

# Reconnaissance des formes

## Analyse Factorielle Discriminante

- Chapitre 3 -

# ANALYSE FACTORIELLE DISCRIMINANTE

## Objectif

---

**Contexte :** Chaque individu  $\mathbf{x}_i$  du tableau  $\mathbf{X}$  est considéré comme un point d'un espace vectoriel  $\mathcal{E}$  de dimension  $p$ .

L'ensemble des  $n$  individus constitue un nuage de points dans  $\mathcal{E}$ .

On suppose que

- $n_1$  individus appartiennent à la classe  $\omega_1$
- $n_2$  individus appartiennent à la classe  $\omega_2$

tel que  $n = n_1 + n_2$ .

**Objectif :** On cherche à projeter les données sur un axe  $\Delta(\mathbf{u})$  de vecteur directeur  $\mathbf{u}$  maximisant la *séparabilité* de  $\omega_1$  et  $\omega_2$ .

La règle de décision s'écrit



$$d(\mathbf{x}) = \begin{cases} \omega_2 & \text{si } \lambda(\mathbf{x}) = \mathbf{u}^\top \mathbf{x} > \lambda_0 \\ \omega_1 & \text{sinon} \end{cases}$$

# ANALYSE FACTORIELLE DISCRIMINANTE

## Objectif

---

**Objectif :** maximiser la séparabilité des données



# ANALYSE FACTORIELLE DISCRIMINANTE

## Mesure de séparabilité

---

**Séparabilité :** Afin de trouver un axe discriminant  $\Delta(\mathbf{u})$ , il convient de définir une mesure de séparabilité.

On note  $\mathbf{m}_1$  et  $\mathbf{m}_2$  les moyennes de chaque classe, soit

$$\mathbf{m}_1 = \frac{1}{n_1} \sum_{\mathbf{x} \in \omega_1} \mathbf{x} \quad \mathbf{m}_2 = \frac{1}{n_2} \sum_{\mathbf{x} \in \omega_2} \mathbf{x}$$

**Solution (mauvaise) par l'exemple :** On pourrait, par exemple, considérer l'écart quadratique entre les moyennes projetées de chaque classe

$$J(\mathbf{u}) = (\mathbf{u}^\top [\mathbf{m}_1 - \mathbf{m}_2])^2 = (\mu_1 - \mu_2)^2$$

Les figures précédentes montrent qu'il convient de prendre en compte la dispersion des classes.

# ANALYSE FACTORIELLE DISCRIMINANTE

## Discriminant de Fisher

---

**Critère utilisé :** Le critère de Fisher suggère de maximiser l'écart inter-classe, normalisé par une mesure de la dispersion intra-classe.

Le discriminant linéaire de Fisher est défini par  $\lambda(\mathbf{x}) = \mathbf{u}^\top \mathbf{x}$ , où  $\mathbf{u}$  maximise le critère dit de Fisher donné par

$$J(\mathbf{u}) = \frac{(\mu_1 - \mu_2)^2}{p_1 \sigma_1^2 + p_2 \sigma_2^2}$$

avec

$$\mu_i = \mathbf{u}^\top \mathbf{m}_i$$


$$\sigma_i^2 = \frac{1}{n_i} \sum_{\mathbf{x} \in \omega_i} (\mathbf{u}^\top [\mathbf{x}_i - \mathbf{m}_i])^2$$

$$p_i = \frac{n_i}{n}$$

# ANALYSE FACTORIELLE DISCRIMINANTE

Discriminant de Fisher

---



# ANALYSE FACTORIELLE DISCRIMINANTE

## Discriminant de Fisher

---

▷ On définit les quantités suivantes dans l'espace des individus

$$\Sigma_i = \frac{1}{n_i} \sum_{\mathbf{x} \in \omega_i} (\mathbf{x} - \mathbf{m}_i) (\mathbf{x} - \mathbf{m}_i)^\top$$

$$\Sigma_w = p_1 \Sigma_1 + p_2 \Sigma_2$$

La matrice  $\Sigma_w$  est appelée matrice de dispersion intra-classe

▷ On peut exprimer  $\Sigma_w$  en fonction de  $\sigma_1^2$  et  $\sigma_2^2$ . En effet

$$\begin{aligned} \sigma_i^2 &= \frac{1}{n_i} \sum_{\mathbf{x} \in \omega_i} \mathbf{u}^\top (\mathbf{x} - \mathbf{m}_i) (\mathbf{x} - \mathbf{m}_i)^\top \mathbf{u} \\ &= \mathbf{u}^\top \Sigma_i \mathbf{u} \end{aligned}$$

En conséquence, on a

$$p_1 \sigma_1^2 + p_2 \sigma_2^2 = \mathbf{u}^\top \Sigma_w \mathbf{u}$$

# ANALYSE FACTORIELLE DISCRIMINANTE

## Discriminant de Fisher

---

▷ On définit les quantités suivantes dans l'espace des individus

$$\Sigma_b = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^\top$$

La matrice  $\Sigma_b$  est appelée matrice de dispersion inter-classe

**Remarque** : la matrice  $\Sigma_b$  est de rang 1.

▷ On peut exprimer  $\Sigma_b$  en fonction de  $\mu_1$  et  $\mu_2$ . En effet

$$\begin{aligned}(\mu_1 - \mu_2)^2 &= [\mathbf{u}^\top (\mathbf{m}_1 - \mathbf{m}_2)]^2 \\ &= \mathbf{u}^\top \Sigma_b \mathbf{u}\end{aligned}$$



# ANALYSE FACTORIELLE DISCRIMINANTE

## Discriminant de Fisher

---

**Définition :** Le critère de Fisher s'exprime ainsi :

$$J(\mathbf{u}) = \frac{\mathbf{u}^\top \boldsymbol{\Sigma}_b \mathbf{u}}{\mathbf{u}^\top \boldsymbol{\Sigma}_w \mathbf{u}}$$

**Maximisation :** On calcule le gradient de  $J(\mathbf{u})$ , qu'on annule ensuite

$$\begin{aligned}\nabla J(\mathbf{u}) &= (\mathbf{u}^\top \boldsymbol{\Sigma}_w \mathbf{u}) \nabla \{\mathbf{u}^\top \boldsymbol{\Sigma}_b \mathbf{u}\} - (\mathbf{u}^\top \boldsymbol{\Sigma}_b \mathbf{u}) \nabla \{\mathbf{u}^\top \boldsymbol{\Sigma}_w \mathbf{u}\} \\ &= 2(\mathbf{u}^\top \boldsymbol{\Sigma}_w \mathbf{u}) \boldsymbol{\Sigma}_b \mathbf{u} - 2(\mathbf{u}^\top \boldsymbol{\Sigma}_b \mathbf{u}) \boldsymbol{\Sigma}_w \mathbf{u}\end{aligned}$$

$$\nabla J(\mathbf{u}) = 0 \quad \Rightarrow \quad (\mathbf{u}^\top \boldsymbol{\Sigma}_w \mathbf{u}) \boldsymbol{\Sigma}_b \mathbf{u} = (\mathbf{u}^\top \boldsymbol{\Sigma}_b \mathbf{u}) \boldsymbol{\Sigma}_w \mathbf{u}$$

En divisant chaque membre par  $(\mathbf{u}^\top \boldsymbol{\Sigma}_w \mathbf{u})$ , on aboutit à

$$\boxed{\boldsymbol{\Sigma}_w^{-1} \boldsymbol{\Sigma}_b \mathbf{u} = J(\mathbf{u}) \mathbf{u}}$$

# ANALYSE FACTORIELLE DISCRIMINANTE

## Discriminant de Fisher

---

**Problème :** Pour maximiser  $J(\mathbf{u})$ , il convient de résoudre

$$\Sigma_w^{-1} \Sigma_b \mathbf{u} = J(\mathbf{u}) \mathbf{u}$$

▷ On sait que  $\Sigma_b = (\mathbf{m}_1 - \mathbf{m}_2) (\mathbf{m}_1 - \mathbf{m}_2)^\top$ . En remplaçant ci-dessus, on obtient

$$J(\mathbf{u}) \mathbf{u} = \Sigma_w^{-1} (\mathbf{m}_1 - \mathbf{m}_2) \underbrace{(\mathbf{m}_1 - \mathbf{m}_2)^\top \mathbf{u}}_{\text{constante}}$$

▷ A une constante près, ceci implique que :

$$\boxed{\mathbf{u} = \Sigma_w^{-1} (\mathbf{m}_1 - \mathbf{m}_2)}$$

Le discriminant  $\lambda(\mathbf{x}) = \mathbf{u}^\top \mathbf{x}$  correspondant est dit *discriminant de Fisher* (1936).

# ANALYSE FACTORIELLE DISCRIMINANTE


## Exemple

**Données :** On considère les deux classes d'individus dans  $\mathbb{R}^2$  suivantes :

$$\omega_1 = \{(4, 1); (2, 4); (2, 3); (3, 6); (4, 4)\}$$

$$\omega_2 = \{(9, 10); (6, 8); (9, 5); (8, 7); (10, 8)\}$$

$$\Rightarrow \quad \mathbf{u} = (1.76, 0.75)^\top$$



# CRITÈRES DU SECOND ORDRE

## Taxonomie

---

Les critères *du second ordre*, tels que le critère de Fisher se contentent d'une quantité d'information modeste, limitée aux 2 premiers moments de  $\lambda(\mathbf{x})$  :

$$\mu_i = \frac{1}{n_i} \sum_{\mathbf{x} \in \omega_i} \lambda(\mathbf{x}) = \mathbf{u}^\top \mathbf{m}_i - \lambda_0$$

$$\sigma_i^2 = \frac{1}{n_i} \sum_{\mathbf{x} \in \omega_i} (\lambda(\mathbf{x}) - \mu_i)^2 = \mathbf{u}^\top \boldsymbol{\Sigma}_i \mathbf{u}$$

**Exemple** : le rapport signal-sur-bruit généralisé

$$J_{\text{rsbg}}(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2) = \frac{(\mu_1 - \mu_2)^2}{\rho \sigma_1^2 + (1 - \rho) \sigma_2^2}.$$

Il se décline suivant le critère de Fisher ( $\rho = p_1$ ), la déflexion ( $\rho = 1/2$ ) et le rapport signal-sur-bruit ( $\rho = 1$ ).

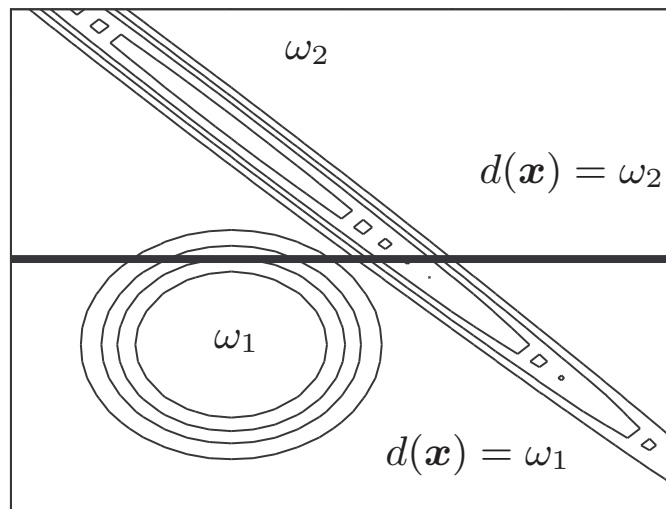
# CRITÈRES DU SECOND ORDRE

## Choix optimum du critère


---

Le choix d'un critère du second ordre constitue un problème crucial car le paramètre  $\rho$  influe largement sur les performances :

rapport signal-sur-bruit ( $\rho = 1$ )



déflexion ( $\rho = 1/2$ )



## CRITÈRES DU SECOND ORDRE

Choix optimum du critère

---

Soit  $\lambda(\mathbf{x})$  la statistique linéaire définie par  $\lambda(\mathbf{x}) = \mathbf{u}^\top \mathbf{x} - \lambda_0$ . Soit  $J(\eta_1, \eta_2, \sigma_1^2, \sigma_2^2)$  un critère du second ordre, ne dépendant donc que des variables suivantes :

$$\mu_i = \frac{1}{n_i} \sum_{\mathbf{x} \in \omega_i} \lambda(\mathbf{x}) = \mathbf{u}^\top \mathbf{m}_i - \lambda_0$$

$$\sigma_i^2 = \frac{1}{n_i} \sum_{\mathbf{x} \in \omega_i} (\lambda(\mathbf{x}) - \mu_i)^2 = \mathbf{u}^\top \boldsymbol{\Sigma}_i \mathbf{u}$$

avec  $\mathbf{m}_i = \frac{1}{n_i} \sum_{\mathbf{x} \in \omega_i} \mathbf{x}$  et  $\boldsymbol{\Sigma}_i = \frac{1}{n_i} \sum_{\mathbf{x} \in \omega_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^\top$ .

**Objectif :**

Rechercher  $\mathbf{u}$  et  $\lambda_0$  maximisant  $J(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2)$  sans expression du critère

## CRITÈRES DU SECOND ORDRE

Choix optimum du critère

---

Les dérivés partielles de  $J$  par rapport à  $\mathbf{u}$  et  $\lambda_0$  doivent être nulles, c'est-à-dire

$$\begin{cases} \frac{\partial J}{\partial \mathbf{u}} = \frac{\partial J}{\partial \sigma_1^2} \cdot \frac{\partial \sigma_1^2}{\partial \mathbf{u}} + \frac{\partial J}{\partial \sigma_2^2} \cdot \frac{\partial \sigma_2^2}{\partial \mathbf{u}} + \frac{\partial J}{\partial \mu_1} \cdot \frac{\partial \mu_1}{\partial \mathbf{u}} + \frac{\partial J}{\partial \mu_2} \cdot \frac{\partial \mu_2}{\partial \mathbf{u}} = 0 \\ \frac{\partial J}{\partial \lambda_0} = \frac{\partial J}{\partial \sigma_1^2} \cdot \frac{\partial \sigma_1^2}{\partial \lambda_0} + \frac{\partial J}{\partial \sigma_2^2} \cdot \frac{\partial \sigma_2^2}{\partial \lambda_0} + \frac{\partial J}{\partial \mu_1} \cdot \frac{\partial \mu_1}{\partial \lambda_0} + \frac{\partial J}{\partial \mu_2} \cdot \frac{\partial \mu_2}{\partial \lambda_0} = 0, \end{cases}$$

où les dérivées partielles de  $\mu_i$  et  $\sigma_i^2$  par rapport à  $\mathbf{u}$  et  $\lambda_0$  sont données par

$$\frac{\partial \sigma_i^2}{\partial \mathbf{u}} = 2 \Sigma_i \mathbf{u}, \quad \frac{\partial \mu_i}{\partial \mathbf{u}} = \mathbf{m}_i, \quad \frac{\partial \sigma_i^2}{\partial \lambda_0} = 0, \quad \frac{\partial \mu_i}{\partial \lambda_0} = -1.$$

Ces résultats permettent de réécrire le système précédent ainsi

$$\begin{cases} 2 \left[ \frac{\partial J}{\partial \sigma_1^2} \Sigma_1 + \frac{\partial J}{\partial \sigma_2^2} \Sigma_2 \right] \mathbf{u} = - \left[ \frac{\partial J}{\partial \mu_1} \mathbf{m}_1 + \frac{\partial J}{\partial \mu_2} \mathbf{m}_2 \right] \\ \frac{\partial J}{\partial \mu_1} + \frac{\partial J}{\partial \mu_2} = 0. \end{cases}$$

# CRITÈRES DU SECOND ORDRE

Choix optimum du critère

---

En introduisant la deuxième équation dans la première, et en notant que  $\mathbf{u}$  peut être défini à un coefficient multiplicatif près, on aboutit au système linéaire

$$[\rho \Sigma_1 + (1 - \rho) \Sigma_2] \mathbf{u} = (\mathbf{m}_2 - \mathbf{m}_1),$$

avec

$$\rho = \frac{\frac{\partial J}{\partial \sigma_1^2}}{\frac{\partial J}{\partial \sigma_1^2} + \frac{\partial J}{\partial \sigma_2^2}}.$$

**Remarque :** On a  $0 \leq \rho \leq 1$  si  $J(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2)$  varie dans le même sens par rapport à  $\sigma_1^2$  et  $\sigma_2^2$  (dérivées de même signe). Cette condition est raisonnable.

**Conclusion.** Ce résultat est particulièrement intéressant puisqu'il établit que l'expression de  $J(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2)$  n'intervient dans  $\mathbf{u}$  que par l'intermédiaire de  $\rho$ .



# CRITÈRES DU SECOND ORDRE

Choix optimum du critère

---

## Algorithme de la méthode

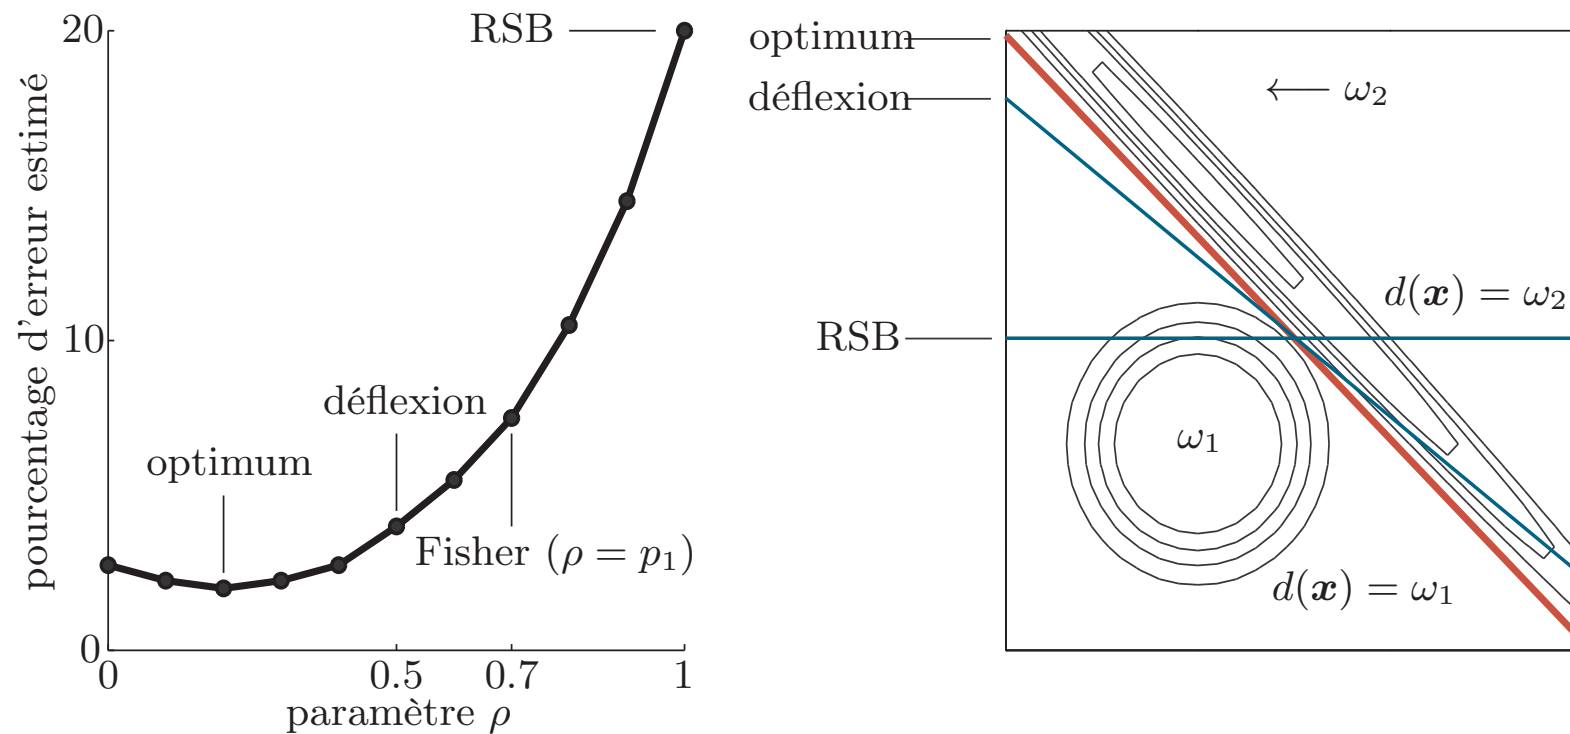
---

1. Initialiser  $\rho$  à 0
  2. Tant que  $\rho \leq 1$ , répéter
    - ▷ résoudre  $[\rho\Sigma_1 + (1 - \rho)\Sigma_2] \mathbf{u} = (\mathbf{m}_2 - \mathbf{m}_1)$  pour obtenir  $\mathbf{u}_\rho$
    - ▷ déterminer le seuil  $\lambda_{\rho,0}$  minimisant par exemple  $P_e(d_\rho)$
    - ▷ mise à jour de  $\rho$ :  $\rho \leftarrow \rho + \Delta\rho$ , avec  $\Delta\rho$  préalablement choisi
  3. Sélectionner le meilleur détecteur  $d_\rho$  obtenu
-

# OPTIMISATION DES CRITÈRES DU SECOND ORDRE

## Choix optimum du critère

Le classifieur obtenu par la méthode précédente est au moins aussi performant que ceux résultant de la maximisation du rapport signal-sur-bruit, etc. En effet, il leur correspond à chacun une valeur particulière de  $\rho$ .



# OPTIMISATION DES CRITÈRES DU SECOND ORDRE

## Choix optimum du critère

---

Le calcul du paramètre  $\rho$  correspondant au rapport signal-sur-bruit conduit au résultat connu suivant :

$$\mathbf{u}_{\text{rsb}} = \boldsymbol{\Sigma}_1^{-1}(\mathbf{m}_2 - \mathbf{m}_1),$$

car  $\rho_{\text{rsb}} = 1$ . De façon analogue, on établit pour la déflexion et le critère de Fisher :

$$\mathbf{u}_{\text{deflex}} = 2(\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2)^{-1}(\mathbf{m}_2 - \mathbf{m}_1)$$

$$\mathbf{u}_{\text{Fisher}} = (p_1 \boldsymbol{\Sigma}_1 + p_2 \boldsymbol{\Sigma}_2)^{-1}(\mathbf{m}_2 - \mathbf{m}_1),$$

car  $\rho_{\text{deflex}} = 1/2$  et  $\rho_{\text{Fisher}} = p_1$ .

# ANALYSE FACTORIELLE DISCRIMINANTE

## Cas multi-classe

---

### Généralisation du critère de Fisher à $C$ classes :

On cherche  $(C - 1)$  projections  $\lambda_i(\mathbf{x}) = \mathbf{u}_i^\top \mathbf{x}$  à partir de  $(C - 1)$  vecteurs  $\mathbf{u}_i$

On range les vecteurs  $\mathbf{u}_i$  dans la matrice  $\mathbf{U}$ , soit  $\boldsymbol{\lambda}(\mathbf{x}) = \mathbf{U}^\top \mathbf{x}$ .

### Notation :

On généralise la dispersion intra-classe comme ceci

$$\boldsymbol{\Sigma}_w = \sum_{i=1}^C \boldsymbol{\Sigma}_i$$


et la dispersion inter-classe comme cela

$$\boldsymbol{\Sigma}_b = \frac{1}{n} \sum_{i=1}^C n_i (\mathbf{m}_i - \mathbf{m}) (\mathbf{m}_i - \mathbf{m})^\top$$

# ANALYSE FACTORIELLE DISCRIMINANTE

Cas multi-classe

---



# ANALYSE FACTORIELLE DISCRIMINANTE

## Cas multi-classe

---

**Définition :** Dans le cas multi-classe, le critère de Fisher s'exprime ainsi

$$J(\mathbf{U}) = \frac{|\mathbf{U}^\top \boldsymbol{\Sigma}_b \mathbf{U}|}{|\mathbf{U}^\top \boldsymbol{\Sigma}_w \mathbf{U}|}$$

**Maximisation :** La solution  $\mathbf{U} = [\mathbf{u}_1, \dots, \mathbf{u}_{C-1}]$  du problème est obtenue en résolvant le problème aux valeurs propres généralisé suivant

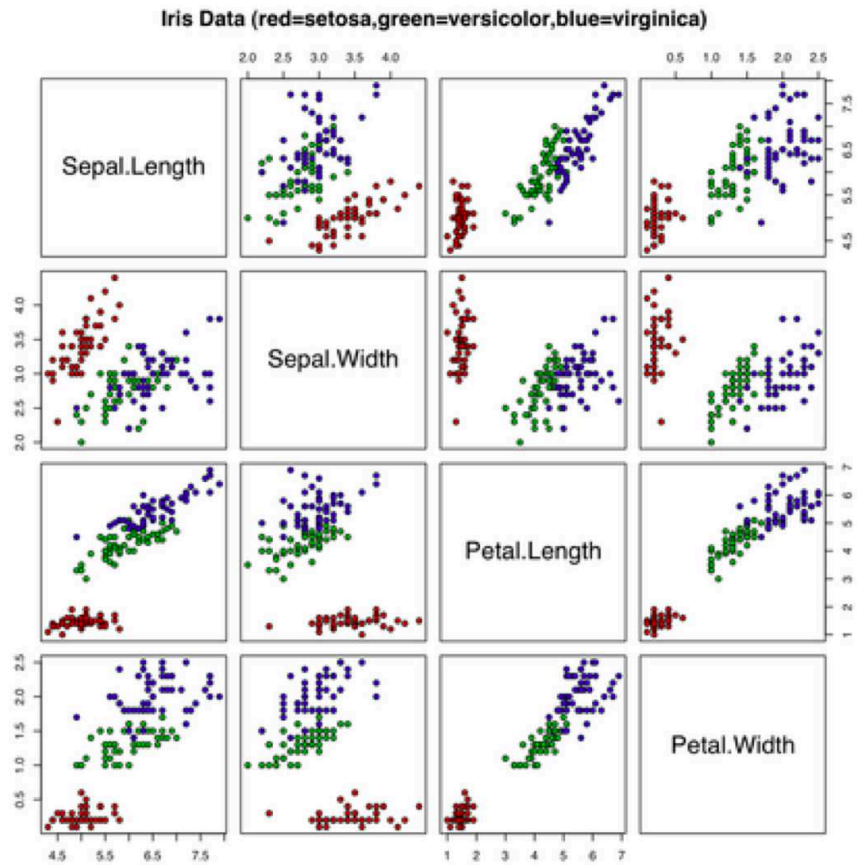
$$\boxed{(\boldsymbol{\Sigma}_b - \lambda_i \boldsymbol{\Sigma}_w) \mathbf{u}_i = 0}$$

pour  $i = 1, \dots, C - 1$ .

**Notes :** Les directions de projection  $\mathbf{u}_i$  correspondent aux vecteurs propres associés aux plus grandes valeurs propres de  $\boldsymbol{\Sigma}_w^{-1} \boldsymbol{\Sigma}_b$ . Au plus  $C - 1$  valeurs propres sont non-nulles car  $\text{rang}(\boldsymbol{\Sigma}_b) = C - 1$ .

# ANALYSE FACTORIELLE DISCRIMINANTE

Cas multi-classe



# ANALYSE FACTORIELLE DISCRIMINANTE

Cas multi-classe

---

LDA: iris projection onto the first 2 linear discriminants

