

マッチング相関分析の一致性についての考察

概要：

CCAの拡張であるCross-view Graph Embedding(別名：マッチング相関分析)について，新たな生成モデルを提案し，マッチングの一致性を調べた。

大阪大学大学院 基礎工学研究科
奥野彰文 下平英寿

目次


- 既存研究：Cross-view Graph Embedding
- 生成モデルの提案
 - 既存のモデル紹介と， その拡張の提案
- Matching Consistency
 - Matching Consistencyの定義
 - 主要な結果

目次


- 既存研究：Cross-view Graph Embedding
- 生成モデルの提案
 - 既存のモデル紹介と，その拡張の提案
- Matching Consistency
 - Matching Consistencyの定義
 - 主要な結果

タグ空間 \mathbb{R}^{p_2}

画像空間 \mathbb{R}^{p_1}




共通(部分)空間 \mathbb{R}^K



タグ空間 \mathbb{R}^{p_2}

画像空間 \mathbb{R}^{p_1}




$$y_i^{\text{img}} = (A^{\text{img}})^\top x_i^{\text{img}}$$

推定したい



共通(部分)空間 \mathbb{R}^K

目的関数(Interのみ)

$$\sum_{i=1}^{n_{\text{img}}} \sum_{j=1}^{n_{\text{tag}}} w_{ij} \| (A^{\text{img}})^\top \mathbf{x}_i^{\text{img}} - (A^{\text{tag}})^\top \mathbf{x}_j^{\text{tag}} \|_2^2$$



$\begin{cases} 1 & (\mathbf{x}_i^{\text{img}} \text{ と } \mathbf{x}_j^{\text{tag}} \text{ が接続}) \\ 0 & (\text{otherwise}) \end{cases}$

二次等式制約の下で最適化

→ 一般化固有値問題

Cross-view Graph Embedding (CvGE)

(Huang et al., (2012) [1])



(正規化した) 損失関数

$$\begin{aligned}
 L(\mathbf{A}^1, \mathbf{A}^2) := & \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \tilde{w}_{ij}^{12} \|(\mathbf{A}^1)^\top \mathbf{x}_i^1 - (\mathbf{A}^2)^\top \mathbf{x}_j^2\|_2^2 \\
 & + \frac{\beta_1}{2} \sum_{i=1}^{n_1} \sum_{i'=1}^{n_1} \tilde{w}_{ii'}^{11} \|(\mathbf{A}^1)^\top \mathbf{x}_i^1 - (\mathbf{A}^1)^\top \mathbf{x}_{i'}^1\|_2^2 \\
 & + \frac{\beta_2}{2} \sum_{j=1}^{n_2} \sum_{j'=1}^{n_2} \tilde{w}_{jj'}^{22} \|(\mathbf{A}^2)^\top \mathbf{x}_j^2 - (\mathbf{A}^2)^\top \mathbf{x}_{j'}^2\|_2^2
 \end{aligned}
 \quad \left. \right\} \text{Inter} \quad \left. \right\} \text{Intra}$$

$$\left(\tilde{w}_{ij}^{12} := w_{ij}^{12} \Big/ \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} w_{ij}^{12}, \quad \tilde{w}_{ii'}^{dd} := w_{ii'}^{dd} \Big/ \sum_{\substack{i=1 \\ i \neq i'}}^{n_d} \sum_{i'=1}^{n_d} w_{ii'}^{dd}, \quad (d \in [2]) \right)$$

CvGEの特殊な形

正準相関分析 (Canonical Correlation Analysis, CCA) [2]

$$\begin{cases} \mathbb{R}^{p_y} \ni \mathbf{y}_i \mapsto \mathbf{A}_y^\top \mathbf{y}_i \in \mathbb{R}^K \\ \mathbb{R}^{p_x} \ni \mathbf{x}_i \mapsto \mathbf{A}_x^\top \mathbf{x}_i \in \mathbb{R}^K \end{cases} \quad \arg \min_{(\mathbf{A}_x, \mathbf{A}_y) \in \mathcal{S}} \sum_{i=1}^n \|\mathbf{A}_y^\top \mathbf{y}_i - \mathbf{A}_x^\top \mathbf{x}_i\|^2$$

重回帰 (目的変数が多次元)

$$\begin{cases} \mathbb{R}^{p_y} \ni \mathbf{y}_i \mapsto \mathbf{y}_i \in \mathbb{R}^{p_y} \\ \mathbb{R}^{p_x} \ni \mathbf{x}_i \mapsto \mathbf{A}^\top \mathbf{x}_i \in \mathbb{R}^{p_y} \end{cases} \quad \arg \min_{\mathbf{A} \in \mathbb{R}^{p_x \times p_y}} \sum_{i=1}^n \|\mathbf{y}_i - \mathbf{A}^\top \mathbf{x}_i\|_2^2$$

重回帰 (目的変数が一次元)

$$\begin{cases} \mathbb{R}^1 \ni y_i \mapsto y_i \in \mathbb{R}^1 \\ \mathbb{R}^p \ni \mathbf{x}_i \mapsto \boldsymbol{\alpha}^\top \mathbf{x}_i \in \mathbb{R}^1 \end{cases} \quad \arg \min_{\boldsymbol{\alpha} \in \mathbb{R}^p} \sum_{i=1}^n (y_i - \boldsymbol{\alpha}^\top \mathbf{x}_i)^2$$

目次

- 既存研究: Cross-view Graph Embeddingの紹介
- 生成モデルの提案
 - 既存のモデル紹介と、その拡張の提案
- Matching Consistency
 - Matching Consistencyの定義
 - 主要な結果

既存のモデル (for CCA)



Bach and Jordan (2005)[3]

$$\boldsymbol{x}_i^0 \sim N_{p_0}[\mathbf{0}, \Sigma_X]$$


$$\boldsymbol{x}_i^1 | \boldsymbol{x}_i^0 \sim N_{p_1}[(\boldsymbol{B}^1)^\top \boldsymbol{x}_i^0, \Sigma^1]$$

$$\boldsymbol{x}_i^2 | \boldsymbol{x}_i^0 \sim N_{p_2}[(\boldsymbol{B}^2)^\top \boldsymbol{x}_i^0, \Sigma^2]$$

$$\boldsymbol{x}_i^1 := (\boldsymbol{B}^1)^\top \boldsymbol{x}_i^0 + \boldsymbol{\varepsilon}_i^1$$




$$\boldsymbol{x}_i^2 := (\boldsymbol{B}^2)^\top \boldsymbol{x}_i^0 + \boldsymbol{\varepsilon}_i^2$$



Latent space

提案するモデル



Latent space




①潜在ベクトルの生成

$$x_t^0 \sim Q$$

提案するモデル

②クラス t の要素数決定


$$n_t^1 \sim F_{n^1}$$




提案するモデル

③クラス t のベクトル生成


$$\mathbf{x}_{t,i}^1 \mid \mathbf{x}_t^0 \sim N_{p_1}[(\mathbf{B}^1)^\top \mathbf{x}_t^0, \Sigma^1] \quad (i = 1, 2, \dots, n_t^1)$$



提案するモデル




提案するモデル



提案するモデル

⑥各潜在変数から
同様のクラスを生成



提案するモデル

得られたもの：
大量のベクトル（クラス）と、その接続の情報

	やること
クラス数	無限大へ
各クラスのサイズ	有限(r.v.)

目次

- 既存研究：Cross-view Graph Embedding
- 生成モデルの提案
 - 既存のモデル紹介と，その拡張の提案
- Matching Consistency
 - Matching Consistencyの定義
 - 主要な結果


一致性の定義

線形回帰では : $\hat{\beta}_n \xrightarrow{p} \underline{\beta}$
真の解

正準相関分析では：「真の解」が存在しない

一致性をどう定義するか？

我々が使える情報




$$\{\boldsymbol{x}_i^1\}_{i=1}^{n_1} \subset \mathbb{R}^{p_1}$$

$$\{\boldsymbol{x}_j^2\}_{j=1}^{n_2} \subset \mathbb{R}^{p_2}$$

と、そのマッチングウェイト $\{w_{ij}\}_{i,j=1}^{n_1, n_2} \subset \mathbb{R}_{\geq 0}$

$$\hat{\mathbf{A}}^1 : \mathbb{R}^{p_1} \rightarrow \mathbb{R}^K$$

$$\hat{\mathbf{A}}^2 : \mathbb{R}^{p_2} \rightarrow \mathbb{R}^K$$



ドメイン1からの射影



$$(\hat{\mathbf{A}}^1)^\top \mathbf{x}_{t,i}^1 \mid \mathbf{x}_t^0 \sim N[(\mathbf{B}^1 \hat{\mathbf{A}}^1)^\top \mathbf{x}_t^0, (\hat{\mathbf{A}}^1)^\top \Sigma^1 \hat{\mathbf{A}}^1]$$

ドメイン2からの射影



$$(\hat{\mathbf{A}}^2)^\top \mathbf{x}_{t,j}^2 \mid \mathbf{x}_t^0 \sim N[(\mathbf{B}^2 \hat{\mathbf{A}}^2)^\top \mathbf{x}_t^0, (\hat{\mathbf{A}}^2)^\top \Sigma^2 \hat{\mathbf{A}}^2]$$

\mathbb{R}^K

$$\mathcal{E}(\hat{\mathbf{A}}; \mathbf{B}) := \frac{E_{\mathbf{x}_t^0}[\|(\mathbf{B}^1 \hat{\mathbf{A}}^1)^\top \mathbf{x}_t^0 - (\mathbf{B}^2 \hat{\mathbf{A}}^2)^\top \mathbf{x}_t^0\|_F^2]}{\text{クラスタ射影の理論的中心の距離}}$$

Matching Consistent $\overset{\text{def}}{\iff} p \lim_{n_0 \rightarrow \infty} \mathcal{E}(\hat{\mathbf{A}}; \mathbf{B}) = 0$

損失関数（再掲）

$$L(\mathbf{A}^1, \mathbf{A}^2) := \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \tilde{w}_{ij}^{12} \|(\mathbf{A}^1)^\top \mathbf{x}_i^1 - (\mathbf{A}^2)^\top \mathbf{x}_j^2\|_2^2 + \frac{\beta_1}{2} \sum_{i=1}^{n_1} \sum_{i'=1}^{n_1} \tilde{w}_{ii'}^{11} \|(\mathbf{A}^1)^\top \mathbf{x}_i^1 - (\mathbf{A}^1)^\top \mathbf{x}_{i'}^1\|_2^2 + \frac{\beta_2}{2} \sum_{j=1}^{n_2} \sum_{j'=1}^{n_2} \tilde{w}_{jj'}^{22} \|(\mathbf{A}^2)^\top \mathbf{x}_j^2 - (\mathbf{A}^2)^\top \mathbf{x}_{j'}^2\|_2^2$$


Inter Intra

$\beta := \beta_1 = \beta_2$: Intra-terms の影響力を調節


実際にやってみると...

$$p_0 = 1, p_1 = 2, p_2 = 2, K = 1,$$

$$\mathbf{B}^1 = (1, 1), \mathbf{B}^2 = (0, 1), \Sigma^1 = \Sigma^2 = \mathbf{I}_2, \Sigma_X = 1$$



$$p \lim_{n_0 \rightarrow \infty} \mathcal{E}(\hat{\mathbf{A}}) = \frac{1}{12} \left(7 + \frac{\beta - 48}{\sqrt{\beta^2 + 48}} \right), \ (\beta \geq -1)$$




数値例が示唆すること：

$$\sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \tilde{w}_{ij}^{12} \|(\mathbf{A}^1)^\top \mathbf{x}_i^1 - (\mathbf{A}^2)^\top \mathbf{x}_j^2\|_2^2$$

$$\begin{aligned} & -\frac{1}{2} \sum_{i=1}^{n_1} \sum_{i'=1}^{n_1} \tilde{w}_{ii'}^{11} \|(\mathbf{A}^1)^\top \mathbf{x}_i^1 - (\mathbf{A}^1)^\top \mathbf{x}_{i'}^1\|_2^2 \\ & -\frac{1}{2} \sum_{j=1}^{n_2} \sum_{j'=1}^{n_2} \tilde{w}_{jj'}^{22} \|(\mathbf{A}^2)^\top \mathbf{x}_j^2 - (\mathbf{A}^2)^\top \mathbf{x}_{j'}^2\|_2^2 \end{aligned}$$


Intraの損失は、引かなければならぬ



クラスタどうしが
勝手にくっつく

$$\sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \tilde{w}_{ij}^{12} \|(\mathbf{A}^1)^\top \mathbf{x}_i^1 - (\mathbf{A}^2)^\top \mathbf{x}_j^2\|_2^2$$

ドメイン間の接続のみ



クラスタを
散らばす

$$\begin{aligned}
 & \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \tilde{w}_{ij}^{12} \|(\mathbf{A}^1)^\top \mathbf{x}_i^1 - (\mathbf{A}^2)^\top \mathbf{x}_j^2\|_2^2 \\
 & - \frac{1}{2} \sum_{i=1}^{n_1} \sum_{i'=1}^{n_1} \tilde{w}_{ii'}^{11} \|(\mathbf{A}^1)^\top \mathbf{x}_i^1 - (\mathbf{A}^1)^\top \mathbf{x}_{i'}^1\|_2^2 \\
 & - \frac{1}{2} \sum_{j=1}^{n_2} \sum_{j'=1}^{n_2} \tilde{w}_{jj'}^{22} \|(\mathbf{A}^2)^\top \mathbf{x}_j^2 - (\mathbf{A}^2)^\top \mathbf{x}_{j'}^2\|_2^2
 \end{aligned}$$

主要な結果

(生成モデルが) 次の条件を満たすとする.

- (1) $B^1, B^2 \neq O$
- (2) $E_Q[\|x_1^0\|_\infty^2] < \infty$
- (3) $E_{F_{n^d}}[(n_t^d)^2] < \infty$
- (4) $P[n_t^d \geq 2] > 0$

多対多の対応が
存在

このとき、生成モデルの下で、

$$\beta = -1 \quad \Rightarrow \quad \mathcal{E}(\hat{A}) \xrightarrow{p} 0, \quad (n_0 \rightarrow \infty)$$

Intra graphの推定

- Inter graphからIntra graphを推定できる.

$$\hat{\mathbf{W}}^{11} = \mathbf{W}^{12}(\mathbf{W}^{12})^\top$$

$$\hat{\mathbf{W}}^{22} = (\mathbf{W}^{12})^\top \mathbf{W}^{12}$$

Intra graph(既知)を推定量に置き換えても,
同様の結果が成り立つ.

数値実験：

$\tilde{\mathcal{E}}(\hat{\mathbf{A}})$: 規格化した誤差

設定:


$$p_0 = 3, p_1 = 5, p_2 = 7,$$

$$\Sigma^1 = \sigma_1^2 \mathbf{I}_{p_1}, \Sigma^2 = \sigma_2^2 \mathbf{I}_{p_2},$$


$$\Sigma_X = ((\Sigma_X)_{ij}) = (2^{-|i-j|}),$$

$$Q = N[\mathbf{0}, \Sigma_X]$$

B^1, B^2 の各要素は標準正規分布から生成




(a) $\tilde{\mathcal{E}}(\hat{\mathbf{A}}_\beta)$




(b) $\tilde{\mathcal{E}}(\hat{\mathbf{A}}_\beta) \pm \sigma(\hat{\mathbf{A}}_\beta)$

Figure 1: $\lambda_1 = 2, \lambda_2 = 2, \sigma_1 = 1, \sigma_2 = 1$



(a) $\tilde{\mathcal{E}}(\hat{\mathbf{A}}_\beta)$





(b) $\tilde{\mathcal{E}}(\hat{\mathbf{A}}_\beta) \pm \sigma(\hat{\mathbf{A}}_\beta)$

Figure 2: $\lambda_1 = 3, \lambda_2 = 3, \sigma_1 = 1, \sigma_2 = 1$


ドメインを増やしても、同様の結果が成り立つ

$$\{x_l^4\}_{l=1}^{n_4} \subset \mathbb{R}^{p_4} \quad \{x_k^2\}_{k=1}^{n_3} \subset \mathbb{R}^{p_3}$$



$$\{x_i^1\}_{i=1}^{n_1} \subset \mathbb{R}^{p_1} \quad \{x_j^2\}_{j=1}^{n_2} \subset \mathbb{R}^{p_2}$$

発表のまとめ：



- 多対多対応を持つベクトルの生成モデルを提案
- Matching Consistencyの定義
- Matching Consistentであるための条件を提示
- (以上の結果は、多ドメインにも容易に拡張できる)

References (cited in slides)

1. Huang, Z., Shan, S., Zhang, H., Lao, S., & Chen, X. (2013). Cross-view graph embedding. *Computer Vision–ACCV 2012*.
2. Hotelling, H. (1936). Relations between two sets of variates. *Biometrika*, 28, 321–377.
3. Bach, F. R., & Jordan, M. I. (2005). A *Probabilistic Interpretation of Canonical Correlation Analysis*. *University of Barkley* (Vol. 688).
4. Shimodaira, H. Cross-validation of matching correlation analysis by resampling matching weights. *Neural Networks* 75, 126–140 (2016).

References (additional)

5. Nori, N., Bollegala, D., & Kashima, H. (2012). Multinomial relation prediction in social data: a dimension reduction approach. *Proceedings of the Twenty-Sixth AAAI Conference on Artificial Intelligence*, 115–121.
6. Yan, S., Xu, D., Zhang, B., Zhang, H. J., Yang, Q., & Lin, S. (2007). Graph embedding and extensions: A general framework for dimensionality reduction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(1), 40–51.
7. He, X., & Niyogi, P. (2004). Locality preserving projections. *Neural Information Processing Systems*, 16, 153.
8. Kettenring, J. R. (1971). Analysis of Several Sets of Variables. *Biometrika*, 58(3), 433–451.

References (additional)

9. Anderson, T. W. (2003). *An Introduction to Multivariate Statistical Analysis* (2nd ed.). New York: Wiley.
10. Davis, C., & Kahan, W. M. (1969). Some new bounds on perturbation of subspaces. *Bull. Amer. Math. Soc*, 75(4), 863–868.
11. Luxburg, U. (2007). A tutorial on spectral clustering. *Statistics and Computing*, 17(4), 395–416.
12. Fukui, K., Okuno, A., & Shimodaira, H. (2016). IMAGE AND TAG RETRIEVAL BY LEVERAGING IMAGE-GROUP LINKS WITH MULTI-DOMAIN GRAPH EMBEDDING. In the proceedings of *International Conference on Image Processing (To appear)*.
13. Oshikiri, T., Fukui, K., & Shimodaira, H. (2016) Cross-Lingual Eigenwords. In the proceedings of ACL.

生成モデル

既知 $n_0 \in \mathbb{N} (\geq 1), \mathbf{B}^d \in \mathbb{R}^{p_0 \times p_d} \ (p_0 \leq p_1, p_2)$


確率変数
(すべてiid)

$$\begin{aligned}\mathbf{x}_t^0 &\sim Q \\ n_t^d &\sim F_{n^d} \quad (\Sigma^d \succ 0, \alpha > 0) \\ \boldsymbol{\varepsilon}_{t,i}^d &\sim N_{p_d}[\mathbf{0}, \Sigma^d] \\ z_{t,i;t',j} &\sim \text{Be}(\alpha)\end{aligned}$$

データベクトル/リンク

$$\mathbf{x}_{t,i}^d = (\mathbf{B}^d)^\top \mathbf{x}_t^d + \boldsymbol{\varepsilon}_{t,i}^d \quad (i \in [n_t^1]; t \in [n_0]; d \in [2])$$

$$w_{t,i;t',j} = \delta_{t,t'} z_{t,i;t',j} \quad (i \in [n_t^1]; j \in [n_{t'}^2]; t, t' \in [n_0])$$



CvGEの定式化：

$$(\hat{\mathbf{A}}^1, \hat{\mathbf{A}}^2) := \arg \min_{(\mathbf{A}^1, \mathbf{A}^2) \in \mathcal{S}} L(\mathbf{A}^1, \mathbf{A}^2)$$

$$\mathcal{S} := \left\{ (\mathbf{A}^1, \mathbf{A}^2) \in \mathbb{R}^{p_1 \times K} \times \mathbb{R}^{p_2 \times K} \middle| \sum_{d=1}^2 \sum_{e=1}^2 (\mathbf{A}^d)^\top \mathbf{G}^{de} \mathbf{A}^e = \mathbf{I}_K \right\}$$

今回考えるセッティング：

$$\eta_n > 0, (\eta_n \rightarrow 0)$$

$$\mathbf{G}^{11} = (\mathbf{X}^1)^\top \tilde{\mathbf{M}}^1 \mathbf{X}^1 + \eta_{\min\{n_1, n_2\}} \mathbf{I}_{p_1},$$

$$\mathbf{G}^{12} = \mathbf{O}, \mathbf{G}^{21} = \mathbf{O},$$

$$\mathbf{G}^{22} = (\mathbf{X}^2)^\top \tilde{\mathbf{M}}^2 \mathbf{X}^2 + \eta_{\min\{n_1, n_2\}} \mathbf{I}_{p_2}$$

$$\left(\tilde{\mathbf{M}}^1 = \text{diag}(\mathbf{W}^{12} \mathbf{1}), \tilde{\mathbf{M}}^2 = \text{diag}((\mathbf{W}^{12})^\top \mathbf{1}) \right)$$

Solution of CvGE Let $\mathbf{A} \in \mathbb{R}^{(p_1+p_2) \times K}$, $\mathbf{X} \in \mathbb{R}^{(n_1+n_2) \times (p_1+p_2)}$, $\mathbf{W} \in \mathbb{R}^{(n_1+n_2) \times (n_1+n_2)}$, and $\mathbf{G} \in \mathbb{R}^{(p_1+p_2) \times (p_1+p_2)}$ be concatenations of some matrices as

$$\mathbf{A} = \begin{pmatrix} \mathbf{A}^1 \\ \mathbf{A}^2 \end{pmatrix}, \tilde{\mathbf{W}} = \begin{pmatrix} \beta_1 \tilde{\mathbf{W}}^{11} & \tilde{\mathbf{W}}^{12} \\ (\tilde{\mathbf{W}}^{12})^\top & \beta_2 \tilde{\mathbf{W}}^{22} \end{pmatrix}, \mathbf{G} = \begin{pmatrix} \mathbf{G}^{11} & \mathbf{G}^{12} \\ \mathbf{G}^{21} & \mathbf{G}^{22} \end{pmatrix}, \mathbf{X} = \begin{pmatrix} \mathbf{X}^1 & \mathbf{0} \\ \mathbf{0} & \mathbf{X}^2 \end{pmatrix}, \quad (3)$$

where $\mathbf{X}^1 \in \mathbb{R}^{n_1 \times p_1}$, $\mathbf{X}^2 \in \mathbb{R}^{n_2 \times p_2}$ are data matrices composed of $\{\mathbf{x}_i^1\}_{i=1}^{n_1}$ and $\{\mathbf{x}_j^2\}_{j=1}^{n_2}$, respectively. $\tilde{\mathbf{W}}^{de}$ ($d, e \in \{1, 2\}$) are rescaled inter/intra-adjacency matrices. Let $\mathcal{L}(\mathbf{W})$ ($= \text{diag}(\mathbf{W}\mathbf{1}) - \mathbf{W}$) denote a laplacian matrix that follows directly from \mathbf{W} , then the problem of CvGE can be simplified to a minimization problem of $\text{tr} \mathbf{A}^\top \mathbf{X}^\top \mathcal{L}(\mathbf{W}) \mathbf{X} \mathbf{A}$ with a quadratic constraint $\mathbf{A}^\top \mathbf{G} \mathbf{A} = \mathbf{I}_K$. The solution $\hat{\mathbf{A}} \in \mathbb{R}^{(p_1+p_2) \times K}$ is obtained as $\hat{\mathbf{A}} = \mathbf{G}^{-1/2}(\hat{\mathbf{u}}_1 \hat{\mathbf{u}}_2 \cdots \hat{\mathbf{u}}_K)$, where $\hat{\mathbf{u}}_k$ is the eigenvector of $\mathbf{G}^{-1/2} \mathcal{L}(\tilde{\mathbf{W}}) \mathbf{G}^{-1/2}$ such that $\mathbf{G}^{-1/2} \mathcal{L}(\tilde{\mathbf{W}}) \mathbf{G}^{-1/2} \hat{\mathbf{u}}_k = \lambda_k \hat{\mathbf{u}}_k$, ($\lambda_1 \leq \lambda_2 \leq \cdots \leq \lambda_p$).