
Sistema neuro-difuso para el control de atributos de calidad en inyección de plásticos

Alejandro Alvarado Iniesta, Roberto Romero López, Rey David Molina Arredondo, Salvador López Jiménez Rascón

Departamento de Ingeniería Industrial y Manufactura. Universidad Autónoma de Ciudad Juárez

RESUMEN

El presente trabajo presenta un híbrido de redes neuronales artificiales y lógica difusa aplicado para la optimización y control del proceso de inyección de plásticos. El objetivo de este estudio es mantener bajo control atributos de calidad de componentes plásticos mediante la manipulación de ciertos parámetros. El software de análisis de elemento finito “Moldflow” es empleado para simular el proceso de inyección. Como resultado se obtiene un sistema de lazo cerrado capaz de mantener bajo control en todo instante los atributos. Los resultados muestran una mejora significativa después de cada iteración del sistema hasta lograr los resultados deseados.

Palabras clave: Lógica Difusa, Redes Neuronales Artificiales, Inyección de Plásticos, Control Moderno

INTRODUCCIÓN

El proceso de inyección de plásticos se ha caracterizado por ser uno de los procesos de manufactura más versátiles con una extensa variedad y gran volumen de producción de componentes plásticos, los cuales son utilizados prácticamente en cada área de la industria (Rosato y Rosato, 1995). Ciertamente, el proceso parece ser muy simple; sin embargo, existen diversas fuentes de variación las cuales lo hacen difícil de controlar. Tales variaciones son inherentes debido a su complejidad, no linealidad e incertidumbre. Además, existen otros factores como lo son el mismo material, diseño del molde, condiciones ambientales, y hasta la interacción humana. Estos cambios afectan la calidad del producto terminado, la cual impacta los tiempos de ciclo y productividad, influyendo en los costos de las empresas del ramo.

En general, un componente plástico moldeado depende de los parámetros

involucrados en el proceso, que típicamente son establecidos y/o ajustados por los operadores y su experiencia. Hoy en día, las empresas no pueden darse el lujo de seguir con estos procedimientos, ya que consumen tiempo y son costosos, lo cual no puede ser permitido debido a la competitividad global que existe. En la actualidad, existen numerosas técnicas para el control y optimización de procesos como lo son los métodos estadísticos y sistemas de inteligencia artificial como lo es “Soft computing”; refiriéndose principalmente a técnicas como lo son la lógica difusa, redes neuronales artificiales, y algoritmos evolutivos. Diversos autores han enfocado su trabajo en el desarrollo y aplicación de estas técnicas ; en relación al proceso de inyección de plásticos, resulta muy conveniente el uso de estos enfoques ya que no requieren de un modelo matemático explícito (Lau et al.,1999; Lotti y Bretas, 2006; Spina, 2006; Liao et al., 2007; Changyu et al., 2007; Shie, 2008a; Shie,

2008b; Chen et al., 2009; Lin y Lian, 2009; Altan, 2010; Huang, 2011; Yin et al., 2011).

Como se mencionó anteriormente, pueden surgir ciertos defectos de calidad en producto terminado (acabado superficial deficiente, coloración deficiente, alabeo, líneas de flujo, encogimiento, rebaba, contaminación, etc.) si el valor en los parámetros del proceso de inyección es erróneamente establecido (temperaturas, presiones, velocidades, tiempos, etc.) Durante una corrida de producción normal, existen variaciones debido a la interacción de todas las variables involucradas y el entorno; comúnmente, los parámetros son ajustados manualmente por los operadores según su criterio y experiencia para lidiar con dicha variabilidad. Sin embargo, esto ya no puede ser permitido debido a la gran diversidad que puede existir en estos criterios. Por lo tanto, surge la necesidad de contar con un sistema capaz de contrarrestar los cambios inherentes del sistema y así mantenerlo bajo control en todo momento. Por consiguiente, este trabajo presenta un sistema neuro-difuso capaz de adaptarse a las variaciones del proceso de inyección combinando las fortalezas de la lógica difusa y las redes neuronales artificiales para obtener el cambio en cada parámetro de ser necesario. El objetivo es mantener bajo control tres atributos de calidad como lo son la deformación de la pieza, encogimiento, y peso final. Cinco parámetros del proceso son contemplados ya que son considerados como críticos en la variabilidad de los atributos de calidad (temperatura de plástico, temperatura de molde, presión de empaque, tiempo de empaque, y tiempo de enfriamiento (Huang y Tai, 2001; Erzurumlu y Ozcelik, 2006; Ozcelik y Sonta, 2009; Deng et al., 2010; Farshi et al., 2011). El

trabajo está dividido como se describe a continuación: la siguiente sección presenta la descripción de la metodología. La sección subsecuente presenta un ejemplo ilustrativo, y finalmente las conclusiones son presentadas en la última parte de este documento.

METODOLOGÍA

Inyección de plásticos es un proceso altamente no lineal en el cual un modelo matemático exacto no existe. Es un sistema complejo y dinámico donde la experiencia humana es parte esencial. Usualmente, esta experiencia es expresada a través de reglas lingüísticas Si-entonces que expresan una situación y una acción (Wang y Mendel, 1992). Típicamente, se puede encontrar información de cualquier proceso ya sea en forma lingüística o numérica. Tomando esto como referencia, este trabajo presenta un modelo neuro-difuso el cual combina la fortaleza de las redes neuronales artificiales (información numérica) y la lógica difusa (información lingüística). Lógica difusa es una metodología la cual a través de reglas Si-entonces, comúnmente generadas por el conocimiento de un experto(s) (información lingüística), describe la estrategia de respuesta. Las redes neuronales artificiales son modelos matemáticos en su forma más simple del cerebro humano, que pueden aceptar un gran número de entradas y aprender de un conjunto de muestras (información numérica). Así, el objetivo es combinar ambas metodologías para general el conjunto de reglas difusas (Si-entonces) mediante redes neuronales, y, lógica difusa para obtener el grado de corrección, por medio de un proceso de inferencia, de cada parámetro con la finalidad de mantener el proceso bajo control.

El sistema neuro-difuso, Fig. 1, es desarrollado para mantener bajo control los atributos de calidad de piezas moldeadas mediante el control de los parámetros del proceso de inyección de plásticos. Dicho control se lleva a cabo mediante un sistema de lazo cerrado el cual hace los ajustes correspondientes empleando el concepto lógica difusa. El proceso de inferencia (mapear un espacio de entrada en uno de salida) en lógica difusa se lleva a cabo mediante la evaluación de un conjunto de reglas difusas, las cuales son generadas comúnmente por un experto o conjunto de expertos sobre algún tema en específico. En el presente trabajo, el conjunto de reglas es generado de un conjunto de datos históricos del proceso. Los atributos de calidad considerados son: la deformación, encogimiento, y peso del componente plástico. Los parámetros del proceso

utilizados son la temperatura del plástico, temperatura del molde, presión de empaque, tiempo de empaque, y tiempo de enfriamiento. Los pasos a seguir para la obtención del sistema son explicados en las siguientes subsecciones.

Entrenamiento de la red neuronal artificial

El objetivo de utilizar redes neuronales es que aprendan la relación entre un conjunto de datos de entrada y de salida para la generación de reglas difusas. Para esto, se aplica una red neuronal inversa, donde las entradas son los atributos de calidad, y la salida son los parámetros del proceso. La Fig. 2 muestra una representación del diseño de la red. El algoritmo de aprendizaje empleado es el de propagación hacia atrás.

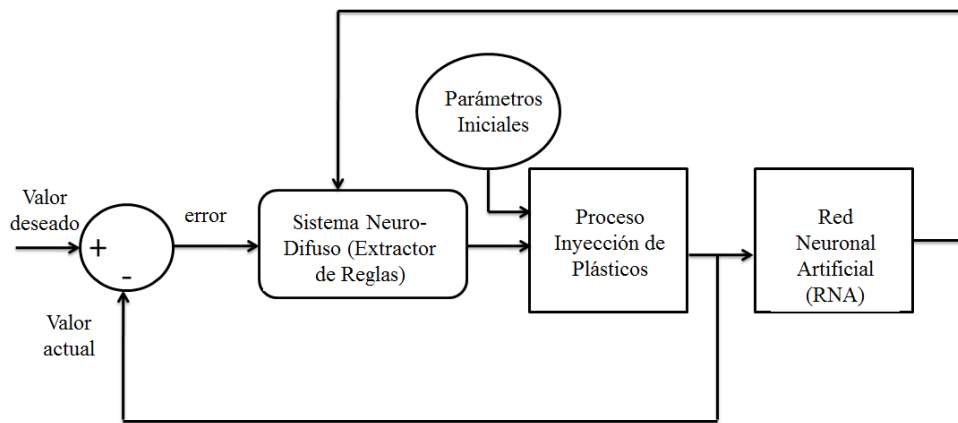


Fig. 1. Sistema Neuro-Difuso

Generación de reglas de la salida de la red neuronal

La red neuronal muestra la relación que existe entre los atributos de calidad y los parámetros involucrados. De este modo, si

existe alguna variación en alguno de los atributos, la respuesta de la red provee un cambio en los parámetros como posible causa de variación. Durante el proceso de generación de las reglas, las entradas y salidas de la red neuronal son fusificadas en

términos lingüísticos. De este modo, las reglas difusas son generadas de datos

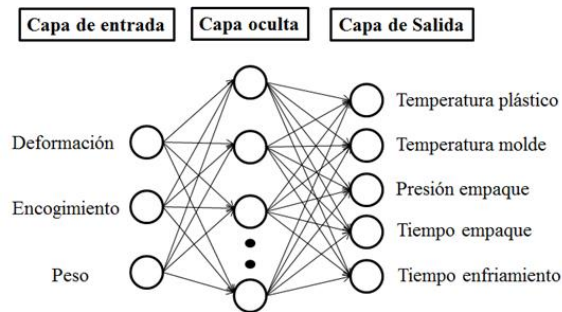


Fig. 2. Diseño de red neuronal artificial

Asumiendo un conjunto de datos entrada-salida, $(x_1^1, x_2^1; y_1^1), (x_1^2, x_2^2; y_1^2)$, donde x_1 y x_2 son entradas, y y_1 es la salida. El objetivo aquí es obtener las reglas de estos datos, para lo cual la metodología es dividida en cuatro pasos.

Dividir los espacios de entrada y salida en regiones difusas

Suponiendo que los intervalos de dominio de x_1 , x_2 y y_1 son $[x_1^-, x_1^+]$, $[x_2^-, x_2^+]$ y $[y_1^-, y_1^+]$ respectivamente, cada intervalo es dividido en regiones (conjuntos difusos), y pueden ser denotados por ejemplo como, pequeño, mediano, grande; donde una función de pertenencia es asignada a cada región. La Figura 3 muestra un ejemplo donde el intervalo de dominio de x_1 , x_2 y y_1 es dividido en tres regiones respectivamente. Para este caso en particular, se eligen funciones de pertenencia triangulares por simplicidad; sin embargo, diferentes funciones pueden ser consideradas, así como el número para cada variable.

Generar reglas difusas de datos numéricos

numéricos como se muestra a continuación.

Como primer paso, se establece el grado de significancia para cada variable. Por ejemplo, la Fig. 3 muestra que la variable x_1 tiene un grado de 0.1666 en *Mediano* y 0.5 en *Grande* para $x_1 = 9.5$; de igual manera, x_2 tiene un grado de 0.8333 en *Mediano* para $x_2 = 6.5$. Asimismo, y_1 tiene un grado de 1 en *Alto* cuando $y_1 = 11$. Segundo, se asigna una región para x_1, x_2, y_1 de acuerdo al máximo valor de grado. Es decir, x_1 es considerado *Grande*, x_2 es *Mediano* y y_1 es *Alto*. Finalmente, se obtiene la regla de la forma:

$$(x_1^1(9.5), x_2^1(6.5); y_1^1(11)) = \text{SI } x_1 \text{ es Grande y } x_2 \text{ es Mediano, ENTONCES } y_1 \text{ es Alto} \leftarrow \text{Regla 1}$$

Asignar grado a cada regla

Dado que es conveniente tener un gran conjunto de datos para entrenar a la red neuronal, cada muestra genera una regla como se muestra en el punto anterior. Por lo tanto, es bastante probable tener reglas en conflicto, es decir reglas con el mismo antecedente, pero diferente consecuente (Mismo SI, diferente ENTONCES). Una manera de lidiar con esta problemática es asignar un grado a cada regla, y tomar la regla con máximo grado. Para ilustrar, se considera la regla SI x_1 es *A* y x_2 es *B*, ENTONCES y_1 es *C*; el grado de la regla, denotado por D (Regla), está dado por:

$$D(\text{Regla}) = \mu_A(x_1)\mu_B(x_2)\mu_C(y_1)$$

Para demostrar, considerando el mismo ejemplo, donde la Regla 1 es: SI x_1 es *Grande* y x_2 es *Mediano*, ENTONCES y_1 es *Alto*, el grado de la regla es $D(\text{Regla1}) =$

$$\mu_{GRANDE}(x_1)\mu_{MEDIANO}(x_2)\mu_{ALTO}(y_1) = (0.5)(0.8333)(1) = 0.4167$$

Crear una base de reglas difusas

La Fig. 4 muestra una base de reglas difusas en base al ejemplo presentado. Los espacios vacíos son llenados con reglas generadas ya sea con información numérica o lingüística. Si más de una regla aplica para el mismo espacio, se elige la regla con máximo grado (en caso de que una sea asignada por un experto, este mismo puede asignar un grado para dicha regla). De este modo, información lingüística y numérica pueden ser codificadas dentro de un mismo marco.

Proceso de Inferencia Difusa

El proceso de obtener la salida de una regla difusa es conocido como inferencia o razonamiento difuso. Para este estudio, el modelo de Mamdani es adoptado como proceso de inferencia. Dicho modelo obtiene la salida de la forma,

$$R_x(y) = \bigvee_{i=1}^n A_i(x) \wedge B_i(y)$$

Para un conjunto extendido de reglas,

$$R_x(y) = R(x_1, x_2, \dots, x_k, y) =$$

$$\bigvee_{i=1}^n (A_{i1}(x_1) \wedge A_{i2}(x_2) \wedge \dots \wedge A_{ik}(x_k) \wedge B_i(y))$$

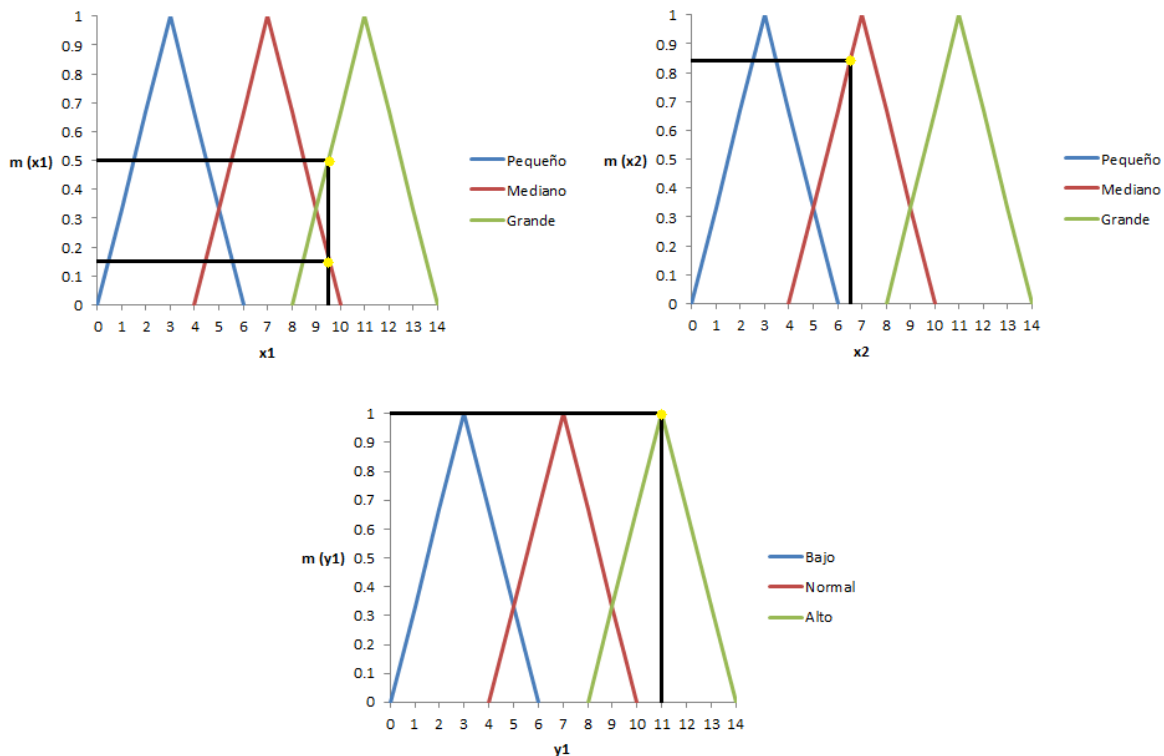


Fig. 3. Regiones Difusas y su función de pertenencia

Big			
x2 Medium			
Small			
	Small	Medium	Big
	x1		

Fig. 4. Base de reglas difusas

Corrección de los parámetros

La mayoría de los procedimientos de inferencia combinan las reglas difusas para producir un conjunto difuso (región difusa). En un sistema de control, un valor numérico exacto es usualmente necesitado. Esto requiere un proceso de defusificación, es decir obtener del conjunto difuso un valor exacto. Existen diversas técnicas para hacer esto donde el método del centroide es el más común por su simplicidad y eficiencia (Prasad et al., 2003). En este estudio se aplica dicho método para obtener un valor numérico exacto el cual representa el grado de corrección para cada parámetro respectivamente.

$$y_0 = \frac{\sum_{j=1}^n y_j R_x(y_j)}{\sum_{j=1}^n R_x(y_j)}$$

RESULTADOS

Ejemplo ilustrativo

En esta sección se presenta un caso de la metodología descrita anteriormente. Por lo tanto, se utiliza la misma estructura para su fácil comprensión.

Entrenamiento de la red neuronal artificial

Dado que los avances computacionales han sido enormes en los últimos años, se han desarrollado múltiples programas para la simulación de procesos y caracterización de materiales a un precio y tiempo razonables. Para este caso en particular, se utilizó el software de simulación del proceso de inyección “Moldflow” para la obtención de datos que se utilizaron para el entrenamiento de la red neuronal. Este software de análisis de elemento finito requiere de ciertas condiciones que deben ser establecidas antes de la simulación. Primero, un espécimen a ser moldeado; la Figura 5 muestra el componente a simular. Segundo, el tipo de material, para nuestro caso se elige uno de la librería del software cuyo nombre es Zytel 70G35HSLRA4BK267. Tercero, se especifica el modelo de máquina a emplear; la selección fue una máquina de 17 toneladas Arburg Allrounder 220 S 17 tons 1.3oz. (18mm). Se consideró una simple cavidad y Acero P-20 como material del molde. Se realizó una corrida con los siguientes valores de los parámetros a modificar.

Temperatura del plástico (°C) = 295

Temperatura del molde (°C) = 95

Presión de empaque (MPa) = 20

Tiempo de empaque (sec) = 6.3

Tiempo de enfriamiento (sec) = 3.5

La Tabla 1 muestra los valores máximos aceptables para la deformación y encogimiento de la pieza, así como el valor nominal para el peso del componente. La ecuación siguiente se utiliza para obtener el porcentaje de desviación del valor actual del valor nominal.

Tabla 1. Valores nominales para los atributos de calidad

	Deformación (mm)	Encogimiento (%)	Peso (gr)
Nominal	0.239177	15.81801	5.4067

$$\text{desviación \%} = \frac{(\text{actual} - \text{nominal}) * 100}{\text{nominal}}$$

La idea es mantener los valores de la deformación y encogimiento por debajo de estos niveles. En el caso del peso, cualquier desviación mayor o menor a cero se considero como una discrepancia. Por lo tanto, el objetivo es mantener el porcentaje de desviación igual o menor a cero para cada atributo.

Se realizaron 52 corridas en el software las cuales fueron utilizadas para llevar a cabo el entrenamiento de la red neuronal, es decir que aprendiera la relación entre los valores de entrada y salida. Se empleó una red con una capa oculta y 20 neuronas en ella. Se entrenó por 100,000 iteraciones y se obtuvo un error cuadrático medio (MSE) de 5.23e-6.




Fig. 5. Componente plástico

Generación de reglas de la salida de la red neuronal

Una vez que la red neuronal se ha entrenado, el siguiente paso fue probarla. Para esto, se introduce ciertos valores de entrada para ver la respuesta. Por ejemplo,

Desviación en la deformación = 3.6051%
 Desviación en el encogimiento = 6.2282 %
 Desviación en el peso = -0.5271 %

Los valores positivos muestran que la parte excedió los valores permitidos para deformación y encogimiento, y el peso esta por debajo del valor nominal. Estos valores fueron introducidos a la red neuronal para obtener el grado de desviación de los parámetros que están ocasionando las discrepancias. Los valores dados por la red fueron:

Temperatura del plástico (%) = 8.2
 Temperatura del molde (%) = -18.84
 Presión de empaque (%) = -15.6
 Tiempo de empaque (%) = -22.65
 Tiempo de enfriamiento (%) = 26.3

Donde el 8.2% muestra la desviación de la temperatura del plástico de su valor nominal. Esto es, si 295°C fuera el valor nominal, el 8.2% (24°C) expresa que la temperatura esta por encima del valor requerido; por lo tanto, ciertas discrepancias podrían presentarse. La misma analogía se emplea en los demás parámetros. Utilizando estos valores obtenidos de la red neuronal, se procedió a la generación de las reglas difusas.

Dividir los espacios de entrada y salida en regiones difusas

La Fig. 6 muestra las regiones difusas (conjuntos) que se emplearon para describir la desviación de los atributos de calidad. Así mismo, la Fig. 7 hace lo mismo para los parámetros del proceso. En la Fig. 6, los conjuntos difusos para deformación y encogimiento son representados por Normal, Relativamente Grande, y Grande, ya que es deseado mantener los valores por debajo del máximo aceptable. Para el caso del peso, este es descrito por Bajo, Relativamente Bajo, Normal, Relativamente Alto, y Alto. Esta misma descripción se usó para los parámetros en la Fig. 7.

Generar reglas difusas de datos numéricos

La regla difusa es generada tal y como se explicó en la sección anterior. Como resultado se obtuvo la primera regla de la forma:

SI

Deformación es *Grande* y
Encogimiento es *Grande* y
Peso es *Relativamente Bajo*

ENTONCES

Temperatura del plástico es
Relativamente Alta

Temperatura del molde es *Baja*
Presión de empaque es *Baja*
Tiempo de Empaque es *Bajo*
Tiempo de enfriamiento es *Alto*

Asignar grado a cada regla

El grado de la regla está dado por:

$$D \quad (\text{Regla}) \quad = \\ (1) * (1) * (0.96) * (0.82) * (0.88) * (0.56) * (1) * (1) \\ = 0.388$$

Proceso de Inferencia Difusa y corrección de los parámetros

El siguiente paso es la evaluación de las reglas difusas para obtener el valor numérico exacto, es decir el grado de corrección en el parámetro para disminuir el nivel de discrepancia en los atributos de calidad. Como resultado se obtiene que la temperatura del plástico fue 10% más alta y debe ser ajustada al mismo valor de manera contraria. Para clarificar, la temperatura fue 29.5°C más alta y debe ser ajustada a 265.5 °C (295-29.5). De igual manera, se sigue el mismo criterio para el resto de los parámetros. Los resultados son presentados en la Tabla 2.

Tabla 2. Parámetros del proceso corregidos

Parámetro	(%)	Valor a corregir	Valor nominal	Valor corregido
Temperatura Plástico	10.0	29.5	295.0	265.5
Temperatura Molde	-16.8	-16.0	95.0	111.0
Presión Empaque	-16.8	-3.4	20.0	23.4
Tiempo Empaque	-16.8	-1.1	6.3	7.4
Tiempo Enfriamiento	16.8	0.6	3.5	2.9

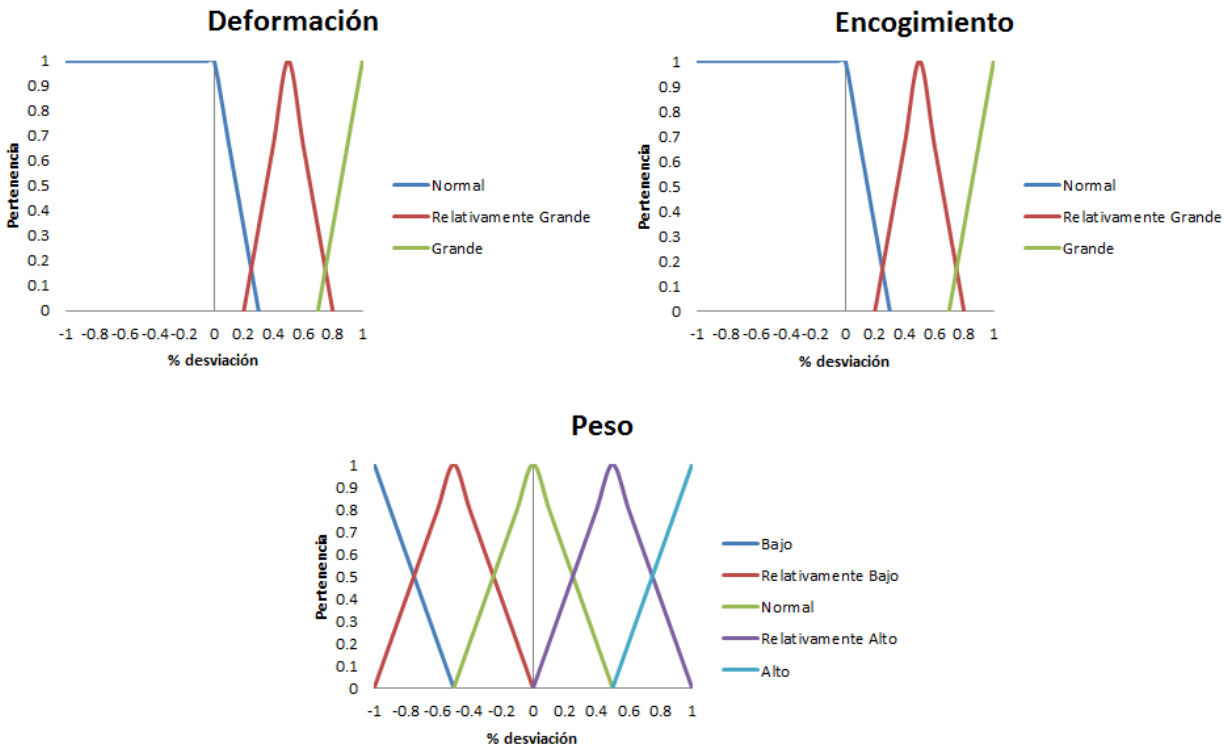


Figura 6. Conjuntos difusos para Atributos de Calidad




Figura 7. Conjuntos difusos para Parámetros del proceso

Los valores de los parámetros fueron corregidos de los valores iniciales. Así, estos valores fueron introducidos nuevamente en el proceso para obtener el grado de desviación actual de los atributos de calidad,

los cuales fueron introducidos en la red nuevamente para su evaluación y subsecuentemente para la generación de una nueva regla difusa. Por consiguiente, el sistema tiene la capacidad de ir disminuyendo la variación en las respuestas de interés hasta lograr un sistema bajo control en relación a los criterios de calidad establecidos. La Tabla 3 muestra cuatro iteraciones que realizó el sistema, y el porcentaje de desviación correspondiente.

Se puede observar que después de la primera iteración la deformación y encogimiento de la pieza se mantuvieron bajo control (por debajo del valor máximo aceptable); mientras que el peso fue mostrando una mejora significativa después

de cada iteración. El sistema neuro-difuso entonces mostró que fue capaz de reducir las discrepancias que se presentaron, ó que

podieran presentarse, para mantener el proceso bajo control en relación a los atributos de calidad considerados.

Tabla 3. Resultados Atributos de Calidad

	<i>Desviación Deformación %</i>	<i>Desviación Encogimiento %</i>	<i>Desviación Peso %</i>
Primera desviación	3.61	6.23	-0.53
Iteración 1	-6.64	-12.54	0.85
Iteración 2	-2.00	-0.63	0.28
Iteración 3	-3.75	-0.94	0.25
Iteración 4	-1.62	-1.50	0.21

CONCLUSIONES

El presente trabajo presentó un sistema neuro-difuso para controlar los atributos de calidad de interés en el proceso de inyección de plásticos mediante la manipulación de ciertos parámetros del proceso. La metodología implementada es mostrada paso a paso para demostrar la funcionalidad de la misma iteración tras iteración. El proceso de inyección es un sistema altamente difícil de controlar debido a la interacción de todas las variables involucradas. El tipo de análisis realizado resulta ser muy benéfico de implementar en procesos como el de plásticos donde una formulación matemática es muy difícil de obtener. Además, resulta muy conveniente ya que es capaz de lidiar con sistemas que contengan múltiples entradas y múltiples salidas como lo son la mayoría de los procesos industriales. Este trabajo pretende ejemplificar como el uso de estas tecnologías pueden ser combinadas fácilmente en la optimización de procesos, principalmente como una herramienta de apoyo en la difícil tarea de la toma de decisiones.

REFERENCIAS

- Altan, Mirigul (2010). Reducing shrinkage in injection moldings via the Taguchi, ANOVA and neural network methods. *Materials and Design*, 31, 599-604.
- Shen, Changyu; Wang, Lixia & Li, Qian (2007). Optimization of injection molding process parameters using combination of artificial neural network and genetic algorithm method. *Journal of Materials Processing Technology*, 183, 412-418.
- Chen, Wen-Chin; Fu, Gong-Loung; Tai, Pei-Hao & Deng, Wei-Jaw. (2009). Process parameter optimization for MIMO plastic injection molding via soft computing. *Expert Systems with Applications*, 36, 1114-1122.
- Deng, Yi-Min; Zhang, Yong & Lam, Yee Cheong (2010). A hybrid of mode-pursuing sampling method and genetic algorithm for minimization of injection molding warpage. *Materials and Design*, 31, 2118-2123.
- Erzurumlu, Tuncay & Ozelik, Babur (2006). Minimization of warpage and sink index in injection-molded thermoplastic parts using Taguchi optimization method. *Materials and Design*, 27, 853-861.
- Farshi, Behrooz; Gheshmi, Siavash & Miandoabchi, Elyar (2011). Optimization of injection molding process parameters using sequential simplex algorithm. *Materials and Design*, 32, 414-423.

Huang, Feng Li (2011). Optimization of Processing Parameters in Injection Molding based on Adaptive Ant Colony Algorithm. *Advanced Materials Research*, 179-180, 304-310.

Huang, Ming-Chih & Tai, Ching-Chih (2001). The effective factors in the warpage problem of an injection molded part with a thin shell feature. *Journal of Material Processing Technology*, 110, 1-9.

Kartalopoulos, Staaios (1996). *Understanding Neural Networks and Fuzzy Logic*. New York, NY: IEEE Press.

Lau, H.C.W.; Wong, T.T. & Pun, K.F. (1999). Neural-fuzzy modeling of plastic injection molding machine for intelligent control. *Expert Systems with Applications*, 17, 33-43.

Liao, X.P.; Xie, H.M.; Zhou, Y.J. & Xia, W. (2007). Adaptive adjustment of plastic injection processes based on neural network. *Journal of Materials Processing Technology*, 187-188, 676-679.

Lin, Jeen & Lian, Ruey-Jing. (2009). Hybrid fuzzy-logic and neural-network controller for MIMO systems. *Mechatronics*, 19, 972-986.

Lotti, C. & Bretas, R.E.S. (2006). Correlations between Injection Molding Parameters, Morphology and Mechanical Properties of PPS Using Artificial Neural Networks. *International Polymer Processing*, 21, 104-115.

Ozcelik, Babur & Sonta, Ibrahim (2009). Warpage and structural analysis of thin shell plastic in the plastic injection molding. *Materials and Design*, 30, 367-375.

Prasad, Ram; Nguyen, Hung; Walker, Elbert & Walker, Carol (2003). *A first course in Fuzzy and*

Neural Control. Boca Raton, Florida: Chapman & Hall.

Rogers, J.K. (1991). *Intelligent Molding: Expert Systems are Coming on Line Now*. *Modern Plastics Magazine*, 68, 56-60.

Rosato, D.V. & Rosato, D.V. (1995). *Injection Molding Handbook (2nd Ed.)*. New York, NY: Chapman & Hall.

Shie, Jie-Ren (2008). Optimization of injection molding process for contour distortions of polypropylene composite components by a radial basis neural network. *International Journal of Advanced Manufacturing Technology*, 36, 1091-1103.

Shie, Jie-Ren (2008). Optimization of injection-molding process for mechanical properties of polypropylene components via a generalized regression neural network. *Polymers for Advanced Technologies*, 19, 73-83.

Spina, R. (2006). Optimization of injection moulded parts by using ANN-PSO approach. *Journal of Achievements in Materials and Manufacturing Engineering*, 15, 146-152.

Wang, Li-Xin & Mendel, Jerry (1992). Generating Fuzzy Rules by Learning from Examples. *IEEE Transactions on Systems, Man, and Cybernetics*, 22, 1414-1427.

Yin Fei; Mao, Huajie & Hua, Lin (2011). A hybrid of back propagation neural network and genetic algorithm for optimization of injection molding process parameters. *Materials and Design*, 32, 3457-3464.