



人工神经网络算法 在光伏发电短期功率预测中的应用

■ 张一平^{1,2} 宋红³ 罗敏⁴ 于佳禾^{1,2} 许盛之^{1,2*}

(1. 南开大学光电子薄膜器件与技术研究所; 2. 天津市光电子薄膜器件与技术重点实验室;
3. 中机华信诚电力工程有限公司; 4. 南开大学财务处)

摘 要: 对近年来国内外利用人工神经网络进行光伏发电短期输出功率预测的研究进展进行了介绍, 为相关预测研究提供了参考。

关键词: 人工神经网络; 光伏发电; 功率预测

0 引言

随着光伏发电技术的快速发展, 光伏发电在能源供给中的占比也有较大提高。光伏发电系统的输出功率对外界环境的依赖性较高, 接入电网时, 会因光照、温度等环境因素的变化而造成光伏发电系统输出功率的波动, 从而对电网的稳定造成一定冲击, 影响其电能质量。光伏发电系统的渗透率越高, 电力系统的复杂性与风险也就越大。因此, 对光伏发电的输出功率进行准确预测有助于调度部门提前做好调度计划和风险规避, 以提高电力系统的安全性及光伏发电的竞争力^[1]。

相对于传统的预测算法, 人工神经网络(Artificial Neural Network, ANN)具有良好的容错性, 泛化能力好, 适于拟合复杂的非线性关系, 应用领域广泛, 是当前许多工程领域的研究热点。如今, ANN已成功应用于与工业自动化相关的诸多领域, 如模式识别、信号处理、知识

工程、专家系统、优化组合、智能控制等^[2]。在利用ANN进行预测算法的研究中, 需要通过建立组合模型、优化输入神经元结构、改进网络内部算法等方式来解决实际的预测问题^[3]。

1 预测算法简介

光伏发电功率预测是以数值天气预报(Numerical Weather Prediction, NWP)的数据或实测数据为基础, 结合光伏电站所在地的经纬度、海拔高度及具体的地域特点建立预测模型及算法, 实现对未来一定时间段内光伏电站输出功率的预测。根据预测时间的长短及应用范围的不同, 光伏发电系统输出功率的预测可划分为3类: 超短期功率预测、短期功率预测及中长期光伏功率预测^[4]。各类别的预测时间及主要用途如表1所示。

1.1 超短期功率预测与中长期功率预测

我国电力部门对超短期功率预测的考核标

收稿日期: 2018-06-13

通信作者: 许盛之(1978—), 男, 高级工程师, 主要从事光伏系统与工程技术方面的研究。xusz@nankai.edu.cn

表 1 光伏发电功率预测分类

类别	预测时间	主要用途
超短期功率预测	15 min ~ 4 h	主要用于电力部门调度
短期功率预测	1 ~ 3 d	主要用于常规光伏发电系统发电计划的安排、节能调度、安全评估等
中长期功率预测	4 d 以上	主要用于光伏发电系统与输出线路的检修、电站规划

准为自报时次起的第 4 个小时的预测结果，主要用于电力部门调度。针对超短期功率预测，目前国内外主要采用基于数值天气预报和中尺度卫星观测云图的方法^[5]、支持向量机的方法^[6]、卫星云图与人工神经网络相结合的方法^[7]。特别是卫星云图与人工神经网络相结合的方法，在对 100 MW 光伏电站的预测中取得了较好效果，为以后的超短期功率预测提供了较好的方法。

中长期功率预测主要是可为光伏发电系统与输出线路的检修及电站的建设提供参考，并可根据数值天气预报的数据或当地的历史光照资源数据等信息，估算未来较长时间段内的光伏发电功率情况。

1.2 短期功率预测

光伏电站的短期功率预测对于电力管理部门的发电计划安排具有重要意义。短期功率预测包括间接预测法和直接预测法两种预测方法^[8]。

间接预测法需要建立两个预测模型，即当地的辐射预测模型与电站发电功率模型。首先建立辐射预测模型，并将该模型的计算结果作为输入条件供光伏电站发电功率模型使用，以计算未来时间段内的输出功率。

直接预测法主要是建立一个复杂的光伏发电系统的模型进行预测。该模型是以历史气象数据和发电功率数据等作为模型的输入信息，直接给出光伏发电系统的输出功率。

间接预测法与直接预测法的流程如图 1 所示。

1.3 预测精度评价指标

统一有效的预测精度评价指标有利于比较不同预测方法的效能。预测方法的评价指标一般有

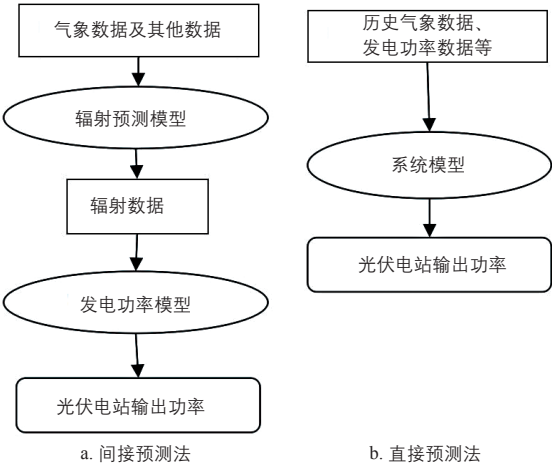


图 1 间接预测法与直接预测法流程图

5 个，具体如表 2 所示，其中，假设 X 为实测值、 \hat{X} 为预测值、 N 为样本数量^[9]。

2 神经网络在短期功率预测中的应用

2.1 人工神经网络 (ANN)

ANN 是一种运用类似于大脑神经突触联接的结构进行信息处理的数学模型，由大量的神经元节点和节点之间相互联接构成，一般由一个输入层、若干个隐藏层和一个输出层组成，每一层由若干个神经元构成^[10-11]。图 2 以人工神经元与反向传播 (BP) 神经网络的基本结构图为例，其中 BP 神经网络的输入层包括 5 个神经元，2 个隐藏层分别包含 3 个和 4 个神经元。人工神经元节点代表一种特定的输出函数，称为激励函数；每 2 个节点间的连接都代表 1 个对于通过该连接信号的加权值，称之为权重。ANN 的使用需要进行结构设计、训练和计算 3 个步骤。结构设计完成之后，该神经网络的层次结构和神经元的激励函数不能再改变，使用大量样本数据进行训练后，网络中各神经元节点的权重逐渐优化，当网




表 2 预测算法的评价指标

参数	公式	意义与作用
均方根误差 e_{RMSE}	$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{X}_i - X_i)^2}$	反映模型的预测值中特大值或特小值对整体预测的影响
平均绝对误差 e_{MAE}	$e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N \hat{X}_i - X_i $	反映模型单个预测值与实际值的偏差，即预测结果在绝对尺度上与实际值的距离有多接近
平均误差 e_{RMBE}	$e_{\text{RMBE}} = \frac{1}{N} \sum_{i=1}^N (\hat{X}_i - X_i)$	指在等精度测量中，测得的所有测量值的随机误差的算术平均值；用于反映模型整体的预测值与实际值之间的偏差
相关系数 ρ	$\rho = \frac{[\text{cov}(\hat{X}, X)]^2}{\text{var}(X) \text{var}(\hat{X})}$	是研究变量之间线性相关程度的量，相关系数越接近 1，说明模型的预测效果越好
标准差 e_{SDE}	$e_{\text{SDE}} = \left(\frac{1}{N-1} \sum_{i=1}^N (e_i - \bar{e})^2 \right)^{\frac{1}{2}}$	反映一个数据集的离散程度

备注：cov 表示协方差；var 表示方差； e_i 为预测值与实测值的差。

络能够输出一定准确率的结果时，就认为训练成功；此时，可以利用网络进行推理计算。

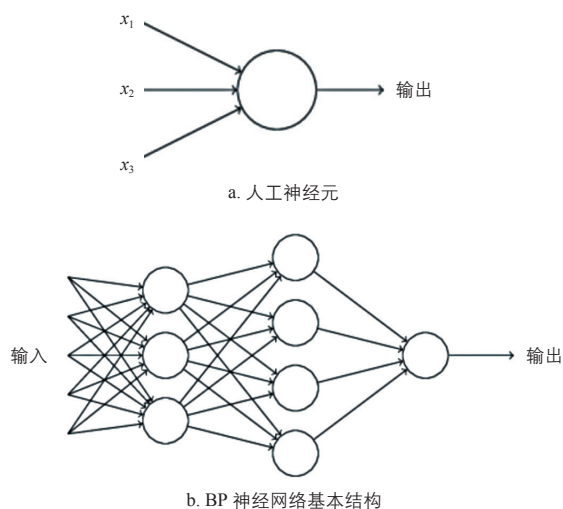


图 2 人工神经元与 BP 神经网络基本结构

2.2 神经网络在间接预测法中的应用

在间接预测法中，第一阶段的重点为建立辐射预测模型。人工神经网络算法很早就被用于建立辐射预测模型，并对此进行了大量的研究，有多种模型被用于太阳辐射的预测。表 3 是采用不同结构模型的人工神经网络或相同结构下输入不同参数时的预测效果对比。Mubiru 等^[12]较早采

用的 BP 神经网络模型中，辐射强度、经纬度、海拔、日照时间、相对湿度和最高温度等因素均被考虑在内，预测结果中相关系数达到 0.997，这说明其对于晴朗天气条件下的辐射强度预测取得了很好的效果。由于阴天比晴天的气象复杂，Mellit 等^[13]将阴天与晴天分开进行了预测，采用隐藏层的 MLP 对意大利某处电站实现了阴天时较好的预测。

但是模型过于复杂时，例如输入维度过大、噪音过多时，将出现“过度拟合”问题，使得模型在训练集上表现出较好的预测结果，然而在进行实际预测时，预测结果却很差^[19]。因此，通过交叉验证和采用 BNN 有助于解决过度拟合。例如，王哲等^[14]采用交叉验证的方法，建立了数个基于 BP 神经网络和时间序列的短期太阳辐射预测模型，通过比较不同的网络结构并进行交叉验证，获得了最适合的神经网络，从而避免了过度拟合。

同样，Yacef 等^[15]采用 BNN 解决了过度拟合问题。BNN 对神经网络的权值向量赋一个先验分布，这样可以有效避免网络在初期样本较少时出现过度拟合的问题。后期训练中，随着样本的逐




表 3 不同结构模型或相同模型下不同参数时的人工神经网络预测辐射效果对比

模型	输入参数	相关系数	均方根误差	平均误差	平均绝对误差	标准差
BP 神经网络 ^[12]	辐射强度、经纬度、海拔、日照时间、相对湿度、最高温度	0.997	—	0.018	—	0.131
多层感知器 (MLP) ^[13]	太阳辐射、空气温度	晴天: 0.990~0.999 阴天: 0.900~0.920	—	—	<0.05	—
BP 神经网络 ^[14]	相对湿度、日照时间、太阳辐射、空气温度	0.990	0.033	—	0.013	—
贝叶斯神经网络 (BNN) ^[15]	长期气温、日照时间、相对湿度、太阳辐射	0.970	0.084	0.0306	0.059	—
径向基函数神经网络 (RBFNN) ^[16]	日照时间、空气温度	0.980	0.013	0.0087	—	—
BP 神经网络 ^[17]	小波分析法处理后的太阳辐射	—	—	—	0.7193	—
	无小波分析法处理的太阳辐射	—	—	—	2.8168	—
建设性神经网络 (CoNN) ^[18]	温度、湿度、风速、天气类型	—	0.079	—	0.1623	—

步增加，BNN 的正则化系数会随着训练进行调整，并能自动调整重要的输入变量权值的后验分布，使概率达到最大化，从而提高预测精度，网络泛化能力也随之得到提升。与经典的神经网络和经验模型相比，BNN 在利用长期气温、相对湿度、日照时间和太阳辐射的输入参数来预测每天的全球太阳辐射时，能达到相关系数 0.97 的良好精度。

激活函数的选择也是影响预测精度的关键因素。BP 神经网络中一般使用 sigmoid 函数作为激活函数，其作用就是引入非线性，但存在饱和时梯度太小的缺点。RBFNN 采用径向基函数作为激活函数，结构简单，并且非随机进行参数初始化，使其收敛速度快且在理论上具有任意函数逼近能力^[20]，有利于提高预测精度。例如，Benghanem 等^[16]利用 RBFNN 预测每天的全球太阳辐射，输入参数包括空气温度、日照时间和相对湿度等气象数据。该文献介绍了其所开发的径向基函数 (RBF)、MLP 和传统回归模型之间的比较研究，结果显示，在负荷损失率为 1% 时开发的 RBF 模型有效。

不仅是采用改进型的模型可以显著提高辐射的预测精度，若对样本数据进行预处理，同样可以达到较好的效果。Cao 等^[17]提出了一种基于小波分析的小波分析方法，将太阳辐射的样本数据序列分解为各种时间频率域的几个分量，然后利用重复的 BP 神经网络对基于这些分量的所有域进行预测，最后给出它们的代数和。在 BP 神经网络相同的情况下，小波分析预测的平均绝对误差为 0.7193，是无小波分析时 2.8168 的近 1/4。

在上述工作中，无论采用何种人工神经网络模型，都是经过长时间的试错过程得到隐层单元数。更重要的是，对于隐层单元较多的神经网络训练时不能保证有效且充分地学习所需的映射。为了减少神经网络的训练时间，找到一个有能力和紧凑的神经网络，Ma 等^[18]提出了一种基于 CoNN 的新的太阳辐射预测方法。在模型训练过程中，从单个隐层单元开始，然后在需要增强网络映射能力时每次添加一个隐层单元，最终获得一个有效的最小神经网络 (NN)。以这种方式获得的神经网络基本上可实现级联相关性，被称为



CoNN。从预测结果来看,均方根误差为 0.0791,虽然有待进一步改进,但为今后的相关研究开辟了新的思路。

准确地预测太阳辐射是间接预测的第一步,还需建立发电功率预测模型,以实现光伏电站发电功率的预测。结合气象数据、电站自身参数和历史发电功率,通过经验公式和统计学公式的计算,最终得到电站发电功率预测值,如图 3 所示。




图 3 发电功率预测模型原理图

发电功率预测模型也存在着以下问题: 1) 电站的实际情况相对复杂,公式不能覆盖所有影响

因素。2) 太阳辐射模型与发电功率模型均会产生预测误差,二者误差相互影响必然导致最终结果出现较大偏差。3) 电站设备存在随时间的推移而老化的现象,电站自身参数的变化会引起预测精度下降。这些问题有待进一步地研究解决。

2.2 人工神经网络在直接预测法中的应用

不同于间接预测法,直接预测法采用较为简单的建模方式,只建立一个模型进行预测,并且将电站内部的诸多因素考虑在内。将人工神经网络运用于直接预测法比运用于间接预测法晚^[21]。仅依靠改变神经网络学习率选取的方法显然不足以应对影响因素复杂的直接预测法。表 4 为不同模型的人工神经网络在直接预测法中的预测效果对比。

表 4 不同模型的人工神经网络或在直接预测法中的预测效果对比

模型	输入参数	天气状况	相关系数	平均绝对误差	均方根误差
BP 神经网络 ^[22]	气溶胶指数	—	—	0.0765	—
前馈神经网络 (AFFNN) ^[23]	太阳辐射、 电池温度、 电池输出功率	晴天	0.9986	0.0192	—
		部分阴天	0.9981	0.0356	—
		阴天	0.9850	0.0167	—
RBFNN ^[23]		晴天	0.9910	0.0230	—
		部分阴天	0.9910	0.0467	—
		阴天	0.9800	0.0245	—
循环神经网络 (DRNN) ^[23]		晴天	0.9965	0.0528	—
		部分阴天	0.9923	0.1098	—
		阴天	0.9878	0.0628	—
GA- 模糊 RBF ^[24]	辐射强度、温度	—	—	0.1630	0.0520
自组织特征映射 (SOM)+BP ^[25]	辐射强度、大气温度、 风速	—	—	0.0722	0.0251
遗传算法 BP 神经网络 ^[26]	辐射强度、环境温度、 历史发电功率	—	—	<0.1000	—

在直接预测法中,气象条件多成为影响预测精度的关键因素,若将所有气象因素都作为预测模型的输入变量,势必导致模型复杂度增加、收敛速度变慢;若将诸多的气象条件采用一种数据进行表达,则会提高预测精度。Liu 等^[22]采用了气溶胶指标作为预测未来 24 h 光伏电源输出的

附加输入参数,而未将辐射强度等作为输入参数。实验结果表明,这种基于 BP 神经网络的新型光伏电力预测模型比传统的考虑温度、湿度和风速的方法更好。

但是采用单一光伏发电预测模型也存在弊端,当天气类型发生转变时,神经网络稳健性的



优势可能会对性能产生反作用,因为它有可能会将天气突变视为异常值,并会逐渐减小对输出平滑性的影响^[27]。

针对不同气象条件下电力输出的预测有较大区别这一特点,针对每一种天气进行建模是提高预测准确度的有效方法。例如, Mellit 等^[23]建立了 3 种不同的人工神经网络,以适应 3 种典型的天气状况(阳光、部分多云、阴天),用于短期预测一个位于意大利南部的大型光伏电站所产生的电力。这种方法极大地提高了预测精度,尤其是晴天预测值的平均绝对误差在 4% 以下。

然而利用人工方法对不同的气象条件进行区分不仅成本高,而且效率低。针对这类问题,叶林等^[24]提出了利用 K 均值聚类的机器学习算法对气象条件进行聚类,并且建立了 GA-模糊 RBF 神经网络预测模型进行功率预测。功率预测结果的平均绝对误差为 16.3%,精度相对于未经过聚类的模型较好,但是仍有较大的改进空间。代倩^[25]提出了利用 SOM 神经网络对不同季节的气象数据进行聚类分析,利用分析结果对相应的 BP 网络进行功率预测。结果显示,通过 SOM 神经网络进行分析后,预测精度有了明显的提升,误差相较于 GA-模糊 RBF 神经网络预测模型也较小。

不仅是气象条件聚类,改进神经网络算法同样可以提高精度。遗传算法是一类借鉴生物界的进化规律(适者生存,优胜劣汰遗传机制)演化而来的随机化搜索方法。Tao 等^[26]利用基于遗传算法的 BP 神经网络,研究了分布式光伏发电功率预测。利用遗传算法方法对 BP 神经网络的权重和阈值进行了优化,提高了 BP 神经网络预测模型的预测精度。基于实验数据的仿真,验证了该方法的有效性,预测值的平均绝对误差降至 10% 以下。

3 结论

人工智能越来越成为工程领域的研究重点,作为人工智能领域的重要分支,人工神经网络的应用也越来越广泛。本文简要概述了人工神经网络

技术在光伏发电短期功率预测方面的应用,对比了直接预测法和间接预测法中的几种模型的预测误差,并介绍了 MLP、BNN、RBFNN、BP 神经网络、遗传算法等技术在光伏发电短期功率预测中起到的作用,为今后相关领域的研究提供了参考。

1) 间接预测法中,太阳辐射的预测精度是该方法的决定性因素。对于人工神经网络模型而言,预防过度拟合,采用新型激活函数和预处理样本数据均能有效地提高预测精度。

2) 直接预测法中,气象条件是该方法的核心影响因素。对气象条件进行综合或分类都能有效提高预测精度。遗传算法的神经网络在复杂气象条件下有着较好的表现。


3) 多云及雨雪天气较为复杂,环境变化速度快,预测精度明显不如晴天。另外,由于早晨与傍晚时段的光照强度较弱,在一定程度上也影响了预测精度。这些问题有待于通过新模型进一步地研究解决。

致谢:

此研究得到了中国三峡新能源有限公司的支持。

参考文献

- [1] 王彬. 基于神经网络的光伏电站功率预测[D]. 北京: 华北电力大学, 2017.
- [2] 汪镭, 周国兴, 吴启迪. 人工神经网络理论在控制领域中的应用综述[J]. 同济大学学报(自然科学版), 2001, 29(3): 357 - 361.
- [3] 龚莺飞, 鲁宗相, 乔颖, 等. 光伏功率预测技术[J]. 电力系统自动化, 2016, (4): 140 - 151.
- [4] 张小萌, 白恺, 柳玉, 等. 大规模分布式光伏短期集群功率预测综述[J]. 华北电力技术, 2017, (6): 1 - 7.
- [5] Taniguchi H, Otani K, Kurokawa K. Hourly forecast of global irradiation using GMS satellite images[J]. Solar Energy Materials & Solar Cells, 2001, 67(1): 551 - 557.
- [6] 王程, 雷金勇, 许爱东, 等. 基于误差分类的分布式光伏超短期功率预测[J]. 南方电网技术, 2015, 9(4): 41 - 46.
- [7] 陈志宝, 丁杰, 周海, 等. 地基云图结合径向基函数人工神经网络的光伏功率超短期预测模型[J]. 中国电机工程学报, 2015, 35(3): 561 - 567.
- [8] 荆博, 谭伦农, 钱政, 等. 光伏发电短期预测研究进展综述[J]. 电测与仪表, 2017, 54(12): 1 - 6.
- [9] NBT 32011-2013, 光伏电站功率预测系统技术要求[S].



- [10] 高隽. 人工神经网络原理及仿真实例 [M]. 北京: 机械工业出版社, 2003.
- [11] 田景文. 人工神经网络算法研究及应用 [M]. 北京: 北京理工大学出版社, 2006.
- [12] Mubiru J. Predicting total solar irradiation values using artificial neural networks[J]. Renewable Energy, 2008, 33(10): 2329 – 2332.
- [13] Mellit A, Pavan A M. A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy[J]. Solar Energy, 2010, 84(5): 807 – 821.
- [14] Wang Z, Wang F, Su S. Solar irradiance short-term prediction model based on BP neural network[J]. Energy Procedia, 2011, 12: 488 – 494.
- [15] Yacef R, Benghane M, Mellit A. Prediction of daily global solar irradiation data using Bayesian neural network: A comparative study[J]. Renewable Energy, 2012, 48: 146 – 154.
- [16] Benghane M, Mellit A. Radial basis function Network-based prediction of global solar radiation data: Application for sizing of a stand-alone photovoltaic system at Al-Madinah, Saudi Arabia[J]. Energy, vol. 2010, 35 (9): 3751 – 3762.
- [17] Cao J C, Cao S H. Study of forecasting solar irradiance using neural networks with preprocessing sample data by wavelet analysis[J]. Energy, 2006, 31(15): 3435 – 3445.
- [18] Ma L, Yorino N, Khorasani K. Solar radiation (insolation) forecasting using constructive neural networks[A]. 2016 International Joint Conference on Neural Networks[C]. Vancouver, Canada, 2016.
- [19] Mitchell T M. Machine learning [M]. Beijing: China Machine Press, 2003.
- [20] Park J, Sandberg I W. Universal approximation using radial-basis-function networks[J]. Neural Computation, 2014, 3(2): 246 – 257.
- [21] Ding M, Wang L, Bi R. An ANN-based approach for forecasting the power output of photovoltaic system[J]. Procedia Environmental Sciences, 2011, 11: 1308 – 1315.
- [22] Liu J, Fang W, Zhang X, et al. An improved photovoltaic power forecasting model with the assistance of aerosol index data[J]. IEEE Transactions on Sustainable Energy, 2015, 6(2): 434 – 442.
- [23] Mellit A, Massi P A, Lughi V. Short-term forecasting of power production in a large-scale photovoltaic plant[J]. Solar Energy, 2014, 105: 401 – 413.
- [24] 叶林, 陈政, 赵永宁, 等. 基于遗传算法——模糊径向基神经网络的光伏发电功率预测模型 [J]. 电力系统自动化, 2015, (16): 16 – 22.
- [25] 代倩, 段善旭, 蔡涛, 等. 基于天气类型聚类识别的光伏系统短期无辐照度发电预测模型研究 [J]. 中国电机工程学报, 2011, 31(34): 28 – 35.
- [26] Tao Y, Chen Y. Distributed PV power forecasting using genetic algorithm based neural network approach[A]. IEEE 2014 International Conference on Advanced Mechatronic Systems[C]. Kumamoto, Japan, 2014.
- [27] Kolentini E, Sideratos G, Rikos V, et al. Developing a matlab tool while exploiting neural networks for combined prediction of hour's ahead system load along with irradiation, to estimate the system load covered by PV integrated systems[A]. IEEE 2009 International Conference on Clean Electrical Power[C]. Capri, Italy, 2009. 太阳能

(接第 62 页) 设计及平台动力分析的重点进行了阐述。与汽轮发电机基座的设计相同, 作为动力设备支撑结构, 熔盐泵基础及上部钢结构平台需要进行动力设计, 且动力设计的结果需要符合设备厂家的要求, 并应满足动力设备基础的设计规范。从厂家提供的结构要求来看, 熔盐泵基础及上部钢结构平台的动力设计仍遵循动力设备基础设计的基本要求, 主要目标仍是控制熔盐泵上部钢结构平台的动位移、动速度或动加速度, 保证在动力设备运行的情况下, 熔盐泵上部钢结构平台不发生较大的动位移, 从而保证设备的稳定运行。

项目实践过程中, 设备厂家要求控制的是动速度, 这一点与我国规范中限制动位移的要求类似: 动位移与动速度为导数关系。但从设计统一的角度来看, 针对太阳能热发电站中的熔盐泵基

础及上部钢结构平台, 我国应尽快建立统一的动力计算规范。从规范的一致性考虑, 熔盐泵基础及上部钢结构平台的动力分析最终应使用动位移作为限制标准^[3]。

由于目前同类结构的研究仍处在起步阶段, 因此, 本文中针对熔盐泵基础及上部钢结构平台的动力分析对今后类似结构的动力设计具有指导意义。今后应在积累足够的项目经验且成熟后, 形成统一的设计规范。

参考文献

- [1] 北京金土木软件技术有限公司, 中国建筑标准设计研究院. SAP2000 中文版使用指南 [M]. 北京: 人民交通出版社, 2006.
- [2] Clough R W, Penzien J. 结构动力学 第二版 (修订版) [M]. 北京: 高等教育出版社, 2006.
- [3] GB 50040-96, 动力机器基础设计规范 [S]. 太阳能