

## **Mejora de la calidad y de la productividad en una planta de galvanización en caliente y en continuo mediante detección y diagnóstico de fallos**

**J. Carlos García-Díaz**

Centro de Gestión de la Calidad y el Cambio. Universitat Politècnica de València.  
Cº de Vera s/nº, 46022 Valencia. [juagardi@eio.upv.es](mailto:juagardi@eio.upv.es)

**Palabras clave:** Calidad; SPC multivariante, PCA, T<sup>2</sup> de Hotelling

### **1. Introducción**


El acero galvanizado es un producto de alto valor añadido, proporcionando el funcionamiento eficaz combinando la resistencia a la corrosión del zinc con la resistencia y la formabilidad del acero. La complejidad de la galvanización continua en caliente y las exigencias de calidad cada vez más rigurosas en la industria del automóvil también han exigido esfuerzos en el control y monitorización del proceso para hacerlo más robusto frente a causas asignables de variabilidad. La utilización de modelos estadísticos avanzados puede ayudar a las industrias para diseñar planes de inversión más económicos y racionales. Por ello, la detección y diagnóstico de los fallos en el proceso de producción es un problema importante en la industria del automóvil dado que los requisitos de calidad cada vez más estrictos requieren esfuerzos respecto al control del proceso. Para ello, se utilizan datos reales procedentes de unja línea de galvanización en caliente cuyo destino es la producción de chapa para la industria del automóvil.

Las técnicas de Control estadístico de procesos (SPC) constituyen un conjunto de herramientas orientadas a la mejora de la calidad y de la productividad ampliamente implantadas en la industria. Las herramientas más importantes del SPC son sin duda los conocidos Gráficos de Control, utilizados para la monitorización y control de características de calidad o de proceso críticas, con el objetivo de fabricar siempre desde el principio unidades dentro de especificaciones con la menor variabilidad posible y centradas en el nominal (Montgomery (2009)). El objetivo del control y monitorización de un proceso industrial es el aseguramiento del éxito de las operaciones planificadas detectando anomalías en su comportamiento. La monitorización del proceso consiste en a) la detección de la presencia de un fallo a partir de la información extraída de los datos del proceso, b) identificación del fallo a través de las variables más relevantes para diagnosticarlo y c) diagnosis del fallo: tipo, tamaño y localización (Himmelblau (1998)).


### **2. Proceso industrial bajo estudio**

En una línea de galvanización continua en caliente (Figura 1), la chapa de acero es recubierta por inmersión en un baño (Figura 2) de zinc fundido normalmente entre 450 y 480 ° C (la temperatura de baño media es de 460°C). Los datos de los que se disponen son referentes a 26

bobinas de acero galvanizado donde se midieron 6 variables seleccionadas: 4 temperaturas del baño, el nivel del baño y la velocidad de entrada de la chapa al mismo. Los datos fueron organizados en una matriz  $X$  de dimensiones  $26 \times 6$  que fue analizada para determinar cuando un fallo ha ocurrido en el proceso.



**Figura 1.** Línea de galvanización en caliente y en continuo.



**Figura 2.** Sección de galvanizado en caliente: Pote de Zinc

### 3. Detección y diagnóstico de fallos


#### 3.1. 3.1 Detección Multivariante: Distancia Robusta.

La identificación de observaciones anómalas o outliers se puede llevar a cabo mediante técnicas robustas considerando dos tipos de distancia para cada observación. (Verboven and

Hubert (2005)). En el caso multivariante asumimos que los datos están dispuestos en una matriz  $X$  de dimensiones  $n \times p$  consistente en  $n$  observaciones correspondientes a  $p$  variables. Cuando el número de variables,  $p$ , es menor que el tamaño de los datos  $n$ , estimaciones robustas del vector de medias  $\mu$  y la matriz de varianzas-covarianzas  $\Sigma$  de  $X$  pueden ser obtenidas mediante el estimador MCD (Minimum Covariance Determinant) propuesto por Rousseeuw and Van Driessen (1999). Este estimador es muy interesante porque es robusto a la presencia de outliers.

Utilizando las distancias robusta y de Mahalanobis (Verboven and Hubert, 2005) algunos datos anómalos fueron identificados. En este gráfico podemos identificar dos grupos outliers. Observando la figura 3 se distinguen claramente tres observaciones anómalas: 7, 17, 18 y 19. Ambos métodos el robusto y el clásico podrían identificar estos datos si exceden el límite de corte horizontal y vertical.

Observación 17 tiene un comportamiento distinto al resto mientras que las observaciones 18 y 19 son anómalas en menor medida.



**Figura 3.** Gráfico de distancias Robusta-Mahalanobis.


### 3.2. Análisis de Componentes Principales (PCA)

Bajo condiciones normales de operación, las medidas proporcionadas por sensores están altamente correlacionadas. PCA (análisis de componentes principales) es una técnica de reducción de la dimensionalidad basada en la explotación de la estructura de correlación entre

las variables implicadas en el proceso de galvanización. Mediante técnicas PCA podemos capturar la estructura de correlación que caracteriza una situación normalidad de funcionamiento del proceso siendo la violación de dicha estructura síntoma de una situación anormal de funcionamiento. PCA descompone la matriz  $\mathbf{X}$  en dos matrices: matriz de scores  $\mathbf{T}$  y matriz de loadings  $\mathbf{P}$  (Nomikos y MacGregor (1995)). Una vez extraídas las componentes principales que mayor variabilidad explican de los datos podemos pasar a utilizar gráficos de control multivariante como el  $T^2$  de Hotelling y el SPE (error cuadrático de predicción) para la detección de fallos. La diagnosis de fallos se puede realizar mediante el estudio de los gráficos de contribución de cada variable al estadístico SPE.

### 3.3. Detección de Fallos

Condiciones normales de operación pueden ser caracterizadas mediante el estadístico  $T^2$  de Hotelling. Un valor del estadístico mayor que el límite de control indica que un fallo ha ocurrido (Figura 4).



**Figura 4.** Elipses de control para para todas las variables y todos los batchs con límites de control al 90 %, 95 % and 99 %.

Figure 5 muestra dos gráficos complementarios para el 17. El primero es un gráfico  $T^2$  Hotelling sobre las dos primeras componentes principales. Este gráfico chequea si un Nuevo

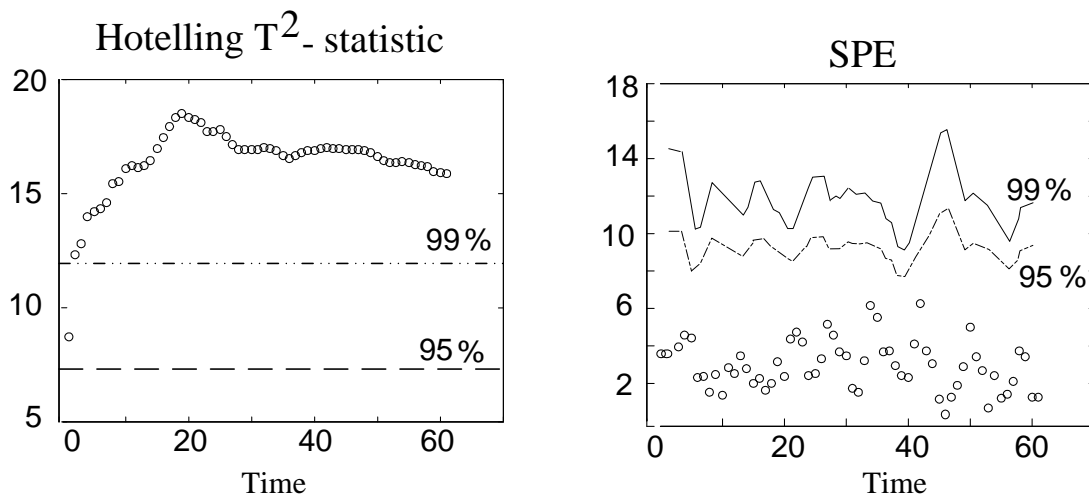
vector de observaciones de las seis variables de proceso proyectado en el plano definido por las dos primeras componentes principales está dentro de la región de aceptación como bajo control. El segundo gráfico es un gráfico *SPE* que detectará la ocurrencia de algún nuevo evento que saque al proceso de su situación bajo control. Los límites para una buena situación de operación son determinados mediante un conjunto de referencia obtenido cuando el proceso está bajo control (training data). Si los puntos caen dentro de los límites el proceso está bajo control. El batch 17 está fuera de control.

### 3.4. Diagnósis del fallo

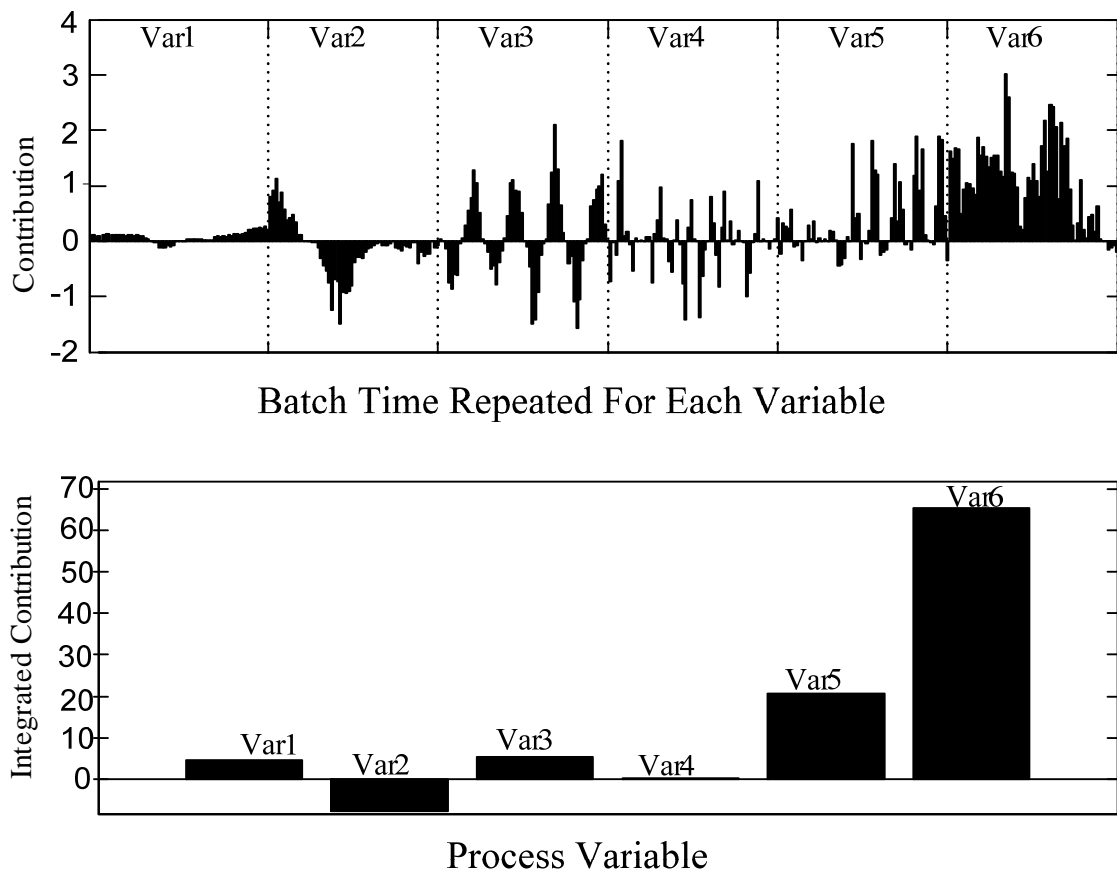
Una vez el fallo sido detectado, se puede calcular la contribución al estadístico *SPE* de cada variable que puede ayudarnos en la clasificación del fallo. Los gráficos de contribución son utilizados para la diagnóstico del fallo detectado. El estadístico  $T^2$  y el gráfico *SPE* producen una señal de fuera de control cuando un fallo ha ocurrido pero no da información de la causa que lo ha producido. Figure 6 muestra el gráfico de contribución al estadístico *SPE* para el batch 17. Variables 5 y 6 (temperaturas del baño) producen mayor contribución al *SPE*.

## 4. Conclusiones

El PCA dio como resultado la aparición de un lote que rompía la estructura de correlación que presentaba el resto de lotes. Mediante la utilización del gráfico multivariante de Hotelling se pudo caracterizar el lote 17 como defectuoso, es decir, en cuya fabricación se detectó la aparición de un fallo. Mediante el gráfico de contribución correspondiente al lote 17 se pudo determinar que variables eran las responsables del fallo, resultando ser dos temperaturas del baño



**Figura 5.** Estadístico  $T^2$  de Hotelling y gráfico *SPE* con límites de control al 95% y 99% para el batch 17.



**Figura 6.** Contribución al estadístico SPE en el batch 17.

### Referencias

- Himmelbau, O.M. 1978. *Fault Detection and Diagnosis in Chemical and Petrochemical Process*. Elsevier, Amsterdam.
- Montgomery, D.C. (2009). *Introduction to Statistical Quality Control*, 6th John Wiley and Sons, New York, NY.
- Nomikos, P. and MacGregor, J.F. 1995. Multivariate SPC charts for monitoring batch processes. *Technometrics* 37 1: 41–59.
- Rousseeuw, P.J.; Van Driessen, K. 1999. A Fast Algorithm for the minimum Covariance Determinant Estimator. *Technometrics*, 41:212-223.
- Verboven, S.; Hubert, M. 2005. LIBRA: a Matlab library for robust analysis, *Chemometrics and Intelligent Laboratory Systems* 75:127-136.