

# Modelado Difuso para Tratamientos térmicos en Materiales

**Dai Pra, Ana Lucía**

Grupo Inteligencia Artificial Aplicada a Ingeniería  
Facultad de Ingeniería – Universidad Nacional de Mar del Plata (UNMDP)  
Juan B. Justo 4302 – 7600 Mar del Plata  
Te: 0223-4816600  
e-mail: daipra@fi.mdp.edu.ar

**Acosta, Gerardo Gabriel**

Grupo ADQDAT- Dto. de Electromecánica  
Facultad de Ingeniería-Universidad Nacional del Centro de la Pcia. de Bs. As. (UNCPBA)  
Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

*Palabras clave:* Razonamiento Aproximado, Sistemas Basados en Reglas, Modelos Basados en lógica difusa, Tratamientos térmicos, Propiedades de materiales.

## Resumen

Los modelos basados en lógica difusa, o modelos difusos, se construyen a partir de reglas que vinculan las entradas y las salidas de una caja negra, que describen el comportamiento del sistema a modelar. La lógica difusa permite definir reglas en términos lingüísticos, a partir del conocimiento que *a priori* se tiene del sistema. Existen casos en los que este conocimiento (estructural) no es bien conocido y a cambio se dispone de datos provenientes de la observación de variables de entrada y salida. Es posible encontrar un conjunto de reglas que vinculen estos datos y así determinar un modelo estructural para los mismos. En este trabajo se presenta la aplicación de esta técnica a un proceso de tratamientos térmicos, que otorga a piezas de fundición, propiedades específicas, pero con variaciones dimensionales impredecibles. La finalidad es predecir esa variación dimensional, de gran importancia a los fines del diseño de las piezas, considerando inconsistencia en las observaciones, patrones de medición inexactos e incompletitud de los casos posibles. Este modelo estructural basado en reglas permite que el conocimiento obtenido sea comprensible para los expertos humanos o bien pueda incorporarse a un sistema experto dedicado a la asistencia en la fabricación de estas piezas.

## 1. Introducción

La división Metalurgia del INTEMA (Instituto de Tecnología de Materiales), investiga y produce piezas en materiales de fundición altamente competitivos, conocidos como fundiciones esferoidales austemperizadas (ADI) [Keough, 1991]. Este material es empleado en la fabricación de gran variedad de piezas, tradicionalmente realizadas en aceros aleados fundidos y forjados, con ventajas técnicas y económicas. El diseño de estas piezas se basa en la obtención de propiedades óptimas, de acuerdo a las exigencias a que serán expuestas en servicio. Para cumplir este objetivo, las piezas son sometidas a tratamientos térmicos que producen un cambio en la microestructura de las piezas. Este proceso es lo suficientemente conocido por expertos, permitiendo el desarrollo de un sistema basado en reglas para asistir la fabricación en forma industrial de las piezas (CAM), el cual sugiere el tratamiento adecuado [Dai Pra, 1996]. Sin embargo, aun no son específicamente conocidas las variaciones dimensionales que puede sufrir cada pieza, en cada cota, a causa del tratamiento; si bien se sabe que son dependientes de la interacción de una cantidad de variables, algunas de las cuales evidentemente no pueden ser evaluadas, y otras, debido a las características del proceso industrial y razones operativas y ambientales, no son

consideradas con exactitud. Para poder predecir estas variaciones (salidas) es de especial interés práctico contar con un modelo del comportamiento de las piezas frente a determinadas características del tratamiento (entradas).

Las observaciones cubren sólo una fracción de los posibles casos, ya que se limitan a un número determinado de piezas, empleadas por distintas empresas, para ciertas operaciones específicas.

En este trabajo se presentan los resultados obtenidos de la aplicación de las técnicas de modelado con lógica difusa, permitiendo obtener un conjunto de reglas, y con ellas determinar aproximadamente la variación dimensional de las piezas a partir de su composición química y de los tratamientos efectuados, caracterizados por temperaturas y tiempos de proceso. La herramienta utilizada es el Fuzzy Logic Toolbox de MATLAB®, que brinda la posibilidad de un entorno gráfico, facilitando la definición del proceso y la visualización de los resultados, contando además con la función ANFIS, que permite la optimización del sistema por métodos adaptativos basados en redes neuronales.

La estructura del artículo se completa de la siguiente manera: en la sección siguientes se da una breve introducción al modelado de sistemas causales mediante reglas difusas para los datos que se tienen. En el apartado que sigue se presenta una idea de cómo se agrupan los datos que van a actuar como entradas al modelo y posteriormente las reglas que se obtienen, antes y después de una optimización con redes neuronales. Finalmente, se agregan los resultados y conclusiones.

## 2. Planteos básicos para la obtención del modelo

En esta sección se determinarán los elementos básicos con los que se pretende caracterizar a cada pieza, y que servirán de entradas al modelo que se obtenga.

Principalmente inciden en la variación dimensional las temperaturas y tiempos del tratamiento (de austenización  $T_\gamma$  y  $t_\gamma$ , y de austemperizado  $T_a$  y  $t_a$ ). La heterogeneidad de la microestructura hace que el mismo tratamiento en igual material produzca variaciones dimensionales levemente diferentes, además, la microestructura es difícil de cuantificar, ya que es determinada visualmente a partir de observaciones de muestras en microscopio, por lo que se adopta la composición química para caracterizar el material.

Otra variable de entrada que experimentalmente se observó como determinante es el tamaño de la pieza considerada. Aparentemente, la variación dimensional no tiene relación lineal con el tamaño, por lo tanto interviene en el modelo no lineal que se intenta establecer.

De este modo, el modelo difuso debe relacionar las variables que se ven en la figura 1.

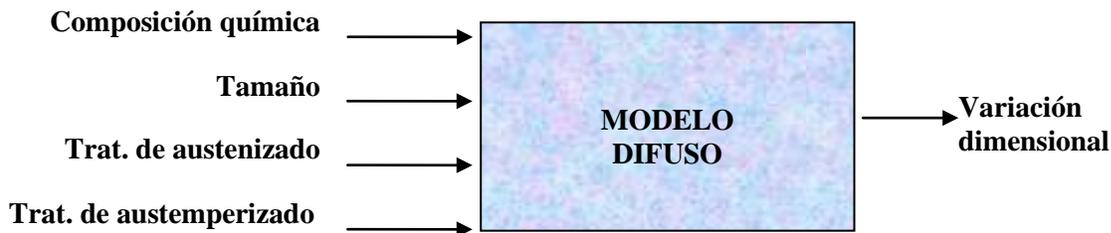


Figura 1: modelo buscado.

## 3. Metodología

### 3.1. Conjuntos difusos

Los conjuntos difusos (CD), propuestos por Zadeh [Zadeh, 1965], permiten expresar conocimientos imprecisos, que representan fácilmente el conocimiento humano que muchas veces es también impreciso debido a que se encuentra comúnmente asociado a términos lingüísticos, tales como

grande, bajo, etc. Cada uno de estos términos define un CD en sí mismo, que queda caracterizado mediante una función de pertenencia  $\mu$ . En este caso, los valores de las variables intervinientes se consideran información imperfecta, debido a la inexactitud en su medición, y cada variable es así susceptible de ser definida recurriendo al uso de CD. Las funciones de pertenencia, que tienen forma gaussiana en este caso, definen el rango de valores y la cercanía al valor que caracteriza el CD, para el cual la pertenencia es máxima ( $\mu=1$ ). Por ejemplo en el CD de temperatura de austenización, etiquetado con 910 pues  $\mu=1$  para esta temperatura, la función de pertenencia representará la cercanía a ese valor. Se eligieron entonces las observaciones más representativas del conjunto de observaciones a analizar, y los valores de las variables de estas observaciones (prototipos), se consideran como los términos que identifican los distintos CD. Luego, los CD representan números difusos. Esto puede apreciarse en la figura 2.

El resto de las observaciones, de acuerdo a las semejanzas con estos prototipos, se agrupará alrededor de ellos. Como se muestra en [Klawonn, 1997], este agrupamiento de los datos alrededor de prototipos, es lo que realizan los algoritmos de ‘clustering’ difuso.

### 3.2. Clustering difuso

La elección de los prototipos y el agrupamiento de datos alrededor de los prototipos, se realizó con técnicas de ‘clustering’ difuso. Estas técnicas se basan en la identificación de centros de clusters, basándose en la densidad de los puntos definidos, y agrupando el resto de los datos a estos centros de manera de minimizar las distancias. La ‘Fuzzy Logic Toolbox’, utiliza la técnica de ‘*subtractive clustering*’, desarrollado por S. Chiu, derivación del método ‘Mountain’ de Yager y Filev [Yager, 1994]. Asume que cada dato es un centro del cluster y calcula una medida de potencial para cada dato en función de la densidad de datos cercanos. El dato con mayor potencial es tomado como centro de cluster, disminuyendo los potenciales de los más cercanos, luego, con el mismo criterio, se van tomando nuevos centros de los datos restantes, hasta que tengan un potencial por debajo del umbral solicitado.

La elección del tamaño, forma y característica de los ‘clusters’, determina la cantidad de centros elegidos. Cada uno de estos centros corresponde a una observación, definida por un valor en cada una de sus variables. El conjunto de valores de una misma variable, para cada uno de los clusters, define los CD que la componen. Esta elección es de vital importancia para el resultado final de la identificación, requiriendo de un exhaustivo análisis y conocimiento previo de los datos. Se están estudiando formas de variar la actual selección, por otras técnicas, por ejemplo basadas en algoritmos genéticos.

En este trabajo se tomaron 181 observaciones, realizadas en distintas piezas, con diversidad de microestructuras, formas y tamaños, de las cuales 143 fueron utilizadas para generar el sistema y 38 para chequearlo.

Con las 143 observaciones se obtuvieron seis clusters que se muestran en el cuadro siguiente, el conjunto de los valores para cada variable, definen los centros de cada cluster.

| <b>T<sub>γ</sub></b><br>[°C] | <b>t<sub>γ</sub></b><br>[min] | <b>T<sub>a</sub></b><br>[°C] | <b>t<sub>a</sub></b><br>[min] | <b>dim</b><br>[mm] | <b>Mn</b><br>% | <b>Cu</b><br>% | <b>Ni</b><br>% | <b>Mo</b><br>% | <b>Si</b><br>% | <b>% VD</b><br><b>relativa</b> |
|------------------------------|-------------------------------|------------------------------|-------------------------------|--------------------|----------------|----------------|----------------|----------------|----------------|--------------------------------|
| 910                          | 120                           | 310                          | 120                           | 53                 | 0.3200         | 0.6200         | 0.6000         | 0.1200         | 2.8400         | 0.2450                         |
| 920                          | 90                            | 320                          | 120                           | 140                | 0.1900         | 1.1800         | 0.8700         | 0.2100         | 2.6200         | 0.1680                         |
| 920                          | 180                           | 280                          | 90                            | 62                 | 0.3600         | 0.8200         | 0.5000         | 0.1400         | 3.0600         | 0.4200                         |
| 910                          | 90                            | 360                          | 120                           | 19                 | 0.1100         | 0.0400         | 0.0000         | 0.0000         | 2.5000         | 0.0680                         |
| 910                          | 90                            | 320                          | 120                           | 215                | 0.4500         | 1.1700         | 1.4300         | 0.1800         | 2.7700         | 0.4300                         |
| 910                          | 120                           | 330                          | 90                            | 45                 | 0.3600         | 0.8200         | 0.5000         | 0.1400         | 3.0600         | 0.3880                         |

Cada cluster define un CD para cada variable, pudiendo repetirse la definición del conjunto para distintos clusters. La figura 2 muestra los CD obtenidos. En el caso de T<sub>γ</sub> quedan definidos solo dos conjuntos, el

de valores cercanos a 910 y el de valores cercanos a 920. El rango de influencia de cada variable fue elegido de manera de asegurar que todos los valores dentro del universo de discurso, pertenezcan a algún conjunto.



Figura 2: particionamiento inicial de las variables involucradas.

### 3.3 Reglas

Cada uno de estos prototipos, equivale a una regla. Por ejemplo, para el prototipo 1, corresponde la regla:

$R_1$ :

*If tempa is 910  
and tiempoa is 120  
and tempg is 310  
and tiempoq is 120  
and tamaño is 53  
and Mn is 0.32  
and Cu is 0.62  
and Ni is 0.60  
and Mo is 0.12  
and Si is 2.84*

*then  
VD is 0.245*

Una vez definidas las reglas, a partir de las  $n$  variables de entrada  $x_1, \dots, x_n$  es posible calcular el valor de su variable de salida  $y$ . Si cada entrada  $x_i$  está particionada en CD  $A_i^{(1)}, A_i^{(2)}, \dots$ , descriptos por las funciones de pertenencia  $\mu_i^{(1)}, \mu_i^{(2)}, \dots$ . La salida  $y$ , es determinada por el sistema de inferencia difuso (FIS) aplicado.

La herramienta permite definir el FIS en dos estilos diferentes:

-**Estilo Mamdani:** Los posibles valores de salida son particionados en CD  $B_i$ , de igual forma que los datos de entrada, cada valor de la variable de salida que define el centro de un cluster, define un CD de la variable de salida.

$$R_{i1...in} : \text{if } x_1 \text{ is } A_1^{(i1)} \text{ and } \dots \text{ and } x_n \text{ is } A_n^{(in)} \text{ then } y \text{ is } B^{(i)}$$

El resultado de la implicación en cada regla trunca el CD de salida. Todos los conjuntos resultantes de las salidas se unen en un solo conjunto, que debe ser defuzificado para obtener el valor de salida. Un desarrollo puede ser visto en [Kacprzyk,1995].

-**Estilo Sugeno:** Los valores de salida son interpretados como una función de los valores de entrada, se obtiene como salida un valor resultante de los pesos de los consecuentes obtenidos [4].

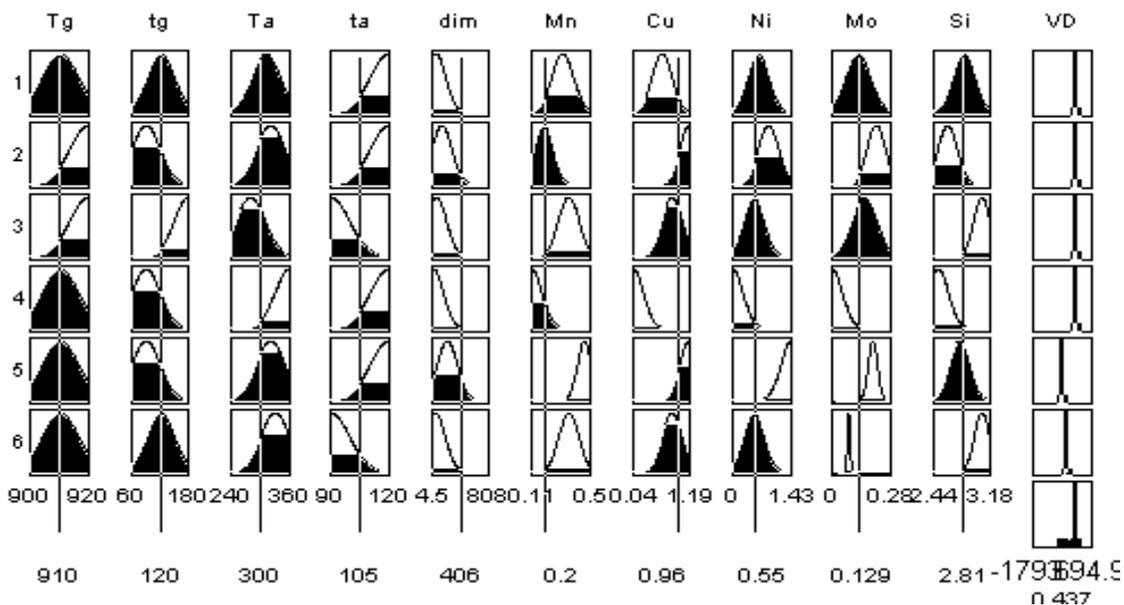
$$R_{i1...in} : \text{if } x_1 \text{ is } A_1^{(i1)} \text{ and } \dots \text{ and } x_n \text{ is } A_n^{(in)} \text{ then } y = f_{ij}(x_1, \dots, x_n)$$

De esta manera las conclusiones son muy simples, no es necesaria la defuzificación y la salida puede ser fácilmente calculada como una suma de pesos. Para ello, para cada regla se calcula un grado de validez  $\alpha_i$  desde los grados de pertenencia por medio de una norma triangular. Con estos grados de validez la salida del FIS, es determinada por

$$y = \frac{\sum_i \alpha_i f(x_1, \dots, x_n)}{\sum_i \alpha_i}$$

Un análisis del método está desarrollado en [Grauel, 1997].

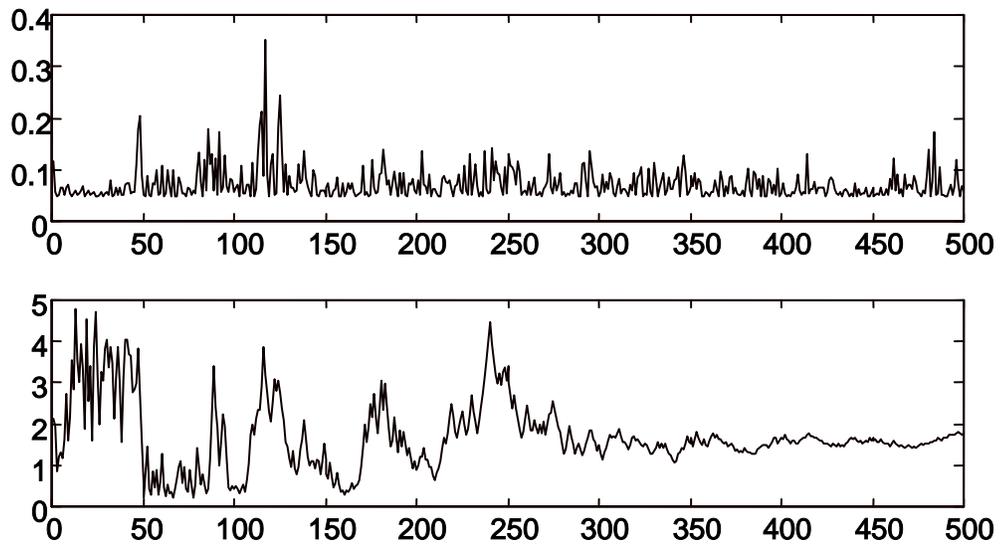
Se adopta el estilo Sugeno, ya que la herramienta utilizada, facilita la optimización del sistema mediante un algoritmo de backpropagation. Estas reglas y los CD están optimizados por la función ANFIS (Adaptive Neuro-Fuzzy Inference System). El ANFIS puede ser utilizado para optimizar un sistema de inferencia aplicando una ley de aprendizaje sobre una red neuronal. Dicha ley puede ser la regla delta generalizada o “backpropagation”, o bien combinada con una metodología del tipo de cuadrados mínimos [Mathwork, 1998]. Esta estructura de red calcula el vector gradiente para los parámetros del FIS proporcionado. En la figura 3 puede verse el comportamiento del FIS (Sugeno) ya optimizado obtenido para una entrada dada. Aquí se aprecian 6 reglas con 10 variables de entrada y la salida que representa la variación dimensional.



**Figura 3: Modelo difuso obtenido.**

En la figura 4 se muestra cómo se fueron modificando los errores (RMSE), tanto de entrenamiento como de chequeo, a través de las distintas etapas de optimización. El error de entrenamiento no puede ser mejorado, permaneciendo mas o menos estable, mientras que en el error de chequeo se producen grandes

cambios. Aunque la estabilización del error se comienza a producir después de la etapa 300, los mejores resultados fueron obtenidos en la etapa 49.



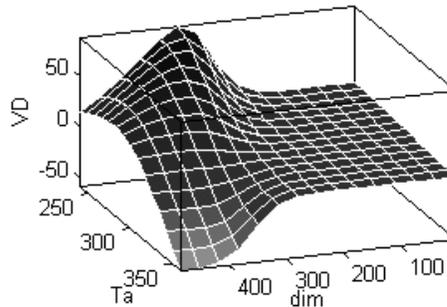
**Figura 4: evolución de los errores de entrenamiento y chequeo.**

Después de la optimización en la cual se va variando el particionamiento inicial del universo de discurso, las funciones de pertenencia adoptaron la forma que se ve en la figura 5.



**Figura 5: particionamiento final, luego de la optimización ANFIS.**

La posibilidad de graficar superficies que muestren el comportamiento de dos variables de entrada y la salida (mapeo), permite en forma clara mostrar el comportamiento del modelo a los expertos, los cuales pueden evaluar la coincidencia con el comportamiento real esperado, y obtener nuevas conclusiones. Esto se aprecia en la figura 6.



**Figura 6: relación obtenida entre la dimensión, la temperatura de austemperizado como entradas, y la variación dimensional como salida.**

#### **4. Resultados**

Para las simulaciones efectuadas con un FIS tipo Sugeno y en base a las observaciones experimentales obtenidas, se obtuvo un error de entrenamiento = 0.030, y un error altísimo de chequeo de  $3.075e5$ , ello es debido a que algunas observaciones del conjunto de chequeo difieren bastante de las de entrenamiento, y la interpolación no es adecuada. La optimización mediante el anfis permitió mejorar el modelo, ya que el error de chequeo final obtenido fue = 0.205, si bien el error de entrenamiento aumentó ligeramente a 0.050, manteniéndose igualmente en un número totalmente aceptable.

Aunque el error para nuevos valores de entrada es excesivo y da valores de salida impredecibles aun (es decir, no modelados), para el conjunto de datos analizados los resultados son aceptables como lo muestran los errores obtenidos. Para terminar de completar el modelo, se ha comenzado a trabajar sobre muestras de laboratorio, pero además se requiere del agregado de reglas, que surgen de analizar el sistema obtenido con los expertos, que seguramente tenderán a minimizar los errores.

#### **5. Conclusiones**

La aproximación se considera adecuada ya que permite dotar a los expertos de una importante herramienta para analizar el comportamiento de las variables bajo una nueva óptica, permitiendo visualizar el comportamiento de las observaciones experimentales.

También se verifica una vez más que es posible modelar el comportamiento de observaciones de un modo simple y natural para el ser humano, sin las restricciones y complejidad de los métodos matemáticos tradicionales. El resultado es un conjunto de reglas fácilmente trasladables a un Sistema Experto. En este problema particular, es de gran importancia incluir este conocimiento en el Sistema Experto ya desarrollado, ya que de ese modo, permite guiar al diseñador en la elección de un tratamiento que además de brindar a las piezas de propiedades específicas, anticipe las variaciones dimensionales y permita alterar el tratamiento en forma adecuada para lograr su objetivo.

## 6. Referencias

- Dai Pra A.L., Sikora J.A., Tejada M.M., Moncada O.J. “Avances en el desarrollo de un Sistema Experto para asistir la Fabricación de Piezas de ADI”. Anales de la Asociación Química Argentina. 84: 209-214. (1996).
- Grauel A., Mackemberg H. “Mathematical analysis of the Sugeno controller leading to general design rules”. Fuzzy Sets and Systems 85: 165-175. (1997).
- Kacprzyk J., Fedrizzi M. “Developing a Fuzzy Logic Controller in Case of Sparse Testimonies”. International Journal of Approximate Reasoning 12: 221-236. (1995).
- Keough, J.R.: “The Development, Processing and Application of Austempered Ductile Iron”, AFS. Proc. Vol II, 3<sup>rd</sup> World Conference on ADI, pág. 638, (1991).
- Klawonn F., Kruse R. “Constructing a fuzzy controller from data”. Fuzzy Sets and Systems 85: 177-193. (1997).
- Yager R., Filev D. “Generation of Fuzzy Rules by Mountain Clustering”. Journal of Intelligent & Fuzzy Systems. Vol2. No. 3. : 209-219. (1994).
- Zadeh L.A. “Fuzzy Sets”. Information and Control. 8. 338-353 (1965).
- The MathWorks Inc., “Fuzzy Logic Toolbox for Matlab – User’s Guide”, 1998.