

## § 2. ОЦЕНКА «СКОЛЬЗЯЩИЙ КОНТРОЛЬ»

Оценим качество решающего правила  $F(x, \mathbf{a}_s)$  минимизирующего на заданной последовательности

$$x_1, y_1; \dots; x_l, y_l$$

эмпирический риск

$$I_s(\mathbf{a}) = \frac{1}{l-1} \sum_{i=1}^{l-1} (y_i - F(x_i, \mathbf{a}))^2$$

с помощью следующего приема. Исключим из обучающей последовательности первую пару  $x_1, y_1$  и найдем функцию, минимизирующую эмпирический риск на оставшихся  $l-1$  элементах обучающей последовательности. Пусть эта функция есть  $F(x, \mathbf{a}(x'_1, y'_1; \dots; x_l, y_l))$ . Здесь знак  $x'_1, y'_1$  указывает на то, что из обучающей последовательности была исключена пара  $x_i, y_i$ . Вычислим величину уклонения на исключенной паре:

$$(y_1 - F(x_1; \mathbf{a}(x'_1, y'_1; \dots; x_l, y_l)))^2.$$

Затем из обучающей последовательности исключим вторую пару (первая пара остается в последовательности) и вычислим уклонение

$$(y_2 - F(x_2; \mathbf{a}(x_1, y_1; x'_2, y'_2; \dots; x_l, y_l)))^2.$$

Так вычислим уклонение для всех  $l$  пар. Образует величину

$$\begin{aligned} T(x_1, y_1; \dots; x_l, y_l) &= \\ &= \frac{1}{l} \sum_{i=1}^l (y_i - F(x_i; \mathbf{a}(x_1, y_1; \dots; x'_i, y'_i; \dots; x_l, y_l)))^2 \end{aligned}$$

и примем ее за оценку качества функции  $F(x, \mathbf{a}_s^{l-1})$ , минимизирующей эмпирический риск на выборке объема  $l-1$ :

$$I(\mathbf{a}_s^{l-1}) = \int (y - F(x, \mathbf{a}_s))^2 P(x, y) dx dy \approx T(x_1, y_1; \dots; x_l, y_l).$$

Такую процедуру оценивания назовем: - «скользящий контроль».

Справедлива теорема:

**Теорема 4.I.** Оценка «скользящий контроль» является несмещенной, т. е.

$$MI(\mathbf{a}_s(x_1, y_1; \dots; x_{l-1}, y_{l-1})) = MT(x_1, y_1; \dots; x_l, y_l).$$

**З а м е ч а н и е.** Процедура «скользящий контроль» определяет несмещенные оценки качества как при восстановлении индикаторных функций, так и при восстановлении произвольных функциональных зависимостей.

Свойство несмещенности, однако, недостаточно характеризует оценку. Необходимо знать еще и дисперсию  $D(T)$  оценки  $T$ . Если бы дисперсия оценки  $T$  была известна, то можно было бы

оценить качество решающего правила, минимизирующего эмпирический риск на выборках длины  $l$ . А именно, с вероятностью  $1-h$  справедливо неравенство

$$MI(\mathbf{a}_s(x_1, y_1; \dots; x_{l-1}, y_{l-1})) \leq T(x_1, y_1; \dots; x_l, y_l) + \sqrt{\frac{D(T)}{h}} \quad (4.11)$$

Где  $1-h$  - надежность, с которой требуется выполнение неравенства (4.11). (Оценка (4.11) следует

из утверждения теоремы 4.1 и неравенства Чебышева  $P\left\{|MT - T| > \sqrt{\frac{D(T)}{h}}\right\} < h$ .

Однако вычислить дисперсию оценки «скользящий контроль» в достаточно общей постановке не удастся. Для частного случая, когда  $F(x, \mathbf{a}) = \sum_{i=1}^n \mathbf{a}_i x^i + \mathbf{a}_0$ , вектор  $x$  распределен по нормальному закону,  $y = F(x, \mathbf{a}) + \mathbf{x}$  и  $\mathbf{x}$  распределено по нормальному закону, можно доказать, что дисперсия оценки мала, имеет порядок  $\frac{1}{l}$ , а не  $\frac{n}{l}$ , и при  $j > 2n$  слабо зависит от размерности вектора  $x$ . Этот результат легко будет следовать из теоремы 4.3, приведенной в следующем параграфе.

Мы предполагаем, что такая же особенность оценки дисперсии сохранится и в общем случае: для задачи распознавания образов — когда класс  $F(x, \mathbf{a})$  имеет ограниченную емкость; а для восстановления регрессии — когда класс  $F(x, \mathbf{a})$  имеет ограниченную емкость и выполняется неравенство

$$\sup_{\mathbf{a}} \frac{M(y - F(x, \mathbf{a}))^4}{(M(y - F(x, \mathbf{a}))^2)^2} = t^2 < \infty.$$

### § 3. ЭКВИВАЛЕНТНОЕ ПРЕДСТАВЛЕНИЕ ОЦЕНКИ

#### «СКОЛЬЗЯЩИЙ КОНТРОЛЬ».

#### $J_s(x_1, y_1; \dots; x_l, y_l)$ -СТАТИСТИКИ

Рассмотрим теперь задачу восстановления функции регрессии в классе линейных по параметрам зависимостей

$$F(x, \mathbf{a}) = \sum_{i=1}^n \mathbf{a}_i j_i(x).$$

Оказывается, что в этом классе функций оценка «скользящий контроль» допускает следующее эквивалентное представление:

$$T(x_1, y_1; \dots; x_l, y_l) = \frac{1}{l} \sum_{i=1}^l \frac{(y_i - f_i^T (\Phi_l^T \Phi_l)^{-1} \Phi_l^T Y_l)^2}{(1 - f_i^T (\Phi_l^T \Phi_l)^{-1} f_i)^2}, \quad (4.12)$$

где обозначено

$$\Phi_l = \begin{pmatrix} j_1(x_1) & \dots & j_n(x_1) \\ \dots & \dots & \dots \\ j_1(x_l) & \dots & j_n(x_l) \end{pmatrix},$$

$f_i$  —  $i$ -я строка матрицы  $\Phi_l$ , а  $Y_l$  есть  $l$ -мерный вектор-столбец значений  $y$ :

$$Y_l = (y_1, \dots, y_l)^T.$$

Выражение  $(\Phi_l^T \Phi_l)^{-1} \Phi_l^T Y$  в числителе (4.12) есть оценка вектора параметров  $\mathbf{a}$ , полученная методом наименьших квадратов по всей обучающей последовательности. Числитель в (4.12) определяет квадрат уклонения в точке  $x_i$ , а знаменатель определяет ту мультипликативную поправку, которая возникает, если оценку параметров  $\mathbf{a}$  получать не по всей обучающей выборке, а по выборке, из которой исключена  $i$ -я пара  $x_i, y_i$ .

Представление (4.12) замечательно тем, что в нем используется лишь одно обращение матрицы, а не  $l$ , как в общей процедуре, описанной в предыдущем параграфе. Это обстоятельство делает процедуру «скользящий контроль» в вычислительном отношении немногим более трудоемкой, чем вычисление невязки в методе наименьших квадратов.

При построении алгоритмов восстановления зависимостей часто имеет смысл искать решение, доставляющее не только безусловный минимум функционалу  $I_g(\mathbf{a})$ , но и условный минимум при ограничении на решение <sup>1)</sup>:

$$|\mathbf{a}|^2 = \sum \mathbf{a}_i^2 \leq C.$$

Отыскание такого условного минимума — задача, эквивалентная поиску безусловного минимума функционала

$$I_g(\mathbf{a}, g) = \frac{1}{l} \sum_{i=1}^l (y_i - F(x_i, \mathbf{a}))^2 + g |\mathbf{a}|^2, \quad (4.13)$$

где  $g$  — положительная константа, зависящая от  $C$  (множитель Лагранжа).

Оценку качества решения  $\mathbf{a} = \mathbf{a}_g$ , минимизирующего функционал (4.13), будем проводить также, с помощью процедуры «скользящий контроль».

Найдем решения  $\mathbf{a}_g(x_i, y_i; \dots; x'_i, y'_i; \dots; x_l, y_l)$ , минимизирующие функционал (4.13), заданный на  $l-1$  паре (пара  $x_i, y_i$  выпущена,  $g$  фиксировано), и образуем величину

$$\begin{aligned} T_g(x_1, y_1; \dots; x_l, y_l) &= \\ &= \frac{1}{l} \sum_{i=1}^l (y_i - F(x, \mathbf{a}_g(x_1, y_1; \dots; x'_i, y'_i; \dots; x_l, y_l)))^2. \end{aligned}$$

Величина  $T_g$ , и будет оценкой качества функции  $F(x, \mathbf{a}_g)$ , минимизирующей функционал (4.13).

Эквивалентное представление  $T_g$ , задается с помощью матрицы

---

<sup>1)</sup> Такое решение иногда называют ридж-оценкой.

$$A_g = (\Phi_l^T \Phi_l + g\mathbf{I}), \mathbf{I} = \begin{pmatrix} 1 & & 0 \\ & 1 & \\ 0 & & \mathbf{O} \\ & & & 1 \end{pmatrix}.$$

А именно,

$$T_g(x_1, y_1; \dots; x_l, y_l) = \frac{1}{l} \sum_{i=1}^l \frac{(y_i - f_i^T A_g^{-1} \Phi_l^T Y_l)^2}{(1 - f_i^T A_g^{-1} f_i)^2} \quad (4.14)$$

при  $g = 0$  выражение (4.14) совпадает с (4.12).

Введем теперь параметрическое (по параметру  $p$ ) семейство статистик

$$J_p(x_1, y_1; \dots; x_l, y_l) = \frac{\left( n + \frac{1}{l+p} + \frac{n}{l+p-n-2} \right)}{\left( 1 + \frac{1}{l-1} + \frac{n}{l-n-3} \right)} \frac{1}{l} \sum_{i=1}^l \frac{(y_i - f_i^T (\Phi_l^T \Phi_l)^{-1} \Phi_l^T Y_l)^2}{(1 - f_i^T (\Phi_l^T \Phi_l)^{-1} f_i)^2}$$

$$l > n+7, \quad p > -l+n+2$$

содержащее (при  $p = -1$ ) статистику «скользящий контроль». С помощью этого семейства статистик для задачи восстановления регрессии

$$y = \sum_{i=1}^n a_i^0 j_i(x) + a_0,$$

которая решается с помощью метода наименьших квадратов, будем по выборке  $x_1, y_1; \dots; x_l, y_l$  объема  $l$  оценивать величины  $I_{l+p}$  среднего риска для решений, полученных по выборкам объема  $l+p$ :

$$I_{l+p} = M \left( y - f^T (\Phi_{l+p}^T \Phi_{l+p})^{-1} \Phi_{l+p}^T Y_{l+p} \right)^2.$$

Здесь математическое ожидание вычисляется по матрицам  $\Phi_{l+p}$  (размера  $(l+p) \times n$ ), вектору  $Y_{l+p}$  (размерности  $l+p$ ), величине  $y$  и вектору  $f$  (размерности  $n$ ).

Итак, примем

$$J_p(x_1, y_1; \dots; x_l, y_l) \propto I_{l+p}.$$

Оказывается, что в условиях, когда вектор  $f$  распределен по нормальному закону, а величина  $y$  задается моделью

$$y_k = \sum_{i=1}^n a_i^0 j_i(x_k) + a_0 + x_k$$

где помеха  $X$  не зависит от  $x$  и распределена по нормальному закону  $N(0, S^2)$  (параметр  $S^2$  нам не известен), справедливы следующие три теоремы <sup>1)</sup>,

**Теорема 4.2.** Статистика  $J_p(x_1, y_1; \dots; x_l, y_l)$  является несмещенной оценкой риска  $I_{l+p}$ .

**Теорема 4.3.** Дисперсия оценки  $J_p(x_{1,y_1}; \dots; x_l, y_l)$  заключена в пределах

$$\frac{2S^4}{l} \left( \frac{1 + \frac{1}{l+p} + \frac{n}{l+p-n-2}}{1 + \frac{1}{l-1} + \frac{n}{l-n-3}} \right)^2 A \leq D(J_p(\cdot)) \leq \frac{2S^4}{l} \left( \frac{1 + \frac{1}{l+p} + \frac{n}{l+p-n-2}}{1 + \frac{1}{l-1} + \frac{n}{l-n-3}} \right)^2 B,$$

где

$$A = \left( 1 + \frac{1}{l-1} + \frac{n}{l-n-3} \right)^3 - \frac{nl^2}{(l-n-5)^3},$$

$$B = \left( 1 + \frac{1}{l-1} + \frac{n+4}{l-n-7} \right)^3 + \frac{nl^2}{(l-n-5)^3}.$$

**Теорема 4.4.** Среднеквадратичная относительная ошибка оценивания риска  $I_{l+p}$ , не зависит от  $p$  и лежит в пределах:

$$\frac{\sqrt{\frac{2A}{l}}}{1 + \frac{1}{l-1} + \frac{n}{l-n-3}} \leq \frac{\sqrt{D(J_p(\cdot))}}{I_{l+p}} \leq \frac{\sqrt{\frac{2B}{l}}}{1 + \frac{1}{l-1} + \frac{n}{l-n-3}}$$

З а м е т и м, что при  $l > 2n$  оценки, полученные в теоремах 4.2 и 4.3, слабо зависят от  $n$  - размерности вектора  $f$ .

Помимо оценки ожидаемого риска, на выборках объема  $l+p$ , статистики

$J_p(x_1, y_1; \dots; x_l, y_l)$  позволяют:

1. Оценить минимальную возможную величину риска. Минимально возможный риск оценивается величиной  $J_\infty(x_1, y_1; \dots; x_l, y_l)$ .

2. Оценить, на сколько следует ожидать уменьшения риска, если выборка будет увеличена на  $p$  элементов. Оценка уменьшения риска задается величиной

$$\Delta_p = J_0(x_1, y_1; \dots; x_l, y_l) - J_p(x_1, y_1; \dots; x_l, y_l).$$

3. Оценить, на сколько элементов должна быть увеличена выборка, чтобы риск уменьшился на величину  $\Delta$ . Величина выборки определяется минимальным решением неравенства

$$J_0(x_1, y_1; \dots; x_l, y_l) - J_p(x_1, y_1; \dots; x_l, y_l) \geq \Delta.$$

<sup>1)</sup> Доказательства этих теорем даны в английском издании [3]: V. N. Vapnik. Estimation of Dependences Based on Emyirical Data.- Springer, New York, 1982.

4. Наконец, можно попытаться использовать статистику  $J_p(x_1, y_1; \dots; x_l, y_l)$  для определения подпространства векторного пространства  $X$ , на котором регрессии, построенные на выборках объема  $l + p$ , будут иметь минимальный средний риск. Для этого надо найти подпространство  $\tilde{X}$  пространства  $X$ , на котором достигается минимум  $J_p(\tilde{x}_1, y_1; \dots; \tilde{x}_l, y_l)$  (для различных  $p$  получаются разные оптимальные подпространства).