

# АЛГОРИТМ ОЦЕНКИ ВОСПРОИЗВОДЯЩЕГО ЯДРА ДЛЯ РЕШЕНИЯ ЗАДАЧИ МАШИННОГО ОБУЧЕНИЯ МЕТОДОМ КОЛЛОКАЦИИ

Бывшев В.А.

Финансовый университет при Правительстве Российской Федерации,  
г. Москва, Ленинградский проспект, д.49

VByvshev@fa.ru

*Аннотация: Обсуждается алгоритм оценки воспроизводящего ядра, необходимого для решения задачи машинного обучения методом коллокации. Метод коллокации восходит к Л.В. Канторовичу и состоит в восстановлении искомым функций по значениям функционалов. Алгоритм базируется на теореме Лоэва об интерпретации воспроизводящего ядра как автоковариационной функции и концепции Винера оценки автоковариационной функции стационарного ряда по индивидуальной реализации*

Ключевые слова: Задача и метод машинного обучения, задача и метод коллокации, искомая функция и функционалы, воспроизводящее ядро.

## Введение

Метод коллокации восходит к лауреату Нобелевской премии Л.В. Канторовичу [1] и состоит в восстановлении искомым функций по определённым на них значениям функционалов. В данной работе сначала излагаются задача и метод коллокации во взаимосвязи с постановкой задачи и методом машинного обучения. Затем строится алгоритм оценки воспроизводящего ядра, необходимого для решения методом коллокации задачи машинного обучения.

## 1 Задача машинного обучения

Задачи машинного обучения по прецедентам состоят в следующем [2], [3]. Задано множество  $X$  объектов  $x \in X$  и задано множество  $Y$  допустимых ответов  $y \in Y$ . Каждый объект  $x \in X$  описывается набором признаков  $a(x) = (a_1(x), \dots, a_q(x))$ , и с этим набором  $x$  отождествляется:  $x \sim a(x)$ . Каждый признак  $a_j(x)$  имеет смысл некоторой характеристики объекта  $x$  и формально может интерпретироваться как отображение множества объектов  $X$  в множество  $A_j$  возможных значений признака  $a_j$ , то есть  $a_j: X \rightarrow A_j$ . В зависимости от типа множества  $A_j$  признак  $a_j$  может быть бинарным, категориальным или количественным. Отметим, что категориальные признаки можно квантифицировать, поэтому будем предполагать, что все признаки в наборе  $a(x)$  являются количественными, то есть  $a(x) \in R_q$ .

По предположению, существует неизвестная функция  $f: X \rightarrow Y$ , значения которой  $y_i = f(x_i)$  известны на конечном множестве объектов  $(x_1, x_2, \dots, x_n) \subset X$ . Пары  $(a(x_i), y_i)$  именуется прецедентами; совокупность  $S = (a(x_i), y_i)_{i=1}^n$  прецедентов образуют выборку. Выборку разделяют на две части: на обучающую выборку  $S_l = (a(x_i), y_i)_{i=1}^n$  и контролирующую выборку  $S_c = (a(x_{(i)}), y_{(i)})_{(i)=1}^{(n)}$ . Требуется по выборке  $S$  построить функцию  $\hat{f}: X \rightarrow Y$ , приближающую неизвестную функцию  $f: X \rightarrow Y$  на всём множестве  $X$ .

Схема решения задачи машинного обучения состоит из трёх шагов [2].

Шаг 1. Задаётся некоторое параметрическое семейство  $\Phi$  функций  $\varphi(a; \theta)$ :

$$(1.1) \quad \Phi = \{\varphi(a; \theta) \mid \varphi: R_q \times \Theta \rightarrow Y\}.$$

Аргументом функции  $\varphi(a; \theta) \in \Phi$  служит вектор  $a = a(x)$  признакового описания объекта  $x \in X$ , компоненты вектора  $\theta$  являются искомыми параметрами функции  $\varphi(a; \theta)$ , при этом  $\theta \in \Theta \subset R_m$ , где  $\Theta$  – множество допустимых значений параметров. Областью изменения функции  $\varphi(a; \theta)$  служит множество ответов  $Y$ . Пусть  $\theta$  – некоторый произвольный фиксированный вектор параметров,  $a(x)$  – признаковое описание некоторого объекта  $x \in X$ . Значение

$$(1.2) \quad \tilde{y} = \varphi(a(x); \theta)$$

имеет смысл оценки истинного ответа  $y = f(x)$  на объекте  $x$ ; разность

$$(1.3) \quad \tilde{y} - y = e(a(x), \varphi, \theta)$$

является истинной ошибкой оценки  $\tilde{y}$  ответа  $y = f(x)$  на объекте  $x \in X$  при векторе параметров  $\theta$ . Качество вектора параметров  $\theta$  измеряется значением некоторой функции ошибки  $e(a(x), \varphi, \theta)$ . Такую функцию принято именовать функцией потерь и обозначать  $Loss$ . Функция потерь является функцией аргументов  $(a(x), \varphi, \theta)$ . Пусть  $Loss(a(x), \varphi, \theta)$  – некоторая функция потерь. Её значения зависят от типа функций  $\varphi \in \Phi$ , вектора параметров  $\theta \in \Theta$  и объекта  $x \in X$ . Усреднённое по множеству  $X$  значение функции потерь обозначим  $Loss(\varphi, \theta)$ , то есть

$$(1.4) \quad Loss(\varphi, \theta) = E_x(Loss(a(x), \theta)).$$

Значение  $Loss(\varphi, \theta)$  зависит от типа функций  $\varphi \in \Phi$  и вектора параметров  $\theta \in \Theta$ . Величина  $Loss(\varphi, \theta)$  интерпретируется как мера риска прогноза (1.4) ответа  $y = f(x)$  при заданном векторе параметров  $\theta$ . На практике значение  $Loss(\varphi, \theta)$ , как правило, не известно, но всегда доступна его оценка, например, по обучающей выборке  $S_l$ :

$$(1.5) \quad Loss(\overline{\varphi}, \overline{\theta}, S_l) = \frac{1}{n} \sum_{i=1}^n Loss(a(x_i), \varphi, \theta),$$

именуемая эмпирическим риском.

Шаг 2. На обучающей выборке решается вариационная задача на условный экстремум

$$(1.6) \quad \begin{cases} Loss(\overline{\varphi}, \overline{\theta}, S_l) = \frac{1}{n} \sum_{i=1}^n Loss(a(x_i), \varphi, \theta) \rightarrow \min \\ \theta \in \Theta \end{cases}$$

То есть отыскивается такой вектор параметров  $\hat{\theta} \in \Theta$ , который минимизирует эмпирический риск на обучающей выборке.

Шаг 3. При найденном векторе параметров  $\hat{\theta}$  вычисляется эмпирический риск на контролирующей выборке:

$$(1.7) \quad Loss(\overline{\varphi}, \overline{\hat{\theta}}, S_c) = \frac{1}{(n)} \sum_{(i)=1}^{(n)} Loss(a(x_{(i)}), \varphi, \hat{\theta}).$$

Если величина  $Loss(\overline{\varphi}, \overline{\hat{\theta}}, S_c)$  значительно не превосходит количество  $Loss(\overline{\varphi}, \overline{\hat{\theta}}, S_l)$ , то есть если имеет место приближённое равенство

$$(1.8) \quad Loss(\overline{\varphi}, \overline{\hat{\theta}}, S_c) \approx Loss(\overline{\varphi}, \overline{\hat{\theta}}, S_l),$$

то задача машинного обучения считается решённой; это означает, что найдена функция

$$(1.9) \quad \tilde{y} = \hat{f}(x) = \varphi(a(x); \hat{\theta}),$$

приближающая неизвестную функцию  $f: X \rightarrow Y$  на всём множестве  $X$ . Функцию (1.9) используют для прогноза ответов. В противном случае, когда величина  $Loss(\overline{\varphi}, \overline{\hat{\theta}}, S_c)$  значительно превосходит  $Loss(\overline{\varphi}, \overline{\hat{\theta}}, S_l)$ , говорят [2], что произошло переобучение модели (1.14), меняют состав обучающей и контролирующей выборок и повторяют шаги 1, 2 и 3 до достижения условия (1.8).

## 2 Задача коллокации

Вернёмся к постановке задачи машинного обучения о восстановлении неизвестной функции  $f: X \rightarrow Y$ . Под символом  $X$  будем теперь понимать признаковый образ множества объектов в задаче машинного обучения, так что  $X \subset R_q$ . В задаче коллокации о восстановлении функции  $f: X \rightarrow Y$  предполагается, что

искомая функция  $y = f(x)$  определена на ограниченном замкнутом множестве  $X$  и принадлежит некоторому гильбертову пространству  $H$  с воспроизводящим ядром  $K(x, x')$ , где  $(x, x') \in X \times X$ ;

известны значения  $(l_i)_{i=1}^n$  ограниченных линейно-независимых функционалов  $(L_i)_{i=1}^n$  на искомой функции  $f(x)$ :

$$(2.1) \quad L_1(f) = l_1, L_2(f) = l_2, \dots, L_n(f) = l_n.$$

Систему (2.1) можно интерпретировать как систему уравнений наблюдений над косвенными проявлениями искомой функции  $f \in H$ ; эту систему удобно записать компактно

$$(2.1)' \quad L(f) = l,$$

где  $L = (L_1, \dots, L_n)^T$  – векторный функционал,  $l = (l_1, \dots, l_n)^T \in R_n$ .

В задаче коллокации требуется по уравнениям наблюдений (2.1) восстановить функцию  $f: X \rightarrow Y$ , то есть найти такую аналитически заданную функцию  $\hat{f}: X \rightarrow Y$ , которая приближала бы  $f$  на  $X$  и удовлетворяла бы системе уравнений наблюдений (2.1)′:

$$(2.2) \quad L(\hat{f}) = l.$$

Решение  $\hat{f}$  задачи коллокации базируется на следующей теореме.

Теорема [4]. Если в системе уравнений наблюдений (2.1)′ компоненты  $L_1, \dots, L_n$  векторного функционала  $L$  являются ограниченными и линейно-независимыми функционалами на гильбертовом пространстве  $H$  с воспроизводящим ядром  $K(x, x')$ , то

1) гильбертово пространство  $H$  разлагается в прямую сумму ортогональных подпространств  $KerL = \{\varphi \in H, L(\varphi) = 0\}$  и  $Ker^\perp L$ :

$$(2.3) \quad H = KerL \oplus Ker^\perp L,$$

где бесконечномерное подпространство  $KerL$  является ядром векторного функционала  $L$ , размерность подпространства  $Ker^\perp L$  совпадает с количеством  $n$  линейно-независимых компонентов векторного функционала  $L$ , базис подпространства  $Ker^\perp L$  образуют функции

$$(2.4) \quad (K(x, L_1), K(x, L_2), \dots, K(x, L_n)) = K(x, L)^T,$$

где символом  $K(x, L_i)$  обозначен результат действия функционала  $L_i$  на воспроизводящее ядро  $K(x, x')$  по аргументу  $x' \in X$ ;

2) решение  $\hat{f}$  задачи коллокации является элементом подпространства  $Ker^\perp L$ , то есть

$$(2.5) \quad \hat{f} \in Ker^\perp L;$$

3) решение задачи коллокации  $\hat{f}(x)$  вычисляется по правилу

$$(2.6) \quad \hat{f}(x) = K(x, L)^T \cdot K^{-1} \cdot l,$$

где символом  $K = (K(L_i, L_j))$  обозначена симметричная положительно определённая матрица

Предположим теперь, что  $\hat{f}(x)$  имеет смысл восстановленной функции в задаче машинного обучения, где всегда

$$(2.7) \quad L_i(f) = \delta_{x_i}(f) = f(x_i), \quad F(f) = \delta_x(f) = f(x),$$

Тогда, согласно (2.4) и (2.6), оценка ответа для любого объекта  $x \in X$  будет вычисляться методом коллокации по правилу

$$(2.8) \quad \tilde{y} = \hat{f}(x) = \sum_{j=1}^n c_j \cdot K(x, x_j).$$

Чтобы применять метод коллокации, нужно иметь оценку воспроизводящего ядра  $K(x, x')$ .

3 Алгоритм оценки воспроизводящего ядра  $K(x, x')$

Ниже представлен алгоритм оценки  $K(x, x')$  по выборке  $S = (a(x_i), y_i)_{i=1}^N$ , базирующийся на теореме Лозва [5, стр 512] об интерпретации воспроизводящего ядра как автоковариационной функции и концепции Винера [6, стр. 17] оценки автоковариационной функции стационарного ряда по индивидуальной реализации. Мы принимаем традиционную в приложениях [4] гипотезу об изотропности функции  $K(x, x')$ , то есть гипотезу, что  $K(x, x') = K(\rho(x, x'))$ .

1. Вычислить  $\bar{y} = \frac{1}{N} \sum_1^N y_i$  и  $y_i = y_i - \bar{y}$  при  $i = 1, 2, \dots, N$ .

2. Вычислить  $\rho_{ij} = \rho(x_i, x_j)$  при  $1 \leq i < j \leq N$  и вычислить  $\rho_{max} = \max \rho_{ij}$ .

3. Задать количество  $M$  узлов сетки  $(\rho_1, \rho_2, \dots, \rho_M)$ , в которых будут вычислены оценки  $(K_1 = K(\rho_1), K_2 = K(\rho_2), \dots, K_M = K(\rho_M))$ ; вычислить шаг сетки  $\Delta\rho = \frac{\rho_{max}}{M}$  и радиус окрестности узла  $r = \frac{\Delta\rho}{2}$ .

4. Вычислить  $K(0) = \frac{1}{N} \cdot \sum_1^N y_i^2$ .

5. Принять  $K_m = 0, N_m = 0$  при  $m = 1, 2, \dots, M$ .

6. Цикл по  $i = 1, 2, \dots, N - 1$ .

7. Цикл по  $j = i + 1, \dots, N$
8. Принять  $\rho = \rho_{ij}$
8. Цикл по  $m = 1, 2, \dots, M$
9. Принять  $\rho_m = \Delta\rho \cdot m$
10. Проверить справедливость неравенства  $(\rho_m - r \leq \rho < \rho_m + r)$ . (3.1)  
 Если (3.1) несправедливо, то идти на конец цикла по  $m$ .  
 Если (3.1) справедливо, то вычислить  $K_m = K_m + y_i \cdot y_j$  и вычислить  $N_m = N_m + 1$ .
11. Вычислить  $K(\rho_m) = K_m/N_m$  при  $m = 1, 2, \dots, M$  и  $N_m \neq 0$ .
12. Конец

## Литература

1. Канторович Л.В. Об одном методе приближённого решения дифференциальных уравнений в частных производных. – ДАН СССР, 1931, 2, № 9.
2. Воронцов К.В. Математические методы обучения по прецедентам (теория обучения машин), <http://www.ccas.ru/voron..>
3. Соловьёв В.И. Анализ данных в экономике. КНОРУС, М., 2019.
4. Мориц Г. Современная физическая геодезия. – М, «Недра», 1983.
5. Лозв М. Теория вероятностей. – М., ИЛ, 1962.
6. Wiener N. Time Series. M.I.T. Press, Cambridge, Mass., 1949.