

ОБ ЭКВИВАЛЕНТНОСТИ И УСТОЙЧИВОСТИ ДЛЯ ЭВРИСТИЧЕСКИХ  
АЛГОРИТМОВ РАСПОЗНАВАНИЯ И ИХ ПРИМЕНЕНИЯ

ХОАНГ КИЕМ и ХО ТУ БАО

Институт Информатики и Кибернетики

Ханой - СРВ

В данной работе исследованы вопросы эквивалентности и устойчивости алгоритмов распознавания, приводятся результаты решения нескольких задач в геологии.

В последнее время теория распознавания образов находит широкое применение во многих областях народного хозяйства. Часто при решении конкретных задач перед математиками-прикладниками возникают интересные вопросы, от ответов на которые зависит эффективность применяемого метода. При решении нескольких задач в геологическом исследовании в СРВ нам пришлось решать вопросы эквивалентности и устойчивости распознающих алгоритмов. В этой работе даётся попытка решения этих вопросов.

Сначала приводим краткое описание некоторых классов распознающих алгоритмов.

§ 1. ОПИСАНИЕ АЛГОРИТМОВ РАСПОЗНАВАНИЯ

Пусть задано множество допустимых объектов  $\{S\}$ . Множество  $\{S\}$  покрыто конечным числом подмножеств  $K_1, \dots, K_\ell$ , называемых классами,  $\{S\} = \bigcup_{j=1}^{\ell} K_j$ . Каждый объект  $S$  представляется набором из  $n$  значений признаков  $I(S) = (a_1(S), \dots, a_n(S))$

Далее задаётся некоторая начальная информация  $I_0$  о классах.

Тогда основная задача распознавания  $Z$  состоит в следующем: для

каждого объекта выделенного подмножества  $\tilde{S}^q \subseteq \{S\}$  установить, используя информацию  $I_0$ , к какому из классов  $K_1, \dots, K_\ell$  принадлежит этот объект.

Введем набор предикатов  $P_j(S) = "S \in K_j"$ ,  $j=1, \dots, \ell$ . Набор  $\alpha(S) = (P_1(S), \dots, P_\ell(S))$  называется информационным вектором объекта  $S$ . Таким образом, результат решения задачи  $Z$  может быть представлен в виде информационной матрицы  $\|P_j(S^i)\|_{q \times \ell}$ ,  $K_1, \dots, K_\ell$  - классы,  $\tilde{S}^q = \{S^1, \dots, S^q\}$ . Если кодировать, например символом  $\Delta$ , отказ от вычисления  $P_j(S^i)$ , то можно считать, что алгоритм  $A$  решения задачи  $Z$  вычислит матрицу

$\|\beta_{ij}\|_{q \times \ell}$ . Если  $\beta_{ij} \in \{0, 1\}$ , то  $\beta_{ij}$  - значение  $P_j(S^i)$ , вычисленное алгоритмом  $A$ . При  $\beta_{ij} = \Delta$  алгоритм отказался от вычисления  $P_j(S^i)$ .

Известно, что каждый алгоритм распознавания  $A$  может быть представлен через последовательное выполнение алгоритмов  $B$  и  $C$ ,  $A = B \cdot C$ , причём если  $A(z) = \|\beta_{ij}\|_{q \times \ell}$ , то  $B(z) = \|b_{ij}\|_{q \times \ell}$ ,  $b_{ij}$  - действительные числа,  $C(\|b_{ij}\|_{q \times \ell}) = \|\beta_{ij}\|_{q \times \ell}$ . Подалгоритм  $C$  называется в дальнейшем решающим правилом и подалгоритм  $B$  - распознающим оператором, который переводит начальную информацию  $I_0$  и описания распознаваемых объектов  $I(S^1), \dots, I(S^q)$  в числовую матрицу  $\|b_{ij}\|_{q \times \ell}$ , где  $b_{ij}$  есть значение функции принадлежности  $S^i$  классу  $K_j$ ,  $i=1, \dots, q$ ;  $j=1, \dots, \ell$  [1]

Чтобы вычислить матрицу  $\|b_{ij}\|_{q \times \ell}$ , почти все алгоритмы распознавания требуют вычисления гипер-матрицы

$$HB(Z) = \|hb_{ij}\|_{q \times \ell}, \quad hb_{ij} = \{b_{ij}^k\}_{k=1}^{N_j}, \quad \begin{matrix} N_j = \text{card}(K_j) \\ \tilde{K}_j = K_j \cap \tilde{S}^m \end{matrix}$$

$b_{ij}^k$  - вещественные или комплексные числа.

После определения трансформации  $F: HB \rightarrow B$ , имеем

$$F \|hb_{ij}\|_{q \times \ell} = \|F[hb_{ij}]\|_{q \times \ell} = \|b_{ij}\|_{q \times \ell}$$

Обычно рассматриваются трансформации, имеющие следующие виды:

$F[hb_{ij}] = M[hb_{ij}]$  - среднее или математическое ожидание множества  $hb_{ij} = \{\rho(S^i, S_j^k)\}_{k=1}^{N_j}$

Алгоритмы, определяющие через  $F[hb_{ij}] = M[hb_{ij}]$ , называются М-алгоритмами распознавания /М-алг/

$F[hb_{ij}] = \text{extr}[hb_{ij}]$  - верхнее значение множества  $hb_{ij}$

Алгоритмы, определяющие через  $F[hb_{ij}] = \text{extr}[hb_{ij}]$ , называются  $\text{extr}$ -алгоритмами распознавания / $\text{extr}$ -алг/.

В дальнейшем, покажем, что почти все алгоритмы распознавания являются или М-алгоритмами или  $\text{extr}$ -алгоритмами.

(а) Алгоритмы вычисления оценок [1]

Напоминаем основные этапы определения этих алгоритмов:

- (1) Указание системы опорных множеств  $\Omega_A$
- (2) Определение функции близости  $B_{\tilde{\omega}}(S, S^i)$
- (3) Вычисление оценки  $\Gamma_{\tilde{\omega}}(S, S^i)$  объекта  $S$  по объекту  $S^i$  и опорному множеству  $\Omega$

$$\Gamma_{\tilde{\omega}}(S, S^i) = f(B_{\tilde{\omega}}(S, S^i), \gamma(S_i), \tilde{p}(\tilde{\omega}))$$

- (4) Вычисление оценки  $\Gamma_{\tilde{\omega}}^j(S)$  объекта  $S$  по опорному множеству  $\Omega$  по классу  $K_j$

$$\Gamma_{\tilde{\omega}}^j(S) = \varphi(\Gamma_{\tilde{\omega}}(S, S_1^j), \dots, \Gamma_{\tilde{\omega}}(S, S_{N_j}^j))$$

(5) Вычисление оценки  $\Gamma_j(S)$  по классу  $K_j$

$$\Gamma_j(S) = \frac{1}{\text{card}(\Omega_A)} \sum_{\tilde{\omega} \leftrightarrow \Omega \in \Omega_A} \frac{1}{\text{card}(\tilde{K}_j)} \sum_{S^i \in \tilde{K}_j} \Gamma_{\tilde{\omega}}(S, S^i).$$

(6) Решающие правила в алгоритмах вычисления оценок

Отметим, что эти алгоритмы являются М-алгоритмами распознавания.

(6) Алгоритмы типа потенциальных функций [2]. Потенциальные функции обычно имеют виды:

$$\varphi(S, S') = e^{-\alpha \rho(S, S')}$$

или

$$\varphi(S, S') = \frac{c_1}{c_2 + c_3 \rho(S, S')}$$

где  $\alpha, c_1, c_2, c_3$  - константы,  $\rho$  - расстояние между  $S$  и  $S'$ . Это монотонные функции по  $\rho$ . Потенциал между объектом  $S$  и классом  $K_j$  определяется

$$\varphi(S, K_j) = \frac{1}{\text{card}(\tilde{K}_j)} \sum_{S^i \in \tilde{K}_j} \varphi(S, S^i)$$

В этом случае, имеем  $hb_{ij} = \{\varphi(S^i, S_j^k)\}_{k=1}^{\text{card}(\tilde{K}_j)}$ ,  $b_{ij} = \varphi(S, K_j)$

Определение алгоритмов в этой модели состоит из двух этапов:

а/ Вычислить потенциальную матрицу  $\|b_{ij}\|_{q \times \ell}$ ,  $b_{ij}$  - потенциал между объектом  $S^i \in S^q$  и классом  $K_j$ .

б/ Решающее правило: Объект  $S$  относится к классу  $K_\omega$  если

$$\bar{\varphi}(S, K_{\omega}) = \max_j \varphi(S, K_j)$$

Очевидно, что алгоритмы типа потенциальных функций являются  $M_{f(\rho)}$  - алгоритмами.

(в) Алгоритмы, основанные на принципе ближайшего соседа

/БС-алг/ широко используются для решения задач распознавания образов. Элемент  $b_{ij}$  матрицы  $\|b_{ij}\|_{q \times \ell}$  определяется расстоянием между  $S^i \in \tilde{S}^q$  и его ближайшим соседом в  $\tilde{K}_j$ .

Это значит

$$b_{ij} = \min_{S_{\omega}^k \in \tilde{K}_j} \rho(S^i, S_{\omega}^k)$$

и также имеем

$$hb_{ij} = \{\rho(S^i, S_j^k)\}_{k=1}^{\text{card}(\tilde{K}_j)}$$

Итак, алгоритм ближайшего соседа определяет принадлежность  $S^i$  к классу  $K_{\omega}$ , если  $b_{iu} = \min_j b_{ij}$

Ясно, что это extr-алгоритм.

(г) Алгоритмы распознавания с параметрами [1].

На практике используются некоторые модели алгоритмов распознавания образов с параметрами. Параметры  $\alpha_1, \alpha_2, \dots, \alpha_n$  - весами признаков. Параметры  $\beta_1, \dots, \beta_{\ell}$  - весами классов. Параметры  $\gamma_1^1, \gamma_1^2, \dots, \gamma_1^{N_1}, \dots, \gamma_{\ell}^1, \dots, \gamma_{\ell}^{N_{\ell}}$  - весами объектов. В дальнейшем, обозначим, например, М-алг с параметрами признаков  $\alpha_1, \dots, \alpha_n$  через  $M^{\alpha}$ -алг, М-алг с параметрами  $\alpha, \beta, \gamma$  через  $M^{\alpha, \beta, \gamma}$ -алг, и т.д.

§ 2. ЭКВИВАЛЕНТНОСТЬ ЭВРИСТИЧЕСКИХ АЛГОРИТМОВ РАСПОЗНАВАНИЯ

Алгоритмы распознавания А и В называются эквивалентными если

$$\forall i, j : C_{ij}^A = C_{ij}^B$$

где  $\|C_{ij}^A\|$  и  $\|C_{ij}^B\|$  являются информационными матрицами для А и В. Эквивалентные алгоритмы А и В обозначим  $A \sim B$ .

Алгоритм распознавания А и В называются эквивалентными по вероятности, если

$$\forall i, j : \lim_{\text{card}(\tilde{S}^m) \rightarrow \infty} P(C_{ij}^A = C_{ij}^B) \approx 1$$

Эквивалентные алгоритмы по вероятности А и В обозначим  $A \overset{\text{prob}}{\sim} B$ .

Будем рассматривать эквивалентность /Эквивалентность по вероятности/ для некоторых эвристических алгоритмов распознавания:

- $M_\rho$  - алгоритмы распознавания:  $b_{ij} = M[hb_{ij}]$
- $M_{f(\rho)}$  - алгоритмы распознавания:  $b_{ij} = M[f(hb_{ij})]$
- extr - алгоритмы распознавания:  $b_{ij} = \text{extr } hb_{ij}$
- extr f(ρ)- алгоритмы распознавания:  $b_{ij} = \text{extr } f(hb_{ij})$

где

$$f(hb_{ij}) = \{f(b_{ij}^1), \dots, f(b_{ij}^{N_j})\}$$

ТЕОРЕМА 1. Если функция монотонна по  $\rho$ , то

$$\text{extr } \rho \sim \text{extr } f(\rho) \text{ -алг}$$

Доказательство. Заметим, что  $\text{extr } f(\rho) = f(\text{extr } \rho)$ , если f является монотонной по  $\rho$ . Тогда сразу имеем

$$\text{extr } \rho \sim \text{extr } f(\rho) \text{ - алг}$$

**ТЕОРЕМА 2.** Пусть распределение  $\rho(\dot{S}, S_k), S_k \in K_j$  является нормальным  $(m_j, \sigma)$  или экспоненциальным  $(\lambda)$ , тогда

$M_\rho$  - алгоритм  $\overset{\text{prob}}{\sim}$   $\text{extr } \rho$  - алгоритм

**Доказательство.** Это доказательство проводится на основе следующего утверждения [6].

Обозначим через  $E_n(x_k), D_n(x_k)$  - математическое ожидание и дисперсию  $k$ -ого верхнего значения эталона из  $n$  элементов с нормальным распределением  $(m, \sigma)$ . Тогда

$$E_n(x_k) = m - \sigma(\sqrt{2 \ln n} - \frac{\ln \ln n + \ln 4\pi + 2[S_1(k) - c]}{2\sqrt{2 \ln n}} + o(\frac{1}{\ln n}))$$

$$D_n^2(x_k) = \frac{\sigma^2}{2 \ln n} \left[ \frac{\pi^2}{6} - S_2(k) \right] + o\left(\frac{1}{\ln^2 n}\right)$$

где  $S_1(k) = \sum_{i=1}^{n-k+1} \frac{1}{i}$ ,  $S_2(k) = \sum_{i=1}^{n-k+1} \frac{1}{i^2}$ ,  $c$  - постоянная Эйлера. Для

экспоненциального распределения  $(\lambda)$ , имеем

$$E_n(x_k) = m \sum_{i=n-k+1}^n \frac{1}{i}, \quad D_n^2(x_k) = m^2 \sum_{i=n-k+1}^n \frac{1}{i^2}, \quad m = \frac{1}{\lambda}$$

Так как решающее правило основывается на  $\text{extr}_j \{b_{ij}\}$ , то для доказательства теоремы достаточно доказать, что

$$E_n[\bar{x}(u)] = \text{extr}_j E_n[\bar{x}(j)] \stackrel{n \rightarrow \infty}{\Leftrightarrow} E_n[x_k(u)] = \text{extr}_j E_n[x_k(j)], \quad j=1, \dots, \ell$$

где  $E_n[\bar{x}(j)]$  и  $E_n[x_k(j)]$  обозначают математическое ожи-

дание k-ого верхнего значения j-ого эталона из n элементов.

Для простоты и не теряя общности, можем предполагать, что

$\text{extr} = \min$  и докажем в этом случае

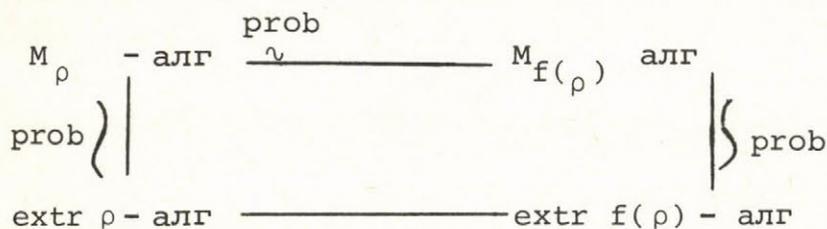
$$E_n[\bar{x}(u)] = \min_j E_n[\bar{x}(j)] \stackrel{n \rightarrow \infty}{\Leftrightarrow} E_n[x_k(u)] = \min_j E_n[x_k(j)]$$

Это эквивалентно

$$\forall j, j', = 1, \dots, l: m_j \leq m_{j'}, \stackrel{n \rightarrow \infty}{\Leftrightarrow} E_n[x_k(j)] \leq E_n[x_k(j')]$$

Тогда теорема доказана в силу вышеуказанного утверждения.

ТЕОРЕМА 3. Если функция  $f$  монотонна по  $\rho$  и распределение  $\rho$  является нормальным  $(m_j, \sigma)$  или экспоненциальным  $(\lambda)$ , то справедлива следующая схема



Доказательство. Из доказанных теорем, имеем

$$\begin{array}{ccc}
 M_\rho & \text{ - алг } & \overset{\text{prob}}{\sim} \text{extr } \rho \text{ - алг} \\
 & & \sim \\
 \text{extr } \rho \text{ - алг} & & \text{extr } f(\rho) \text{ - алг}
 \end{array}$$

Сразу вытекает

$$M_{f(\rho)} \text{ - алг } \overset{\text{prob}}{\sim} \text{extr } f(\rho) \text{ - алг}$$

Наконец, учитывая, что

$$M_\rho \text{ - алг } \overset{\text{prob}}{\sim} \text{extr } \rho \text{ - алг} \sim \text{extr } (\rho) \text{ - алг } \overset{\text{prob}}{\sim} M_{f(\rho)} \text{ - алг}$$

Тогда

$$M_\rho \text{ - алг } \overset{\text{prob}}{\sim} M_{f(\rho)} \text{ - алг}$$

Доказана теорема.

Рассмотрим некоторый результат об эквивалентности  $M_{\rho}^{\gamma}$ -алгоритма с  $M_{\rho}$ -алгоритмом.

Расстояние  $\rho_k = \rho(S, S^k), S^k \in K_j$  - случайная величина  $\rho$

Вес объектов класса  $K_j: \gamma^1, \dots, \gamma^{N_j}$  - случайная величина  $\gamma$

$\bar{\rho}$  - арифметическое среднее расстояний между  $S$  и  $\tilde{K}_j$

$$\bar{\rho} = \frac{1}{N_j} \sum_{k=1}^{N_j} \rho_k$$

$\bar{\rho}_{\gamma}$  - арифметическое среднее расстояний с весами объектов между  $S$  и  $\tilde{K}_j$

$$\bar{\rho}_{\gamma} = \frac{\sum_{k=1}^{N_j} \rho_k \gamma_k}{\sum_{k=1}^{N_j} \gamma_k}$$

$M(\bar{\rho}_{\gamma})$  - действительное среднее расстояний с весами объектов между  $S$  и  $K_j$

$$M(\bar{\rho}_{\gamma}) = \lim_{N_j \rightarrow \infty} \bar{\rho}_{\gamma}$$

$\hat{\sigma}_{\rho}^2, (\hat{\sigma}_{\rho\gamma}^2)$  - экспериментальная дисперсия случайной величины  $\rho$  /с арифметическим средним с весами/

$$\hat{\sigma}_{\rho}^2 = \frac{\sum_{k=1}^{N_j} (\rho_k - \bar{\rho})^2}{N_j - 1}, \quad \hat{\sigma}_{\rho\gamma}^2 = \frac{\sum_{k=1}^{N_j} (\rho_k - \bar{\rho}_{\gamma})^2}{N_j - 1}$$

$\hat{V} = \frac{\hat{\sigma}_{\rho}}{\rho}, \hat{V}_{\gamma} = \frac{\hat{\sigma}_{\gamma}}{\gamma}$  - трансформированные коэффициенты случайных

величин  $\rho$  и  $\gamma$

$$\hat{r}_{\rho\gamma} = \frac{\sum_{k=1}^{N_j} (\rho_k - \bar{\rho})(\gamma_k - \bar{\gamma})}{N_j \bar{\rho} \bar{\gamma}}$$

- экспериментальный коэффициент корреляции между  $\rho$  и  $\gamma$

Тогда имеем:

ТЕОРЕМА 4. Если  $\rho$  и  $\gamma$  статистически независимы, то

$$M_{\rho}^{\gamma} - \text{алг} \stackrel{\text{prob}}{\sim} M_{\rho} - \text{алг}$$

Доказательство. Будем доказывать, что

$$\bar{\rho}_{\gamma} = \bar{\rho} (1 + \hat{r}_{\rho\gamma} \hat{V}_{\rho} \hat{V}_{\gamma})$$

Имеем

$$\begin{aligned} \bar{\rho} (1 + \hat{r}_{\rho\gamma} \hat{V}_{\rho} \hat{V}_{\gamma}) &= \bar{\rho} \left( 1 + \frac{\sum_{k=1}^{N_j} (\rho_k - \bar{\rho})(\gamma_k - \bar{\rho})}{N_j \hat{\sigma}_{\rho} \hat{\sigma}_{\gamma}} \cdot \frac{\hat{\sigma}}{\bar{\rho}} \cdot \frac{\hat{\sigma}_{\gamma}}{\bar{\gamma}} \right) \\ &= \bar{\rho} \left( 1 + \frac{\sum_{k=1}^{N_j} (\rho_k - \bar{\rho})(\gamma_k - \bar{\gamma})}{N_j \cdot \bar{\rho} \cdot \bar{\gamma}} \right) = \bar{\rho} \left( 1 + \frac{\sum_{k=1}^{N_j} \rho_k \gamma_k - N_j \bar{\rho} \bar{\gamma}}{N_j \cdot \bar{\rho} \cdot \bar{\gamma}} \right) \\ &= \bar{\rho} \left( 1 + \frac{\sum_{k=1}^{N_j} \rho_k \gamma_k}{N_j \bar{\rho} \bar{\gamma}} - 1 \right) = \frac{\sum_{k=1}^{N_j} \rho_k \gamma_k}{N_j \bar{\gamma}} = \frac{\sum_{k=1}^{N_j} \rho_k \gamma_k}{\sum_{k=1}^{N_j} \gamma_k} = \bar{\rho}_{\gamma} \end{aligned}$$

Так как  $\lim_{N_j \rightarrow \infty} \bar{\rho}_{\gamma} = M(\bar{\rho}_{\gamma})$ ,  $\lim_{N_j \rightarrow \infty} \bar{\rho} = M(\bar{\rho})$  - математическое ожидание случайной величины  $\rho$ ,

$$\lim_{N_j \rightarrow \infty} \hat{r}_{\rho\gamma} = r_{\rho\gamma}; \quad \lim_{N_j \rightarrow \infty} \hat{V} = V$$

То когда  $N_j$  стремится к бесконечности, справедливо

$$M(\bar{\rho}_{\gamma}) = M(\bar{\rho}) [1 + r_{\rho\gamma} V_{\rho} V_{\gamma}]$$

Ясно, что если  $r_{\rho\gamma} = 0$ , то

$$M(\bar{\rho}_{\gamma}) = M(\bar{\rho})$$

Теорема доказана.

### § 3. УСТОЙЧИВОСТЬ И НОРМИРОВАНИЕ ЭВРИСТИЧЕСКИХ АЛГОРИТМОВ РАСПОЗНАВАНИЯ

Дисперсия алгоритма распознавания  $A$  определяется следующим образом:

$$D(A) = D(\|b_{ij}\|_{m \times l}) = \sum_{i,j} D(b_{ij}), \quad D(b_{ij}) = D\{\rho(S', (K_j \setminus S') \cup S^i)\}$$

ТЕОРЕМА 5. Сохранив все условия теоремы 3, имеется

$$D(\text{BC-алг}) = \min D(\text{extr } \rho\text{-алг})$$

Доказательство. Известно, что BC-алг является  $\min \rho$ -алг. Тогда достаточно доказать

$$\forall i, j \quad D(b_{ij}^{\min \rho}) = \min D(b_{ij}^{\text{extr } \rho})$$

где

$$b_{ij}^{\min \rho} = \min_k \{b_{ij}^k\}, \quad b_{ij}^{\text{extr } \rho} = \text{extr}_r \{b_{ij}^k\}$$

Из указанного утверждения теоремы 3, следует

$$D_n^2(b_{ij}^{\text{extr } \rho}) = \frac{\sigma^2}{2 \ln n} \left[ \frac{\pi^2}{6} - S_2(k) \right] + o\left(\frac{1}{\ln^2 n}\right)$$

для случая нормального распределения и

$$D_n^2(b_{ij}^{\text{extr } \rho}) = m^2 \sum_{i=n-k+1}^n \frac{1}{i^2}$$

для случая экспоненциального распределения. В обоих случаях  $D_n(b_{ij}^{\text{extr } \rho})$  достигаются максимум при  $k=1$ , т.е

$$D_n(b_{ij}^{\min \rho}) = \min D_n(b_{ij}^{\text{extr } \rho})$$

СЛЕДСТВИЕ. Если распределение  $\{\rho(S, S^k); S^k \in K_j\}$  является нормальным, то выполняется

$$D(\text{BC-алг}) \leq D(\text{M-алг})$$

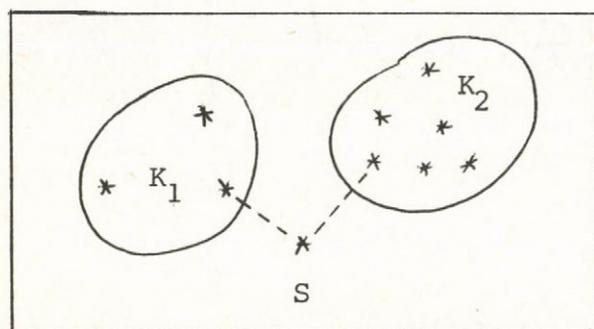
Это неравенство вытекает из

$M_\rho$  -алгоритм = медиана  $\rho$ -алгоритм  $\in$  {extr  $\rho$ -алгоритм}

Будем определять устойчивость распознающих алгоритмов через его дисперсию. Чем меньше его дисперсия, тем больше его устойчивость. В условиях теоремы 3 и из следствия теоремы 5 следует, что БС-алгоритм имеет наибольшую устойчивость. Эти результаты используются при проектировании комбинированной системы распознающих алгоритмов.

Возникает вопрос можно ли модифицировать алгоритмы распознавания для повышения их эффективности.

Сначала рассмотрим наглядный пример, в котором БС-алг - используется для задачи двух классов.



$$\rho(S, K_1) = \rho(S, K_2)$$

$S \in ?$

Заметим, что

$$\rho(S, K_1) \approx \rho(S', K_1 \setminus S'), \quad \forall S' \in K_1$$

$$\rho(S, K_2) \gg \rho(S'', K_2 \setminus S''), \quad \forall S'' \in K_2$$

Несмотря на то, что  $\rho(S, K_1) = \rho(S, K_2)$ ,  $S$  может относиться к классу  $K_1$ .

Следующий метод позволяет модифицировать распознающие алгоритмы для повышения их эффективности зависимо от того, что структуры классов.

- Сначала, вычисляем

$$1/ \quad \rho(S, K_j)$$

$$2/ \quad \{\rho(S', K_j)\}_{\forall S' \in \check{K}_j} \quad \text{или} \quad \{\rho(S', K_j \setminus S')\}_{\forall S' \in \check{K}_j}$$

- Обозначим

$$M(\rho(S, K_j)) = M\{\rho(S', K_j)\} \quad \text{или} \quad M\{\rho(S', K_j \setminus S')\}$$

$$D(\rho(S, K_j)) = D\{\rho(S', K_j)\} \quad \text{или} \quad D\{\rho(S', K_j \setminus S')\}$$

Имеем следующую нормированную формулу

$$\tilde{\rho}(S, K_j) = \left| \frac{\rho(S, K_j) - M(\rho(S, K_j))}{D(\rho(S, K_j))} \right|$$

Алгоритм распознавания, модифицированный по указанному методу называется нормированным алгоритмом распознавания и обозначается через

Ясно, что если все распределения классов  $K_j$  одинаковы, то

$$\tilde{\rho}(S, K_j) \equiv \rho(S, K_j) \quad , \quad \text{т.е.} \quad \tilde{A} \equiv A$$

ТЕОРЕМА 6.  $\tilde{M}_\rho$ -алгоритм распознавания эквивалент  $\tilde{M}_m$ -алгоритму распознавания

Где  $\tilde{M}_\rho : M_\rho$  - нормированный алгоритм распознавания

$\tilde{M}_m : M_m$  - нормированный алгоритм распознавания

$$M_m = B.C, \quad B = \|b_{ij}\|_{m \times l}, \quad b_{ij} = (S^i, M(K_j))$$

$\rho_E$  - эвклидовое расстояние,  $\rho = \rho_E^2$

Доказательство. Известно, что [5] по теореме Гиугельса

$$\rho(S, K_j) = \rho(S, M(K_j)) + D(K_j)$$

Непосредственно используя теорему Гиугельса и указанное опре-

деление выражения  $M(\rho(S, K_j)), D(\rho(S, K_j))$  можно записать

$$M[\rho(S, K_j)] = \frac{M[\rho(S', M(K_j)) + D(K_j)]}{S' \in K_j} = \frac{M[\rho(S', M(K_j))]}{S' \in K_j} + D(K_j)$$

$$D[\rho(S, K_j)] = \frac{D[\rho(S', M(K_j)) + D(K_j)]}{S' \in K_j} = \frac{D[\rho(S', M(K_j))]}{S' \in K_j}$$

Тогда, нормированная формула для  $\rho(S, K_j)$  задает таким образом

$$\tilde{\rho}(S, K_j) = \frac{\rho(S, M(K_j)) + D(K_j) - \frac{M[\rho(S', M(K_j))]}{S' \in K_j} - D(K_j)}{\frac{D[\rho(S', M(K_j))]}{S' \in K_j}}$$

$$= \frac{\rho(S, M(K_j)) - \frac{M[\rho(S', M(K_j))]}{S' \in K_j}}{\frac{D[\rho(S', M(K_j))]}{S' \in K_j}}$$

Теорема доказана.

#### § 4. НЕКОТОРЫЕ РЕЗУЛЬТАТЫ ПРИМЕНЕНИЯ КОМБИНИРОВАННОЙ СИСТЕМЫ РАСПОЗНАЮЩИХ АЛГОРИТМОВ В ГЕОЛОГИЧЕСКОМ ИССЛЕДОВАНИИ

Как известно, в геологическом исследовании часто встречаются задачи распознавания и классификации. Перед нами были поставлены конкретные задачи геологами. Для решения этих задач была составлена комбинированная система распознающих алгоритмов, состоящая из алгоритмов модели вычисления оценок, алгоритмов ближайшего соседа, алгоритмов K-внутригрупповых средних, алгоритмов типа потенциальных функций. Эта система реализована на ЭВМ и даёт хороший результат. Опишем вкратце эти за-

дачи:

1. Распознавание гранитоидов с количественной информацией.

Гранитоид является видом популярных объектов на Севере Вьетнама. Были собраны и проанализированы тысячи блоков гранитоидов.

Задача состоит в том, что из таких блоков распознавать блоки, содержащие руды, например, свинцовая руда, антимон ....

Каждый блок гранитоида объект определяется 10 числовыми признаками, являющими содержание компонентов  $SiO_2$ ,  $TiO_2$ ,  $Al_2O_3$ , ... [8]

2. Классификация формации руд Pb - Zn [8]

В этой задаче каждый распознаваемый объект рудная точка характеризуется 36 признаками, из которых 27 признаков о минералах, 3 признака об элементах, 2 признака об их отношениях и 4 признака о других породах. Знаем только о качественных информациях признаков, например, "значительное значение", "незначительное значение", ..... .

По определенному разбиению эталона из 70 объектов на 4 формации, нужно распознавать сотни других рудных точек.

3. Классификация данных нефтяной скважины

Нефтяной промысел является молодой областью в СРВ. Она еще не имеет необходимого количества обработанных данных, служащих эталонами. Поэтому на первых шагах обработки данных нефтяной скважины возникает вопрос автоматической классификации. Нефтяники предложили нам несколько задач, одна из которых - автоматическая классификация по глубине нефтяной

скважины для выявления пластов песка, углей, глины, и т.д. Каждый распознаваемый объект характеризуется 7 признаками: диаметром скважины, удельным сопротивлением, естественным электрическим полем, нейтрон-кароттажем,  $\gamma$ -кароттажем . . . . Мы обработали несколько скважин.

Эквивалентность и устойчивость распознаваемых алгоритмов применяются для сравнения результатов и определения весов алгоритмов при построении комбинированной системы следующих алгоритмов:

- алгоритм, основанный на принципе ближайшего соседа;
- алгоритмы вычисления оценок;
- модифицированный алгоритм К-внутригрупповых средних;
- алгоритмы типа потенциальных функций.

Применение этой системы для решения вышеуказанных задач указывает на то, что

- вероятность для того, чтобы результаты 4 алгоритмов были одинаковы является 0,72;
- вероятность для того, чтобы результаты 3 алгоритмов были одинаковы является 0,78;
- вероятность для того, чтобы результаты 2 алгоритмов были одинаковы является 0,99.

Авторы считают своим приятным долгом поблагодарить доктора Бак Хынг Кханг за внимание к работе и обсуждения результатов.

Л И Т Е Р А Т У Р А

- 1 ЖУРАВЛЁВ Ю.И.: Об алгебраическом подходе к решению задач распознавания и классификации. Сб. "Проблемы кибернетики", вып. 33, М., 1978.
- 2 АЙЗЕРМАН М.А., БРАВЕРМАН Э.М., РОЗОНОЗР Л.И.: Метод потенциальных функций в теорию обучения машин. Москва, Наука, 1970.
- 3 БАК ХЫНГ КХАНГ: Об одном параметрическом семействе статистических алгоритмов распознавания, Ж. Выч. Матем. и Мат. Физики, № 5, 1977.
- 4 Логико-информационные решения геологических задач. Из-во Наука, 1975.
- 5 DIDAY E.: Recent progress in distances and similarity measures in pattern recognition, Rapport de recherche, № 76, IRIA, 1974.
- 6 CRAMER H.: Mathematical Methods of Statistics, 1966.
- 7 HOANG KIEM: Some models and the recognition algorithms for complex survey /Thesis candidate for doctor in Institute of Computer Science and Cybernetice/, Hanoi, 1981.
- 8 BACH HUNG KHANG, HO TU BAO, NGUYEN HOANG PHUNG, GIANG VU THANG: The first application results of recognition methods in geological survey, Conference 1981 of Institute of Computer Science and Cybernetics, Hanoi.

ABOUT THE EQUIVALENCE AND STABILITY OF HEURISTIC  
ALGORITHM OF PATTERN-RECOGNITION WITH APPLICATION

Hoang Kiem, Ho Tu Bao  
Hanoi, Vietnam

In the paper the question of the stability and equivalence of pattern-recognition algorithms are investigated. The results are applied to some problems of geology. The solutions of these problems are also discussed in the paper.

A HEURISZTIKUS ALAKFELISMERÉSI ALGORITMUSOK EKVIVALENCIÁJA  
ÉS STABILITÁSA ÉS ALKALMAZÁSAI

Hoang Kiem, Ho Tu Bao  
Hanoi, Vietnám

A cikkben a heurisztikus alakfelismerési algoritmusokat vizsgáljuk, az ekvivalenciájukat és a stabilitásukat. Az eredmények geológiai feladatokra való alkalmazásáról is beszámolunk.