

# 基于人工神经网络的机械通风开式冷却塔运行性能在线预测

## ONLINE PERFORMANCE PREDICTION OF MECHANICAL DRAFT WET COOLING TOWER USING ARTIFICIAL NEURAL NETWORK

徐哲恬<sup>1</sup> 潘毅群<sup>2</sup> 黄治钟<sup>3</sup>

1 上海建筑设计研究院有限公司, 上海 200041, E-mail: xuzt@siadr.com.cn

2 同济大学机械与能源工程学院, 上海 201804

3 同济大学中德工程学院, 上海 201804

**摘要:** 本文提出了一种基于人工神经网络的机械通风开式冷却塔运行性能在线预测方法。方法以四层BP网络为核心, 利用进塔水温、空气湿球温度、塔内水气质量比这三个参数预测出塔水温。在对上海某建筑中的机械通风横流冷却塔进行测试后发现, 出塔水温在线预测值和实测值之间相关系数为0.95, 预测效果良好, 在线预测方法有效。

**关键词:** 开式冷却塔; 人工神经网络; 在线预测

## 0 引言

时代的发展催生了大规模、集成化的建筑, 也加重了建筑对人工环境的依赖, 建筑内的空调设备日趋多样、复杂。维持空调系统安全、稳定、高效的运行就需要对其进行全面的监测, 并进行实时诊断、评估。

目前, 成套的楼宇自控系统已经能够做到实时监测建筑各个部件的运行数据。但利用数据发现问题、解决问题还需要更完善的故障自动诊断机制。一些学者[1][2]提出了基于模型的故障诊断方法, 这些模型是对部件正常运行性能的数学描述, 它们可以是物理模型、性能曲线或人工神经网络等。

冷却塔作为空调系统中重要的散热部件, 它的出塔水温会直接影响冷水机组的运行性能。有研究显示, 如果出塔水温比所要求的温度偏高1℃, 那么冷水机组的COP会降低约3~4%[3]。因此, 冷却塔的故障诊断模型就需要能够准确预测出塔水温, 及时判断是否存在运行故障。

本研究以建筑空调系统中常用的机械通风开式冷却塔为例, 讨论并测试一种出塔水温在线预测的方法。

## 1 在线预测

预测是根据已有事件的客观规律推算未来事件的发展结果, 它包含三个过程: 学习、分析和推算。在线预测是将在线学习和预测结合, 边工作边学习, 利用新发生的事件不断更新学习法则, 使学习法则与事件的发展紧密相连。

冷却塔出塔水温在线预测方法可以辅助冷却

水系统的运行监测、故障诊断和优化控制。但与此同时, 方法的服务对象也对方法本身提出了几点要求:

- 预测速度快
- 预测结果准确
- 具有良好的泛化能力
- 具有良好的自适应能力

为了解决这四个问题, 就需要建立一个有效的冷却塔模型和一套完整的在线预测机制。

## 2 冷却塔模型

在已有的研究中, 通常会使用两种模型描述冷却塔的运行性能。一种是以热质传递过程为基础的物理模型, 如Merkel[4]提出的以焓差为驱动力的传热公式和在此基础上进行改进和优化的Poppe方法[5]和e-NTU方法[6]等。另一种模型是以实测数据为基础的数学模型。物理模型虽然能较准确地反映冷却塔的热力过程, 但是描述模型需要使用大量冗长复杂的方程, 并需要借助假设简化计算过程, 影响计算的准确性。而数学模型则完全抛开物理意义, 通过对大量实测数据的统计和分析, 总结出经验公式等, 求解运行参数。

在线预测冷却塔的运行性能给预测模型提出了两个要求, 第一个是快速准确, 第二个是能够根据预测误差及时修正模型。物理模型和经验公式都很难同时满足这两点要求。而人工神经网络是一种模拟动物神经网络行为特征的模型, 具有自学习和自适应的能力, 可以利用预先提供的一批相互对应的输入、输出数据, 分析掌握两者之间潜在的规律, 并依此推算预测结果。预测误差是模型自我修正过程中最重要的反馈信号。

BP (误差反向传播)神经网络是目前应用最广的一种人工神经网络,它具有多层映射的结构,计算误差可以对网络的权值进行调整。它常被用于模式识别、自适应控制等领域。一些学者[7][8][9]将BP算法应用到冷却塔的性能预测中,通过实验证明了人工神经网络可以有效准确地预测冷却塔的运行性能。因此,本文所提出的在线预测方法也将用BP网络作为学习和预测的核心模型。

## 2.1 影响出塔水温的因素

机械通风开式冷却塔内的水冷却过程实质是空气和水之间的热质传递过程。在风机的作用下,空气被吸入冷却塔,和填料上的水滴、水膜进行热质交换,带走水的热量,降低水的温度。影响冷却水出塔水温的因素可以分为以下三类:

1) 冷却塔的进塔水温——影响冷却散热量:在其余条件恒定的情况下,进塔水温越高则出塔水温越高。

2) 空气的干、湿球温度——影响冷却极限:在其余条件恒定的情况下,空气的干、湿球温度越高则出塔水温越高。

3) 冷却塔内的空气流量和水流量——影响水和空气的接触时间和换热速度:在其余条件恒定的情况下,冷却水量越大,空气流量越小则出塔水温越高。空气流量和水流量之间的关系也反映了冷却塔结构特性对于出塔水温的作用。

这三类因素中,有三个是温度参数,两个流量参数。为了统一输入模型的参数形式,引入无量纲因子——水气质量比(F)代替空气流量和水流量。

$$F = \frac{\text{冷却水质量流量}}{\text{空气流量}} \quad (1)$$

通过对5000组实测数据的对比分析后发现(表1),空气干球温度与出塔水温的相关系数远小于其余三个参数。因此确定模型将使用进塔水温、湿球温度和水气质量比预测出塔水温。

表1 输入参数的相关性检验

	进塔水温	干球温度	湿球温度	水气质量比	出塔水温
样本个数	5000	5000	5000	5000	5000
平均值	36.12	32.53	27.17	1.94	30.62
标准差	1.29	3.26	0.82	0.53	1.01
相关系数					
出塔水温	0.549	0.054	0.403	0.516	--

## 2.2 冷却塔的人工神经网络模型

### 2.2.1 网络结构

本研究采用BP神经网络模型来学习并预测冷却塔的出塔水温。网络有三个输入节点:湿球温度、进塔水温和水气质量比;一个输出节点:出塔水温。由于实际工程中的冷却塔存在着启停、工况调节等多种变化,出塔水温的变化曲线是不连续的。因此本研究所建立的网络模型含有两个隐层,它能较好地映射非连续型函数。

为了进一步确定网络隐层的节点数,研究利用1000组实测数据进行10次迭代计算,并比较不同隐层节点数的网络全局误差。如封装TRNSYS到MATLAB函数的目的是使得在MATLAB的M文件中可以非常方便和灵活地调用TRNSYS,可以根据需要来修改TRNSYS的运行时间、优化变量值以及将计算结果返回到MATLAB的工作空间。封装TRNSYS到MATLAB函数的步骤如下:

首先,在TRNSYS Simulation Studio中建立好建筑及空调系统模型,并且定义好所需要

	第一隐层节点数	第二隐层节点数	训练阶段全局误差	测试阶段全局误差
1	3	3	56.997	21.709
2	4	3	49.662	26.927
3	5	3	58.081	23.898
4	6	3	63.275	31.649
5	7	3	57.392	21.972
6	4	4	54.448	25.238
7	5	4	53.285	28.314
8	6	4	59.646	24.069
9	5	5	57.637	22.235

的输出文件,通常是模拟者所关注的如系统总能耗、费用或者舒适性等。模型建立好后,TRNSYS的输入文件都会保存到Dck格式的文本文件。Dck文件保存和记录了模型中各组件的信息和组件间的连接关系,可以由TRNExe.exe调用并执行。同时,Dck文件可以很容易的在MATLAB中加载和读取。TRNExe程序是一个代数和微分方程的求解器,根据Dck输入文件在每个时间步长迭代计算直至收敛,再进行下一个时间步长的计算。

其次,在MATLAB中,如图3所示,可以通过复制原Dck文件到MATLAB工作目录下,以免在优化过程中修改最原始的DCK文件。在M文件中,通过Dos()命令或!命令可以调用TRNExe,不过需要将当前MATLAB的工作目录改为TRNExe的工作目录。多区建筑

模块 Type56 的 bui 输入文件须与 Dck 文件放在同一个文件夹内。运行 TRNExe 结束后，可以再将 TRNSYS 的输出结果文本文件通过 textread 命令函数加载到 MATLAB 工作空间中读取，然后返回当前优化变量对应的目标函数值。在 M 文件中，通过 ga() 函数调用遗传算法工具箱，通过遗传算法不断寻优，每一次寻优结束后，将更新的优化变量在 MATLAB 中通过查找和替换 Dck 文件中相应的优化变量值，再进行下一步的寻优计算，直至算法结束。

最后，再对计算结果进行后处理。可以通过 MATLAB 的画图函数将这些优化变量和优化目标函数值输出，也可以通过遗传算法自带的画图函数在线输出。

通过封装 TRNSYS 到 MATLAB 函数，在 MATLAB 工作空间中只要输入 [x fval] = ga(@MATLAB\_TRNSYS\_HVAC.2.options) 命令，就会自动计算并反馈优化变量矩阵 x 以及对应的最优函数值 fval。其中，@MATLAB\_TRNSYS\_HVAC 表示封装的优化函数，是一个 M 函数文件，放在当前 MATLAB 的工作目录下，用来计算空调系统的能耗。2 则表示当前优化变量的个数为两个，在本研究中是 AHU 送风温度和冷机的供水温度。options 定义了遗传算法的参数，优化变量的取值范围，如交叉选择的概率、变异的概率、算法终止条件等。

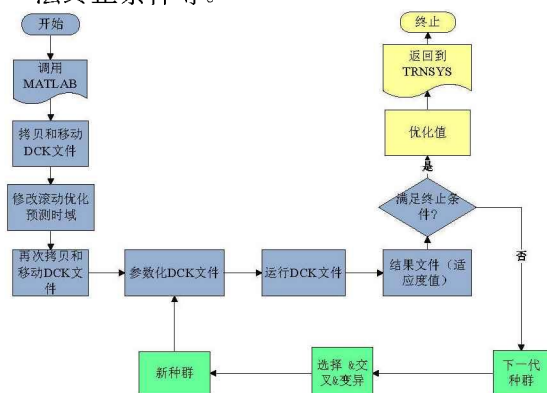


图 3 封装 TRNSYS 到 MATLAB 函数

所示，当第一、第二隐层分别设三个节点时，模型的测试全局误差最小。

### 2.2.2 激发函数

BP 神经网络的常用激发函数有双曲正切函数、S 型 (Sigmoid) 函数和线性函数等。

利用 1000 组数据试算不同激发函数的网络计

表2不同隐层节点数的全局误差

算误差 (在本研究中，选取的目标函数为空调系统的总能耗，包括水泵、风机、机组和冷机塔的能耗之和，可以通过 TRNSYS 组件 Type65 打印并在线输出。即目标函数为  $fval = Pfan + Ppump + Pchiller + Ptower$ 。水泵和风机均采用变频控制。选取的优化变量为空气处理机组 AHU 送风温度和机组冷冻水供水温度。选取的这个两个变量与空调系统风侧和水侧的能耗变化紧密相关。

) 后发现，当隐层使用双曲正切函数、输出层使用 S 型函数的网络全局误差最小。

表3不同激发函数的全局误差

隐层激发函数	输出层激发函数	训练阶段全局误差	测试阶段全局误差
双曲正切函数	线性函数	48.122	25.538
	双曲正切函数	4.141	2.21
	S 型函数	1.415	0.338
S 型函数	线性函数	50.176	23.734
	双曲正切函数	4.609	1.885
	S 型函数	1.723	0.463

综合上述的测试结果，确定本研究中的冷却塔人工神经网络模型为四层结构 (图 1)。隐层的激发函数为双曲正切函数，输出层的为 S 型函数。




图1机械通风开放式冷却塔人工神经网络模型结构图

模型的输入数据用公式-2 进行归一化，输出数据用公式-3 进行还原。

$$x'_i = 0.02 + 0.96 \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

$$x_i = \frac{(x'_i - 0.02)(x_{\max} - x_{\min})}{0.96} + x_{\min} \quad (3)$$

用 1000 组数据训练人工神经网络，并输入新的 200 组数据进行预测。预测结果和实测值的对比如图 2 所示。预测值和实测值之间的误差分析见表 4、图 3 和图 4。




图2 200 组数据预测结果

表4测试集误差

误差	最大值	最小值	平均值	标准差
绝对误差 (°C)	0.81	-0.93	-0.06	0.4
相对误差 (%)	2.8	-3.1	-0.2	1.32
-0.7°C<绝对误差<+0.7°C的出现频率				88%




图3测试集的绝对误差频率分布图




图4预测值与实测值对比

预测值和实测值之间的相关系数为 0.9，接近与 1。预测误差不超过±1°C，误差平均值接近于 0°C。误差在工程允许的范围，可以认为该冷却塔人工神经网络模型能准确预测出塔水温。

### 3 在线预测的实现

在线预测的实现可以分为四个阶段，第一个是前期调研阶段，在这个阶段内需要搜集冷却塔的基本信息，确定冷却塔型号、额定工况。第二个是实测准备阶段，在这个阶段内需要在整个冷却水系统

中加装测量和数据记录仪器。第三个是试运行阶段，目的在于发现问题并获得实测数据。第四个是在线学习阶段，每隔一段时间更新学习算法的训练样本。最后一个就是预测阶段，不间断地输出预测结果。

当将在线预测的方法运用到实际运行中的时候会出现这样两个问题：

1) 冷却塔的启停和调节等运行工况突变的数据会被采集，而这些数据不能真实反映冷却塔的稳态性能，会混淆在线预测算法的学习对象。

2) BP 神经网络对于内涵域中的预测准确性较高，外延域中的预测准确性较低。实测数据是以时间为序的，随着气候条件、空调负荷的季节性波动，如果训练样本量较小，就有可能出现预测范围超出学习范围的情况，预测的准确性降低。

为了满足快速准确的要求，就需要寻找合适的解决办法。针对问题（1）——如何剔除工况突变数据，本研究采取了两种方法。一是利用合理的采样周期降低工况突变数据被记录到的概率。二是对用于训练的数据进行平滑处理。提高模型的稳定性。针对问题（2）——如何控制合理的预测范围，在线预测算法会记录预测误差，并根据平均累积误差（公式-4）判断是否需要更新学习算法。

$$\text{平均累积误差} = \frac{1}{n} \sum_{i=1}^n \text{预测值} - \text{实测值} \quad (4)$$

冷却塔出塔水温在线预测的具体流程如图 5所示：

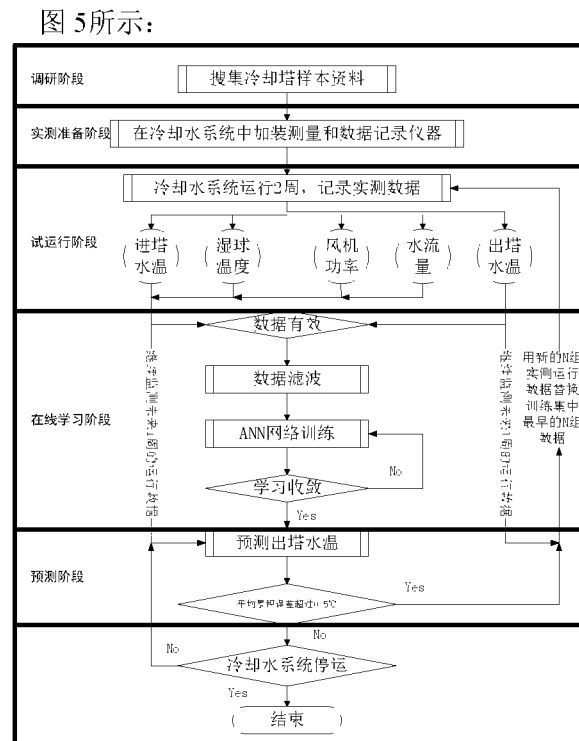


图5冷却塔运行性能在线预测流程

### 4 实测检验

为了证明在线预测方法的有效性,研究选用一组位于上海的冷却塔进行实测检验。测试对象是7台并联的机械通风横流冷却塔。这7台冷却塔型号相同。

表5实测冷却塔型号及参数

型号	SC-700
冷却水量	700m <sup>3</sup> /h
风机功率	22kW
风机风量	529000m <sup>3</sup> /h
风筒直径	3580mm
风筒半高 <sup>d</sup>	3880mm
塔体全压	5.5mH <sub>2</sub> O

当对2012年9月6日至9月15日的运行数据进行分析后发现,采样周期为6分钟时,BP网络最稳定,预测准确性最高。因此确定该套测试系统的采样周期为6分钟。

经过2012年9月17日至10月17日一个月的在线预测运行试验后,出塔水温预测值和实测值的对比结果见图6、图7和图8。




图6在线预测结果-温度变化趋势图




图7在线预测绝对误差频率分布图

<sup>d</sup>风筒半高——出风口和进风口中部的高度差




图8在线预测结果-预测值与实测值对比

表6预测误差统计

	最大值	最小值	平均值	标准差
绝对误差(°C)	2.45	-3.28	0.16	0.69
相对误差(%)	10.59	-10.22	0.73	2.64
-1°C<绝对误差<+1°C的出现频率			87.20%	

统计显示(表6),使用在线学习的方法进行预测,得到的最大预测误差未超过±3.3°C,有87.2%的预测误差未超过±1°C,绝对误差平均值为0.16°C,误差向零点集中。预测值和实测值之间的相关系数为0.95,接近于1。满足工程上对于预测出塔水温的误差控制要求,预测效果良好。

## 5 结论

以四层BP神经网络为核心的在线预测算法可以快速、准确地预测机械通风开式冷却塔的出塔水温。然而,这个方法也存在一定的特殊性,它的计算核心是以实测数据为基础的,不是一个通用的计算公式,要得到准确的预测结果,必须预先开展调研、实测、试运行等工作,并根据系统自身的情况判断合适的采样周期,获得有效的数据样本。

在对上海某建筑中的机械通风横流冷却塔进行测试后发现,出塔水温在线预测值和实测值之间相关系数为0.95,预测效果良好。在线预测方法有效。

### 参考文献

- 1 J.Gertler, Survey of Model-based Failure Detection and Isolation in Complex Plants[J], IEEE Control Systems Magazine 1988.6(8),3-11
- 2 A.S.Glass, P.Gruber, M.Roos, and J.Todtli, Preliminary Evaluation of a Qualitative Model-Based Fault Detector for a Central Air-Handling Unit[C], Proceedings of 3<sup>rd</sup> IEEE Conference on Control Applications, Glasgow, 1994
- 3 李苏龙,徐莉,朱海峰,水冷式冷水机组冷凝温度控制法研究[J],制冷学报,2005,12(4)59-62
- 4 F.Merkel, Verdunstungskühlung[D], VDI

- Forschungsarbeiten, 1925(in German)
- 5 M.Popp, H.Rögener, Berechnung von Rückkühlwerken[J], VDI-Wärmeatlas, 1991, 1-15(in German)
- 6 H.Jaber, R.L.Webb, Design of cooling towers by the effectiveness-NTU method, Journal of Heat Transfer 1988.111.837-843
- 7 M.Hosoz, H.M.Ertunc, H.Bulgurcu. Performance Prediction of a Cooling Tower Using Artificial Neural Network[J], Energy Conversion and Management, 2007,48,1349-1359
- 8 Xiaoni Qi, Zhenyan Liu, Dandan Li. Numerical Simulation of Shower Cooling Tower Based on Artificial Neural Network[J], Energy Conversion and Management, 2008,49,724-732
- 9 Ming Gao, Feng-zhong Sun, Shou-jun Zhou, Yue-tao Shi, Yuan-bin Zhao, Nai-hua Wang, Performance Prediction of Wet Cooling Tower Using Artificial Neural Network Under Cross-wind Conditions[J], International Journal of Thermal Sciences, 2009,