

**А. В. Бернштейн** (Москва, ИСА РАН). **Локальная обобщающая способность в задаче восстановления по данным нелинейного многообразия.**

Задача снижения размерности формулируется как задача восстановления многообразия: по выборке  $\mathbf{X}_n = \{X_1, X_2, \dots, X_n\}$  из неизвестного  $q$ -мерного многообразия данных  $\mathbf{X} = \{X = f(b) \in \mathbf{R}^p : b \in \mathbf{B} \subset \mathbf{R}^q\}$  в  $\mathbf{R}^p$ , покрытого одной координатной системой (картой), необходимо построить такие отображение вложения  $h$  многообразия  $\mathbf{X}$  в  $q$ -мерное множество  $\mathbf{Y} = h(\mathbf{X}) \subset \mathbf{R}^q$  и отображение восстановления  $g$  множества  $\mathbf{Y}$  в  $\mathbf{R}^p$ , что пара  $\theta = (h, g)$  обеспечивает выполнение приближенных равенств

$$r_\theta(X) \equiv g(h(X)) \approx X \text{ для всех } X \in \mathbf{X}. \quad (1)$$

Ошибки восстановления  $\delta_\theta(X) = \|X - r_\theta(X)\|$  могут быть вычислены для точек  $X \in \mathbf{X}_n$  выборки, а для новых (out-of-sample) точек  $X \in \mathbf{X} \setminus \mathbf{X}_n$  величина  $\delta_\theta(X)$  характеризует обобщающую способность процедуры  $\theta$  в точке  $X$ .

Рассмотрим эмпирическое многообразие  $\mathbf{X}_\theta = \{X = g(y) \in \mathbf{R}^p : y \in \mathbf{Y} \subset \mathbf{R}^q\}$  в  $\mathbf{R}^p$  и касательные подпространства  $T(X) \equiv X \oplus L(X)$  и  $T_\theta(r_\theta(X)) \equiv r_\theta(X) \oplus L_\theta(r_\theta(X))$  к многообразиям  $\mathbf{X}$  и  $\mathbf{X}_\theta$  в точках  $X \in \mathbf{X}$  и  $r_\theta(X) \in \mathbf{X}_\theta$  соответственно, где  $q$ -мерные линейные подпространства  $L$  и  $L_\theta$  — точки многообразия Грассмана  $\text{Grass}(p, q)$  [1], состоящего из  $q$ -мерных линейных подпространств в  $\mathbf{R}^p$ . Для точек  $L, L' \in \text{Grass}(p, q)$  величина  $d_{P,2}(L, L') = \|P_L - P_{L'}\|_2$  является метрикой (проекционной 2-нормой) [2] на многообразии Грассмана, где  $P_L$  и  $P_{L'}$  — операторы проектирования на линейные подпространства  $L$  и  $L'$ .

Если многообразие данных  $\mathbf{X}$  лежит в трубке  $\text{Tube}(\mathbf{X}_\theta)$  эмпирического многообразия, состоящей из точек в  $\mathbf{R}^p$ , проекции которых на многообразие  $\mathbf{X}_\theta$  единственны, то можно рассмотреть новое решение  $\theta(g) = (h_g, g)$ , в котором  $h_g(X) = \arg \min \{\|X - g(y)\|, y \in \mathbf{Y}\}$  для  $X \in \text{Tube}(\mathbf{X}_\theta)$  есть функция проектирования на эмпирическое многообразие  $\mathbf{X}_\theta$ . По определению, при  $\theta(g) = (h_g, g)$  с  $r_{\theta(g)}(X) = g(h_g(X))$  для решения имеет место неравенство

$$\|X - r_{\theta(g)}(X)\| \leq \|X - r_\theta(X)\| \text{ для } X \in \mathbf{X}. \quad (2)$$

Пусть  $X_0 \in \mathbf{X}$  и  $\delta_\theta(X_0, \varepsilon) = \max \{\delta_\theta(X) : X \in U_\varepsilon(X_0)\}$  есть максимальная ошибка восстановления в  $\varepsilon$ -окрестности  $U_\varepsilon(X_0) = \{X \in \mathbf{X} : \|X - X_0\| \leq \varepsilon\}$  точки  $X_0$ , характеризующая локальную обобщающую способность процедуры  $\theta$  в окрестности точки  $X_0$ . Следующая теорема устанавливает нижнюю границу для локальной обобщающей способности процедуры  $\theta$  в произвольной точке  $X_0 \in \mathbf{X}$ .

**Теорема.** *Если многообразие данных  $\mathbf{X}$  лежит в трубке  $\text{Tube}(\mathbf{X}_\theta)$  эмпирического многообразия  $\mathbf{X}_\theta$ , а отображения  $h$  и  $g$  — гладкие и имеют ранг  $q$ , то при  $\varepsilon \rightarrow 0$  имеет место неравенство*

$$\delta_{\theta(g)}^2(X_0, \varepsilon) \geq \delta_{\theta(g)}^2(X_0) + \varepsilon^2 d_{P,2}^2(L(X_0), L_{\theta(g)}(r_{\theta(g)}(X_0))) + o(\varepsilon^2). \quad (3)$$

Здесь и далее символ  $o(\cdot)$  в векторном случае понимается в покомпонентном смысле. При  $\delta_{\theta(g)}(X_0) = 0$  неравенство (3) превращается в равенство.

С учетом (2), теорема определяет оценку снизу для величины  $\delta_{\theta}(X_0, \varepsilon)$ , а при  $X \in U_{\varepsilon}(X_0)$  и  $\varepsilon \rightarrow 0$  имеют место асимптотические неравенства

$$\|(X - X_0) - (r_{\theta(g)}(X) - r_{\theta(g)}(X_0))\| \leq \|X - X_0\| d_{P,2}(L(X_0), L_{\theta(g)}(r_{\theta(g)}(X_0))) + o(\|X - X_0\|);$$

$$\begin{aligned} \|X - X_0\| \sqrt{1 - d_{P,2}^2(L(X_0), L_{\theta(g)}(r_{\theta(g)}(X_0)))} &\leq \|r_{\theta(g)}(X) - r_{\theta(g)}(X_0)\| \\ &+ o(\|X - X_0\|) \leq \|X - X_0\|. \end{aligned}$$

Левая часть в первом неравенстве характеризует, насколько отображение  $r_{\theta}(g)$  сохраняет локальную структуру многообразия данных  $\mathbf{X}$ , а второе неравенство характеризует степень локальной неизометричности этого отображения.

Следовательно, чем больше расстояния между линейными подпространствами  $L(X)$  и  $L_{\theta(g)}(X)$ , тем ниже локальная обобщающая способность построенного решения, хуже сохраняется локальная структура многообразия данных и обеспечиваются свойства локальной изометричности. Поэтому от процедуры снижения размерности  $\theta = (h, g)$  естественно требовать, чтобы она обеспечивала не только близость (1) между точками  $X \in \mathbf{X}$  и их образами  $r_{\theta(g)} \in \mathbf{X}_{\theta}$ , но и тангенциальную близость между линейными пространствами  $L$  и  $L_{\theta(g)}$  в выбранной метрике на многообразии Грассмана  $\text{Grass}(p, q)$ .

#### СПИСОК ЛИТЕРАТУРЫ

1. Lee J. M. Introduction to smooth manifolds. New-York: Springer-Verlag, 2003.
2. Hamm J., Lee D. D. Grassmann Discriminant Analysis: a Unifying View on Subspace-Based Learning. — In: Proceedings of the 25th International Conference on Machine Learning (ICML 2008), July 2006.