

El enfoque de suficiencia en la reducción de dimensiones para el reconocimiento de patrones

Diego Tomassi

Trabajo conjunto con Liliana Forzani y Diego Milone



11 de junio de 2010

Organización

- 1 Introducción
- 2 Antecedentes
- 3 El enfoque de reducción suficiente de dimensiones
- 4 Simulaciones
- 5 Comentarios finales

Organización

- 1 Introducción
- 2 Antecedentes
- 3 El enfoque de reducción suficiente de dimensiones
- 4 Simulaciones
- 5 Comentarios finales

El problema de clasificación

Ejemplos

- Detección de patologías para asistencia de diagnóstico médico.
- Reconocimiento de rostros y aplicaciones biométricas en general.
- Reconocimiento de escritura manuscrita (tablet PC).
- Reconocimiento del habla.
- Filtros anti-spam.

El problema de clasificación

Sean $Y = 1, 2, \dots, h$ las clases y $\mathbf{X} \in \mathbb{R}^p$ las características.

Un clasificador es una función $f : \mathbb{R}^p \rightarrow \{1, 2, \dots, h\}$ tal que la predicción $\hat{Y} = f(\mathbf{X})$ tiene una mínima probabilidad de error.

El problema de clasificación

Sean $Y = 1, 2, \dots, h$ las clases y $\mathbf{X} \in \mathbb{R}^p$ las características.

Un clasificador es una función $f : \mathbb{R}^p \rightarrow \{1, 2, \dots, h\}$ tal que la predicción $\hat{Y} = f(\mathbf{X})$ tiene una mínima probabilidad de error.

Si conocemos $p(Y, \mathbf{X})$ la regla óptima es

$$f(\mathbf{X}) = \arg \max_y p(Y = y | \mathbf{X})$$

El problema de clasificación

- Suponemos modelos paramétricos para $p(\mathbf{X}|Y = y)$.
- Usamos un conjunto de ejemplos $\{(Y_i, \mathbf{X}_i)\}$ para estimar.

El problema de clasificación

- Suponemos modelos paramétricos para $p(\mathbf{X}|Y = y)$.
- Usamos un conjunto de ejemplos $\{(Y_i, \mathbf{X}_i)\}$ para estimar.

Definidos los modelos, el diseño del clasificador se reduce a un problema de estimación de parámetros.

El problema de clasificación

- Suponemos modelos paramétricos para $p(\mathbf{X}|Y = y)$.
- Usamos un conjunto de ejemplos $\{(Y_i, \mathbf{X}_i)\}$ para estimar.

Definidos los modelos, el diseño del clasificador se reduce a un problema de estimación de parámetros.

¿Qué modelos se usan?

- Gaussianas
- Mezclas de Gaussianas
- Modelos ocultos de Markov
- ...

El problema de clasificación

- Suponemos modelos paramétricos para $p(\mathbf{X}|Y = y)$.
- Usamos un conjunto de ejemplos $\{(Y_i, \mathbf{X}_i)\}$ para estimar.

Definidos los modelos, el diseño del clasificador se reduce a un problema de estimación de parámetros.

¿Qué modelos se usan?

- Gaussianas

$$\mathbf{X}|Y = y \sim \mathcal{N}(\mathbf{X}|\mu_y, \Delta_y)$$

Reducción de dimensiones

¿Para qué?

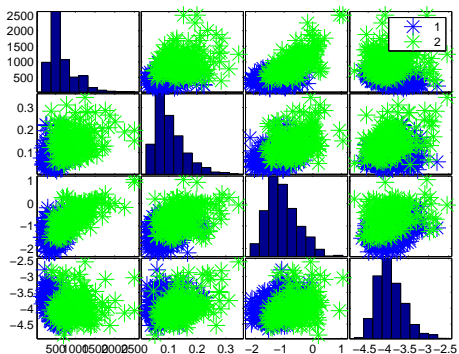
- Disminuir varianza de estimadores.

Reducción de dimensiones

¿Para qué?

- Disminuir varianza de estimadores.
- Facilitar la decisión del clasificador.

Reducción de dimensiones



Reducción de dimensiones



Reducción de dimensiones

¿Para qué?

- Facilitar la decisión del clasificador.
- Disminuir varianza de estimadores.
- Reducir costo computacional.

Reducción de dimensiones

¿Para qué?

- Facilitar la decisión del clasificador.
- Disminuir varianza de estimadores.
- Reducir costo computacional.

¿Qué buscamos?

Una reducción $R : \mathbb{R}^p \rightarrow \mathbb{R}^d, d \leq p$ tal que para cada \mathbf{X}

$$p(Y = y|R(\mathbf{X})) = p(Y = y|\mathbf{X})$$

Organización

- 1 Introducción
- 2 Antecedentes**
- 3 El enfoque de reducción suficiente de dimensiones
- 4 Simulaciones
- 5 Comentarios finales

Métodos usados comúnmente

Consideremos:

- Reducciones lineales $R(\mathbf{X}) = \boldsymbol{\theta}^T \mathbf{X}$, con $\boldsymbol{\theta} \in \mathbb{R}^{p \times d}$.
- Estimación de máxima verosimilitud.

Métodos usados comúnmente

- Análisis discriminante lineal (LDA)

Métodos usados comúnmente

- Análisis discriminante lineal (LDA)
- Análisis discriminante lineal para modelos heteroscedásticos (HLDA).

Sea $\Theta = (\boldsymbol{\theta} \ \boldsymbol{\theta}_0) \in \mathbb{R}^{p \times p}$, $\boldsymbol{\theta} \in \mathbb{R}^{p \times d}$, $\boldsymbol{\theta}^T \boldsymbol{\theta} = \mathbf{I}_d$, $\boldsymbol{\theta}^T \boldsymbol{\theta}_0 = \mathbf{0}$.

Supongamos $\Theta^T \mathbf{X} \sim \mathcal{N}(\boldsymbol{\mu}_y^*, \Delta_y^*)$, con

$$\boldsymbol{\mu}_y^* = \begin{pmatrix} \boldsymbol{\theta}^T \boldsymbol{\mu}_y \\ \boldsymbol{\theta}_0^T \boldsymbol{\mu} \end{pmatrix} \qquad \Delta_y^* = \begin{pmatrix} \Omega_y & \mathbf{0} \\ \mathbf{0} & \Omega_0 \end{pmatrix}$$

Métodos usados comúnmente

- Análisis discriminante lineal (LDA)
- Análisis discriminante lineal para modelos heteroscedásticos (HLDA).

Sea $\Theta = (\boldsymbol{\theta} \ \boldsymbol{\theta}_0) \in \mathbb{R}^{p \times p}$, $\boldsymbol{\theta} \in \mathbb{R}^{p \times d}$, $\boldsymbol{\theta}^T \boldsymbol{\theta} = \mathbf{I}_d$, $\boldsymbol{\theta}^T \boldsymbol{\theta}_0 = \mathbf{0}$.

Supongamos $\Theta^T \mathbf{X} \sim \mathcal{N}(\boldsymbol{\mu}_y^*, \Delta_y^*)$, con

$$\boldsymbol{\mu}_y^* = \begin{pmatrix} \boldsymbol{\theta}^T \boldsymbol{\mu}_y \\ \boldsymbol{\theta}_0^T \boldsymbol{\mu} \end{pmatrix} \quad \Delta_y^* = \begin{pmatrix} \Omega_y & \mathbf{0} \\ \mathbf{0} & \Omega_0 \end{pmatrix}$$

HLDA busca Θ que maximiza

$$\mathcal{L}_{\text{HLDA}}(\boldsymbol{\theta}) = -\frac{n}{2} \log |\boldsymbol{\theta}^T \tilde{\Sigma}^{-1} \boldsymbol{\theta}| - \frac{1}{2} \sum_{y=1}^h n_y \log |\boldsymbol{\theta}^T \tilde{\Delta}_y \boldsymbol{\theta}|.$$

Nos preguntamos...

- ¿Se satisface $p(Y = y|\boldsymbol{\theta}_{\text{HLDA}}^T \mathbf{X}) = p(Y = y|\mathbf{X})$ para todo \mathbf{X} ?
- ¿Es $\text{span}(\boldsymbol{\theta}_{\text{HLDA}})$ el menor subespacio que conserva la información?

Organización

- 1 Introducción
- 2 Antecedentes
- 3 El enfoque de reducción suficiente de dimensiones**
- 4 Simulaciones
- 5 Comentarios finales

Resultados conocidos

Cook y Yin, 2001: para $\mathbf{X}|Y = y \sim \mathcal{N}(\mu_y, \Delta_y)$:

$$f(\boldsymbol{\theta}^T \mathbf{X}) = f(\mathbf{X}) \Leftrightarrow X|(Y, \boldsymbol{\theta}^T \mathbf{X}) \sim \mathbf{X}|\boldsymbol{\theta}^T \mathbf{X}$$

Resultados conocidos

Cook y Yin, 2001: para $\mathbf{X}|Y = y \sim \mathcal{N}(\mu_y, \Delta_y)$:

$$f(\boldsymbol{\theta}^T \mathbf{X}) = f(\mathbf{X}) \Leftrightarrow \mathbf{X}|(Y, \boldsymbol{\theta}^T \mathbf{X}) \sim \mathbf{X}|\boldsymbol{\theta}^T \mathbf{X}$$

Resultados conocidos

Cook y Yin, 2001: para $\mathbf{X}|Y = y \sim \mathcal{N}(\mu_y, \Delta_y)$:

$$f(\boldsymbol{\theta}^T \mathbf{X}) = f(\mathbf{X}) \Leftrightarrow \mathbf{X}|(Y, \boldsymbol{\theta}^T \mathbf{X}) \sim \mathbf{X}|\boldsymbol{\theta}^T \mathbf{X}$$

Cook y Forzani, 2008:

Supongamos que $\mathbf{X}|Y = y \sim \mathcal{N}(\mu_y, \Delta_y)$, $y = 1, 2, \dots, h$. Sea $\Delta = E(\Delta_y)$, $\boldsymbol{\theta} \in \mathbb{R}^{p \times d}$ una matriz semiortogonal y sea $(\boldsymbol{\theta} \boldsymbol{\theta}_0) \in \mathbb{R}^{p \times p}$ una matriz ortogonal. $\boldsymbol{\theta}^T \mathbf{X}$ es una reducción lineal suficiente si y sólo si

- 1 $\text{span}(\mu_y - \mu) \subseteq \Delta \text{span}(\boldsymbol{\theta})$.
- 2 $\boldsymbol{\theta}_0^T \Delta_y^{-1}$ es constante.

Resultados conocidos

Cook y Yin, 2001: para $\mathbf{X}|Y = y \sim \mathcal{N}(\mu_y, \Delta_y)$:

$$f(\boldsymbol{\theta}^T \mathbf{X}) = f(\mathbf{X}) \Leftrightarrow X|(Y, \boldsymbol{\theta}^T \mathbf{X}) \sim \mathbf{X}|\boldsymbol{\theta}^T \mathbf{X}$$

Cook y Forzani, 2008:

Supongamos que $\mathbf{X}|Y = y \sim \mathcal{N}(\mu_y, \Delta_y)$, $y = 1, 2, \dots, h$. Sea $\Delta = E(\Delta_y)$, $\boldsymbol{\theta}$ una matriz semiortogonal y sea $(\boldsymbol{\theta} \boldsymbol{\theta}_0) \in \mathbb{R}^{p \times p}$ una matriz ortogonal. $\boldsymbol{\theta}^T \mathbf{X}$ es una reducción lineal suficiente si y sólo si

$$\begin{aligned} \mu_y &= \mu + \Delta \boldsymbol{\theta} \nu_y, \\ \Delta_y &= \Delta + \Delta \boldsymbol{\theta} T_y \boldsymbol{\theta}^T \Delta. \end{aligned}$$

con $E(\nu_y) = 0$ y $E(T_y) = 0$.

Estimador MLE para θ

El estimador de máxima verosimilitud θ_{LAD} que maximiza la función

$$\mathcal{L}_{LAD}(\theta) = \text{const} + \frac{n}{2} \log |\theta^T \tilde{\Sigma} \theta| - \frac{1}{2} \sum_y n_y \log |\theta^T \tilde{\Delta}_y \theta|,$$

provee una reducción lineal suficiente mínima $\theta_{LAD}^T \mathbf{X}$.

HLDA bajo el enfoque de suficiencia

Recordemos que en HLDA $\Theta^T \mathbf{X} \sim \mathcal{N}(\mu_y^*, \Delta_y^*)$

$$\mu_y^* = \begin{pmatrix} \boldsymbol{\theta}^T \mu_y \\ \boldsymbol{\theta}_0^T \mu \end{pmatrix} \quad \Delta_y^* = \begin{pmatrix} \Omega_y & \mathbf{0} \\ \mathbf{0} & \Omega_0 \end{pmatrix}$$

$$\mathbf{X}|Y = y \sim \mathcal{N}(\mu + \boldsymbol{\theta}\gamma_y, \boldsymbol{\theta}\Omega_y\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T).$$

Si $\Omega = E(\Omega_y)$, $\Delta = \boldsymbol{\theta}\Omega\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T$. Entonces $\Delta\boldsymbol{\theta} = \boldsymbol{\theta}\mathbf{A}$ y

- $\mu_y = \mu + \boldsymbol{\theta}\gamma_y = \mu + \boldsymbol{\theta}\mathbf{A}\nu_y = \mu + \Delta\boldsymbol{\theta}\nu_y$.
- $\Delta_y - \Delta = \boldsymbol{\theta}(\Omega_y - \Omega)\boldsymbol{\theta}^T = \boldsymbol{\theta}\mathbf{A}T_y\mathbf{A}^T\boldsymbol{\theta}^T = \Delta\boldsymbol{\theta}T_y\boldsymbol{\theta}^T\Delta$.

Luego, $\boldsymbol{\theta} = \boldsymbol{\theta}_{\text{HLDA}}$ es una reducción suficiente bajo este modelo para $\mathbf{X}|Y = y$.

HLDA bajo el enfoque de suficiencia

Recordemos que en HLDA $\Theta^T \mathbf{X} \sim \mathcal{N}(\mu_y^*, \Delta_y^*)$

$$\mu_y^* = \begin{pmatrix} \boldsymbol{\theta}^T \mu_y \\ \boldsymbol{\theta}_0^T \mu \end{pmatrix} \quad \Delta_y^* = \begin{pmatrix} \Omega_y & \mathbf{0} \\ \mathbf{0} & \Omega_0 \end{pmatrix}$$

$$\mathbf{X}|Y = y \sim \mathcal{N}(\mu + \boldsymbol{\theta}\gamma_y, \boldsymbol{\theta}\Omega_y\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T).$$

Si $\Omega = E(\Omega_y)$, $\Delta = \boldsymbol{\theta}\Omega\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T$. Entonces $\Delta\boldsymbol{\theta} = \boldsymbol{\theta}\mathbf{A}$ y

- $\mu_y = \mu + \boldsymbol{\theta}\gamma_y = \mu + \boldsymbol{\theta}\mathbf{A}\nu_y = \mu + \Delta\boldsymbol{\theta}\nu_y$.
- $\Delta_y - \Delta = \boldsymbol{\theta}(\Omega_y - \Omega)\boldsymbol{\theta}^T = \boldsymbol{\theta}\mathbf{A}T_y\mathbf{A}^T\boldsymbol{\theta}^T = \Delta\boldsymbol{\theta}T_y\boldsymbol{\theta}^T\Delta$.

Luego, $\boldsymbol{\theta} = \boldsymbol{\theta}_{\text{HLDA}}$ es una reducción suficiente bajo este modelo para $\mathbf{X}|Y = y$.

HLDA bajo el enfoque de suficiencia

Recordemos que en HLDA $\Theta^T \mathbf{X} \sim \mathcal{N}(\mu_y^*, \Delta_y^*)$

$$\mu_y^* = \begin{pmatrix} \boldsymbol{\theta}^T \mu_y \\ \boldsymbol{\theta}_0^T \mu \end{pmatrix} \quad \Delta_y^* = \begin{pmatrix} \Omega_y & \mathbf{0} \\ \mathbf{0} & \Omega_0 \end{pmatrix}$$

$$\mathbf{X}|Y = y \sim \mathcal{N}(\mu + \boldsymbol{\theta}\gamma_y, \boldsymbol{\theta}\Omega_y\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T).$$

Si $\Omega = E(\Omega_y)$, $\Delta = \boldsymbol{\theta}\Omega\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T$. Entonces $\Delta\boldsymbol{\theta} = \boldsymbol{\theta}\mathbf{A}$ y

- $\mu_y = \mu + \boldsymbol{\theta}\gamma_y = \mu + \boldsymbol{\theta}\mathbf{A}\nu_y = \mu + \Delta\boldsymbol{\theta}\nu_y$.
- $\Delta_y - \Delta = \boldsymbol{\theta}(\Omega_y - \Omega)\boldsymbol{\theta}^T = \boldsymbol{\theta}\mathbf{A}T_y\mathbf{A}^T\boldsymbol{\theta}^T = \Delta\boldsymbol{\theta}T_y\boldsymbol{\theta}^T\Delta$.

Luego, $\boldsymbol{\theta} = \boldsymbol{\theta}_{\text{HLDA}}$ es una reducción suficiente bajo este modelo para $X|Y = y$.

HLDA bajo el enfoque de suficiencia

Recordemos que en HLDA $\Theta^T \mathbf{X} \sim \mathcal{N}(\mu_y^*, \Delta_y^*)$

$$\mu_y^* = \begin{pmatrix} \boldsymbol{\theta}^T \mu_y \\ \boldsymbol{\theta}_0^T \mu \end{pmatrix} \quad \Delta_y^* = \begin{pmatrix} \Omega_y & \mathbf{0} \\ \mathbf{0} & \Omega_0 \end{pmatrix}$$

$$\mathbf{X}|Y = y \sim \mathcal{N}(\mu + \boldsymbol{\theta}\gamma_y, \boldsymbol{\theta}\Omega_y\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T).$$

Si $\Omega = E(\Omega_y)$, $\Delta = \boldsymbol{\theta}\Omega\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T$. Entonces $\Delta\boldsymbol{\theta} = \boldsymbol{\theta}\mathbf{A}$ y

- $\mu_y = \mu + \boldsymbol{\theta}\gamma_y = \mu + \boldsymbol{\theta}\mathbf{A}\nu_y = \mu + \Delta\boldsymbol{\theta}\nu_y$.
- $\Delta_y - \Delta = \boldsymbol{\theta}(\Omega_y - \Omega)\boldsymbol{\theta}^T = \boldsymbol{\theta}\mathbf{A}T_y\mathbf{A}^T\boldsymbol{\theta}^T = \Delta\boldsymbol{\theta}T_y\boldsymbol{\theta}^T\Delta$.

Luego, $\boldsymbol{\theta} = \boldsymbol{\theta}_{\text{HLDA}}$ es una reducción suficiente bajo este modelo para $X|Y = y$.

HLDA bajo el enfoque de suficiencia

Recordemos que en HLDA $\Theta^T \mathbf{X} \sim \mathcal{N}(\mu_y^*, \Delta_y^*)$

$$\mu_y^* = \begin{pmatrix} \boldsymbol{\theta}^T \mu_y \\ \boldsymbol{\theta}_0^T \mu \end{pmatrix} \quad \Delta_y^* = \begin{pmatrix} \Omega_y & \mathbf{0} \\ \mathbf{0} & \Omega_0 \end{pmatrix}$$

$$\mathbf{X}|Y = y \sim \mathcal{N}(\mu + \boldsymbol{\theta}\gamma_y, \boldsymbol{\theta}\Omega_y\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T).$$

Si $\Omega = E(\Omega_y)$, $\Delta = \boldsymbol{\theta}\Omega\boldsymbol{\theta}^T + \boldsymbol{\theta}_0\Omega_0\boldsymbol{\theta}_0^T$. Entonces $\Delta\boldsymbol{\theta} = \boldsymbol{\theta}\mathbf{A}$ y

- $\mu_y = \mu + \boldsymbol{\theta}\gamma_y = \mu + \boldsymbol{\theta}\mathbf{A}\nu_y = \mu + \Delta\boldsymbol{\theta}\nu_y$.
- $\Delta_y - \Delta = \boldsymbol{\theta}(\Omega_y - \Omega)\boldsymbol{\theta}^T = \boldsymbol{\theta}\mathbf{A}T_y\mathbf{A}^T\boldsymbol{\theta}^T = \Delta\boldsymbol{\theta}T_y\boldsymbol{\theta}^T\Delta$.

Luego, $\boldsymbol{\theta} = \boldsymbol{\theta}_{\text{HLDA}}$ es una reducción suficiente bajo este modelo para $X|Y = y$.

HLDA y minimalidad

Cuando Δ_y satisface el modelo de HLDA, el subespacio de reducción estimado, ¿es el menor posible? **No necesariamente.**

Sea $\alpha \in \mathbb{R}^u$ una base para ese subespacio de reducción mínimo.

$\text{span}(\theta) \supseteq \text{span}(\alpha)$ también es un subespacio de reducción suficiente.

En HLDA, θ es una base para el subespacio que contiene a $\text{span}(\alpha)$ tal que $\Delta_y = \theta \Omega_y \theta^T + \theta_0 \Omega_0 \theta_0^T$.

Existe $\mathbf{A} \in \mathbb{R}^{d \times u}$: $\alpha = \theta \mathbf{A}$ y α maximiza

$$\begin{aligned} \mathcal{L}(\theta, \mathbf{A}) = & \text{const} - \frac{n}{2} \log |\theta^T \tilde{\Sigma}^{-1} \theta| - \frac{n}{2} \log |\theta^T \tilde{\Sigma} \theta| - \\ & - \frac{n}{2} \log |\mathbf{A}^T \theta^T \tilde{\Sigma} \theta \mathbf{A}| - \frac{1}{2} \sum_y n_y \log |\mathbf{A}^T \theta^T \tilde{\Delta}_y \theta \mathbf{A}|. \end{aligned}$$

HLDA y minimalidad

Cuando Δ_y satisface el modelo de HLDA, el subespacio de reducción estimado, ¿es el menor posible? **No necesariamente.**

Sea $\alpha \in \mathbb{R}^u$ una base para ese subespacio de reducción mínimo.

$\text{span}(\theta) \supseteq \text{span}(\alpha)$ también es un subespacio de reducción suficiente.

En HLDA, θ es una base para el subespacio que contiene a $\text{span}(\alpha)$ tal que $\Delta_y = \theta \Omega_y \theta^T + \theta_0 \Omega_0 \theta_0^T$.

Existe $\mathbf{A} \in \mathbb{R}^{d \times u}$: $\alpha = \theta \mathbf{A}$ y α maximiza

$$\begin{aligned} \mathcal{L}(\theta, \mathbf{A}) = & \text{const} - \frac{n}{2} \log |\theta^T \tilde{\Sigma}^{-1} \theta| - \frac{n}{2} \log |\theta^T \tilde{\Sigma} \theta| - \\ & - \frac{n}{2} \log |\mathbf{A}^T \theta^T \tilde{\Sigma} \theta \mathbf{A}| - \frac{1}{2} \sum_y n_y \log |\mathbf{A}^T \theta^T \tilde{\Delta}_y \theta \mathbf{A}|. \end{aligned}$$

HLDA y minimalidad

Cuando Δ_y satisface el modelo de HLDA, el subespacio de reducción estimado, ¿es el menor posible? **No necesariamente.**

Sea $\alpha \in \mathbb{R}^u$ una base para ese subespacio de reducción mínimo.

$\text{span}(\theta) \supseteq \text{span}(\alpha)$ también es un subespacio de reducción suficiente.

En HLDA, θ es una base para el subespacio que contiene a $\text{span}(\alpha)$ tal que $\Delta_y = \theta \Omega_y \theta^T + \theta_0 \Omega_0 \theta_0^T$.

Existe $\mathbf{A} \in \mathbb{R}^{d \times u}$: $\alpha = \theta \mathbf{A}$ y α maximiza

$$\begin{aligned} \mathcal{L}(\theta, \mathbf{A}) = & \text{const} - \frac{n}{2} \log |\theta^T \tilde{\Sigma}^{-1} \theta| - \frac{n}{2} \log |\theta^T \tilde{\Sigma} \theta| - \\ & - \frac{n}{2} \log |\mathbf{A}^T \theta^T \tilde{\Sigma} \theta \mathbf{A}| - \frac{1}{2} \sum_y n_y \log |\mathbf{A}^T \theta^T \tilde{\Delta}_y \theta \mathbf{A}|. \end{aligned}$$

HLDA y minimalidad

Cuando Δ_y satisface el modelo de HLDA, el subespacio de reducción estimado, ¿es el menor posible? **No necesariamente.**

Sea $\alpha \in \mathbb{R}^u$ una base para ese subespacio de reducción mínimo.

$\text{span}(\theta) \supseteq \text{span}(\alpha)$ también es un subespacio de reducción suficiente.

En HLDA, θ es una base para el subespacio que contiene a $\text{span}(\alpha)$ tal que $\Delta_y = \theta \Omega_y \theta^T + \theta_0 \Omega_0 \theta_0^T$.

Existe $\mathbf{A} \in \mathbb{R}^{d \times u}$: $\alpha = \theta \mathbf{A}$ y α maximiza

$$\begin{aligned} \mathcal{L}(\theta, \mathbf{A}) = & \text{const} - \frac{n}{2} \log |\theta^T \tilde{\Sigma}^{-1} \theta| - \frac{n}{2} \log |\theta^T \tilde{\Sigma} \theta| - \\ & - \frac{n}{2} \log |\mathbf{A}^T \theta^T \tilde{\Sigma} \theta \mathbf{A}| - \frac{1}{2} \sum_y n_y \log |\mathbf{A}^T \theta^T \tilde{\Delta}_y \theta \mathbf{A}|. \end{aligned}$$

HLDA y minimalidad

Cuando Δ_y satisface el modelo de HLDA, el subespacio de reducción estimado, ¿es el menor posible? **No necesariamente.**

Sea $\alpha \in \mathbb{R}^u$ una base para ese subespacio de reducción mínimo.

$\text{span}(\theta) \supseteq \text{span}(\alpha)$ también es un subespacio de reducción suficiente.

En HLDA, θ es una base para el subespacio que contiene a $\text{span}(\alpha)$ tal que $\Delta_y = \theta \Omega_y \theta^T + \theta_0 \Omega_0 \theta_0^T$.

Existe $\mathbf{A} \in \mathbb{R}^{d \times u} : \alpha = \theta \mathbf{A}$ y α maximiza

$$\begin{aligned} \mathcal{L}(\theta, \mathbf{A}) = & \text{const} - \frac{n}{2} \log |\theta^T \tilde{\Sigma}^{-1} \theta| - \frac{n}{2} \log |\theta^T \tilde{\Sigma} \theta| - \\ & - \frac{n}{2} \log |\mathbf{A}^T \theta^T \tilde{\Sigma} \theta \mathbf{A}| - \frac{1}{2} \sum_y n_y \log |\mathbf{A}^T \theta^T \tilde{\Delta}_y \theta \mathbf{A}|. \end{aligned}$$

Consideraciones

Qué puede heredar HLDA del enfoque de suficiencia?

- Herramientas mejor justificadas para inferir d .
- Eficiencia de cómputo.

Limitaciones

- fijado d , HLDA estima un subespacio de reducción suficiente sólo para una estructura particular de Δ_y .
- $\mathcal{S}_{\text{HLDA}}$ no es invariante ni equivariante ante una transformación de las características \mathbf{X} .

Propaganda: ¡¡deberíamos usar $\theta_{\text{LAD}}!!$

Consideraciones

Qué puede heredar HLDA del enfoque de suficiencia?

- Herramientas mejor justificadas para inferir d .
- Eficiencia de cómputo.

Limitaciones

- fijado d , HLDA estima un subespacio de reducción suficiente sólo para una estructura particular de Δ_y .
- $\mathcal{S}_{\text{HLDA}}$ no es invariante ni equivariante ante una transformación de las características \mathbf{X} .

Propaganda: ¡¡deberíamos usar $\theta_{\text{LAD}}!!$

Consideraciones

Qué puede heredar HLDA del enfoque de suficiencia?

- Herramientas mejor justificadas para inferir d .
- Eficiencia de cómputo.

Limitaciones

- fijado d , HLDA estima un subespacio de reducción suficiente sólo para una estructura particular de Δ_y .
- $\mathcal{S}_{\text{HLDA}}$ no es invariante ni equivariante ante una transformación de las características \mathbf{X} .

Propaganda: ¡¡deberíamos usar $\theta_{\text{LAD}}!!$

Consideraciones

Qué puede heredar HLDA del enfoque de suficiencia?

- Herramientas mejor justificadas para inferir d .
- Eficiencia de cómputo.

Limitaciones

- fijado d , HLDA estima un subespacio de reducción suficiente sólo para una estructura particular de Δ_y .
- $\mathcal{S}_{\text{HLDA}}$ no es invariante ni equivariante ante una transformación de las características \mathbf{X} .

Propaganda: ¡¡deberíamos usar $\theta_{\text{LAD}}!!$

Consideraciones

Qué puede heredar HLDA del enfoque de suficiencia?

- Herramientas mejor justificadas para inferir d .
- Eficiencia de cómputo.

Limitaciones

- fijado d , HLDA estima un subespacio de reducción suficiente sólo para una estructura particular de Δ_y .
- $\mathcal{S}_{\text{HLDA}}$ no es invariante ni equivariante ante una transformación de las características \mathbf{X} .

Propaganda: ¡¡deberíamos usar $\theta_{\text{LAD}}!!$

Consideraciones

Qué puede heredar HLDA del enfoque de suficiencia?

- Herramientas mejor justificadas para inferir d .
- Eficiencia de cómputo.

Limitaciones

- fijado d , HLDA estima un subespacio de reducción suficiente sólo para una estructura particular de Δ_y .
- $\mathcal{S}_{\text{HLDA}}$ no es invariante ni equivariante ante una transformación de las características \mathbf{X} .

Propaganda: ¡¡deberíamos usar $\theta_{\text{LAD}}!!$

Consideraciones

Qué puede heredar HLDA del enfoque de suficiencia?

- Herramientas mejor justificadas para inferir d .
- Eficiencia de cómputo.


Limitaciones

- fijado d , HLDA estima un subespacio de reducción suficiente sólo para una estructura particular de Δ_y .
- $\mathcal{S}_{\text{HLDA}}$ no es invariante ni equivariante ante una transformación de las características \mathbf{X} .

Propaganda: ¡¡deberíamos usar $\theta_{\text{LAD}}!!$


¿Cómo extendemos esto a modelos ocultos de Markov?

Datos secuenciales y modelos ocultos de Markov (HMM)



Datos secuenciales y modelos ocultos de Markov (HMM)

- Las características observadas no son independientes, sino que forman una **secuencia** $\mathbf{X} = \mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_N$.
- Modelamos esas secuencias mediante **modelos ocultos de Markov**.



Reducción suficiente de dimensiones para HMM

¿Cómo son los modelos de las clases ahora?

$$p(\mathbf{X}|\mathcal{Y} = \vartheta) = \sum_{\mathbf{q}} \prod_{t=1}^T b_{q_t}(\mathbf{x}_t) a_{q_{t-1}q_t},$$

Reducción suficiente de dimensiones para HMM

¿Cómo son los modelos de las clases ahora?

$$p(\mathbf{X}|\mathcal{Y} = \vartheta) = \sum_{\mathbf{q}} \prod_{t=1}^T b_{q_t}(\mathbf{x}_t) a_{q_{t-1}q_t},$$

¿Cómo estimamos parámetros?

$$\begin{aligned} \mathcal{Q}(\vartheta, \vartheta^{old}) &= \sum_{\mathbf{q}} p(\mathbf{q}|\mathbf{X}, \vartheta^{old}) \log p(\mathbf{q}, \mathbf{X}|\vartheta) \\ &= \sum_{\mathbf{q}} p(\mathbf{q}|\mathbf{X}, \vartheta^{old}) \times \left\{ \sum_t \log a_{q_{t-1}q_t} + \sum_t \log b_{q_t}(\mathbf{x}_t) \right\} \\ &= \mathcal{Q}_a(\vartheta, \vartheta^{old}) + \mathcal{Q}_b(\vartheta, \vartheta^{old}) \end{aligned}$$

Reducción de dimensiones en HMM

Si $b_y(\mathbf{w}_t) = \mathcal{N}(\mathbf{w}_t | \mu_y, \Delta_y)$

$$\begin{aligned} Q_b(\vartheta, \vartheta^{old}) &= \sum_{y=1}^{N_q} \sum_{t=1}^T p(q_t = y | \mathbf{X}, \vartheta^{old}) \log \mathcal{N}(\mathbf{w}_t | \mu_y, \Delta_y) \\ &= \sum_{y=1}^{N_q} \sum_{t=1}^T \gamma_t(y) \log \mathcal{N}(\mathbf{w}_t | \mu_y, \Delta_y), \end{aligned}$$

Organización

- 1 Introducción
- 2 Antecedentes
- 3 El enfoque de reducción suficiente de dimensiones
- 4 Simulaciones**
- 5 Comentarios finales

Simulaciones


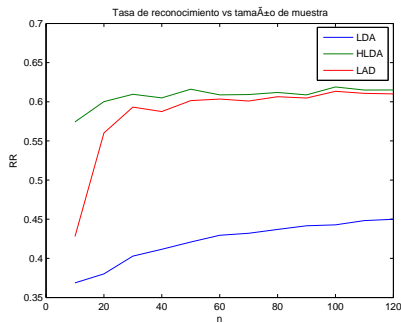


Figura: Tasas de reconocimiento para d conocida. Izq.: datos generados con el modelo de HLDA. Der.: datos generados con el modelo de HLDA y luego multiplicados con una matriz A .

Simulaciones




Figura: Inferencia sobre d cuando los datos corresponden al modelo de HLDA.

Simulaciones





Figura: Inferencia sobre d para los mismo datos, después de multiplicarlos por una matriz \mathbf{A} .

Organización

- 1 Introducción
- 2 Antecedentes
- 3 El enfoque de reducción suficiente de dimensiones
- 4 Simulaciones
- 5 Comentarios finales

muchas gracias