

Aplicación de modelos de caja gris neuro-difusos con aprendizaje híbrido para predicción de temperatura en laminado en caliente

José Ángel Barrios-Gómez, Gerardo Maximiliano-Méndez, Alberto Cavazos-González
 Universidad Autónoma de Nuevo León (Méjico)

DOI: <http://dx.doi.org/10.6036/7859>

El proceso de laminado en caliente transforma planchones de acero, con dimensiones aproximadas de 10 m x 1 m x 0.2 m, en lámina enrollada de espesor entre 0.002 m y 0.0127 m y alrededor de 1m de ancho. Una línea de laminado en caliente consiste de: 1) Horno de Recalentamiento; 2) Molino Desbastador (MD); 3) Molino Acabador (MA), consistente de 6 ó 7 castillos; 4) Mesas de Enfriamiento y 5) Enrolladores. El planchón es recalentado hasta aproximadamente 1300 °C y transportado al MD donde se realiza la reducción inicial de espesor. El producto del MD es conocido como barra de transferencia (BT), típicamente de dimensiones de 90 m x 1 m x 0.0254 m. Al salir del MD la BT es transportada al MA.

Para laminar un producto en particular exitosamente, es necesario configurar el

MA de manera correcta. Para llevar a cabo esta tarea es crucial tener conocimiento preciso y de manera anticipada de la temperatura de la BT a la entrada del MA. Sin embargo, las mediciones a la entrada del MA no son confiables y tiene que estimarse a partir de las mediciones a la salida del MD, las cuales son más seguras.

Actualmente, en la mayoría de los molinos, la temperatura de la BT se estima mediante modelos físicos cuyas entradas son: 1) la temperatura a la salida del MD y 2) el tiempo de traslado de la salida del MD a la entrada del MA.

Barrios *et al.* (2015) [1] presentan, para la estimación de la temperatura de la BT, varios modelos de caja gris (MCG) basados en sistemas neurodifusos de aprendizaje híbrido (AH) dada la capacidad de adaptación de éstos [2-4]. Las entradas del MCG son las mismas que las del modelo físico. La línea de laminado involucrada cuenta con dos MDs reversibles y un MA de 6 castillos. Este reporte técnico resume y discute los resultados obtenidos en [1].

Se usaron MCGs en paralelo, en los cuales el modelo físico y el sistema de in-

ferencia difusa (SID) se interconectan tal que tienen entradas comunes y sus salida se suman. La salida del SID se interpretó como una compensación aditiva del error de estimación del modelo físico. Se desarrollaron cuatro MCGs cada uno basado en los siguientes SIDs: 1) Mamdani tipo-1 de AH de 9 reglas, 2) Mamdani tipo-1 de AH de 25 reglas, 3) Mamdani tipo-2 de AH de 9 reglas y 4) Mamdani tipo-2 de AH de 25 reglas. Se usaron funciones Gaussianas como funciones de pertenencia (FP). Los sistemas se evaluaron mediante 5 medidas de rendimiento (MR) aplicadas al error de estimación: 1) media del error (ME), 2) desviación estándar del error (DE), 3) error medio absoluto (MAE), 4) raíz cuadrada del error cuadrático medio (RMSE) y 5) porcentaje de barras con error de estimación entre $\pm 20^{\circ}\text{C}$, abreviado como '%Barras $\pm 20^{\circ}\text{C}$ '. El rendimiento se comparó con el de otros sistemas difusos de diferentes tipos presentados en trabajos anteriores [5-7].

La Tabla 1 muestra los resultados principales. Algunos hallazgos importantes son los siguientes:

1. El mejor sistema fue el MCG de AH Mamdani tipo-1 de 9 reglas con 100% de '% Barras $\pm 20^{\circ}\text{C}$ ', el cual superó al resto de los sistemas en las cinco MRs usadas.
2. 18 de los 24 sistemas difusos superaron al modelo físico.
3. Los 8 mejores sistemas fueron MCGs, los 6 mejores con AH.
4. Los MCGs de 9 reglas sin AH son in-

Posición	Sistema	No. de Reglas	DE	ME	MAE	RMSE	"% Barras $\pm 20^{\circ}\text{C}$ "
1	AH CG Tipo-1 Mamdani	9	5.25	-0.17	4.16	5.25	100.00
2	CG ANFIS	9	7.83	2.60	6.12	8.25	99.66
3	AH CG Tipo-2 Mamdani	9	5.45	2.98	4.67	6.21	99.51
4	AH CG Tipo-2 Mamdani	25	5.50	3.62	4.96	6.59	99.35
5	AH CG Tipo-1 Mamdani	25	5.52	1.90	4.37	5.83	99.33
6	CG ANFIS	25	8.84	4.69	7.32	10.00	95.62
...
9	SID ANFIS	25	15.54	-2.93	12.70	15.81	79.97
10	SID AH Tipo-2 Mamdani	25	15.64	-1.81	12.72	15.74	79.27
11	SID AH Tipo-1 Mamdani	25	15.69	-3.61	12.87	16.10	78.78
12	SID ANFIS	9	15.50	2.09	12.93	15.64	78.51
13	SID AH Tipo -2 Mamdani	9	15.66	-3.63	12.85	16.08	78.43
...
19	Modelo Físico	N/A	17.35	-6.14	14.44	18.40	73.97

Tabla 1: Desempeño de algunos de los sistemas desarrollados en [1, 5-7] clasificados por "% Barras $\pm 20^{\circ}\text{C}$ ".

suficientes para modelar la temperatura de la BT, los cuales mostraron sobrepredicción y dispersión altas.

5. El desempeño de los MCGs con AH es superior que el de los sistemas puramente difusos con AH.
6. El rendimiento de MCG de 9 reglas tipo-1 mejoró sustancialmente con el AH, de 56.57% a 100%, reduciendo ambos ME y DE.
7. AH o MCG mejoran el desempeño considerablemente ya sea usados de manera combinada o separada.
8. El número de reglas tiene influencia en el comportamiento de los sistemas dependiendo de si son MCGs o puramente difusos. Los MCGs de 9 reglas pasan de ocupar los últimos tres lugares a los tres primeros cuando se aplica AH, mientras que los puramente difusos de 25 reglas pasan de ser los últimos de su tipo a los tres primeros de su tipo al aplicar AH.

Algunas actividades futuras son: encontrar la operación de inferencia difusa más adecuada para la estimación de temperatura, comparación del desempeño utilizando diferentes FPs y probar sistemas Sugeno de más alto orden.

En algunos casos el modelo físico no está disponible o simplemente no es deseable, dado el consumo de recursos computacionales, ya que está implementado mediante diferencias finitas [8]. Por lo tanto es importante mejorar el rendimiento de los sistemas puramente difusos. Una oportunidad de mejora es como sigue: el algoritmo de AH adaptó los parámetros de algunos conjuntos difusos tal que sus efectos en la regla correspondiente son casi nulos (no mostrados). Esto sugiere que el uso de alguna función de extracción de reglas puede traer algunos beneficios para optimizar la base de reglas antes de la aplicación del AH. Otro beneficio de estos algoritmos es que permiten la incorporación de otras entradas que tengan influencia en la predicción sin incrementar el número de reglas.

Este trabajo fue parcialmente financiado por PROMEP y CONACYT. Agradecemos a los Drs. Luis Leduc y Jorge Ramírez y al Sr. César Villanueva de TERNIUM-Hylsa por la ayuda prestada y al Dr. Oscar Castillo por facilitar el software para desarrollar algunos de los sistemas difusos tipo-2.

REFERENCIAS

- [1] Cavazos-Gonzalez A, Barrios-Gómez JA, Maximiliano-Méndez G. "Entry temperature estimation in a hot strip mill by hybrid-learning type-1 and type-2 fuzzy grey-box models". *DYNA New Technologies*, Enero 2016, vol. 2, no. 1, p.1-12. DOI: <http://dx.doi.org/10.6036/NT7760>
- [2] Paliwal M, Kumar UA. "Neural networks and statistical techniques: A review of applications". *Expert Systems with Applications*. 2009. Vol.36-1 p. 2-17. (DOI: <http://dx.doi.org/10.1016/j.eswa.2007.10.005>)
- [3] Kar S, Das S, Ghosh PK. "Applications of neuro fuzzy systems: A brief review and future outline". *Applied Soft Computing*. 2014. Vol.15-2 p. 243-259. (DOI: <http://dx.doi.org/10.1016/j.asoc.2013.10.014>)
- [4] Dareli T, Baycasoglu A, Altun K, et al. "Industrial applications of type-2 fuzzy sets and systems: A concise review". *Computers in Industry*. 2011. Vol.62-1 p.125-137. (DOI: <http://dx.doi.org/10.1016/j.compind.2010.10.006>)
- [5] Mendez GM, Cavazos A, Soto R, et al. "Entry temperature prediction of a hot strip mill by a hybrid learning type-2 FIS". *Journal of Intelligent and Fuzzy Systems*. 2006, Vol.17-6 p.583-596.
- [6] Barrios JA, Cavazos A, Leduc L, et al. "Fuzzy and Fuzzy Grey-Box Modelling for Entry Temperature Prediction in a Hot Strip Mill" *Materials and Manufacturing Processes*. 2011. Vol.26-1 p.66-77. (DOI: <http://dx.doi.org/10.1080/10426910903124803>)
- [7] Barrios JA, Torres-Alvarado M, Cavazos A. "Neural and Fuzzy Grey-Box Modelling for Entry Temperature Prediction in a Hot Strip Mill". *Expert Systems with Applications*. 2012, Vol.39-1, p. 3374-3384. (DOI: <http://dx.doi.org/10.1016/j.eswa.2011.09.025>)
- [8] Barrios JA, Torres-Alvarado M, Cavazos A, et al. "Neural and Neural Grey-Box Modelling for Entry Temperature Prediction in a Hot Strip Mill". *Journal of Materials Engineering and Performance*. 2011. Vol.20-7 p. 1128-1139. (DOI: <http://dx.doi.org/10.1007/s11665-010-9759-1>).

29 BIEMH

YOU MAKE IT BIG

SMART SOLUTIONS

BILBAO
30 MAYO
4 JUNIO
2016

Soluciones avanzadas y negocios inteligentes en una feria donde los expositores son los verdaderos protagonistas.

Colaboran



EUSKO JAURLARITZA
GOBIERNO VASCO

EKONOMIAREN GARAPEN
ETA LEHAKORTASUN SAILA
DEPARTAMENTO DE DESARROLLO
ECONÓMICO Y COMPETITIVIDAD

AiMHE
ASOCIACIÓN DE INGENIEROS
DE MÁQUINA - HERRAMIENTA

Organizan

AFM
Advanced
Manufacturing
Technologies

www.afm.es

B!
I!
E!
C!
BILBAO
EXHIBITION
CENTRE

EXPOSSIBLE!

www.biemh.com