

Empleo de la inteligencia artificial en la determinación de propiedades de refrigerantes

Juan Carlos Armas Valdes, Yarelis Valdivia Nodal,
Julio Gómez Sarduy, Roy Reyes Calvo

Universidad de Cienfuegos “Carlos R. Rodríguez”. Cienfuegos. Cuba
jcarlos@ucf.edu.cu , yvaldivia@ucf.edu.cu ,
jgomez@ucf.edu.cu , royrc@ucf.edu.cu

RESUMEN

Este trabajo está enfocado al uso de redes neuronales artificiales y algoritmo genético para la determinación del estado termodinámico de los refrigerantes, R22 y R134a en el circuito primario de refrigeración para un sistema de climatización centralizado con agua helada. El modelo neuronal diseñado parte de una red multicapa que define como variables de entrada; las presiones de succión y descarga, y los grados de sobrecalentamiento y subenfriamiento a las salidas del evaporador y del condensador respectivamente. Se obtienen: la entalpía, entropía y el volumen específico de ambos refrigerantes en cada punto del ciclo de refrigeración.

PALABRAS CLAVES

Refrigerantes, redes neuronales, algoritmo genético.

ABSTRACT

This work is focused on the use of artificial neuronal networks and genetic algorithms for the determination of the thermodynamic states of refrigerants R22 and R134a, in the primary refrigeration circuit of a chilled water centralized air conditioning system. The designed neuronal model starts up from a multilayer grid that defines suction and discharge pressures, and overheating and undercooling levels on the evaporator and condenser outlets respectively, as input variables. The enthalpy, entropy and specific volume of both refrigerants at each point of the refrigeration cycle were obtained.

KEYWORDS

Refrigerants, neuronal network, genetic algorithm.

INTRODUCCIÓN

El desarrollo de las técnicas de computación ha posibilitado evaluar equipos y mejoras de instalaciones a través de simuladores que permiten obtener el comportamiento de un diseño dado sin tener que hacer un prototipo a escala de laboratorio, lo que facilita el trabajo, se gana en rapidez y los recursos económicos



a emplear son mínimos en comparación con la prueba de un dispositivo físico.

Existe gran tendencia a establecer un nuevo campo de la computación que integra los diferentes métodos de resolución de problemas que no pueden ser descritos fácilmente mediante un enfoque algorítmico tradicional. Estos métodos, que tienen su origen en la emulación de sistemas biológicos son una nueva herramienta computacional capaz de manejar las imprecisiones e incertidumbres de problemas relacionados con el mundo real (reconocimiento de formas, toma de decisiones, etc.). Para ello se dispone de un conjunto de metodologías como son: la lógica difusa, el razonamiento aproximado, la teoría del caos, algoritmos genéticos y las redes neuronales artificiales (RNA), siendo esta última herramienta de inteligencia artificial el centro de este trabajo.

Los sistemas de climatización centralizados también pueden ser evaluados utilizando estas técnicas computacionales, enfocadas a la optimización y el control del consumo energético de estos equipos. Unas de las técnicas más novedosas en cuanto a la optimización de sistemas térmicos son la fusión de criterios termodinámicos con económicos, conocido como método termoeconómico que engloba contabilidad, asignación de costos, diagnóstico, y la optimización de componentes de un sistema térmico.

Para la aplicación de dicho método es necesario definir el modelo físico y económico del sistema. El físico se encontrará caracterizado por un conjunto de ecuaciones que relacionan las variables termodinámicas y físicas de los distintos flujos y equipos de la planta, y el modelo económico por ecuaciones que permiten calcular los costos del sistema, que incluyen los costos de energía y suministros utilizados y así como los costos asociados a los componentes del sistema (Z).

Para la conformación del modelo físico se hace necesario definir el estado de las sustancias de trabajo en el sistema.

Este artículo se enfoca al uso de redes neuronales contempladas dentro de las cajas de herramientas especializadas del Matlab¹ para el cálculo del estado termodinámico de refrigerantes R22 y el R134a del circuito primario de un sistema de climatización centralizado por agua helada.

REVISIÓN BIBLIOGRÁFICA

Las redes neuronales artificiales son una potente herramienta que pueden ser utilizadas en la interpretación matemática de sistemas térmicos. Su trabajo está fundamentado sobre modelos estocásticos que permiten resolver matemáticamente un problema con un alto grado de complejidad de manera sencilla, pues el sistema es interpretado como una caja negra y el modelo obtenido será una función del comportamiento de las variables de entrada y salida del sistema o componente en estudio.

Dadas las posibilidades de trabajo descritas anteriormente, las redes neuronales artificiales pueden ser empleadas para describir el comportamiento termodinámico de los refrigerantes sin necesidad de recurrir al método gráfico (nomogramas, diagramas, tablas) ni a funciones complejas basadas en la ecuación de estado, facilitando el cálculo de las propiedades y ganándose en confiabilidad y rapidez de cálculo.

Varios autores han hecho uso de las redes neuronales para el cálculo de propiedades termodinámicas de diferentes fluidos como es el caso de Adnan Sözen,² el cual desarrolló un algoritmo



para la determinación del estado termodinámico en la zona de ebullición y condensación de las mezclas refrigerantes alternativas metanol - bromuro de litio y metanol - cloruro de litio, obteniendo un coeficiente de correlación de 99,99 % y un error promedio cercano al 1%, el error máximo obtenido por la red fue inferior al 3% .

Sözen³ además define como variables de salida la entalpía, entropía y volumen específico, tales propiedades pueden ser calculadas tanto en la zona de saturación como en la zona de sobrecalentamiento y las variables de entrada a la red están dadas por la conjugación de los grados de sobrecalentamiento (SC) y las presiones de trabajo, pero no tiene en cuenta en su estudio, la zona de subenfriamiento.

G.N. Xie⁴ desarrolló un análisis para intercambiadores de calor de tubo y coraza con datos experimentales utilizando redes neuronales artificiales con el objetivo de analizar el proceso de transferencia de calor. Utilizó el algoritmo de retropropagación para el entrenamiento y prueba de la red neuronal, y estudia diferentes configuraciones para la búsqueda de una red óptima para predecir la temperatura del fluido a la salida del intercambiador y la razón de transferencia de calor, la desviación máxima entre los resultados de la predicción y los datos experimentales fue de 2%, por lo que se recomienda este algoritmo para predecir el funcionamiento de sistemas térmicos en aplicaciones ingenieriles, y la modelación de intercambiadores de calor.

H.M. Ertun⁵ hace uso de las redes neuronales artificiales basado en un algoritmo de retropropagación con datos experimentales en la evaluación de sistemas y componentes, donde predice el funcionamiento de un sistema de refrigeración con condensación evaporativa; con esta herramienta de inteligencia artificial se predicen varios parámetros de funcionamiento, como calor cedido en el condensador, flujo másico de refrigerante, potencia de compresión y coeficiente de funcionamiento.

Los resultados de la red neuronal se encuentran cercanos a los valores experimentales obteniendo coeficientes de correlación mayor que 0.93, lo que indica que el error relativo oscila en el rango de 1.90–4.18 %. Mostrándose así las potencialidades de las redes neuronales artificiales en la modelación estocástica de sistemas y componentes.

M. Hosoz⁶ utiliza RNA con retropropagación para predecir varios parámetros de funcionamiento de un sistema de refrigeración por compresión de vapor, obteniendo como variables de salida de la red la temperatura de evaporación, la potencia de compresión y el coeficiente de funcionamiento del ciclo y el error medio relativo obtenido después de entrenada la red osciló en un rango de 0,2 - 6% confiéndole al modelo validez de aplicación en la evaluación de este tipo de sistemas.

H. Bechtler⁷ utilizó la red radial base generalizada (GRBF), definida por las variables de entrada siguientes: temperatura del agua a la salida del evaporador, temperatura del agua a la entrada del condensador y la capacidad de refrigeración en el evaporador, mediciones fáciles de obtener, con el objetivo de evaluar el coeficiente de funcionamiento del ciclo. Bechtler desarrolló el modelo para tres refrigerantes: LPG, R22 y R290; notando que no se logra en todos el mismo grado de exactitud dadas las peculiaridades de cada una de las sustancias en estudio.

Underwood⁸ desarrolló un modelo para la simulación de una planta de refrigeración que utiliza refrigerante R134a con el propósito de investigar sobre el funcionamiento del sistema de control. Utiliza una técnica de optimización para lograr sintonizar los dos lazos de control principal que regulan los grados de sobrecalentamiento en el evaporador.

Erol Arcaklio⁹ investigó acerca del funcionamiento de una bomba de calor por compresión de vapor para dos tipos de refrigerantes R12 y R22. Para ello utiliza como variable de entrada a la red: la temperatura de entrada al evaporador y la presión en el condensador, mientras que obtiene como datos de salida el coeficiente de funcionamiento y la eficiencia racional. El tipo de red que utilizó es de algoritmo con retropropagación obteniendo un coeficiente de correlación de 0.99 y un error medio relativo inferior a 0.006. Arcaklio no tuvo en cuenta en su estudio los grados de subenfriamiento y de sobrecalentamiento del ciclo.

El caso que ocupa este trabajo es la determinación del estado termodinámico de los refrigerantes R22 y R134a a partir de RNA multicapas con propagación hacia adelante con algoritmo de aprendizaje con

retropropagación, con el fin de una posterior simulación y evaluación termoeconómica del sistema de climatización. Este método se diferencia de los reportados anteriormente en que las RNA obtenidas para cada zona de trabajo están resumidas en una función obtenida en Matlab que las integra y que devuelve como resultado los estados termodinámicos en cada zona del sistema, sin necesidad de llamar de forma independiente cada RNA, obteniendo economía de cómputo y facilitando el trabajo para una posterior simulación del sistema.

ARQUITECTURA DE LA RED NEURONAL ARTIFICIAL, (RNA)

Se diseñó un modelo neuronal para la obtención del estado termodinámico de los refrigerantes R22 y R134a. El cual consiste en un conjunto de elementos de cálculo llamados neuronas (por su similitud con las neuronas biológicas) conectadas en serie y paralelo. La conexión de varias neuronas en paralelo conforman una capa y varias de estas últimas pueden conectarse en serie para formar una RNA. Las RNA realizan sus cálculos empleando funciones no lineales y factores simples de multiplicación, llamados pesos, los que están asociados con un enlace entre dos neuronas.

Estas estructuras tienen la capacidad de “aprender” relaciones complejas no lineales entre entradas y salidas a partir de la experiencia vivida mediante un proceso denominado entrenamiento, durante el cual son ajustados los pesos hasta que el conjunto de entrada produzca las salidas deseadas.

Existen varios tipos de RNA adecuadas para diferentes aplicaciones. Los modelos desarrollados se basan en una red multicapa con propagación hacia adelante con algoritmo de aprendizaje con retropropagación. Este tipo de red fue escogida dadas las posibilidades que brinda y su amplio uso en un gran número de aplicaciones.

Para la modelación de los estados del circuito primario de un sistema de refrigeración por compresión de vapor se conformaron tres redes neuronales artificiales referidas a las siguientes zonas: saturación, sobrecalentamiento y subenfriamiento, describiéndose de esta forma el comportamiento de las sustancias refrigerantes a su paso por el circuito.

En el caso de la RNA referente a la saturación se diseñó con algunas particularidades que la diferencia de las restantes (figura 1). Debido a que las propiedades de la sustancia en la saturación, tanto para líquido como para gas, tienen una relación unívoca con la presión, es posible implementar un modelo en el que se obtenga como resultado todos los estados del refrigerante en esta zona cuando el mismo se encuentra a una presión determinada, evitando la necesidad de diseñar una red individual para cada propiedad o grupo de ellas.

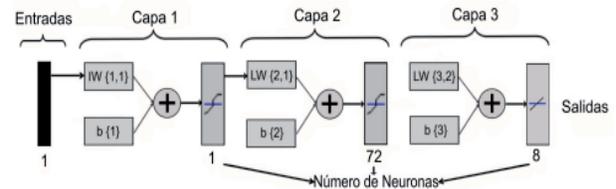


Fig. 1. Arquitectura RNA 1-72-8 zona de saturación.

De esta forma, la red se ha estructurado con una neurona en la primera capa correspondiente a la variable de entrada (Presión P), 72 neuronas en la capa intermedia y ocho neuronas en la tercera capa correspondientes a las variables de salida (temperatura de saturación (tsat), entalpía del líquido (hl), entalpía del vapor (hv), entropía del líquido (sl), entropía del vapor (sv), volumen específico del líquido (vl), volumen específico del gas (vg) y coeficiente adiabático (k)). Se utilizaron como funciones transferenciales la función Tansig en la primera y segunda capa y Purelin como función transferencial a la salida de la red, en la figura LW {i,j} y b {i} corresponden las matrices de pesos y polarizaciones respectivamente de la i-ésima capa de las RNA.

El diseño de la RNA correspondiente a la zona de Subenfriamiento (figura 2) se conformó en tres capas con la siguiente estructura: dos neuronas en la primera capa correspondientes a las variables de

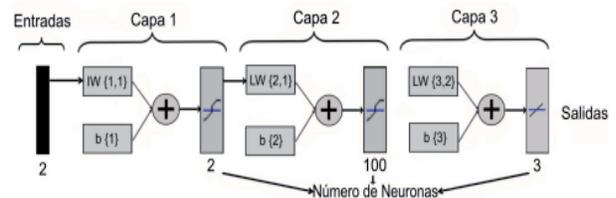


Fig. 2. Arquitectura RNA 2-100-3: zona de subenfriamiento.

entrada (P y grados de subenfriamiento (GSE)), 100 neuronas en la segunda capa y tres neuronas en la última capa, que describen el comportamiento de las variables de salida (entalpía (h), entropía (s) y volumen específico (h, s, Ve)). Las funciones transferenciales utilizadas para el subenfriamiento y sobrecalentamiento son similares a la de la zona de saturación. Mientras en la zona de sobrecalentamiento se diseñó una red de cuatro capas con dos neuronas en la primera capa correspondiente a las variables de entrada (P, Tsob), nueve y seis neuronas en las capas intermedias respectivamente y tres en la capa de salida correspondiente a las variables de salida (h, s, Ve).

No se conoce una forma para determinar de antemano el número de capas intermedias (ocultas) ni el número de neuronas de las mismas, por lo que se requiere una aproximación de prueba y error. En todos los casos, para las redes diseñadas, el número de neuronas de las capas intermedias fue escogido mediante este tipo de ensayo seleccionando aquellas que garantizaron el mínimo error durante el entrenamiento.

IMPLEMENTACIÓN DEL MODELO NEURONAL

Para la implementación del modelo neuronal de los refrigerantes descritos se hizo necesario definir juegos de datos de entrenamiento y de validación con el objetivo de comprobar el resultado de las RNA. Para la definición de los datos se parte de un juego de valores obtenidos a partir de las propiedades termodinámicas de los refrigerantes,¹⁰ seleccionando un conjunto de estos para el entrenamiento y otro para la validación de las redes diseñadas. Los datos fueron normalizados para obtener una mayor exactitud y confiabilidad del modelo, lo cual se corroboró con la posterior simulación y validación de la RNA.

Una vez diseñada la red y definidas las variables de entrada y salida de las mismas se procede a su entrenamiento y validación, obteniendo las matrices de pesos correspondientes y las polarizaciones que caracterizan a cada RNA.

Los resultados obtenidos en el entrenamiento y validación de la RNA del R-22 en la zona de saturación muestran un alto grado de correlación entre ambos comportamientos, obteniéndose un error medio cuadrático del orden de 10^{-6} . Las demás

redes referentes a las zonas de sobrecalentamiento y subenfriamiento también se comportan de forma similar a la descrita.

Una vez definidas las RNA de cada zona de trabajo del circuito primario de refrigeración se creó una función en Matlab para calcular las propiedades de los refrigerantes, a la cual se le introduce como entrada la presión de succión, la presión de descarga y los grados de sobrecalentamiento y subenfriamiento, en caso de estar presente en el ciclo. La función devuelve como resultado el estado del refrigerante en cada punto del circuito primario de refrigeración (figura 3). El algoritmo para el cálculo de las propiedades de los refrigerantes se muestra en la figura 4.

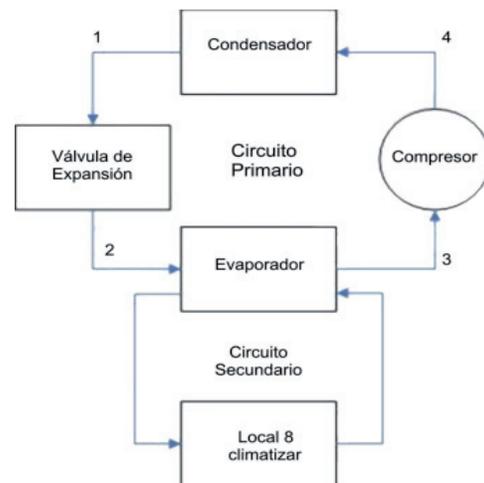


Fig. 3. Puntos principales del circuito primario de refrigeración.

MODELO HÍBRIDO PARA LA DETERMINACIÓN DE LA TEMPERATURA DE SALIDA DEL COMPRESOR DEL SISTEMA DE REFRIGERACIÓN POR COMPRESIÓN DE VAPOR

La temperatura del refrigerante a la salida del compresor se determina a partir de un modelo híbrido que conjuga el modelo neuronal con la herramienta de optimización mediante un algoritmo genético simple (AG). La función de aptitud de este algoritmo es una función de error entre la entropía del gas a la salida del evaporador teniendo en cuenta los grados de sobrecalentamiento a la salida de este intercambiador y la entropía que se obtiene del modelo neuronal del refrigerante en la zona de sobrecalentamiento.

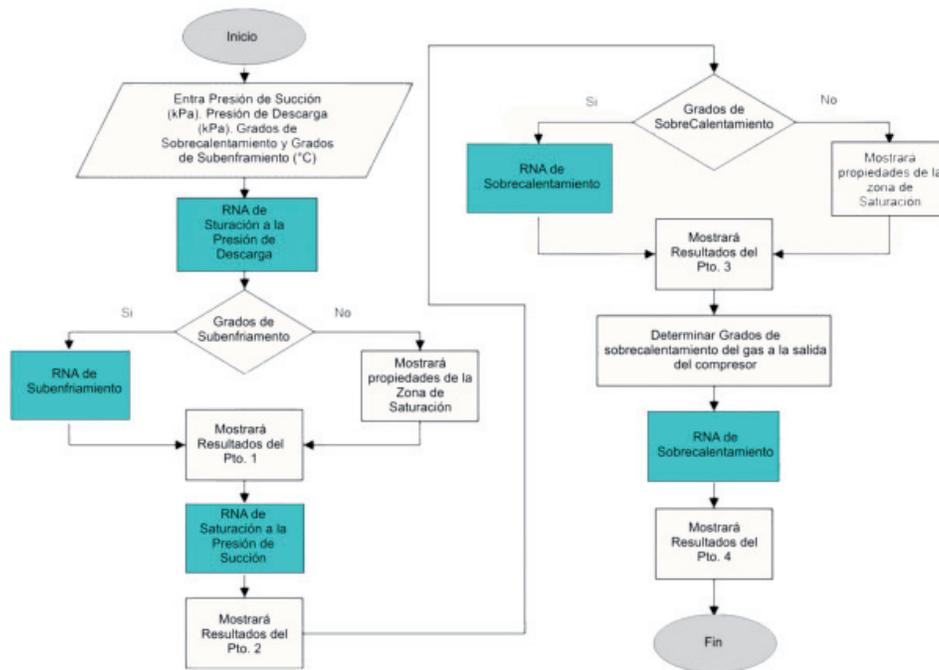


Fig. 4. Diagrama de bloques de la aplicación desarrollada en Matlab para determinar las propiedades termodinámicas de los refrigerantes utilizando RNA en cada punto del sistema.

Con este algoritmo de trabajo para la determinación de la temperatura de salida del gas refrigerante a la salida del compresor se reemplazan las ecuaciones tradicionales basadas en el comportamiento del gas ideal y determinadas por el coeficiente adiabático y la relación de presiones del ciclo.

En la figura 5 se muestra un diagrama que representa el proceso seguido en el AG. La variable genética corresponde a los grados de sobrecalefacción (X) y el AG busca el valor

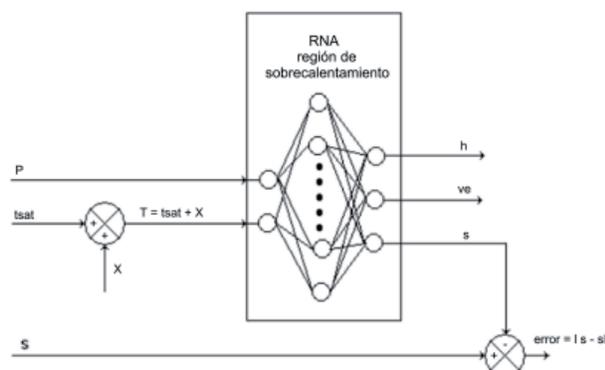


Fig. 5. Diagrama esquemático de la función de aptitud a minimizar por un AG para determinar los grados de sobrecalefacción del refrigerante a la salida de un compresor.

de esta variable que garantiza un mínimo error. Las variables de salida del modelo (h, V_e , s), corresponden a la RNA que caracteriza la zona de sobrecalefacción.

La validación del modelo híbrido para la determinación de la temperatura de salida del gas refrigerante en el proceso de compresión, se realiza comparando los resultados obtenidos a partir del modelo híbrido artificial con las tablas dadas por el fabricante.¹⁰ En la tabla I se muestran los resultados obtenidos por ambos métodos y el error para diferentes casos de estudio empleando como sustancia refrigerante el R22.

A continuación se muestra la validación de la función realizada en el Matlab para el cálculo de las propiedades del refrigerante (R22) en cada punto del circuito primario del sistema de climatización centralizado por agua helada a partir de un caso de estudio (tabla II), los puntos mostrados se refieren a los señalados en la figura 4.

Como se puede observar en la tabla II, la comparación de los resultados obtenidos por la función desarrollada en Matlab basada en las RNA y los resultados obtenidos a partir de las tablas del fabricante,¹⁰ muestran un error menor de 3%.

Tabla I. Resultados del modelo en la validación.

RNA (datos de entrenamiento)			Tablas	AG		% Error
P (kPa)	Tsat (°C)	s (kJ/KgK)	Tsal. Comp.	X	Tsal Comp. (Usando AG)	
1195.700	30.123	1.790	59.509	28.653	58.770	1.24
1334.000	34.388	1.835	84.664	50.170	84.561	0.123
1533.500	39.998	1.774	66.778	24.210	64.208	3.850
1579.900	41.228	1.774	68.590	24.821	66.048	3.706
1947.100	50.108	1.753	72.907	22.362	72.468	0.602

Tabla II Validación de los resultados de la RNA.

Ptos.	RNA			Tablas del fabricante		
	h (kJ/Kg)	s (kJ/KgK)	Ve (m ³ /kg)	h (kJ/Kg)	s (kJ/KgK)	Ve (m ³ /kg)
1	255.331	1.167	9.02e-4	256.364	1.187	9.02e-4
2	255.331	1.204	0.014	256.364	1.208	0.014
3	407.201	1.771	0.051	407.491	1.765	0.051
4	446.087	1.771	0.014	442.432	1.765	0.015

CONCLUSIONES

Al concluir el presente trabajo se creó una función en Matlab que integra cada una de las zonas de las RNA para la simulación y evaluación termodinámica del sistema que facilita el trabajo para la obtención del cálculo de sus propiedades para cualquier punto del circuito primario de refrigeración de un sistema de climatización centralizado por agua helada.

Como herramienta de apoyo para la determinación de propiedades se obtuvo un modelo híbrido fusionando la RNA referente al sobrecalentamiento y un algoritmo genético simple para la estimación de la temperatura del gas refrigerante a la salida del proceso de compresión, se validó el modelo y se obtuvo un error inferior al 3 %.

Se confirma el elevado potencial de las herramientas de inteligencia artificial para la determinación de propiedades y simulación de sistemas térmicos, con un alto grado de precisión.

REFERENCIAS

1. Matlab, Matlab. 2005, www.mathworks.com.
2. Sözen, A. and M. Özalp, Formulation based on artificial neural network of thermodynamic properties of ozone friendly refrigerant/absorbent couples in Applied Thermal Engineering. 2005. p. 1808-1820.
3. Sözen, A., M. Özalp, and E. Arcaklioğlu, Calculation for the thermodynamic properties of an alternative refrigerant (R508b) using artificial neural network in Applied Thermal Engineering. 2007. p. 551-559.
4. Xie, G.N., et al., Heat transfer analysis for shell-and-tube heat exchangers with experimental data by artificial neural networks approach 2006.
5. Ertunc, H.M. and M. Hosoz, Artificial neural network analysis of a refrigeration system with an evaporative condenser, in Applied Thermal Engineering. 2006. p. 627-635.
6. Hosoz, M. and H.M. Ertunc, Modelling of a cascade refrigeration system using artificial neural network, in Applied Thermal Engineering 2005.
7. Bechtler, H., et al., Neural networks - a new approach to model vapour-compression heat pumps, in Applied Thermal Engineering. 2001. p. 941-953.
8. Underwood, C.P., Analysing multivariable control of refrigeration plant using matlab/simulink, in Seventh International IBPSA Conference. 2001, University of Northumbria: Rio de Janeiro, Brazil.
9. Arcaklio, E., A. Eri, and R. Yilmaz, Artificial neural network analysis of heat pumps using refrigerant mixtures, in Applied Thermal Engineering. 2003. p. 937-952.
10. ASHRAE, ed. Handbook, Fundamentals 1997 SI Edition. 1997.