

# **Aplicación de la Red Neuronal Probabilística para la clasificación de productos conforme a sus especificaciones**

**Paloma Teresita Gutiérrez-Rosas**

Instituto Tecnológico de Celaya, Celaya, Guanajuato, México, [palomagt89@hotmail.com](mailto:palomagt89@hotmail.com)

**José Antonio Vázquez-López**

Instituto Tecnológico de Celaya, Celaya, Guanajuato, México, [antonio.vazquez@itcelaya.edu.mx](mailto:antonio.vazquez@itcelaya.edu.mx)

**Manuel Darío Hernández-Ripalda**

Instituto Tecnológico de Celaya, Celaya, Guanajuato, México, [buzonmdhr@yahoo.com.mx](mailto:buzonmdhr@yahoo.com.mx)

**Armando Javier Ríos-Lira**

Instituto Tecnológico de Celaya, Celaya, Guanajuato, México, [armando.rios@itcelaya.edu.mx](mailto:armando.rios@itcelaya.edu.mx)

## **ABSTRACT**

The present article is about the problem of product classification in predetermined classes. In this problem was considered more than one evaluation criteria associated with quality product assessment, the considered product was an industrial plastic injection moulded test tube whose metrics for evaluation of quality were diameter and length; both features have upper and lower specifications. We consider a database obtained by measuring diameter and length of a test tube sample group, expressing the measurements in millimeters; forming the database that produces the product classification rules. This problem was approached in two stages; different between them by the number of classes. The first stage considers nine classes and the second one considers two. The classification problem was solved by a probabilistic neuronal network (PNN) with the use of a bayesian optimal classification rule. The efficacy of classification results of PNN and the best parameters values of network operation are presented. The PNN has a higher efficacy with a classification of a two-classes problem than in a nine-classes problem.

**Keywords: Probabilistic Neural Network, bayesian classification rule, classification problem.**

## **RESUMEN**

En la presente investigación se plantea el problema de la clasificación de productos en clases predeterminadas. En este problema se consideró más de un criterio de evaluación asociado con valoraciones sobre la calidad del producto, el producto considerado fue una probeta industrial moldeada por inyección en plástico, cuyas métricas para evaluar la calidad fueron diámetro y longitud; ambas características cuentan con especificaciones inferiores y superiores. Se consideró una base de datos obtenida por la medición del diámetro y longitud de un grupo de probetas muestra, expresando en milímetros las mediciones; formando la base de datos que dio origen a las reglas de clasificación del producto. Este problema se abordó en dos etapas, diferentes entre sí por la cantidad de clases existentes en cada una. En la primera etapa se consideraron nueve clases y dos en la segunda. El problema de clasificación fue resuelto con la aplicación de una Red Neuronal Probabilística (RNP) y una estrategia de clasificación bayesiana. Se presentan los resultados de la eficacia de clasificación de la RNP y los mejores valores para los parámetros de operación de la red. La RNP presenta una mayor eficacia con un problema de clasificación en dos clases que en nueve.

**Palabras claves:** Red Neuronal Probabilística, estrategia de clasificación bayesiana, problema de clasificación.

## 1. INTRODUCCIÓN

Las redes neuronales artificiales (RNA) han tenido aplicación en el campo de la ingeniería industrial, para la detección de patrones que comúnmente suelen detectarse en los gráficos de control al medir características de calidad de productos manufacturados. Gutiérrez-Rosas et al., (2012) aplicó a la RNA Perceptrón para la detección del patrón de variación especial denominado “cambio superior en la media” y de igual manera Vázquez-López et al., (2012) aplicó la RNA Perceptrón como sistema clasificador de puntos fuera de control en el ámbito del gráfico de control de mediciones individuales.

En el ámbito de la ingeniería industrial en ocasiones es deseable clasificar un producto como defectuoso o no defectuoso, suele utilizarse este tipo de clasificación cuando en el producto bajo estudio existen no una, sino varias características de calidad en las cuales se han establecido especificaciones de calidad para cada una de las características que contiene el producto. En otras palabras existen dos o más características de calidad bajo estudio, con dos o más especificaciones cada una.

Diversos autores señalan a la Red Neuronal Probabilística como una herramienta eficiente para el reconocimiento de patrones (Kiyani & Yildirim, 2004, Adeli & Panakkat, 2009, Cadena et al., 2008, Pérez Ramírez & Fernández, 2007, Hunter et al., 2002), en la mayoría de los casos usada en problemas de clasificación y reconocimiento, en los cuales exista más de una variable a evaluar. Los autores referidos han reportado una eficiencia de reconocimiento mayor al 90% en algunas de las investigaciones, ofreciendo un menor rango de error y tiempo de ejecución en comparación de otras redes neuronales como las que utilizan el algoritmo backpropagation (Cadena et al., 2008) o la Perceptrón simple y de doble capa (Pérez Ramírez & Fernández, 2007).

Una norma aceptada o estrategia, para la toma de decisión al clasificar, es que se debe de buscar la forma de minimizar el “riesgo esperado”, es decir el riesgo de asignar o clasificar a la clase equivocada. Tales estrategias son llamadas “Estrategias Bayesianas” y pueden ser aplicadas a problemas que contengan cualquier número de categorías o clases (Specht, 1990).

Es por las razones anteriores por lo cual se seleccionó a la RNP con el uso de una regla de clasificación bayesiana óptima para realizar la clasificación de probetas industriales moldeadas por inyección en plástico. La clasificación fue planteada considerando dos criterios asociados directamente con la evaluación sobre la calidad de las probetas. Los criterios de evaluación fueron dos variables de calidad de la probeta: diámetro y longitud ambas mediciones son expresadas en milímetros. Tomando en consideración que las variables: diámetro y longitud, cuentan con especificaciones de calidad tanto inferiores como superiores se plantearon dos etapas para resolver el problema de clasificación del producto.

En la primera etapa se consideró realizar la clasificación de las probetas en 9 clases diferentes y excluyentes entre sí. Las clases para esta primera etapa se formaron al considerar que cada una de las probetas al ser evaluada con respecto a las especificaciones de una de las características de calidad sólo podría clasificarse en tres diferentes estados: por debajo de la especificación inferior o por arriba de la especificación superior o cumpliendo con ambas especificaciones, es decir por arriba de la especificación inferior pero por debajo de la especificación superior. Considerando las evaluaciones de calidad de la probeta con respecto a las dos variables establecidas se obtienen 9 clases diferentes, por ejemplo; la primer clase se encuentra definida por las probetas cuya medida de longitud se encuentra por debajo de su correspondiente límite inferior de calidad y cuya medida de diámetro se encuentra también por debajo de su correspondiente límite inferior de calidad.

Para establecer las clases en la segunda etapa, se consideró que la finalidad de fijar especificaciones para diversas variables en un mismo producto, es definir si el producto cumple con todos los requisitos establecidos o no los cumple. Asignando de esta manera solamente dos clases: una primer clase conformada por las probetas que cumplan con todas las características de calidad establecidas, es decir la medida tanto de su longitud como de su diámetro se encuentran tanto por arriba de su límite inferior, como por debajo del límite superior de manera correspondiente y una segunda clase conformada por aquellas probetas que no cumpla con las especificaciones de calidad establecidas ya sea para una o para ambas variables.

En el primer apartado del presente documento se explica la forma en la cual opera una RNP de manera general al aplicar la regla de clasificación bayesiana óptima. En el segundo apartado se presenta el método utilizado en la

investigación, presentado la base de datos empleada para generar los datos utilizados en la experimentación para ser clasificados por la RNP Bayesiana, los valores de los parámetros de operación que se establecieron en la RNP Bayesiana y el procedimiento para asignar dichos valores y por último la explicación de la forma en la cual se llevó a cabo el proceso de clasificación en sus dos etapas. En el tercer apartado del documento se presentan los resultados obtenidos por la RNP Bayesiana considerando diversos valores para los parámetros de operación considerados y cuál fue la eficacia presentada con el uso de los mismos; por último se presentan las conclusiones obtenidas en el cuarto apartado, antes de finalizar con las referencias bibliográficas utilizadas para la creación de la presente investigación.

## 2. RED NEURONAL PROBABILÍSTICA

Las redes neuronales probabilísticas (RNP) pertenecen a la familia de redes neuronales con función base radial (Cadena et al., 2008). En el año de 1989 Donald F. Specht publicó su obra “Probabilistic Neural Networks”, en la cual introdujo el desarrollo una red neuronal probabilística (RNP) capaz de estimar límites o superficies de decisión no lineales mediante un enfoque óptimo Bayesiano.

### 2.1 REGLA DE CLASIFICACIÓN BAYESIANA

La regla de clasificación óptima bayesiana puede ser definida de la siguiente manera, dada una colección de muestras aleatorias de  $n$  poblaciones. La probabilidad a priori de que la muestra  $y_i$  pertenezca a la población  $k$ , es denotada como  $h_k$ . El costo asociado con una clasificación errónea de que una muestra pertenezca a la población  $k$  es denotada por  $l_k$ . La probabilidad condicional de que una muestra específica pertenezca a la población  $k$ ,  $p(k|y_i)$  está dada por la función de densidad de probabilidad  $f_k(y_i)$ . Por tanto, una muestra  $y_i$  es clasificada dentro de la población  $k$  si cumple la condición establecida en la Ecuación 1, en el caso de dos poblaciones (Hunter et al., 2002).

$$h_k l_k f_k(y_i) > h_j l_j f_j(y_i)$$

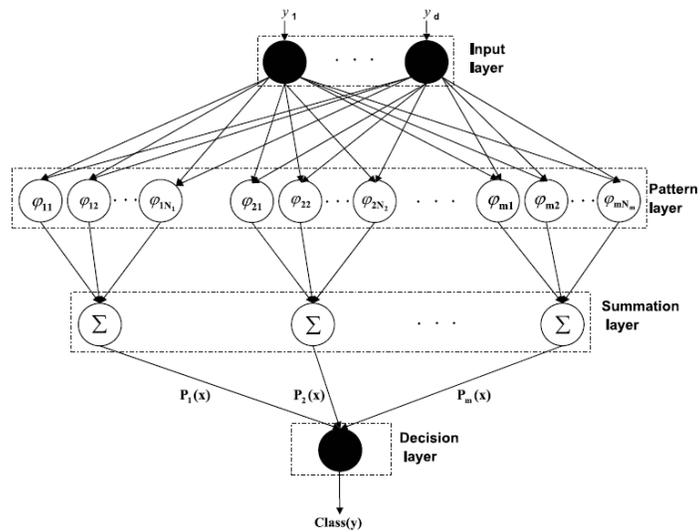
Ecuación 1

A diferencia del proceso de aprendizaje que se lleva a cabo en la mayoría de las Redes Neuronales Artificiales, en el cual se realiza un ajuste a los valores de los parámetros conocidos como pesos ( $w$ ) y bias ( $b$ ); para hacer uso de una RNP no es necesario realizar ningún ajuste de pesos y sólo se determina a los patrones de salida mediante la comparación y el cálculo de las distancias de cada uno de los patrones o vectores de datos de entrada con cada uno de los llamados patrones ejemplo, los cuales como su nombre lo dice son ejemplos representativos de los patrones de cada una de las clases existentes (Cadena et al., 2008).

### 2.2 ESTRUCTURA DE UNA RNP

Las redes neuronales probabilísticas están compuestas por cuatro capas: una capa de entrada, la cual consiste en  $d$  neuronas, donde  $a$  es la dimensión de los datos de entrada, una capa de patrones, la cual consiste en  $N$  neuronas, una por cada vector ejemplo, una capa sumatoria de  $k$  neuronas, donde  $k$  es el número de clases y una capa de decisión, la cual consiste en una neurona (Mehran & Hojjat, 2010), la descripción anterior se representa en la Figura 1.

Cuando a la red se le presenta un vector  $x = [x_1, \dots, x_d]$  a ser clasificado, la segunda capa se ocupa de calcular las distancias desde el vector de entrada hasta cada uno de los vectores o patrones ejemplo a través de la función  $\phi_j$  la cual funciona de acuerdo al kernel normal estándar utilizado como la función de densidad de probabilidad como se muestra en la Ecuación 2.



**Figura 1: Estructura de una Red Neuronal Probabilística (Mehran & Hojjat, 2010)**

$$p_i(y) = \frac{1}{(2\pi)^{\frac{d}{2}} \sigma^d} \exp \left[ -\frac{(y-x_i)^T (y-x_i)}{2\sigma^2} \right]$$

**Ecuación 2**

En la Ecuación 2, sigma ( $\sigma$ ) es el parámetro de dispersión, el cual toma un valor entre 0 y 1 que debe ser definido por el investigador. El término  $P_i(y)$  en la capa de sumatoria, indica la probabilidad condicional o verosimilitud de que  $y$  (el dato de entrada) pertenezca a la  $i$ -ésima clase y es obtenido a través de un proceso de sumatoria como el mostrado en la Ecuación 3.

$$P_i(y) = \frac{1}{N_i} \sum_{j=1}^{N_i} p_j(y)$$

**Ecuación 3**

En la capa de salida y será asignada a la clase con mayor verosimilitud, cumpliendo con lo establecido en la Ecuación 4.

$$Class(y) = \arg \max_i \{P_i(y)\}$$

**Ecuación 4**

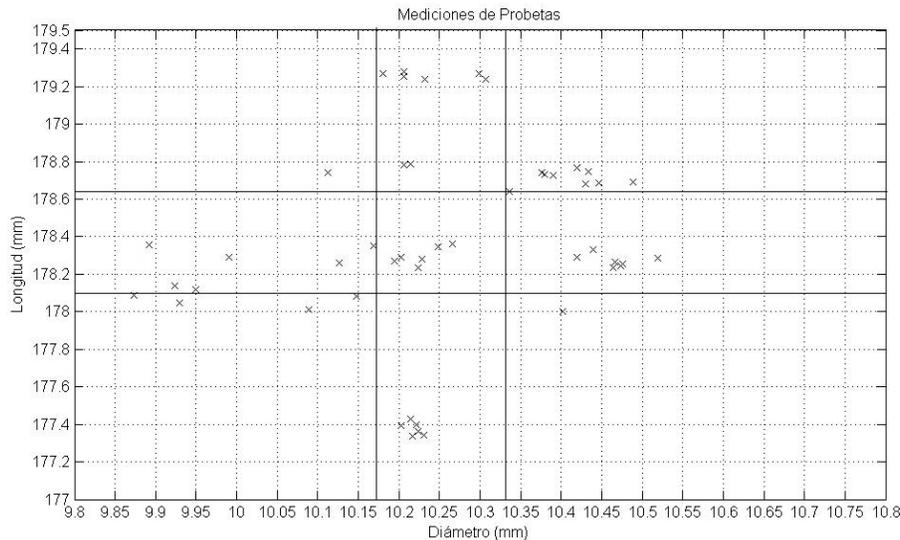
Donde  $Class(y)$  es la clase a la que  $y$  pertenece (Mehran & Hojjat, 2010).

### 3. MÉTODO

#### 3.1 DESCRIPCIÓN DE LOS DATOS BAJO ESTUDIO

Se generaron datos a través de un proceso de simulación utilizando el comando `normrnd` de Matlab (The Mathworks Inc., 2009), los datos se generaron bajo las características presentadas por los datos reales producto de mediciones de dos características de calidad de probetas industriales moldeadas por inyección en plástico, el diámetro y la longitud, ambas mediciones tomadas en milímetros. Para definir una clasificación real y adecuada a tales datos se consideraron especificaciones inferiores y superiores para ambas características.

En la Figura 2 se muestran las mediciones por probeta graficadas sobre un plano  $xy$  que considera a  $x$  como la medida del diámetro, y como la longitud; en dicho gráfico se observan las especificaciones para las características como líneas horizontales y verticales.



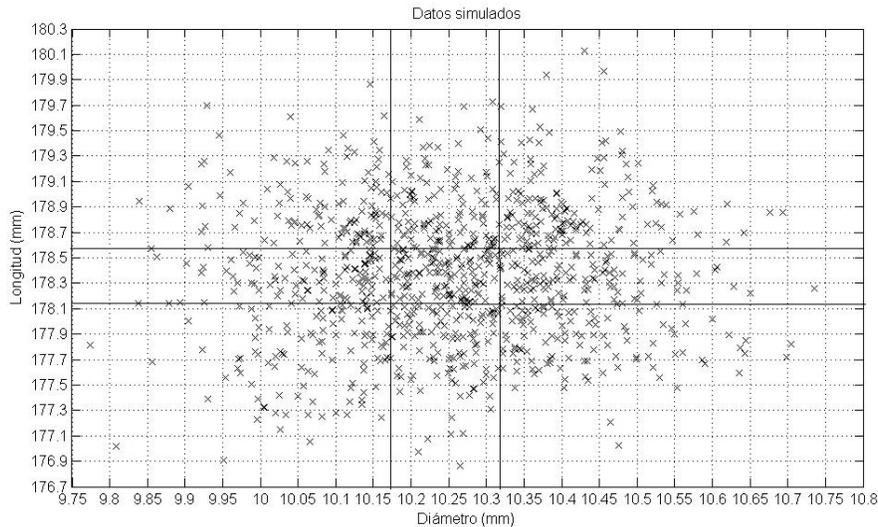
**Figura 2: Datos reales de las mediciones de probetas**

En la Figura 3, se muestra un ejemplo de los datos generados por simulación, los cuales fueron posteriormente clasificados por la RNP con la finalidad de verificar la eficacia de clasificación de la red.

### 3.2 ETAPA 1: CLASIFICACIÓN EN NUEVE CLASES

Se planteó en primera instancia el problema de clasificación considerando nueve clases, estas clases se forman al segmentar el plano  $xy$  mostrado en las figuras 2 y 3 en nueve áreas, formadas precisamente por los cortes entre las líneas que representan las especificaciones, de esta manera la clase 1, se encuentra formada por las probetas cuyo diámetro y longitud se encuentran por debajo de la especificación inferior correspondiente; la clase 2, ubicada a la derecha de la clase 1, corresponde a las probetas que cumplan con las especificaciones para la característica diámetro pero cuya longitud siga siendo menor a la establecida como deseable y así sucesivamente.

Para la aplicación de la RNP con el uso de la regla de clasificación bayesiana se requirió la simulación de la red en el software Matlab (The Mathworks Inc., 2009), a continuación se expone el pseudocódigo utilizado para realizar la programación, para la cual se siguieron las ecuaciones 1, 2, 3 y 4 con la finalidad de identificar la eficacia de clasificación de la red, ante diversos valores de las variables sigma ( $\sigma$ ) y función de pérdida de clase  $\mathcal{L}$  a fin de encontrar aquellos valores que minimicen la cantidad de errores durante la clasificación.



**Figura 3: Datos generados de las mediciones de probetas**

Inicia

Para cada  $k$ , desde  $k=1$  hasta  $k=N$

Para cada  $m$ , desde  $m=1$  hasta  $m=1000$

$$f_{1m} = \frac{1}{N} \sum_{j=1}^N \frac{1}{2\pi\sigma^2} \times e^{-\left[ \frac{(y_{m,j} - \mu_1)^2}{2\sigma^2} \right]}$$

$$f_{2m} = \frac{1}{N} \sum_{j=1}^N \frac{1}{2\pi\sigma^2} \times e^{-\left[ \frac{(y_{m,j} - \mu_2)^2}{2\sigma^2} \right]}$$

$$D_{k,m} = f_{k,m} \cdot h_k \cdot l_k$$

Obtener  $\text{Max}(D_{1,m}, \dots, D_{N,m}) = K_m$

Fin

Fin

Termina

En el pseudocódigo se representa con  $Y_{m,j}$  a la matriz de  $1000 \times 2$ , que representa la base de los 1000 datos generados a partir de las mediciones de las probetas, donde cada renglón de dicha matriz representa una probeta, cuyo primer elemento (primer columna) indica la medición del diámetro y cuyo segundo elemento (segunda columna) indica la medición de la longitud. De la misma manera entiéndase a  $X_{i,N,j}$  como la matriz que contiene a los  $N$  patrones ejemplo de la clase  $i$ , cuyos elementos se denotarán por  $x_{i,j}$ , existiendo tantas matrices  $X_i$  como  $k$  clases se consideren en el problema.

Los  $k$  vectores  $\mathbf{f}_{i,m}$  están compuestos por los 1000 elementos denotados como  $f_{i,m}$ . Los vectores  $\mathbf{K}_m$  contienen 1000 elementos cuyos valores van desde 1 hasta  $k$ , lo cual denota la clase a la que pertenece el  $m$ -ésimo dato.

Para el valor de sigma  $\sigma$  se consideraron los valores:  $\sigma=0.2, 0.4, 0.6, 0.8$  y  $1$ , mientras que para los valores de  $l_i$  se especificó para la investigación que sólo se realizarían pruebas modificando el parámetro para una de las nueve clases, se seleccionó a la clase número 5 pues corresponde a la clase en la cual se ubican los datos de las probetas que se encuentran dentro de las especificaciones tanto para el diámetro, como para la longitud, por tanto se incurriría en una pérdida económica mayor al clasificar los datos ubicados en esta categoría de modo incorrecto, es decir, la clase 5 es una categoría crítica.

Los valores que se consideraron para la  $l_5$  fueron de  $0.11, 0.12, 0.13, 0.14, 0.15, 0.16$  y  $0.17$ . Para cada valor de  $l_5$  considerado, se definieron valores de pérdida para las demás clases, atendiendo la regla de que cuando el valor de  $l_5$  aumentaba, el valor de pérdida para las otras clases disminuirían en la misma proporción para todas, manteniendo así las igualdades mostradas en la ecuación 5 y 6 durante la experimentación realizada.

$$1 - l_5 = l_1 + l_2 + l_3 + l_4 + l_6 + l_7 + l_8 + l_9$$

### Ecuación 5

Donde:

$$l_1 = l_2 = l_3 = l_4 = l_6 = l_7 = l_8 = l_9$$

### Ecuación 6

Con los resultados obtenidos de la experimentación anterior se especificó que los mejores valores para los parámetros de la red son  $\sigma=0.2$ ,  $h_i = \frac{l_i}{\sigma}$  y  $l_i = \frac{l_i}{\sigma}$ , donde el subíndice  $i$  indica la clase a la cual se hace referencia donde  $i=1,2,3,4,5,6,7,8,9$  para la primer etapa del problema de clasificación.

Con los valores previamente definidos se aplicó nuevamente la RNP en 35 bases de datos que contenían 1000 datos de probetas cada una, con la finalidad de obtener un promedio del número de errores y de la proporción de aciertos que presentó dicha Red para la clasificación en nueve categorías.

Se estableció de manera previa a la investigación, un nivel de aceptación para la resolución del problema de clasificación, si la red presentaba una eficacia mayor al 90%. Para la primera etapa del problema presentado, no se obtuvo el resultado deseado. Se realizaron varias pruebas aumentando el número de patrones ejemplo para verificar si esto contribuía a lograr el objetivo planteado, sin embargo al no obtener resultados satisfactorios se estableció una segunda etapa para la resolución del problema de clasificación.

### 3.3 ETAPA 2: CLASIFICACIÓN EN DOS CLASES

Para la segunda etapa para la solución del problema de clasificación se planteó la reducción del número de clases en las cuales se desea categorizar los datos, siguiendo el mismo pseudocódigo utilizado en la etapa anterior, esta reducción del número de clases se realizó considerando el hecho de que en la literatura sobre aplicación de RNP las pruebas experimentales realizadas han sido para clasificaciones de sólo dos clases y en todas ellas se ha tenido un alto índice de eficacia en cuanto a número de aciertos realizados por la red.

Se consideró el problema de la clasificación de datos con un enfoque de categorización en dos clases, esto se planteó al enfocar la atención del problema en identificar a aquellos datos que se encuentran dentro de todas las especificaciones (clase ubicada al centro de la Figura 3) como elementos de la clase uno y a los datos que no cumplen con alguna o varias de las especificaciones como elementos de una segunda clase.

Los valores establecidos para este nuevo planteamiento del problema de clasificación fueron de  $\sigma=0.2$ ,  $h_1 = \frac{l_1}{\sigma}$ ,  $h_2 = \frac{l_2}{\sigma}$ ,  $l_1 = \frac{l_1}{\sigma}$ , donde  $i=1$  es el identificador para la clase 1, la cual contiene a los datos que se

encuentran dentro de todas las especificaciones, el valor de  $h_1$  se estableció considerando que sólo un noveno de la población de datos se encontrará dentro de todas las especificaciones según lo observado en las características de las probetas y el resto de la población se encontrará fuera de al menos una de las especificaciones, esto se observa a partir de las Figuras 2 y 3. Con este nuevo planteamiento para la RNP se obtuvieron altos niveles de aciertos en la clasificación de los datos.

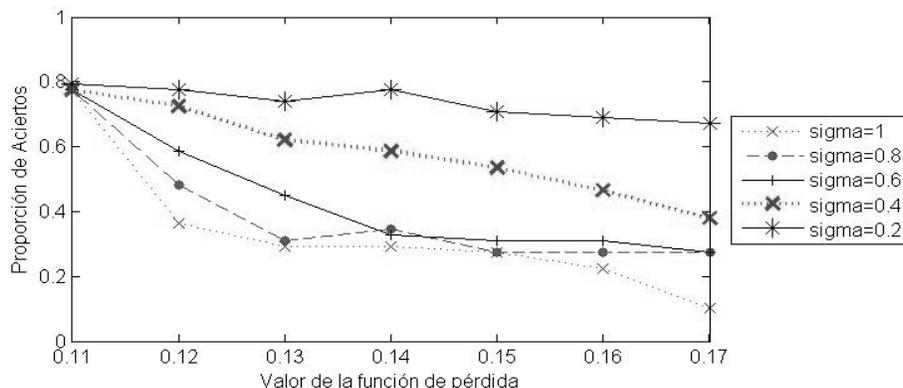
## 4. RESULTADOS

### 4.1 ETAPA 1: CLASIFICACIÓN EN NUEVE CLASES

La Figura 4 muestra la proporción de aciertos de clasificación obtenidos de aplicar la RNP Bayesiana en los datos reales de las probetas, para los diferentes valores asignados  $l_5$ , y considerando los diferentes valores de sigma establecidos en la sección anterior.

Como es posible observar en la Figura 4 el mejor valor, para el parámetro sigma fue  $\sigma=0.2$  y el mejor valor a considerar para la variable función de pérdida de la clase 5 ( $l_5$ ), fue de  $1/9$ , estos valores se consideraron como los óptimos para la experimentación con la RNP con los datos generados.

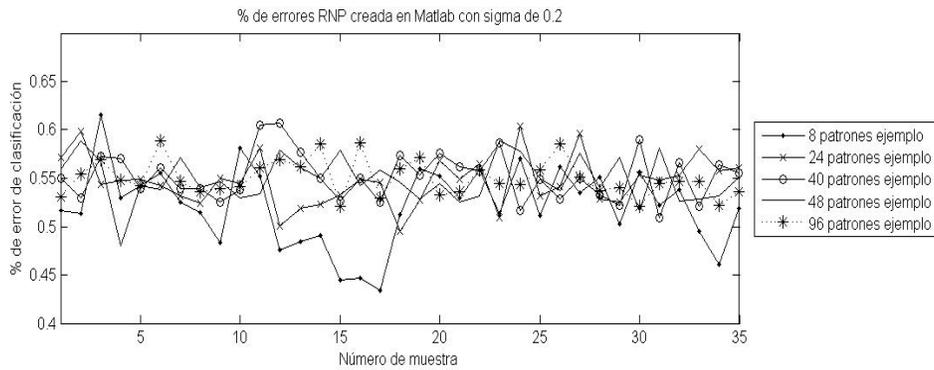
La RNP clasificó de manera correcta solamente el 53% de los datos generados (en promedio) que se encontraban segmentados en 9 clases, su margen de error es muy alto y permanece prácticamente constante aunque el número de patrones ejemplo en la segunda capa de la red sea aumentado, como se observa en la Figura 5. Sin importar el número de patrones ejemplo que la red utilice ya sean 10 ó 100 la RNP solo clasifica de manera correcta del 50 al 60% de los datos en las 9 clases correspondientes.



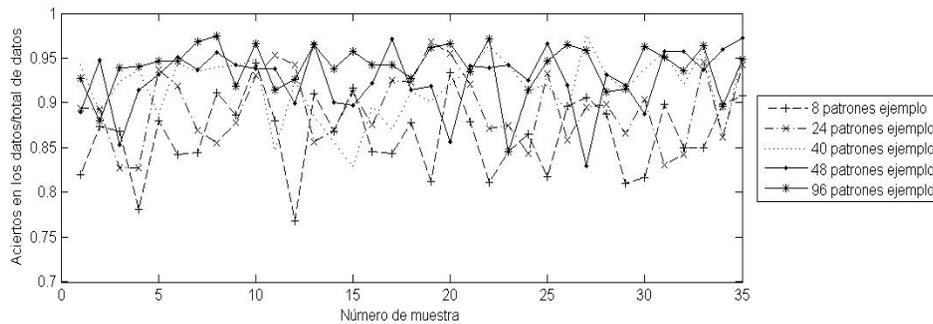
**Figura 4: Proporción de aciertos de la RNP aplicada a los datos reales de probetas para diferentes valores de la función de pérdida y sigma**

### 4.2 ETAPA 2: CLASIFICACIÓN EN DOS CATEGORÍAS

Al considerar el problema de clasificación solamente para dos clases y así mismo ajustar algunos de los parámetros de la RNP, ésta presentó una clasificación correcta de datos en el 92% de los casos en promedio. De igual manera que en el caso anterior se verificó si al aumentar el número de patrones ejemplo existía alguna modificación en la eficacia de la red, es decir si esto impactaba el número de clasificaciones correctas, se comprobó al igual que en el caso anterior que el número de patrones ejemplo en la red no afecta de manera muy significativa el desempeño de la red, lo cual se observa en la Figura 6.



**Figura 5: Proporción de aciertos de clasificación de la RNP para nueve clases, para diferente número de patrones ejemplo.**



**Figura 6: Proporción de aciertos de clasificación de la RNP para dos clases, considerando diferente número de patrones ejemplo**

## 5. CONCLUSIONES

La red neuronal probabilística no fue un buen multi-clasificador para el caso bajo estudio, es posible que esto se deba al número de variables o características implicadas en los datos bajo estudio puesto que son solo dos. Sin embargo ésta red presentó un muy buen desempeño como clasificador ante un problema de clasificación de dos clases, considerando los mismos datos con solo dos variables bajo estudio, presentando con ello aciertos en la clasificación mayores al 85%, con un promedio de 92% de aciertos en general.

Para los datos de probetas industriales considerados y el correspondiente problema de clasificación presentado en la investigación, el valor óptimo para el parámetro de dispersión  $\sigma$  de la red fue de 0.2, mientras que los valores de la función de pérdida para todas las clases se ubicaron en  $1/9$  para el problema de las nueve categorías y en  $1/2$  al considerar solamente dos clases.

La RNP suele mejorar su desempeño con el aumento de patrones ejemplo, sin embargo en los resultados arrojados por la presente se observó que la eficacia de la red neuronal presenta un comportamiento asintótico a partir de cierto número de patrones ejemplo. Al aumentar el número de patrones ejemplo en la red, se incrementa la eficacia de clasificación de la red, pero dicho aumento en la eficacia es mínimo a partir de un cierto número de patrones ejemplo. Lo anterior muestra un indicio de que es necesario tomar a consideración el costo o esfuerzo necesario para introducir nuevos patrones ejemplo a la red, en comparación con el beneficio obtenido en la eficacia de la red.

## 6. REFERENCIAS

- Adeli, H., & Panakkat, A. (2009). A probabilistic neural network for earthquake magnitude prediction. *Neural Networks* , 1018-1024.
- Cadena, J. A., Cadena, J. M., & Pérez Londoño, S. M. (2008). Aplicación de redes neuronales probabilísticas en la detección de fallas incipientes en transformadores. *Scientia et Technica* , 47-53.
- Gutiérrez-Rosas, P. T., Vázquez-López, J. A., Hernández-Ripalda, M. D., & Hernández-González, S. Uso de la red neuronal Perceptrón para detección de cambios pequeños en la media en los gráficos de control. *1st LACCEI International Symposium on Software Architecture and Patterns (LACCEI-ISAP-MiniPloP'2012)*. Panamá: LACCEI.
- Hunter, L., Klein, T. E., Jung, T. A., & Altman, R. B. (2002). *Pacific Symposium on Biocomputing 2003. Singapore: World Scientific.*
- Kiyan, T., & Yildirim, T. (2004). BREAST CANCER DIAGNOSIS USING STATISTICAL NEURAL NETWORKS. *Journal of electrical & electronics engineering* , 1149-1153.
- MATLAB, (2009). (R2009a) [Software de cómputo], Natick, Massachusetts: Math Works Inc.
- Mehran, A., & Hojjat, A. (2010). Enhanced probabilistic neural network with local decision circles: A robust classifier. *Integrated Computer-Aided Engineering* , 17, 197-210.
- Pérez Ramírez, F. O., & Fernández, C. H. (2007). Las redes neuronales y la evaluación del riesgo de crédito. *Revista Ingenierías Universidad de Medellín* , 77-91.
- Specht, D. F. (1990). Probabilistic Neural Networks. *Neural Networks* , 3, 109-118.
- Vázquez-López, J. A., Gutiérrez-Rosas, P. T., Ríos-Lira, A. J., & Esparza-Díaz, L. G. (2012). Aplicación de la Perceptrón en el gráfico de control de mediciones individuales. *Publicaciones en Ciencias y Tecnología* , 6, 21-30.

### ***Autorización y Renuncia***

*Los autores autorizan a LACCEI para publicar el escrito en las memorias de la conferencia. LACCEI o los editores no son responsables ni por el contenido ni por las implicaciones de lo que esta expresado en el escrito.*