

# 整体式翅片管换热器的精度自校正模型\*

丁国良 张春路 刘 浩

(上海交通大学机械与动力工程学院 上海 200030)

摘要: 为提高换热器性能的计算精度和速度, 建立了整体式翅片管式换热器的精度自校正模型。该模型中带了两个神经网络, 一个用于补偿简化模型与分布参数模型的差异, 另一个则用于自适应地学习试验结果, 提高模型的精度。用该模型计算整体式翅片管冷凝器和蒸发器性能, 并与试验结果相对照。对于冷凝器, 换热量误差的平均值和最大值分别为 0.63% 和 1.72%, 过冷度误差的平均值和最大值则为 0.9 °C 和 3.2 °C。对于蒸发器, 换热量误差的平均值和最大值分别为 1.56% 和 11.0%, 过热度误差的平均值和最大值则为 1.5 °C 和 9.8 °C。对于冷凝器和蒸发器, 计算速度较分布参数模型均提高两个数量级。

关键词: 换热器 模型 神经网络

中图分类号: TB65

## 0 前言

换热器性能的准确预测, 对于使用换热器的装置的优化设计, 降低能耗具有关键作用。由于整体式翅片管换热器应用广泛, 光是我国每年用于空调器上作为蒸发器或冷凝器的翅片管式换热器即达数千万套, 因此研究该型换热器性能预测, 具有更为重要的价值<sup>[1]</sup>。

已有的对于管内制冷剂侧与管外空气侧换热系数与流动阻力系数的研究成果<sup>[1~3]</sup>是准确预测翅片管式换热器性能的基础, 但是希望在较大的工况变化范围内准确预测换热器性能, 仍有较大难度。难点之一为, 现有的管内制冷剂侧与管外空气侧换热系数的精度有一定限制。比如通过试验整理得到的空气侧换热系数与翅片高度、形状、管排数和分路数等多种因素有关, 由于影响因素众多, 在其试验工况数据范围内进行公式整理时, 就会有一定的误差, 当公式外推使用时, 精度将更低。如果所用的整体式翅片管换热器的结构尺寸或工作状态与该式整理时所依赖的结构与工况参数相差较大时, 偏差会更大。难点之二为, 实际换热器传热是三维的, 但按三维传热进行计算则过于复杂, 而按实用化要求进行简化的话, 必然会增加误差。

由于传统方法的限制, 已有学者采用神经网络来代替传统的换热器模型<sup>[4]</sup>, 并在其试验范围内达到了传统回归换热系数方法难以达到的高精度。但作为完全脱离了经典传热模型的黑箱模型, 必须要有大量的试验数据对于神经网络进行训练, 所需神

经网络的结构比较复杂, 更严重的是, 该模型外推性较传统的方法要差。

为了既能提高精度, 同时又减少计算量, 文中采用基于模型的智能仿真方法<sup>[5~7]</sup>预测翅片管式换热器在实际装置中的性能, 该方法中的模型可分为两大部分: 一部分为经过简化的基本模型, 反映换热器工作机理; 另一部分为神经网络, 用于反映简化模型与分布参数模型间的非线性关系, 以及自适应地补偿基本模型与试验结果间的误差。这里所用的试验数据是通过专用空调换热器试验台测得的, 该试验台可测试翅片管式蒸发器与冷凝器在空调器常用工况下的工作特性<sup>[8,9]</sup>。

## 1 模型与神经网络的结合方式

结合神经网络的翅片管式换热器模型如 1 所示, 包含了三个部分: 第一是简化的换热器基本模型, 能够快速计算换热器的性能; 第二是简化用神经网络, 用以修正因为模型简化而引起的误差; 第三是精度改进用神经网络模块, 用以自适应地修正模型与试验结果的差异。

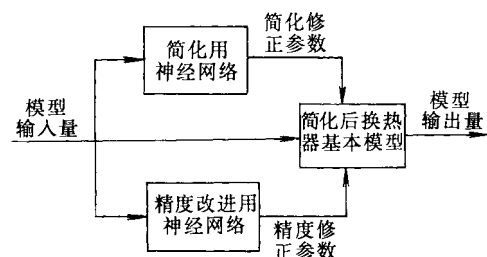


图 1 神经网络与换热器简化模型结合示意图

下面进一步就整体式翅片管式换热器作为冷凝器和蒸发器时的情况, 分别加以论述。

\* 国家重点基础研究发展规划(973)资助项目(G2000026309)。20020118 收到初稿, 20020810 收到修改稿

## 2 翅片管式冷凝器

### 2.1 冷凝器基本模型

为保证基本模型的简单实效,作以下简化处理:

①翅片管式换热器为逆流型换热器。②管外空气的流动视作一维均匀流动。③管内制冷剂的流动为一维均相流动。④不计制冷剂侧压降。

作如上简化处理的理由如下:①整体式翅片管式换热器在实际应用中,管内制冷剂和管外空气的相对流动介于叉流与逆流之间,而更接近于叉流。但如果考虑成叉流,模型就与具体的结构布置相关,缺乏通用的描述方法,故简化为逆流。②管外空气的流动的不均匀并不是主要影响因素,管内制冷剂的流动较接近一维均相流动,冷凝器内的制冷剂侧压降较小而可以忽略。③精度改进用神经网络模块可以起到自动提高模型精度的作用,数学模型的主要功能是反映基本特征,而忽略次要的误差源。简化后的模型如图 2 所示。




图 2 冷凝器模型示意图

对于冷凝器中的任一微元,其传热方程为

$$dQ = \pi D(T_r - T_a)UdL \quad (1)$$

$$U = [1/\alpha_i + A_i/(\alpha_o A_o)]^{-1} \quad (2)$$

式中  $Q$ ——换热量

$T$ ——温度

$U$ ——总表面传热系数

$D$ ——管径

$A$ ——有效传热面积

$\alpha$ ——表面传热系数

$a$ ——下标,代表空气侧

$r$ ——下标,代表制冷剂侧

$i$ ——下标,代表管内侧

$o$ ——下标,代表管外侧

表面传热系数的计算关联式取自文献[1~3]。

### 2.2 基本模型简化

冷凝器分布参数模型较之集中参数模型,具有良好的参数变化敏感性,但计算量和存储量大,在系统仿真迭代时会严重影响仿真速度,有必要在保持一定的参数敏感性基础上对分布参数模型进行简化。由式(1)和式(2)可得

$$dQ = \pi DgdL \quad (3)$$

$$\text{式中 } g = \frac{T_r - T_a}{\frac{1}{\alpha_i} + \frac{A_i}{\alpha_o A_o}}$$

$g$  反映了微元换热的强弱,是表征冷凝器分布特性的特征参数。对每个相区而言,通过求取沿管长的平均特征参数  $g_{av}$ ,式(3)可以写成

$$Q = \pi Dg_{av}L \quad (4)$$

对式(4)沿管长积分,可以在保持相当的参数敏感性的前提下将每个相区简化为一个节点,其相区长度计算公式如下

$$L = \frac{Q}{\pi Dg_{av}} \quad (5)$$

图 3~5 显示  $g$  随管长变化的趋势。计算时单相区取 30 个微元、两相区取 200 个微元(进一步增加微元数目对计算结果已几乎没有影响)。

图 3、图 4 显示过冷区、过热区  $g$  值沿管长的变化趋势近似于二次曲线,亦较接近线性,而且过热区、过冷区长度占总长度的比例较小,故直接将其简化为一个微元对结果影响不大,取  $g_{av} = 0.8g$ 。 $g$  为对单个微元过热区或过冷区用算术平均温度得出的特征参数值。根据数值试验,这样简化所导致的换热量误差大都在 0.3% 以下,影响甚微。

对两相区的简化采用与单相区类似的思路,沿管长的平均特征参数  $g_{av}$  写成与用算术平均温度得出的特征参数值  $g$  成一定比例,比例的大小记为  $l$ ,则有以下公式

$$g_{av} = lg \quad (6)$$

从图 3 可以看出, $g$  沿两相区管长变化较为复杂,加上两相区的长度与换热量在冷凝器中占的比例较大,两相区简化时不能简单地取比例  $l$  为常数。由于  $l$  受多个因素影响,它与其相关因素之间的关系难以用数学关联式明确表达,这里采用人工神经网络来描述。表 2 中列出了经整理后的  $l$  值的主要影响因素,这三个参数即是冷凝器简化用神经网络的输入参数,而  $l$  则是冷凝器简化用神经网络的输出参数。




图 3 特征参数  $g$  沿过冷区管长变化




图 4 特征参数  $g$  沿过热区管长变化




图 5 特征参数  $g$  沿两相区管长变化

表 1 冷凝器  $l$  值影响因素

变量	计算公式	说明
$T_{rai}$	$10(T_c - T_{atpo})/T_{atpo}$	$T_c$ 为冷凝温度 $T_{atpo}$ 为两相区空气出口干球温度
$\alpha_{i0}$	$5\alpha_o/\alpha_i$	$\alpha_i$ 为两相区入口制冷剂侧换热系数 $\alpha_o$ 为两相区入口空气侧换热系数
$A_{i0}$	$A_o/(50A_i)$	$A_i$ 为冷凝器管内传热面积 $A_o$ 为冷凝器管外传热面积

### 2.3 试验数据的自学习

数学模型与真实的物理过程总有一定的差距，造成计算结果与试验值的不一致。为处理上的简单起见，将导致这种不一致的因素包容在总的换热系数  $U$  内。

修正后的总换热系数  $U'$  可以表示为

$$U' = kU \quad (7)$$

式中  $k$ ——总换热系数的修正系数

$k$  和工况、结构参数有关。由于影响因素众多，相互关系复杂，难以用确定的修正函数形式，因而采用人工神经网络来描述。该神经网络，即精度改进后神经网络，包含输入层、输出层和一个隐层。输出层只有一个神经元，对应修正系数  $k$ 。输入层神经元个数由输入参数的个数决定。输入参数的选取至少应满足这样两个原则：其一是所有的输入参数在计算  $k$  值时都应该是已知量，这样可以避免引入附加的迭代计算；其二是输入参数必须能反映各类因变量(工况、结构参数)的变化。另外，输入参数应尽量为量纲一参数，以提高神经网络的通用

性。根据上述原则选取的输入参数如表 2 所示。

表 2 精度改进用神经网络输入参数

输入	定义	说明
$Re$	$u_a D_o / \nu$	$u_a$ 为最窄面风速 $\nu$ 为空气进口动力粘度 $D_o$ 为换热管外径
$S_D$	$s / D_o$	$s$ 为翅片间距
$L_D$	$l_f / D$	$l_f$ 为沿空气流动方向的翅片长度
$T_{ra}$	$(T_r - T_{ai}) / T_{ai}$	$T_r$ 为制冷剂饱和温度 $T_{ai}$ 为空气入口干球温度
$q_{m,ra}$	$q_{m,r} / q_{m,a}$	$q_{m,r}$ 为制冷剂流量 $q_{m,a}$ 为空气流量
$N_d$		分路数

### 2.4 冷凝器计算效果检验

首先检验上述简化方法的有效性。

将冷凝器分布参数模型简化为三节点模型时，所采用的简化用神经网络的输入参数为表 1 所列变量，输出为  $l$ 。网络输入层为 3 个神经元，隐藏层为 4 个神经元，输出层为 1 个神经元，学习收敛精度为 0.018。训练该网络的样本数据采用常规空调条件下，用分布参数模型算出的 183 组数据，进一步检验计算效果则采用了较大范围的数据。验证样本数据有 16 384 组，验证范围如下：翅片间距 1.4~3.0 mm，冷凝温度 35~60 °C，空气进口风速 0.9~1.5 m/s，空气进口干球温度 19~52 °C，制冷剂流量 30~120 kg/h。结果表明，简化模型与分布参数模型换热量最大误差 8.2%，平均误差 1.6%，计算速度提高两个数量级。

然后，通过对于试验数据的学习与检验，考察整个复合模型的计算效果。

冷凝器的试验在春兰技术中心的换热器综合试验台上进行。所用的翅片管式冷凝器包括波纹片光管换热器和单桥片内螺纹管换热器两种。两种换热器的管排数有 2 排、3 排两种，翅片间距有 1.5 mm、2.0 mm 和 2.4 mm 三种，分路数有 2 路、3 路两种。共有 10 个试件。试验中空气进口状态分高、中、低温和高、中、低温工况，空气进风干球温度范围 17~50 °C，迎面风速范围 1~2 m/s，制冷剂进口过热度范围 30~40 °C，过冷度范围 3~9 °C。精度改进用神经网络结构为 6 个输入神经元、4 个隐层神经元和 1 个输出层神经元。对于试验用冷凝器的 58 组试验数据，取其中 26 组数据作为学习样本。神经网络学习的收敛精度为 0.012。结果表明，换热量最大误差 1.72%，平均误差 0.63%；过冷度最大误差 3.2 °C，平均误差 0.9 °C。

### 3 翅片管式蒸发器

#### 3.1 蒸发器基本模型及其简化

与冷凝器类似,同样需要假定:①翅片管式换热器为逆流型换热器。②管外空气的流动视作一维均匀流动。③管内制冷剂的流动为一维均相流动。④蒸发器中的制冷剂压降较大,则不能予以忽略,仅忽略过热区的压降。简化后的模型如图 6 所示。




图 6 蒸发器模型示意图

由于蒸发器必须考虑析湿和压降,使得蒸发器的简化较冷凝器更为复杂。以下按换热、析湿和压降三个方面加以考虑。

对于换热,考虑方式类似于冷凝器,仿照式(1)~(6)的推导过程,同样引入修正因子  $l$ 。

与冷凝器不同,蒸发器的空气侧计算时,需要考虑空气的析湿,因此引入析湿修正因子  $r$ 。简化成单个微元后的平均析湿系数  $\xi_{av}$  采用以下公式

$$\xi_{av} = r\xi \quad (8)$$

$\xi_{av}$  采用平均湿度、温度计算。

对于单个微元,制冷剂侧的压降计算可以采用下式

$$\Delta p = \frac{8fq_{m,r}^2 L}{\pi^2 \rho_1 D_i^3} + \frac{16q_{m,r}^2}{\pi^2 D_i^2} \left( \frac{1}{\rho_2} - \frac{1}{\rho_1} \right) \quad (9)$$

式中  $\Delta p$ ——压降

$f$ ——沿程阻力系数

$\rho_1, \rho_2$ ——进出口制冷剂密度

对于整个相区的压降计算时,仍然用进出口点的状态作为计算的依据,再需要引入修正因子对于误差进行修正,如下式

$$\Delta p_{av} = n\Delta p \quad (10)$$

以上对换热、析湿和压降的处理集中于  $l$ 、 $r$ 、 $n$  三个系数上。影响这三个系数的量很多,而且对这三个量的影响不是分立的,因此在考虑影响因素时可以作为整体来考虑。提取了表 3 所示的变量作为以上三个系数的影响量,构造一个 5 输入、3 输出的 BP 神经网络。

BP 神经网络的训练样本共 83 组,为保证神经网络学习的有效性,样本包括了各种需要变化的条件:变翅片间距、变管长、变迎面风速、变空气入

口温度和变制冷剂入口温度。BP 神经网络的结构为 3 层,输入层有 5 个神经元,隐藏层有 8 个神经元,输出层有 3 个神经元。采用快速 BP 算法学习,学习的收敛精度为 0.06。

表 3  $l$ 、 $r$ 、 $n$  值影响因素

变 量	计算公式	说 明
$T_{ra}$	$10(T_{ai}-T_{ro})/T_{ai}$	$T_{ro}$ 为蒸发器制冷剂入口温度 $T_{ai}$ 为蒸发器空气入口干球温度
$\alpha_o$	$10\alpha_o/\alpha_i$	$\alpha_i$ 为蒸发器入口制冷剂侧换热系数 $\alpha_o$ 为蒸发器出口空气侧换热系数
$A_{io}$	$A_o/(10A_i)$	$A_i$ 为蒸发器管内传热面积 $A_o$ 为蒸发器管外传热面积
$q_{m,ra}$	$q_{m,r}/q_{m,a}$	$q_{m,r}$ 为制冷剂流量 $q_{m,a}$ 为空气流量
$D_L$	$D_{ei}/L_e$	$D_{ei}$ 为蒸发器管内径 $L_e$ 为蒸发器管长

将训练好的 BP 神经网络串入蒸发器简化程序中进行验证计算,验证样本共 1 600 个,覆盖如下范围:翅片间距 1.4~3 mm,蒸发温度 4~20 °C,空气进口风速 0.9~1.5 m/s,空气进口干球温度 15~30 °C,制冷剂流量 30~120 kg/h。结果表明,简化模型与分布参数模型换热量最大误差 11.0%,平均误差 1.56%;过热度最大误差 9.8 °C,平均误差 1.5 °C。计算速度提高两个数量级。

#### 3.2 蒸发器试验数据的自学习

蒸发器简化模型的仿真值接近分布参数模型,而分布参数模型仿真值与试验值有一定的差距。为了提高简化模型的仿真精度,有必要提供一种方式,使得简化模型在通用性的基础上进一步满足准确性的要求。

提高精度用神经网络输出量为  $k_1$ 、 $k_2$ 、 $k_3$ ,分别用以修正制冷剂侧换热系数、析湿系数和制冷剂侧压降。

修正后的制冷剂侧换热系数  $\alpha'_i$  可以表示为

$$\alpha'_i = k_1 \alpha_i \quad (11)$$

修正后的析湿系数  $\xi'$  可以表示为

$$\xi' = k_2 \xi \quad (12)$$

修正后的制冷剂侧压降  $\Delta p'$  可以表示为

$$\Delta p' = k_3 \Delta p \quad (13)$$

$k_1$ 、 $k_2$ 、 $k_3$  和工况、结构参数有关,采用多层前向神经网络来辨识这种非线性关系。神经网络结构定为:6 个输入神经元、6 个隐层神经元和 3 个输出层神经元。输入神经元对应的变量同冷凝器类似,如表 2 所示;输出神经元为  $k_1$ 、 $k_2$ 、 $k_3$  三个系数。神经网络的训练样本为所测得的 91 组数据中随机选取的 30 组。神经网络收敛精度为 0.008。

将学习好的神经网络与简化模型结合起来,重新计算试验所测得的 91 组数据,并与试验结果对照,结果表明:换热量最大误差 10.5%,平均误差 1.2%;过热度最大误差 9.7 °C,平均误差 3.5 °C。

#### 4 结论

通过对于整体式翅片管换热器与神经网络的结合,一方面得以简化模型,提高了计算精度,另一方面也使模型具有自适应性,从而提高模型的精度。

对于整体式翅片管式换热器作为蒸发器与冷凝器使用的情况,分别进行了研究,结果发现,用于冷凝器所得的结果好于蒸发器的结果。这主要是冷凝器不存在析湿与结霜,工作状况较为单一,而蒸发器则存在析湿等情况,较为复杂。

如果增加神经网络的神经元数目,提高收敛精度设定,可以使复合模型对于学习样本有更好的精度,但这样一来可能降低泛化能力。因此神经元的个数不宜过多,收敛精度设定也不能过高。文中例子中给出的神经网络结构是经过权衡而定的较好的结构。

#### 参 考 文 献

- 1 李旻,陶文铨,康海军,等.整体式翅片管换热器传热和阻力性能的试验研究.机械工程学报,1997,33(1):81~86
- 2 Shah M M. A general correlation for heat transfer During film condensation inside pipes. Int. J. Heat Mass Transfer, 1979, 22(4): 547~556
- 3 Wang H, Toubert S. Distributed and non-steady-state modeling of an air cooler. Int. J. Refrig., 1991, 14(2): 98~111
- 4 Diaz G, Sen M, Yang K T, et al. Simulation of heat exchanger performance by artificial neural networks. Int. J. HVAC&R Research, 1999, 5(3): 195~208
- 5 Ding G L, Li H, Zhang C L. Study on thermodynamic model of a compressor with artificial neural networks. Chinese Journal of Mechanical Engineering, 1999, 12(1): 23~26
- 6 丁国良,张春路,詹涛,等.制冷压缩机热力计算的复

合模糊模型.科学通报,2000,45(6):660~663

- 7 张春路,丁国良,李灏.小型制冷压缩机热力计算神经网络方法的改进.机械工程学报,2001,37(1):75~77
- 8 魏志勇.房间空调器性能预测方法的研究与应用:[硕士学位论文].上海:上海交通大学,1999
- 9 刘浩.结合人工神经网络的空调器稳态仿真研究:[硕士学位论文].上海:上海交通大学,2000

### ACCURACY SELF-ADAPTIVE MODEL FOR FIN-IN-TUBE HEAT EXCHANGERS

Ding Guoliang Zhang Chunlu Liu Hao  
(Shanghai Jiaotong University)

**Abstract:** An accuracy self-adaptive model for fin-in-tube heat exchangers is established, in which two artificial neural networks are combined with a simplified traditional mathematical model. One of the neural networks is used to compensate the difference between the distributed-parameter model and the simplified one, the other is used to improve the model accuracy by adaptively learning from experimental data. The model is used for predicting fin-in-tube heat exchangers and compared with experimental results. For condensers, it is shown that the average and maximum deviations of heat flow rate are 0.63% and 1.72% respectively, while the average and maximum deviations of subcooling are 0.9 °C and 3.2 °C respectively. For evaporators, the average and maximum deviations of heat flow rate are 1.56% and 11.0% respectively, while the average and maximum deviations of superheat is 1.5 °C and 9.8 °C respectively. For condensers and evaporators, the computational speed with the new model is about two orders of magnitude faster than that with the distributed-parameter model.

**Key words:** Heat exchanger Model

Artificial neural network

作者简介:丁国良,男,1966年出生,博士,教授,博士生导师,系主任。主要从事制冷空调装置仿真、优化和自然工质应用。科研项目获省部级奖3项,个人被评为上海市科技启明星、教育部高校骨干教师,获霍英东基金会高校青年教师科研奖。发表论文70余篇,专著4本,编著2本和教材1本。