



同濟大學

TONGJI UNIVERSITY

硕士学位论文

(专业学位)

基于 ANN 的机械通风开式冷却塔运行性能在
线预测研究

姓 名：徐哲恬

学 号：1052030033

所在院系：机械与能源工程学院

学科门类：工程

学科专业：动力工程

指导教师：潘毅群

二〇一三年三月



同濟大學
TONGJI UNIVERSITY

A dissertation submitted to
Tongji University in conformity with the requirements for
the degree of Master

Online Performance Prediction of Mechanical Draft Wet Cooling Tower Using Artificial Neural Network

Candidate: Xu Zhetian

Student Number: 1052030033

School/Department: School of Mechanical
Engineering

Discipline: Engineering

Major: Power Engineering

Supervisor: Pan Yiqun

March, 2013

学位论文版权使用授权书

本人完全了解同济大学关于收集、保存、使用学位论文的规定，同意如下各项内容：按照学校要求提交学位论文的印刷本和电子版本；学校有权保留学位论文的印刷本和电子版，并采用影印、缩印、扫描、数字化或其它手段保存论文；学校有权提供目录检索以及提供本学位论文全文或者部分的阅览服务；学校有权按有关规定向国家有关部门或者机构送交论文的复印件和电子版；在不以赢利为目的的前提下，学校可以适当复制论文的部分或全部内容用于学术活动。

学位论文作者签名：

年 月 日

声明

本人郑重声明：所呈交的学位论文，是本人在导师指导下，进行研究工作所取得的成果。除文中已经注明引用的内容外，本学位论文的研究成果不包含任何他人创作的、已公开发表或者没有公开发表的作品的内容。对本论文所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明。本学位论文原创性声明的法律责任由本人承担。

学位论文作者签名：

年 月 日

摘要

本文主要分析并探索了针对机械通风开式冷却塔运行性能的在线预测方法。研究中, 选用出塔水温来表征冷却塔的运行性能, 重点分析了进塔水温、湿球温度、水气质量比三个参数对出塔水温的影响, 并用这三个参数预测出塔水温。

本文使用四层 BP 神经网络模型对冷却塔出塔水温进行在线学习和预测, 建模过程中所使用的数据来自实际运行中的机械通风逆流冷却塔。在确定模型有效后, 着重探讨了如何处理实际运行时易发生的运行工况突变情况。经过研究发现, 选用合适的采样周期既可以客观地反映冷却塔的运行性能, 也可以快速剔除工况突变点, 降低工况突变对 BP 神经网络稳定性和预测准确性的影响。在这些研究基础上, 本文又运用了另外一组机械通风横流冷却塔的实测数据进行算法校验。

通过实验和校验, 证明了所提出的算法可以实现机械通风开式冷却塔运行性能的在线预测。整个在线预测过程要经历 5 个阶段: 前期调研、实测准备、试运行、在线学习、预测。算法会监测累积预测误差。如果一个小时内的累积预测误差超过工程允许的范围, 那么就需要更新训练样本, 重新学习。就已测试的冷却塔而言, 出塔水温在线预测值与实测值之间最大预测误差未超过 $\pm 3.3^{\circ}\text{C}$, 有 87.2% 组数据的预测误差未超过 $\pm 1^{\circ}\text{C}$, 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。满足工程上的误差控制要求, 预测结果有效, 算法成立。

关键词:

开式冷却塔; 人工神经网络; 在线预测

ABSTRACT

This thesis analyzes and explores the online prediction method for operating performance of mechanical draft wet cooling tower. The research selects the tower outlet water temperature (t_{out}) to characterize the operating performance of the cooling tower and analyzes its relationship with three parameters: inlet water temperature (t_{in}), wet bulb temperature (t_{wb}) and mass ratio of air and water (F), these three parameters are then used to predict t_{out} .

This thesis uses a 4-layer BP neural network model for online learning and prediction of t_{out} . Actual operation data of mechanical draft counter-flow cooling towers is used to build the model. After proving the effectiveness of this model, the study focuses on how to deal with the operating condition mutations that frequently happen during actual runtime. It discovers that a suitable sampling period can both retain the average operating performance of the cooling tower and weaken the impact of condition mutations on the stability and prediction accuracy of the BP neural network. On the basis of these studies, another group of measured data is used to test and verify the algorithm of the method.

The experiments and verifications prove that the proposed algorithm can achieve online prediction of the operating performance of the mechanical draft wet cooling tower. The online prediction process consists of 5 steps: preliminary survey, test preparation, commissioning, online learning and online prediction. The algorithm will monitor the accumulated prediction error. If the accumulated error in one hour exceeds the limitation, the algorithm will refresh the learning samples and execute a new learning process. According to the test results, the maximum absolute error between predicted and measured values is within $\pm 3.3^{\circ}\text{C}$; 87.2% test samples have errors within $\pm 1^{\circ}\text{C}$; the average absolute error is 0.16°C , and the correlation coefficient between the two values is higher than 0.95. These results meet the engineering error control requirements, proving that the online prediction algorithm is applicable.

KEY WORDS:

Wet Cooling Tower; Artificial Neural Network; Online Prediction

目录

摘要.....	a
ABSTRACT.....	a
目录.....	i
主要符号表.....	iii
第 1 章. 绪论.....	1
1.1. 课题背景.....	1
1.1.1. 研究的意义.....	1
1.1.2. 国内外研究现状.....	2
1.2. 研究内容与步骤.....	4
第 2 章. 基本理论与方法.....	5
2.1. 冷却塔内热质传递过程的热力计算方法.....	5
2.1.1. 接触散热的热力学原理.....	5
2.1.2. 蒸发冷却过程的热力学原理.....	5
2.2. 冷却塔的物理模型.....	6
2.2.1. Merkel 方法.....	7
2.2.2. ϵ -NTU 方法.....	9
2.2.3. Poppe 方法.....	10
2.2.4. 三种方法的对比.....	12
2.2.5. 常用建筑仿真模拟软件中的冷却塔模型.....	13
2.3. 冷却塔的 ANN 模型.....	16
2.4. 人工神经网络 (ANN) 理论.....	17
2.4.1. 人工神经网络的发展史.....	17
2.4.2. 人工神经元.....	18
2.4.3. 人工神经网络.....	21
2.5. 在线预测.....	23
2.6. 本章小结.....	24
第 3 章. 数据的获得和数据处理.....	26
3.1. 数据的获得.....	26
3.2. 数据处理.....	27
3.2.1. 风机风量.....	27
3.2.2. 有效数据的判别.....	30
3.2.3. 数据平滑.....	30
3.3. 误差控制.....	32
第 4 章. 基于 ANN 的机械通风开式冷却塔模型.....	34
4.1. 模型的输入输出参数.....	34
4.1.1. 影响和表征机械通风开式冷却塔冷却能力的参数.....	34
4.1.2. 相关性检验.....	35
4.2. BP 神经网络.....	36
4.2.1. BP 神经网络的基本结构与学习算法.....	37
4.2.2. BP 神经网络的训练过程.....	40

4.2.3. BP 神经网络的改进方案.....	40
4.3. 机械通风开式冷却塔 ANN 模型	43
4.3.1. 建模过程.....	43
4.3.2. 测试结果.....	48
4.3.3. 多次采样后的测试结果.....	51
4.3.4. 针对工况突变的模型改进.....	53
4.4. 本章小结	61
第 5 章. 机械通风开式冷却塔 ANN 算法校验	62
5.1. 校验用冷却塔的基本情况	62
5.2. 数据处理	64
5.2.1. 风机功率与风量.....	64
5.2.2. 数据平滑.....	64
5.3. 测试结果	65
第 6 章. 冷却塔运行性能在线预测的实现	69
6.1. 训练样本与预测样本	69
6.2. 在线预测步骤	74
6.3. 在线预测结果	75
第 7 章. 总结与展望	77
致谢.....	79
参考文献.....	80

主要符号表

英文字母

m	质量, kg
\dot{m}	质量流量, kg/s
c	比热容, kJ/(kg·°C)
t/T	温度, °C
w	含湿量, g/kg(a)
A	面积, m ²
i	比焓, kJ/kg
n	个数; 系数
Q	换热量, kJ; 流量, m ³ /s
V	体积, m ³ ; 速度, m/s
X	输入信号
θ	阈值
W	权值
P	压强, Pa
N	功率, kW
g	重力加速度, N/kg
F	水气质量流量比

希腊字母

α	水面散热系数; 学习率
β	水面散质系数
γ	汽化潜热 kJ/(kg·°C)
ρ	密度 kg/m ³

下标

w	冷却水
a	空气
s	饱和湿空气
out	出塔
in	进塔
wb	湿球
set	设定值
cell	冷却塔风机单元
S	静压
m	平均值
max	最大值
min	最小值
1	进口
2	出口
e	额定

第1章. 绪论

1.1. 课题背景

在工业生产和建筑空调系统的运行过程中会产生大量废热，需要通过冷却介质带走废热，降低工作温度。水是最常用的冷却介质，它易获得、无污染、状态稳定、比热容大，被广泛运用在冷却系统中。冷却塔就是利用空气和水的直接或间接接触，通过接触散热和蒸发散热将废热排到大气中，降低水的温度。

冷却塔一般由填料、配水系统、风机设备、风筒、导风装置、集水槽和挡水板等部分组成。不同类型的冷却塔中的部件不尽相同，如无填料冷却塔中就不存在填料；自然通风冷却塔中就不存在风机设备。

冷却塔的种类较多，如果按照空气和水流动的方式划分，则可以分为逆流冷却塔和横流冷却塔。

如果按照气流产生的方式划分，则可以分为自然通风冷却塔和机械通风冷却塔。

如果按照冷却过程的类型划分，则可以分为开式（湿式）冷却塔和闭式（干式）冷却塔。

在建筑空调系统中，为了提高冷却水系统效率并节省设备占地空间，最常使用的是机械通风开式冷却塔。本文主要针对机械通风开式冷却塔（下文简称冷却塔）的运行性能展开研究。

1.1.1. 研究的意义

冷却塔是建筑空调系统中常用的散热装置。在空调系统的设计、运行管理和能耗分析时都需要分析冷却塔的热力性能。目前，冷却塔运行性能的传统预测方法是以传热、传质的物理过程为基础，计算过程繁琐、耗时长，并且无法根据实测数据修正预测算法，其预测结果的准确度较低。因此需要寻找一种快速、准确、通用的冷却塔运行性能在线预测方式，以便应用于实际工程中。

1.1.2. 国内外研究现状

关于冷却塔理论计算和性能分析的研究由来已久。

1925 年,德国学者Merkel^[1]首次提出了用焓差法分析蒸发冷却的传热传质过程。他使用刘易斯关系数,导出了一个以焓差为驱动力的传热公式。Merkel为了简化方程,对计算过程做了一些假设,如忽略水量蒸发损失;忽略液膜热阻;出塔空气为饱和湿空气,并且其特性由焓值唯一决定;将刘易斯关系数设为常数 1。这些假设在一定程度上影响了计算结果的准确性。在随后的一段时间内,诸多学者为Merkel方法的修正、推广和应用作出了贡献,1940 年,London^[2]等利用Merkel方法,结合实验数据,绘制了一系列适用于机械通风逆流冷却塔的曲线,将Merkel方法推广到工业应用中。1956 年,Zivi和Brand^[3]将Merkel方法推广到横流冷却塔的热力计算中。1974 年,ASHRAE^[4]根据Merkel方法绘制了大量通用性能曲线。1976 年,Kelly^[5]在Zivi和Brand横流冷却塔模型的基础上,用实验数据绘制了一些横流冷却塔性能曲线。这些实验数据和工程曲线的出现为冷却塔的设计计算和运行校核提供了便利。Merkel方法虽然被广泛用于工程领域,但是由于它在建模过程中使用了简化假设,其对冷却塔热力性能的计算结果会有一些的误差。1975 年,Nahavandi^[6]就提出忽略冷却水的蒸发损失会造成冷却塔设计散热量和实际散热量有 12%的偏差。

正是由于Merkel方法存在一些偏差,Poppe和Rögener^[7]在Merkel的研究基础上,对空气的不饱和性做了处理,他们没有采用Merkel方法中所做的简化假设,而是考虑了冷却塔内由于蒸发过程所造成的水损失和刘易斯关系数的可变性,其计算得到的蒸发水量与实测结果有较高的一致性。

Poppe的方法虽然准确,但计算过程极为繁琐,而在计算冷却塔的出塔水温时,它和Merkel方法的计算结果相差不大^[8]。因此,进入 80 年代后,诸多学者还是围绕Merkel方法进行了大量的探讨和深化。1983 年,Sutherland^[9]严格推导了冷却塔内的传热传质过程,并对Merkel方法中由简化假设所造成的偏差进行了分析,其主要考虑了忽略蒸发水损失的影响,并将刘易斯关系数的值近似取为 0.9,由他的方法所得到散热量计算误差比Merkel方法降低了 5%~15%。

1987 年,Jaber和Webb^[10]提出了一个具有划时代意义的方法,他们将换热器

中的传热单元数引入冷却塔的模拟计算,提出了有效传热单元数方法,即 ϵ -NTU方法,该方法虽然仍沿用Merkel方法的假设,但它简化了Merkel方法的积分过程,这种结合传热单元数的计算方法也受到了诸多商用软件的青睐。1988年,Braun^[11]对Merkel方法、Sutherland方法和 ϵ -NTU方法的误差进行了对比分析,他提出Merkel方法计算得出的散热能效值偏低,Sutherland方法和 ϵ -NTU方法的计算结果更接近,当将 ϵ -NTU方法的计算结果与实测数据对比后发现,出塔水温的误差不大,但水损失率计算结果偏低,能量平衡在10%以内。据此,Braun提出了更全面的冷却塔热力性能计算公式,考虑了冷却水在冷却塔高度方向上的蒸发损失。

上世纪90年代后,对于冷却塔运行性能的发展更为多元化。有些学者拓展或改进了Merkel方法^{[12][13]}和 ϵ -NTU方法^[14],有些学者从微观入手,研究冷却塔的热力性能^{[15][16]},也有些学者对热质传递物理方程的数值计算进行了研究^{[17][18][19]}。21世纪后,出现了一些将实验数据和物理公式结合的冷却塔半物理模型。2004年,孟华^[20]等从热力学、流体力学和传热传质基本原理出发,对冷却塔实验数据进行统计分析,以最小二乘法得出空气和水热湿交换的两个特性参数,并搭建冷却塔仿真平台,以实测数据进行对比、验证。2006年,Guang-Yu Jin^[21]等在Merkel方法和 ϵ -NTU方法的基础上,应用Levenberg-Marquardt优化方法来计算冷却塔的三个运行特征参数(散热量与气、水质量流量关系式中的三个系数),简化传统的预测过程。这些研究成果丰富了冷却塔运行性能的分析方法。

传统的冷却塔热力性能计算方法,需要从热质传递的物理过程中推导公式。在计算过程中求解多个繁琐的积分公式。而集成了实测数据的半物理模型,是利用从数据中总结出的经验公式对物理模型中的某个或某几个参数进行求解,再和其他公式一同求解冷却塔的热力性能。这些方法计算耗时长,且不能根据误差修正模型,不适宜在实际系统中应用。由于传统方法存在这些缺点,也有学者尝试使用人工神经网络预测冷却塔的运行性能。

ANN(人工神经网络)是一种模拟动物神经网络行为特征,以分布式并行处理信息的数学模型。ANN具有自学习和自适应的能力,可以通过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,最终根据这些

规律，用新的输入数据来推算输出结果。ANN具有黑箱性、鲁棒性、非线性映射性，可以快速解决复杂、模糊、非线性的问题。正是由这些优点，ANN被广泛应用于各种能源工程领域。Kalogirou^[22]曾就在能源系统中运用神经网络做了探讨，例如将其应用于分析建筑供热负荷、太阳辐射、HVAC系统、负荷预报等问题。如果将ANN应用与预测冷却塔的运行性能，那么就可以避免求解繁琐的积分方程，冷却塔的结构特性和填料特性也不用逐一进行讨论，取而代之的是利用数据训练，将这些特性记忆到ANN模型中。2006年，Hosoz^[23]等将BP（反向传播）神经网络算法应用到湿式冷却塔的性能预测中，其搭建了一个独立的冷却塔模型，从中读取运行数据，并将运行数据用于训练、校正神经网络模型。神经网络算法的预测结果与实测结果基本吻合，证实了神经网络可以有效预测冷却塔运行性能。2007年，齐晓霓^[24]等在Hosoz的基础上进行了深入研究，将神经网络应用于预测无填料机械通风式冷却塔的运行性能。2008年，高明^[25]等将相同的算法应用于预测自然通风逆流式冷却塔在侧风作用下的运行性能。以上三位学者的研究证实了神经网络既可以预测不同类型的冷却塔运行性能，也可以预测特定工况下的冷却塔的运行性能。

1.2. 研究内容与步骤

本研究将神经网络应用于在线预测机械通风开式冷却塔的运行性能。主要是通过以下三点得出通用的冷却塔运行性能在线预测方法：

1) 利用 ANN 预测冷却塔运行性能

在了解冷却塔运行机理和 ANN 应用方法的基础上，利用 ANN 搭建冷却塔运行性能在线预测模型。利用一组冷却塔的实测数据对 ANN 算法进行初步测试和调整，以提高计算速度，确保模型稳定、可靠。

2) 利用另一组冷却塔运行性能实测数据校验 ANN 算法

利用另一组冷却塔的实测数据训练、校验 ANN 算法，得到通用的基于 ANN 的冷却塔运行性能预测算法。

3) 实现冷却塔运行性能的在线预测

将上述通用算法应用到实际的空调系统中，实现冷却塔运行性能的在线预测。

第2章. 基本理论与方法

2.1. 冷却塔内热质传递过程的热力计算方法

冷却塔内的冷却过程是通过空气和水之间的热质传递完成的。冷却循环水通过喷头淋到填料上。填料将水滴分化，形成水膜，增大了空气和水的接触面积，并延长了接触时间。水和空气存在一定的温差，这个温差就是空气和水热交换的驱动力。填料间的空气属于不饱和湿空气，空气中的水分和冷却水之间的状态差别是空气和水质交换的驱动力，因此部分水滴被蒸发到空气中，在水分子从液态到蒸发态的变化过程会释放出气化潜热，排出了冷却水的热量，使冷却水温降低。

2.1.1. 接触散热的热力学原理

接触散热是指水和空气在接触过程中所发生的传热过程。冷却水和冷却塔内的空气存在一定的温差，温差越大，散热效果越好，反之则越差。进入冷却塔的水温是高于塔内空气的干球温度的，当经过塔体后，水温降低，气温升高，两者之间的差减小。温差是接触散热的驱动力，当水温等于气温时，接触散热停止。

2.1.2. 蒸发冷却过程的热力学原理

水在液态、气态和气液共存态之间的状态变化在冷却塔的运行过程中扮演了重要的角色。水由液态变为气态的过程称为汽化，由气态变为液态的过程称为凝结。沸腾和蒸发是汽化的两种形式，其中沸腾是液体内部的汽化过程，蒸发是液体表面的汽化过程。冷却塔内的水状态变化属于蒸发过程，它可以在任何温度下发生。汽化和凝结受到气液两相的温度和压力影响在两个介质内同时进行，当汽化和凝结达到动态平衡时，水蒸汽和液态水就达到了饱和状态。一般将水蒸汽和干空气的组合成为湿空气，大气中的空气就是湿空气。湿空气的压力是水蒸气分压力和干空气分压力的和。水蒸气的分压力和湿空气的干球温度决定了水蒸气的状态。而饱和水蒸汽和干空气组成的湿空气被称为饱和空气，饱和空气中水蒸气分压力称为饱和分压力。在相同干球温度下，不饱和空气中的水蒸气分压力低于饱和分压力，两者的比值即为相对湿度，由此可知，相对湿度接近 100%的湿空

气的饱和度较高。

从微观上看,汽化是水分子脱离液面束缚,跃入空气的过程,而凝结过程则是空气中的水蒸汽分子不断冲撞液面,被水分子捕获变为液体的过程。液体水分子的平均能量决定了液体的温度,水分子在汽化过程中,带走了水表面的能量,水温降低,这就是蒸发散热。根据道尔顿定律,被蒸发的水分子首先会在水表面形成一层薄的饱和空气层,这个空气层的温度和水面温度相同,水蒸气从饱和空气层向大气中扩散的快慢取决于饱和层的水蒸气压力和大气水蒸气压力之间的差。

由水蒸气的蒸发过程和湿空气的组成可知,水面饱和空气层和大气湿空气之间的水蒸气压力差是蒸发散热的驱动力。水和空气之间的蒸发冷却过程即存在热交换又存在质交换。从能量平衡和质量平衡的角度上看,水在这个过程中的质量减少,温度降低,而空气的质量增加,温度升高。

2.2. 冷却塔的物理模型

接触散热、蒸发冷却和这两个传热过程中所包含的传质过程是冷却塔物理模型的理论基础。冷却过程中的接触散热和蒸发散热可以分成了四个阶段。第一个阶段中水温高于空气干球温度,接触散热和蒸发散热共同发生,水温下降,水分子进入空气中。第二个阶段中水温等于空气干球温度,此时接触散热停止,蒸发散热继续进行,水温继续下降,水分子继续进入空气中。第三个阶段中水温已经低于空气干球温度,空气向水产生接触传热,但水面的蒸发散热照常进行,且水的蒸发散热量大于接触得热量,水温下降。第四个阶段与第三个阶段类似,但水的温度已经下降到了极限,即水的蒸发散热量等于接触得热量。理论上说,湿球温度(包着一层被水浸润的湿纱布的温度计所测得的气温)^[26]是水冷却的极限。但由于冷却塔受到其形状和结构的限制,进入塔内的水和空气都是有限的,经过冷却塔冷却后的水温是高于进塔空气的湿球温度的,甚至是高于进塔空气的干球温度的。出塔水温和进塔空气湿球温度越接近,则说明冷却得越充分。为了进一步评价和分析冷却塔的冷却效果,世界各地的学者就冷却过程的物理描述做了很多研究^[27]。

从 20 世纪发展至今,关于冷却塔蒸发冷却过程的物理描述已经有了相当多

的科研成果。20 世纪初期，冷却塔的物理模型都是以温度差为驱动力的，忽略了冷却过程中物质传递的存在。此后，多位学者也提出了对蒸发冷却过程中热质交换独立进行的理论。到了 20 世纪的 20 年代，Merkel 综合了热交换和质交换，以此作为蒸发冷却过程描述的基础，提出了冷却作用是由空气和水之间的焓差所引起的。然而，由于 Merkel 所提出的方法和与其相应的研究都是以德语发表的，受到语言的限制，该研究成果并没有迅速在世界范围内推广开，直到 1941 年，Merkel 理论被翻译成英语后，才被广泛应用^[13]。随后，蒸发冷却过程的物理描述有了新的发展，有些研究仍然是以 Merkel 理论为基础，对其进行改进和优化，有些研究则提出了更准确更详细的物理模型。在这期间， ϵ -NTU 方法和 Poppe 方法的出现是比较有影响力的成果，这两个方法也是最有代表性的冷却塔热力计算方法。

下面将简要解释一下 Merkel 方法^[1]、 ϵ -NTU 方法^[10]和 Poppe 方法^[7]的基本理论。

2.2.1. Merkel 方法

1925 年，Merkel 提出了热交换和物质交换方程，在随后的 50 年中，这个方法被用于描述湿空气和水之间的热质交换冷却过程。

Merkel 方法中的有一个重要的等式：由对流和蒸发面引起的水热量损失等于空气热量的增量：

$$m_w c_w dt_w = \beta \left[\frac{\alpha}{\beta} (t_w - t_a) + \gamma (w_s - w_a) \right] dA \quad (2-1)$$

上式中：

m_w ——冷却水质量

c_w ——冷却水比热

t_w ——冷却水温度

β ——水面散质系数

α ——水面散热系数

t_a ——空气干球温度

γ —— t_w 温度下液体的汽化潜热，即饱和蒸汽和液体之间的焓差

w_s —— t_a 温度下饱和湿空气的含湿量

w_a ——空气的含湿量

A ——换热面积

为了简化冷却塔填料间水气蒸发冷却过程的物理描述，Merkel 做了一些简化假设：

- 1) 假设表征传热传质相对速率的 Lewis 关系数 ($Lewis_f$) 等于 1。
- 2) 假设出塔空气达到了饱和状态，其状态参数由焓值决定。
- 3) 在计算能力平衡时，忽略了冷却过程中的水蒸发损失。
- 4) 假设水膜或水滴的表面温度与水体内部温度一致，不考虑水侧热阻。

由以上假设可知：

$$Lewis_f = \frac{\alpha}{\beta c_p} = 1 \Rightarrow \frac{\alpha}{\beta} = c_p \quad (2-2)$$

上式中 c_p 为空气的定压比热容。

将式(2-2)代入式(2-1)中得：

$$m_w c_w dt_w = \beta [c_p t_w + \gamma w_s - (c_p t_a + \gamma w_a)] dA \quad (2-3)$$

湿空气的焓 $i = c_p t_a + \gamma w_a$ ；液体表面饱和空气的焓 $i_s = c_p t_w + \gamma w_s$

由此可以得到水热量变化与空气焓值变化的关系：

$$m_w c_w dt_w = \beta (i_s - i) dA \quad (2-4)$$

Merkel 将式(2-4)归纳为蒸发参数（又称 Merkel 数）：

$$Me_M = \frac{\beta}{m_w} A = \int_{t_w-out}^{t_w-in} \frac{c_w}{i_s - i} dt_w$$

Merkel数表征了冷却塔的蒸发冷却能力。冷却塔的设计和运行性能评价都会使用到Merkel数。由于水温不是空气焓值的直接函数，对于Merkel数进行积分求解有困难，因此学术界采用了近似积分的方法。近似积分的方法有很多，例如辛普森积分法、平均推动力法、对数及算术平均焓差法，切比雪夫积分法。其中切比雪夫积分法得到了美国冷却塔协会（CTI）的推荐，在美国和日本得到了广泛使用^[28]。中国的冷却塔设计规范中所推荐的积分方法是多段辛普森积分法^[29]。

辛普森积分公式如下：

$$\begin{aligned}
 & \int_{t_w-out}^{t_w-in} \frac{c_w}{i_s - i} dt_w \\
 & \approx \frac{c_w \Delta t}{3n} \left\{ \frac{1}{i_1'' - i_2} + \frac{4}{i_{(t_1-\delta t)}'' - (i_2 - \delta i)} + \frac{2}{i_{(t_1-2\delta t)}'' - (i_2 - 2\delta i)} \right. \\
 & \quad + \frac{4}{i_{(t_1-3\delta t)}'' - (i_2 - 3\delta i)} + \dots + \frac{2}{i_{[t_1-(n-2)\delta t]}'' - [i_2 - (n-2)\delta i]} \\
 & \quad \left. + \frac{4}{i_{[t_1-(n-1)\delta t]}'' - [i_2 - (n-1)\delta i]} + \frac{1}{i_1'' - i_2} \right\} \quad (2-5)
 \end{aligned}$$

上式中： n 为分段数，下标 1 表示进塔空气，2 表示出塔空气， t 表示水温。

为了方便工程计算，也可以通过经验曲线与图来查询 Merkel 数，美国制冷协会就曾给出了逆流冷却塔的特性曲线，以方便工程师查阅^[30]。

2.2.2. ϵ -NTU 方法

ϵ -NTU 方法又称有效传热单元数方法，是由 Jaber 和 Webb 在 1989 年提出的。 ϵ -NTU 方法将换热器中的传热单元数法运用到逆流和横流冷却塔的热力性能和尺寸计算中。该方法的基本假设和 Merkel 方法相同。

在换热器的设计计算中，将换热器的实际传热量与最大可能传热量之比定义为 ϵ ——效能。换热过程会在有能量差的两个流体中发生。效能 ϵ 是比热容量较小的流体的“进出口温度差”与“冷热流体进口温度差”之比。其反应了换热器里“冷热流体进口温度差”的利用率。^[31]

在冷却塔中，Merkel 方法的能量平衡方程可以用下式表达：

$$\frac{d(i_s - i)}{(i_s - i)} = \beta \left(\frac{di_s}{dt_w} - \frac{1}{m_a} \right) dA \quad (2-6)$$

在这个等式中， m_a 是干空气的质量流量，它和 $\frac{m_w c_w}{di_s/dt_w}$ 决定了空气焓值的变化情况。这两个参数，就相当于换热其中两个流体的比热容量。在 ϵ -NTU 方法中，把 m_a 和 $\frac{m_w c_w}{di_s/dt_w}$ 中较小的流体称为“最小比热容量流体” —— C_{\min} ；较大的流体称为“最大比热容量流体” —— C_{\max} 。

比容率 $C = C_{\min} / C_{\max}$ ，则冷却塔的效能：

$$\varepsilon = \frac{Q}{Q_{\max}} = \frac{m_w c_w (t_{w-in} - t_{w-out})}{C_{\min} (i_{s-in} - i_{in})} \quad (2-7)$$

1961 年，Berman^[32]提出了饱和空气的焓 i_s 和冷却水温 t_w 的修正系数：

$$f = (i_{s-out} + i_{s-in} - 2i_{s-mean}) / 4 \quad (2-8)$$

上式中， i_{s-out} 表示出塔空气温度下饱和空气焓值， i_{s-in} 表示进塔空气温度下饱和空气的焓值， i_{s-mean} 表示进出塔空气平均温度下饱和空气的焓值。

Jaber 和 Webb 将这个修正系数 f 引入了 ε -NTU 方法，得：

$$\varepsilon = \frac{Q}{Q_{\max}} = \frac{m_w c_w (t_{w-in} - t_{w-out})}{C_{\min} (i_{s-in} - i_{in} - f)} \quad (2-9)$$

冷却塔的传热单元数：

$$NTU = \frac{1}{1 - C} \ln \frac{1 - \varepsilon C}{1 - \varepsilon} \quad (2-10)$$

最终由传热单元数所表示的 Merkel 数可以被表述为：

$$\begin{cases} Me_{\varepsilon} = \frac{c_w}{di_s/dt_w} NTU, & \text{当 } m_a > \frac{m_w c_w}{di_s/dt_w} \\ Me_{\varepsilon} = \frac{m_a NTU}{m_w}, & \text{当 } m_a < \frac{m_w c_w}{di_s/dt_w} \end{cases}$$

ε -NTU 方法是求解 Merkel 数的一种数值计算方法，它将冷却塔填料分成等大小的单元，可以有效地提升 Merkel 数的计算速度和计算准确度。

2.2.3. Poppe 方法

Poppe 和 Rögner 在上世纪 70 年代提出了 Poppe 方法，这种热力计算方法没有采用 Merkel 方法的简化假设，其将冷却水在蒸发过程中的散失量纳入到了热力计算过程中，并且 Lewis 关系数也不再是一个等于 1 的常量，而是一个与空气含湿量有关的变量。

由于 Poppe 方法考虑了冷却水的蒸发散失量，那么冷却水侧的水分蒸发量就应该等于空气侧的水蒸气的增量：

$$dm_w = m_a dw \quad (2-11)$$

上式中：

dm_w ——冷却水的质量变化量，即水分蒸发量

dw ——空气含湿量的增量

m_a ——干空气质量

填料间的热量平衡关系式如下：

$$m_a di = m_w di_w + i_w dm_w = dQ \quad (2-12)$$

上式中：

i ——湿空气的焓

i_w ——水的焓 $i_w = c_w t_w$

Q ——换热量

当引入水面散质系数 β 后，可以得到水分蒸发量、空气含湿量和换热面积之间的关系：

$$dm_w = \beta(w_s - w_a)dA \quad (2-13)$$

冷却过程中的散热由潜热和显热两部分组成。潜热散热是由于水表面饱和湿空气层和主体湿空气流之间存在水蒸气分压力差，这个过程可用下式描述：

$$dQ_m = \gamma\beta(w_s - w_a)dA \quad (2-14)$$

显热散热是由于水和空气之间存在温差，这个过程可用下式表达

$$dQ_c = \alpha(t_w - t_a)dA \quad (2-15)$$

由于湿空气的焓 $i = c_p t_a + \gamma w_a$ ，液体表面饱和空气的焓 $i_s = c_p t_w + \gamma w_s$ ，那么空气和水之间的温差可以用空气焓、定压比热容、含湿量 and 水的汽化潜热表示：

$$t_w - t_a = \frac{(i_s - i) - (w_s - w_a)\gamma}{c_p} \quad (2-16)$$

由式(2-14)、式(2-15)和式(2-16)可知：

$$\begin{aligned} dQ &= dQ_m + dQ_c = \gamma\beta(w_s - w_a)dA + \alpha \left[\frac{(i_s - i) - (w_s - w_a)\gamma}{c_p} \right] dA \\ &= \beta \left[\frac{\alpha}{\beta c_p} (i_s - i) + \left(1 - \frac{\alpha}{\beta c_p} \right) \gamma (w_s - w_a) \right] dA \end{aligned} \quad (2-17)$$

式(2-17)中的 $\frac{\alpha}{\beta c_p}$ 就是Lewis关系数。Bosnjakovic^[33]在研究蒸发冷却系统时得到了一个Lewis关系数和含湿量的经验关系式：

$$\text{Lewis}_f = 0.865^{0.667} \left(\frac{w_s + 0.622}{w_a + 0.622} - 1 \right) / \left[\ln \left(\frac{w_s + 0.622}{w_a + 0.622} \right) \right] \quad (2-18)$$

由式(2-11)和式(2-13)可得

$$m_a dw = \beta(w_s - w_a)dA \quad (2-19)$$

将式(2-13)和式(2-17)代入式(2-12)，可得：

$$m_w c_w dt_w = \beta dA [Le_f (i_s - i) + (1 - Le_f) \gamma (w_s - w_a) - c_w t_w (w_s - w_a)] \quad (2-20)$$

由式(2-19)和式(2-20)，Poppe 推导出了蒸发参数如下：

$$\left\{ \begin{aligned} & Me_p = \int_{t_w-out}^{t_w-in} \frac{m_a}{m_w} \frac{dw/dt_w}{w_s - w_a} dt_w \\ & Me_p = \int_{t_w-out}^{t_w-in} \frac{c_w}{Le_f(i_s - i) + (1 - Le_f)\gamma(w_s - w_a) - c_w t_w(w_s - w_a)} dt_w \end{aligned} \right.$$

Poppe 方法严格按照蒸发冷却过程中的热质平衡关系推导得出了蒸发参数，其考虑了 Lewis 关系数的可变性和蒸发水量，是对于 Merkel 方法的扩充。

2.2.4. 三种方法的对比

通过 Merkel 方法计算得到的 Merkel 数表征了蒸发冷却过程是以焓差为驱动力的， ϵ -NTU 方法利用了 Merkel 方法的简化假设，引入了有效传热单元数求解 Merkel 数。而 Poppe 方法是从蒸发冷却过程的物理模型出发，推导出了更准确的 Merkel 数。

表 2-1 三种方法推导过程对比

	Merkel 方法	ϵ -NTU 方法	Poppe 方法
质量平衡		忽略水蒸发损失 $m_{w-in} = m_{w-out}$	水蒸发损失量等于空气中水蒸气的增量 $dm_w = m_a dw$
能量平衡	$m_a di = m_w di_w = dQ$	$\frac{d(i_s - i)}{(i_s - i)} = \beta \left(\frac{di_s}{dt_w} - \frac{1}{m_a} \right) dA$	$m_a di = m_w di_w + i_w dm_w = dQ$
散热量	$dQ = \alpha(t_w - t_a)dA + \beta\gamma(w_s - w_a)dA$		
Lewis 关系数	$Lewis_r = \frac{\alpha}{\beta c_p} = 1$	$Lewis_r = \frac{\alpha}{\beta c_p} = 1$	$Lewis_r = \frac{\alpha}{\beta c_p} = f(w_s, w_a)$
Merkel 数	$Me_M = \int_{t_w-out}^{t_w-in} \frac{c_w}{i_s - i} dt_w$	$\begin{cases} Me_\epsilon = \frac{c_w}{di_s/dt_w} NTU, & \text{当 } m_a > \frac{m_w c_w}{di_s/dt_w} \\ Me_\epsilon = \frac{m_a NTU}{m_w}, & \text{当 } m_a < \frac{m_w c_w}{di_s/dt_w} \end{cases}$	$Me_p = \int_{t_w-out}^{t_w-in} \frac{m_a}{m_w} \frac{dw/dt_w}{w_s - w_a} dt_w$

表 2-1 对比了Merkel、 ϵ -NTU和Poppe方法推导Merkel数的方法。Merkel方法较为简单，若计算时，使用适当的水蒸发系数，就可以准确地预测出塔水温。然而受到简化假设的限制，Merkel方法在预测出塔空气的物理性质和由蒸发引起的水量变化时不够准确。 ϵ -NTU方法的计算结果与Merkel方法的计算结果几乎是一样的^[34]，因为它们的简化假设是相同的。相对而言，Poppe方法的计算结果更为准确，因为它更好地还原了蒸发冷却过程，如果预先能获得足够多的冷却塔运行实测数据，那么在随后预测蒸发水量和出塔空气中的水分时，Poppe方法的

准确性较高。但Poppe方法在分析处于温暖、干燥环境中的自然通风冷却塔时，预测的出塔水温较真实值偏低。^[35]通过Merkel方法和 ε -NTU方法预测得到的冷却塔散热量低于Poppe方法的预测值。这三种方法对于出塔水温的预测结果非常接近。相对而言， ε -NTU方法的计算过程最简单，Poppe方法最繁琐。如果工程师只需要预测出塔水温的话，那么使用Merkel方法和 ε -NTU方法已经足够了。无论使用哪种方法进行预测，都要保证测试阶段和预测阶段所用是同一个方法^[8]。

2.2.5. 常用建筑仿真模拟软件中的冷却塔模型

● DOE-2^[36]

DOE-2 是建筑能耗模拟的计算引擎，它由美国劳伦斯·伯克利国家实验室（Lawrence Berkeley National Laboratory, LBNL）开发，是目前世界上使用最多的能耗模拟软件之一。1999年，软件开发停止，DOE2.1E是最后的官方版本。

在DOE-2.1的计算引擎中，可以模拟1)抽风式横流塔，2)抽风式逆流塔，3)鼓风式横流塔和4)鼓风式逆流塔。抽风式与鼓风式的区别在于，前者风机位于空气出口侧，后者风机位于空气进口侧。描述和计算冷却塔的运行过程和性能有以下几个关键变量：

T_{out} : 出塔水温；

T_{in} : 进塔水温；

T_{wb} : 空气湿球温度；

Approach: 冷幅，出塔水温与空气湿球温度之差；

Range: 进出塔水温差

90-80-70: 冷却塔运行的标准工况。即进塔水温 90°F(32.2°C)，出塔水温 80°F(26.7°C)，湿球温度 70°F(21.1°C)。

Tower Unit(TU): 冷却塔系数，表征在 90-80-70 的标准工况下，利用冷却塔冷却 1gpm 水所需要的冷却面积。

Ar: 相对面积，表征以 TU 为计量单位的冷却塔冷却能力。Ar 数只与冷却塔的设计信息有关。

Fr: 关系数，是 Ar 与冷却水流量之比—— $Fr = \frac{Ar}{gpm}$ 。如果冷却水流量为设计流量，则 $Fr=1$ 。如果冷却塔的风机转速可调，则 $Fr = \left[\frac{M_a}{M_{a-design}}\right]^P \times \frac{Ar}{gpm}$ ，

$P \in [0.6, 1.1]$, P 的默认值是 0.9。这是一个半经验公式, 当实际风量与设计风量偏差不大时, 公式较准确。

根据经验数据, 可以得到是湿球温度为 60°F (15.5°C), 70°F (21.1°C) 和 80°F (26.7°C) 的 Fr 数, Range 数和 Approach 数的综合曲线。这些曲线是 DOE-2.1 计算冷却塔性能的基础。

DOE2.1 模拟的是冷却塔的能耗, 它并没有将模拟重点放在蒸发冷却过程上, 只是通过分析冷却负荷、天气参数和控制方式, 完成冷却塔的能耗计算和出塔水温预测。软件有以下两点的局限性:

- 1) 出塔水温是冷水机组中的一个重要参数, 软件可以根据预测的出塔水温调整冷机的设计参数, 并计算非额定工况下的系统能耗。这里存在一个交叉关系: 当模拟冷却塔是, 需要知道冷机的排热量。但在模拟冷机时, 需要知道冷却水的出塔水温。解决这个问题的最准确的方法就是进行迭代计算, 直到排热量和出塔水温收敛。只有当湿球温度变化得很慢, 并且冷机对于冷却水温的变化不敏感时, 迭代计算次数才较少。实际上, DOE-2.1 运用的是另一种方法: 模拟冷机时所用的冷却水温是前一个计算时刻的结果, 如果冷却塔在前一个计算时刻未启用, 那么算法会调用冷却塔的子程序去估算冷却水温。这个算法也有足够的精确度, 而且计算速度很快, 这也是 DOE-2.1 未使用迭代算法的原因。
- 2) 55°F (12.7°C) 的湿球温度是计算极限。当湿球温度低于 55°F (12.7°C) 时, 冷却塔的程序会停止运算。如果实际的湿球温度低于 55°F (12.7°C), 那么程序会将湿球温度修正到 55°F (12.7°C), 并进行下一步的计算。如果模拟冷却塔的过滤循环时, 最低的湿球温度是 30°F (-1°C)。

● TRNSYS

TRNSYS (Transient Systems Simulation) 是一款瞬态系统仿真软件, 它由美国 Wisconsin, Madison 大学的太阳能实验室开发, 并在德国太阳能研究中心 (TRANSSOLAR)、法国建筑技术与科学中心 (CSTB) 等研究所的共同努力下逐步完善。^[37] 软件在进行系统仿真时会将系统中各个部件拆分成一个个小组件 (Type), 这样的模块化结构, 可以实现部件与部件之间的灵活连接, 方便建模仿真。

在各个组件中, 模拟冷却塔的组件是 Type51。这个组件可以模拟由多台风机

单元和集水盘所组成的逆流或横流冷却塔系统。整个冷却塔模型的数学描述如下[38]：

● 冷却塔的散热量：

$$Q_{\text{cell}} = \varepsilon_a \dot{m}_a (i_{a,w,\text{in}} - i_{a,\text{in}}) \quad (2-21)$$

上式中， ε_a 表示空气侧散热效率， \dot{m}_a 表示干空气的质量流量， $i_{a,w,\text{in}}$ 表示进塔水温所对应的空气焓值， $i_{a,\text{in}}$ 表示进塔空气焓值。

$\dot{m}_a (i_{a,w,\text{in}} - i_{a,\text{in}})$ 表示整个冷却塔内空气焓值的最大变化范围，即最大散热量。而 ε_a 就是空气侧实际散热量与最大散热量之间的比值。与 ε -NTU方法相似，Braun^[11]在推导 ε_a 时也用了传热单元数的概念，并对其进行了修正：

$$\text{逆流冷却塔: } \varepsilon_a = \frac{1 - \exp[-\text{NTU}(1 - m^*)]}{1 - m^* \exp[-\text{NTU}(1 - m^*)]} \quad (2-22)$$

$$\text{横流冷却塔: } \varepsilon_a = \frac{1 - \exp\{-m^*[1 - \exp(-\text{NTU})]\}}{m^*} \quad (2-23)$$

$$\text{NTU} = \frac{\beta A_v V_{\text{cell}}}{\dot{m}_a} \quad (2-24)$$

上式中， β 表示散质系数， A_v 表示每台冷却塔内水滴的表面积， V_{cell} 表示每台冷却塔的换热体积。

$$m^* = \frac{\dot{m}_a C_s}{\dot{m}_{w,i} C_{pw}} \quad (2-25)$$

上式中， C_{pw} 表示水的定压比热容。 C_s 是饱和比热，它的表达式如下：

$$C_s = \frac{i_{s,w,\text{in}} - i_{s,w,\text{out}}}{t_{w,\text{in}} - t_{w,\text{out}}} \quad (2-26)$$

上式中， $i_{s,w,\text{in}}$ 和 $i_{s,w,\text{out}}$ 分别表示进塔水温和出塔水温下饱和空气的焓值； $t_{w,\text{in}}$ 和 $t_{w,\text{out}}$ 分别表示进塔水温和出塔水温。

● 冷却塔运行性能

为了确定冷却塔的运行效率就需要算出传热单元数——NTU。软件根据ASHRAE Equipment Guide^[39]将NTU与空气和水的质量流量联系起来：

$$\text{NTU} = c \left(\frac{\dot{m}_w}{\dot{m}_a} \right)^{1+n} \quad (2-27)$$

上式中有两个系数，其中指数上的 n 一般取-0.35~0.1.1，比例系数 c 一般取0.5~5。这两个系数是软件模拟冷却塔的关键，要确定一台冷却塔的运行特性，就首先要确定这两个系数。软件也采用了一些Simpson和Sherwood^[40]所得出的不

同冷却塔的设计数据，方便用户建模。

● 出塔水温

有了上述计算公式，流出冷却塔的冷却水温度可以由下式表达：

$$t_{w,out} = \frac{\dot{m}_{w,i}C_{pw}t_{w,in} - Q_{cell}}{\dot{m}_{w,out}C_{pw}} \quad (2-28)$$

上式中， $\dot{m}_{w,in}$ 是进塔冷却水的质量流量， $\dot{m}_{w,out}$ 是出塔冷却水的质量流量。

综上所述, TRNSYS 描述冷却塔热力性能的数学表达式是由物理模型和实验数据组成的半经验公式。它用 Wisconsin 大学学者 Braun^[11]的研究成果来建立蒸发冷却的物理模型, 该模型使用传热单元数来简化分析过程, 模型假设 Lewis 关系数等于 1, 但其考虑了蒸发水损失对于出塔水温的影响。实际上, 当计算集水盘中的补水量时, 还需要使用到这个水损失量。

2.3. 冷却塔的ANN模型

进入到 21 世纪后, 有些学者开始研究利用 ANN 模型预测冷却塔的运行性能。下表对一些研究成果进行了比较。

表 2-2 文献中的冷却塔 ANN 模型对比

	文献 ^[23]	文献 ^[41]	文献 ^[24]	文献 ^[25]	文献 ^[42]
研究对象	机械通风开式逆流冷却塔	闭式冷却塔	无填料冷却塔	自然通风开式逆流冷却塔	无特定
神经网络	三层 BP 网络	三层 BP 网络	三层 BP 网络	三层 BP 网络	三层 BP 网络
输入节点	1 进塔空气干球温度 2 进塔空气相对湿度 3 进塔水温 4 进塔的空气流量 5 进塔的水流量	1 冷却水流量 2 空气流量 3 喷淋水流量 4 空气湿球温度 5 进塔水温 6 淋水温度	1 淋水系统高度 2 液滴直径 3 淋水初速度 4 空气流速 5 气水质量比 6 进塔空气干球温度 7 进塔空气相对湿度 8 进塔水温	1 进空气干球温度 2 进塔空气湿球温度 3 进塔水温 4 进塔空气速度 5 冷却塔中的循环水流量	1 进塔空气干球温度 2 进塔空气相对湿度 3 进塔水温 4 冷却水流量
隐层节点	5 个	6 个	17 个	6 个	9 个

输出节点	1 冷却塔散热量 2 补水量 3 出塔水温 4 出塔空气干球温度; 5 出空气相对湿度	出塔水温	出塔水温	1 出塔水温 2 进出塔水温差 3 冷却效率=冷却塔进出水温差/(进塔水温-进塔空气的湿球温度)	出塔水温
数据来源	自搭建的实验冷却塔模型	实际运行的冷却塔中的实测数据	厂家所提供的样本数据	自搭建的实验冷却塔模型	自搭建的实验冷却塔模型
出塔水温预测误差	平均相对误差: 0.89%		平均相对误差: 1.13%	平均绝对误差: 0.044℃	最大相对误差: 0.8%

从上表中可以看出，已有的冷却塔 ANN 模型都是三层 BP 神经网络，该模型也是目前使用最广的人工神经网络模型之一。虽然各位学者所研究的冷却塔类型不同，但 ANN 模型所给出的预测结果都较为准确，说明利用 ANN 模型预测冷却塔运行性能是可行的。然而，这些研究在建模和预测过程中所使用的数据大多来自冷却塔模型或厂家所提供的样本，空调系统中，冷却塔的实际运行情况和可能出现的问题是实验无法模拟的，这对于 ANN 建模和数据处理提出了更高的要求。因此，本研究将以实际运行中的冷却塔数据为基础，探讨冷却塔运行性能的在线预测方法。

2.4. 人工神经网络 (ANN) 理论

2.4.1. 人工神经网络的发展史

人工神经网络 (ANN—Artificial Neural Networks) 起源于 20 世纪 40 年代初，它是一门交叉学科，它的灵感来自于生物学中对于人脑和神经系统的认识。人脑是一个复杂的系统，它具有“认知”、“意识”和“感情”功能，可以并行处理大量信息。心理学家 W.S.Mcculloch 和数理逻辑学家 W.Pitts 合作，利用数学模型模拟脑细胞的动作和结构及生物神经元的一些基本生理特性，他们提出了神经元的阈值元件模型 (MP 模型)，这个简单的神经网络模型是由一些节点以及节点与节点之间的相互联系所组成的，是第一个用数理语言描述大脑处理信息过程的模型，开创了神经网络的研究^[43]。1949 年神经生物学家 Hebb 提出了大脑神经细胞在学习条件反射时的学习规则假设，即大脑经常在突触上作微妙的变化，突触联

系强度可变是学习和记忆的基础^[44]。这个假设的正确性在 30 年后得到了证实，因此被称为Hebb学习规则，它对于神经网络的发展有重要的意义。1958 年，F.Rosenblatt^[45]提出的感知器（Perceptron）模型网络是第一个智能型的人工神经网络系统，它具有学习、平行处理、分布式存储等基本的神经网络特性，至今还在广泛应用。1960 年，B.Widrow和M.E.Hoff^[46]提出了一种自适应线性神经元模型和一种有效的网络学习方式，即通常所说的Widrow-Holf学习规则（ δ 学习规则）。1972 年，T.Kohonen^[47]提出了自组织映射网络模型，映射具有拓扑性质，自适应学习效果显著。主要用于模式识别、语言识别、数据分类等方面。1982 年，生物物理学家Hopfield^[48]提出了一种新的神经网络模型，并指出通过微电子器件可以实现这个模型，人们称之为Hopfield神经网络，它的出现为神经计算机的研制奠定了基础，开创了神经网络用于联想记忆和优化计算的新途径。1986 年至 1988 年D.E.Rumelhart和J.L.McClelland^[49]将神经网络模型的特性归结为三点——结构、神经节点传递函数及学习算法，提出了“并行分布处理（PDP）”。并发展了适用于多层网络学习的误差逆传播算法（BP算法）。BP算法是迄今为止应用最普遍的神经网络学习算法。

时至今日，人工神经网络的发展已经历了半个多世纪，它的特殊功能引起了国防、科研部门和企业界的关注，被广泛应用于多个学科领域。

2.4.2. 人工神经元

从生物学的角度看，神经元是基本的信息处理单元，它由树突、轴突和突触等组成。其中树突是由细胞体向外伸出的分支，一个细胞体上可以有多个较短的分支，它相当于信号的输入端，用于接受神经冲动。轴突是由细胞体向外延伸出的最长的一个分支，即神经纤维，它是信号的输出电缆，它的端部有许多神经末梢，相当于输出端子，用于传输神经活动。神经元之间通过轴突（输出）和树突（输入）相互连接，其接口称为突触。神经突触是调整神经元之间相互作用的基本结构和功能单元。人工神经元是生物神经元的模拟和抽象，相当于一个多输入单输出的非线性阈值器件，图 2-1 是人工神经元模型的示意图。




图 2-1 人工神经元模型

上图中， $X_1, X_2 \dots X_n$ 是输入信号， O 是输出信号， $W_1, W_2 \dots W_n$ 是权值，其表示 n 个突触的连接强度， $\sum W_i X_i$ 是激活值，它表示这个人工神经元的输入综合。 θ 是这个神经元的阈值，若激活值超过 θ ，则该神经元被激活， $f(x)$ 是神经元的激发函数，表示该神经元输入信号与输出信号之间的关系。因此，人工神经元的输出可以用以下公式描述：

$$O = f(\sum W_i X_i - \theta) \tag{2-29}$$

人工神经元的激发函数有许多种类，比较常用的激发函数大致有四种形式：线性型、饱和型、阈值型和 S 型。

● **线性型**

线性型激发函数的输入量与输出量有线性关系，它起到对输入量进行适当线性放大的作用。线性型激发函数的表达式及函数图见表 2-3。

表 2-3 线性型激发函数

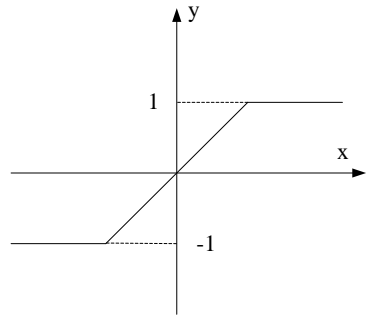
线性型函数	函数表达式	函数图象
线性型激发函数	$f(x) = kx + b$	

● **饱和型**

由于线性函数过于简单，会降低人工神经网络的性能，因此需要引入非线性函数，饱和型函数就是线性函数的一种最简单的变形，它实际是一种分段线性函数。其输出值的范围为 $[-1,1]$ 。饱和型激发函数的表达式及函数图见表 2-4。

表 2-4 饱和型激发函数

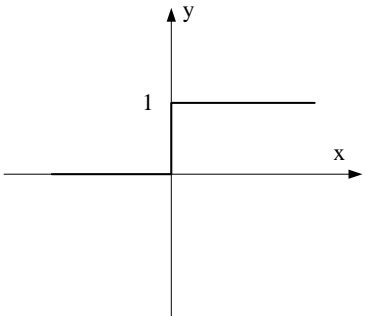
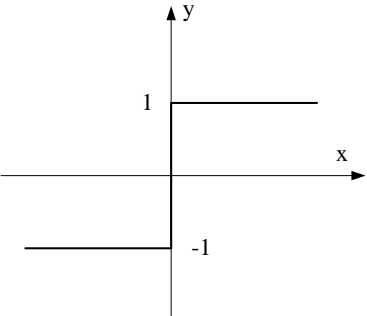
饱和型函数	函数表达式	函数图象
-------	-------	------

饱和型激发函数	$f(x) = \begin{cases} 1, & x \geq \frac{1}{k} \\ kx, & -\frac{1}{k} \leq x < \frac{1}{k} \\ -1, & x < -\frac{1}{k} \end{cases}$	
---------	---	--

● 阈值型

阈值型激发函数是由美国心理学家 McCulloch 和数学家 Pitts 共同提出的，因此也被称为 MP 模型。其输出值为 1、0（或+1、-1）。1 代表神经元处于兴奋状态，0 则表示处于抑制状态，根据此特性阈值型激发函数也被称为阶跃响应函数。阈值型激发函数的表达式及函数图见表 2-5。

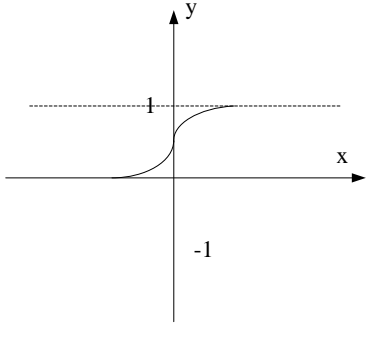
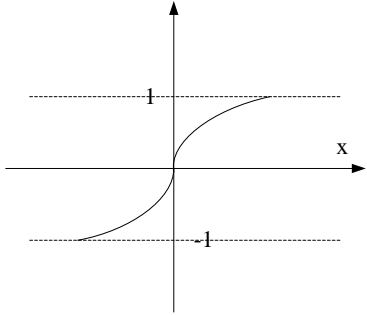
表 2-5 阈值型激发函数

阈值型函数	函数表达式	函数图象
单极型的阈值型激发函数	$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$	
双极型的阈值型激发函数	$f(x) = \text{sgn}(x) = \begin{cases} +1, & x \geq 0 \\ -1, & x < 0 \end{cases}$	

● S型

S 型（Sigmoid 型）激发函数是一个连续函数，它的输出特性比阈值型函数软，它的硬度可由作用于自变量上的系数 λ 来调节， λ 越大，函数越硬，曲线越陡峭。其输出值的范围为[0,1]（或[-1,+1]）。S 型激发函数的表达式及函数图见表 2-6。

表 2-6 S 型激发函数

S 型函数	函数表达式	函数图象
单极型的 S 型激发函数	$f(x) = \frac{1}{1 + e^{-\lambda x}}, f(x) \in [0,1]$	
双极型的 S 型激发函数	$f(x) = \frac{2}{1 + e^{-\lambda x}} - 1, f(x) \in [-1, +1]$	

2.4.3. 人工神经网络

人工神经网络是由人工神经元组成的运算模型。它可以利用大脑神经突触连接的结构进行信息处理。不同的连接方式、权值和激发函数会得到不同的网络输出值，网络自身通常都是对自然界某种算法或者函数的逼近，也可以是对一种逻辑策略的表达。人工神经网络有以下几个特点：

- 1) 可以实现并行分布式的数据处理
- 2) 可以处理非线性问题
- 3) 具有自学习功能
- 4) 具有联系储存功能
- 5) 具有高速寻优的能力

目前已经提出了 60 多种人工神经网络模型，它们可以从以下几个角度进行分类：

- 1) 从网络性能角度，可以分为连续型与离散型网络、确定性与随机性网络。

- 2) 从网络结构角度，可以分为前向网络与反馈网络。
- 3) 从学习方式角度，可以分为有教师学习网络和无教师学习网络。
- 4) 按连接突触性质，可以分为一阶线性关联网络和高阶非线性关联网络。⁵⁰

常用的神经网络模型有以下几种^{[50][51]}：

● 感知器

1956 年，美国学者 F.Rosenblatt^[45]提出了感知器模型，它是一种模仿生物感知机制、用于模式识别的简单神经网络。感知器的激发函数为强限幅激发函数 hardlim（式 2-32）。

$$\text{hardlim}(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (2-30)$$

单层感知器可以将外部输入分为两类。而多层感知器的输入层输出层之间存在非线性关系，可以增强网络的分类能力。感知器的学习规则是有监督训练的学习，网络的权值需要根据实际输出和网络输出之间的绝对误差进行调整。由于感知器激发函数和学习规则的特性，它在使用是有一定的局限性：

- 1) 感知器的输出值是 0 或 1，只能处理简单的分类问题。
- 2) 感知器只能对线性可分的向量集合进行分类。
- 3) 若输入样本中存在奇异样本，且奇异样本与其余样本的偏差较大时，会延长感知器的训练时间。

● BP神经网络

BP 神经网络即误差反向传播神经网络，它是一种多层映射的神经网络，是目前应用最广的一种人工神经网络，常被应用于模式识别、自适应控制、图像处理、语言识别等领域。BP 神经网络的激发函数可以是线性的也可以是非线性的函数。BP 神经网络的学习算法是 LMS 算法的变形，它的实质是求解最小均方误差，并利用该误差调节多层前馈网络的权值。由于网络的结构特性，它在运行时是单向传播的，没有反馈，因此 BP 神经网络实际上是一个静态网络，并且网络对于初设参数的敏感性较强，如果初设参数不合理，会直接影响网络的计算速度和计算准确度。

● Hopfield神经网络

1982 年，美国物理学家 J.Hopfield^[48]提出了一种单层反馈神经网络，被后人称为 Hopfield 神经网络。它是单层对称全反馈网络，网络中的各个神经元彼此都是相互连接的。它的激发函数可以是离散型函数或连续型函数。Hopfield 网络可

以是实现联想记忆功能。它可以用于图像或数据的恢复处理。然而 Hopfield 网络的各个连接权值都是预先设定的,网络的学习过程只能对它进行微小的调整,网络在运行时根据一定规则进行计算并更新网络,以实现网络的稳定。网络的稳定点可能是局部极小点,但这个点不一定是全局最小点。

● 径向基网络

径向基网络是一种三层前向网络,网络的第一层为输入层,其由感知源节点组成。网络的第二层为隐层,第三层为输出层,隐层与输入层由计算节点组成。隐层的激发函数为径向基函数(一般使用高斯函数),输入数据直接映射到隐层,不需要通过权连接,而隐层到输出层之间的映射是线性的。径向基网络具有局部逼近能力,能以任意精度逼近任意一个连续函数。

● 竞争型神经网络

竞争型神经网络是一种以无监督方式进行学习的网络。它有明显的层向连接结构,与 Hopfield 网络相似的是,它可以利用自身的训练过程,自动分类输入模式。一个最简单的竞争型神经网络由两层神经元和一组前向连接权组成。它的学习基本思想是网络竞争层的各神经元通过竞争来获取输入模式的响应机会,兴奋程度最强的一个神经元成为竞争胜利者,与这个神经元有关的连接权被加强,其余神经元的兴奋程度被抑制。这样的学习方式可以有效地进行自适应分类,它可以对外界未知环境进行学习或仿真,并对自身的网络结构进行调整。

2.5. 在线预测

预测是指在已有事件的基础上,寻找事件间的客观规律,并依据这个规律,使用一定方法预先推算未来事件的发展结果。预测包含三个过程——学习、分析、推算。

学习的方法有两种,一种是批量学习,即当事件全部发生后,收集齐全部的数据样本,然后再开始进行数据分析和处理。在实际工程中,事件的发生具有偶然性,往往不能一次性获得所有的事件样本,并且,事件之间的客观规律不一定是一成不变的,它也有可能是实时更新的。此时,批量学习的方法就不再适用,需要使用在线的学习方法。所谓在线学习就是指一边学习一边工作,新发生的事件不断更新学习法则,使学习结果与事件的发展紧密相连。

使用在线学习的方法进行预测就是在线预测方法。方法的基本工作流程如图

2-2。

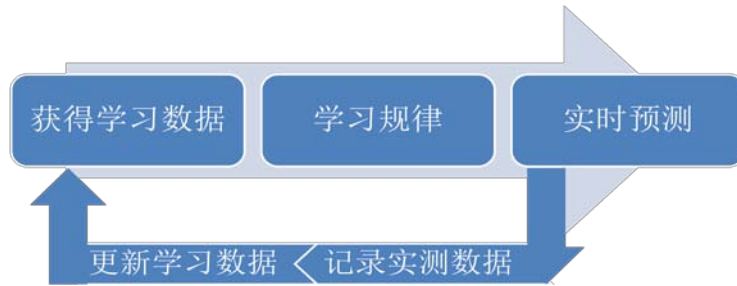


图 2-2 在线预测流程

对于在线预测的学习和预测方法要求有以下几点：

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

人工神经网络的特性符合以上几点要求，可以作为在线预测的核心方法应用于实际工程中。

2.6. 本章小结

本章简要介绍了几种经典的冷却塔热力计算方法和人工神经网络模型。不同的人工神经网络可以解决不同的工程问题。表 2-7 对五个人工神经网络模型进行了对比。

表 2-7 神经网络对比

神经网络	常用激发函数	可解决的问题
感知器	hardlim 函数	分类、识别
BP 神经网络	S 型函数	分类、识别、预测
Hopfield 神经网络	S 型函数或 Sgn 函数	优化、联想记忆
径向基网络	径向基函数	分类、识别、预测
竞争型神经网络	非线性函数	自适应学习或仿真

在这个五个模型中，BP 神经网络和径向基网络都可以解决预测问题。径向基网络虽然可以提高学习速率，但径向基函数一般使用高斯函数，网络最终的输出量并不是单调递增。而 BP 神经网络的激发函数通常为 S 型函数，有单调递增的趋势，适合预测单调变化的问题。诸多学者通过实验研究证明三层 BP 神经网络可以预测冷却塔的运行性能，但他们的实验数据大多是从冷却塔模型上采集的，

无法准确反映实际系统中的冷却塔运行性能。因此，本研究将以 BP 神经网络为基础，并利用实际空调系统中的冷却塔运行数据，探讨如何实现运行性能的在线预测。

第3章. 数据的获得和数据处理

3.1. 数据的获得

本研究的数据是通过现场实测获得。数据的来源是一组实际运行中的冷却塔，下文中称为实验用冷却塔。

实验用冷却塔位于中国深圳，该地区属于我国的夏热冬暖地区，全年供冷需求时间较长。

测试对象所在的冷却水系统中共有四台并联的圆筒形机械通风逆流冷却塔。这四台冷却塔型号相同，它们的基本参数见表 3-1，塔体的结构见图 3-1。

表 3-1 实验冷却塔型号及参数

型号	冷却水量	风机功率	风机风量	塔体高度	塔体全压
MKT-600	600m ³ /h	18.5kW	320500m ³ /h	4310mm	50000Pa




图 3-1 实验用逆流冷却塔结构图

冷却塔和冷却回路的工作状态通过实时监测平台监控并记录数据，整个回路和测点位置见图 3-2。该系统中的四台冷却塔以两台为一组，共同开启或关闭，测点 3、4 分别记录了两组冷却塔的输入总功率。




图 3-2 实验用冷却水回路及测点示意图

实验监测记录从 2011 年 8 月 1 日至 2012 年 4 月 28 日，每隔两分钟记录一次数据，共记录了 56,449 组数据。监测数据类型见表 3-2。

表 3-2 实验用监测数据类型

测点编号	监测信号	信号类型	量程	信号单位	测量仪器
1	进塔水温	温度	0~100	℃	插入式温度传感器
2	冷却水流量	流量	0~500	l/s	超声波流量传感器
3	冷却塔风机功率	功率	0~50	kW	功率电表
4	冷却塔风机功率	功率	0~50	kW	功率电表
5	出塔水温	温度	0~100	℃	插入式温度传感器
6	空气干球温度	温度	0~100	℃	室外温湿度传感器
7	空气湿球温度	温度	0~100	℃	室外温湿度传感器

3.2. 数据处理

3.2.1. 风机风量

● 风机工作时的风量

机械通风冷却塔中的风机为轴流风机。工程中，关于冷却塔轴流风机的空气动力计算实际是一个逆向工程问题，即在已知流量、压力的情况下，确定风机的直径、轮毂比、工作转速和叶片形状。轴流风机的动力特性中有几个关键的参数：

[52]

通过风机叶轮前后的空气的静压升为：

$$P_{S_2} - P_{S_1} = \frac{1}{2} \rho V_a^2 (K_{th} - K_R + \epsilon_p^2 - \epsilon_s^2) \quad (3-1)$$

上式中：

P_{S_1} ——叶轮之前的空气静压；

P_{S_2} ——叶轮之后的空气静压；

ρ ——空气密度，由于轴流风机的压力较低、变化较小，可以认为空气的密度保持不变；

V_a ——空气通过叶轮的轴向速度；

ϵ_p 、 ϵ_s ——叶轮前、后的气流旋流系数；

K_{th} ——理论全压系数；

K_R ——叶轮压力损失系数。

风机出口截面和进口截面上的全压差：

$$P_T = (P_{S_2} - P_{S_1}) + \frac{1}{2}\rho(V_2^2 - V_1^2) \quad (3-2)$$

上式中：

V_1 、 V_2 ——风机进、出口气流平均速度。

风机流量：

$$Q = V_a \cdot A \quad (3-3)$$

上式中：

A ——风机叶轮处的面积。

轴流风机的有用功率为：

$$N_e = P_T \cdot Q \quad (3-4)$$

将式(3-1)，式(3-2)和式(3-3)代入式(3-4)，可得：

$$N_e = \left[\frac{1}{2}\rho V_a^2 (K_{th} - K_R + \epsilon_p^2 - \epsilon_s^2) + \frac{1}{2}\rho (V_2^2 - V_1^2) \right] \cdot V_a \cdot A \quad (3-5)$$

由此可见，轴流风机的功率可以近似为气流轴向速度的三次方的正比例函数。推导得冷却塔的风量与电机功率之间的关系如下：

$$Q = k \cdot \sqrt[3]{N} \quad (3-6)$$

上式中， N 为功率， Q 为风量。由表 3-1 可知，实验用冷却塔的额定功率为

18.5kW，额定风量为 320500m³/h，即 89m³/s，则比例系数 $k=33.66\text{m}^3/(\text{s}\cdot\text{kW}^{1/3})$ 。

● 风机停转时的风量

在工程实例中，一组冷却塔可以由多台风机单元组成，一个冷却水系统中也可以包含多组冷却塔。暖通的设计标准中要求多台冷却塔并联运行，且未设置积水箱时，宜在冷却塔的进出水管上设置电动阀，电动阀宜与冷却水泵联动。^[53]然而，设计规范中并没有出现关于电动阀是否与冷却塔的风机联动的要求。以本研究的实验对象为例，它们的冷却塔进水阀和出水阀并未与风机联动。冷却水系统运行时，阀门处于常开状态。因此，在冷却塔风机关闭期间，塔内冷却水仍存在自然冷却的过程。对整体冷却水系统的热力性能进行分析时需要考虑自然冷却过程的热力性能，所以要确定风机停转且塔内淋水时的风量。

与自然通风冷却塔类似，风机关停时，塔内空气的流动是由空气的密度差所产生的抽力驱动的。进塔空气温度较低，密度较大，而出塔空气的温度较高，密度较小。一般而言，塔内空气的平均密度 $\rho_m = 0.98\rho_1$ ， ρ_1 为进塔空气密度^[28]。以此推算出塔空气密度 $\rho_2 = 0.96\rho_1$ 。描述塔内抽力的方程如下：

$$\Delta P' = H \cdot g(\rho_2 - \rho_1) \quad (\text{Pa}) \quad (3-7)$$

上式中 g 为重力加速度，9.8N/kg。

描述冷却塔阻力的方程如下：

$$\Delta P = \xi\rho_m \frac{V_m^2}{2} \quad (\text{Pa}) \quad (3-8)$$

$$V_m = \frac{Q}{A_m} \quad (\text{m/s}) \quad (3-9)$$

冷却塔的阻力与流速和塔内各部分的局部阻力系数有关，这个阻力实际是冷却塔的全压。冷却塔的样本中给出了额定冷却塔的风量和全压值，由此就可以估算出冷却塔的综合阻力系数。即：

$$\xi\rho_m = \frac{A_m^2 \Delta P}{Q_e^2} \quad (3-10)$$

上式中 Q_e 为额定风量 (m³/s)； ΔP 为设计全压 (Pa)。

由式(3-7)和式(3-10)可得：

$$Q = Q_e \cdot \sqrt{\frac{0.04H \cdot g \cdot \rho_1}{\Delta P}} \quad (\text{m}^3/\text{s}) \quad (3-11)$$

实验用冷却塔的额定风量为 320500m³/h，即 89m³/s，设计全压为 50,000Pa，塔高为 4.31m，则风机关停时冷却塔的风量为 0.56m³/s。

3.2.2. 有效数据的判别

实验使用的相关仪表和自动传感器在信号采集和传递的过程中难免会产生粗大误差,粗大误差的存在会歪曲测量结果,监测数据无效。为了剔除无效数据,可以根据蒸发冷却过程的物理意义判断各个冷却塔运行性能数据的有效范围。判断的依据有以下几条:

- 1) 剔除温度测量错误数据:进塔水温、出塔水温、干球温度、湿球温度的测量值应当在 $0\sim 50^{\circ}\text{C}$ 的范围内,剔除该范围以外的数据对。
- 2) 剔除冷却水系统停止运行时的监测数据:冷却水流量和风机运行总功率应当大于 0.01,剔除该范围以外的数据对。
- 3) 剔除不符合蒸发冷却过程的数据:冷却塔的冷幅 (Approach) 和进出塔的冷却水温差 (Range) 应当大于 0°C ,剔除该范围以外的数据对。

经过这三轮数据剔除后,实验用冷却塔的 56,449 组实测数据中共有 45,923 组有效数据。

3.2.3. 数据平滑

对实测数据进行数据平滑处理的原因有两个,其一是实验使用的相关仪表和自动传感器在信号采集和传递的过程中难免会产生随机误差,这种误差的大小和符号变化无规律,无法预测。其二是,冷却塔在运行期间会出现工况变化的情况,在工况变动期间,实测数据会出现无规律的波动,这样的波动与冷却塔的稳态性能无关。如果直接使用实测数据进行建模,那么会降低模型的稳定性,导致预测结果出现较大的偏差。因此,在建模分析前,需要先用数据平滑的方法处理原始数据。

常用于抑制小幅度高频噪声的平滑算法有滑动算术平均法和滑动加权平均法等^[54]:

算术平均算法即以 N 次连续采样值的算术平均值作为本次测量采样值。这个算法的平滑效果主要取决于采样次数 N , N 越大,平滑效果越好,但系统的灵敏度会下降,因此,这种方法只适用于缓慢变化的信号。

加权平均算法即对 N 次连续采样值以权重区分，通常越接近当前时刻的数据的权重越大，以此来提高系统对最新一次采样值的灵敏度。

移动窗口即把 N 次连续采样值看成一个窗口，N 就是窗口的固定长度，每进行一次新的采样后，把最新采样数据放入队尾，同时剔除原来队首的一个数据，这样在窗口中始终有 N 个最新的数据。把移动窗口和算术平均算法、加权平均算法结合后就可以得到滑动算术平均法和滑动加权平均法。

本文使用采用滑动加权平均算法处理原始数据，算法的加权平滑公式如下：

$$n = 0.16 \times n_{15} + 0.12 \times (n_{14} + n_{13}) + 0.08 \times (n_{12} + n_{11} + n_{10} + n_9) + 0.05 \times (n_8 + n_7 + n_6 + n_5) + 0.02 \times (n_4 + n_3 + n_2 + n_1) \quad (3-12)$$

实验数据平滑处理后的结果见图 3-3、图 3-4 和图 3-5。




图 3-3 出塔水温、进塔水温和湿球温度的平滑处理结果(°C)




图 3-4 冷却水流量的平滑处理结果(l/s)




图 3-5 风机功率的平滑处理结果(kW)

3.3. 误差控制

所有的模拟数据或计算数据和真实测量值之间都会存在一定的差异,这个差异就是误差。误差的存在具有普遍性和必然性,通过对于误差的分析和研究可以判断数据的计算方法的有效性和计算结果的准确性。

误差不可能完全消除,只能尽可能地控制在可接受的范围内。因此,在进行研究前需要确定可接受的误差类型和范围。

一般而言,误差可以分为四类:偶然误差、系统误差、粗大误差和函数误差 [55]。

偶然误差大小、方向和出现频率没有规律,但偶然误差总体满足统计学上正态分布的规律。即正负误差出现的次数相等;绝对值小的误差比绝对值大的误差出现次数多;误差的绝对值是有界的;随着测量次数的增多,误差的算术平均值趋向于零。

系统误差是由固定不变或按确定规律变化的因素所造成的。这样的误差有一定的规律型,比如固定不变、线性增加或周期性变化,会直接影响测量结果的准确性。

粗大误差是由主客观因素所引发的测量错误,通常误差数值较大,不符合逻辑,明显歪曲了测量结果。

函数误差出现在直接测量量和间接测量量的函数转换过程中,具有一定的函数规律性,一般可以通过修正来消除。

在验证一个模拟或预测算法时,应当保证算法的计算结果和真实值之间只存在偶然误差,即误差分布基本满足正态分布的规律。而偶然误差的大小决定了预测精度。

为了衡量模型计算结果的准确性,需要计算模拟值和实测值之间的误差。

其中绝对误差的计算公式为:

$$\text{绝对误差} = \text{模拟值} - \text{实测值} (\text{°C}) \quad (3-13)$$

相对误差的计算公式为:

$$\text{相对误差} = \frac{\text{绝对误差}}{\text{实测值}} \times 100\% \quad (3-14)$$

在概率统计中,还会用到标准差来统计数据的分布程度,它能反映个体间的

离散程度。误差标准差的计算公式为：

$$\text{误差标准差} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\text{单次预测误差} - \overline{\text{误差平均值}})^2} \quad (3-15)$$

在判断预测准确性时，还可以使用一个检验统计量——相关系数，它的计算公式为：

$$R = \frac{\sum_{i=1}^N (\overline{\text{实测值}} - \overline{\text{实测值}})(\overline{\text{预测值}} - \overline{\text{预测值}})}{\sqrt{\sum_{i=1}^N (\overline{\text{实测值}} - \overline{\text{实测值}})^2 \sum_{i=1}^N (\overline{\text{预测值}} - \overline{\text{预测值}})^2}} \quad (3-16)$$

相关系数越接近于 1，那么说明两个观测值之间的线性联系越紧密，预测的准确性越高。

在集中式空调系统中，冷却塔和冷却水回路通常是冷水机组散热服务的。流出冷却塔的冷却水会被送入冷水机组的冷凝侧，被用于冷却制冷剂。在蒸汽压缩式制冷过程中，冷凝温度会直接影响机组的运行性能。当蒸发温度不变时，冷凝温度增加，制冷系数减小，机组能耗增大。据测算，冷凝温度每增加 1℃，单位制冷量所对应的能耗增加约 3%~4%。而冷凝温度又与进入机组的冷却水流量和温度有关，文献^[56]通过模拟证明，当冷冻水出塔水温、冷冻水流量、冷却水流量恒定时，冷水机组的运行效率会随冷却水温度的升高而降低，如果冷却水温度比所要求的温度偏高 1℃，那么冷水机组的 COP 降低约 3~4%^[57]。

国家标准《冷水机组能效限定值及能源效率等级》GB19577-2004 中，给出了水冷式冷水机组能源效率等级（表 3-3）。

表 3-3 冷水机组能源效率等级^[58]

类型	额定制冷量 (CC) kW	能效等级 (COP) W/W				
		1	2	3	4	5
水冷式	CC ≤ 528	5.00	4.70	4.40	4.10	3.80
	528 < CC ≤ 1163	5.50	5.10	4.70	4.30	4.00
	1163 < CC	6.10	5.60	5.10	4.60	4.20

从上表中可见，COP 每降低 0.3~0.5，就有可能降低一个能效等级。如果冷却水温度的预测误差对于冷机 COP 的影响超过了一个能效等级，那么认为这个误差是不可接受的。0.3~0.5 的变化区间，相当于 COP 降低 6~8%，因此，在稳态运行的系统中，对冷却水温的预测误差不宜超过 ±1℃。若系统发生机组启停等突变工况，预测结果需要能够反映工况突变对出塔水温变化趋势的影响，工况突变点的预测误差不宜超过 ±5℃。

第4章. 基于ANN的机械通风开式冷却塔模型

4.1. 模型的输入输出参数

4.1.1. 影响和表征机械通风开式冷却塔冷却能力的参数

在风机的作用下,空气被吸入冷却塔内,和填料上的水滴和水膜进行热交换。图 4-1 给出了开式冷却塔内水和空气温度变化的示意图。图中,冷却水进入冷却塔时处于 A 状态点,温度较高,出冷却塔时处于 B 状态点。A, B 状态点所表示的温度差就是进出塔的冷却水温差 (Range)。这个温差与冷却塔本身的结构性能和空气状态有关,温差越大冷却效果越好。图 4-1 中另一条曲线描述的空气温度的变化,即从进塔时的 a 点温度上升到了出塔时的 b 点温度。B 点水温和 a 点的湿球温度差,即出塔水温和进塔空气的湿球温度差被称为冷幅 (Approach)。冷幅越小,说明冷却塔内的冷却过程越充分。由水冷却原理可知,进塔空气的湿球温度是水冷却的极限,因此这个湿球温度是决定冷却效果的关键参数。

冷幅是表征冷却塔运行性能的一个重要参数,由于湿球温度是由气象条件所决定的,那么间接地可以认为出塔水温是表征冷却塔运行性能的主要参数。而出塔水温也是影响空调系统运行性能的一个关键因素。在空调系统中,负荷侧的降温排热工作由冷冻水负责。随后,冷冻水在冷水机组的作用下,将废热传递给冷却水。最后,再由冷却水将废热排到大气中。流进冷却塔的冷却水温实际是由冷水机组的制冷负荷决定的,而出塔水温却影响着冷水机组下一步的运行性能。




图 4-1 开式冷却塔内水和空气的温度变化

综上所述，开式冷却塔中，表征冷却塔热力性能的主要参数是出塔水温，影响出塔水温的因素可以分为以下五个：

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，空气量越大则出塔水温越低；

在其余条件恒定的情况下，冷却水量越大则出塔水温越高。

由此可见，冷却塔的出塔水温的变化过程是单调的递增或递减的，在多个参数综合作用下，仍有可能保持单调的趋势。因此在本研究中，使用以单调函数为激发函数的 BP 网络来实现冷却塔的运行性能在线预测。

如果以出塔水温作为预测值，各影响因素为 ANN 模型的输入参数，则这五组参数中，有四组为温度参数，两组为流量参数。为了简化 ANN 模型的参数种类，需要引入一个无量纲因子——水气质量比，以代替空气流量和水流量。这个水气质量比 (F) 的表达式如下：

$$F = \frac{\text{冷却水质量流量}}{\text{空气质量流量}} \quad (4-1)$$

4.1.2. 相关性检验

在开始建模前，利用 SPSS 软件对进塔水温、干球温度、湿球温度、气水质量比与出塔水温之间的相关性进行了分析。

相关性分析是衡量两个变量因素的相关密切程度的方法。当两个变量被判定相关后，则变量 A 的变化就对变量 B 的变化有影响，相关性越大，影响程度越深。

本次检验共提出了四种假设：

1) 进塔水温与出塔水温无关

2) 干球温度与出塔水温无关

3) 湿球温度与出塔水温无关

4) 水气质量比与出塔水温无关

检验的显著性水平为 0.1，如果假设的相关系数小于 0.1，则认为假设成立，两个变量无关；反之若相关系数大于 0.1，则认为假设不成立，两个变量相关，且相关系数越接近 1，两者的相关性越强。

相关系数的计算有三种方式：

Pearson 相关系数：适用于定距连续变量

Spearman 相关系数和 Kendall 相关系数：秩相关检验，适用于定序变量或不满足正态分布假设的等间隔数据。

本次检验选用 Pearson 相关系数，当对 5000 组实测数据进行分析后，四种假设的检验结果如下表：

表 4-1 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	--

由上表可知，假设 2 不成立，其余 3 个假设都成立，即进塔水温、湿球温度和水气质量比都与出塔水温相关，其中进塔水温的相关性最大，湿球温度的相关性最小。

经过相关性检验后，最终确定，ANN 模型的输入参数为 3 组：进塔水温、湿球温度和水气质量比。输出参数为 1 组：出塔水温。

4.2. BP神经网络

BP 神经网络一种典型的分层型前向网络，网络由输入层、隐层和输出层组成，层与层之间的连接方式为全连接，同一层的各神经元之间无相互连接。图 4-2 是一个典型的三层 BP 神经网络结构，由图可见，BP 神经网络与多层感知器类似，但两者之间也存在显著的区别，即 BP 神经网络中每一层的权值都可以通过学习来调整。这个区别也就是 BP 神经网络的计算核心——误差反向传播校正方

法。




图 4-2 三层 BP 神经网络结构图

4.2.1. BP神经网络的基本结构与学习算法

BP 神经网络的激发函数一般采用 S 型函数，网络利用误差的负梯度来调整各个连接权，这样的学习规则被称为 Delta 学习规则，它的描述如下：

在图 4-2 所示的三层 BP 神经网络中，输入层共有 n 个神经元，隐层共有 P 个神经元，输出层共有 q 个神经元，共有 k 组训练数据集。

$$\text{输入向量 } I_k = [i_1^k, i_2^k, \dots, i_n^k];$$

$$\text{期望输出向量 } T_k = [t_1^k, t_2^k, \dots, t_q^k];$$

$$\text{隐层的激发向量 } H_k = [h_1^k, h_2^k, \dots, h_p^k];$$

$$\text{隐层的输出向量 } HO_k = [ho_1^k, ho_2^k, \dots, ho_p^k];$$

$$\text{输出层的激发向量 } OI_k = [oi_1^k, oi_2^k, \dots, oi_q^k];$$

$$\text{输出向量 } O_k = [o_1^k, o_2^k, \dots, o_q^k];$$

输入层和隐层之间的连接权 W_{ih} ;

隐层和输出层之间的连接权 V_{ho} ;

隐层各神经元的阈值 θ_h ;

输出层各神经元的阈值 γ_o ;

期望输出与实际输出之间的误差 $\delta_o^k = (t_o^k - o_o^k)$;

误差的平方和 $E_k = \sum_{o=1}^q (\delta_o^k)^2 / 2 = \sum_{o=1}^q (t_o^k - o_o^k)^2 / 2$;

连接权 V_{ho} 的调整量 $\Delta V_{ho} = -\alpha \cdot \frac{\partial E_k}{\partial V_{ho}} = -\alpha \cdot \frac{\partial E_k}{\partial o_o^k} \cdot \frac{\partial o_o^k}{\partial V_{ho}}$;

$$\frac{\partial E_k}{\partial o_o^k} = -\delta_o^k$$

$$\frac{\partial o_o^k}{\partial V_{ho}} = o_o^k (1 - o_o^k) \cdot ho_h^k$$

则 $\Delta V_{ho} = \alpha \cdot \delta_o^k \cdot o_o^k (1 - o_o^k) \cdot ho_h^k$;

连接权 W_{ih} 的调整量 $\Delta W_{ih} = -\beta \frac{\partial E_k}{\partial W_{ih}}$;

$$\frac{\partial E_k}{\partial W_{ih}} = -\left[\sum_{o=1}^q \delta_o^k \cdot o_o^k (1 - o_o^k) \cdot V_{ho} \right] \cdot ho_h^k (1 - ho_h^k) \cdot i_i^k$$

则 $\Delta W_{ih} = \beta \cdot \left[\sum_{o=1}^q \delta_o^k \cdot o_o^k (1 - o_o^k) \cdot V_{ho} \right] \cdot ho_h^k (1 - ho_h^k) \cdot i_i^k$;

令 $d_o^k = \delta_o^k \cdot o_o^k (1 - o_o^k)$; $e_h^k = \left[\sum_{o=1}^q d_o^k \cdot V_{ho} \right] \cdot ho_h^k (1 - ho_h^k)$

则 $\Delta V_{ho} = \alpha \cdot d_o^k \cdot ho_h^k$; $\Delta W_{ih} = \beta \cdot e_h^k \cdot i_i^k$;

输出层阈值调整量 $\Delta \gamma_o = \alpha \cdot d_o^k$;

隐层阈值调整量 $\Delta \theta_h = \beta e_h^k$;

k 组训练集的全局误差 $E = \sum_{k=1}^m E_k = \sum_{k=1}^m \sum_{o=1}^q (t_o^k - o_o^k)^2 / 2$ 。

其中 $i = 1, 2, \dots, n$; $h = 1, 2, \dots, p$; $o = 1, 2, \dots, q$; α, β 为学习率。

BP神经网络的层数不局限于三层，随着层数的增加，网络所能接受的信息会增多，但过多的层数，训练时间会增多，并且会出现网络容错性变差、泛化能力下降等问题。因此，有不少学者利用四层BP神经网络来解决科研问题^[59]。一个四层的BP神经网络由一个输入层、两个隐层和一个输出层组成（图 4-3）。它的权值和阈值的修正公式如下^[60]：




图 4-3 四层 BP 神经网络结构图

隐层 J 的激发向量 $J_k = [j_1^k, j_2^k, \dots, j_s^k]$;

隐层 J 的输出向量 $JO_k = [jo_1^k, jo_2^k, \dots, jo_s^k]$;

隐层 H 的激发向量 $H_k = [h_1^k, h_2^k, \dots, h_p^k]$;

隐层 H 的输出向量 $HO_k = [ho_1^k, ho_2^k, \dots, ho_p^k]$;

输入层和隐层 J 之间的连接权 U_{ih} ;

隐层 J 各神经元的阈值 μ_h ;

令:

$$d_o^k = \delta_o^k \cdot o_o^k (1 - o_o^k)$$

$$e_h^k = \left[\sum_{o=1}^q d_o^k \cdot V_{ho} \right] \cdot ho_h^k (1 - ho_h^k)$$

$$f_j^k = \left[\sum_{h=1}^s e_h^k \cdot W_{jh} \right] \cdot jo_j^k (1 - jo_j^k)$$

则:

$$\Delta V_{ho} = \alpha \cdot d_o^k \cdot ho_h^k$$

$$\Delta W_{jh} = \beta \cdot e_h^k \cdot jo_j^k$$

$$\Delta U_{ij} = \tau \cdot f_j^k \cdot i_i^k$$

输出层阈值调整量 $\Delta \gamma_o = \alpha \cdot d_o^k$;

隐层 H 阈值调整量 $\Delta\theta_h = \beta e_h^k$;

隐层 J 阈值调整量 $\Delta\mu_j = \tau f_j^k$;

其中 $i = 1, 2, \dots, n$; $j = 1, 2, \dots, s$; $h = 1, 2, \dots, p$; $o = 1, 2, \dots, q$ 。 α , β , τ 为学习率

4.2.2. BP神经网络的训练过程

数据信号在 BP 神经网络间的运行有四个过程^[50]:

“模式顺传播”过程: 输入数据由输入层传递到隐层, 经过隐层各神经元的处理后再传递到输出层。

“误差逆传播”过程: 如果输出数据与期望数据之间的误差不满足要求时, 那么将误差值沿着连接通路逐层传递并修正各层连接权值。

“记忆训练”过程: “模式顺传播”过程和“误差逆传播”过程的反复交替, 不断修正各个连接的权值。

“学习收敛”过程: 判定全局误差是否趋向极小值, 如果成立, 则说明网络已经完成了整个学习过程。

整个训练过程可以用图 4-4 表示。




图 4-4 BP 神经网络的训练过程⁵¹

4.2.3. BP神经网络的改进方案

BP 神经网络的虽然可以实现输入样本与输出样本之间的非线性映射, 但它在实际应用中还存在一些问题^{[50][51]}:

- 1) 学习过程的收敛速度慢。

- 2) 不能保证收敛到全局最小值。
- 3) 初始参数的敏感性较强。
- 4) 隐层层数和隐层节点数的设计缺乏理论依据。
- 5) 网络的学习、记忆具有不稳定性。

因此, 为了搭建一个准确的 BP 神经网络模型, 需要改进它的学习规则、合理设计训练数据集, 并利用实验确定网络结构。

● 学习算法的优化

梯度下降算法是修正网络权值和阈值的最基本的方法。梯度下降算法中误差和学习率是影响权值和阈值修正量的主要参数。

针对误差而言, 可以使用累积误差校正算法, 使全局误差形成梯度下降的趋势。这种方法虽然可以有效地减少网络的校正次数, 但在某些情况下容易引起振荡。

针对学习率而言, 可以根据需要动态调整学习率, 这就是学习率可变的 BP 算法。一般而言, 修正量与学习率是成正比的, 通常学习率在 0.1~0.8 之间的定值, 如果初设学习率太小, 那么网络的校正次数会增加, 如果初设学习率太大, 那么会出现修正过头的问题。采用学习率可变的 BP 算法, 就是利用误差来修正学习率。如果本次计算误差小于前次计算误差, 则学习率减小, 反之学习率增大。

针对修正量整体而言, 可以在梯度下降算法的基础上加以改进, 如使前次校正结果的影响作用于本次校正量上, 可以加快校正过程, 这就是动量 BP 算法, 也被称为惯性校正法。还有如使用符号函数替代梯度幅度的弹性 BP 算法等都可以提高算法的计算速度。

● 训练样本的选择

BP 神经网络的学习和记忆功能不稳定。在应用阶段, 如果新输入的训练数据未被包括在训练阶段所使用的数据集时, 会打乱网络原有的记忆, 影响输出结果的准确性。所以网络训练集的值域和模式应包含测试集的值域和模式。

● 数据归一化

神经网络的输入层由多个节点组成, 每个节点代表着不同意义的物理量。由于物理意义和量纲的不同, 物理量的数值会存在很大的差别。例如温度的范围是 0~100, 风量的范围是 0~10000, 这时, 数量级大的节点的兴奋程度被加强, 而数量级小的则被抑制, 因此后者的变化趋势会被前者淹没。从另一个角度看, 神

经网络的输出量的物理意义与量纲和输入量的也不尽相同。网络中的激发函数大多为 S 型函数，改函数的值域为[0,1]，即使可以放大值域，也无法逐个确定网络中每个节点的值域范围。因此，在训练网络之前，需要将训练集中的所有数据做归一化处理。一般将原始数据归一化到[0.02,0.98]的区间内。归一化的公式为^[50]：

$$x'_i = a + b \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (4-2)$$

上式中 a, b 是常量，如果取值范围为[0.02,0.98]，则 a=0.02,b=0.96。x_{max}, x_{min} 是每组因子变量的最大值和最小值，如果数据集是确定的，那么x_{max}, x_{min} 也是一个定值。x_i是实际数据，x'_i是归一化后的数据。

● 隐层结构的设计

Hecht-Nielsen 曾证明，任意一个封闭区间内的连续函数都可以用三层 BP 网络来逼近，如果需要学习的是不连续的函数时，才需要含两个隐层。因此，一般情况下至多需要两个隐层^[50]。

一般而言，隐层节点数的确定可以参考以下公式^[61]：

$$n_h = \sqrt{n + m} + a \quad (4-3)$$

其中n_h为隐层节点数，n 为输入节点数，m 为输出节点数，a 为[1,10]之间的常数。

目前而言，关于隐层节层数和节点数的确定并无理论上的指导，以提出的结论或公式也仅供参考，具体应用时，仍需要通过训练测试，来确定最佳的隐层结构。

● 激发函数的改进

BP 神经网络常用的激发函数为 S 型函数，该函数的值域为[0,1]或[-1,1]。值域的两端称为饱和区，中间称为非饱和区。在饱和区，函数值对变量的变化敏感性降低。因此，如果隐层中某个节点的输入值处于饱和区时，权值的微小变化不会对该神经元的输出产生影响，这会影响网络学习的收敛速度。为解决这个问题，可以对激发函数进行调整，以单极型 S 型激发函数为例，可以做一下调整：

$$f(x) = \frac{1}{a + b e^{-\lambda x}} \quad a, b, \lambda \text{ 都是可调参数} \quad (4-4)$$

4.3. 机械通风开式冷却塔ANN模型

4.3.1. 建模过程

● 训练样本集的确定

实验冷却塔的监测系统是每隔两分钟记录 1 组数据，即一个小时内记录 30 组数据。实验冷却塔所服务的建筑为办公楼，冷却水系统每天的有效工作小时数约为 8 小时，一周有效工作天数为 5 天。则一周内记录的有效数据约为 1200 个。BP 神经网络的一个建模要求就是训练数据集应当包含预测数据集，即用于训练模型的冷却塔运行数据值域应大于预测数据值域，且训练数据不宜少于预测数据。本研究中，训练样本集的确定考虑到了以下两个因素：

- 1) 实验对象所服务的建筑为办公建筑，生产作息的变化周期约为一周，即受生产作息所影响的冷却负荷变化周期约为一周。
- 2) 实验对象所在的深圳地区输入夏热冬暖地区，该地区的全年温度和相对湿度变化规律见图 4-5 和图 4-6，由图可见，深圳空调供冷季的时间较长，且期间的温度和相对湿度变化规律较平缓，如无极端天气影响，可以干、湿球温度的变化周期大于一周，即受天气影响的冷却负荷变化周期大于一周。




图 4-5 深圳全年空气干球温度变化趋势




图 4-6 深圳全年空气相对湿度变化趋势

因此，本研究以一周为周期，取连续的 1000 组有效数据用于模型训练，之后的 200 组数据用于测试模型的预测准确性。




图 4-7 1000 组冷却塔数据

图 4-7 是从平滑处理后的冷却塔运行实测数据中按序选取的 1000 组数据。这 1000 组数据所对应的记录时间是 2011 年 8 月 1 日的 7 点至 2011 年 8 月 6 日的 8 点。图中进塔水温、湿球温度、出塔水温单位均为摄氏度，水气质量比为无量纲数。预测样本选用 2011 年 8 月 6 日 8 点后的 200 组未经平滑处理的实测数据，这 200 组数据的数值范围未超过前 1000 组数据，满足 ANN 模型对于训练和预测数据集的要求。由图中各种数据的变化规律可知，整个冷却水环路的运行工况在不断变化，变化幅度时而大、时而小，其中第 830~880 组数据最大，冷却

塔进、出塔水温和水气质量比都陡降至最小值再陡升至最高值，这反映了冷却水环路经历了启停过程。各种监测数据的变化是由空调制冷负荷的变化所造成的，说明整个冷却水环路处于动态运行中。

● **BP神经网络学习算法的确定**

为了提高模型的计算速度，本研究采用学习率可变 BP 算法。

学习率的修正公式如下：

$$\alpha(k+1) = \frac{E(k)}{E(k+1)} \alpha(k) \tag{4-5}$$

上式中：

$\alpha(k)$ ——第 k 组输入对的学习率；

$\alpha(k+1)$ ——第 k+1 组输入对的学习率；

$E(k)$ ——第 k 组输入对的均方误差；

$E(k+1)$ ——第 k+1 组输入对的均方误差。

● **BP神经网络结构的确定**

根据预测要求，机械通风开式冷却塔 ANN 模型的输入层有 3 个节点，分别表示湿球温度、进塔水温和水气质量比；输出层有 1 个节点，表示出塔水温。然而，隐层的层数和节点数对模型的学习速度和计算准确性有很大的影响。下面列举一些文献中利用 BP 神经网络预测冷却塔运行性能的网络结构：

表 4-2 文献对比——冷却塔 BP 神经网络模型结构

冷却塔类型	输入节点数	输出节点数	隐层层数	隐层节点数	预测误差	出处
无特定	4	1	1	9	0.8% (最大相对误差)	文献 [42]
无填料冷却塔	8	1	1	17	1.13% (平均相对误差)	文献 [24]
机械通风逆流冷却塔	5	5	1	5	0.89% (平均相对误差)	文献 [23]
自然通风逆流式冷却塔	5	3	1	6	0.044℃ (出塔水温均方误差)	文献 [25]
闭式冷却塔	6	1	1	13	--	文献 [41]

上述文献中的模型都使用了三层网络的结构，但它们都是利用实验冷却塔进行数据采用的。实际工程中的冷却塔存在着启停、工况调节等多种变化，其性能曲线不是连续的。含有 2 个隐层的 BP 神经网络能较好地映射非连续型函数^[60]，因此，本研究中选用含有 2 个隐层的 BP 神经网络。在利用大量样本进行训练前，

先利用少量样本来确定最佳网络结构。

依据式(4-3)可以得到, BP 神经网络的隐层可以有 3~10 个节点。在两个隐层中, 每个隐层至少可含 3 个节点, 第一隐层的节点数不宜小于第二隐层。下面(表 4-3)利用 1000 组数据进行 10 次迭代计算, 以此来测试不同隐层节点数的网络的全局误差。全局误差只是神经网络的计算误差, 它反映了输出节点上, 1000 组期望值和输出值的误差, 期望值和输出值都是归一化后的数据, 不能直接反映出塔水温的计算误差。

表 4-3 10 次迭代后不同隐层节点数的误差

测试序号	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

经过 10 次迭代计算后发现, 当第一、第二隐层分别设 3 个节点时, 模式的测试全局误差最小。其余结构中虽然有些在训练阶段的全局误差较小, 但测试阶段的全局误差较大。因此确定本研究中的冷却塔 ANN 模型为四层结构, 包含两个隐层, 每个隐层各有 3 个节点(图 4-8)。




图 4-8 机械通风开式冷却塔 ANN 模型网络结构图

● 激发函数的确定

BP 神经网络的激发函数直接影响到输入和输出数据之间的映射关系和预测误差。BP 神经网络的常用的激发函数有双曲正切函数、S 型函数和线性函数等。

双曲正切函数的公式为： $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ ，函数的值域为(-1,1)；

S 型函数和线性函数的公式和值域见表 2-6 和表 2-3。

下面（表 4-4）利用 1000 组数据进行计算，以此来测试使用不同激发函数的网络计算误差。

表 4-4 不同激发函数的误差

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 tanh(x)	线性函数 y(x)	48.122	25.538
	双曲正切函数 tanh(x)	4.141	2.21
	S 型函数 Sigmoid(x)	1.415	0.338
S 型函数 Sigmoid(x)	线性函数 y(x)	50.176	23.734
	双曲正切函数 tanh(x)	4.609	1.885
	S 型函数 Sigmoid(x)	1.723	0.463

经过计算后发现，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，因此选定这样的组合为机械通风开式冷却塔 ANN 模型的激发函数。

4.3.2. 测试结果

在对 1000 组数据进行初步的测试对比后，确定机械通风开式冷却塔 ANN 模型的基本结构为 3-3-3-1BP 神经网络——输入层 3 个节点、第一隐层 3 个节点、第二隐层 3 个节点、输出层 1 个节点；模型的学习算法为学习率可变的 BP 算法；网络中的隐层激发函数为双曲正切函数，输出层的激发函数为 S 型函数。

模型的输入数据对根据以下公式进行归一化：

$$x'_i = 0.02 + 0.96 \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (4-6)$$

网络的输出结果是 0~1 之间的值，要得到冷却塔水温的预测值，需要对输出结果进行还原，还原的公式如下：

$$x_i = \frac{(x'_i - 0.02)(x_{\max} - x_{\min})}{0.96} + x_{\min} \quad (4-7)$$

利用 1000 组数据训练网络后，训练的最终结果见图 4-9。图中进塔水温、湿球温度、出塔水温实测值和出塔水温预测值的单位均为摄氏度，水气质量比为无量纲数。

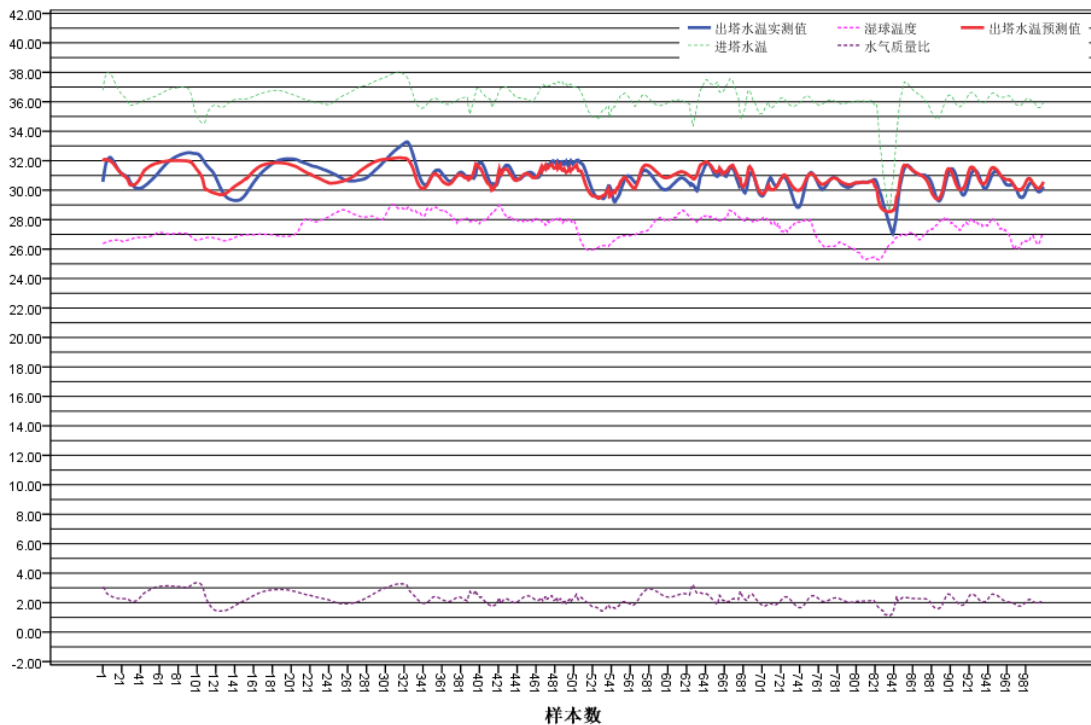


图 4-9 机械通风开式冷却塔 ANN 模型的训练结果-温度变化趋势图

训练完毕后，ANN 模型的全局误差为 1.415，将 1000 组预测值和实测值还原至出塔水温后，两者间的误差见表 4-5：

表 4-5 训练集误差

	最大值	最小值	平均值	标准差
绝对误差 (°C)	+1.43	-1.77	+0.02	0.53
相对误差 (%)	+5.1	-5.6	+0.09	1.72
-1°C<绝对误差<+1°C的出现频率			96.1%	

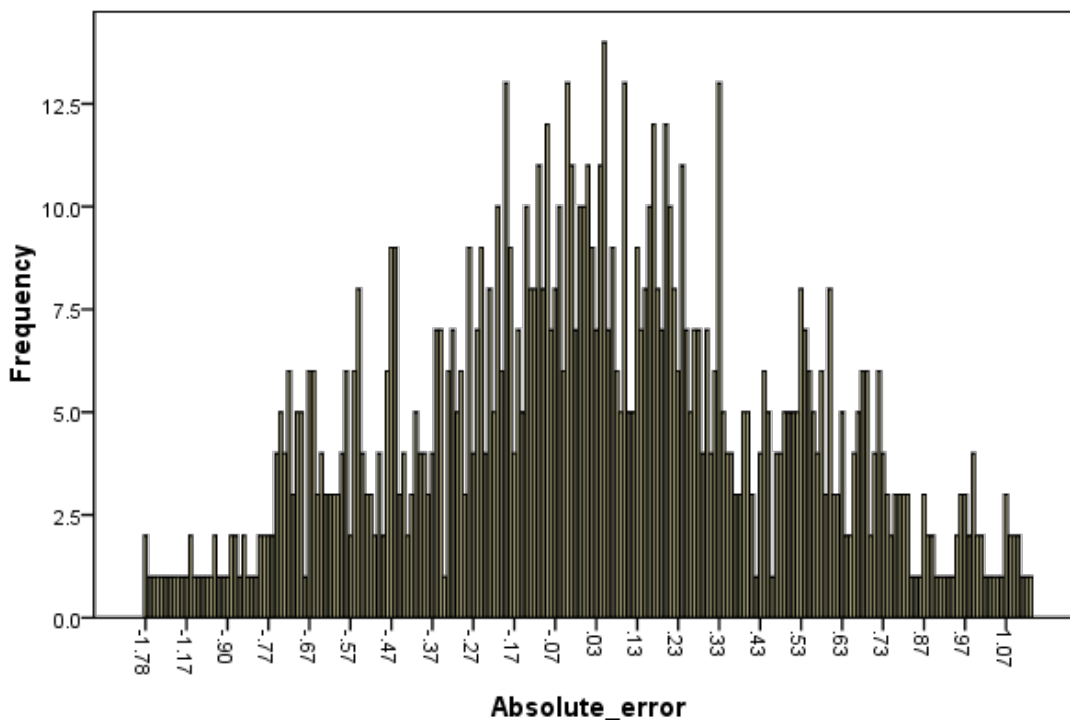


图 4-10 训练集绝对误差频率分布图

由图 4-9、图 4-10 和表 4-5 可知：

- 1) 训练完毕的 ANN 模型,可以根据训练数据集预测出塔水温的变化趋势。
- 2) 冷却塔出塔水温接近最高值和最低值时的模拟误差较大,这和最高值和最低值出现的数据对个数有关,个数越少,ANN 模型学习的次数越少,预测误差较大。
- 3) 预测值和实测值之间绝对误差的最大值不超过 2°C,且出现频率低于 4%。
- 4) 实测值和预测值之间的相关系数为 0.81,接近于 1。
- 5) 预测值和实测值之间绝对误差的平均值接近于 0°C,误差的频率分布呈现出中间高两端低的正态分布趋势。由这三个特点可以推断出模拟值和实验值之间误差基本满足偶然误差的分布规律。

上述 5 点说明了机械通风开式冷却塔 ANN 模型的训练结果已满足预测要求,可以进行预测。

当将新的 200 组未经平滑处理的数据输入到训练完毕的 ANN 模型计算后，可以得到出塔水温的预测结果（图 4-11）。图中另一条红色虚线是用 ϵ -NTU 方法计算得到的预测结果。两种方法的预测值和实测值之间的误差分析见表 4-6。




图 4-11 机械通风开式冷却塔 ANN 模型预测结果

表 4-6 测试集误差

方法	误差	最大值	最小值	平均值	标准差
ANN 方法	绝对误差 ($^{\circ}\text{C}$)	+0.81	-0.93	-0.06	0.40
	相对误差 (%)	+2.8	-3.1	-0.2	1.32
	-0.7 $^{\circ}\text{C}$ <绝对误差<+0.7 $^{\circ}\text{C}$ 的出现频率			88%	
ϵ -NTU 方法	绝对误差 ($^{\circ}\text{C}$)	+2.17	-1.98	-0.16	0.89
	相对误差 (%)	+7.6	-6.3	-0.5	2.95
	-1 $^{\circ}\text{C}$ <绝对误差<+1 $^{\circ}\text{C}$ 的出现频率			70%	

从图 4-11 和表 4-6 上可以看出，与 ANN 方法相比， ϵ -NTU 方法的预测误

差较大，预测值和实测值之间的相关系数为 0.49。 ϵ -NTU 方法虽然可以追踪出塔水温的波动趋势，但对于小幅波动的敏感性较差，200 组测试数据中，有 30% 的预测误差超过了 $\pm 1^\circ\text{C}$ ，多于 ANN 方法。

图 4-12 给出了 ANN 方法预测绝对误差的分布频率，图 4-13 给出了 ANN 方法实测值和预测值的散点图。




图 4-12 测试集的绝对误差频率分布图




图 4-13 预测值与实测值对比

由图 4-11、图 4-12、图 4-13 和表 4-6 可见：

- 1) ANN 方法的预测准确性高于 ϵ -NTU 方法。
- 2) 这 200 组测试集数据的变化趋势比 1000 组训练集数据的变化趋势缓和，但其中也包含了工况突变点。使用 ANN 方法所得到的预测结果能较好地吻合实测结果。预测值和实测值之间的相关系数为 0.9，接近 1。
- 3) ANN 方法预测误差不超过 $\pm 1^\circ\text{C}$ ，误差平均值接近于 0°C 。误差在工程允许的范围之内。

4.3.3. 多次采样后的测试结果

上一小节中所得到的测试结果是从 2011 年 8 月 1 日的 7 点至 2011 年 8 月 6 日的 8 点间的监测数据集中得到的。以下将更换采样时间，进行多次测试，验证 ANN 算法可以应用到预测该组冷却塔的全年运行性能。

为进行验证，本次验证在该组冷却塔的实测数据中选取三个不同时间的数据样本进行测试。这三个样本的代表着不同的运行季节，样本概述见表 4-7。

表 4-7 多次采样样本概述

样本集	采样时间	样本个数	代表季节	训练数据	测试数据
1	2011-8-20~2011-8-25	1200	夏季	1000	200
2	2011-10-15 ~2011-10-20	1200	过渡季	1000	200
3	2011-11-30 ~2011-12-7	1200	冬季	1000	200

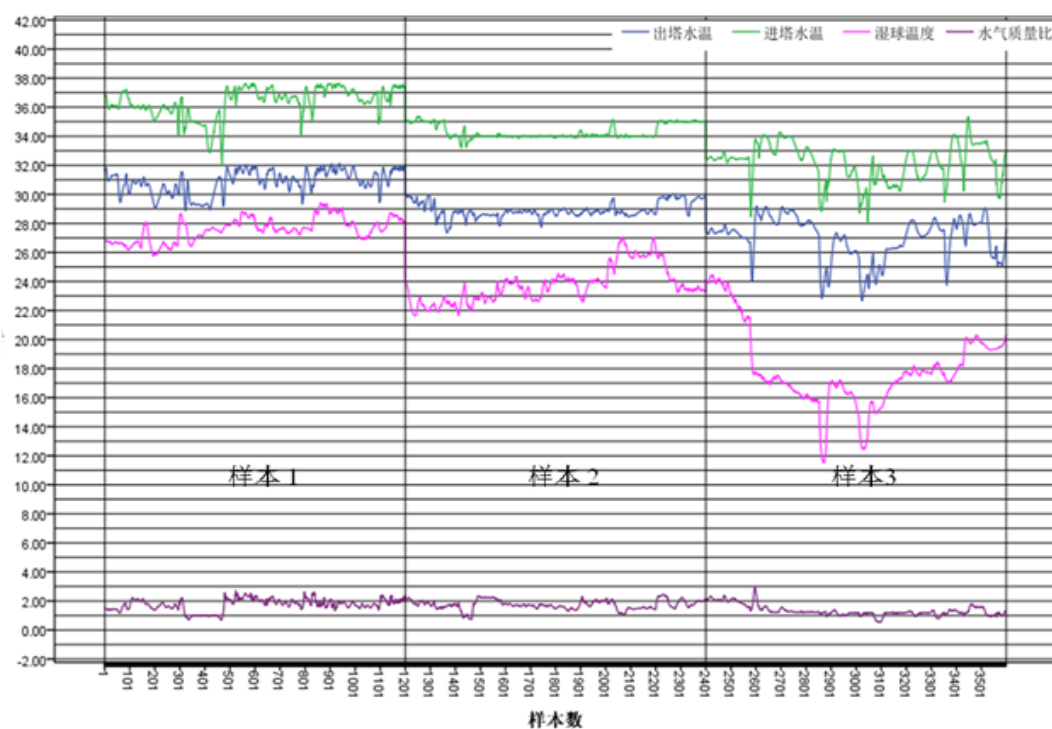


图 4-14 三组样本数据集

图 4-14 给出了三组样本数据趋势。与建模所使用的样本相比，这三组样本中数据的波动幅度较大，尤其进入冬季后，幅度较大的波动出现频率增多，说明整个冷却水系统启停运行频繁交替，采样时间并不是连续的，样本中包含了多个工况突变点。经过训练后，三组样本的预测结构见图 4-15。

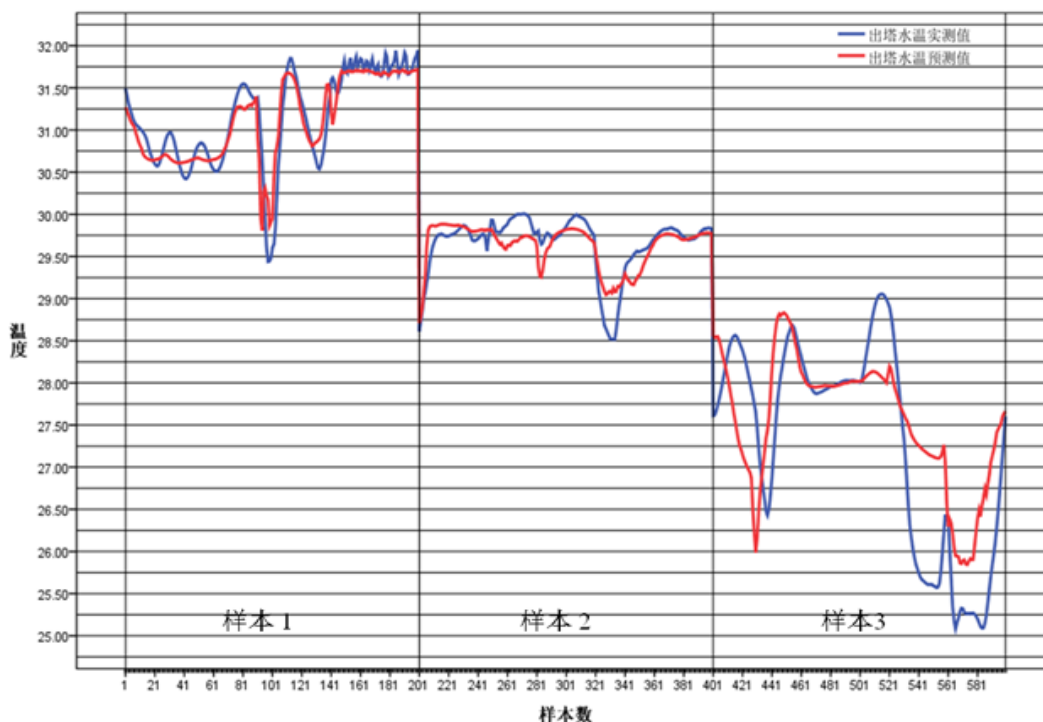


图 4-15 三组样本的预测结果

这三组样本的预测误差如下表所示：

表 4-8 三组样本的预测误差

样本集	ANN 模型预测阶段全局误差	出塔水温预测误差平均值	预测精度	绝对误差的标准差	预测值和实测值的相关系数
1	0.64	-0.03°C	±1°C	0.23	0.91
2	0.26	-0.02°C	±0.7°C	0.20	0.82
3	0.52	+0.26°C	±1.7°C	0.82	0.76

从预测结果的误差上看，样本 3 的预测误差离散程度大，预测结果较差。该预测结果虽然反应了整体出塔水温的变化趋势，但由于学习过程中存在多个工况突变点，影响 ANN 模型的学习收敛速度和预测准确度，网络的稳定性变差，其对于稳态数据的预测准确性降低。为了提高预测准确度，需要改进预测模型。

4.3.4. 针对工况突变的模型改进

进入过渡季和冬季后，建筑空调冷却水系统连续运行时间变短，启停频繁，监测数据中的运行工况突变点增多，因此当讨论针对工况突变的模型改进方法时，以过渡季和冬季工况的部分数据进行方法测试。

实验冷却水系统在 2011 年 11 月至 2012 年 1 月之间，运行的时间如表 4-9 所示，监测数据共 10739 组。

表 4-9 实验冷却塔 2011 年 11 月至 2012 年 1 月之间的运行时间

日期	时间
2011-11-1~2011-11-5	8:00~18:00
2011-11-7~2011-11-12	8:00~18:00
2011-11-14~2011-11-19	8:00~18:00
2011-11-21~2011-11-26	8:00~18:00
2011-11-28~2011-12-3	8:00~18:00
2011-12-5~2011-12-9	8:00~18:00
2011-12-12~2011-12-15	8:00~16:00
2011-12-16	8:00~14:00
2011-12-17	8:00~9:00
2011-12-19	8:00~14:00
2011-12-20	8:00~14:00
2011-12-21	8:00~15:00
2011-12-22~2011-12-23	8:00~16:00
2011-12-26~2011-12-27	8:00~14:00
2011-12-28~2011-12-29	8:00~16:00
2011-12-30~2011-12-31	8:00~14:00
2012-1-4	8:00~10:00
2012-1-9	9:00~9:30
2012-1-10	13:00~15:00
2012-1-11	8:00~9:00
2012-1-12~2012-1-13	13:00~14:00
2012-1-16~2012-1-20	13:00~14:00
2012-1-30	8:00~9:00

● 方法 1: 剔除工况突变点

BP 神经网络对于训练样本数据的敏感性较高。如果训练样本中存在和数据总体平均值偏差较大的异常样本时, 容易使神经元节点异常兴奋, 使网络整体的预测稳定性降低, 即使预测常规工况下的数据时, 也会出现较大的误差。另一个

方面，异常样本出现频率极低时，会降低网络对于异常样本的学习次数，网络对于异常工况的预测准确度也会有所降低。这样的异常且低频样本就是工况突变点（A）所对应的样本。在实时监测，数据的变化趋势还会存在阶跃状态，这时候会出现另一种工况突变点（B），它表征了运行工况从前一个状态快速进入到后一个状态。这两种工况突变点的区别在于，A 点数据与前一时刻数据和后一时刻数据的偏差都较大，有显著的回弹趋势；B 点数据点前后时刻数据呈阶跃变化，无显著的回弹趋势。

图 4-16 给出了 10739 组数据中的前 5000 组数据。在图中可以看到 A、B 两种工况突变点的区别。

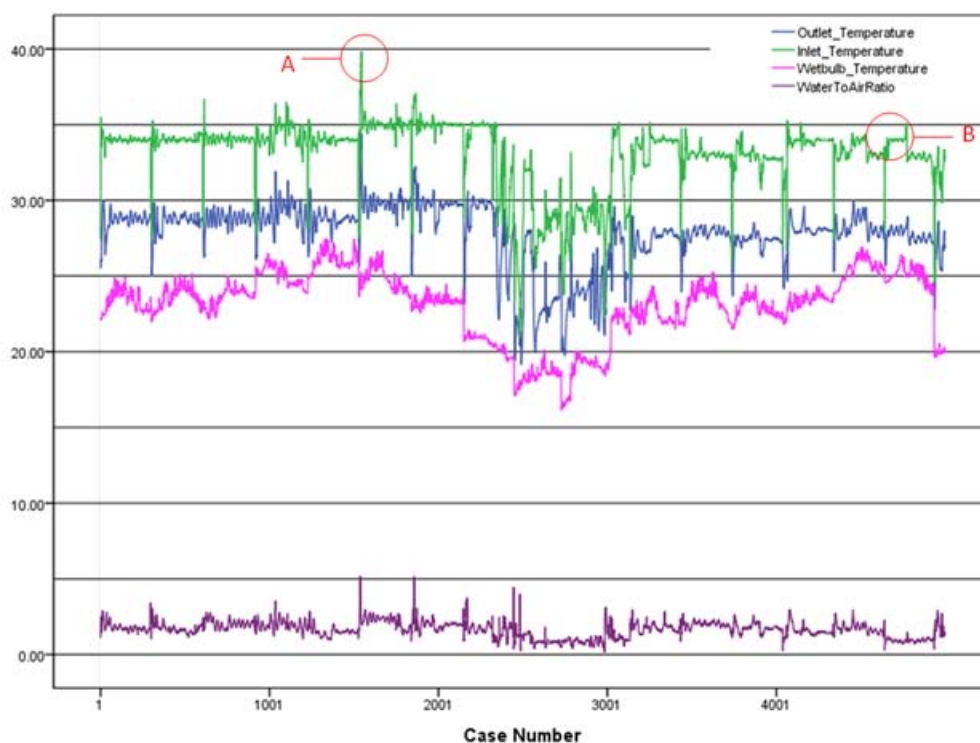


图 4-16 5000 组实测数据

为了减小 A 类工况突变点对网络稳定性和预测准确度的影响，可以在数据平滑处理前先进行剔除。剔除的规则有以下三条：

- 1) 数据出现频率低于 0.1%。
- 2) 该时刻数据与前 10 个时刻数据的平均值之间的相对误差大于 5%。
- 3) 该时刻数据与后 10 个时刻数据的平均值之间的相对误差大于 5%。

10739 组数据的前 10539 组数据中，各类数据的数值范围和低频数值范围如下表所示：

表 4-10 第一轮数据剔除依据

数据类型	值域范围	低频频数	低频数值范围
进塔水温 (°C)	20.9~39.8	10	[20.9~27]&[37~39.8]
出塔水温 (°C)	19.1~34.4		[19.1~24]&[30~34.4]
湿球温度 (°C)	8.3~27.5		[8.3~9]&[26~27.5]
水气质量比	0.05~7.32		[0.05~0.4]&[5~7.32]

经过规则 1 的第一轮数据剔除后，共获得 7261 组有效数据。再使用规则 2 和规则 3 进行第二轮数据剔除，最终共获得 6301 组有效数据（图 4-17）。这 6301 中虽然仍存在部分 A 类工况突变点，但数据突变程度比图 4-16 所示的小很多。可以进行 ANN 模型的训练和预测。




图 4-17 经过剔除后的 6301 组有效数据

在这 6301 组数据中选取后 1000 组数据平滑处理后进行网络训练，并利用原样本集中的第 10540~10739 组数据直接用于测试预测准确性。最终 200 组预测数据的测试结果见图 4-18 和图 4-19。




图 4-18 方法 1 预测结果-温度变化趋势图




图 4-19 方法 1 预测结果-预测值与实测值对比

预测阶段，出塔水温预测值和实测值之间的绝对误差平均值为 0.12°C ，标准差为 0.528 ，误差离散度较小，预测值和实测值之间的相关系数为 0.75 ，预测精度小于 $\pm 2.66^{\circ}\text{C}$ ，且误差大于 $\pm 1^{\circ}\text{C}$ 的出现频率小于 6% 。总体而言，预测误差在工程允许的范围之内，方法有效。

● **方法 2：增大采样周期**

关系到预测准确度的一个重要因素就是训练样本的采样周期。本研究所用到的实时监测系统都是每隔两分钟记录一组数据。这样的采样周期太过密集，如果直接采用这样的实测数据，那就可能会采集到冷却塔处于工况调节、工况突变时

的运行数据。

下面将分别选取实验用冷却塔在 2011 年 8 月 2 日和 11 月 3 日的实测数据进行观察对比，分析系统启停时的工况突变、运行时的突变和缓慢变化过程的时间间隔。除了缓慢变化情况外，其余两种情况都不能反映冷却塔的真实运行性能，ANN 模型的训练数据集中应当滤除这两种数据。

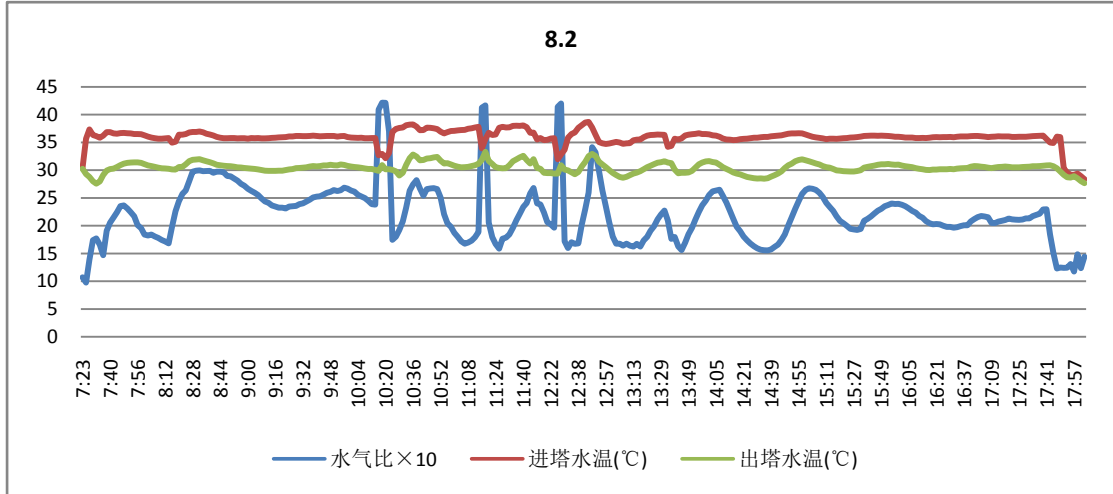


图 4-20 2011 年 8 月 2 日实测数据




图 4-21 2011 年 11 月 3 日实测数据

以上两幅图是实验用冷却塔在这两天之内的运行实测数据。从这两幅图中，可以观察到三种运行工况的变化：系统启停、运行工况突变和缓慢变化。这三类变化的具体发生时刻和所用时间如下表所示：

表 4-11 运行变化类型及发生时刻

	8 月 2 日	11 月 3 日
系统开启		

波动发生时刻	7:23	7:31
波动稳定时刻	7:38	7:43
系统关停		
波动发生时刻	17:47	17:39
波动稳定时刻	18:03	17:53
运行突变		
波动发生时刻	10:12	无显著突变
波动稳定时刻	10:28	
波动发生时刻	11:12	
波动稳定时刻	11:24	
波动发生时刻	12:22	
波动稳定时刻	12:30	
运行缓慢变化		
波动发生时刻	14:30	13:53
波动稳定时刻	15:22	14:59

要滤除系统启停和工况突变时的数据，可以通过增大采样周期的方式来实现。若采样周期合适，那么就会保留大周期的变化趋势，忽略了小周期的突变波动，由上表可知，在实验系统中，由冷却水系统启停变化所造成的数据波动平均周期约为 14 分钟，运行突变所造成的数据波动平均周期约为 12 分钟，运行缓慢变化所造成的数据波动平均周期约为 1 小时。由此可以推断，突变波动的周期在 15 分钟以内，以这个周期的一半作为采样周期，那么采样周期约为 6~10 分钟。

在 2011 年 11 月至 2012 年 1 月之间的 10739 组实测数据中，对前 10539 组数据分别以 6 分钟、8 分钟和 10 分钟的时间间隔进行采样。随后对采样结果进行平滑处理，并用平滑后的后 1000 组数据训练 ANN 模型。最后用第 10540~10739 组数据进行预测检验，这 200 组预测数据的输出周期仍为 2 分钟，预测结果见图 4-22。




图 4-22 不同采样周期的预测结果

表 4-12 采样周期不同的训练样本训练 ANN 模型后的预测绝对误差

采样周期	平均值 (°C)	最大值 (°C)	最小值 (°C)	绝对误差的标 准差	预测值和实测值的 相关系数
6 分钟	0.01	2.76	-1.72	0.53	0.87
8 分钟	-0.17	2.28	-2.81	0.48	0.60
10 分钟	0.08	2.35	-2.40	0.60	0.47

从图 4-22 上可以看出，即使在工况突变点，不同采样周期下的预测结果都能追踪出塔水温的变化规律，如果训练样本的采样周期为 6 分钟，预测结果与实测值吻合得最好，它的平均预测误差为 0.01°C，相关系数为 0.87，是三次测试中最高的。而以 8 分钟和 10 分钟的间隔进行采样，预测结果的准确性有所降低，这说明过疏的采样周期除了滤掉了一些工况突变点以外，也滤去了一些反应缓慢变化过程和稳态过程的数据，对于提高算法的准确性不利。

三次测试在预测阶段所使用的数据都和方法 1 一致，即都是每隔两分钟给出一个预测结果，但方法 2 的预测误差明显小于方法 1，预测准确度更高。这说明，即使采样周期比预测周期大，预测也能有较好的效果。事实上，ANN 模型是一个静态的模型，它的预测结果与预测阶段采样周期无关，只要网络在学习过程中避开了突变数据的干扰，并顺利完成学习过程，那么无论预测阶段的时间间隔是

多少，都能就稳态运行过程给出准确的预测结果。

增大采样周期只是针对训练样本而言，与剔除工况突变点的方法相比，增大采样周期的方法有效地降低了预测误差。就实验用冷却塔而言，前者的平均预测误差比后者低 0.11°C 。不仅如此，它也简化了训练样本的数据处理过程，缩短了算法整体的运行时间，可以运用到冷却塔运行性能的在线预测中。

4.4. 本章小结

通过实验和数据分析可以证明使用四层 BP 神经网络可以预测实验冷却塔的全年运行性能。

在夏季运行时，冷却水系统启停间隔时间短，冷却负荷和天气参数的变化慢，使用前一周的实测运行数据可以预测未来 1 天的运行性能时，预测精度在 $\pm 2^{\circ}\text{C}$ 的范围内，已测试的数据中，90% 以上的预测误差未超过 $\pm 1^{\circ}\text{C}$ 。进入过渡季和冬季后，冷却水系统启停间隔时间变长，冷却负荷和天气参数的变化速度加快，工况突变点增多，影响 ANN 模型的稳定性和预测准确性。如果使用一定规则剔除工况突变点，可以提升预测的准确度，但当将 ANN 模型应用到冷却塔运行性能的在线预测时，不利于简化在线学习过程；如果将训练样本集的采样周期扩大，那么采样时就可以过滤掉部分处于工况突变中的数据，经过训练后的网络可以有效地预测和追踪出塔水温的突变趋势，预测精度也比前一种方法有所提高，因此后一种方法更优。

综上所述，使用 ANN 模型预测机械通风逆流冷却塔的运行性能是可行的。但在组织训练样本前，需要根据每个系统的特性确定最合适的采样周期。

第5章. 机械通风开式冷却塔ANN算法校验

对于机械通风开式冷却塔 ANN 算法的校验是校验该算法能否推广应用于所有的机械通风开式冷却塔。因此，校验时所用的实验对象应当和先前建立算法时所用的实验对象应当具有不同的结构和不同的运行环境。以新塔的实际运行数据集训练 ANN 模型，然后根据预测结果判断算法是否具有推广的可能。本次进行 ANN 算法校验的数据是上海某办公楼空调系统中冷却塔的实际运行数据。

5.1. 校验用冷却塔的基本情况

校验用冷却塔位于中国上海，该地区属于夏热冬冷地区，四季变化明显。

测试对象所在的空调系统中共有 7 台并联的机械通风横流冷却塔。这 7 台冷却塔型号相同，它们的基本参数见表 5-1。冷却塔的现场情况见图 5-1。

表 5-1 校验冷却塔型号及参数

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



图 5-1 校验用横流冷却塔

冷却塔和冷却回路的工作状态通过实时监测平台监控并记录数据，整个回路和测点位置见图 5-2。

^a 风筒半高——出风口和进风口中部的高度差

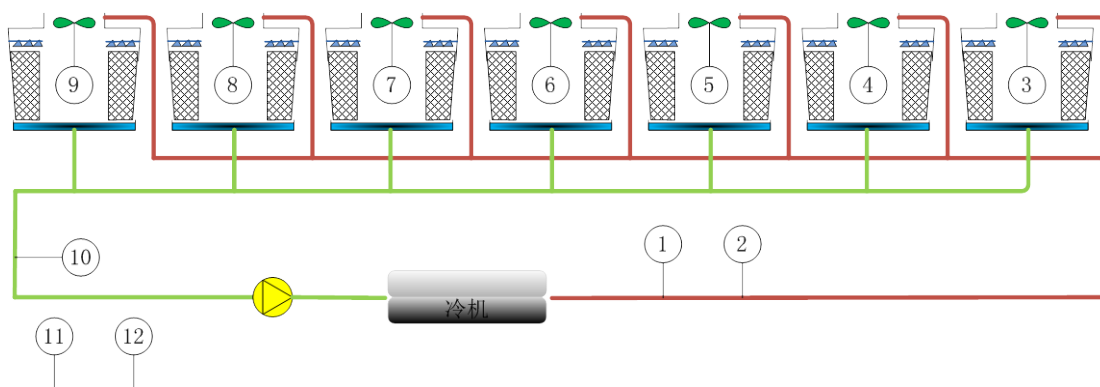


图 5-2 校验用冷却水回路及测点示意图

实时监测从 2012 年 9 月 6 日起至 10 月 17 日，每隔 6 分钟记录一组数据，共记录 9854 组数据，其中有效数据为 8988 组。各个测点所监测的数据类型见表 5-2。

表 5-2 校验用监测数据类型

测点编号	监测信号	信号类型	量程	信号单位	测量仪器
1	进塔水温	温度	0~100	℃	插入式温度传感器
2	冷却水流量	流量	0~1000	l/s	超声波流量传感器
3	冷却塔风机功率	功率	0~50	kW	功率电表
4	冷却塔风机功率	功率	0~50	kW	功率电表
5	冷却塔风机功率	功率	0~50	kW	功率电表
6	冷却塔风机功率	功率	0~50	kW	功率电表
7	冷却塔风机功率	功率	0~50	kW	功率电表
8	冷却塔风机功率	功率	0~50	kW	功率电表
9	冷却塔风机功率	功率	0~50	kW	功率电表
10	出塔水温	温度	0~100	℃	插入式温度传感器
11	空气干球温度	温度	0~100	℃	室外温湿度传感器
12	空气湿球温度	温度	0~100	℃	室外温湿度传感器

校验用冷却塔和实验用冷却塔有较大的区别：从冷却塔的形式而言，实验用冷却塔为逆流冷却塔，校验用冷却塔为横流冷却塔，两者的物理结构和冷却过程不同；从冷却塔的数量而言，用于建模的实验冷却塔共有 4 台，用于校验模型的校验冷却塔共有 7 台，两个冷却水系统不同；从测试环境而言，实验用冷却塔位于深圳，校验用冷却塔位于上海，两地天气条件不同。正因为存在这样的差异性，校验才有了实际意义。如果能证实本研究所提出的 ANN 模型同样能用于预测校验用冷却塔的出塔水温，那么基于 ANN 的机械通风开式冷却塔运行性能预测方法才能有推广的可行性。

5.2. 数据处理

5.2.1. 风机功率与风量

风机开启时冷却塔的风量和运行功率之间的关系可以根据式(3-6)确定, 校验冷却塔的额定功率为 22kW, 额定风量为 529000m³/h, 即 147m³/s, 则比例系数 $k=52.46\text{m}^3/(\text{s}\cdot\text{kW}^{1/3})$ 。

由于冷却塔的进水阀门并未与冷却塔的风机保持联动, 因此, 当风机停转时冷却塔内的风量可以根据式(3-11)确定。校验用冷却塔的设计全压为 5.5mH₂O, 即 55729Pa, 由于横流冷却塔侧面进风口面积较大, 近似以进风口中部到塔顶出风口的距离为热压高度差。风筒半高为 3.88m, 则风机关停时冷却塔的风量为 0.83m³/s。

综上所述, 冷却塔风量和功率的关系式如下:

$$Q = 52.46\sqrt[3]{P} + 0.83 \text{ m}^3/\text{s} \quad (5-1)$$

5.2.2. 数据平滑

和实验数据处理的方式一样, 校验数据也采用滑动加权平均算法进行数据平滑处理, 平滑后的结果见图 5-3、图 5-4 和图 5-5。

图 5-3 所示的冷却塔进、出塔水温的变化幅度较大, 图 5-4 和图 5-5 所示的冷却水流量和冷却塔风机功率的变化呈阶跃的趋势。整个冷却水环路在高、低负荷工况间反复运行, 数据的不稳定性较大。这说明既定的 6 分钟采样周期, 对于该系统而言太过密集, 但这不影响校验, 如果训练样本的数据质量较差, 但预测结果仍较为准确, 那么算法本身的有效性就更有保障。




图 5-3 进塔水温、出塔水温和湿球温度的平滑处理结果(°C)




图 5-4 冷却水流量的平滑处理结果(l/s)




图 5-5 风机功率的平滑处理结果(kW)

5.3. 测试结果

校验阶段所使用的 ANN 模型结构、学习算法和激发函数与实验阶段的相同。

本次校验将 2012 年 9 月 6 日 10 点至 2012 年 9 月 16 日 8 点的 1000 组实测数据进行平滑处理，形成校验数据集，然后再利用新的、未处理的 200 组数据校验推广 ANN 算法的可行性。

当输入 1000 组数据进行训练后，ANN 模型的全局误差为 1.041，训练结果见图 5-6。图中进塔水温、湿球温度、出塔水温实测值和出塔水温预测值的单位

均为摄氏度，水气质量比为无量纲数。将 1000 组预测值和实测值还原至出塔水温后，两者之间的误差见表 5-3。




图 5-6 训练结果-温度变化趋势图

如图 5-6 所示。出塔水温受到了进塔水温、出塔水温和湿球温度这三个因素的影响。ANN 模型的预测结果也能较好地反映这些影响因素，与实测出塔水温较吻合。

表 5-3 训练集误差

	最大值	最小值	平均值	标准差
绝对误差 (°C)	0.98	-1.49	-0.04	0.46
相对误差 (%)	3.9	-5.1	-0.1	1.63
-0.9°C < 绝对误差 < +0.9°C 的出现频率			94.8%	




图 5-7 训练集绝对误差频率分布图

预测精度不超过 $\pm 1.5^{\circ}\text{C}$ ，预测值和实测值之间的相关系数为 0.92，误差的平均值接近于 0，图 5-7 所示的绝对误差频率分布向零点集中。因此，可以认为训练完成，经过训练的网络可以用于后续的预测。

当将新的 200 组未经处理的数据代入到训练完毕的 ANN 模型计算后，可以得到出塔水温的预测结果（图 5-8）。预测值和实测值之间的误差见表 5-4。




图 5-8 预测结果-温度变化趋势图

表 5-4 测试集误差

	最大值	最小值	平均值	标准差
绝对误差 ($^{\circ}\text{C}$)	+1.34	-0.41	+0.16	0.46
相对误差 (%)	+5.4	-1.6	+0.6	1.80
-0.41 $^{\circ}\text{C}$ <绝对误差<+1 $^{\circ}\text{C}$ 的出现频率			93.5%	




图 5-9 测试集的绝对误差频率分布图




图 5-10 预测结果-预测值与实测值对比

预测阶段 ANN 模型的全局误差为 0.232。如图 5-8 所示网络对于整体测试数据的预测结果可以吻合实测结果，预测值和实测值之间的相关系数为 0.72。预测精度不超过 $\pm 1.5^{\circ}\text{C}$ ，误差的平均值接近于 0（表 5-4），满足工程上对于误差的要求。预测结果理想。

综上所述，使用 BP 神经网络预测机械通风开式横流冷却塔出塔水温的方法是可行的。

第6章. 冷却塔运行性能在线预测的实现

冷却塔出塔水温对于计算空调水系统的运行性能、运行能耗和优化系统控制都极为重要。在实际工程中，通常要求能够实时、准确地预测出冷却塔的出塔水温，以便及时反映给系统控制器，执行下一步的控制策略。上述章节已经证明了 ANN 算法可以进行机械通风开式冷却塔的运行性能学习和预测。以下将阐述如何将该算法应用到在线预测上。

6.1. 训练样本与预测样本

ANN 算法的实质是利用 ANN 模型学习不同数据之间的关联性，记忆在 ANN 模型中，完成对于某个未知数据的预测。它有三个特点：

- 1) 数据是 ANN 算法的基础，如果要预测一台冷却塔的出塔水温，那么首先要获得该塔已有的运行实测数据，其次要实时监测进塔水温、空气湿球温度、冷却水流量和风机功率，最后才能根据这些数据预测出准确的出塔水温。
- 2) 由于 BP 神经网络的学习和记忆能力有限，如果模型的预测范围超过了已经完成的学习范围，那么预测的准确性会下降。
- 3) 输入模型的训练数据集和预测数据都是以时间为序的，完成训练的模型容易遗忘最早输入训练数据，而对于与最近一组训练数据相似工况的预测准确性较好。

因为 ANN 算法存在以上三个特点，所以使用 ANN 算法在线预测出塔水温时，需要合理分配训练样本数和预测样本数，监测各项运行数据，当累积误差较大时，及时更新 ANN 模型。

ANN 模型的学习过程需要经历数据处理、计算学习和结果输出三个过程，训练数据量的大小会影响学习速度，一般 1000 组数据的整个学习过程需要经历 5 分钟，如果频繁进行学习，会影响预测速度。因此可以阶段性地进行学习和预测。要划定这个阶段就要分析一定量的训练数据可以准确预测多久以后的冷却塔运行性能。

冷却塔运行性能的实时监测数据为每隔 6 分钟记录一组数据。以一天工作 8 小时计算，200 组数据约能反映 2.5 个工作日的运行情况，1000 组数据约能反映 12.5 个工作日的运行情况。在已进行的算法校验中，是用前 2 周的实测数据预测后 2 天的运行性能，预测结果良好。以下将测试两种情况：

- A 在训练样本不变的情况下，预测样本增多后预测结果的准确性。
- B 在预测样本不变的情况下，训练样本减少后预测结果的准确性。
- C 根据预测误差及时更新训练样本，实现以误差为基础的在线学习，判定预测准确性。

● 测试A

以上海的校验冷却塔为例，1000 组训练数据得到的 200 组预测结果的精度不超过±1.5℃。当使用相同的训练数据，而将预测样本扩大至 400，600，800，1000。这些预测样本的采样时间是连续，它们的预测结果见图 6-1



图 6-1 预测结果

上图中黄色所标记的温度范围为训练样本中出塔水温的变化范围。由此可见，预测样本中的部分数据已经超出了训练范围。下表详细对比了不同预测样本的数值范围和预测误差。

表 6-1 不同预测范围的预测结果对比

预测样本序号	输入数据数值范围				预测绝对误差平均值	预测值和实测值之间的相关系数
	进塔水温	出塔水温	湿球温度	水气质量比		
1~200	27.90~31.94	24.89~26.72	19.65~21.28	0.63~1.73	0.16	0.72
201~400	28.59~32.59	24.39~28.78	20.03~24.18	0.35~2.00	0.20	0.68
401~600	31.18~34.43	27.18~29.81	22.25~24.81	0.39~2.37	0.10	0.85
601~800	26.36~32.28	22.99~29.38	18.02~22.34	0.39~1.86	0.53	0.55
801~1000	26.29~33.61	22.07~29.76	16.70~19.07	0.23~1.57	-0.01	0.42
训练样本	29.02~36.35	25.06~32.16	20.98~25.46	0.29~2.65		

表 6-1 所示的是不同预测样本的数值范围、预测误差和其与训练样本之间的数据对比。从表中可知：

- 1) 预测样本中的个别数据已经超出了训练样本的数值范围。第 1~200 组数据与训练样本的采样时间最接近，它与实测值之间吻合得较好。第 401~600 组数据和训练样本数据的数字范围最接近，它的预测误差也相对最小。
- 2) 比较第 1~200 组和第 601~800 组测试结果可知，预测样本的进塔水温是否超出学习范围，超出范围有多少，对于预测的准确性影响最大。湿球温度的变化受到了气候的影响，全年变化有一定的周期性规律。当进入 9 月份以后，湿球温度会随着日期的推移逐渐降低。但与进塔水温相比，湿球温度对于出塔水温的影响较低（表 4-1）。
- 3) 第 601~800 组和第 801~1000 组预测结果与实测值之间有显著的偏差，两种的输入参数也与训练阶段的数值有较大的偏差，这种偏差是影响预测结果准确性的主要原因。由于预测阶段的时间变长，进塔水温、湿球温度和水气质量比都会随着天气和空调使用情况发生改变，已经超出了 ANN 模型的学习范围，因此网络无法给出准确的预测结果。

综上所述，预测样本所覆盖的时间不宜过长。用前 2 周的实测数据预测未来 1 周内的性能，其准确性还在可接受的范围内。进塔水温对于出塔水温的影响最大，如果由于负荷或工艺需求，进塔水温发生大范围波动时，应当缩短预测周期。

● 测试B

以上海的校验冷却塔为例，1000 组训练数据对未来 200 组数据的预测误差在可接受的范围内。当使用相同的预测数据而将训练样本缩小至 800, 600, 400,

200 后的预测结果见图 6-2。




图 6-2 预测结果

从图中可以看出，用数量不同的训练集训练的 ANN 模型虽然都能预测出塔水温的变化趋势，但预测值的上下限受到训练数据的限制，训练样本越大，预测结果越接近实测值。

表 6-2 不同训练范围的预测结果对比

训练样本序号	输入数据数值范围				预测绝对误差平均值	预测值和实测值之间的相关系数
	进塔水温	出塔水温	湿球温度	水气质量比		
1~1000	29.02~36.35	25.06~32.16	20.98~25.46	0.29~2.65	0.16	0.72
201~1000	30.71~36.35	26.39~32.16	20.98~25.46	0.29~2.65	0.84	-0.24
401~1000	30.71~36.35	26.39~32.16	20.98~25.46	0.29~2.65	0.61	0.35
601~1000	30.71~36.06	26.39~28.94	20.98~25.46	0.30~2.65	0.51	0.16
801~1000	30.71~34.93	26.39~28.94	20.98~23.22	0.49~2.65	0.5	0.41
预测样本	27.90~31.94	24.89~26.72	19.65~21.28	0.62~1.73		

表 6-2 所示的是不同训练样本的数值范围、预测误差和其与预测样本之间的数据对比。从表中的数据可以看出，预测误差随着训练样本的减少而增加。

综上所述，要得到最佳的预测结果，至少要用过去 1000 组实测数据进行学习。

● 测试C

训练样本集的容量仍为 1000 组数据，但需要根据预测误差判断是否要更新

训练样本并重新训练 ANN 模型。

在测试 A 中发现，即使预测阶段输入数值的范围略超过训练阶段，预测结果仍能保证一定的准确性，但当数值范围发生严重偏离时，就无法准确预测，这时就需要重新学习。因此，尝试采用非固定的在线预测周期，以预测误差为依据，判断是否要重新学习。

假设每小时观察一次预测误差，如果一小时内的累积绝对误差超过了一定限度，那就需更新 ANN 模型。校验冷却塔运行一小时约能记录 10 组数据，误差的判定依据如下：

$$\text{累积误差} = \sum_{i=1}^{10} |\text{预测值} - \text{实测值}| \quad (6-1)$$

如果，累积误差>10，则需要更新 ANN 模型，否则继续预测。

当按序输入 400 组数据，预测到第 188 组数据时，累积误差超过 10，ANN 模型更新后重新预测，此后，预测到第 270 组数据时，有更新了一次模型。最终，这 400 组数据的预测结果见下图：




图 6-3 400 组数据的预测结果-温度变化趋势图

表 6-3 预测误差

	最大值	最小值	平均值	标准差
绝对误差 (°C)	+1.33	-0.63	+0.23	0.46
相对误差 (%)	+5.46	-2.37	-0.90	1.79
-0.63°C < 绝对误差 < +1°C 的出现频率			95.5%	




图 6-4 预测结果-预测值与实测值对比

如图 6-4 所示，第 318 组以后的预测数据和实测值吻合得较好，这说明，网络通过不断的学习修正，能更好地追踪出塔水温的变化趋势。整体而言，这 400 组预测值和实测值之间的相关系数为 0.74，。最大预测误差不超过 $\pm 1.4^{\circ}\text{C}$ ，误差的离散程度较小，与测试 A 的预测结果相比，测试 C 更理想。

6.2. 在线预测步骤

通过以上研究可以得出以下几个结论：

- 1) 冷却塔进塔水温、空气湿球温度、冷却水和进塔空气质量流量比是影响出塔水温的三个主要因素，其中进塔水温的影响作用最大。
- 2) 用四层 BP 神经网络预测机械通风开式冷却塔出塔水温的方法是可行的。
- 3) 训练样本和预测样本的数量对预测的准确性有影响，训练样本越多、预测样本越少且训练样本数值范围完全覆盖预测样本时，预测越准确。如果能够根据预测误差判断是否要更新预测模型，那么会提高预测的准确度。

由以上三个结论就可以确定冷却塔运行性能在线预测的学习对象、核心学习方法和在线学习周期。

在线预测的实现可以分成四个阶段，第一个是前期调研阶段，在这个阶段内需要搜集冷却塔的样本信息，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基础的实测数据。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,不间断输出预测数据。具体流程如下图所示:




图 6-5 机械通风开式冷却塔运行性能在线预测流程

6.3. 在线预测结果

将上一节中所提出的在线预测流程应用到上海的校验冷却塔,经过一个月的

运行后，2000 组出塔水温的预测值和实测值的对比结果见图 6-6 和图 6-8。




图 6-6 未来 5000 组数据的在线预测结果-温度变化趋势图




图 6-7 未来 5000 组数据在线预测绝对误差频率分布图




图 6-8 未来 5000 组数据在线预测结果-预测值与实测值对比

表 6-4 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			87.2%	

统计显示，使用在线学习的方法对未来 2000 组数据进行预测，得到的最大预测误差未超过 $\pm 3.3^{\circ}\text{C}$ ，有 87.2% 的预测误差未超过 $\pm 1^{\circ}\text{C}$ ，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。满足工程上对于出塔水温预测的误差控制要求，预测结果良好。

第7章. 总结与展望

本文主要分析并探索了针对机械通风开式冷却塔运行性能的在线预测方法。研究中, 选用出塔水温来表征冷却塔的运行性能, 重点分析了进塔水温、湿球温度、水气质量比三个参数对出塔水温的影响, 并用这三个参数预测出塔水温。

本文使用四层 BP 神经网络模型对冷却塔出塔水温进行在线学习和预测, 建模过程中所使用的数据来自实际运行中的机械通风逆流冷却塔。在确定模型有效后, 着重探讨了如何处理实际运行时易发生的运行工况突变情况。最后, 用另一组机械通风横流冷却塔的运行数据校验模型, 并在该组冷却塔上进行在线预测测试。

通过研究可以得出以下结论:

- 进塔水温、空气湿球温度、塔内冷却水和空气的质量流量比是决定出塔水温的关键因素, 其中进塔水温对于出塔水温的影响最大。
- 采样周期对于预测的准确性有影响。合适的采样周期即可以客观地反映冷却塔的运行性能, 也可以快速剔除工况突变点, 降低工况突变对 BP 神经网络稳定性和预测准确性的影响。不同冷却系统的采样周期各不相同, 需要根据运行数据的变化规律确定。
- 四层 BP 神经网络能够快速、准确地预测机械通风开式冷却塔的运行性能。从数据处理到输出预测结果, 1000 组数据的在线预测耗时约为 5 分钟。就已测试的冷却塔而言, 出塔水温在线预测值与实测值之间最大预测误差未超过 $\pm 3.3^{\circ}\text{C}$, 有 87.2% 组数据的预测误差未超过 $\pm 1^{\circ}\text{C}$, 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。满足工程上的误差控制要求, 预测结果有效。

本研究首次利用了四层 BP 神经网络对冷却塔运行性能进行在线预测, 与已有的三层 BP 网络的结构相比, 四层 BP 网络能够更好地追踪冷却塔间断运行和工况突变时的出塔水温。这种在线学习方法利用训练数据样本把不同冷却塔中填料、风机、布水器等部件的特性记忆到 ANN 模型中。与基于物理过程的热力计算方法相比, 这种方法既避免了详细讨论冷却塔的结构和部件特性, 也避免求解繁琐的积分公式, 这些优点都决定了它能够快速、准确、有效地预测冷却塔出塔

水温。然而，这个方法也存在一定的特殊性，由于 ANN 只是一种基于数据的算法，它不是一个通用的热力性能计算公式。要得到准确的预测结果，就必须先获得实测数据。不同冷却塔都需要根据它自身的运行情况，来确定合适的采样周期和数据处理方法。因此，在预测前期，必须开展调研、实测、试运行等工作，以获得有效的训练数据样本。学习阶段和预测阶段的数据必须来自同一组冷却塔。

这种快速、准确但又独特的在线预测方法，可以用于冷却塔的模拟试验，预测不同气候条件下，冷却塔的运行性能。也可以和冷水机组等设备的模型结合，辅助暖通空调系统的运行监测、故障诊断和优化控制。未来的研究可以深入探讨这种方法的应用方式，或将其与其他设备模型进行整合，形成完整的暖通空调系统运行性能预测方法。

致谢

感谢学校为我提供了良好的学习氛围和丰富的学习资源,使我能通过各种途径学习、补充所欠缺的知识。感谢院、校各位领导对于学生毕业论文工作的重视,为我提供了很多便利的条件。感谢老师们的教导与帮助,使我能学习到丰富的知识和经验。是你们用智慧和辛勤的劳动,把我领入了科学的殿堂,培养我对专业的兴趣;对学习的钻研精神;对科研工作的负责态度,真正成长成了一名研究生。

在课题研究过程中,特别要感谢潘毅群老师和黄治钟老师对我的耐心教导和帮助。潘毅群老师学术造诣深厚,科研经历丰富,无论在学习还是生活中,都给予我莫大的关心和帮助。黄治钟老师风趣幽默,思维敏捷,在本论文的撰写过程中给了我宝贵的灵感和建议。最后还要感谢我的师兄左明明以及我的同学、朋友,正是有了他们的帮助,我才能顺利完成课题研究。

再次对所有帮助过我的老师和同学表示衷心的感谢!

参考文献

- [1] F.Merkel, Verdunstungskühlung[D], VDI Forschungsarbeiten, 1925(in German)
- [2] A.L.London, W.E.Mason, and L.K.Boelter, Performance Characteristics of a Mechanically Induced Draft, Counterflow, Packed Cooling Tower[J],Trans.ASME,1940,62,pp.41-50
- [3] S.M.Zivi, B.B.Brand, An Analysis of the Cross Flow Cooling Tower[J], Refrigeration Engineering, 1956
- [4] G.Yadigaroglu, and E.J.Pastor, An Investigation of the Accuracy of the Merkel Equation for Evaporative Cooling Tower Calculations[J], ASME Paper,1974
- [5] N.W.Kelly, Kelly's Handbook of Crossflow Cooling Tower Performance[M], Kansas City, Missouri: Neil W. Kelly and Associates, 1976
- [6] Amir N. Nahavandi, Rashid M. Kershah, Benjamin J. Serico, The Effect of Evaporation Losses in the Analysis of Counterflow Cooling Tower[J], Nuclear Engineering and Design, 1975, 32(1), 29-36
- [7] M.Poppe, H.Rögener, Berechnung von Rückkühlwerken[J], VDI-Wärmeatlas, 1991, 1-15(in German)
- [8] J.C.Kloppers, D.G.Kröger, Cooling Tower Performance Evaluation: Merkel, Poppe, and e-NTU Methods of Analysis[J], Journal of Engineering for Gas Turbines and Power, 2005.127,1-7
- [9] J.W.Sutherland, Analysis of Mechanical-Draught Counterflow Air/Water Cooling Towers[J], Journal of Heat Transfer-transactions of The Asme, 1983.105
- [10] H.Jaber, R.L.Webb, Design of cooling towers by the effectiveness-NTU method, Journal of Heat Transfer 1988.111.837-843
- [11] J.E.Braun. Methodologies for Design and Control of Central Cooling Plants. Ph D Thesis[D], Department of Mechanical Engineering, University of Wisconsin-Madison, 1988
- [12] A.E.Feltzin, D.J. Benton, A More Nearly Exact Representation of Cooling Tower Theory[R],Houston, Cooling Tower Institute, 1991
- [13] F.Osterle, On the Analysis of Counter-flow Cooling Towers[J], International Journal of Heat and Mass Transfer, 1991.34(4-5),1313-1316
- [14] H.T.A.EL-Dessouky, A.AL-Haddad, F.AL-Juwayhel, A Modified Analysis of Counter Flow Wet Cooling Towers[J], Journal of Heat Transfer, 1997, 119(3), 617-626
- [15] MA Bernier, Cooling Tower Performance: Theory and Experiments[J], ASHRAE Transactions, 1994, 100, 114-121
- [16] E.de Villiers and D.G.Kröger, Analysis of Heat, Mass and Momentum Transfer in the Rain Zone of Counterflow Cooling Towers[J], Journal of Engineering for Gas Turbines Power, 1999,121(4),751-756
- [17] Nenad Milossavlijevic, Pertti Heikkila, A Comprehensive Approach to Cooling Tower Design[J], Applied Thermal Engineering, 2001,21(9), 899-915
- [18] 赵正国, 石金陵, 周常虹, 滕新军,冷却塔的一个新的热力计算方法——用一维方法作二维计算[J], 水利学报, 2002,2
- [19] 周兰欣,蒋波,叶云飞, 湿式冷却塔热力性能数值分析[J], 华北电力大学学报, 2009,36(1), 53-58
- [20] 孟华, 龙惟定, 王盛卫, 适于系统仿真的冷却塔模型及其实验验证[J],暖通空调,2004, 34(7),1-5

- [21] Guang-Yu Jin, Wen-Jian Cai, Lu Lu, Eng lock Lee, Andrew Chiang. A Simplified Modeling of Mechanical Cooling Tower for Control and Optimization of HVAC Systems[J], Energy Conversion and Management, 2007,48,355-365
- [22] Soteris A.Kalogitou. Applications of Artificial Neural-networks for Energy Ssystems[J]. Applied Energy, 2000,67,17-35
- [23] 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
- [24] 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
- [25] 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, 2009,48,583-589
- [26] 廉乐明, 谭羽非, 吴家正, 朱彤, 工程热力学(第五版)[M], 北京: 中国建筑工业出版社, 2007
- [27] 赵振国, 冷却塔[M], 北京: 中国水利水电出版社, 2001
- [28] 史佑吉, 冷却塔运行与试验[M], 北京: 中国水利水电出版社, 1990
- [29] 中国工程建设标准化协会化工分会, 机械通风冷却塔工艺设计规范 GB/T 50392-2006[S],2006
- [30] CTI, Cooling Tower Performance Curves[S], The Cooling Tower Institute, Houston 1967
- [31] 章熙民, 任泽霏, 梅飞鸣, 传热学(第五版)[M], 北京: 中国建筑工业出版社, 2007
- [32] L.D.Berman, Evaporative Cooling of Circulating Water, 2nd Edition[M],New York, 1961
- [33] F.Bosnjacovic, Technische Thermodynamik[M], Theodor Steinkopf, Dresden,1965(in German)
- [34] J.C.Kloppers, D.G.Kröger, A Critical Investigation into the Heat and Mass Transfer Analysis of Counterflow Wet-cooling Towers[J], International Journal of Heat and Mass Transfer 2005,28, 765-777
- [35] C.Bourillot, On the Hypothesis of Calculating the Water Flowrate Evaporated in a Wet Cooling Tower[R], EPRI Report CS-3144-SR, August 1983
- [36] DOE-2 Energineers Manual(Version 2.1A)[R], Energy and Environment Division Building Energy Simulation Group, Lawrence Berkeley Laboratory, University of California, and Group Q-11, Solar Energy Group, Energy Division, Los Alamos National Laboratory, 1982, V45-68
- [37] TRNSYS, TRNSYS 16.1: A Transient Simulation Program[R], University of Wisconsin, Madison,USA,2007
- [38] Type 51: Cooling Tower, TRNSYS 16-Mathematical Reference[R], University of Wisconsin, Madison, USA,2007
- [39] ASHRAE, ASHRAE Equipment Guide[M],American Society of Heating, Refrigerating, and Air Conditioning Engineers, Atlanta,USA,1983.
- [40] W.M.Simpson, T.K.Sherwood, Performance of Small Mechanical Draft Cooling Towers[J], Refrigeration Engineering, 1946
- [41] 李永安, 《空调用封闭式冷却塔》 [M].北京: 中国建筑工业出版社,2008
- [42] 刚文杰,王劲柏, 基于神经网络的冷却塔出水温度的预测[C], 全国暖通空调

制冷 2010 年学术年会资料集,2010

- [43] Roberto Moreno-Díaz, Arminda Moreno-Díaz, On the Legacy of W.S.McCulloch[J], Biosystems, 2007,88(3),185-190
- [44] Steven J. Cooper, Donald O. Hebb's Synapse and Learning Rule: A History and Commentary[J], Neuroscience & Biobehavioral Reviews, 2005, 28(8),851-874
- [45] F.Rosenblatt, The Perceptron: A probabilistic Model for Information Storage and Organization in the Brain[J], Psychological Review, 1958,65(6),386-408
- [46] B.Widrow, M.E.Hoff, Adaptive Switching Circuits[J], IRE WESCON Convention Record, 1960,4,96-104
- [47] T.Kohonen, Correlation Matrix Memories[J], IEEE Transactions on Computers, 1972, 21, 353-359
- [48] J.Hopfield, Neural Networks and Physical Systems with Emergent Collective Computational Abilities, Proceedings of the National Academy of Sciences of the United States of America, 1982,79,2554-2558
- [49] J.L.McClellan, D.E.Rumelhart, Neural Network Programs (Book Reviews: Explorations in Parallel Distributed Processing)[J], Science,1988,241,1107-1108
- [50] 傅荟璇, 赵红, MATLAB 神经网络应用设计[M], 北京: 机械工业出版社, 2010
- [51] 王旭, 王宏, 王文辉, 人工神经网络原理与应用(第二版)[M], 沈阳: 东北大学出版社, 2007
- [52] 吴秉礼, 李文渊, 轴流通风机的工程设计方法[M], 长春: 吉林大学出版社, 2007
- [53] 中国有色金属工业总公司,采暖通风与空气调节设计规范 GB50019-2003[S], 2003
- [54] 王庆河,王庆山, 数据处理中的集中常用数字滤波算法[J], 计量技术, 2003(4).
- [55] 费业泰, 误差理论与数据处理(修订本)[M], 北京:机械工业出版社,1987
- [56] 李威,用于建筑环境设计的冷水机组数学模型[D],武汉,武汉纺织大学硕士学位论文,2011.3
- [57] 李苏泷,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
- [58] 中华人民共和国国家质量监督检验检疫总局,中国国家标准化管理委员会, 冷水机组能效限定值及能源效率等级 GB19577-2004[S], 2004
- [59] 李含光,赵晓瑜,高宝建,吴昊, 基于四层 BP 神经网络的催化剂活性图像识别[J], 武汉理工大学学报, 2010,8,68-71
- [60] 焦李成,神经网络系统理论[M],西安:西安电子科技大学出版社,1996
- [61] 飞思科技产品研发中心,神经网络理论与 MATLAB7 实现[M],北京:电子工业出版社,2005

个人简历、在读期间发表的学术论文与研究成果

个人简历:

徐哲恬, 女, 1988 年 6 月生。

2010 年 7 月, 毕业于同济大学建筑环境与设备工程专业, 获工学学士学位。

2010 年 9 月入同济大学动力工程专业攻读硕士研究生。

已发表论文:

- [1] Y.Q.Pan, Y.M.Li, Y.M.Qin, Z.T.Xu, Energy Modeling of Prototypical Shopping Malls in Shanghai[C], 7th International Symposium on Heating, Ventilating and Air Conditioning-Proceedings of ISHVAC 2001, 2011,4,1183-1188

待发表论文:

- [1] 徐哲恬,潘毅群,李玉明,邓小茜, 基于能耗模拟的某校园供冷供热系统规划[J], 建筑节能, 2013,3(已录用)