

# Componentes principales en detección de fallos: elipsoide de confianza

Antonio Sala Piqueras

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

Video-presentación disponible en:

[personales.upv.es/asala/videos/fdpca1.html](http://personales.upv.es/asala/videos/fdpca1.html)



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA

# Presentación

## Motivación:

Con análisis de componentes principales / TLS pueden estimarse modelos reducidos (aproximados) de la variabilidad de un sistema.

## Objetivos:

En detección de fallos, se considerará anormal aquella muestra que no “concuerde” con el modelo. En multivariable, una muestra son “muchos” números, correlados entre sí: conveniente generar uno o dos estadísticos “sencillos” no correlados (en vez de muchos umbrales no independientes).

## Contenidos:



Elipsoide de confianza. Estadístico  $\chi^2$  ( $T^2$ ) asociado. Conclusiones.



UNIVERSITAT  
POLITÀCNICA  
DE VALÈNCIA

## Ejemplo motivador


Se tiene un conjunto de 3000 datos de 2 variables. Sus histogramas (marginales) son:



Las líneas rojas indican umbrales (conf. 99%) que una aproximación a distribución normal propondría. Las líneas verdes, los cortes 0.5% inferior y superior del histograma “experimental”.

## Ejemplo motivador (2)

Podría pensarse en disparar una alarma (“detección” de fallo) en cada variable si se supera dicho umbral. Pero no tiene en cuenta la **correlación** entre ambas:



La alarma se dispararía cuando las muestras estén fuera del cuadrado.

\*No detectaría puntos claramente anormales en las zonas superior izquierda / inferior derecha dentro del cuadrado.

► El **elipsoide de confianza** parece más indicado para detección de muestras anormales (fallos).

# Objetivos de la detección de fallos basada en PCA

Generar “resíduos” para identificar:

- ① qué muestras ya adquiridas eran anormales (fuera de línea, **a posteriori**)
- ② para identificar “en línea” muestras que no concuerden con el modelo y detectar fallos lo más rápidamente posible.

Dos tipos de enfoque:

- ① Análisis “completo”: elipsoide de confianza a partir de  $X = USV^T$ .
- ② Análisis “disgregado”: de  $X = U_{n \times n} S_{n \times n} (V_{n \times N})^T$ , podemos descomponer la matriz de datos

$$X_{n \times N} = \underbrace{U_{n \times q} S_{1:q} V_{q \times N}}_{\text{mucha vza.}} + \underbrace{U_{n \times (n-q)} \overset{\approx 0}{S_{(q+1):n}} V_{(n-q) \times N}}_{\text{vza. residual descartada}}$$

donde el componente izquierdo tiene “mucha variabilidad” y el derecho tiene “poca” (ruido fuera de modelo, varianza descartada).

# SVD y PCA completo

De  $X = U_{n \times n} S_{n \times n} (V_{n \times N})^T$ , la matriz VC es  $\Sigma = \frac{1}{N-1} X X^T = U \frac{S^2}{N-1} U^T$ . Podemos entender que los datos han sido originados, muestra a muestra como

$$x = U_{n \times n} \psi$$

donde  $\psi$  es un vector de “fuentes de variabilidad” con desv. típ. muestral de  $\psi_i$  igual a  $s_{ii}/\sqrt{N-1}$ , esto es  $E(\psi \psi^T) = \frac{1}{N-1} S V^T V S = \frac{1}{N-1} S^2 := \Lambda$ .

Equivalentemente,  $x = U \Lambda^{1/2} z$ , siendo  $z$  un vector de componentes “normalizado” de varianza (muestral) identidad, con  $\psi = \Lambda^{1/2} z$ .

Si hay muuuchas muestras ( $N \rightarrow \infty$ ),  $\|z\|^2$  debería ser una  $\chi^2$  de  $n$  grados de libertad (o menos, si hay elementos de  $\text{diag}(S)$  exactamente cero, que no ocurre con ruido de medida en la práctica. Elementos “muy pequeños” de  $S$  se discutirán en otros materiales).

# Umbral para PCA completo

A partir de los datos, como  $x = U\Lambda^{1/2}z$ , tenemos  $z = \Lambda^{-1/2}U^T x$ .  
Entonces  $\|z\|^2 = x^T U \Lambda^{-1} U^T x = x^T \Sigma^{-1} x$ .

► Existe un 95% de probabilidad que  $x^T \Sigma^{-1} x \leq \text{chi2inv}(0.95, n)$ .  
Esto puede ser usado de umbral para detección de algún “fallo” o “muestra irregular”.

\*Con pocas muestras, existe “incertidumbre” en el estimado muestral de  $\Sigma$ ; el umbral debe ser cambiado usando la distribución  $T^2$  de Hottelling.  
 $x^T \Sigma^{-1} x \leq \text{t2inv}(0.95, N, n)$ .

\*Los umbrales pueden ser adaptados a la “media de  $m$  muestras”, para filtrar mejor outliers esporádicos.

► Todo esto es una reescritura del “test de medias multivariantes”, vídeo [THMMV]. ◀

# Conclusiones

- Con muestras de distrib. normal, matriz VC  $\Sigma$ , el PCA (SVD) me permite calcular cotas  $\chi^2$  o  $T^2$  de  $x^T \Sigma^{-1} x$ .
- Realmente, es renombrar los conceptos de “elipsoide de confianza” o “test de hipótesis sobre media multivariable” y llamarle “umbrales de detección de fallos”.
- En modelos reducidos (descartando valores singulares pequeños), tiene interés poder detectar:
  - 1 Cambios “dentro de modelo”: algún componente de gran varianza tiene un valor anormal, pero la correlación se mantiene.
  - 2 Cambios “fuera de modelo”: la correlación entre las variables no es la misma que con los datos de entrenamiento.

Ello se verá en otros materiales.