j, \nu} = D_{z_j}$. Очевидно, что такое представление подмно-

жеств $\tilde{E}_x^t, \tilde{E}_z^t, t \in \overline{1, M}$, есть своеобразное ограничение на разбиение множества D .

Класс разбиений, удовлетворяющий этому ограничению, обозначим через Ψ . В дальнейшем будем рассматривать только данный класс разбиений множества D .

Разбиение $\alpha \in \Psi_M$ удобнее всего описывать в виде дерева. Под деревом B принимается корневое дихстомическое дерево, у которого каждой внутренней вершине (узлу) ставится в соответствие некоторый предикат; ветвям, исходящим из внутренней вершины, соответствует истинность или ложность высказывания, получающегося при замене признаков их значениями. Если каждой конечной вершине $b^t, t \in \overline{1, M}$, дерева B приписать решение, то такое дерево будем называть деревом решений (логическим решающим правилом). Логическое решающее правило f задается парой $\langle \alpha, r^\alpha \rangle, \alpha \in \Psi_M, r^\alpha \in R_M$, где R_M - множество возможных решений. Класс логических решающих правил определяется декартовым произведением $\Phi_M = \Psi_M \times R_M$.

Рассматриваются следующие типы предикатов: $J(a, E_j) = [X_j(a) \in E_j]$, где $a \in \Gamma, E_j \subset W_j$. Для дискретного признака под W_j понимается любое подмножество из множества различных значений признака X_j ; для количественного признака W_j - множество всевозможных подынтервалов некоторого интервала $D_j = [\beta_j, \gamma_j]$.

В статье рассматривается следующая модель регрессионного анализа: для любого разбиения α укажем набор решений $\Gamma^\alpha = \{y'_1, \dots, y'_t, \dots, y'_M\}$, где $y'_t = (y'_{1t}, \dots, y'_{jt}, \dots, y'_{kt})$ - некоторый вектор, $y'_{jt} \in [\beta_j, \gamma_j]$, $y'_t = f'_t(x, z) = (f'_{1t}(x, z), \dots, f'_{jt}(x, z), \dots, f'_{kt}(x, z))$.

Критерий качества предсказания при использовании решающего правила $f \in \Phi_M$ вычисляется следующим образом:

$$F_f = F(\alpha, r^\alpha) = \sum_{t=1}^M P[(x, z) \in E^t] \cdot F_f^t,$$

$$P[(x, z) \in E^t] = \sum_{z \in E_z^t} P(z) \int_{E_x^t} p(x/z) dx,$$

$$F_f^t = \sum_{z \in E_z^t} P(z) \int_{E_x^t} p(x/z) \times$$

$$\times \left\{ \sum_{j=1}^k \lambda_j \int_{\beta_j}^{\gamma_j} (y_j - y'_{jt})^2 p(y_j/x, z) dy_j \right\} dx,$$

где $P[(x, z) \in E^t]$ - вероятность того, что точка (x, z) попала в область E^t , F_f^t - значение критерия качества для области E^t .

Под оптимальным правилом $f(M) \in \Phi_M$ понимается правило, при котором

$$F_f(M) = F^*(\alpha, r^\alpha) = \min_{\alpha \in \Psi_M} \cdot \min_{r^\alpha \in R_M} F(\alpha, r^\alpha).$$

Очевидно, что $F_f(M) \geq F_{f_0}$.

Наилучший набор решений Γ^α для фиксированного разбиения α задается следующим образом: если $(x, z) \in E^t$, то

$$y'_{jt} = \sum_{z \in E_z^t} P(z) \left[\int_{E_x^t} M(y_j/x, z) p(x/z) dx \right], \quad t = 1, M.$$

При $M = 1$ получим

$$y'_j = \sum_{z \in D_z} P(z) \int_{D_x} M(y_j/x, z) p(x/z) dx,$$

а критерий

$$F_f(1) = \sum_{z \in D_z} P(z) \int_{D_x} p(x/z) x \times \left\{ \sum_{j=1}^k \lambda_j \int_{B_j}^{Y_j} (y_j - y'_j)^2 p(y_j/x, z) dy_j \right\} dx.$$

В дальнейшем будем использовать нормированные критерии:

$$\frac{F_f(M)}{F_f(1)} = F(M); \quad \frac{F_{f_0}}{F_f(1)} = F_0.$$

На практике условные плотности распределения и распределения вероятностей неизвестны, решающее правило строится по подмножеству наблюдений $A \subseteq \Gamma$, которому соответствует таблица данных $V = \{x_\nu^i, z_\mu^i, y_j^i\}$, $i = \overline{1, N}$; $\nu = \overline{1, l}$; $\mu = \overline{1, n}$; $j = \overline{1, k}$, называемая обучающей выборкой, N - объем обучающей выборки.

Для фиксированного разбиения α набор решений $\Gamma^\alpha = (y'_1, \dots, y'_t, \dots, y'_M)$ строится так:

$$y_{jt}^i = \bar{y}_{jt} = \sum_{(x^i, z^i) \in E^t} y_{jt}^i / N_t,$$

где N_t - число точек (x^i, z^i) , принадлежащих подмножеству E^t , $y_t^i = (y_{1t}^i, \dots, y_{jt}^i, \dots, y_{kt}^i)$.

Критерий качества предсказания при фиксированном разбиении α оцениваем следующим образом:

$$\bar{F}(\alpha, r^\alpha) = \bar{F}_{\bar{f}(M)} = \frac{1}{N} \left[\sum_{t=1}^M \sum_{(x^i, z^i) \in E^t} \sum_{j=1}^k \lambda_j (y_j^i - \bar{y}_{jt})^2 \right],$$

а нормированный критерий

$$\bar{F}(M) = \frac{\bar{F}_{\bar{f}(M)}}{\bar{F}_{\bar{f}(1)}},$$

где

$$\bar{F}_{\bar{f}(1)} = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^k \lambda_j (y_j^i - \bar{y}_j)^2, \quad \bar{y}_j = \frac{1}{N} \sum_{i=1}^N y_j^i.$$

Под наилучшим решающим правилом $\bar{f}^*(M) \in \Phi_M$, определенным по таблице V , будем понимать правило, для которого

$$\bar{F}^*(M) = \min_{\bar{f}(M) \in \Phi_M} \bar{F}(M).$$

§3. Алгоритм многооткликовой регрессии

Как уже отмечалось в предыдущем параграфе, разбиение α представляется в виде дерева решений, при построении которого осуществляется последовательное "наращивание" вершин дерева в соответствии с принципом присоединения "лучшей" вершины к "луч-

шей¹¹. Подобное построение дерева решений, но для задач дискриминантного анализа рассматривалось в [3].

До построения дерева решений в алгоритме предусмотрена нормировка всех значений y_j^i , $i = \overline{1, N}$; $j = \overline{1, k}$. Нормировка

проводится следующим образом: $\tilde{y}_j^i = (y_j^i - \bar{y}_j) / s_j$, где

$$s_j = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_j^i - \bar{y}_j)^2}.$$

Нормированные значения $\{\tilde{y}_j^i\}$ используются при вычислении критерия $\bar{F}(M)$. В алгоритме рассматриваются следующие типы предикатов:

1. Для дискретных признаков $J(a, E_j) = [Z_j(a) \in E_j]$, где $a \in \Gamma$, $E_j \in W_j$, $j = \overline{1, n}$. Под W_j понимается множество различных значений признака Z_j или всевозможных объединений двух различных значений.

2. Для количественных признаков $J(a, E_j) = [X_j(a) \in E_j]$, где $a \in \Gamma$, $E_j \in W_j$, $j = \overline{1, l}$. Под W_j понимается множество интервалов типа $[\rho', \rho'']$, $[-\infty, \rho'']$, где $\rho', \rho'' \in D_{X_j}^i$, $D_{X_j}^i$ - множество среднеарифметических значений двух соседних несовпадающих выборочных значений признака X_j . Для сокращения машинного времени среднеарифметическое значение между двумя соседними точками множества $D_{X_j}^i$ не рассматривается, если для всех $l = \overline{1, k}$ имеем $(y_1^r - y_1^{r+1}) > \epsilon$, где $\epsilon = \epsilon' \cdot s$; $r = \overline{1, N}$;

$$s = \sqrt{\frac{1}{N \cdot k} \sum_{i=1}^N \sum_{j=1}^k (y_j^i - \bar{y}_j)^2}; \quad \bar{y}_j = \frac{1}{k} \sum_{i=1}^k \bar{y}_j^i; \quad \epsilon' \in [0, 1],$$

ϵ' - входной параметр, близкий к нулю.

Предположим, что построено дерево с M конечными вершинами, $m = \overline{2, M}$. Этому этапу соответствует некоторое разбиение пространства переменных $\alpha = \{E^1, \dots, E^t, \dots, E^M\}$. Далее для каждого подмножества E^t ищется свое, лучшее в смысле критерия $\Delta \bar{F}^t$ высказывание J_t . Множество E^t разбивается на два подмножества E^{t_1} и E^{t_2} , $E^{t_1} \cup E^{t_2} = E^t$.

Критерием оценки качества вершины b^t дерева решений является величина:

$$\begin{aligned} \Delta \bar{F}^t &= \bar{F}(m) - \bar{F}(m+1) = \\ &= \frac{1}{N} \left[\sum_{(x^i, z^i) \in E^t} \sum_{j=1}^k \lambda_j (y_j^i - \bar{y}_{jt})^2 - \right. \\ &\quad - \sum_{(x^i, z^i) \in E^{t_1}} \sum_{j=1}^k \lambda_j (y_j^i - \bar{y}_{jt_1})^2 - \\ &\quad \left. - \sum_{(x^i, z^i) \in E^{t_2}} \sum_{j=1}^k \lambda_j (y_j^i - \bar{y}_{jt_2})^2 \right] / \bar{F}_{\bar{F}}(1), \end{aligned}$$

где

$$\bar{y}_{jt_1} = \frac{1}{N_{t_1}} \sum_{(x^i, z^i) \in E^{t_1}} y_j^i,$$

$$\bar{y}_{jt_2} = \frac{1}{N_{t_2}} \sum_{(x^i, z^i) \in E^{t_2}} y_j^i,$$

N_{t_1} , N_{t_2} - число точек (x^i, z^i) , принадлежащих соответственно подмножествам E^{t_1} , E^{t_2} .

Находим

$$\Delta \bar{F}^t = \max_{t=1, \dots, m} \Delta \bar{F}^t.$$

Дальнейшее ветвление дерева проводим из вершины b^{t^*} и получаем дерево с $(m+1)$ конечной вершиной. Этому этапу соответствует некоторое разбиение пространства переменных $\alpha = \{E^1, \dots, E^{t^*-1}, E^{t^*1}, E^{t^*2}, E^{t^*+1}, \dots, E^m\}$.

Число конечных вершин m увеличиваем до тех пор, пока не выполнится одно из трех условий:

1. $\bar{F}(m) \leq \delta$ (δ - некоторый входной параметр, близкий к 0, $\delta \in [0, 1]$).

2. Число конечных вершин m не превысит некоторое число M (M - входной параметр).

3. Все вершины b^t делению не подлежат. Вершина b^t не подлежит делению, если не существует ни одного разбиения множества E^t на два подмножества E^{t1} и E^{t2} таких, что $N_{t1} > \mu$ и $N_{t2} > \mu$, где μ - минимально допустимое число наблюдений в конечной вершине (μ - входной параметр).

Конечной вершине b^t , $t = \overline{1, M}$, дерева решений ставится в соответствие следующий набор решений:

1) вектор средних $(\bar{y}_{1t}, \dots, \bar{y}_{jt}, \dots, \bar{y}_{kt})$, где

$$\bar{y}_{jt} = \frac{\sum_{(x^i, z^i) \in E^t} y_j^i / N_t}{N_t};$$

2) вектор оценок стандартных уклонений $(s_{1t}, \dots, s_{jt}, \dots, s_{kt})$, где

$$s_{jt} = \frac{1}{N_t} \sum_{(x^i, z^i) \in E^t} (y_j^i - \bar{y}_{jt})^2;$$

3) вектор наибольших значений $(\hat{y}_{1t}, \dots, \hat{y}_{jt}, \dots, \hat{y}_{kt})$,
 где

$$\hat{y}_{jt} = \max_{(x^i, z^i) \in E^t} y_j^i ;$$

4) вектор наименьших значений $(\check{y}_{1t}, \dots, \check{y}_{jt}, \dots, \check{y}_{kt})$,
 где

$$\check{y}_{jt} = \min_{(x^i, z^i) \in E^t} y_j^i .$$

Необходимо отметить, что для формирования векторов решений используются первоначальные ненормированные значения откликов y_j^i .

Пусть решающее правило построено. Для прогноза значений y_1, \dots, y_k наблюдения a в предикаты, находящиеся в узлах дерева, подставляются конкретные значения признаков, и достигается некоторая конечная вершина b^t , которой соответствует вектор средних $(\bar{y}_{1t}, \dots, \bar{y}_{kt})$. Компоненты этого вектора и являются прогнозируемыми значениями y_1, \dots, y_k для рассматриваемого наблюдения a .

Заметим, что если в таблице V для некоторого наблюдения a отсутствует значение признака X_j или Z_j , то при выборе предиката $J(a, E_j)$ это наблюдение не рассматривается. Если же для прогнозируемого наблюдения a пропущено значение признака X_j или Z_j , то при определении вершины b^t рассматривается среднее значение для этого признака.

В заключение отметим, что алгоритм реализован на языке FORTRAN для машин типа ЕС. Работа алгоритма продемонстрирована на тестовом примере (см. приложение 1). В приложении 1 описаны обучающая выборка V и прогнозируемая выборка. В таблицах име-

ются пропуски (пропуск выделен чертой). В приложении 2 описаны результаты работы программы.

Л и т е р а т у р а

1. ДРЕЙПЕР Н., СМИТ Г. Прикладной регрессионный анализ: Пер. с англ. /Под ред. Ю.П.Адлера и В.Г.Горского. - М.: Финансы и статистика, 1986. Т.2.

2. LBOV G.S. The logical decision rules for automatic discovery of Knowledge in expert system data base //Int. J. of pattern recognition and artificial intelligence. - Singapore, New Jersey, Hong Kong, 1989. - Vol. 3, N 1.

3. ЛБОВ Г.С., СТАРЦЕВА Н.Г. Алгоритм многоклассового распознавания, основанный на логических решающих функциях. - Новосибирск.-1985. - Вып. 111: Вычислительные системы. - С. 3-10.

Поступила в ред.-изд.отд.

24 января 1989 года

Контрольный пример

Обучающая выборка					
№ объекта	П р и з н а к и				
	X ₁	X ₂	Z ₁	Y ₁	Y ₂
1	10	0.8	1	1	0.1
2	11	0.5	2	2	0.2
3	12	0.7	4	1	0.1
4	16	0.1	5	2	0.3
5	10	0.4	1	1	0.2
6	12	0.6	2	3	0.15
7	13	0.5	4	1	0.25
8	-	0.6	3	4	0.17
9	14	0.7	1	1	0.19
10	15	0.2	6	3	0.4
11	20	0.9	5	2	0.4
12	8	0.1	1	6	0.4
13	9	0.2	1	5	0.2
14	7	0.3	1	6	0.4
15	9	0.1	2	5	0.3
16	8	0.2	3	3	0.6
17	5	0.3	2	6	0.1
18	4	0.1	3	3	0.7
19	6	0.2	4	7	0.6
Прогнозируемая выборка					
1	10	0.7	1		
2	12	0.6	2		
3	8	0.3	2		
4	7	0.2	3		
5	-	0.2	4		
6	15	0.4	6		

Номер вершины $NF(K5, 3)=1$

$S(1, 1)=3,26315$	$D(1, 1)=1,96929$	$SMOL(1, 1)=1,0$	$BIG(1, 1)=7,0$
$S(1, 2)=0,30316$	$D(1, 2)=0,17529$	$SMOL(1, 2)=0,1$	$BIG(1, 2)=0,7$
$F(1, 1)=18,31398$	$F(1, 2)=0,51805$		

Номер вершины $NF(K5, 3)=2$

$S(2, 1)=5,12499$	$D(2, 1)=1,36359$	$SMOL(2, 1)=3,0$	$BIG(2, 1)=7,0$
$S(2, 2)=0,41250$	$D(2, 2)=0,19645$	$SMOL(2, 2)=0,1$	$BIG(2, 2)=0,7$
$F(2, 1)=2,28345$	$F(2, 2)=0,39284$		

Номер вершины $NF(K5, 3)=3$

$S(3, 1)=1,70000$	$D(3, 1)=0,78102$	$SMOL(3, 1)=1,0$	$BIG(3, 1)=3,0$
$S(3, 2)=0,22900$	$D(3, 2)=0,10329$	$SMOL(3, 2)=0,1$	$BIG(3, 2)=0,4$
$F(3, 1)=2,47449$	$F(3, 2)=0,45293$		

Номер вершины $NF(K5, 3)=6$

$S(4, 1)=1,00000$	$D(4, 1)=0,0$	$SMOL(4, 1)=1,0$	$BIG(4, 1)=1,0$
$S(4, 2)=0,16800$	$D(4, 2)=0,05913$	$SMOL(4, 2)=0,1$	$BIG(4, 2)=0,25$
$F(4, 1)=0,0$	$F(4, 2)=0,0$		

Номер вершины $NF(K5, 3)=7$

$S(5, 1)=2,40000$	$D(5, 1)=0,48990$	$SMOL(5, 1)=2,0$	$BIG(5, 1)=3,0$
$S(5, 2)=0,29000$	$D(5, 2)=0,10198$	$SMOL(5, 2)=0,15$	$BIG(5, 2)=0,4$
$F(5, 1)=0,0$	$F(5, 2)=0,0$		

Номер вершины $NF(K5, 3)=4$

$S(6, 1)=5,50000$	$D(6, 1)=1,5$	$SMOL(6, 1)=3,0$	$BIG(6, 1)=7,0$
$S(6, 2)=0,50000$	$D(6, 2)=0,1$	$SMOL(6, 2)=0,4$	$BIG(6, 2)=0,6$
$F(6, 1)=0,0$	$F(6, 2)=0,0$		

Номер вершины $NF(K5, 3)=5$

$S(7, 1)=4,75000$	$D(7, 1)=1,08972$	$SMOL(7, 1)=6,0$	$BIG(7, 1)=6,0$
$S(7, 2)=0,32500$	$D(7, 2)=0,22776$	$SMOL(7, 2)=0,1$	$BIG(7, 2)=0,7$
$F(7, 1)=0,0$	$F(7, 2)=0,0$		

Пояснения к таблице:

$S(K5, J)$ - среднее значение J -го признака в вершине $NF(K5, 3)$

$D(K5, J)$ - стандартное отклонение J -го признака в вершине $NF(K5, 3)$

$SMOL(K5, J)$ - наименьшее значение J -го признака в вершине $NF(K5, 3)$

$BIG(K5, J)$ - наибольшее значение J -го признака в вершине $NF(K5, 3)$

$F(K5, 1)$ - значение критерия вершины $NF(5, 3)$

$F(K5, 2)$ - значение критерия дерева на шаге $K5$

$J = 1, K; K5 = 1, KWT$

Результаты прогноза

Количество объектов на контроле $M1 = 6$

Объект номер 1 = 1 попал в вершину 6

$SY(1,1)=1,00000$ $DY(1,1)=0,0$ $BIGY(1,1)=1,0000$ $SMOLY(1,1)=1,0000$
 $SY(1,2)=0,16800$ $DY(1,2)=0,05913$ $BIGY(1,2)=0,25$ $SMOLY(1,2)=0,1000$

Объект номер 1 = 2 попал в вершину 7

$SY(2,1)=2,40000$ $DY(2,1)=0,48990$ $BIGY(2,1)=3,0000$ $SMOLY(2,1)=2,0000$
 $SY(2,2)=2,9000$ $DY(2,2)=0,10198$ $BIGY(2,2)=0,4000$ $SMOLY(2,2)=0,1500$

Объект номер 1 = 3 попал в вершину 4

$SY(3,1)=5,50000$ $DY(3,1)=1,50000$ $BIGY(3,1)=7,0000$ $SMOLY(3,1)=3,0000$
 $SY(3,2)=0,50000$ $DY(3,2)=0,10000$ $BIGY(3,2)=6,000$ $SMOLY(3,2)=0,4000$

Объект номер 1 = 4 попал в вершину 4

$SY(4,1)=5,50000$ $DY(4,1)=1,50000$ $BIGY(4,1)=7,0000$ $SMOLY(4,1)=3,0000$
 $SY(4,2)=0,50000$ $DY(4,2)=0,10000$ $BIGY(4,2)=0,6000$ $SMOLY(4,2)=0,4000$

Объект номер 1 = 5 попал в вершину 6

$SY(5,1)=1,00000$ $DY(5,1)=0,0$ $BIGY(5,1)=1,0000$ $SMOLY(5,1)=1,0000$
 $SY(5,2)=0,16800$ $DY(5,2)=0,05913$ $BIGY(5,2)=0,2500$ $SMOLY(5,2)=0,1000$

Объект номер 1 = 6 попал в вершину 7

$SY(6,1)=2,40000$ $DY(6,1)=0,48990$ $BIGY(6,1)=3,0000$ $SMOLY(6,1)=2,0000$
 $SY(6,2)=0,29000$ $DY(6,2)=0,10198$ $BIGY(6,2)=0,4000$ $SMOLY(6,2)=0,1500$

Пояснения к таблице:

$SY(I,K1)$ - среднее значение для I-го объекта $K1$ компоненты
 $DY(I,K1)$ - стандартное отклонение для I-го объекта $K1$ компоненты
 $BIGY(I,K1)$ - наибольшее значение для I-го объекта $K1$ компоненты
 $SMOLY(I,K1)$ - наименьшее значение для I-го объекта $K1$ компоненты
 $I = 1, M1$ $K1 = 1, K$

Исходные данные

Количество объектов $M = 19$
 Количество признаков факторов $N = 3$
 Количество признаков откликов $K = 2$
 Параметр $KJET = 3$, $DEL = 0,005$, $EPS = 0,17569$
 Количество ветвей $KWT = 7$
 Конечное значение критерия $ED = 0,39284$
 Код пропуска $B = 99,9$

Решающее правило

K5	NF(K5, 3)	NF(K5, 1)	NF(K5, 2)	NJF(1, K5)	NJF(2, K5)	APF(1, K5)	APF(2, K5)	NF(K5, 4)	NF(K5, 5)
1	1	2	3	1	1	-99999,0	9,5	1	19
2	2	4	5	1	1	5,5	8,5	1	8
3	3	6	7	0	3	1,0	4,0	1	10
4	6	0	0	0	0	0,0	0,0	2	5
5	7	0	0	0	0	0,0	0,0	2	5
6	4	0	0	0	0	0,0	0,0	2	4
7	5	0	0	0	0	0,0	0,0	2	4

Пояснения к таблице:

K5 - номер;
NF(K5, 3) - номер вершины исходной;
NF(K5, 1) - номер вершины, в которую надо идти, если высказывание - истина;
NF(K5, 2) - если ложно;
NJF(1, K5) - индекс высказывания;
NJF(2, K5) - номер признака, по которому строится высказывание;
APF(J, K5) - $J = 1, 2$ - пороги;
NF(K5, 4) - указывает конечность вершины;
NF(K5, 5) - указывает число объектов в вершине.