

# DETECCIÓN DE FALLAS EN PIEZAS FUNDIDAS USANDO UNA METODOLOGÍA DE RECONOCIMIENTO DE PATRONES.

## Domingo Mery

Departamento de Ingeniería Informática, Universidad de Santiago de Chile  
Av. Ecuador 3659, Santiago de Chile  
Email: [dmery@ieec.org](mailto:dmery@ieec.org)  
<http://www.diinf.usach.cl/~dmery>

## Romeu R. da Silva

Engenharia Metalúrgica y de Materiais, Escola de Engenharia y COPPE  
Universidade Federal del Rio de Janeiro  
EMail: [romeu@metalmat.ufri.br](mailto:romeu@metalmat.ufri.br)  
<http://www.metalmat.ufri.br>

## Luiz P. Calôba

Engenharia Eletrônica, Escola de Engenharia y COPPE  
Universidade Federal del Rio de Janeiro  
EMail: [caloba@lps.ufri.br](mailto:caloba@lps.ufri.br)  
<http://www.lps.ufri.br>

## João M. A. Rebello

Engenharia Metalúrgica y de Materiais, Escola de Engenharia y COPPE  
Universidade Federal del Rio de Janeiro  
EMail: [jmarcos@metalmat.ufri.br](mailto:jmarcos@metalmat.ufri.br)  
<http://www.metalmat.ufri.br>

**Abstract.** La detección automática de fallas en piezas fundidas se lleva a cabo mediante el análisis de imágenes radioscópicas digitales. Comúnmente se emplea con este fin una metodología de reconocimiento de patrones que consta de tres etapas: segmentación, en la que se obtienen regiones de las imágenes que corresponden posiblemente a las fallas; extracción de características, en la que se miden las regiones segmentadas; y finalmente clasificación, en la que de acuerdo a las características extraídas, se separan las regiones segmentadas en dos clases: 'defectos' y 'estructuras regulares'. La detección se realiza en la etapa de clasificación, la que tiene como finalidad reducir el número de los falsos positivos obtenidos en la etapa de segmentación, sin disminuir el número de verdaderos positivos. En el presente trabajo se presenta un análisis exhaustivo de más de 400 características extraídas en casi 23.000 regiones de 50 imágenes radioscópicas. Las características extraídas se pueden agrupar en características geométricas (perímetro, área, factores de forma, descriptores de Fourier, momentos invariantes, etc.) y características de intensidad (texturas, contrastes, transformadas de Fourier, Karhunen Løeve, de cosenos, etc.). Se presenta un análisis ROC (receiver operation characteristic) con el que es posible medir el desempeño de cada una de las características de manera individual. Con el fin de reducir el costo computacional de la clasificación, es necesario hacer una selección de las características, de esta manera el clasificador sólo trabaja con características no correlacionadas y que proporcionen información para la detección de fallas. En este artículo se presenta una selección usando discriminante Fisher y el método de selección secuencial hacia adelante, con el que se garantiza una varianza intraclase pequeña y una varianza interclase grande en el espacio de las características seleccionadas. Se realiza también un análisis de las componentes principales de discriminación lineal para la visualización de la separación entre las clases. Adicionalmente, se estudia la matriz de correlación lineal de las características seleccionadas. Finalmente, se implementan clasificadores lineales basados en clasificadores estadísticos y basados en redes neuronales.

**Keywords.** Detección de fallas, reconocimiento de patrones, piezas fundidas, clasificadores, procesamiento digital de imágenes.

## 1. Introduction

La detección automática de fallas en ensayos no destructivos se realiza comúnmente utilizando un método de reconocimiento de patrones, cuyos pasos se ilustran en la Fig. (1): formación de la imagen, preprocesamiento, segmentación, extracción de características y clasificación (Mery et al, 2003). A continuación se presentan brevemente cada una de estas etapas.

**Formación de la imagen:** La imagen se obtiene irradiando la pieza de estudio con rayos X. Los rayos X son convertidos a luz visible por medio de un amplificador de imagen o elementos de estado sólido sensibles a los rayos X. El sensor es bidimensional (o unidimensional en movimiento) para poder captar las dos dimensiones de la imagen. A través de un conversor analógico-digital se convierte la señal eléctrica a un código binario que puede ser interpretado por un computador para conformar una imagen digital del objeto de estudio.

**Preprocesamiento:** En esta etapa se intenta aumentar la calidad de la imagen con el fin de reconocer mejor las fallas que puedan existir en la imagen. Algunas de las técnicas empleadas en el preprocesamiento son eliminación de ruido mediante filtros digitales o integración, mejora del contraste y restauración.

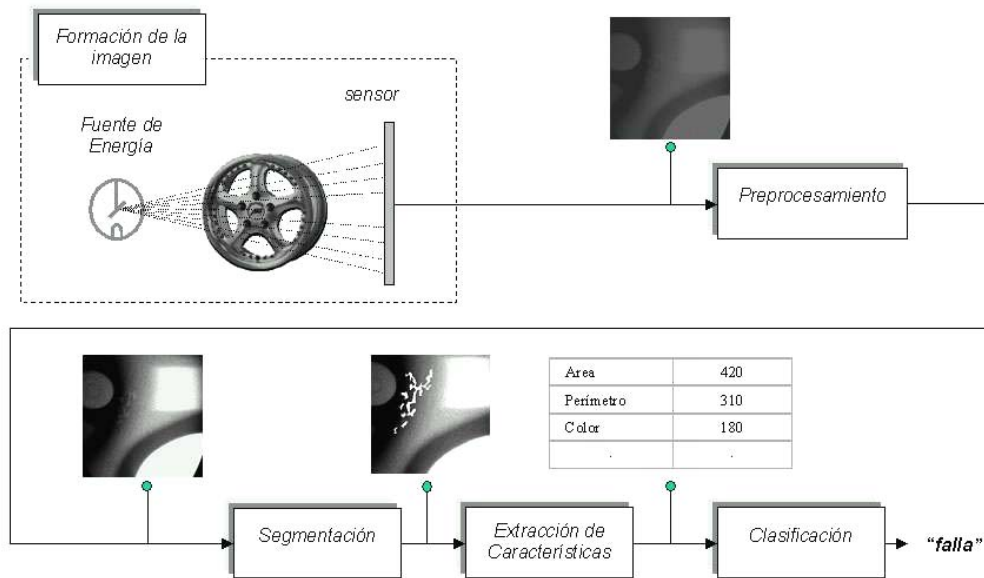


Figura 1. Reconocimiento de patrones en la detección automática de fallas.




Figura 2: Detección de fallas utilizando detección de bordes: (a) imagen original, (b) gradiente, (c) segunda derivada, (d) bordes usando filtro LoG, (e) y (f) detección de fallas.

**Segmentación:** El proceso de segmentación divide la imagen digital en regiones inconexas, con el fin de separar las partes de interés del resto de la escena. A lo largo de las últimas décadas se han desarrollado diversas técnicas de segmentación, las que se pueden agrupar en tres: técnicas orientadas al pixel, a los bordes y a las regiones. En este artículo se utiliza el método de segmentación orientado a la detección de bordes empleando el filtro LoG (Mery & Filbert, 2002b). Como se aprecia en la Fig. (2), en esta técnica se buscan los cambios bruscos de tonos de gris en la imagen (bordes), para constituir así zonas delimitadas por bordes que constituyen fallas.

**Extracción de características:** En la inspección de piezas fundidas, la segmentación detecta regiones denominadas 'defectos hipotéticos', que pueden ser fallas, o bien, estructuras del objeto. Luego, la extracción de características se centra principalmente en la medición de las propiedades geométricas (área, perímetro, factores de forma, descriptores de Fourier, momentos invariantes, etc.) y de intensidad de las regiones (nivel de gris, gradiente, segunda derivada, características de textura, etc.). Es importante saber cuáles características son las que brindan información sobre la

fallas. Con este fin se realiza una selección de características, que encuentra las características que mejor describen las fallas (eliminando por ejemplo aquellas características que estén correlacionadas entre sí o que no brinden información alguna) (Jain et al, 2000).

**Clasificación:** Finalmente, la clasificación ordena las regiones segmentadas en determinadas clases según las características que posean, asignando cada región a un grupo de muchos grupos preestablecidos, que representan todos los posibles tipos de regiones que se espera que existan en la imagen. Comúnmente las clases existentes en detección de fallas de piezas fundidas son dos: 'defectos' o 'estructuras regulares'<sup>1</sup>. Es necesario destacar que la clasificación se realiza en un sistema automático de inspección luego de una etapa de entrenamiento supervisado. En esta etapa se hace un estudio estadístico de las características que se extraen de objetos cuyas fallas sean conocidas a priori. Clasificadores simples se pueden implementar comparando las características medidas con valores de umbral, sin embargo también es posible utilizar técnicas de clasificación más sofisticadas como por ejemplo aquellas que realizan un análisis estadístico y geométrico del espacio vectorial de las características, o bien aquellas que emplean redes neuronales o lógica difusa (Castleman, 1996; Jain et al, 2000; Mery & Filbert, 2002b).

En este trabajo se presenta un análisis exhaustivo de más de 400 características extraídas de unas 23.000 regiones en 50 imágenes radioscópicas. El artículo describe brevemente en la Sección 2 las características empleadas. Posteriormente en la Sección 3 se realiza una selección de características con el fin de reducir el costo computacional de la clasificación. Luego, en la Sección 4 se presenta el método de correlación lineal de las características seleccionadas. Posteriormente, en la Sección 5 se muestran los resultados obtenidos empleando clasificadores estadísticos y lineales basados en redes neuronales utilizando características originales y también obtenidas de un análisis de componentes principales. Finalmente se presentan las conclusiones y sugerencias para trabajos futuros.

## 2. Extracción de características

Como ya se señaló en la sección anterior, la segmentación se lleva a cabo utilizando una técnica de detección de bordes. Se considera como 'defecto hipotético' cada una de las regiones encerradas por bordes en la imagen binaria (ver ejemplo en Fig. (3)). En el proceso de extracción de características se miden las propiedades de cada una de las regiones obtenidas en la segmentación. La idea es que a partir de las características medidas se pueda decidir si el defecto hipotético corresponde a una falla o es una estructura regular.

A continuación se mencionarán las características extraídas en este trabajo. Las características han sido agrupadas en dos tipos: *geométricas* y *de intensidad*. Las características geométricas brindan información relativa al tamaño y forma de las fallas hipotéticas segmentadas. Mientras que las características basadas en la intensidad entregan información del tono de gris de las regiones segmentadas. La Tabla (1) presenta el conjunto de características usadas en este trabajo. Los detalles de cómo son calculadas se pueden encontrar en las referencias.

El total de características extraídas es de 405, agrupándose en 37 características geométricas y 368 características de intensidad.

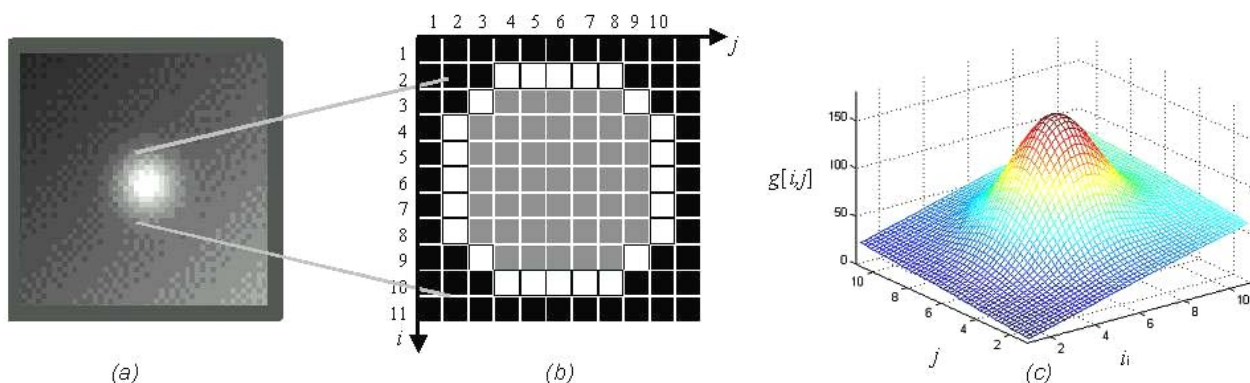


Figura 3: Ejemplo de una región. (a) imagen de rayos X, (b) región segmentada, (c) representación 3D de la intensidad (tonos de gris) de la región y su entorno.

## 3. Selección de características

Con el fin de reducir el costo computacional de la clasificación es necesario hacer una selección de las características, de esta manera el clasificador sólo trabaja con características no correlacionadas y que proporcionen información para la detección de fallas. Existen diversas formas para evaluar el desempeño de las características extraídas. En esta Sección se mencionará el análisis ROC y el discriminante Fisher, mientras que en la siguiente Sección se explicará el análisis de correlación lineal.

<sup>1</sup> Una sub-clasificación de las fallas es posible para determinar el tipo de falla.

El análisis ROC (*receiver operation characteristic*) se emplea comúnmente para medir el desempeño de una clasificación en dos clases. En nuestro caso, cada característica es analizada independientemente usando un clasificador de umbral. De esta manera, una falla hipotética es clasificada como 'estructura regular' (o 'defecto') si el valor de la característica está debajo (o encima) de un umbral. La curva ROC representa una gráfica de la 'sensibilidad' ( $S_n$ ) versus '1-especificidad' ( $1-S_p$ ), definidas como:

$$S_n = \frac{TP}{TP + FN}, \quad 1 - S_p = \frac{FP}{TN + FP} \quad (1)$$

Tabla 1. Características extraídas.

Tipo	Variable	Nº	Descripción	Ref.
geo	$I$	1	Número de la imagen	
geo	$(\bar{i}, \bar{j})$	2-3	Centro de gravedad	Castleman, 1996
geo	$h, w$	4-5	Altura y ancho	Castleman, 1996
geo	$A, L$	6	Área y perímetro	Castleman, 1996
geo	$R$	8	Redondez	Castleman, 1996
geo	$\phi_1 \dots \phi_7$	9-15	Momentos de Hu	Sonka et al, 1998
geo	$ DF_0  \dots  DF_7 $	16-23	Descriptores de Fourier	Zahn & Roskies, 1971
geo	$FM_1 \dots FM_4$	200	Momentos invariantes de Flusser y Suk	Sonka et al, 1998
geo	$FZ_1 \dots FZ_3$	204-206	Momentos invariantes de Gupta y Srinath	Sonka et al, 1998
geo	$(a_e, b_e)$	207-208	Eje mayor y menor de elipse ajustada	Fitzibbon et al, 1999
geo	$a_e / b_e$	209	Razón de eje mayor a menor de elipse ajustada	Fitzibbon et al, 1999
geo	$\alpha$	210	Orientación de la elipse ajustada	Fitzibbon et al, 1999
geo	$(i_0, j_0)$	211-212	Centro de la elipse ajustada	Fitzibbon et al, 1999
geo	$G_d$	213	Factor de forma según Danielsson	Danielsson, 1978
int	$G$	24	Promedio del tono de gris	Castleman, 1996
int	$C$	25	Promedio del gradiente en el borde	Mery & Filbert, 2002b
int	$D$	26	Promedio de la segunda derivada	Mery & Filbert, 2002b
int	$K_1 \dots K_3$	27-29	Contrastes radiográficos	Kamm, 1998
int	$K_\sigma$	30	Desviación de contraste	Mery & Filbert, 2002b
int	$K$	31	Contraste basado en CLP <sup>2</sup> a 0° y 90°	Mery & Filbert, 2002b
int	$\Delta_Q$	32	Diferencia entre mínimo y máximo de BCLP <sup>2</sup>	Mery, 2003
int	$\Delta'_Q$	33	$\ln(\Delta_Q + 1)$	Mery, 2003
int	$\sigma_Q$	34	Desviación estándar de BCLP <sup>2</sup>	Mery, 2003
int	$\Delta''_Q$	35	$\Delta_Q$ normalizado por el promedio de los extremos de BCLP <sup>2</sup>	Mery, 2003
int	$\bar{Q}$	36	Promedio de BCLP <sup>2</sup>	Mery, 2003
int	$F_1 \dots F_{15}$	37-51	Magnitud de los armónicos de la DFT de BCLP <sup>2</sup>	Mery, 2003
int	$\phi'_1 \dots \phi'_7$	52-58	Momentos de Hu con información de tonos de gris	Sonka et al, 1998
int	$\sigma_g^2$	59	Varianza local	Mery & Filbert, 2002b
int	$Tx_1$	60-87	Promedio y rango de 14 características de textura <sup>3</sup> con $d=1$	Haralick et al, 1973
int	$Tx_2$	88-115	Promedio y rango de 14 características de textura <sup>3</sup> con $d=2$	Haralick et al, 1973
int	$Tx_3$	116-143	Promedio y rango de 14 características de textura <sup>3</sup> con $d=3$	Haralick et al, 1973
int	$Tx_4$	144-171	Promedio y rango de 14 características de textura <sup>3</sup> con $d=4$	Haralick et al, 1973
int	$Tx_5$	172-199	Promedio y rango de 14 características de textura <sup>3</sup> con $d=5$	Haralick et al, 1973
int	$Y_{KL}$	214-277	64 primeros componentes de la transformada KL <sup>4</sup>	Castleman, 1996
int	$Y_{DFT}$	278-341	64 primeros componentes de la transformada DFT <sup>4</sup>	Castleman, 1996
int	$Y_{DCT}$	342-405	64 primeros componentes de la transformada DCT <sup>4</sup>	Castleman, 1996

<sup>2</sup> CLP: *Crossing line profile*, función de tonos de gris a lo largo de una línea recta que cruza la región por su centro de gravedad. El término BCLP se refiere a *best CLP*, es decir el CLP que presente mejor homogeneidad en los extremos (Mery, 2003).

<sup>3</sup> Se extraen las siguientes características basadas en la matriz de co-ocurrencia: segundo momento angular, contraste, correlación, suma de cuadrados, momento de diferencia inverso, suma promedio, varianza de la suma, entropía de la suma, entropía, varianza de la diferencia, entropía de diferencia, 2 mediciones de información de correlación y coeficiente de correlación máximo, para una distancia de  $d$  píxeles.

<sup>4</sup> La transformada toma una ventana redimensionada a  $32 \times 32$  píxeles que incluye la región y su entorno.

donde  $TP$  es el número de verdaderos positivos (defectos clasificados correctamente),  $TN$  el número de verdaderos negativos (estructuras regulares clasificadas correctamente),  $FP$  es el número de falsos positivos (falsas alarmas, es decir estructuras regulares clasificadas como defectos), y  $FN$  falsos negativos (fallas clasificadas como estructuras regulares)<sup>5</sup>. Una representación gráfica se muestra en la Fig. (4). Idealmente,  $S_n = 1$  y  $1-S_p = 0$ , esto quiere decir que todos los defectos fueron detectados sin haberse encontrado falsas alarmas. La curva ROC permite evaluar el desempeño de la detección en distintos puntos de operación (como por ejemplo definidos por medio de umbrales en la clasificación). El área bajo la curva ( $A_z$ ) es usada normalmente como una medición de este desempeño ya que indica cómo puede ser realizada la detección de las fallas: un valor de  $A_z = 1$  indica una detección ideal, mientras que un valor  $A_z = 0.5$  corresponde a una clasificación aleatoria (Egan, 1975).

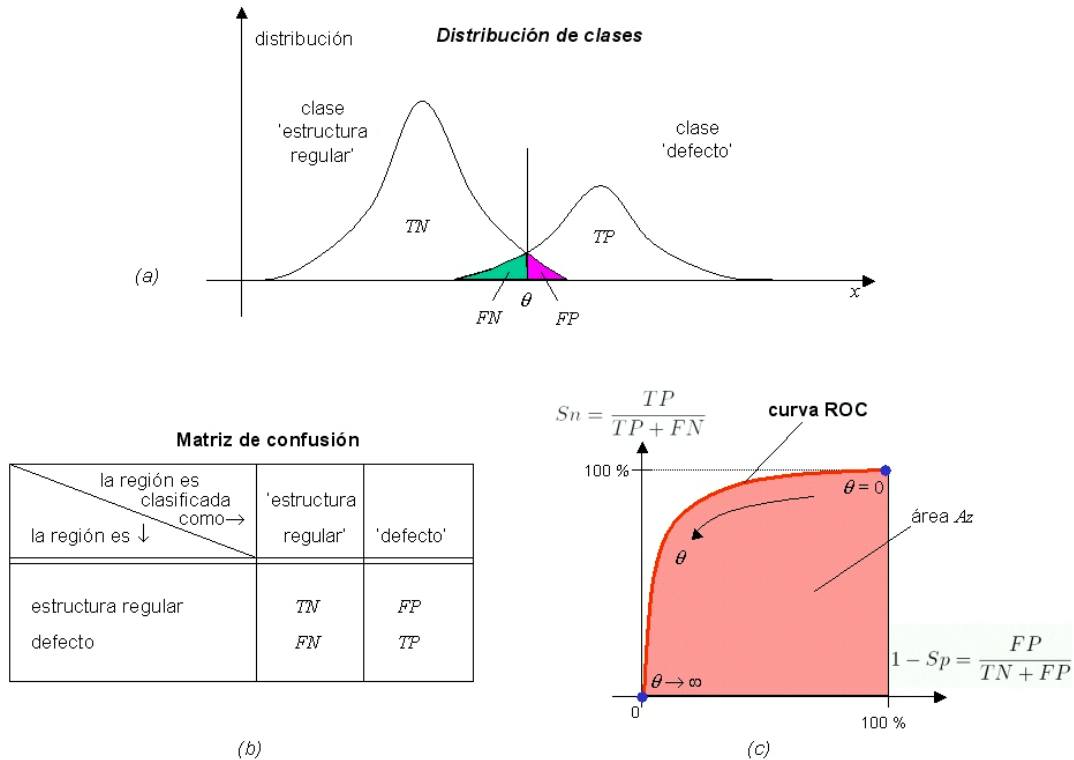


Figura 4: Clasificación de defectos. a) Distribución de clases usando sólo una característica  $x$ . b) Matriz de confusión. c) Curva ROC variando el umbral  $\theta$ .

Otra manera de evaluar el desempeño de un clasificador es usando el discriminante Fisher, por medio del cual se evalúa la función:

$$J = \text{spur}(\mathbf{C}_w^{-1}\mathbf{C}_b) \tag{2}$$

donde  $\mathbf{C}_b$  y  $\mathbf{C}_w$  representan respectivamente las covarianzas interclase e intraclase de las características seleccionadas. Un valor de  $J$  grande indicará una buena separabilidad de las clases, ya que se asegura una pequeña variación intraclase y una gran variación interclase en el espacio de las características (Fukunaga, 1990).

Los resultados presentados en este artículo se obtienen del análisis de 50 imágenes radioscópicas de piezas de aluminio fundido. Las imágenes presentan una alta componente de ruido ya que fueron tomadas sin utilizar la técnica de integración en la que se promedian varias imágenes tomadas de la misma escena para aumentar el SNR. En estas imágenes se segmentaron un total de 22.936 regiones dentro de las cuales, mediante una inspección visual, se detectaron 60 fallas reales, las que corresponden a zonas de aire en la pieza. Estas fallas están ubicadas en zonas de la pieza en las que su detección resulta muy difícil (ver ejemplos en (Mery & Filbert, 2002b)). A cada una de las casi 23.000 regiones se le extrajeron las 405 características mencionadas en la Tab. (1).

Una preselección de características se obtuvo eliminando aquellas que presentaban un área bajo la curva ROC  $A_z < 0.8$  y un discriminante Fisher  $J < 0.2 J_{\max}$ , donde  $J_{\max}$  corresponde al máximo discriminante Fisher obtenido al evaluar cada una de las características. Adicionalmente, si dos características presentan un valor absoluto de coeficiente de correlación mayor o igual al 0.95 se elimina aquella que tenga un valor  $A_z$  menor. De esta manera, de las 405 características iniciales se pudieron eliminar 376. La Tabla (2) muestra las 28 características preseleccionadas. Se observa que los mejores resultados fueron obtenidos con características pertenecientes a la familia de los contrastes.

<sup>5</sup> En la literatura también se conocen los términos *False Acceptance Rate (FAR)* y *False Rejected Rate (FRR)* definidos como  $1-S_p$  y  $1-S_n$  respectivamente (Jain et al, 2000; Mery & Filbert, 2002a).



También las texturas alcanzaron buenos desempeños. Asimismo se observa que algunas características pertenecen a las características geométricas, sin embargo se aprecia que los mejores resultados se alcanzaron con las características de intensidad. La Figura (5) muestra la mejor curva ROC, obtenida para  $F_1$ , la característica de contraste basada en el análisis de Fourier de los tonos de grises a lo largo de líneas rectas que cruzan las regiones (Mery, 2003). En este caso el área bajo la curva es  $A_z = 0.9944$ . Se aprecia también la buena separación de clases que ofrece esta característica.

Tabla 2. Valores de área bajo la curva ROC  $A_z$  y discriminante Fischer  $J$  para las 28 características preseleccionadas.

Nº	var	$A_z$	$J$	Nº	var	$A_z$	$J$	Nº	var	$A_z$	$J$	Nº	var	$A_z$	$J$
4	$h$	0.94	1.5	59	$\sigma_g^2$	0.95	1.8	139	$Tx_3$	0.87	1.5	186	$Tx_5$	0.96	3.9
8	$R$	0.91	2.0	85	$Tx_1$	0.93	2.9	156	$Tx_4$	0.92	1.9	190	$Tx_5$	0.90	1.5
25	$C$	0.93	2.0	87	$Tx_1$	0.83	1.9	162	$Tx_4$	0.89	1.4	195	$Tx_5$	0.94	3.0
30	$K_\sigma$	0.99	3.0	100	$Tx_2$	0.97	4.6	167	$Tx_4$	0.91	2.2	208	$b_e$	0.96	1.7
31	$K$	0.99	<u>6.8</u>	101	$Tx_2$	0.83	1.6	170	$Tx_4$	0.90	1.9	285	$Y_{DFT}$	0.96	1.4
33	$\Delta'_Q$	0.99	4.6	113	$Tx_2$	0.92	2.5	179	$Tx_5$	0.97	3.6	360	$Y_{DCT}$	0.95	2.5
37	$F_1$	<u>0.99</u>	1.9	128	$Tx_3$	0.96	3.2	182	$Tx_5$	0.94	2.8	376	$Y_{DCT}$	0.94	1.7

Luego de esta preselección de características se llevó a cabo un proceso de selección basado en el método *Sequential Forward Selection* (SFS) (Jain, et al, 2000). Para usar este método es necesario tener una función objetivo  $f$  que evalúe el desempeño de la clasificación usando  $m$  características. Esta función puede ser por ejemplo el discriminante Fisher definido en la Ec. (2). El método empieza con una característica ( $m=1$ ), es decir se busca en todas las características, aquella que maximice la función  $f$ . Luego se busca la segunda característica que combinada con la anterior maximice nuevamente  $f$  con dos características ( $m=2$ ). De esta manera, no son consideradas características que estén muy correlacionadas con la característica ya seleccionada, o bien que no proporcionen información para la detección, ya que no maximizan  $f$ . El método se repite hasta conseguir las mejores  $n$  características. En este caso es conveniente trabajar con las características normalizadas, es decir cada característica es transformada linealmente de tal forma que tenga un valor medio igual a cero y una varianza igual a uno.

También es posible usar otra función objetivo para evaluar la separación entre las clases. Una función alternativa sería evaluar la especificidad para una clasificación por umbral que obtenga una sensibilidad de un 100%, esto es conocido en la literatura como  $S_p @ S_n=100\%$ . Las selecciones de las 10 primeras características usando SFS son mostradas en la Fig. (6) para ambas funciones objetivo. Se observa el aumento de la función objetivo a medida que se van agregando nuevas características con el método SFS. A manera de ejemplo, utilizando sólo una característica, la característica N° 31 ( $K$ ) es el que maximiza la función  $J$ , obteniendo así un valor de  $J=6.8$  (ver primera columna de Fig. (6a)). Asimismo, al emplear esta característica con la característica N° 101 ( $Tx_2$ ) la función objetivo  $J$  aumenta a 8.5 (ver segunda columna de Fig. (6a)). Cabe recalcar que esta textura es la característica que más incrementa  $J$  en combinación con la característica  $K$ . Este proceso se repite hasta completar las 10 mejores características.

Se puede concluir que hay varias características seleccionadas que tienen un desempeño significativo. Una combinación adecuada de características de contraste y textura son las que obtienen una mejor separabilidad de las clases. Al diseñar el clasificador también es necesario considerar el costo computacional del cálculo de las características. Es recomendable optar por características que puedan ser computadas de manera rápida para que la detección de fallas pueda hacerse en el tiempo requerido en el proceso de inspección automática.




Figura 5: Curva ROC y distribución de clase para la mejor característica de contraste.

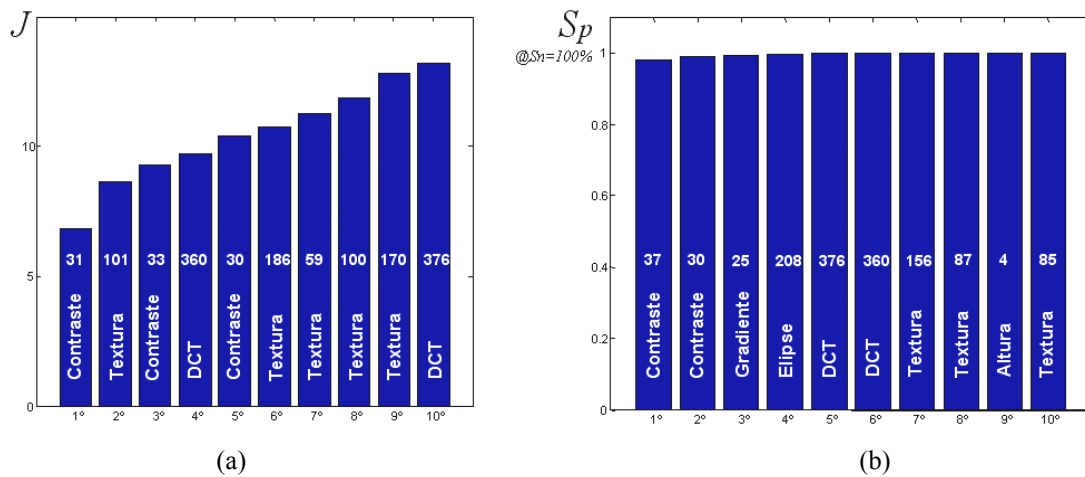


Figura 6: Selección de las primeras 10 características por medio del método SFS usando a) discriminante Fisher ( $J$ ) y b) especificidad para sensibilidad = 100%.

#### 4. Análisis de correlación lineal

El análisis de los coeficientes de correlación lineal es una forma de evaluar la correlación existente entre las características escogidas, así como la correlación entre las características y la variable de supervisión de clasificación ideal  $y_k$ , donde  $y_k$  es 1 (ó 0) si la muestra  $k$  pertenece a las clase 'defecto' (o 'estructura regular'). Una obtención de los coeficientes de correlación lineal es explicada en detalle en (Silva et al, 2002a).

En este trabajo, después de la preselección de las 28 características más relevantes según los criterios de Fisher y ROC resumidos en la Tab. (2), se realizó un análisis de correlación lineal con un conjunto escogido de las 60 muestras existentes de la clase 'defecto' y 180 muestras seleccionadas aleatoriamente de la clase 'estructura regular' del total de 22.876 muestras pertenecientes a esta clase. El valor límite para que una variable tenga 95% de probabilidad de estar correlacionada con otra está dado por  $2/\sqrt{N}$  donde  $N$  es el número de muestras de las variables (Silva et al, 2002a). Los valores límites encontrados entonces fueron  $2/\sqrt{60} = 0.26$  para la correlación con la clase 'defecto' y  $2/\sqrt{180} = 0.15$  para la correlación con la clase 'estructura regular', mientras que para la correlación entre características el valor límite encontrado fue  $2/\sqrt{60+180} = 0.13$ . La Figura (7a) muestra el histograma resultante para los valores de los coeficientes de correlación encontrados entre las características y la variable  $y_k$ . Asimismo, la Fig. (7b) muestra el histograma de los coeficientes de correlación obtenidos entre todas las características. Resulta evidente de la Fig. (7a) que las 28 características están correlacionadas con la variable de supervisión de clasificación ideal  $y_k$ , pues los límites de 0.26 ó 0.15 son superados por el valor mínimo correspondiente a 0.56 (obtenido por la característica N° 25). El máximo coeficiente de correlación 0.81 fue obtenido por la característica N° 100.




Figura 7: a) Histograma de los coeficientes de correlación entre las características y las clases 'defecto' y 'estructura regular': b) histograma de los coeficientes de correlación entre las características.

La Figura (7b) muestra que existe una fuerte correlación entre la mayoría de las características pues el límite de 0.13 es superado por todos los coeficientes de correlación encontrados. A partir del gráfico se observa también que existen características altamente correlacionadas y que su utilización en un clasificador resultaría redundante.

Una buena medida de selección de características es emplear aquellas que representen una buena relación costo-beneficio, es decir las que su extracción no exija un costo computacional elevado y que al mismo tiempo tengan un buen desempeño en la clasificación. En este trabajo se seleccionan entonces las características de mayor relevancia según los criterios mencionados y que sean de fácil extracción. El objetivo es reducir por una parte la dimensión de los datos de entrada de los clasificadores y por otra parte reducir el tiempo de cómputo necesario para la extracción de las características, y de esta forma se puede disminuir el tiempo total del proceso de inspección.

## 5. Clasificación

En esta Sección se presentan los resultados obtenidos al utilizar clasificadores estadísticos y clasificadores lineales usando redes neuronales. El principal problema que se presenta en el diseño de estos clasificadores es la escasa información con que se cuenta de la clase 'defecto', ya que en los datos obtenidos de la segmentación, existen alrededor de 381 muestras de la clase 'estructura regular' por cada muestra de la clase 'defecto'. En este tipo de clasificación el desempeño no puede optimizarse minimizando el error en la clasificación, ya que un clasificador que indique que todas las muestras pertenecen a la clase 'estructura regular' tendrá, en nuestro caso, un *acierto* de  $381/382 = 99.74\%$ , sin embargo este clasificador no habrá detectado ninguno de los defectos. Por esta razón el desempeño de la clasificación debe medirse de acuerdo a los valores de sensibilidad y especificidad explicados en la Sección 3. En el entrenamiento se recomienda usar el criterio de Neyman-Pearson (Kay, 1998), en el que se maximiza la sensibilidad para una especificidad dada.

Para entrenar los clasificadores, se emplearon los conjuntos de datos mostrados en la Tabla (3). En estos conjuntos se tomaron el total de muestras de la clase 'defecto'. El conjunto I corresponde al total de la muestra. En los conjuntos II, III, IV y V se redujo la cantidad de muestras de la clase 'estructura regular'. En estos casos las muestras de 'estructura regular' fueron seleccionadas aleatoriamente y no existe entre los conjuntos seleccionados muestras comunes. En los conjuntos V y VI se duplicaron las muestras de la clase 'defecto' hasta igualar el número de muestras de la clase 'estructura regular'.

Tabla 3: Conjuntos de datos empleados en los experimentos.

	Conjunto I	Conjunto II	Conjunto III	Conjunto IV	Conjunto V	Conjunto VI
Defectos	60	60	60	60	2.000 <sup>6</sup>	22.876 <sup>6</sup>
Estructuras Regulares	22.876	180	500	2000	2.000	22.876

### 5.1 Clasificador estadísticos

En el reconocimiento estadístico de patrones, la clasificación es realizada usando el concepto de similitud: patrones que son *similares* son asignados a la misma clase (Jain et al, 2000). A pesar de que esta metodología es muy simple es necesario establecer una buena métrica que defina la similitud. Con una muestra representativa, en la que se conozca cómo debe ser la clasificación, es posible llevar a cabo una *clasificación supervisada* encontrando una función discriminante que nos proporcione información acerca del grado de similitud entre las  $m$  características a evaluar (contenidas en el vector de características  $\mathbf{x} = [x_1, \dots, x_m]^T$ ) y las características que representen cada clase. En este trabajo se realizan experimentos con los siguientes clasificadores estadísticos (Mery & Filbert, 2002a):

- **Clasificador por umbral:** Las fronteras de decisión de la clase 'defecto' definen un hipercubo en el espacio de las características, esto es, sólo si todas las características se encuentran dentro de ciertos límites ( $\theta_{11} \leq x_1 \leq \theta_{12} \dots \theta_{m1} \leq x_m \leq \theta_{m2}$ ) el vector de características  $\mathbf{x}$  será asignado a la clase 'defecto'.
- **Clasificador lineal:** se define una función discriminante  $d(\mathbf{x})$  como una combinación cuadrática de las características seleccionadas. Si  $d(\mathbf{x}) > \theta$  entonces  $\mathbf{x}$  es asignado a la clase 'defecto', de lo contrario a la clase 'estructura regular'. Usando la técnica de mínimos cuadrados, la función  $d(\mathbf{x})$  se puede estimar de la variable de supervisión de clasificación ideal  $\gamma(\mathbf{x})$  conocida a priori en la muestra representativa.
- **Clasificador del vecino más cercano (Euclídeo):** El vector de características  $\mathbf{x}$  es asignado a la clase 'defecto' si la distancia al centro de gravedad de esta clase  $\bar{\mathbf{x}}_1$  es menor que la distancia al centro de gravedad de la clase 'estructura regular'  $\bar{\mathbf{x}}_0$ . Cada centro de gravedad es calculado como el valor medio de la clase correspondiente en la muestra representativa. En este caso la detección de 'defectos' se realiza comparando las distancias Euclídeas ponderadas  $\|\mathbf{x} - \bar{\mathbf{x}}_1\| > p\|\mathbf{x} - \bar{\mathbf{x}}_0\|$ , dándole más importancia a la clase 'defecto'.

<sup>6</sup> Las 60 muestras de la clase 'defecto' fueron duplicados hasta igualar el número de muestras de la clase 'estructura regular'.



- **Clasificador de Mahalanobis:** Es el mismo que el clasificador del vecino más cercano pero utilizando la distancia de Mahalanobis, que por medio de la matriz de covarianza se ponderan las características a evaluar de acuerdo a sus varianzas.

En los experimentos primero se probó con un clasificador estadístico basado en umbral. Usando una sola característica ( $N^{\circ} 37$ ), la regla es clasificar una región como 'defecto' si la característica es mayor que un umbral. De esta manera se obtiene  $S_n = 95.0\%$  y una especificidad de  $1-S_p = 1.4\%$  usando el Conjunto I de datos. Esto quiere decir que de las 60 fallas reales existentes se han podido encontrar  $TP = 57$  correctamente, sin embargo también se obtienen  $FP = 325$  (falsas alarmas). Un clasificador de umbral con dos características clasifica una región como 'defecto' si cada característica supera un umbral de manera independiente. El espacio vectorial, así como las líneas de decisión para esta clasificación se aprecian en la Fig. (8). El desempeño obtenido es  $S_n = 95.0\%$ ,  $1-S_p = 1.0\%$  ( $TP = 57$  y  $FP = 230$ ) usando el Conjunto I de datos. El uso de clasificadores estadísticos más sofisticados no mejoró el desempeño de la clasificación, esto se debe a que las clases están sobrepuestas en el espacio de características. Los resultados de los clasificadores estadísticos se encuentran resumidos en la Tab. (4), Grupos 1 a 5.

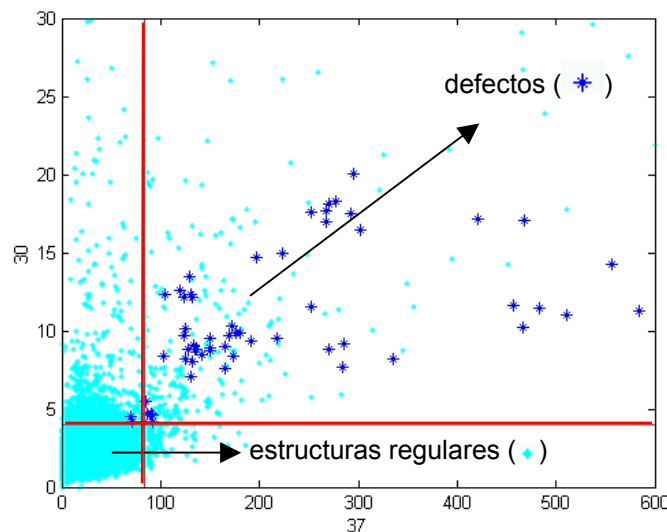


Figura 8: Espacio vectorial de las características  $F_1$  ( $N^{\circ} 37$ ) y  $K_{\sigma}$  ( $N^{\circ} 30$ ), las líneas rectas representan los umbrales.

## 5.2 Clasificadores lineales usando redes neuronales

En un criterio de reconocimiento de patrones usando redes neuronales, normalmente se comienza por el estudio de clasificadores lineales con el fin de establecer la posibilidad de separación lineal de las clases. Esto se debe a la simplicidad operacional y de desarrollo de estos clasificadores en comparación con los no lineales. Se puede explicar el funcionamiento de estos clasificadores de la siguiente manera. Un discriminador lineal decide si la muestra, representada por sus características agrupadas en un vector  $\mathbf{x}$ , pertenece a la clase 'defecto' si  $d(\mathbf{x}) > 0$  donde

$$d(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b. \quad (3)$$

En caso contrario se asignará  $\mathbf{x}$  a la clase 'estructura regular'. Se aprecia que el discriminador queda definido por el vector  $\mathbf{w}$ , que pondera la entrada  $\mathbf{x}$ , y  $b$  que representa un valor de *off-set*. En el dominio de la entrada, la función de discriminación representa un lugar geométrico de los puntos que satisfacen  $d(\mathbf{x}) = 0$ , es decir un hiperplano perpendicular al vector  $\mathbf{w}$  y a una distancia (en el sentido de  $\mathbf{w}$ ) de  $-b / \|\mathbf{w}\|$  del origen. Usualmente se normaliza  $\|\mathbf{w}\|=1$ , ajustándose el valor de  $b$  de modo de no alterar la inequación  $d(\mathbf{x}) > 0$ . En este caso  $d(\mathbf{x})$  mide la distancia de la entrada  $\mathbf{x}$  al hiperplano, y es una medida de la probabilidad de acierto de la clasificación para aquella entrada específica (Silva et al, 2001). Un discriminador óptimo es aquel que maximiza la probabilidad de acierto de la clasificación. Los discriminadores lineales óptimos son una técnica muy utilizada en estadística conocida como *Discriminadores de Fisher*. Una forma práctica de implementarlos es a través de un red neuronal con una capa y, en esta capa, una única neurona por clase, conforme a lo que describe Haykin (1994). En nuestro trabajo, los clasificadores lineales fueron implementados usando una red supervisada con sólo una neurona del tipo tangente hiperbólica:

$$U = \tanh(d(\mathbf{x})). \quad (4)$$

El aprendizaje se realizó usando el algoritmo de retro-propagación del error y con entrenamiento en cascada (Haykin, 1994). La Figura (9) ilustra el modelo neuronal de implementación del clasificador usado.

Como el proceso de aprendizaje neuronal usado es la minimización del error medio cuadrático total, el entrenamiento en el que existen muchas muestras de la clase 'estructura regular' y muy pocas de la clase 'defecto' (en nuestro caso la proporción es 381:1) no es aconsejable, ya que la clase 'estructura regular' sería predominante en este proceso de aprendizaje y, lógicamente, la red se entrenaría más en el sentido de minimizar el error de la 'estructura regular' que del 'defecto'. Existen dos soluciones para solucionar este problema: se puede reducir la cantidad de muestras de la clase más grande (perdiendo la capacidad de generalización de la red), o bien se duplica las muestras de la clase más pequeña disminuyendo así la tendencia de predominancia de la clase más grande (Haykin, 1994). En nuestro caso se probaron ambas posibilidades.




Figura 9: Modelo de la red supervisada con retro-propagación del error. La red cuenta con sólo una neurona para implementación de los clasificadores lineales.

La Tabla (4), Grupos 6, 7 y 8, presenta los resultados de  $S_n$  y  $1-S_p$  obtenidos con los clasificadores lineales para los tres conjuntos de datos usando las 28 características de la Tab. (2). Se observa que se detectaron todos los defectos en los tres casos. Por otra parte, el número de falsas alarmas ( $FP$ ) es apenas 2 para los conjuntos II y IV, y cero para el conjunto III, lo que significa un valor de  $1-S_p$  muy bajo en todos los casos. Estos resultados son excelentes y comprueban que es posible la separación lineal usando redes neuronales entre ambas clases cuando se utilizan las 28 características de la Tab. (2).

Tabla 4: Desempeño de los clasificadores estadísticos y de redes neuronales en diversos experimentos.

Grupo	Características	Clasificador	Conjunto	TP	FP	$S_n$	$1-S_p$
1	Nº 37	umbral	I	57 / 60	324 / 22.876	95.0%	1.42%
2	Nº 30, 37	umbral	I	57 / 60	230 / 22.876	95.0%	1.00%
3	Nº 30, 31, 37	lineal	I	57 / 60	310 / 22.876	95.0%	1.33%
4	Nº 30, 37, 101	Euclideo	I	57 / 60	326 / 22.876	95.0%	1.59%
5	Nº 30, 37, 101	Mahalanobis	I	57 / 60	363 / 22.876	95.0%	1.59%
6	28 características de Tab. (2)	RN	II	60 / 60	0 / 180	100.0%	0.00%
7	28 características de Tab. (2)	RN	III	60 / 60	0 / 500	100.0%	0.00%
8	28 características de Tab. (2)	RN	IV	60 / 60	2 / 2000	100.0%	0.10%
9	Nº 25, 30, 31, 33, 37, 101, 186, 208, 360, 376	RN	IV	60 / 60	2 / 2000	100.0%	0.10%
10	Nº 4, 8, 25, 30, 31, 33, 37	RN	IV	58 / 60	8 / 2000	99.6%	0.40%
11	Nº 30, 37	RN	IV	52 / 60	7 / 2000	86.5%	0.35%
12	Nº 30, 37	RN	V	60 / 60	2 / 2000	100.0%	0.10%
13	Nº 30, 37	RN	VI	60 / 60	558 / 22.876	100.0%	2.44%
14	$P_1, P_2$ de PCA de 28 características	RN	IV	60 / 60	2 / 2000	100.0%	0.10%
15	$P_1$ de PCA de características 30 y 37	RN	IV	60 / 60	2 / 2000	100.0%	0.10%

Con el objeto de realizar un clasificador que use menos características, se tomaron de las diez características más relevantes encontradas por el método SFS usando el discriminante Fisher (ver Fig. (6a)) y la variable  $S_p @ S_n=100\%$  (ver Fig. (6b)), un conjunto de 10 características compuesta por las 6 primeras características de cada método (como se aprecia de la Fig. (6)) las características Nº 30 y Nº 360 son comunes en ambas selecciones). Se evaluó el desempeño en un clasificador lineal de estas características con el Conjunto IV de datos. El resultado obtenido, como se muestra en la Tab. (4), Grupo 9, fue también  $S_n = 100\%$  y  $1-S_p = 0.1\%$  ( $TP = 60, FP = 2$ ). Por lo tanto, con una reducción dimensional de 28 a 10 características, el resultado es idéntico, comprobando que la reducción de la dimensión de los datos de entrada es posible y aconsejable.

Posteriormente, usando las 8 características que representan el menor costo computacional -las 8 primeras de la Tab. (2)- se constituyó un nuevo conjunto de entrenamiento usando también los datos Conjunto IV. El resultado obtenido se muestra en la Tab. (4), Grupo 10. Se aprecia que  $S_n = 96.6\%$  y  $1-S_p = 0.4\%$  ( $TP = 58, FP = 8$ ), lo que representa un índice un poco inferior al obtenido con las 28 características inicialmente usadas. Sin embargo, la reducción porcentual es pequeña comparada con la dificultad que representa la extracción del total de características.

En la Figura (8), donde se ilustra el espacio vectorial de las características Nº 30 y Nº 37, se puede apreciar la buena separación entre las clases usando estas características. Por esta razón se realizó un nuevo experimento con los

datos del Conjunto III, pero usando sólo las dos características mencionadas. Inicialmente, para este conjunto de datos, el resultado fue apenas  $S_n = 86.5\%$  y  $1-S_p = 0.35\%$  (ver Tab (4), Grupo 11). En este caso, la reducción de la sensibilidad es bastante significativa. La justificación para esta reducción de la sensibilidad se debe, probablemente, a la diferencia de cantidad de muestras por clase, la que se acentúa aún más en la medida que 26 características fueron eliminadas. Para comprobar esta hipótesis, se duplicó la cantidad de datos de defecto hasta obtener 2000 muestras (Conjunto V de datos), igualando la cantidad de las muestras pertenecientes a las clase 'estructura regular', dando así igual importancia a ambas clases durante el proceso de entrenamiento de la red. El resultado encontrado se aprecia en la Tab. (4), Grupo 12. Sorprendentemente, el desempeño fue el mismo que el obtenido por el conjunto compuesto por las 28 características, es decir  $S_n = 100\%$  y  $1-S_p = 0.1\%$ . Por esta razón, se comprueba definitivamente que la reducción de los datos de entrada es satisfactoria.

Como prueba final se entrenó la red neuronal con el conjunto VI formado por 22.876 muestras de la clase 'defecto' (duplicados) y las 22.876 muestras de la clase 'estructura'. Como el entrenamiento de esta red representa un costo computacional muy alto, se consideraron sólo dos características, la N° 30 y la N° 37 que presentaron un muy buen desempeño en su evaluación. El resultado dio  $S_n = 100\%$  y  $1-S_p = 2.44\%$  (ver Tabla (4), Grupo 13).

### 5.3 Principales Componentes de Discriminación Lineal

Es difícil visualizar el espacio vectorial de las características cuando se trata de un sistema de más de 3 dimensiones. Éste es el caso mostrado en la Tab. (2) en el que existe un conjunto de 28 características. Una forma de visualizar este espacio es mediante su proyección a otro espacio de dos o tres dimensiones. Comúnmente, esta reducción se hace por medio de la Transformada de Karhunen-Löve o conocida también como análisis de las componentes principales (PCA) (Castleman, 1996).

En este trabajo, se usaron las dos componentes principales de discriminación lineal con actuación independiente, implementadas con una red del tipo retro-propagación del error y sólo un neurona (Silva et al, 2003), para visualizar la discriminación entre ambas clases con el Conjunto IV de datos. La Figura (9) muestra el gráfico bidimensional compuesto por las dos componentes principales ( $P_1$  y  $P_2$ ) obtenido de las 28 características. Se aprecia que es posible la separación de las clases usando un simple clasificador lineal. En este caso ocurren sólo dos falsas alarmas, los resultados se resumen en la Tab. (4), Grupo 14.

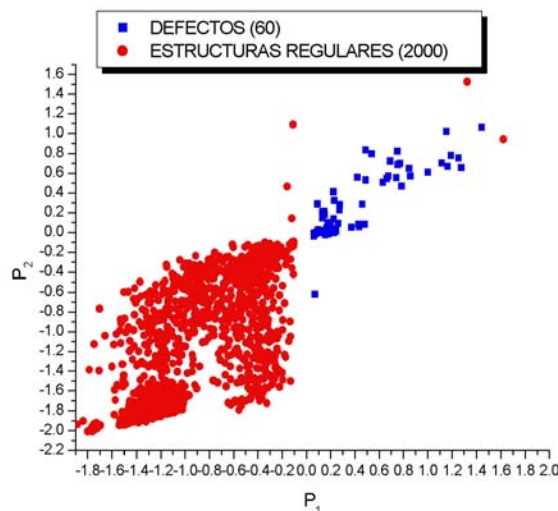


Figura 9: Gráfico bidimensional de las dos componentes principales ( $P_1$  y  $P_2$ ) de discriminación lineal a partir de las 28 características de la Tab. (2).

Otra aplicación de las componentes principales de discriminación es la reducción de la dimensión de los datos de entrada al clasificador, que en nuestro caso las características candidatas representan un total de 405 (ver Tab. (1)). Estas características pueden ser sustituidas por las componentes principales de discriminación, reduciendo la dimensión del sistema a 2, 3 ó 4 dimensiones<sup>7</sup>. En este caso, el resultado de clasificación obtenido mostró que las características N° 30 y N° 37 son extremadamente relevantes y suficientes para obtener un índice elevado de acierto. A partir de un análisis de componentes principales para estas dos características y tomando sólo la primera componente principal como variable de entrada al clasificador lineal se puede realizar un nuevo experimento. Es decir, con la primera componente resultante, definida como la proyección de la entrada en dirección principal de discriminación lineal (Silva et al, 2003), tenemos ahora una nueva característica que es la combinación lineal de las dos primeras. Una nueva

<sup>7</sup> Esta reducción implica una simplificación sólo en el diseño del clasificador. No hay que olvidar que para obtener las componentes principales es necesario contar con todas las características originales. En el ejemplo mencionado, para obtener las dos, tres o cuatro primeras componentes es necesario extraer primero las 405 características iniciales.

evaluación de desempeño usando este componente fue hecha y el resultado indicó el mismo  $S_n = 100\%$  y  $S_p = 99.9\%$  (ver Tab. (4), Grupo 15). Resumiendo, a partir de una dimensión inicial de 405 características, se llega a apenas una dimensión. Estos resultados comprueban una vez más lo que Silva et al (2002b) concluyó en su trabajo: lo importante es la *calidad* de las características y no la *cantidad* de características utilizadas.

## 6. Conclusiones

En este trabajo se ha presentado un análisis exhaustivo de regiones segmentadas de imágenes radioscópicas ruidosas con el fin de poder llevar a cabo una detección automática de fallas en piezas de aluminio fundido. En este estudio se presentan más de 400 características que fueron extraídas de casi 23.000 regiones. El análisis de las características extraídas indica que la información de las fallas no está tan contenida en las características geométricas sino más bien en las características de intensidad, especialmente en las de contraste y textura. Diversos experimentos fueron realizados en distintas situaciones, evaluando el desempeño de clasificadores estadísticos y basados en redes neuronales en diversas combinaciones de características y conjuntos de datos de entrenamiento. Los resultados son similares, en casi la totalidad de los experimentos fue posible detectar un alto número de defectos reales con un número muy bajo de falsas alarmas ( $S_n > 95\%$ ,  $1-S_p < 2.5\%$ ). Si bien es cierto que este resultado es muy bueno en términos porcentuales, no lo es tanto en términos absolutos, ya que el número de falsas alarmas aún es muy alto: considerando que hay alrededor 23.000 fallas hipotéticas en 50 imágenes, un valor  $1-S_p = 1\%$  indica que en promedio hay aproximadamente 5 falsas alarmas por imagen, lo cual en la industria no es aceptable. Sin embargo, estos resultados son sustancialmente mejores que los presentados por Mery & Filbert (2002a), en los que en las mismas imágenes se obtuvo por ejemplo un valor de  $1-S_p = 8\%$  lo cual indica una detección de alrededor 15 falsas alarmas por imagen. El incremento en el desempeño se debe principalmente al desarrollo de las nuevas características de contraste presentadas en (Mery, 2003). Esto nos lleva a la conclusión ya mencionada que lo importante es la *calidad* de las características y no la *cantidad* de características utilizadas.

Por otra parte, esta línea de investigación pertenece al área de detección de fallas sin conocimiento a priori de la estructura de la imagen y con imágenes ruidosas. Es sabido que para estas imágenes, las falsas alarmas pueden ser eliminadas usando un análisis posterior basado en el procesamiento de secuencias de imágenes (Mery & Filbert, 2002b). Sin embargo, sería interesante probar los métodos descritos en este artículo en el análisis de imágenes radioscópicas en donde el ruido haya sido reducido mediante un proceso de integración, es decir promediando varias imágenes de la misma escena. Es muy probable que las falsas alarmas disminuyan aún más.

Como trabajo futuro pretendemos investigar la relevancia de las características extraídas según el criterio de relevancia usando redes neuronales descrito en (Silva et al, 2002b); indagar sobre otras técnicas de selección de características (Jain et al, 2000); implementar otros clasificadores (basados en redes neuronales más complejas, o en lógica difusa, o bien en una fusión de clasificadores) y experimentar con nuevas características que aumenten el desempeño de la clasificación.

También es necesario encontrar nuevos datos con el fin de contar con una muestra más representativa de la clase 'defectos', esto permitiría por una parte entrenar mejor los clasificadores y por otra parte tener un conjunto de datos de entrenamiento y otro conjunto de datos de pruebas independientes. Como en este trabajo la muestra de la clase 'defecto' es muy pequeña, las pruebas se hicieron sobre los mismos datos del entrenamiento.

Con el fin de que otros miembros de la comunidad científica de ensayos no destructivos hagan aportes al conocimiento en esta área, la tabla de datos usada en este trabajo se encuentra disponible en

<http://www.diinf.usach.cl/~dmery/papers/PANNDT2003a.htm>

Los datos están en formato de texto plano. La tabla contiene 22.936 filas y 29 columnas. Cada fila es una muestra. Las primeras 28 columnas corresponden a las 28 características de la Tabla (2), a manera de ejemplo la columna 7 es la característica  $F_1$ . La columna 29 constituye la variable de supervisión de clasificación ideal  $y_k$ , donde  $y_k$  es 1 (ó 0) si la muestra  $k$  ( $k=1\dots 22.936$ ) pertenece a las clase 'defecto' (o 'estructura regular').

## 7. Referencias

- Bishop C. M., 1995: "Neuronal Networks for Pattern Recognition". New York. Oxford University Press. 1995.
- Castleman, K., 1996, "Digital Image Processing". Prentice-Hall, Englewood Cliffs, New Jersey.
- Danielsson, P.Y., 1978: "A new shape factor". Computer Graphics and Image Processing 7, 292–299.
- Egan, J., 1975 "Signal detection theory and ROC analysis". Academic Press, New York.
- Fitzibbon, A., Pilu, M., Fisher, R.B., 1999, "Direct Least Square Fitting Ellipses", IEEE Trans. Pattern Analysis and Machine Intelligence, 21(5):476-480.
- Fukunaga, K., 1990, "Introduction to statistical pattern recognition", Academic Press, Inc., Second Edition, San Diego.
- Haralick, R., Shanmugam, K., Dinstein, I., 1973, "Textural features for image classification". IEEE Trans. on Systems, Man, and Cybernetics SMC-3, 610–621.
- Haykin S. "Neuronal Networks – A Comprehensive Foundation". Macmillian College Publishing. Inc. 1994.

- Jain, A.K., Duin, R.P.W., Mao, J., 2000, "Statistical Pattern Recognition: A Review", IEEE Trans. Pattern Analysis and Machine Intelligence, 22(1):4-37.
- Kamm, K.F., 1998, "Grundlagen der Röntgenabbildung". In *Moderne Bildgebung: Physik, Gerätetechnik, Bildbearbeitung und -kommunikation, Strahlenschutz, Qualitätskontrolle*, K. Ewen (Ed.), 45-62, Georg Thieme Verlag, Stuttgart, New York, 1998.
- Kay, S.M., 1998, "Fundamentals of Statistical Signal Processing: Detection Theory". Prentice Hall Signal Processing Series, Volume 2. 1998.
- Mery, D., Filbert, D., 2002a, "Clasificación de Potencial Defects in Automated Inspection of Aluminium Castings Using Statistical Pattern Recognition". In Proceedings of 8th European Conference on Non-Destructive Testing (ECNDT 2002), Jun. 17-21, Barcelona, Spain.
- Mery, D., Filbert, D., 2002b, "Automated Flaw Detection in Aluminum Castings Based on the Tracking of Potential Defects in a Radioscopic Image Sequence". IEEE Transactions on Robotics and Automation, 18(6): 890-901.
- Mery, D., 2003, "Crossing line profile: a new approach to detecting defects in aluminium castings". Accepted in Scandinavian Conference on Image Analysis (SCIA-2003), June 29 – July 2, Göteborg, Sweden. To be published in Lecture Notes in Computer Science, 2003.
- Mery, D., Filbert, D., Jaeger, Th., 2003, "Image Processing for Fault Detection in Aluminum Castings". In "Analytical Characterization of Aluminum and Its Alloys", Ed. C.S. MacKenzie and G.Y. Totten, Marcel Dekker Inc. , New York (in Press).
- Silva, R.R., Siqueira, M. H. S., Calôba, L.P. et al, 2001, "Radiographics Pattern Recognition of Welding Defects using Linear Clasifiers". Insight, 43(10):669-674.
- Silva R R, Siqueira M H. S, Calôba L P, et al., 2002a, "Contribution to the Development of a Radiographic Inspection Automated System". In Proceedings of 8th European Conference on Non-Destructive Testing (ECNDT 2002), Jun. 17-21, Barcelona, Spain.
- Silva R R, Siqueira M H. S, Calôba L P, et al., 2002b "Evaluation of the Revelant Characteristic Parameters of Welding Defects and Probability of Correct Clasification using Linear Clasifiers". Insight, 44(10): 616-622.
- Silva R R, Calôba L P, Siqueira M H. S, Rebello, J.M.A., 2003, "Patterns nonlinear clasifier of weld defects in industrial radiographies". In Proceedings of 3th Panamerican Conference for Nondestructive Testing – PANNDT, Rio de Janeiro, 02-07 Junio, 2003.
- Sonka, M., Hlavac, V., Boyle, R., 1998: "Image Processing, Analysis, and Machine Vision", 2 edn. PWS Publishing, Pacific Grove, CA.
- Zahn, C., Roskies, R., 1971, "Fourier descriptors for plane closed curves". IEEE Trans. Computers C-21 269–281.

## 8. Copyright Notice

The author is the only responsible for the printed material included in his paper.

## Agradecimientos

Los autores agradecen al Departamento de Investigación y Desarrollo de la Universidad de Santiago de Chile (proyecto DICYT 06-0119MQ), y al CNPq, CAPES y FAPERJ por el financiamiento de esta investigación.

# DETECTION OF FLAWS IN CASTINGS USING PATTERN RECOGNITION

**Domingo Mery, Romeu R. da Silva, Luiz P. Calôba, João M. A. Rebello**

**Abstract.** *In this paper we report the results obtained recently by classifying potential defects in the automated x-ray inspection of aluminium castings using pattern recognition. In our classification, more than 400 features (e.g. area, perimeter, roundness, invariant moments, Fourier descriptors, mean grey level, several contrasts, texture features, etc.) were analysed to characterise the potential flaws. The extracted features were measured from approximately 23.000 regions segmented in 50 radiosopic images (without frame averaging) of cast aluminium wheels. In addition, statistical classifiers and classifiers based on neural networks were tested.*

**Keywords.** *flaw detection, pattern recognition, castings, classifiers, digital image processing.*