

Димитров Д.В. (Москва, Россия) — **Статистические методы определения неоднородностей волокнистых материалов с помощью статистик ближайших соседей.**

В работе рассматривается применение оценок k -ближайших соседей дивергенции Кульбака–Лейблера [5] к поиску областей неоднородности в материалах. Асимптотические свойства таких оценок (а именно: асимптотическая несмещенность и L^2 -состоятельность) были доказаны в недавней работе [2]. В статьях [1, 3] оценки дифференциальной энтропии Шеннона применяются для обнаружения неоднородностей в волокнистом материале, заполняющем параллелепипед $\Pi \subset \mathbb{R}^3$. Используется естественный подход, при котором выбирается скользящее окно достаточно малого размера, в пределах которого оценивается некоторая характеристика материала (фактически дифференциальная энтропия Шеннона распределения направлений волокон). Затем на основе собранных характеристик делается статистический вывод о свойствах этого материала.

В статье [4] оценки дивергенции Кульбака–Лейблера используются для обнаружения многомерных пространственных кластеров в модели Бернулли. Нами развиваются и обобщаются идеи этой работы для обнаружения произвольных неоднородностей в волокнистых материалах. Вводится понятие *волокна* — пары (X, T) , где X — случайный вектор со значениями в $\mathbb{R}^{d_1} \cap \Pi$, который по смыслу является центром волокна, а T — случайный вектор со значениями в \mathbb{R}^{d_2} , который по смыслу является меткой или некоторым свойством волокна (например, направлением в пространстве). Именно среди таких меток и будет искаться неоднородность. Здесь предполагается, что Π — некоторое объемлющее множество или материал, $\Pi \in \mathcal{B}(\mathbb{R}^{d_1})$, $0 < \mu_{\mathbb{R}^{d_1}}(\Pi) < \infty$, $\mu_{\mathbb{R}^{d_1}}$ — мера Лебега в пространстве $(\mathbb{R}^{d_1}, \mathcal{B}(\mathbb{R}^{d_1}))$; $\mathbf{P}(X \in B) = \frac{\mu_{\mathbb{R}^{d_1}}(B)}{\mu_{\mathbb{R}^{d_1}}(\Pi)}$ для любого борелевского $B \in \mathcal{B}(\mathbb{R}^{d_1}) \cap \Pi$, а T имеет следующую природу: $T = \xi \cdot \mathbb{1}\{X \in R_0\} + \eta \cdot \mathbb{1}\{X \in \Pi \setminus R_0\}$, где ξ, η — некоторые случайные векторы со значениями в \mathbb{R}^{d_2} , $\text{law}(\xi) \neq \text{law}(\eta)$, $p_\xi := \frac{d\mathbf{P}_\xi}{d\mu_{\mathbb{R}^{d_2}}}$, $p_\eta := \frac{d\mathbf{P}_\eta}{d\mu_{\mathbb{R}^{d_2}}}$, $R_0 \in \mathcal{B}(\mathbb{R}^{d_1}) \cap \Pi$, $0 < \mu_{\mathbb{R}^{d_1}}(R_0) < \mu_{\mathbb{R}^{d_1}}(\Pi)$. В этом случае назовём R_0 областью неоднородности. Все случайные элементы определены на пополненном вероятностном пространстве $(\Omega, \mathcal{F}, \mathbf{P})$.

Рассматривается модель (см. Рис. 1), в которой наблюдателю доступны $\{X_i, T_i, i \in \{1, \dots, \zeta_n\}\}$, $\zeta_n \sim \text{Pois}(\lambda_n \cdot \mu_{\mathbb{R}^{d_1}}(\Pi))$, где для любого $n \in \mathbb{N}$, $\lambda_n > 0$, $\lambda_n \rightarrow \infty$, $n \rightarrow \infty$. Отметим также, что $\{X_i, T_i, \zeta_i, i \in \mathbb{N}\}$ предполагаются независимыми, $\text{law}(X_i) = \text{law}(X)$, $\text{law}(T_i) = \text{law}(T)$ для любого $i \in \mathbb{N}$. Для каждого множества R из некоторого набора множеств \mathcal{R} строится оценка $\hat{T}_n(R) := \frac{1}{2} \left(\hat{D}_n(R) + \hat{D}_n(\bar{R}) \right)$, где $\hat{D}_n(A)$ — оценка k -ближайших соседей дивергенции Кульбака–Лейблера (см. статью [2]) между распределением меток T_j внутри окна A (то есть при $X_j \in A$) и вне его (то есть при $X_j \in \Pi \setminus A$). Оценка области неоднородности \hat{R}_n полагается равной аргументу максимума такой специальной статистики $\hat{T}_n(R)$, взятого по всем окнам $R \in \mathcal{R}$, то есть $\hat{R}_n := \underset{R \in \mathcal{R}}{\text{argmax}} \hat{T}_n(R)$.

При широких условиях на плотности p_ξ и p_η удастся доказать состоятельность предложенной процедуры.

Теорема 1 Пусть для некоторых $\varepsilon, R > 0$, $N \in \mathbb{N}$, $f \in \{p_\xi, p_\eta\}$, $g \in \{p_\xi, p_\eta\}$ функционалы $K_{f,g}(2, N)$, $Q_{f,g}(\varepsilon, R)$, $T_{f,g}(\varepsilon, R)$ конечны. Тогда

$$\mathbf{P} \left(\hat{R}_n \in \underset{R \in \mathcal{R}}{\text{argmax}} d_\Pi(R, R_0) \right) \rightarrow 1, n \rightarrow \infty.$$

Здесь $d_\Pi(R, R_0) := \left| \frac{\mu(RR_0)}{\mu(R)} - \frac{\mu(\bar{R}R_0)}{\mu(\bar{R})} \right|$, $\bar{R} := \Pi \setminus R$, а определения функционалов K_{f_1, f_2} , Q_{f_1, f_2} , T_{f_1, f_2} для плотностей f_1, f_2 можно найти в статье [2].

Работа выполнена при поддержке гранта МГУ им.М.В.Ломоносова “Современные проблемы фундаментальной математики и механики”.




Рис. 1: Исследуемый волокнистый материал Π с областью неоднородности R_0

В процессе доказательства Теоремы 1 также устанавливаются новые результаты, касающиеся асимптотической несмещенности и L^2 -состоятельности оценок $\hat{D}_n(A)$ (в оценку входит сумма пуассоновского числа случайных величин; ранее в работе [2] асимптотические свойства были установлены только для оценок, вовлекающих суммы постоянного числа схожих случайных величин).

СПИСОК ЛИТЕРАТУРЫ

1. *Alonso-Ruiz, P., Spodarev, E.* (2018). Entropy-based inhomogeneity detection in fiber materials. *Methodology and Computing in Applied Probability*. **20**, 1223–1239.
2. *Bulinski, A., Dimitrov, D.* (2021). Statistical Estimation of the Kullback–Leibler Divergence. *Mathematics*. **9**, 544, 1–36.
3. *Dresvyanskiy, D., Karaseva, T., Makogin, V., Mitrofanov, S., Redenbach, C., Spodarev, E.* (2020). Detecting anomalies in fibre systems using 3-dimensional image data. *Statistics and Computing*. **30**, 4, 817–837.
4. *Walther, G.* (2010). Optimal and fast detection of spatial clusters with scan statistics. *The Annals of Statistics*. **38**, 1010–1033.
5. *Wang, Q., Kulkarni, S.R., Verdú, S.* (2009). Divergence estimation for multidimensional densities via k -nearest-neighbor distances. *IEEE Transactions on Information Theory*. **55**, 2392–2405.