

# Fórmulas de predicción óptima lineal

Antonio Sala Piqueras

Dept. Ing. Sistemas y Automática (DISA)  
Universitat Politècnica de València (UPV)

\*Presentación disponible en:

<http://personales.upv.es/asala/YT/V/preli2.html>

# Presentación

## Motivación:

La predicción óptima lineal (mínima varianza error, no correlado con información) puede obtenerse a partir de fórmulas relacionadas con las medias, varianzas y covarianzas de las variables implicadas.

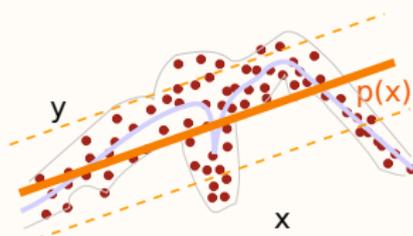
## Objetivos:

Comprender las relaciones entre las propiedades estadísticas de dos variables (o conjunto de ellas) y la fórmula de la mejor predicción lineal.

## Contenidos:

Fórmula de mejor predicción (media). Calidad de la predicción (fórmula de varianza).

# Predicción óptima LINEAL



## Definición (Predicción óptima **lineal**)

La mejor predicción **lineal** de una variable aleatoria  $y$  dado un valor  $x_0$  de otra variable aleatoria  $x$  es una función  $p(x_0) = \Theta x_0 + \mu$  tal que el error de predicción  $e = y - p(x)$  sea una variable aleatoria de **media cero**, **no correlada** con  $x$  (esto es,  $\Sigma_{ex} = 0$ ), de **mínima varianza** entre todos los predictores **lineales** (variación total mínima, en caso multivariable).

## Fórmula de predicción óptima lineal

Dadas dos variables aleatorias  $x \in \mathbb{R}^n$ ,  $y \in \mathbb{R}^m$  de las que se conoce (analíticamente o experimentalmente –varianza y covarianza muestral–) medias  $\mu_x = E(x)$ ,  $\mu_y = E(y)$ , y matriz de varianzas-covarianzas  $(n+m) \times (n+m)$ :

$$\Sigma = \begin{pmatrix} \Sigma_y & \Sigma_{yx} \\ \Sigma_{yx}^T & \Sigma_x \end{pmatrix}$$

### Teorema

La predicción óptima lineal de  $y$  dada una muestra  $x_0$  de  $x$  es:

$$p(x_0) = (\Sigma_{yx} \Sigma_x^{-1}) \cdot (x_0 - \mu_x) + \mu_y$$

## Prueba de la fórmula

(a) Media **cero**:  $E[y - p(x)] = E[(y - \mu_y) - \Sigma_{yx}\Sigma_x^{-1}(x - \mu_x)] = 0$

(b) Error **no correlado**:  $E[(y - p(x))(x - \mu_x)^T] =$   
 $E[((y - \mu_y) - \Sigma_{yx}\Sigma_x^{-1}(x - \mu_x))(x - \mu_x)^T] = \Sigma_{yx} - \Sigma_{yx}\Sigma_x^{-1}\Sigma_x = 0$

(c) **Mínima varianza**: en variables incrementales sobre la media,

$$E(ee^T) = E[(y - \Theta x)(y - \Theta x)^T] = E[yy^T + \Theta xx^T \Theta^T - yx^T \Theta^T - \Theta xy^T]$$

$$= \Sigma_y + \Theta \Sigma_x \Theta^T - \Sigma_{yx} \Theta^T - \Theta \Sigma_{yx}^T$$

Hagamos cambio de variable  $\Theta = \Sigma_{yx}\Sigma_x^{-1} + \delta$ . Entonces,

$$E(ee^T) = \Sigma_y + (\Sigma_{yx}\Sigma_x^{-1} + \delta)\Sigma_x(\Sigma_x^{-1}\Sigma_{yx}^T + \delta^T)$$

$$- \Sigma_{yx}(\Sigma_x^{-1}\Sigma_{yx}^T + \delta^T) - (\Sigma_{yx}\Sigma_x^{-1} + \delta)\Sigma_{yx}^T = \Sigma_y - \Sigma_{yx}\Sigma_x^{-1}\Sigma_{yx}^T + \delta\Sigma_x\delta^T$$

Como  $\Sigma_x$  es semidefinida positiva,  $\delta\Sigma_x\delta^T$  también lo es (diagonal no negativa). Por lo tanto, sea cual sea  $\delta$  la variación total del error (traza de  $E[ee^T]$ ) aumenta (o se queda igual) comparado con  $\delta = 0$ .

## Resumen:

### [Ecuación de medias]

La mejor predicción lineal puntual de una variable aleatoria dada otra es:

$$p(x_0) = (\Sigma_{yx} \Sigma_x^{-1}) \cdot (x_0 - \mu_x) + \mu_y$$

### [Ecuación de varianzas]

El error de predicción  $e = y - p(x)$  tiene una varianza dada por:

$$\Sigma_e := E[e_p e_p^T] = \Sigma_y - \Sigma_{yx} \Sigma_x^{-1} \Sigma_{yx}^T$$

## Calidad del modelo óptimo lineal

$$\Sigma_e = \Sigma_y - \Sigma_{yx} \Sigma_x^{-1} \Sigma_{yx}^T$$

### Teorema

*Si dos variables  $x$ ,  $y$  son **no correladas**, los modelos lineales son inútiles para predecir una en función de la otra.*

\*Si inicialmente  $x$ ,  $y$  eran no correladas tenemos  $\Sigma_{yx} = 0$ , entonces  $\Sigma_e = \Sigma_y$  (no mejoramos la calidad de la predicción de  $y$  conociendo  $x$ ).

El teorema es una versión “lineal” del concepto de “estadísticamente independiente” (imposible predecir con **ningún** modelo).

Si  $\Sigma_{yx} \neq 0$  entonces  $\Sigma_e < \Sigma_y$ , medir  $x$  sí **mejora** la calidad de la estimación de  $y$ .

## Calidad del modelo óptimo lineal

$$\Sigma_e = \Sigma_y - \Sigma_{yx} \Sigma_x^{-1} \Sigma_{yx}^T$$

### Teorema

*Si dos variables  $x$ ,  $y$  son **no correladas**, los modelos lineales son inútiles para predecir una en función de la otra.*

\*Si inicialmente  $x$ ,  $y$  eran no correladas tenemos  $\Sigma_{yx} = 0$ , entonces  $\Sigma_e = \Sigma_y$  (no mejoramos la calidad de la predicción de  $y$  conociendo  $x$ ).

El teorema es una versión “lineal” del concepto de “estadísticamente independiente” (imposible predecir con **ningún** modelo).

Si  $\Sigma_{yx} \neq 0$  entonces  $\Sigma_e < \Sigma_y$ , medir  $x$  sí **mejora** la calidad de la estimación de  $y$ .

## Conclusiones

- La predicción óptima lineal puede obtenerse con una fórmula a partir de la matriz de varianzas-covarianzas de los datos intervinientes: error de predicción de mínima varianza, no correlado con datos de entrada, (subóptimo si la relación “real” es no lineal).
- Coincide con el estimador “determinista” de mínimos cuadrados (no demostrado aquí).
- Si existe correlación entre dos variables, el error **a posteriori** ( $\Sigma_y - \Sigma_{yx}\Sigma_x^{-1}\Sigma_{yx}^T$ , utilizando la mejor predicción) es **más pequeño** que el error **a priori** ( $\Sigma_y$  antes de usar la información).