

OPTIMIZACIÓN DE LOS PARÁMETROS GEOMÉTRICOS DE UN DISIPADOR DE CALOR DE ENFRIAMIENTO POR LÍQUIDO USANDO REDES NEURONALES ARTIFICIALES

Gustavo Guerrero Arellano¹ y Abel Hernández Guerrero²

RESUMEN

En este trabajo se realiza la optimización de los parámetros geométricos por medio de redes neuronales artificiales (RNA) de un disipador de calor de enfriamiento líquido en concreto se estudian los efectos de la variación de la distancia entre las paredes de los canales y el impacto que tienen en la caída de presión del sistema. También se estudia el análisis numérico del conjunto de parámetros. La configuración del disipador de calor con los parámetros optimizados genera una caída de presión menor que 9 kPa.

PALABRAS CLAVE Optimización, Transferencia de calor, Disipador de calor, Redes neuronales artificiales.

INTRODUCCIÓN

Hoy en día la industria electrónica gasta a gran cantidad de capital en el desarrollo de dispositivos electrónicos más rápidos, pequeños y eficientes. Los dispositivos electrónicos son la piedra angular en gran parte de los procesos industriales y el entretenimiento. La nueva generación de dispositivos electrónicos tiene mayor capacidad para procesar información y un tamaño mucho más pequeño comparado con sus predecesores. El incremento en la capacidad de memoria, en la capacidad gráfica, capacidad de los discos duros y mayor rendimiento de los procesadores han contribuido a la creación de equipos de cómputo mucho más poderosos y a medida que se incrementan las capacidades de los dispositivos también aumenta la potencia que consumen y en consecuencia se necesita mayor disipación de calor. Como la disipación de potencia aumenta y el tamaño de los dispositivos disminuye los ingenieros térmicos han tenido que innovar para evitar que los dispositivos no se sobrecalienten. Los dispositivos que cuentan con una buena disipación de calor tienen una mayor vida útil.

¹ Estudiante de la División de Ingeniería Campus Irapuato-Salamanca, Ingeniería Mecatrónica, Universidad de Guanajuato. Carretera Salamanca-Valle de Santiago km 3.5+1.8 km Comunidad de Palo Blanco C.P:36885, Salamanca, Guanajuato. Teléfono (464) 647 9940.

² Profesor, Universidad de Guanajuato, División de Ingeniería Campus Irapuato-Salamanca, Departamento de Ingeniería Mecánica, Carretera Salamanca-Valle de Santiago km 3.5+1.8 km Comunidad de Palo Blanco C.P:36885, Salamanca, Guanajuato. Teléfono (464) 647 9940; abel@ugto.mx

Una buena alternativa para la disipación de calor, son los sistema de enfriamiento por liquido en este trabajo se realiza la optimización de los parámetros geométricos por medio de redes neuronales artificiales (RNA) de un disipador de calor de enfriamiento líquido propuesto. El sistema de refrigeración consta de una placa de cobre con la geometría de flujo, una bomba y un radiador. Se usa agua como refrigerante, en régimen laminar y una sola fase. El funcionamiento del sistema es el siguiente: el refrigerante entra a baja temperatura (temperatura ambiente) a través de un conducto de inyección y luego se le distribuye a través de los canales de flujo de la placa que está en contacto térmico con los componentes electrónicos a ser enfriados. La temperatura de los componentes disminuye por los fenómenos de transferencia de calor. El refrigerante a alta temperatura sale de la placa y se envía al radiador donde el calor es expulsado del sistema para bajar su temperatura a la temperatura ambiente; a la salida del radiador, el refrigerante pasa por una bomba para comenzar un nuevo ciclo a través del sistema. El modelo de la red neuronal artificial se ha desarrollado para mapear la relación no lineal entre los arreglos de la geometría y la caída de presión del líquido de refrigeración del disipador de calor.

MÉTODOS Y MATERIALES

El material utilizado para la fabricación del disipador de calor es cobre, que tiene una conductividad térmica de 385 W/(m K). La Figura 1 muestra un distribuidor de flujo realizado por Ramos (Ramos-Alvarado, 2005), diseñado para celdas de combustible tipo PEM, este modelo se modificó y se estudió para el intercambio de calor.




Figura 1. Distribuidor de flujo base.

La estructura del distribuidor de flujo está conformada por cuatro niveles de bifurcación en la entrada, con el objetivo de tener un perfil de flujo uniforme en los veinticuatro canales paralelos resultantes. De manera idéntica para la salida de los canales, las bifurcaciones de la salida se retiró del modelo original debido a las caídas de presión que genera y fue reemplazado por un canal único para recolectar el fluido de los canales y expulsarlo por un punto de salida Figura 2.




Figura 2. Distribuidor de flujo propuesto.

Este trabajo investiga el impacto que tiene la modificación de los parámetros del distribuidor en la caída de presión. La Figura 3 muestra los principales parámetros del disipador de calor que necesitan ser optimizados: a es el ancho del canal en el primer nivel, b es la anchura de canal en el segundo nivel, c es la anchura de canal en el tercer nivel, d es la anchura de canal del cuarto nivel y e es la anchura de canal del quinto nivel.




Figura 3. Parámetros geométricos

Es necesario establecer un rango en los datos de entrada para realizar el análisis numérico y obtener una base de datos de salida y poder entrenar la red neuronal artificial. Los errores en la simulación podrían ser debidos al truncamiento o a la no convergencia. El rango para cada nivel de bifurcación se muestra en la Tabla 1.

Tabla 1. Resumen de los parámetros geométricos

| Parámetros | 1 ^{er} Nivel [mm] | 2 ^{do} Nivel [mm] | 3 ^{er} Nivel [mm] | 4 ^{to} Nivel [mm] | 5 ^{to} Nivel [mm] |
|------------|-------------------------------|-------------------------------|-------------------------------|-------------------------------|-------------------------------|
| Máximo | 4 | 2.5 | 2 | 1.5 | 1.2 |
| Media | 3 | 2.25 | 1.75 | 1.25 | 1 |
| Mínimo | 2 | 2 | 1.5 | 1 | 0.8 |

Las suposiciones para el análisis del modelo numérico son: (1) el sistema está en estado estable (2) agua en una sola fase y en flujo laminar que entra en el sistema a temperatura ambiente (25 °C) (3) propiedades termodinámicas del sólido y del fluido permanecen constantes, excepto la viscosidad del fluido. La justificación para esta suposición se puede encontrar en (Toh, 2005) y (Li, 2007). (4) flujo de calor es constante y uniforme (5) efectos por radiación son despreciados.

Las ecuaciones de gobierno del sistema son mostradas en la Tabla 2.

Tabla 2. Ecuaciones de gobierno del modelo

| Ecuaciones de gobierno | Expresión matemática |
|------------------------|--|
| Continuidad | $\nabla \vec{U} = 0$ |
| Momento | $\rho(\vec{U} \cdot \nabla \vec{U}) + P - \varphi = 0$ |
| Energía | $\nabla^2 T = 0$ para sólidos |
| | $\rho c_p(\vec{U} \cdot \nabla T) - k_f \nabla^2 T = 0$ para fluidos |

Las condiciones de frontera para el modelo se ajustan de acuerdo a la interacción del fluido con el entorno. Se considera flujo másico constante de refrigerante en la entrada del modelo. Se establece un flujo de calor constante en la pared inferior del dominio sólido. Se asume que la presión estática es cero en la salida. Condiciones de simetría para ambos dominios se consideran en las paredes. Las paredes entre los dominios se establecen como condiciones de interfaz. La pared superior del canal se establece como adiabática.

Un software comercial de CFD (Computational Fluid Dynamics) específicamente ANSYS Fluent fue usado para resolver las ecuaciones que rigen ambos dominios bajo las suposiciones y condiciones de frontera mencionadas anteriormente.

Usando combinaciones de los cinco parámetros geométricos del modelo, se crea una base de datos de entrada, dando un total de 243 combinaciones. Posteriormente, se realiza el análisis numérico para cada una de las combinaciones, con los resultados de presión en la entrada y salida y la calidad de la malla se crea la base de datos de salida.

Algunos investigadores encuentran que redes de múltiples capas pueden ser usadas para aproximar cualquier función, si se dispone de las suficientes neuronas en las capas ocultas. Así, en este trabajo, seleccionamos una red de dos capas.

La función activación de la capa oculta es la tangente hiperbólica, mostrada en la ecuación 1).

$$f(n) = \tanh(1.5 n) \quad (1)$$

Las bases de datos son divididas en dos partes para obtener la base de datos de entrenamiento y la base de datos para la validación. Los datos son repartidos en 80% para el entrenamiento y 20% para la validación.

Un estudio de rendimiento fue realizado para determinar el número mínimo de neuronas que debe tener cada capa oculta para ser entrenadas en la RNA, como se muestra en la Figura 4. El resultado del estudio indica que se necesitan 9 neuronas en la primera capa oculta y 4 en la segunda capa oculta.




Figura 4. Estudio de rendimiento para el entrenamiento de la RNA

Para el entrenamiento de la RNA, se utilizó un software libre de simulación de redes neuronales desarrollado en la Universidad de Guanajuato, llamado Neural Lab (Ledesma-Orozco, 2013). Una de las principales características de Neural Lab es que proporciona un entorno visual para diseñar y probar las redes neuronales artificiales.

RESULTADOS

Con el fin de determinar la solución del modelo numérico hace una comparación entre el análisis con viscosidad variable respecto al análisis con temperatura y viscosidad esto se lleva a cabo mediante la observación de la variación en la caída de presión del modelo, como se muestra en la Tabla 3, de modo que el flujo de calor deja de ser una variable del sistema, solo hay que tener en cuenta la caída de presión como dato de salida.

Tabla 3. Resumen del análisis de la viscosidad dinámica

| $\Delta P_{\mu=0}$ [kPa] | $\Delta P_{\mu=0}$ [kPa] | Diferencia [kPa] | % Error |
|-----------------------------|-----------------------------|---------------------|---------|
| 15.591 | 14.262 | 1.329 | 0.0852 |

La ecuación de la viscosidad dinámica calculada es mostrada en la ecuación 2).

$$\mu = (2.414 \times 10^{-5}) \frac{10.247.8}{T-140} \quad (2)$$

Teniendo en cuenta lo anterior, se realiza el análisis de las combinaciones geométricas para el desarrollo de los datos de salida.

Se utilizó el método de templado simulado para el pre entrenamiento de la RNA y el método de Levenberg-Marquardt para el entrenamiento, registrando un error cuadrático medio de 0.002784, como se muestra en la Figura 5.




Figura 5. Error cuadrático medio de la RNA entrenada

Una vez que se entrena la red, se realiza un barrido de datos de entrada, generando 103623 datos de entrada que se suministran a la red con el fin de obtener la relación de la caída de presión, consecuentemente un 1% de los datos con caída de presión baja son barridos de nuevo creando una nueva entrada, el proceso interactivo es realizado hasta que la variación de los datos de entrada es menor a $10 \mu\text{m}$. La Tabla 4 muestra el conjunto de parámetros que producen la menor caída de presión.

Tabla 4. Parámetros optimizados

| 1er Nivel | 2do Nivel | 3er Nivel | 4to Nivel | 5to Nivel |
|-----------|-----------|-----------|-----------|-----------|
| [mm] | [mm] | [mm] | [mm] | [mm] |
| 2.400 | 2.183 | 1.600 | 1.500 | 1.200 |

Posteriormente, se realiza el análisis numérico del modelo con los parámetros óptimos y se obtiene un error de 7,36%.

Tabla 5. Porcentaje de Error

| RNA | Análisis numérico | Diferencia | % Error |
|--------|-------------------|------------|---------|
| [kPa] | [kPa] | [kPa] | |
| 8.9925 | 9.7066 | 7.14177 | 0.0736 |

CONCLUSIONES

A medida que los sistemas de cómputo incrementan sus prestaciones, se tiene que disipar más calor y los sistemas de enfriamiento por líquido son una excelente opción que nos ofrece una alta disipación de calor y poco ruido. Pero para aprovechar al máximo el disipador de calor es necesario tener un diseño óptimo para la distribución de flujo del refrigerante, en este trabajo se implementó una red neuronal artificial que nos permitió determinar cuáles son los mejores parámetros para un diseño propuesto. La ventaja de la red neuronal artificial es que permite

encontrar de manera rápida los mejores parámetros para nuestro distribuidor de flujo propuesto. La desventaja de este método es que para cada diseño del distribuidor de flujo es necesario tener que crear una nueva red neuronal y entrenarla con nuevos conjuntos de datos, pero la rapidez para encontrar los mejores parámetros la convierten en una poderosa herramienta de optimización.

REFERENCIAS

HINES, M. L., CARNEVALE, N. T., "The NEURON simulation environment", *Neural Comp.*, vol. 9, no. 6, pp. 1179–1209, 1997.

LEDESMA-OROZCO, S.E., "Neural Lab", Wikipedia, (2013). Retrieved June 21, 2014, from http://en.wikipedia.org/wiki/Neural_Lab

LI, Z., HUAI, X., TAO, Y., and CHEN, H., "Effects of thermal property variations on the liquid flow and heat transfer in microchannel heat sinks", *Appl. Thermal Eng.*, vol. 27, nos. 17–18, pp. 2803–2814, Dec. 2007.

PETERSON, G.P., "An Introduction to Heat Pipes: Modeling, Testing and Applications", Fourth Ed., Wiley, New York, 1994.

RAMOS-ALVARADO, B., HERNANDEZ-GUERRERO, A., JUAREZ-ROBLES, D., LI, P., "Numerical investigation of the performance of symmetric flow distributors as flow channels for PEM fuel cells," *Int. J. Hydrogen Energy*, vol. 37, pp. 436 – 448, 2012

TOH, K. C., CHEN, X. Y., and CHAIN, J. C., "Numerical computation of fluid flow and heat transfer in microchannels," *Appl. Thermal Eng.*, vol. 25, pp. 1472–1487, Aug. 2005.

VAPNIK, V., "Statistical Learning Theory", New York: Wiley, 1998.