

# Apprentissage en grande dimension (Partie #5)

Thomas Verdebout

Université de Lille

## Contenu du cours

1. Introduction.
2. Apprentissage supervisé: régression.
3. Apprentissage supervisé: classification.
4. Apprentissage non-supervisé

4: Apprentissage non-supervisé: analyse en composantes principales.

Supposons qu'on a un  $p$ -vecteur aléatoire  $\mathbf{X}$ . Nous aspirons à transformer  $\mathbf{X}$  en un nouveau vecteur  $\mathbf{Y}$  de dimension inférieure  $q$  (de préférence  $q$  est bien plus petit que  $p$ ). Cette transformation devrait être opérée en minimisant la perte d'“information contenue” dans le vecteur original  $\mathbf{X}$ .

$\implies$  *réduction de la dimension de données*

En fin de compte nous espérons que  $\mathbf{Y}$  soit plus facile à interpréter que  $\mathbf{X}$ :

$\implies$  *meilleure interprétation*

*Exemple.* Supposons qu'on ait sauvegardé pour une étude financière plusieurs centaines de prix d'actions sur base quotidienne (p.ex. S&P 500 contient 500 actions!) Il s'avère très difficile de tirer des conclusions statistiques à partir de vecteurs si larges. Comme bon nombre des prix d'actions sont fortement corrélés, on pourrait songer à en enlever une certaine quantité. Cependant, chaque prix peut contenir à lui seul des informations précieuses sur le marché, voilà pourquoi on ne peut pas les enlever de façon arbitraire!

Afin de “compresser” le vecteur  $\mathbf{X}$  nous allons utiliser une fonction  $H$ :

$$\mathbf{X} \mapsto H(\mathbf{X}) = \mathbf{Y}, \quad \mathbf{Y} \in \mathbb{R}^q,$$

où  $q \leq p$ . Souvent il est désirable que  $q$  soit beaucoup plus petit que  $p$ :  
 $q \ll p$ .

L'approche la plus simple consiste à choisir pour  $H$  une fonction linéaire, et alors  $\mathbf{Y} = \mathbf{H}\mathbf{X}$  avec  $\mathbf{H} \in \mathbb{R}^{q \times p}$ .

Question: quel pourrait être un choix intelligent pour  $\mathbf{H}$ ?

L'ACP utilise la stratégie suivante: soit  $\mathbf{H} = (\mathbf{h}_1, \dots, \mathbf{h}_q)'$ .

(1) Commençons par  $q = 1$  et choisissons  $\mathbf{h}_1$  tel que

$$\text{Var}(Y_1) = \text{Var}(\mathbf{h}'_1 \mathbf{X})$$

soit maximal sous la contrainte  $\|\mathbf{h}_1\| = 1$ . (Sans contrainte ceci ne fait aucun sens!)

$$\mathbf{h}_1 = \operatorname{argmax} \{ \text{Var}(\mathbf{h}'\mathbf{X}) : \mathbf{h} \in \mathbb{R}^p, \|\mathbf{h}\| = 1 \}.$$

Remarquons que

$$\text{Var}(\mathbf{h}'_1 \mathbf{X}) = \text{Var}(\|\langle \mathbf{h}_1, \mathbf{X} \rangle \mathbf{h}_1\|).$$

En d'autres mots: projetons  $\mathbf{X}$  sur le sous-espace 1-dimensionnel  $L_1$  qui donne la plus grande (possible) variabilité pour la norme de la projection.

(2) Pour  $q = 2$  choisissons  $\mathbf{h}_1$  comme avant et définissons

$$\mathbf{h}_2 = \operatorname{argmax} \{ \operatorname{Var}(\mathbf{h}'\mathbf{X}) : \mathbf{h} \in \mathbb{R}^p, \|\mathbf{h}\| = 1, \mathbf{h} \perp \mathbf{h}_1 \}.$$

En d'autres mots: projetons  $\mathbf{X}$  sur le sous-espace 1-dimensionnel  $L_2$  qui donne la plus grande (possible) variabilité pour la norme de la projection, sous la contrainte que  $L_2 \perp L_1$ .

(3) Pour  $q = 3$  choisissons  $\mathbf{h}_1$  et  $\mathbf{h}_2$  comme avant et définissons

$$\mathbf{h}_3 = \operatorname{argmax} \{ \operatorname{Var}(\mathbf{h}'\mathbf{X}) : \mathbf{h} \in \mathbb{R}^p, \|\mathbf{h}\| = 1, \mathbf{h} \perp \mathbf{h}_1, \mathbf{h}_2 \}.$$

(4) Continuons de la même manière pour  $q = 4, \dots, p$ . Nous appelons  $Y_i = \mathbf{h}'_i \mathbf{X}$  la  $i$ -ème *composante principale* de  $\mathbf{X}$ .

Remarquons que les  $Y_i$  ne dépendent pas du nombre de composantes que nous voulons inclure. D'où le fait que nous pouvons toujours supposer que  $\mathbf{H} \in \mathbb{R}^{p \times p}$ ,  $\mathbf{Y} \in \mathbb{R}^p$  et que par après nous rejetons les composantes  $Y_i, i > q$ .

En fin de compte nous avons

$$\mathbf{Y} = \mathbf{H}\mathbf{X},$$

où  $\mathbf{H}$  est une matrice orthogonale, et donc  $\mathbf{H}$  effectue une rotation ou bien une réflexion de nos données.

Une première question est de savoir comment implémenter  $\mathbf{H}$  en pratique.

Puisque  $\text{Var}(\mathbf{v}'\mathbf{X}) = \mathbf{v}'\Sigma\mathbf{v}$ , la détermination de  $\mathbf{H}$  sera facile à l'aide des deux lemmes suivants.

### Lemma

Soit  $\Sigma$  une matrice symétrique et définie positive, de valeurs propres  $\lambda_1 > \lambda_2 > \dots > \lambda_p (> 0)$  et soient  $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_p$  les vecteurs propres associés. Alors

$$\max \{ \mathbf{v}'\Sigma\mathbf{v} : \mathbf{v} \in \mathbb{R}^p, \|\mathbf{v}\| = 1 \} = \lambda_1,$$

et

$$\operatorname{argmax} \{ \mathbf{v}'\Sigma\mathbf{v} : \mathbf{v} \in \mathbb{R}^p, \|\mathbf{v}\| = 1 \} = \mathbf{e}_1.$$

*Remarque.* Ceci reste vrai si nous demandons seulement que  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ . Néanmoins le terme maximisant n'est alors plus unique.

Preuve.

Les vecteurs propres forment une base orthonormée de  $\mathbb{R}^p$  et donc nous pouvons exprimer tout vecteur  $v$  comme  $\mathbf{v} = \sum_{i=1}^p \alpha_i \mathbf{e}_i$ . La condition  $\|\mathbf{v}\| = 1$  est équivalente par Pythagore à

$$1 = \|\mathbf{v}\|^2 = \sum_{i=1}^p \|\alpha_i \mathbf{e}_i\|^2 = \sum_{i=1}^p \alpha_i^2.$$

Remarquons que

$$\Sigma \mathbf{v} = \Sigma \left( \sum_{i=1}^p \alpha_i \mathbf{e}_i \right) = \sum_{i=1}^p \alpha_i \Sigma \mathbf{e}_i = \sum_{i=1}^p \lambda_i \alpha_i \mathbf{e}_i$$

et donc par l'orthonormalité des vecteurs propres il suit que

$$\mathbf{v}' \Sigma \mathbf{v} = \left( \sum_{i=1}^p \alpha_i \mathbf{e}_i \right)' \sum_{i=1}^p \lambda_i \alpha_i \mathbf{e}_i = \sum_{i=1}^p \lambda_i \alpha_i^2 \underbrace{\mathbf{e}_i' \mathbf{e}_i}_{=1}.$$

Clairement, par la contrainte  $\sum_{i=1}^p \alpha_i^2 = 1$ , cette somme est maximisée si  $\alpha_1 = 1$  et  $\alpha_i = 0$  pour  $i = 2, \dots, p$ . Le maximum est  $\lambda_1$  et le maximisant est  $\mathbf{e}_1$ . (Discuter de l'unicité.) □

## Lemma

Soit  $\Sigma$  une matrice symétrique et définie positive, de valeurs propres  $\lambda_1 > \lambda_2 > \dots > \lambda_p (> 0)$  et soient  $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_p$  les vecteurs propres associés. Alors pour  $k = 2, \dots, p$

$$\max \{ \mathbf{v}'\Sigma\mathbf{v} : \mathbf{v} \in \mathbb{R}^p, \|\mathbf{v}\| = 1, \mathbf{v} \perp \mathbf{e}_1, \dots, \mathbf{e}_{k-1} \} = \lambda_k,$$

et

$$\operatorname{argmax} \{ \mathbf{v}'\Sigma\mathbf{v} : \mathbf{v} \in \mathbb{R}^p, \|\mathbf{v}\| = 1, \mathbf{v} \perp \mathbf{e}_1, \dots, \mathbf{e}_{k-1} \} = \mathbf{e}_k.$$

*Preuve.* La preuve est presque la même. Il nous suffit juste de remarquer que les conditions

$$\mathbf{v} \perp \mathbf{e}_1, \dots, \mathbf{e}_{k-1} \quad \text{et} \quad \|\mathbf{v}\| = 1$$

impliquent que  $\mathbf{v} = \sum_{i=k}^p \alpha_i \mathbf{e}_i$  avec  $\sum_{i=k}^p \alpha_i^2 = 1$ .



Il est commun de centrer d'abord les données avant que les composantes principales ne soient implémentées. Cela mène à la définition suivante:

### Definition

Soit  $\mathbf{X}$  un  $p$ -vecteur aléatoire de moyenne  $\boldsymbol{\mu}$  et de matrice de variance-covariance définie positive  $\boldsymbol{\Sigma}$ . Alors la transformation

$$\mathbf{X} \mapsto \mathbf{Y} = \mathbf{H}(\mathbf{X} - \boldsymbol{\mu})$$

est appelée transformation des composantes principales.

## Proposition

Soit  $\Sigma$  une matrice de variance-covariance non-singulière d'un certain  $p$ -vecteur aléatoire  $X$  et supposons que  $\lambda_1 > \lambda_2 > \dots > \lambda_p$  sont ses valeurs propres et que  $\beta = (\beta_1, \dots, \beta_p)$  est la matrice des vecteurs propres correspondants. Soit  $Y$  le vecteur des composantes principales de  $X$ . Alors

$$(i) \quad \mathbf{H} = \beta',$$

$$(ii) \quad \text{Var}(\mathbf{Y}) = \mathbf{\Lambda} = \text{diag}(\lambda_1, \dots, \lambda_p),$$

$$(iii) \quad \text{tr}(\mathbf{\Lambda}) = \text{tr}(\mathbf{\Sigma}) = E\|\mathbf{X} - \boldsymbol{\mu}\|^2,$$

$$(iv) \quad |\mathbf{\Lambda}| = |\mathbf{\Sigma}|.$$

*Preuve.* Nous avons déjà démontré (i). Le théorème spectral nous donne

$$\text{Var}(\mathbf{Y}) = \text{Var}(\mathbf{H}\mathbf{X}) = \mathbf{H}\boldsymbol{\Sigma}\mathbf{H}' = \mathbf{H}\boldsymbol{\beta}\boldsymbol{\Lambda}\boldsymbol{\beta}'\mathbf{H}' = \boldsymbol{\Lambda},$$

ce qui prouve (ii). De même,

$$\text{tr}(\boldsymbol{\Sigma}) = \text{tr}(\boldsymbol{\beta}\boldsymbol{\Lambda}\boldsymbol{\beta}') = \text{tr}(\boldsymbol{\beta}'\boldsymbol{\beta}\boldsymbol{\Lambda}) = \text{tr}(\boldsymbol{\Lambda}),$$

et

$$|\boldsymbol{\Sigma}| = |\boldsymbol{\beta}\boldsymbol{\Lambda}\boldsymbol{\beta}'| = |\boldsymbol{\beta}||\boldsymbol{\Lambda}||\boldsymbol{\beta}'| = |\boldsymbol{\Lambda}|,$$

ce qui établit (iii) et (iv). □

Les composantes principales sont le plus facilement intelligibles dans le contexte d'un  $p$ -vecteur aléatoire  $\mathbf{X} \sim \mathcal{N}_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ . Souvenez-vous que les contours de la densité de  $X$  sont donnés par

$$\{\mathbf{x} \mid (\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) = c^2\}.$$

Vous avez vu/verrez aux exercices que ces contours forment des ellipsoïdes de centre  $\boldsymbol{\mu}$  et d'axes principaux  $\beta_1, \dots, \beta_p$ , où les  $\beta_i$  sont des vecteurs propres de  $\boldsymbol{\Sigma}$ . Les rayons de ces axes sont  $c\sqrt{\lambda_i}$ .


Les composantes principales  $\mathbf{Y} = \mathbf{H}(\mathbf{X} - \boldsymbol{\mu}) \sim \mathcal{N}_p(\mathbf{0}, \boldsymbol{\Lambda})$ , et de ce fait les nouveaux contours correspondent à

$$\{\mathbf{y} \mid \mathbf{y}' \boldsymbol{\Lambda}^{-1} \mathbf{y} = c^2\}.$$

Nous avons donc des ellipsoïdes de centre  $\mathbf{0}$ , des axes principaux canoniques et les rayons sont les mêmes que précédemment.

La figure ci-dessous montre la transformation des composantes principales appliquée à 100 données/observations issues d'une loi

$$\mathcal{N}_p(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \text{ avec } \boldsymbol{\mu} = \begin{pmatrix} 3 \\ 4 \end{pmatrix} \text{ et } \boldsymbol{\Sigma} = \begin{pmatrix} 5 & 3 \\ 3 & 2.25 \end{pmatrix}.$$



Jusqu'à présent nous n'avons pas encore retiré d'observations de notre jeu de données. Nous pouvons toujours réobtenir  $\mathbf{X}$  tout entier à partir de  $\mathbf{Y}$ :

$$\mathbf{X} = \mathbf{H}'\mathbf{Y} + \boldsymbol{\mu}. \quad (1)$$

Nous souhaitons remplacer le vecteur  $\mathbf{Y} = (Y_1, \dots, Y_p)$  par un vecteur de plus petite dimension  $\mathbf{Y}^{(q)} = (Y_1, \dots, Y_q)$ ,  $q \leq p$ .

Comme  $\mathbf{H}' = (\beta_1, \dots, \beta_p)$  nous obtenons de (1) que

$$\mathbf{X} - \boldsymbol{\mu} = Y_1\beta_1 + Y_2\beta_2 + \dots + Y_p\beta_p.$$

Si nous gardons seulement  $Y_1, \dots, Y_q$ , nous pourrions utiliser l'approximation

$$\mathbf{X} - \boldsymbol{\mu} \approx Y_1\beta_1 + Y_2\beta_2 + \dots + Y_q\beta_q.$$

La proposition suivante montre que l'approximation

$$\mathbf{X} - \boldsymbol{\mu} \approx Y_1\boldsymbol{\beta}_1 + Y_2\boldsymbol{\beta}_2 + \cdots + Y_q\boldsymbol{\beta}_q.$$

est "la meilleure" en termes de  $q$  vecteurs de base

### Proposition

Soit  $\mathbf{B} = (\mathbf{b}_1, \dots, \mathbf{b}_p)$  une quelconque base orthonormale de  $\mathbb{R}^p$ . Alors

$$\mathbf{X} - \boldsymbol{\mu} = W_1\mathbf{b}_1 + W_2\mathbf{b}_2 + \cdots + W_p\mathbf{b}_p,$$

et pour tout  $1 \leq q \leq p$

$$E \left\| (\mathbf{X} - \boldsymbol{\mu}) - \left( \sum_{i=1}^q W_i \mathbf{b}_i \right) \right\|^2 \geq E \left\| (\mathbf{X} - \boldsymbol{\mu}) - \left( \sum_{i=1}^q Y_i \boldsymbol{\beta}_i \right) \right\|^2.$$

Cette proposition montre que les composantes principales retiennent "le maximum" de l'information contenue dans le vecteur original  $\mathbf{X}$ . Aucune autre base orthonormale jouit d'une meilleure puissance d'approximation que la fonction propre de  $\Sigma$ .

Notons que

$$E \left\| (\mathbf{X} - \boldsymbol{\mu}) - \left( \sum_{i=1}^q Y_i \boldsymbol{\beta}_i \right) \right\|^2 = \lambda_{q+1} + \dots + \lambda_p.$$

Le ratio

$$\frac{\lambda_{q+1} + \dots + \lambda_p}{\lambda_1 + \dots + \lambda_p} = \frac{\lambda_{q+1} + \dots + \lambda_p}{\text{tr}(\Sigma)} \quad (2)$$

peut donc être vu comme une mesure de la quantité d'information expliquée par les  $q$  premières composantes principales. On dit que (2) est *la part de la variabilité de  $\mathbf{X}$  expliquée par les  $q$  premières CP.*

*Preuve.* Par simplicité, prenons  $\boldsymbol{\mu} = \mathbf{0}$  (sans perte de généralité). Tout d'abord, il est clair que  $\mathbf{X}$  peut être réécrit sous la forme  $\sum_{i=1}^p W_i \mathbf{b}_i$ . Cela suit du fait que  $\mathbf{B}$  forme une base orthonormale. Remarquons aussi que  $W_i = \mathbf{b}_i' \mathbf{X}$  (puisque la transformation des composantes principales nous dit que  $\mathbf{W} = \mathbf{B}' \mathbf{X}$ ).

On sait que

Maintenant, par le théorème de Pythagore, nous avons

$$\begin{aligned} E \left\| \left( \mathbf{X} - \left( \sum_{i=1}^q W_i \mathbf{b}_i \right) \right) \right\|^2 &= E \left\| \sum_{i=q+1}^p W_i \mathbf{b}_i \right\|^2 \\ &= \sum_{i=q+1}^p E W_i^2 \underbrace{\|\mathbf{b}_i\|^2}_{=1} = \sum_{i=q+1}^p \mathbf{b}_i' \boldsymbol{\Sigma} \mathbf{b}_i = \text{tr}(\tilde{\mathbf{B}}' \boldsymbol{\Sigma} \tilde{\mathbf{B}}), \end{aligned}$$

où  $\tilde{\mathbf{B}} = (\mathbf{b}_{q+1}, \dots, \mathbf{b}_p)$  est une matrice  $p \times (p - q)$  orthonormale.

Nous cherchons donc une matrice  $\mathbf{B}^*$  qui minimise  $\text{tr}(\tilde{\mathbf{B}}'\Sigma\tilde{\mathbf{B}})$  sur l'ensemble des matrices  $(p - q) \times q$  orthonormales  $\tilde{\mathbf{B}}$ . Comme les  $e_i$  forment une base de  $\mathbb{R}^p$ , nous avons que  $\tilde{\mathbf{B}} = \mathbf{H}\mathbf{C}$  où  $\mathbf{C} = (c_{jk})$  est  $p \times (p - q)$ . Nous avons que

$$\text{tr}(\tilde{\mathbf{B}}'\Sigma\tilde{\mathbf{B}}) = \text{tr}(\mathbf{C}'\Lambda\mathbf{C}) = \sum_{j=1}^p \lambda_j \left( \sum_{k=1}^{p-q} c_{jk}^2 \right) \quad (3)$$

et que  $\mathbf{C}' = \tilde{\mathbf{B}}'\mathbf{H}$  est telle que  $\mathbf{C}'\mathbf{C} = \tilde{\mathbf{B}}'\mathbf{H}\mathbf{H}'\tilde{\mathbf{B}} = \mathbf{I}_{p-q}$  (orthonormale). Puisque les valeurs propres sont supposées être bien ordonnées, la matrice orthonormale  $\mathbf{C}$  qui minimise (3) est obtenue en prenant les vecteurs propres associés dans  $\mathbf{H}$  associés aux plus petites valeurs propres.

□

*Exemple.* Supposons que  $\mathbf{X} = (X_1, X_2, X_3)$  est de moyenne nulle et de matrice de variance-covariance

$$\Sigma = \begin{pmatrix} 1 & -2 & 0 \\ -2 & 5 & 0 \\ 0 & 0 & 2 \end{pmatrix}.$$

Alors les valeurs propres sont

$$(\lambda_1, \lambda_2, \lambda_3) = (5.83, 2, 0.17)$$

avec comme vecteurs propres associés

$$\beta_1 = \begin{pmatrix} 0.383 \\ -0.924 \\ 0 \end{pmatrix} \quad \beta_2 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} \quad \beta_3 = \begin{pmatrix} 0.923 \\ -0.383 \\ 0 \end{pmatrix}.$$

Cela nous donne

$$Y_1 = 0.383X_1 - 0.923X_2$$

$$Y_2 = X_3$$

$$Y_3 = 0.924X_1 + 0.383X_2$$

*Les coordonnées des vecteurs propres nous révèlent combien de poids est attribué à chaque  $X_i$ !*

Dans cet exemple la proportion de la variance totale expliquée par les premières CP équivaut à  $\lambda_1/\text{tr}(\mathbf{\Sigma}) = 5.83/8 = 0.73$ , celle expliquée par les 2 premières CP correspond à  $(\lambda_1 + \lambda_2)/\text{tr}(\mathbf{\Sigma}) = (5.83 + 2)/8 = 0.98$ .

Une propriété défavorable de l'ACP est que cette méthode *n'est pas échelle-invariante*. Cela veut dire que si  $\mathbf{A}$  est une matrice d'échelle et si  $P_{tr}$  représente la transformation des composantes principales, alors

$$P_{tr}(\mathbf{AX}) \neq \mathbf{A}P_{tr}(\mathbf{X}).$$

*Exemple.* Soient  $E\mathbf{X} = \mathbf{0}$  et  $\text{Var}(\mathbf{X}) = \begin{pmatrix} 1 & 4 \\ 4 & 100 \end{pmatrix}$ . Les valeurs propres sont  $\lambda_1 = 100.16$  and  $\lambda_2 = 0.84$  avec comme vecteurs propres associés

$$\beta_1 = \begin{pmatrix} 0.04 \\ 0.999 \end{pmatrix} \quad \text{et} \quad \beta_2 = \begin{pmatrix} 0.999 \\ -0.04 \end{pmatrix}.$$

Nous avons  $\lambda_1/\text{tr}(\Sigma) = 0.992$ .

La grande variance de  $X_2$  domine complètement la première composante principale obtenue à partir de  $\Sigma$ !

Nous utilisons maintenant le même scénario, mais nous standardisons d'abord  $X$  en divisant ses composantes par leur dispersion. Cela veut dire que nous utilisons la matrice de corrélation

$$\mathbf{P} = \begin{pmatrix} 1 & 0.4 \\ 0.4 & 1 \end{pmatrix}$$

afin de déterminer les composantes principales. Les valeurs propres sont maintenant  $\lambda_1 = 1.4$  and  $\lambda_2 = 0.6$  avec comme vecteurs propres associés

$$\beta_1 = \begin{pmatrix} 0.707 \\ 0.707 \end{pmatrix} \quad \text{et} \quad \beta_2 = \begin{pmatrix} 0.707 \\ -0.707 \end{pmatrix}.$$

Nous avons  $\lambda_1/\text{tr}(\mathbf{P}) = 0.7$ .

Nous attribuons donc la même importance à  $X_1$  et à  $X_2$  lors du calcul de  $Y_1$ .

Cet exemple montre que l'ACP doit être utilisée avec prudence.

L'ACP peut être utilisée au mieux si toutes les variables se trouvent à une échelle comparable.

Les variables devraient donc être proprement standardisées si elles sont mesurées sur des échelles fortement différentes.

Bien sûr, en pratique, nous ne connaissons ni  $\mu$  ni  $\Sigma$  et par conséquent nous devons baser nos analyses sur leurs estimateurs

$$\bar{\mathbf{X}} \quad \text{et} \quad \mathbf{S},$$

basés eux-mêmes sur l'échantillon  $\mathbf{X}_1, \dots, \mathbf{X}_n$ .

Soient  $\hat{\beta} = (\hat{\beta}_1, \dots, \hat{\beta}_p)$  les vecteurs propres standardisés de  $\mathbf{S}$  correspondant aux valeurs propres  $\hat{\lambda}_1 \geq \hat{\lambda}_2 \geq \dots \geq \hat{\lambda}_p$ . La transformation des composantes principales empiriques est donnée par

$$\mathbf{X}_k \mapsto \hat{P}_{tr}(\mathbf{X}_k) = \hat{\mathbf{X}}_k = \hat{\beta}(\mathbf{X}_k - \bar{\mathbf{X}}), \quad 1 \leq k \leq n.$$

Posant  $\hat{\mathbf{Y}}_k = (\hat{Y}_{k,1}, \dots, \hat{Y}_{k,p})'$ , les variables  $\hat{Y}_{k,i}$  sont appelées les  $i$ -èmes scores des composantes principales.

## Proposition

Soit  $\mathbf{S}$  une matrice de variance-covariance non-singulière correspondant à un certain échantillon  $\mathbf{X}_1, \dots, \mathbf{X}_n$  de  $p$ -vecteurs. Supposons que  $\hat{\lambda}_1 > \hat{\lambda}_2 > \dots > \hat{\lambda}_p$  soient ses valeurs propres et que  $\hat{\beta} = (\hat{\beta}_1, \dots, \hat{\beta}_p)$  soit la matrice des vecteurs propres correspondants. Soient  $Y_1, \dots, Y_n$  les composantes principales. Alors

$$(i) \quad \mathbf{S}_Y = \hat{\Lambda} = \text{diag}(\hat{\lambda}_1, \dots, \hat{\lambda}_p),$$

$$(ii) \quad \text{tr}(\hat{\Lambda}) = \text{tr}(\mathbf{S}) = \frac{1}{n-1} \sum_{k=1}^n \|\mathbf{x}_k - \bar{\mathbf{x}}\|^2,$$

$$(iii) \quad |\hat{\Lambda}| = |\mathbf{S}|.$$

Preuve. *Exercice.*



Comme dans le cas de la population il est possible d'établir une propriété d'optimalité des fonctions propres.

### Proposition

Soit  $\mathbf{B} = (\mathbf{b}_1, \dots, \mathbf{b}_p)$  une base orthonormale de  $\mathbb{R}^p$ . Alors

$$\mathbf{x}_k - \bar{\mathbf{x}} = W_{k,1}\mathbf{b}_1 + W_{k,2}\mathbf{b}_2 + \dots + W_{k,p}\mathbf{b}_p,$$

et pour tout  $1 \leq q \leq p$

$$\begin{aligned} \sum_{k=1}^n \left\| (\mathbf{x}_k - \bar{\mathbf{x}}) - \left( \sum_{i=1}^q W_{k,i} \mathbf{b}_i \right) \right\|^2 \\ \geq \sum_{k=1}^n \left\| (\mathbf{x}_k - \bar{\mathbf{x}}) - \left( \sum_{i=1}^q \hat{Y}_{k,i} \hat{\beta}_i \right) \right\|^2. \end{aligned}$$

Considérons le modèle :

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_p X_p + \varepsilon, \text{ avec } E(\varepsilon|\mathbf{X}) = 0$$

à estimer via des données observées  $S_n = (x_1, y_1), \dots, (x_n, y_n)$  dans  $\mathbb{R}^p \times \mathcal{Y}$ ,  $p \geq 1$ , issues d'une suite de variables aléatoires i.i.d.

- ▶ But : remplacer les variables  $X_1, \dots, X_p$  par des variables  $Z_1, \dots, Z_r$  ( $r < p$ )
- ▶  $Z_1, \dots, Z_r$  sont les  $r$  premières composantes principales de l'ACP associées aux variables centrées (pour éviter des problèmes d'hétérogénéité des variances) de  $X_1, \dots, X_p$
- ▶ les  $Z_1, \dots, Z_r$  sont orthogonales entre elles et de normes  $\lambda_1 > \lambda_2 > \dots > \lambda_r$  respectivement

- ▶ Estimateur de  $\beta$ :  $\hat{\beta} = (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T \mathbf{Y}$ .
- ▶  $Cov(\hat{\beta}_i, \hat{\beta}_j) = 1/\lambda_j$  si  $i = j$ , 0 sinon.
- ▶  $r = p$  donne l'estimateur des moindres carrés
- ▶  $r < p$  élimine les composantes de variances faibles ou nulles (et élimine le problème de co-linéarité mais également quand  $n > p$ )
- ▶ Le choix de  $r$  peut se faire par validation croisée
- ▶ Inconvénient : les premières composantes principales ne sont pas forcément corrélées avec la variable réponse  $Y$

Nous avons vu que les composantes principales sont obtenues en calculant les vecteurs propres  $\hat{\boldsymbol{\beta}} = (\hat{\boldsymbol{\beta}}_1, \dots, \hat{\boldsymbol{\beta}}_p)$  de

$$\mathbf{S} = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})'$$

Pour rappel, la première composante empirique est obtenue comme

$$\hat{\boldsymbol{\beta}}_1 := \operatorname{argmax}_{\mathbf{h}} \mathbf{h}' \mathbf{S} \mathbf{h},$$

avec comme contrainte  $\|\mathbf{h}\|^2 = 1$

Gros inconvénient de l'ACP, lorsque  $p = p_n$  est tel que  $p_n/n \rightarrow c > 0$ ,  $\hat{\beta}_1$  n'est pas un estimateur convergent de  $\beta_1$ .

Dans la PCA sparse, on considère

$$\hat{\beta}_{1,\text{sp}}(\rho) := \operatorname{argmax}_{\mathbf{h}} \mathbf{h}'\mathbf{S}\mathbf{h},$$

avec comme contrainte  $\|\mathbf{h}\|^2 = 1$  et  $\operatorname{Card}(\mathbf{h}) \leq k(\rho)$ , où  $\operatorname{Card}(\mathbf{h})$  est le nombre de coefficients non-nuls dans  $\mathbf{h}$ .

```
###  
states <- row.names(USArrests)  
###  
pr.out <- prcomp(USArrests, scale = TRUE)  
###  
names(pr.out)  
###  
pr.out$center  
pr.out$scale  
###  
pr.out$rotation  
###  
dim(pr.out$x)  
###  
biplot(pr.out, scale = 0)  
###  
pr.out$rotation = -pr.out$rotation  
pr.out$x = -pr.out$x
```

```
biplot(pr.out, scale = 0)
###
pr.out$rotation = -pr.out$rotation
pr.out$x = -pr.out$x
biplot(pr.out, scale = 0)
###
pr.out$sdev
###
pr.var <- pr.out$sdev^2
pr.var
###
pve <- pr.var / sum(pr.var)
pve
###
```

Sparse PCA with the "sparsepca" package