



О. А. Галкін

Київський національний університет ім. Тараса Шевченка

E-mail: galkin.a.o@gmail.com

Афінно-інваріантні глибинні класифікатори на основі методу k -найближчих сусідів

(Представлено членом-кореспондентом НАН України А. В. Анісімовим)

Досліджуються глибинні класифікатори на основі методу k -найближчих сусідів, що мають непараметричну узгодженість при будь-яких неперервних розподілах. Запропоновано метод симетризації функції глибини, що забезпечує центрально-зовнішнє впорядкування для визначення найближчих сусідів. Побудова симетризації асимптотично гарантує унікальність найглибшої точки, що вирішує проблему опуклої області з нескінченою множиною найглибших точок. Побудованний глибинний класифікатор на основі глибинних околів є афінно-інваріантним, а отже нечутливим до екстремальних значень.

Ключові слова: симетризація, глибинний класифікатор, непараметрична узгодженість.

Постановка задачі. Областю глибини порядку φ є множина $C_\varphi(P) = \{z \in \mathbb{R}^r : E(z, P) \geqslant \varphi\}$ для $\forall \varphi > 0$ та \forall статистичної функції глибини. Оскільки такі області глибини є вкладеними, їх індексація буде відбуватися за ймовірнісною схемою, тобто для $\forall \gamma \in [0, 1]$ величина $R^\gamma(P)$ вказуватиме на найменше значення $R_\varphi(P)$, що має P -ймовірність $\geqslant \gamma$. Тому для глибинних рівнів та ймовірнісного наповнення використовуються верхні та нижні індекси для областей глибини.

Зазначимо, що вибіркові форми верхніх глибин можна отримати шляхом заміни P на відповідний емпіричний розподіл $P^{(m)}$ за умови, якщо наявними є r -вимірні дані Z_1, \dots, Z_m . Зазначимо, що Z_i можна впорядкувати таким чином, що

$$E(Z_{(1)}, P^{(m)}) \geqslant E(Z_{(2)}, P^{(m)}) \geqslant \dots \geqslant E(Z_{(m)}, P^{(m)}), \quad (1)$$

оскільки вибіркова глина забезпечує центрально-зовнішнє впорядкування елементів даних відносно відповідної найглибшої точки $\bar{\lambda}^{(m)}$. Тому у глибинному сенсі $Z_{(1)}$ є елементом

даних, найближчим до $\bar{\lambda}^{(m)}$, $Z_{(2)}$ — другим елементом даних, найближчим до $\bar{\lambda}^{(m)}$, ..., а $Z_{(m)}$ — елементом даних, найвіддаленішим від $\bar{\lambda}^{(m)}$.

Використовуючи впорядкування (1), статистична функція глибини може застосовуватися для визначення сусідів найглибшої точки $\bar{\lambda}^{(m)}$. Однак для реалізації класифікатора найближчого сусіда необхідно визначити сусідів довільної точки $z \in R^r$.

У даній роботі пропонується підхід, де глина розглядається відносно емпіричного розподілу $P_Z^{(m)}$, що пов'язаний з вибіркою, отриманою шляхом додавання до початкових елементів даних Z_1, Z_2, \dots, Z_m їх відображені $2z - Z_1, \dots, 2z - Z_m$ відносно z . Зазначимо, що z є асимптотично унікальною найглибшою точкою відносно $P_Z^{(m)}$. Тому відповідна побудова симетризації призводить до z -зовнішнього впорядкування такої форми:

$$E(Z_{Z,(1)}, P_Z^{(m)}) \geq E(Z_{Z,(2)}, P_Z^{(m)}) \geq \dots \geq E(Z_{Z,(m)}, P_Z^{(m)}), \quad (2)$$

елементи даних якого не є впорядкованими, а використовуються лише для визначення порядку [1].

Отже глибинні околи, тобто вибіркові області глибини $C_{Z,\varphi}^{(m)} = C_\varphi(P_Z^{(m)})$ є критично важливими у даному дослідженні. Зазначимо, що $C_Z^{\gamma(m)}$ означає найменшу область глибини $C_{Z,\varphi}^{(m)}$, що містить щонайменшу частину γ точок Z_1, Z_2, \dots, Z_m . Тому для $\gamma = k/m$, $C_Z^{\gamma(m)}$ є найменшим глибинним околом, що містить k всіх Z_i .

Симетризація функцій глибини. Ми пропонуємо будувати глибинні класифікатори k -найближчих сусідів шляхом заміни евклідових околів на відповідно визначені глибинні околи. Тобто запропонований підхід k -найближчих сусідів буде класифікувати елемент z в множину 1 тоді і тільки тоді, коли множина 1 містить більшу кількість елементів даних, ніж множина 2 в найменшому глибинному околі z , що містить k елементів даних тобто в $C_Z^{\gamma(m)}$, де $\gamma = k/m$.

Отже, запропонований глибинний класифікатор визначається, як

$$\bar{n}_E^{(m)}(z) = \Lambda \left[\sum_{i=1}^m \Lambda[X_i = 1] D_i^{\gamma(m)}(z) > \sum_{i=1}^m \Lambda[X_i = 0] D_i^{\gamma(m)}(z) \right], \quad (3)$$

де $D_i^{\gamma(m)}(z) = (1/N_z^{\gamma(m)}) \Lambda[Z_i \in C_z^{\gamma(m)}]$, а $N_z^{\gamma(m)} = \sum_{l=1}^m \Lambda[Z_l \in C_z^{\gamma(m)}]$ визначає число елементів даних в глибинному околі $C_z^{\gamma(m)}$. Зазначимо, що запропонований класифікатор (3) отриманий з використанням глибинної оцінки $\bar{\theta}_E^{(m)}(z)$ умовного математичного сподівання $\theta(z)$, оскільки

$$\bar{n}_E^{(m)}(z) = \Lambda \left[\bar{\theta}_E^{(m)}(z) > \frac{1}{2} \right], \quad (4)$$

де $\bar{\theta}_E^{(m)}(z) = \sum_{i=1}^m \Lambda[X_i = 1] D_i^{\gamma(m)}(z)$.

Відзначимо, що в одновимірному випадку $\bar{n}_E^{(m)}$ зводиться до евклідового класифікатора k -найближчих сусідів незалежно від статистичної функції глибини E . Крім того, запропонований класифікатор є афінно-інваріантним, тобто, якщо Z_1, \dots, Z_m та z підлягають загальній афінній трансформації, результат класифікації залишиться незмінним [2]. У даному випадку спосіб визначення афінно-інваріантного класифікатора k -найближчих сусідів

полягає у застосуванні класичного методу k -найближчих сусідів на нормалізованих даних $\bar{\Xi}^{-1/2}Z_i$, $i = 1, \dots, m$. Для \forall оберненої $r \times r$ матриці G та $\forall r$ -вектора v , оцінка $\bar{\Xi}$ є афінно-інваріантною оцінкою, що має такий вигляд:

$$\bar{\Xi}(GZ_1 + v, \dots, GZ_m + v) \propto G\bar{\Xi}(Z_1, \dots, Z_m)G'. \quad (5)$$

Такий трансформаційний підхід призводить до околів, що не використовують геометрію розподілу в околі точки z та є еліпсоїдами з z -незалежною орієнтацією та формою [3, 4].

Запропонований глибинний класифікатор на основі методу k -найближчих сусідів є узгодженим за відповідних умов. Для цього статистична глибинна функція W повинна задовольняти таким властивостям:

а) властивість унікальної максимізації в центрі симетрії, тобто $E(\lambda, P) > E(z, P)$ для всіх $z \neq \lambda$, якщо P є симетричним відносно λ та має щільність, що є додатньою в λ ;

б) властивість узгодженості, тобто величина $\sup_{z \in V} |E(z, P^{(m)}) - E(z, P)| = o(1)$ майже напевно при $m \rightarrow \infty$ для \forall обмеженої r -вимірної борелівської множини V . У даному випадку $P^{(m)}$ є емпіричним розподілом, пов'язаним з m випадковими векторами, що є незалежними однаково розподіленими випадковими величинами P ;

в) властивість неперервності, тобто $z \mapsto E(z, P)$ є неперервним в околі λ , якщо розподіл P є симетричним відносно λ та має щільність, що є додатньою в λ .

Отже, запропоновані класифікатори є узгодженими при практично будь-яких абсолютно неперервних розподілах. Крім того, має місце непараметрична узгодженість, що є відмінною рисою у порівнянні з універсальною узгодженістю стандартного класифікатора k -найближчих сусідів [5].

Теорема 1. Нехай k_m є послідовністю таких додатних чисел, що $k_m \rightarrow \infty$ та $k_m = o(m)$ при $m \rightarrow \infty$. Крім того, нехай E є функцією глибини, що задовільняє властивостям максимальності в центрі, монотонності по відношенню до найглибшої точки, а також властивостях неперервності, унікальної максимізації в центрі симетрії та узгодженості. Припустимо, що $Z|X = l$ має функцію щільності h_l , набір точок розриву якої має міру Лебега нуль для $l = 0,1$. Тоді, якщо \sum_m є сигма-алгеброю, пов'язаною з (Z_i, X_i) , $i = 1, \dots, m$, має місце узгодженість глибинного класифікатора k_m -найближчих сусідів $n_E^{(m)}$ з (3), тобто

$$P\left[n_E^{(m)}(Z) \neq X \middle| \sum_m\right] - P[n_B(Z) \neq X] = o_P(1) \quad (6)$$

при $m \rightarrow \infty$.

Доведення. Припустимо, що $\text{Supp}_+(h) = \{z \in \mathbb{R}^r : h(z) > 0\}$, а також визначимо $S(h_l)$ для множини точок неперервності h_l , $l = 0,1$, де

$$M = \text{Supp}_+(h) \cap S(h_0) \cap S(h_1). \quad (7)$$

Зазначимо, що Z має функцію щільності $z \mapsto h(z) = p_0h_0(z) + p_1h_1(z)$, що випливає з теореми Байєса.

Отже, при $P[Z \in M] = 1$ ми маємо

$$\begin{aligned} P[Z \in R^r \setminus M] &\leqslant \\ &\leqslant P[Z \in R^r \setminus \text{Supp}_+(h)] + \sum_{l \in \{0,1\}} P[Z \in R^r \setminus S(h_l)] \int_{R^r \setminus \text{Supp}_+(h)} h(z) dz = 0, \end{aligned} \quad (8)$$

оскільки $R^r \setminus S(h_l)$ має нульову міру Лебега, де $l = 0,1$ [6].

Далі припустимо, що $z \in M$, де $z \mapsto \theta(z) = p_1 h_1(z)/(p_0 h_0(z) + p_1 h_1(z))$ є неперервною функцією на M . Оцінку $\bar{\theta}_E^{(m)}$ з (3) можна записати у такій формі:

$$\bar{\theta}_E^{(m)} = \sum_{i=1}^m X_i D_i^{\gamma(m)}(z) = \frac{1}{N_z^{\gamma(m)}} \sum_{i=1}^{N_z^{\gamma(m)}} X_{z,(i)}, \quad (9)$$

припускаючи, що $X_{z,(i)} = X_{l(z)}$, де $l(z)$ є таким, що $Z_{z,(i)} = Z_{l(z)}$.

Отже,

$$Q^{(m)}(z) := \Omega[\bar{\theta}_E^{(m)}(z) - \theta(z)]^2 \leqslant 2Q_1^{(m)}(z) + 2Q_2^{(m)}(z), \quad (10)$$

де

$$Q_1^{(m)}(z) = \Omega \left[\left| \frac{1}{N_z^{\gamma(m)}} \sum_{i=1}^{N_z^{\gamma(m)}} (X_{z,(i)} - \theta(Z_{z,(i)})) \right|^2 \right] \quad (11)$$

та

$$Q_2^{(m)}(z) = \Omega \left[\left| \frac{1}{N_z^{\gamma(m)}} \sum_{i=1}^{N_z^{\gamma(m)}} (\theta(Z_{z,(i)}) - \theta(z)) \right|^2 \right]. \quad (12)$$

Зауважимо, що величину γ_m замінено на γ для спрощення запису. Крім того, $X_{z,(i)} - \theta(Z_{z,(i)})$, $i = 1, \dots, m$ є нульовими середніми значеннями взаємно незалежних випадкових величин, на що вказує $\sum_Z^{(m)}$ для сигма-алгебри, породженої Z_i , $i = 1, \dots, m$ [7].

В результаті, використовуючи той факт, що $N_z^{\gamma(m)} \geqslant k_m$ майже напевно, ми отримуємо таку рівність:

$$\begin{aligned} Q_1^{(m)}(z) &= \Omega \left[\frac{1}{(N_z^{\gamma(m)})^2} \sum_{i,l=1}^{N_z^{\gamma(m)}} \Omega \left[(X_{z,(i)} - \theta(Z_{z,(i)}))(X_{z,(l)} - \theta(Z_{z,(l)})) \mid \sum_Z^{(m)} \right] \right] = \\ &= \Omega \left[\frac{1}{(N_z^{\gamma(m)})^2} \sum_{i=1}^{N_z^{\gamma(m)}} \Omega \left[(X_{z,(i)} - \theta(Z_{z,(i)}))^2 \mid \sum_Z^{(m)} \right] \right] \leqslant \Omega \left[\frac{4}{N_z^{\gamma(m)}} \right] \leqslant \frac{4}{k_m} = o(1) \end{aligned} \quad (13)$$

при $m \rightarrow \infty$.

Далі, використовуючи нерівність Коші–Шварца, маємо нерівність

$$\begin{aligned}
Q_2^{(m)}(z) &\leq \Omega \left[\frac{1}{N_z^{\gamma(m)}} \sum_{i=1}^{N_z^{\gamma(m)}} (\theta(Z_{z,(i)}) - \theta(z))^2 \right] = \\
&= \Omega \left[\frac{1}{N_z^{\gamma(m)}} \sum_{i=1}^{N_z^{\gamma(m)}} (\theta(Z_{z,(i)}) - \theta(z))^2 \Lambda[\|Z_{z,(i)} - z\| \leq \tau] \right] + \\
&\quad + \Omega \left[\frac{1}{N_z^{\gamma(m)}} \sum_{i=1}^{N_z^{\gamma(m)}} (\theta(Z_{z,(i)}) - \theta(z))^2 \Lambda[\|Z_{z,(i)} - z\| > \tau] \right] \leq \\
&\leq \sup_{z' \in V_z(\tau)} |\theta(z') - \theta(z)|^2 + 4 \Omega \left[\frac{1}{N_z^{\gamma(m)}} \sum_{i=1}^{N_z^{\gamma(m)}} \Lambda[\|Z_{z,(i)} - z\| > \tau] \right] := \\
&:= \bar{Q}_2(z; \tau) + \bar{Q}_2^{(m)}(z; \tau)
\end{aligned} \tag{14}$$

для $\forall \tau > 0$.

Тому для $\forall \mu > 0$ можна вибрати таке $\tau = \tau(\mu) > 0$, що $\bar{Q}_2(z; \tau(\mu)) < \mu$. Даний вивід слідує з неперервності θ в z . Крім того очевидно, що $Q_2^{(m)}(z; \tau(\mu)) = 0$ для великих m , а оскільки $Q_2^{(m)}(z) \in o(1)$, те саме має місце і для $Q^{(m)}(z)$.

Отже, при $m \rightarrow \infty$,

$$\begin{aligned}
\Omega \left[\left| P \left[\bar{n}_E^{(m)}(Z) \neq X \middle| \sum_m \right] - J_* \right| \right] &= \Omega \left[P \left[\bar{n}_E^{(m)}(Z) \neq X \middle| \sum_m \right] - J_* \right], \\
P[\bar{n}_E^{(m)}(Z) \neq X] - J_* &\leq 2 \left(\Omega \left[\bar{\theta}_E^{(m)}(Z) - \theta(Z) \right]^2 \right)^{1/2} = o(1),
\end{aligned} \tag{15}$$

оскільки $P \left[\bar{n}_E^{(m)}(Z) \neq X \middle| \sum_m \right] \geq J_*$ майже напевно. Теорему доведено.

Цитована література

1. Oja H., Paindaveine D. Optimal signed-rank tests based on hyperplanes // J. Statist. Plann. Inference. – 2005. – **135**. – P. 307–321.
2. Chacon J. I., Duong T., Wand M. P. Asymptotics for general multivariate kernel density derivative estimators // Statist. – 2011. – **21**. – P. 810–837.
3. Галкін О. А. Вплив варіацій смуги пропускання на поведінку показника помилкової класифікації ядерного класифікатора // Вісн. Київ. нац. ун-ту ім. Тараса Шевченка. Серія фіз.-мат. науки. – 2014. – № 4. – С. 125–130.
4. Holmes C. C., Adams N. M. A probabilistic nearest neighbor method for statistical pattern recognition // J. the Royal Statist. Society. – 2002. – **64**. – P. 298–303.
5. Jornsten R., Vardi Y., Zhang C. H. A robust clustering method and visualization tool based on data depth // Statist. data Analysis. – 2002. – P. 354–365.
6. Rousseeuw P. J., Struyf A. Characterizing angular symmetry and regression symmetry // Statist. Plann. Inference. – 2004. – **122**. – P. 163–170.
7. Lange T., Mosler K., Mozharovskyi P. Fast nonparametric classification based on data depth // Statist. Papers. – 2014. – **55**. – P. 53–67.

References

1. Oja H., Paindaveine D. J. Statist. Plann. Inference, 2005, **135**: 307–321.
2. Chacon J. I., Duong T., Wand M. P. Statist., 2011, **21**: 810–837.
3. Galkin O. A. Bulletin of Taras Shevchenko National Univ. of Kyiv, Series Phys. & Math., 2014, No 4: 125–130 (in Ukrainian).
4. Holmes C. C., Adams N. M. Journal of the Royal Statistical Society, 2002, **64**: 298–303.
5. Jornsten R., Vardi Y., Zhang C. H. Statistical data Analysis, 2002: 354–365.
6. Rousseeuw P. J., Struyf A. Statist. Plann. Inference, 2004, **122**: 163–170.
7. Lange T., Mosler K., Mozharovskyi P. Statist. Papers., 2014, **55**: 53–67.

Надійшло до редакції 17.08.2015

A. A. Галкин

Киевский национальный университет им. Тараса Шевченко

E-mail: galkin.a.o@gmail.com

Аффинно-инвариантные глубинные классификаторы на основе метода k -ближайших соседей

Исследуются глубинные классификаторы на основе метода k -ближайших соседей, которые имеют непараметрическую согласованность при любых непрерывных распределениях. Предложен метод симметризации функции глубины, что обеспечивает центрально-внешнее упорядочение для определения ближайших соседей. Построение симметризации асимптотически гарантирует уникальность наиболее глубокой точки, что решает проблему выпуклой области с бесконечным множеством наиболее глубоких точек. Построенный глубинный классификатор на основе глубинных окрестностей является аффинно-инвариантным, а следовательно, нечувствительным к экстремальным значениям.

Ключевые слова: симметризация, глубинный классификатор, непараметрическая согласованность.

O. A. Galkin

Taras Shevchenko National University of Kiev

E-mail: galkin.a.o@gmail.com

Affine-invariant depth-based classifiers on the basis of the k -nearest neighbors method

Depth-based classifiers on the basis of the k -nearest neighbors method are studied with nonparametric consistency for any continuous distribution. The method of symmetrization of a depth function is proposed, providing a centrally external ordering to determine the nearest neighbors. The construction of a symmetrization asymptotically guarantees the uniqueness of the deepest point that solves the problem of a convex domain with an infinite set of the deepest points. The constructed depth-based classifier based on the depth-based neighborhoods is affine invariant and, therefore, insensitive to extreme values.

Keywords: symmetrization, depth-based classifier, nonparametric consistency.