

Последовательное восстановление обобщенных линейных моделей зависимостей по возрастающей обучающей совокупности

Морозов Алексей Олегович^{1,2} ao.morozov@phystech.edu

Моттль Вадим Вячеславович² vmottl@yandex.ru

Сулимова Валентина Вячеславовна³ vsulimova@yandex.ru

¹Московский физико-технический институт

²ФИЦ ИУ РАН

³Тулльский государственный университет

«Математические методы распознавания образов»

Москва

28 ноября 2019

Обобщенная задача восстановления зависимости в линейном пространстве наблюдений

Дано:

$\mathbf{x} \in \mathbb{R}^n$ — объекты реального мира

$y = f(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{Y}$ — неизвестная зависимость

Найти:

$\hat{y} = \hat{f}(\mathbf{x}), \mathbb{R}^n \rightarrow \mathbb{Y}$

$\hat{y} \approx y$

Частные случаи:

- $\mathbb{Y} = \mathbb{R}$ оценивание регрессионной зависимости: $\mathbb{R}^n \rightarrow \mathbb{R}$
- $\mathbb{Y} = \{-1, 1\}$ бинарная классификация: $\mathbb{R}^n \rightarrow \{-1, 1\}$

Обобщенная линейная модель (Generalized Linear Model)

$z(\mathbf{x}|\mathbf{a}, b) = \mathbf{a}^T \mathbf{x} + b : \mathbb{R}^n \rightarrow \mathbb{R}$ — обобщенная линейная модель зависимости

$q(y, z) : \mathbb{Y} \times \mathbb{R} \rightarrow \mathbb{R}^+$ — функция связи (штрафа, потерь, loss), выпуклая по $z \in \mathbb{R}$

$\hat{y}(\mathbf{x}|\mathbf{a}, b) = \arg \min_{y \in \mathbb{Y}} q(y, z(\mathbf{x}|\mathbf{a}, b))$ — решающее правило

Частные случаи:

- Регрессия: $q(y, z) = (y - z)^2$
- Классификация (бинарная): выпуклая функция, удовлетворяющая следующим свойствам $\lim_{z \rightarrow -\infty} q(y = +1, z) = \infty$,
 $\lim_{z \rightarrow \infty} q(y = +1, z) = 0$, $\lim_{z \rightarrow -\infty} q(y = -1, z) = 0$,
 $\lim_{z \rightarrow \infty} q(y = -1, z) = \infty$.
- Логистическая регрессия: $q(y, z) = \ln \left(1 + \frac{1}{e^{yz}} \right)$

Общепринятый принцип обучения по прецедентам: Минимум регуляризованного эмпирического риска

Множество прецедентов: $\{(\mathbf{x}_j, y_j), j = 1 \dots, N\}$

Нужно найти параметры линейной модели: $\mathbf{a} \in \mathbb{R}^n, b \in \mathbb{R}$.

Критерий: минимум потерь в пределах обучающей совокупности.

Эмпирический риск на обучающей совокупности вместо среднего риска по всем объектам реального мира.

$$EmpR(\mathbf{a}, b) = \sum_{j=1}^N q(y_j, \mathbf{a}^T \mathbf{x}_j + b) \rightarrow \min$$

Однако, если $n > N$, то существует континуум точек минимума $(\mathbf{a}, b) \in \mathbb{R}^{n+1}$

Минимум регуляризованного эмпирического риска

Ридж регуляризация, $\gamma > 0$

$$J(\mathbf{a}, b) = \gamma \mathbf{a}^T \mathbf{a} + \sum_{j=1}^N q(y_j, \mathbf{a}^T \mathbf{x}_j + b)$$

Селективная регуляризация $\mu > 0$

$$J(\mathbf{a}, b|\mu) = \gamma \sum_{i=1}^n \begin{pmatrix} 2\mu|a_i|, & |a_i| \leq \mu \\ \mu^2 + a_i^2, & |a_i| > \mu \end{pmatrix} + \sum_{j=1}^N q(y_j, \mathbf{a}^T \mathbf{x}_j + b)$$

При увеличении параметра селективности μ , коэффициенты при «лишних» признаках, мало способствующих уменьшению эмпирического риска, стремятся к нулю.

В результате имеем малое подмножество активных признаков:

$$\mathbb{I}(\mu) = \{i : a_i \neq 0\} \subseteq \{1, \dots, n\}$$

Двойственная формулировка и численное решение задачи минимизации эмпирического риска

$$\begin{cases} \gamma \sum_{i=1}^n \begin{pmatrix} 2\mu|a_i|, & |a_i| \leq \mu \\ \mu^2 + a_i^2, & |a_i| > \mu \end{pmatrix} + \sum_{j=1}^N q(y_j, z_j) \rightarrow \min(a_1, \dots, a_n, z_1, \dots, z_n | \mu) \\ z_j = \mathbf{a}^T \mathbf{x}_j + b, \quad j = 1, \dots, N \end{cases}$$

Теорема

Решение разделенной задачи полностью определяется решением выпуклой двойственной задачи

$$\begin{cases} \frac{1}{2} \sum_{i=1}^n \max \left[0, \left(\sum_{j=1}^N \lambda_j x_{ji} \right)^2 - \mu^2 \right] - \sum_{j=1}^N \inf_{z \in \mathbb{R}} \left[\frac{1}{2\gamma} q(y_j, z) + \lambda_j z \right] \rightarrow \\ \rightarrow \min(\lambda_1, \dots, \lambda_N) \\ \sum_{j=1}^N \lambda_j = 0 \end{cases}$$

Способ последовательного приближенного решения двойственной задачи

$$\hat{a}_i = \begin{cases} 0, & \left| \sum_{j=1}^N \hat{\lambda}_j x_{ji} \right| \leq \mu \\ \left| \sum_{j=1}^N \hat{\lambda}_j x_{ji} \right|, & \left| \sum_{j=1}^N \hat{\lambda}_j x_{ji} \right| > \mu \end{cases}$$

Ограничимся случаем ридж-регуляризации с фиксированным числом признаков

Двойственная задача для N объектов:

$$W_N(\lambda_1, \dots, \lambda_N) = \frac{1}{2} \sum_{i=1}^n \left(\sum_{j=1}^N \lambda_j x_{ji} \right)^2 - \sum_{j=1}^N \inf_{z \in \mathbb{R}} \left[\frac{1}{2\gamma} q(y_j, z) + \lambda_j z \right]$$

Пусть она решена $(\hat{\lambda}_{N,1}, \dots, \hat{\lambda}_{N,N})$ и пришел новый объект (x_{N+1}, y_{N+1})

Задача выпуклой оптимизации только с двумя переменными (ξ, λ)

$$W_{N+1}(\lambda_1, \dots, \lambda_N, \lambda_{N+1}) = \frac{1}{2} \sum_{i=1}^n \left(\sum_{j=1}^N \lambda_j x_{ji} + \lambda_{N+1} x_{N+1,i} \right)^2 - \sum_{j=1}^N \inf_{z \in \mathbb{R}} \left[\frac{1}{2\gamma} q(y_j, z) + \lambda_j z \right] - \inf_{z \in \mathbb{R}} \left[\frac{1}{2\gamma} q(y_{N+1}, z) + \lambda_{N+1} z \right]$$

Идея: искать заново только одну новую переменную λ_{N+1} и один общий коэффициент ξ при прежних переменных $(\xi \hat{\lambda}_{N,1}, \dots, \xi \hat{\lambda}_{N,N})$

$$W_{N+1}(\xi, \lambda) = \frac{1}{2} \sum_{i=1}^n \left(\xi \sum_{j=1}^N \hat{\lambda}_{N,j} x_{ji} + \lambda x_{N+1,i} \right)^2 - \sum_{j=1}^N \inf_{z \in \mathbb{R}} \left[\frac{1}{2\gamma} q(y_j, z) + \xi \hat{\lambda}_{N,j} z \right] - \inf_{z \in \mathbb{R}} \left[\frac{1}{2\gamma} q(y_{N+1}, z) + \lambda z \right]$$

Двойственная задача для регрессии


$$W_{N+1}(\xi, \lambda) = \frac{1}{2} \sum_{i=1}^n \left(\xi \sum_{j=1}^N \hat{\lambda}_{N,j} x_{ji} + \lambda x_{N+1,i} \right)^2 + \sum_{j=1}^N \left(\frac{1}{2} \gamma (\xi \hat{\lambda}_{N,j})^2 - y_j \xi \hat{\lambda}_{N,j} \right) + \left(\frac{1}{2} \gamma \lambda^2 - y_{N+1} \lambda \right)$$

Её решение сводится к решению системы двух линейных уравнений:




$$\left(\begin{array}{c|c} \sum_{i=1}^n \left(\sum_{j=1}^N \hat{\lambda}_{N,j} x_{ji} \right)^2 + \gamma \sum_{j=1}^N \hat{\lambda}_{N,j}^2 & \sum_{i=1}^n \left(\sum_{j=1}^N \hat{\lambda}_{N,j} x_{ji} \right) x_{N+1,i} \\ \hline \sum_{i=1}^n \left(\sum_{j=1}^N \hat{\lambda}_{N,j} x_{ji} \right) x_{N+1,i} & \sum_{i=1}^n x_{N+1,i}^2 + \gamma \end{array} \right) \begin{pmatrix} \xi \\ \lambda \end{pmatrix} = \begin{pmatrix} \sum_{j=1}^N y_j \hat{\lambda}_{N,j} \\ y_{N+1} \lambda \end{pmatrix}$$

Эксперимент

Данные: временные ряды ежемесячных доходностей активов на бирже за 20 лет ($N = 250$). Мы вычислили временной ряд доходности $y = \mathbf{X}^T \mathbf{a} + \psi \in \mathbb{R}^N$ с 5%-ой дисперсией шума ψ . Взяли первые 20 наблюдений и инкрементально обучались



Использованная литература

-  Nelder J. A., Wedderburn R. W. M. Generalized linear models //Journal of the Royal Statistical Society: Series A (General). – 1972. – Т. 135. – №. 3. – С. 370-384.
www.rss.onlinelibrary.wiley.com/doi/abs/10.2307/2344614
-  Crammer K. et al. Online passive-aggressive algorithms //Journal of Machine Learning Research. – 2006. – Т. 7. – №. Mar. – С. 551-585.
www.jmlr.org/papers/volume7/crammer06a/crammer06a.pdf
-  Tatarchuk A. et al. A support kernel machine for supervised selective combining of diverse pattern-recognition modalities //International Workshop on Multiple Classifier Systems. – Springer, Berlin, Heidelberg, 2010. – С. 165-174.
www.link.springer.com/chapter/10.1007/978-3-642-12127-2_17

Спасибо за внимание!