

基于独立但不同分布样本的系数正则化回归算法的研究

常欣欣, 王 鑫

安阳工学院, 河南 安阳

收稿日期: 2021年9月8日; 录用日期: 2021年9月29日; 发布日期: 2021年10月11日

摘 要

本文分析了基于独立但不同分布样本的系数正则化回归学习算法。全文的框架不同于以往的经典核学习方法, 核函数不再要求满足半正定性; 对于样本输出, 令其满足弱化的矩假设条件。文章使用积分算子的方法得到了满意的与容量无关的误差界, 最后通过选取合适的正则化参数得到较为满意的学习率。

关键词

系数正则化回归, 非正定核, 矩假设条件, 积分算子, 学习率

Analysis of Coefficient Regularized Regression with Non-Identically and Independently Sampling

Xinxin Chang, Xin Wang

Anyang Institute of Technology, Anyang Henan

Received: Sep. 8th, 2021; accepted: Sep. 29th, 2021; published: Oct. 11th, 2021

Abstract

This paper considers the error analysis of coefficient regularization with non-identically and independently sampling. The framework under investigation is different from classical kernel learning. The kernel function no longer satisfies the positive semidefiniteness; we carry out the error analysis with output sample values satisfying a generalized moment hypothesis. Satisfactory capacity independently error bounds are derived by the techniques of integral operator for this learning al-

gorithm, finally, a satisfactory learning rate is obtained by selecting appropriate regularization parameters.

Keywords

Coefficient Regularization Regression, Indefinite Kernel, Unbounded Hypothesis, Integral Operator, Learning Rates

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

统计学习理论中的最小二乘回归问题陈述如下:

设 X 为一个紧子集, $Y = \mathbb{R}$. ρ 为 $Z: X \times Y$ 上未知的概率测度, $z = \{(x_i, y_i)\}_{i=1}^m \in Z^m$ 为服从 ρ 的一组独立同分布的取样. 在回归学习中定义关于函数 $f: X \rightarrow Y$ 的期望风险泛函,

$$\varepsilon(f) = E(f(x) - y)^2 = \int_Z (f(x) - y)^2 d\rho$$

回归函数定义为

$$f_\rho(x) = E(y|x) = \int_Y y d\rho(y|x), x \in X$$

记 $\rho(y|x)$ 为 ρ 在 $X = x$ 时的条件分布, 回归函数刻画了输出值 y 与输入值 x 之间的依赖关系. 实际上, 由于 ρ 是未知的, 所以 f_ρ 无法直接求得, 于是我们的目标是利用样本 z 产生关于 f_ρ 的一个最佳逼近.

在这篇文章里, 我们学习 l^2 系数正则化算法:

$$f_{z,\lambda} = f_{\alpha_z} \text{ 其中 } \alpha_z = \arg \min_{\alpha \in \mathbb{R}^T} \left\{ \frac{1}{T} \sum_{i=1}^T (f_\alpha(x_i) - y_i)^2 + \lambda T \sum_{i=1}^T \alpha_i^2 \right\}, \lambda > 0 \quad (1.1)$$

有关该算法的研究可以参看文献[1] [2].

2. 相关定义

在本章中, 考虑基于 Z 上的概率分布 ρ_t , 对任意的 $t \geq 1$, ρ_t 在 x 处的条件分布为 $\rho(\cdot|x)$. 第 t 个样本 $z_t = (x_t, y_t)$ 的选取依赖于 ρ_t . 我们选取样本序列 $z_t = (x_t, y_t)$ 来自于强平稳过程. 令 ρ_X 和 ρ_X^t 分别为 ρ 和 ρ_t 在 X 上的边缘测度. 接下来的假设和文献[3]中一样, 边缘分布 ρ_X^t 收敛到 Holder 空间 $C^s(X)$ 的对偶空间 $(C^s(X))^*$ 中的 ρ_X .

Holder 空间 $C^s(X)$ ($0 \leq s \leq 1$) 包含 X 上所有的连续函数, 并且具有以下有界范数:

$$\|f\|_{C^s(X)} = \|f\|_\infty + |f|_{C^s(X)}$$

其中

$$|f|_{C^s(X)} := \sup_{x \neq y \in X} \frac{|f(x) - f(y)|}{(d(x, y))^s}.$$

接下来给出的定义是对序列 ρ_X^t 的处理.

定义 2.1 令 $0 \leq s \leq 1$, 则序列 ρ_X^t 以指数形式收敛到 $(C^s(X))^*$ 中的 ρ_X , 如果存在 $C_1 > 0, 0 < \alpha < 1$ 使下列式子成立:

$$\|\rho_X^{(t)} - \rho_X\|_{(C^s(X))^*} \leq C_1 \alpha^t, \forall t \in N \tag{2.1}$$

根据对偶空间 $(C^s(X))^*$ 的定义, 上式也可以表示为:

$$\left| \int_X f(x) d\rho_X^{(i)} - \int_X f(x) d\rho_X \right| \leq C_1 \alpha^i \|f\|_{C^s(X)}, \forall f \in C^s(X), i \in N.$$

根据积分算子的定义, 有

$$L_{K, \rho_X} f(x) = \int_X K(x, u) f(u) d\rho_X(u), L_{K, \rho_X^t} f(x) = \int_X K(x, u) f(u) d\rho_X^{(t)}(u),$$

为了进行误差分析, 假设核函数 \tilde{K} 满足序数 $s(0 \leq s \leq 1)$ 的核条件:

定义 2.2 若对一些常数 $k_s > 0$, 且 $\tilde{K} \in C^s(X \times X)$, 满足对所有的 $u, v \in X$, 有

$$\|\tilde{K}_u - \tilde{K}_v\|_{\tilde{K}} \leq k_s (d(u, v))^s. \tag{2.2}$$

称 Mercer 核 \tilde{K} 满足序数 $s(0 \leq s \leq 1)$ 的核条件。

满足序数 $s(0 \leq s \leq 1)$ 的核条件称 Mercer 核 \tilde{K} 使得对任意的 $f \in H_{\tilde{K}}$, 且 $u, v \in X$, 有

$$|f(u) - f(v)| = \left| \langle f, \tilde{K}_u - \tilde{K}_v \rangle_{\tilde{K}} \right| \leq \|f\|_{\tilde{K}} \|\tilde{K}_u - \tilde{K}_v\|_{\tilde{K}} \leq k_s \|f\|_{\tilde{K}} (d(u, v))^s$$

所以, $f \in C^s(X)$ 并且 $\|f\|_{C^s(X)} \leq (k + k_s) \|f\|_{\tilde{K}}$ 。

对于样本 Z , 假设其满足弱化的矩假设条件: 存在两个常数 $\tilde{M} > 0$, 及 $p \geq 2$, 使得

$$\int_Z |y|^p \leq \tilde{M}^2 \tag{2.3}$$

文献[4], 文献[5], 文献[6]中对样本输出的要求均是满足弱化的矩假设条件。

本文的目标是估计 $f_{Z, \lambda}$ 与 f_ρ 之间的误差, 用 RKHS $H_{\tilde{K}}$ 逼近 f_ρ , 定义:

$$f_{\lambda, \rho_X} = \arg \min_{f \in H_{\tilde{K}}} \left\{ \int_Z (f(x) - f_\rho(x))^2 d\rho(x, y) + \lambda \|f\|_{\tilde{K}}^2 \right\}. \tag{2.4}$$

但由于样本 Z 是不同分布的, 引入

$$f_{\lambda, \bar{\rho}_X^{(m)}} = \left(\lambda I + L_{\tilde{K}, \bar{\rho}_X^{(m)}} \right)^{-1} L_{\tilde{K}, \bar{\rho}_X^{(m)}} f_\rho \tag{2.5}$$

其中 $\bar{\rho}_X^{(m)} = \frac{1}{m} \sum_{i=1}^m \rho_X^{(i)}$ 。

然后整体的误差就可以分解成三部分:

$$\|f_{Z, \lambda} - f_\rho\|_\rho = \left\| f_{Z, \lambda} - f_{\lambda, \bar{\rho}_X^{(m)}} \right\|_\rho + \left\| f_{\lambda, \bar{\rho}_X^{(m)}} - f_{\lambda, \rho_X} \right\|_\rho + \|f_{\lambda, \rho_X} - f_\rho\|_\rho$$

不等式右侧的三部分分别称为样本误差、测量误差和正则化误差。

对于算法的学习, 最重要的步骤就是进行误差分析。接下来, 首先会给出本文最重要的一个定理, 然后对其进行证明。下面将分几步对误差进行分析。第一, 对于样本误差, 主要的困难是样本是不同分布且输出是无界的, 本文通过引入一个中间积分算子的方法来解决。第二, 本文用一个新的方法得到了较小的测量误差, 从而使算法整体的误差界变小。

3. 主要定理及其证明

3.1. 主要定理

下面给出本文的主要结论:

定理 3.1 假设弱化的矩有界假设条件(2.3)成立; ρ_X^t 满足条件(2.1), 并且 \tilde{K} 满足条件(2.2); $L_{\tilde{K}, \rho_X}^{-r} f_\rho \in L_{\rho_X}^2$, 对于 $1/2 < r \leq 3/2$, 令 $\lambda = T^{-\theta}$ ($0 < \theta < 1/3$), 则有

$$E \|f_{Z, \lambda} - f_\rho\|_\rho \leq C_k'' T^{-\min\{1/2 - (3/2)\theta, (r-1/2)\theta\}},$$

这里的 C_k'' 跟 k, s, α 有关, 和 T 无关的常数。其具体的表达式会在 3.2 部分给出。

该定理的证明会在下面的误差分析中给出。

3.2. 误差分析

首先, 分析正则误差 $\|f_{\lambda, \rho_X} - f_\rho\|_\rho$ 。

关于正则误差的分析, 已经在很多关于学习理论的文献中分析过, 本文将省略它的证明过程并直接给出结果。

命题 3.1 假设 $L_{\tilde{K}, \rho_X}^{-r} f_\rho \in L_{\rho_X}^2$, 并且对 $r > 0$, 下列正则误差的界成立:

$$\|f_{\lambda, \rho_X} - f_\rho\|_\rho \leq C_q \lambda^q$$

其中, $C_q = (1 + k^{2r-2}) \|L_{\tilde{K}, \rho_X}^{-r} f_\rho\|_\rho$, $q = \min\{r, 1\}$, 并且, 当 $1/2 < r \leq 3/2$, 有

$$\|f_{\lambda, \rho_X} - f_\rho\|_{\tilde{K}} \leq C_r \lambda^{r-1/2},$$

这里, $C_r = \|L_{\tilde{K}, \rho_X}^{-r} f_\rho\|_\rho$ 。

接下来分析 $\|f_{\lambda, \tilde{\rho}_X^{(l)}} - f_{\lambda, \rho_X}\|_{\tilde{K}}$, 它是由不同的测量引起的, 所以我们称其为侧量误差, 可以参看文献[7]。

在给出结果之前, 我们需要以下 2 个引理。

引理 3.1 对任意的 $f, g \in C^s(X)$, 有

$$\|fg\|_{C^s(X)} \leq \|f\|_{C^s(X)} \times \|g\|_\infty + \|f\|_\infty \times \|g\|_{C^s(X)}$$

引理 3.2 假设 \tilde{K} 满足核条件(2.2), 则有

$$\|L_{\tilde{K}, \tilde{\rho}_X^{(l)}} - L_{\tilde{K}, \rho_X}\| \leq k(k + 2k_s) \|\tilde{\rho}_X^{(l)} - \rho_X\|_{(C^s(X))^*}$$

证明: 对任意的 $h \in C^s(X)$, 则有

$$\begin{aligned} & \left\| \left(L_{\tilde{K}, \tilde{\rho}_X^{(l)}} - L_{\tilde{K}, \rho_X} \right) h \right\|_{\tilde{K}}^2 \\ &= \int_X h(x) \left\{ \int_X h(t) \tilde{K}(x, t) d(\tilde{\rho}_X^{(l)} - \rho_X)(t) \right\} \times d(\tilde{\rho}_X^{(l)} - \rho_X)(x) \\ &\leq \left\| h(u) \int_X h(v) \tilde{K}(u, v) d(\tilde{\rho}_X^{(l)} - \rho_X) \right\|_{(C^s(X))^*} \times \left\| \tilde{\rho}_X^{(l)} - \rho_X \right\|_{(C^s(X))^*} \\ &\leq \left\{ \|h\|_{C^s(X)} \times \left\| \int_X h(v) \tilde{K}(u, v) d(\tilde{\rho}_X^{(l)} - \rho_X) \right\|_\infty \right. \\ &\quad \left. + \|h\|_\infty \times \left\| \int_X h(v) \tilde{K}(u, v) \times d(\tilde{\rho}_X^{(l)} - \rho_X) \right\|_{(C^s(X))^*} \right\} \times \left\| \tilde{\rho}_X^{(l)} - \rho_X \right\|_{(C^s(X))^*} \end{aligned} \quad (3.1)$$

记

$$I = \left\| \int_X h(v) \tilde{K}(u, v) d(\bar{\rho}_X^{(T)} - \rho_X) \right\|_{\infty},$$

$$II = \left\| \int_X h(v) \tilde{K}(u, v) d(\bar{\rho}_X^{(T)} - \rho_X) \right\|_{C^s(X)}$$

现在我们需要分别估计 I 和 II 。对于 I ，很容易有

$$\begin{aligned} I &= \max_{x \in X} \left| \int_X h(v) \tilde{K}(u, v) d(\bar{\rho}_X^{(T)} - \rho_X) \right| \\ &\leq \max_{x \in X} \|h(\cdot) \tilde{K}(u, \cdot)\|_{C^s(X)} \times \|\bar{\rho}_X^{(T)} - \rho_X\|_{(C^s(X))^*} \\ &\leq \max_{x \in X} \left[\|h\|_{C^s(X)} \times k^2 + \|h\|_{\infty} \times |\tilde{K}(u, \cdot)|_{C^s(X)} \right] \times \|\bar{\rho}_X^{(T)} - \rho_X\|_{(C^s(X))^*} \\ &\leq \left[k^2 \|h\|_{C^s(X)} + k k_s \|h\|_{\infty} \right] \times \|\bar{\rho}_X^{(T)} - \rho_X\|_{(C^s(X))^*} \end{aligned} \tag{3.2}$$

要分析 II ，考虑

$$\begin{aligned} &\left| \int_X h(v) [\tilde{K}(u_2, v) - \tilde{K}(u_1, v)] d(\bar{\rho}_X^{(T)} - \rho_X) \right| \\ &\leq \|h(v) [\tilde{K}(u_2, v) - \tilde{K}(u_1, v)]\|_{C^s(X)} \times \|\bar{\rho}_X^{(T)} - \rho_X\|_{(C^s(X))^*} \\ &\leq \left[\|h\|_{C^s(X)} \times \|\tilde{K}(u_2, v) - \tilde{K}(u_1, v)\|_{\infty} + \|h\|_{\infty} |\tilde{K}(u_2, v) - \tilde{K}(u_1, v)|_{C^s(X)} \right] \times \|\bar{\rho}_X^{(T)} - \rho_X\|_{(C^s(X))^*} \end{aligned} \tag{3.3}$$

因为

$$\left[\tilde{K}(u_2, v_2) - \tilde{K}(u_1, v_1) \right] - \left[\tilde{K}(u_2, v_1) - \tilde{K}(u_1, v_1) \right] \leq k_s^2 d^s(u_1, u_2) d^s(v_1, v_2)$$

则有

$$\begin{aligned} |\tilde{K}(u_2, v) - \tilde{K}(u_1, v)|_{C^s(X)} &\leq k_s^2 d^s(u_1, u_2), \\ |\tilde{K}(u_2, v) - \tilde{K}(u_1, v)| &\leq k \cdot k_s d^s(u_1, u_2) \end{aligned} \tag{3.4}$$

得

$$\begin{aligned} II &= \left\| \int_X h(v) \tilde{K}(u, v) d(\bar{\rho}_X^{(T)} - \rho_X) \right\|_{C^s(X)} \\ &\leq \left(k k_s \|h\|_{C^s(X)} + k_s^2 \|h\|_{\infty} \right) \|\bar{\rho}_X^{(T)} - \rho_X\|_{(C^s(X))^*} \end{aligned} \tag{3.5}$$

$$\begin{aligned} &\left\| \left(L_{\tilde{K}, \bar{\rho}_X^{(T)}} - L_{\tilde{K}, \rho_X} \right) h \right\|_{\tilde{K}}^2 \\ &\leq \left\{ \|h\|_{C^s(X)} \left[k^2 \|h\|_{C^s(X)} + k k_s \|h\|_{\infty} \right] + \|h\|_{\infty} \left[k k_s \|h\|_{C^s(X)} + k_s^2 \|h\|_{\infty} \right] \right\} \times \|\bar{\rho}_X^{(T)} - \rho_X\|_{(C^s(X))^*}^2 \\ &= \left(k \|h\|_{C^s(X)} + k_s \|h\|_{\infty} \right) \|\bar{\rho}_X^{(T)} - \rho_X\|_{(C^s(X))^*}^2 \end{aligned}$$

当条件(2.2)满足时，在文献[8]中已经证明， $H_{\tilde{K}}$ 包含在 $C^s(X)$ 中，并且有下列式子成立

$$\|h\|_{C^s(X)} \leq (k + k_s) \|h\|_{\tilde{K}}, \forall h \in H_{\tilde{K}}$$

然后有

$$\left\| \left(L_{\tilde{K}, \tilde{\rho}_X^{(T)}} - L_{\tilde{K}, \rho_X} \right) h \right\|_{\tilde{K}} \leq k(k+2k_s) \|h\|_{\tilde{K}} \left\| \tilde{\rho}_X^{(T)} - \rho_X \right\|_{(C^s(X))^*}$$

证明结束。

命题 3.2 假设 $L_{\tilde{K}, \rho_X}^{-r} f_\rho \in L_{\rho_X}^2$ ($1/2 < r < 2/3$)； \tilde{K} 满足核条件(2.2)，则测量误差满足

$$\left\| f_{\lambda, \tilde{\rho}_X^{(T)}} - f_{\lambda, \rho_X} \right\|_{\tilde{K}} \leq \frac{C_2 \lambda^{r-3/2}}{T} \quad (3.6)$$

其中 $C_k = k(k+2k_s)$, $C_2 = C_1 C_k C_r \alpha / (1-\alpha)$

证明：

$$\begin{aligned} \left\| f_{\lambda, \tilde{\rho}_X^{(T)}} - f_{\lambda, \rho_X} \right\|_{\tilde{K}} &= \left\| \left(\lambda I + L_{\tilde{K}, \tilde{\rho}_X^{(T)}} \right)^{-1} \left\{ \left(L_{\tilde{K}, \tilde{\rho}_X^{(T)}} - L_{\tilde{K}, \rho_X} \right) f_\rho + \left(L_{\tilde{K}, \rho_X} - L_{\tilde{K}, \tilde{\rho}_X^{(T)}} \right) f_{\lambda, \rho_X} \right\} \right\|_{\tilde{K}} \\ &= \left\| \left(\lambda I + L_{\tilde{K}, \tilde{\rho}_X^{(T)}} \right)^{-1} \left(L_{\tilde{K}, \tilde{\rho}_X^{(T)}} - L_{\tilde{K}, \rho_X} \right) (f_\rho - f_{\lambda, \rho_X}) \right\|_{\tilde{K}} \\ &\leq \frac{1}{\lambda} \left\| \left(L_{\tilde{K}, \tilde{\rho}_X^{(T)}} - L_{\tilde{K}, \rho_X} \right) (f_\rho - f_{\lambda, \rho_X}) \right\|_{\tilde{K}} \end{aligned}$$

应用引理 3.2，令 $h = f_\rho - f_{\lambda, \rho_X}$ ，得

$$\left\| f_{\lambda, \tilde{\rho}_X^{(T)}} - f_{\lambda, \rho_X} \right\|_{\tilde{K}} \leq \frac{1}{\lambda} k(k+2k_s) \left\| \tilde{\rho}_X^{(T)} - \rho_X \right\|_{(C^s(X))^*} \left\| f_{\lambda, \rho_X} - f_\rho \right\|_{\tilde{K}}$$

根据 $\tilde{\rho}_X^{(T)}$ 的定义和(2.1)式，有

$$\left\| \tilde{\rho}_X^{(T)} - \rho_X \right\|_{(C^s(X))^*} = \frac{1}{T} \sum_{t=1}^T \left\| \rho_X^{(t)} - \rho_X \right\|_{(C^s(X))^*} \leq \frac{C_1 \alpha}{T(1-\alpha)}$$

最后联立命题，即得结论。

接下来分析样本误差，这里不再给予具体证明，详细证明过程可参考文献[9]。

命题 3.3 $f_{Z, \lambda}$ 由(1.1)给出；假设输出满足矩有界假设条件(2.3)；并且边缘分布序列 $\rho_X^{(t)} \in N$ ，且满足条件(2.1)，则

$$E \left\| f_{Z, \lambda} - f_{\lambda, \tilde{\rho}_X^{(T)}} \right\|_{\rho} \leq \frac{C'_k}{\lambda^{3/2} T^{1/2}}$$

其中 $C'_k = 2\sqrt{6}Mk^2 + 2\sqrt{10}Mk^3 + C_3 / (1-\alpha)$, $C_3 = \alpha C_1 k M (k+2|k|_{C^s(X \times Y)}) \times (k+1)$

最后，证明定理 3.1。

证明：由命题 3.3，有

$$E \left\| f_{Z, \lambda} - f_{\lambda, \tilde{\rho}_X^{(T)}} \right\|_{\rho} \leq \frac{C'_k}{\lambda^{3/2} T^{1/2}}$$

当 $1/2 < r < 3/2$ ，由命题 3.2，有

$$\left\| f_{\lambda, \tilde{\rho}_X^{(T)}} - f_{\lambda, \rho_X} \right\|_{\tilde{K}} \leq \frac{C_2 \lambda^{r-3/2}}{T}$$

并且由命题 3.1，有

$$\left\| f_{\lambda, \rho_X} - f_\rho \right\|_{\tilde{K}} \leq C_r \lambda^{r-1/2},$$

因为

$$\|f\|_p \leq \|f\|_\infty \leq k \|f\|_{\tilde{K}}, \forall f \in H_{\tilde{K}}$$

联立三个误差界, 并令 $\lambda = T^{-\theta}$ ($0 < \theta < 1/3$), 即可证明定理 3.1, 其中 $C_k'' = (C_2 + C_r)k + C_k'$ 。

参考文献

- [1] 郭芹, 孙红卫. 基于弱相关抽样的系数正则化的一致性分析[J]. 济南大学学报(自然科学版), 2010, 24(1): 99-103.
- [2] Sun, H.W. and Wu, Q. (2011) Least Square Regression with Indefinite Kernels and Coefficient Regularization. *Applied and Computational Harmonic Analysis*, **30**, 96-109. <https://doi.org/10.1016/j.acha.2010.04.001>
- [3] Nie, W.L. and Wang, C. (2016) Error Analysis of ERM Algorithm with Unbounded and Non-Identical Sampling. *Journal of Applied Mathematics and Physics*, **4**, 156-168. <https://doi.org/10.4236/jamp.2016.41019>
- [4] Chu, X.R. and Sun, H.W. (2013) Regularized Least Square Regression with Unbounded and Dependent Sampling. *Abstract and Applied Analysis*, **2013**, 900-914.
- [5] Chu, X.R. and Sun, H.W. (2012) Coefficient Regularization with Unbounded Sampling. *Journal of Computational Information Systems*, **8**, 1613-1621.
- [6] Gao, Q. and Ye, P.X. (2016) Coefficient-Based Regularized Regression with Dependent and Unbounded Sampling. *International Journal of Wavelets, Multiresolution and Information Processing*, **14**, No. 5. <https://doi.org/10.1142/S0219691316500399>
- [7] Vapnik, V. (1979) Estimation of Dependent Based on Empirical Data. Nauka, Moscow.
- [8] Sun, H.W. and Guo, Q. (2011) Coefficient Regularized Regression with Non-IID Sampling. *International Journal of Computer Mathematics*, **88**, 3113-3125. <https://doi.org/10.1080/00207160.2011.587511>
- [9] Cai, J. (2013) Coefficient-Based Regression with Non-Identical Unbounded Sampling. *Abstract and Applied Analysis*, **2013**, Article ID: 134727. <https://doi.org/10.1155/2013/134727>