

基于深度信念网络的凝汽式汽轮机 效率衰退研究

徐红伟, 李崇晟

(西安热工研究院有限公司, 陕西 西安 710054)

[摘 要] 为实现凝汽式汽轮机的效率衰退研究, 避开了传统研究方法中针对排汽焓的计算或预测, 通过对汽轮机做功原理的分析, 提出了汽轮机效率基准期和汽轮机效率衰退指标 2 个概念。利用机组历史数据, 采用深度信念网络建立了汽轮机效率基准期模型。通过滑动区间的极差限定法对初始数据进行了稳态筛选, 并将初始数据与稳态数据相结合实现了模型的训练。通过将汽轮机实时输出功率与基准期模型的理想输出功率的对比, 得到了实时汽轮机效率相对基准期的退化程度。应用结果表明: 汽轮机效率衰退指标在大修前的螺旋式下降趋势, 与汽轮机性能随时间的缓慢下降相吻合; 大修后汽轮机效率衰退指标的快速升高, 与汽轮机大修后机组通流能力的提升相吻合。该方法可以有效表征汽轮机的效率变化趋势, 对电厂人员实时了解汽轮机的经济性提供了有效的参考。

[关 键 词] 凝汽式汽轮机; 效率衰退; 效率基准期; 深度信念网络; 受限玻尔兹曼机; 神经网络

[中图分类号] TK267 [文献标识码] A [DOI 编号] 10.19666/j.rlfed.201910236

[引用本文格式] 徐红伟, 李崇晟. 基于深度信念网络的凝汽式汽轮机效率衰退研究[J]. 热力发电, 2020, 49(4): 93-100. XU Hongwei, LI Chongsheng. Research of efficiency degradation of condensing steam turbine based on deep belief network[J]. Thermal Power Generation, 2020, 49(4): 93-100.

Research of efficiency degradation of condensing steam turbine based on deep belief network

XU Hongwei, LI Chongsheng

(Xi'an Thermal Power Research Institute Co., Ltd., Xi'an 710054, China)

Abstract: In order to research the efficiency degradation of condensing steam turbines, the calculation and prediction of exhaust enthalpy in conventional research methods is avoided, and two concepts, namely the efficiency reference period and the efficiency degradation index, are put forward, by analyzing the working principle of steam turbines. Based on historical data, a model of the turbine in efficiency reference period is established by deep belief network. The initial data are filtered steadily by limiting the range of data in continuous sliding intervals, and the model is trained by the initial data combined with the steady data. By comparing the real-time output power of the turbine with the ideal output power of the model, the degradation degree of the real-time turbine efficiency relative to the reference period is obtained. The application results show that, the spiral decline trend of turbine efficiency degradation index before overhaul is consistent with the slow decline of turbine performance over time, and the rapid rise of turbine efficiency degradation index after overhaul is consistent with the increase of turbine current capability after overhaul. This method can effectively characterize the efficiency trend of the turbine, and provide an effective reference for users to master the performance of the turbine in real time.

Key words: condensing steam turbine, efficiency degradation, efficiency reference period, deep belief network, restricted Boltzmann machine, neural network

汽轮机作为火电厂最重要的大型动力设备之一, 其运行经济性与整个电厂的经济性密切相关。

在传统的汽轮机经济性分析中, 对某一级组或缸, 一般通过级组或缸的进出口间实际焓降与理想焓

收稿日期: 2019-10-25

基金项目: 国家重点研发计划项目(2017YFF0210500)

Supported by: National Key Research and Development Program (2017YFF0210500)

第一作者简介: 徐红伟(1990), 男, 硕士, 主要研究方向为火电厂设备状态监测及状态检修, xuhongwei@tpri.com.cn.

降之比来计算其效率。对出口为过热蒸汽的级组或缸,其效率可简单通过进出口参数(压力、温度)进行计算;但对从低压缸末段或次末段抽汽到低压缸排汽这段来说,抽汽和排汽均为湿蒸汽,因其干度难以测得,故此段的效率难以得到。

低压缸排汽焓的传统计算方法主要有能量平衡法、曲线外推法、弗留格尔公式法^[1]、汽轮机变工况计算方法,以及其他的一些改进方法。文献[2]根据热力学原理由汽轮机功率反推相对内效率,并通过循环吸热量和放热量的近似计算简化了内效率的表达式。文献[3]将汽轮机、凝汽器及回热系统视为闭口系统,采用弗留格尔及其改进公式结合闭口系统的能量平衡计算汽轮机排汽焓。文献[4]将汽轮机低压缸损失划分为排汽损失、湿汽损失和其他损失,得到了各损失与低压缸理想焓降的二次关系式,据此得出了排汽焓计算公式。文献[5]提出了基于能量平衡法和曲线外推法改进的湿蒸汽区蒸汽焓值计算模型。文献[6]提出了简单的末级流态判别法,根据试验数据与结构数据顺序计算汽轮机排汽焓。另外,许多学者尝试采用一些基于智能算法的方法来预测低压缸排汽焓。文献[7]利用遗传算法优化后的 Elman 神经网络建立了汽轮机排汽焓预测模型。文献[8]提出了基于支持向量机的汽轮机排汽焓在线预测方法,其可简单表示排汽焓与运行参数

间的复杂耦合关系。文献[9]采用 BP 神经网络实现了汽轮机排汽焓预测。但这些模型在训练学习时所用数据的目标排汽焓多为预测值而非真实值,以此模型预测的准确性也大打折扣。

长期以来,对汽轮机效率的在线监测仅针对高、中压缸能获得较好的效果,而低压缸效率难以监测,往往只能在大修前后实施性能试验时获知,导致汽轮机的整体经济性评估受到限制。本文避开了传统研究方法中针对排汽焓的计算或预测,直接将汽轮机本体作为研究对象,以某电厂超临界 1 000 MW 一次再热凝汽式汽轮机为例(以下简称 H 机),对其效率衰退趋势进行分析。

1 方法原理

1.1 研究假设

本文提到的汽轮机本体包括主蒸汽阀、调节阀、高压缸、中压联合汽阀、中压缸、低压缸、各抽汽口、各阀门及轴封在内。H 机本体形貌如图 1 所示。图 1 中, p_0 、 T_0 、 G_0 分别为主蒸汽阀前蒸汽压力、温度和流量, G_2 、 G_3 分别为一段抽汽和二段抽汽的流量, p_1 、 T_1 、 G_1 分别为中压联合汽阀前蒸汽压力、温度和流量, G_4 、 G_5 、 G_6 、 G_7 、 G_8 、 G_9 分别为三段—八段抽汽的流量, p_k 为排汽压力。

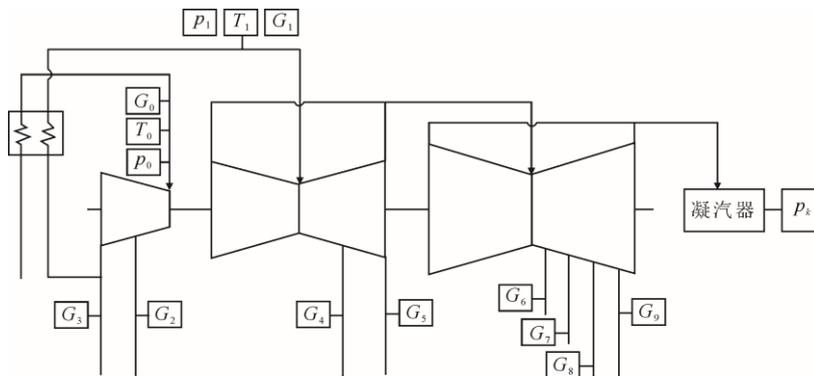


图 1 H 机本体形貌

Fig.1 Schematic diagram of H turbine

首先假定汽轮机本体在某一段时间(以下简称基准期)恒定不变,无老化、无磨损、无结垢,汽封和阀门等都不变。则当图 1 中给出的所有参数固定时,汽轮机的输出功率确定。这是因为图 1 中给出的参数确定了汽轮机主蒸汽参数(包括流量)、再热蒸汽参数(包括流量)、各级抽汽量及排汽压力,结合上述假设,汽轮机各级组的进排汽参数和流

量、阀门漏汽量和汽封漏汽量也随之确定,进而各级组的功率也确定,汽轮机总输出功率也就随之确定。可见,对给定的汽轮机而言,其输出功率与图 1 中给出的参数之间有对应关系,汽轮机输出功率的模型可以通过图 1 中给出的参数来建立。

1.2 指标定义

在实际中,虽然汽轮机本体不可能在某一段时

间恒定不变,但在较短期间内(如 3~6 个月),其性能变化较小,可基本满足研究假设。当汽轮机本体经过长期运行发生变化时,如叶片结垢、漏汽增多、通流磨损等,假定此时图 1 中的参数均未发生变化,汽轮机的实际输出功率也必然减少。那么可以以此为依据,建立汽轮机在基准期内的模型。在其后任一时间,将汽轮机当前的实际输出功率与模型得到的理想输出功率进行对比,即可得到当前汽轮机相对基准期汽轮机的效率衰退指标。另外,由于汽轮机不同负荷级别的性能相差较大,在对比时必须以相同或相近负荷级别的数据进行。据此,本文提出汽轮机效率衰退指标(turbine efficiency degradation index, I_{TED})定义,其表达式为

$$I_{TED,\Omega,t_0}(t_c) = \frac{P_{out}(t_c)}{P_{out-M}(t_c)} \quad (1)$$

式中: $I_{TED,\Omega,t_0}(t_c)$ 为在 t_c 时刻、机组处于 Ω 负荷等级下相对于 t_0 时期的汽轮机效率衰退指标; Ω 为负荷等级,用于限定 I_{TED} 的比较基准; t_c 为计算 I_{TED} 的当前时刻; t_0 为性能基准期; $P_{out}(t_c)$ 为 t_c 时刻的汽轮机实际输出功率; $P_{out-M}(t_c)$ 为采用基准期模型预测的 t_c 时刻汽轮机理想输出功率。

实际中,可将 t_0 选取为汽轮机新投运后、大修后或其他性能较优时间段,以便了解汽轮机在长期运行中相对于性能优良期发生的效率衰退情况。由于监测参数的随机误差以及工况变化等的影响,由式(1)计算出的实时 I_{TED} 数据稳定性欠佳,故此处可将式(1)的固定时刻改为滑动区间,以减少随机误差及工况变化的影响,即

$$I_{TED,\Omega,\tau,t_0}(t_c) = \frac{1}{S_{t_c,\tau}} \sum_{t=t_c-\tau}^{t_c} \frac{P_{out}(t)}{P_{out-M}(t)} \quad (2)$$

式中: $I_{TED,\Omega,\tau,t_0}(t_c)$ 为 t_c 时刻及其之前的 τ 时间间隔内、机组处于 Ω 负荷等级下相对于 t_0 时期的汽轮机效率衰退指标; τ 为用于计算 I_{TED} 的滑动区间长度; $S_{t_c,\tau}$ 表示 t_c 时刻及其之前的 τ 时间间隔内、机组处于 Ω 负荷等级下的数据点数量。

本文案例 H 机于 2009 年投运,2018 年第四季度进行了第 2 次大修。厂级监控信息系统(SIS)现存的该汽轮机有效数据是 2016 年 7 月至今。这里选取 2016 年 7 月—2016 年 9 月为该汽轮机的性能基准期,即式(2)中 $I_{TED,\Omega,\tau,t_0}(t_c)$ 的 t_0 取 2016 年 7 月—2016 年 9 月,选取 2016 年 10 月—2018 年 8 月(大修前)及 2019 年 1 月—2019 年 4 月(大修后)为验证时间段。

1.3 参数选择

实际上,图 1 中给出的参数只有部分有直接测点,如 p_0 、 T_0 、 p_1 、 T_1 、 p_k 等;其他参数均需通过另外的测点间接计算得到,如 G_0 需根据给水流量再考虑过热减温水流量得到, G_1 需根据主蒸汽阀前至再热冷段的流量平衡计算后再考虑再热减温水流量得到,各抽汽口抽汽流量(G_2 、 G_3 、 G_4 、 G_5 、 G_6 、 G_7 、 G_8 、 G_9)需由各抽汽对应的加热器热平衡计算得到,包含给水泵汽轮机进汽的抽汽流量计算时还需额外考虑给水泵汽轮机进汽流量。加热器热平衡计算所需测点如图 2 所示。

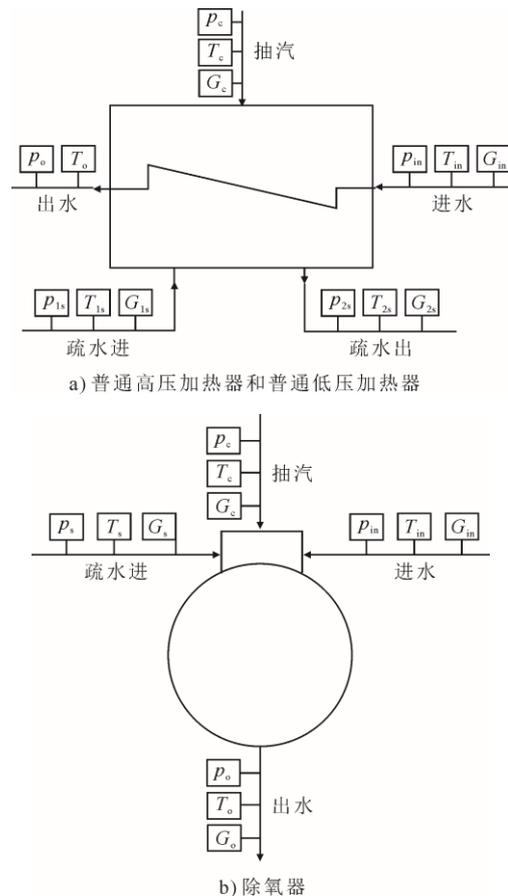


图 2 加热器热平衡计算所需测点示意
Fig.2 Schematic diagram of measuring points for calculating heat balance of the heaters

图 2a)中,对于第一级高压加热器和第一级低压加热器,需去掉进入加热器的疏水。由于普通高压加热器和低压加热器中进、出水的压力变化不大,图 2a)中表征压力的测点可相应减少。

将以上相关测点全部汇总,统一作为汽轮机基准期模型的输入参数,将汽轮机输出功率(以发电机功率代替)作为模型输出参数。总体涉及的参数见表 1。

表 1 汽轮机本体模型涉及的可测参数
Tab.1 The measurable parameters involved in turbine model

序号	位置	参数
1	主蒸汽阀前蒸汽	压力、温度
2	高压缸排汽	压力、温度
3	中压缸进汽	压力、温度
4	低压缸进汽	压力、温度
5	凝汽器	压力
6	各级抽汽	压力、温度
7	各级加热器进口水	压力、温度
8	各级加热器出口水	温度
9	各级加热器进汽	压力、温度
10	各级加热器疏水进	压力、温度
11	各级加热器疏水出	压力、温度
12	给水泵出口水	压力、温度、流量
13	除氧器内	压力
14	给水泵汽轮机进汽	流量
15	过热及再热减温水	流量
16	发电机	功率

此模型不仅考虑了汽轮机通流部分的效率，还考虑了轴封漏汽、阀门漏汽等，故最终得到的汽轮机效率衰退指标 I_{TED} 也涵盖了包括上述情况在内的诸多汽轮机本体损耗因素造成的广义效率下降。

2 方法实现

2.1 受限玻尔兹曼机

受限玻尔兹曼机 (restricted Boltzmann machine, RBM) 是 Smolensky 在玻尔兹曼机的基础上引入的一种特殊拓扑结构^[10]，由可见层和隐层组成，每个神经元与另一层的所有神经元之间建立连接，而各层内部神经元之间均无连接。RBM 结构如图 3 所示。图 3 中， v_i ($i=1, 2, 3, \dots, n$) 表示第 i 个可见层神经元的状态， h_j ($j=1, 2, 3, \dots, m$) 表示第 j 个隐层神经元的状态， a_i 和 b_j 分别表示第 i 个可见层神经元和第 j 个隐层神经元的偏置， w_{ij} 表示第 i 个可见层神经元和第 j 个隐层神经元之间的连接权值。

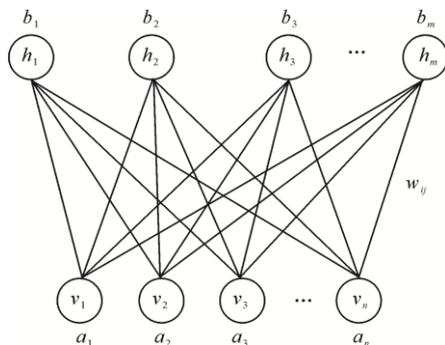


图 3 RBM 结构示意图

Fig.3 Schematic diagram of the structure of RBM

RBM 神经元的输出只有激活与未激活 2 种状态，其取值由概率法则确定。当给定可见层各神经元状态时，隐层各神经元的激活条件独立，反之亦然^[11]。由多层 RBM 堆叠成的多隐层神经网络具有优异的特征学习能力，可将训练数据的特征逐级抽象，最终表达为有利于分类或回归的高级特征^[12]。

RBM 通过能量函数描述整个系统的状态，能量函数的最小值对应系统的最稳定状态。RBM 的能量函数定义为

$$E(v, h) = -\sum_{i=1}^n \sum_{j=1}^m w_{ij} v_i h_j - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j \quad (3)$$

根据上述定义，结合 RBM 层间有连接、层内无连接的特殊结构，可以得到第 i 个可见层神经元的激活概率为

$$p(v_i=1|h) = \sigma(a_i + \sum_j w_{ij} h_j) \quad (4)$$

式中 $\sigma(x) = \frac{1}{1 + \exp(-x)}$ 表示 sigmoid 激活函数。

第 j 个隐层神经元的激活概率为

$$p(h_j=1|v) = \sigma(b_j + \sum_i w_{ij} v_i) \quad (5)$$

通过最大化 RBM 在训练数据集上的对数似然函数，可以得到网络权值和偏置；但由于可见单元与隐单元的联合分布难以获取，只能通过一些采样方法（如 Gibbs 采样）获得近似值，且效率较低。Hinton 在此基础上提出了对比散度算法^[13]，当使用训练数据初始化可见层时，仅需使用 k 步（通常 $k=1$ ）Gibbs 采样便可得到相当好的结果。

2.2 深度信念网络

深度信念网络 (deep belief network, DBN) 是由多层 RBM 堆叠后外加一层 BP 网络组成的一种深层神经网络，网络训练可通过逐层训练来实现。首先，第 1 层 RBM 以原始输入数据进行训练，并将原始数据映射到另一个特征空间，应保证重构后的特征尽可能多地保留原特征信息；然后将第 1 层 RBM 训练得到的特征作为第 2 层 RBM 的输入，训练得到第 2 次重构后的特征；重复此过程，直到最后一层 RBM 训练完毕。在逐层训练中，具体的特征逐渐转化为抽象的特征。最终通过样本标签对已初始化的网络权值进行有监督微调，完成训练^[14]。

多层 RBM 的逐层训练可以看作一个深层 BP 神经网络的权值初始化。这样不仅克服了网络因权值的随机初始化而容易陷入局部最优的缺点，并且可以将训练整个 DBN 的高复杂度问题简化为分别训练多个 RBM 的低复杂度问题。

2.3 汽轮机基准期模型

2.3.1 数据预处理

电厂的负荷处于不断的波动之中,但很多参数并不随之实时波动,而有一定的滞后性。在进行数据分析时,一般需从原始数据中筛选出参数稳定的工况,即稳态筛选。Narasimhan 等人^[15-16]提出了组合统计检验法和置信度法,通过比较两相邻窗口内数据的方差和均值结合 T 检验法判断稳态;Cao 等人^[17]提出了改进的 R 检验法,通过变量滤波前后均方差估计值的比值构建稳态检验量;Jiang 等人^[18]提出了基于小波变换的多尺度数据处理方法,结合一、二阶小波变换构建稳态指标。

由于汽轮机内蒸汽流速很高,参数的滞后性可以忽略,主要需考虑给水流量的不同步导致的各加热器参数的不同步。故此处针对机组负荷和给水流

量 2 个参数进行稳态筛选,也即当机组负荷和给水流量都处于近似稳态时,将整个汽轮机本体的相关参数都视为处于稳态。本文采用滑动窗口中数据极差与均值的比值作为稳态指数:

$$I_{st} = \frac{\max\{x_p \sim x_{p+q}\} - \min\{x_p \sim x_{p+q}\}}{\text{sum}(x_p \sim x_{p+q}) / (q+1)} \quad (6)$$

式中, I_{st} 为稳态指数, p 为窗口初始时刻, q 为窗口时间宽度, x_p 为窗口初始时刻值, x_{p+q} 为窗口最末时刻值。

取 $I_{st}=1.5\%$ 作为机组负荷和给水流量的稳态指数阈值,窗口时间宽度 $q=30 \text{ min}$ 。筛选从初始时刻到最末时刻之间连续滑动进行,如果所选取的稳态区间重叠,则将其合并。图 4a)、图 4b)分别表示对发电机功率、给水泵 A 流量的稳态筛选结果。图中的灰色图框为各自参数的稳态区间,灰色图框重叠的区域即为最终的稳态区间。

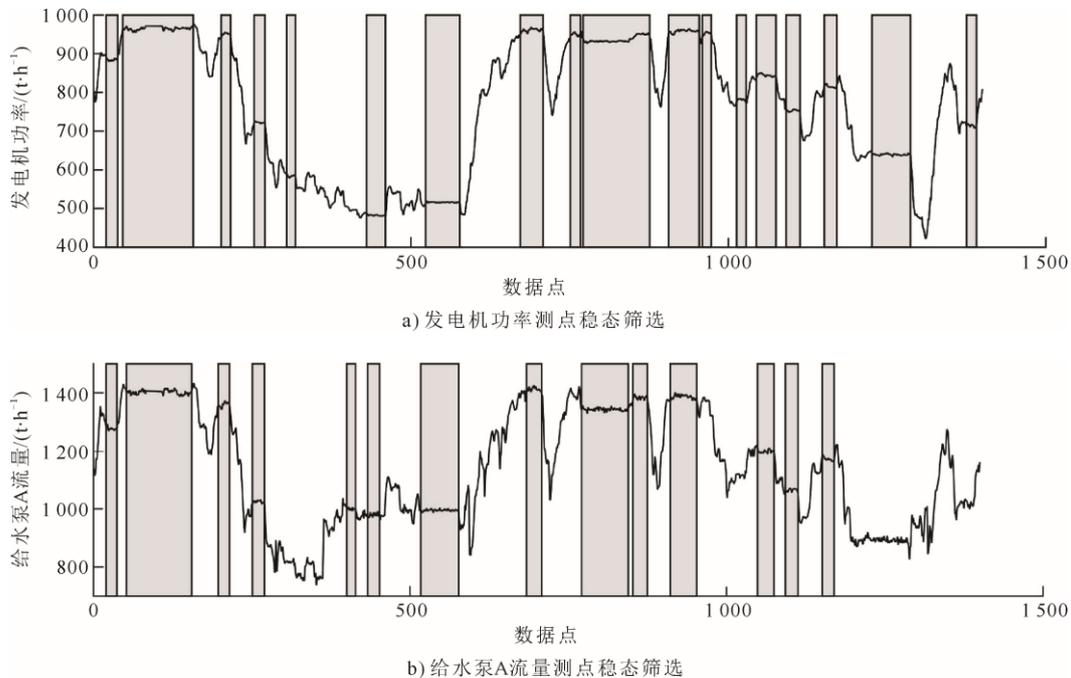


图 4 稳态筛选结果示例

Fig.4 Schematic diagram of steady-state screening of the data

当机组处于低负荷时,很多参数会处于非常规区间(如小汽轮机进汽不来自四段抽汽而改为再热冷段蒸汽),这会影响模型的一致性,也须将其剔除。

2.3.2 模型训练

根据 1.3 节的分析,模型输入参数维度为 104,输出为 1 维,训练样本个数随基准期长度、稳态筛选程度以及原始数据的插值时间间隔而有所差别,一般在 10^4 数量级。模型采用 4 层的深度信念网络,即 3 层堆叠的 RBM 外加 1 层仅包含 1 个神经元的

输出层。RBM 的隐层神经元数的选取并无标准或准则,这里通过多次试算将 3 层 RBM 的隐层神经元数分别定为 [20, 30, 15],即整个 DBN 网络从输入到输出各层的神经元数分别为 [104, 20, 30, 15, 1]。汽轮机基准期模型所用 DBN 结构如图 5 所示。模型对基准期数据拟合的相对误差如图 6 所示。

模型的训练共分为 3 步: 1) 采用稳态筛选之前的归一化数据(不包括发电机功率)逐层训练 RBM; 2) 采用同样的数据(包括发电机功率)对整个深度

信念网络进行有监督参数微调; 3) 采用稳态数据对整个网络进行第 2 次有监督参数微调。

这样处理的原因有 3 点: 1) 直接采用稳态数据训练时, 数据量偏少; 2) 稳态数据在部分负荷区间过于集中, 而在其余很多负荷区间数据很少甚至无数据, 易造成模型对个别负荷区间过拟合, 而在其余负荷区间欠拟合; 3) 采用先非稳态数据训练、后稳态数据调整的逐级训练方式, 保证了训练前期模型对整体各负荷区间数据的无差异化对待, 并在训练后期用稳态数据提升了模型准确率。

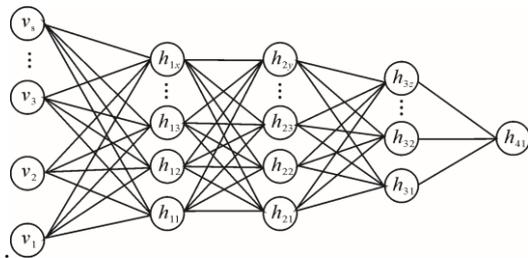


图 5 汽轮机基准期模型所用 DBN 结构示意图
Fig.5 Schematic diagram of structure of DBN used in the turbine model

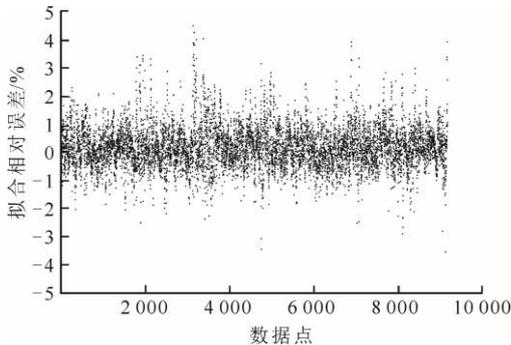


图 6 模型拟合相对误差
Fig.6 The relative errors of the model

由图 6 可以看出, 拟合误差绝大多数处于 1% 以内, 拟合效果良好。

3 方法对比

为验证 DBN 模型的优势, 这里将单层 BP 神经网络、GA-SVR (采用遗传算法优化的支持向量回归)、MLR (多元线性回归) 与深度信念网络的拟合效果进行比较, 并同时比较了稳态指数 I_{st} 取 1.5%、2.0% 和 3.0% 的情况, 对比结果如图 7 所示。纵坐标为对数坐标, 表示模型预测值与实际值的均方误差 δ_{MSE} 。用于建模的基准期数据均为 H 机在 2016 年 7 月—2016 年 9 月的数据, 用于验证的数据为 2017 年 5 月的数据。

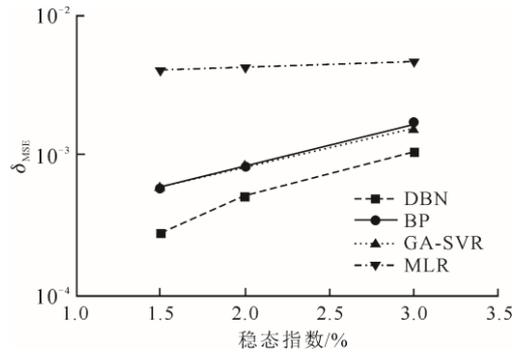


图 7 各算法建模的预测效果对比
Fig.7 Comparison of prediction results between and among models established by different algorithms

由图 7 可以看出: DBN 的拟合误差明显小于另 3 种模型; 单层 BP 神经网络与 GA-SVR 模型的拟合误差很接近, 均大于 DBN 小于 MLR; MLR 的拟合误差远大于另 3 种模型; 随着稳态指数 I_{st} 取值的增大, 各模型的拟合误差均逐渐增大。可见, 在本研究中, DBN 模型相比其他几种模型有较大优势, 稳态指数 I_{st} 取 1.5% 亦是为了保证模型的拟合准确率。当稳态指数取更低值时, 稳态数据量的减少将不利于模型训练。

4 应用结果分析

根据 1.2 节中设定的 H 机性能基准期及验证时间段, 按月计算汽轮机效率衰退指标 I_{TED} , 以其在大修前后的变化趋势及与实际性能试验结果的对比来验证其有效性。

按月计算 I_{TED} 时, 式(2)中的 τ 取为 1 个月; 由于机组的稳态负荷主要集中在 800 MW 以上, 将式(2)中的负荷范围 Ω 分为 950~1 000 MW、900~950 MW、850~900 MW、800~850 MW 等 4 个区间; 为简便起见, t_c 取每月最末时刻。

根据上述配置, 得到 H 机 I_{TED} 随时间的变化情况如图 8 所示。图 8 中, 个别空缺的点表示当月缺少所取功率区间的数据。

H 机实际完成的修前、修后性能试验结果表明: 在三阀全开工况下, H 机修后机组出力比修前提升 6.28%; 在四阀全开工况下, H 机修后机组出力比修前提升 3.49%。大修使机组的通流能力明显提升。

图 8 各分图中 $t=1$ 的点表示基准时间段的数据, 此时 $I_{TED} \approx 1$, 可知模型对训练数据的拟合非常好。 $t=22$ 月与 $t=23$ 月这 2 个点之间, 汽轮机进行了第二次大修。从图 8 中可清晰地看出, 在 $t=22$ 月及其之前的点, H 机 I_{TED} 一直处于螺旋式的下降趋势中,

这与汽轮机性能随时间的推移而缓慢下降相吻合；在 $t=23$ 月的点， I_{TED} 快速升高，并在之后的4个月中维持高位，这与性能试验得到的 H 机大修后机组的通流能力明显提升相吻合。

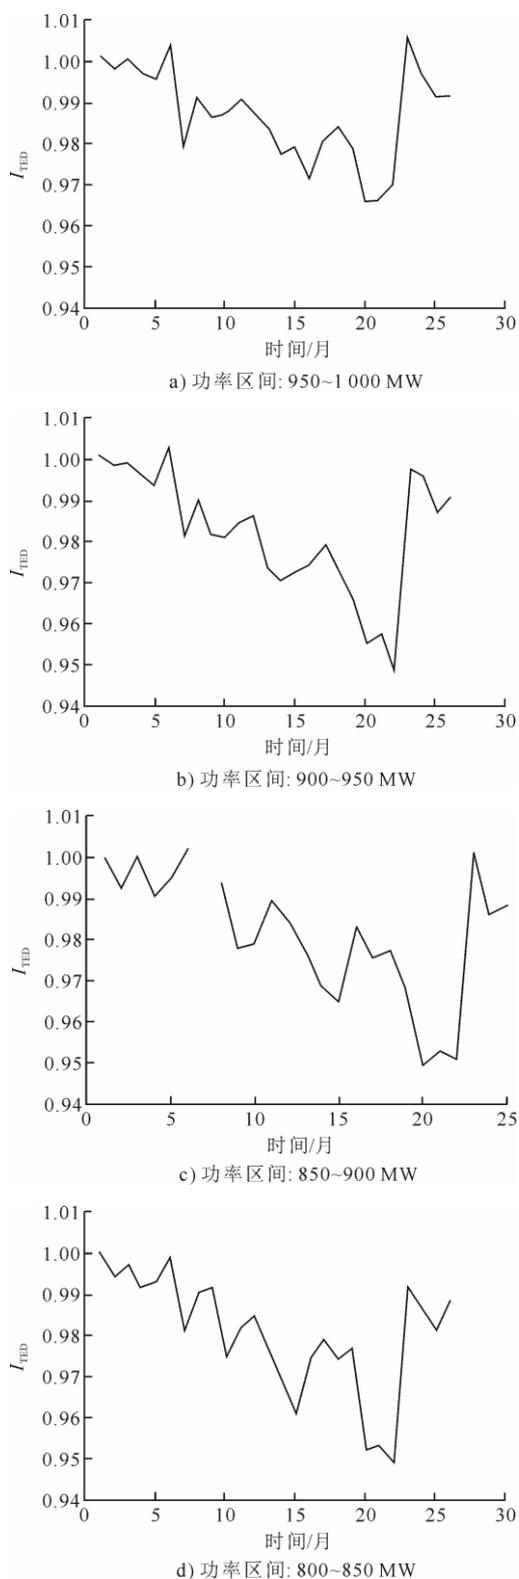


图8 H 机 I_{TED} 随时间的变化

Fig.8 Changes of I_{TED} of the H turbine with time

5 结论与展望

本文通过深度信念网络建立了汽轮机基准期功率拟合模型，将实时输出功率与模型的理想输出功率进行对比，得到了汽轮机效率衰退指标。并采用案例证实了本方法相比其他算法的优势，以及在电厂实际应用的可行性与有效性。

下一步的研究可着力于将汽轮机效率衰退指标分解到汽轮机各缸、各级组及阀门、汽封，以更全面、方便地监控汽轮机经济性。

[参考文献]

- [1] 闫顺林, 王俊有. 汽轮机排汽比焓在线计算方法的选择[J]. 热力发电, 2008, 37(4): 28-32.
YAN Shunlin, WANG Junyou. On-line calculation method of exhaust steam's enthalpy[J]. Thermal Power Generation, 2008, 37(4): 28-32.
- [2] 李勇, 曹丽华, 杨善让. 凝汽式汽轮机相对内效率在线监测的一种近似计算方法[J]. 中国电机工程学报, 2002, 22(2): 64-67.
LI Yong, CAO Lihua, YANG Shanrang. An approximate method of online monitoring relative internal efficiency for condensing steam turbine[J]. Proceedings of the CSEE, 2002, 22(2): 64-67.
- [3] 韩中合, 杨昆, 田松峰, 等. 在线确定凝汽式汽轮机排汽焓的热力学方法[J]. 动力工程, 2004, 24(3): 356-359.
HAN Zhonghe, YANG Kun, TIAN Songfeng, et al. A thermodynamics method of online calculation steam turbine exhaust enthalpy[J]. Power Engineering, 2004, 24(3): 356-359.
- [4] 张赞, 胥建群, 杨涛, 等. 一种基于级内损失理论的排汽焓计算方法[J]. 汽轮机技术, 2013, 55(2): 81-85.
ZHANG Yun, XU Jianqun, YANG Tao, et al. A calculation method of exhaust enthalpy based on stage loss theory[J]. Turbine Technology, 2013, 55(2): 81-85.
- [5] 张乐乐, 张燕平, 黄树红, 等. 汽轮机湿蒸汽区蒸汽焓值的计算模型研究[J]. 动力工程学报, 2013, 33(4): 272-277.
ZHANG Lele, ZHANG Yanping, HUANG Shuhong, et al. Steam enthalpy calculation model for wet steam region of steam turbines[J]. Journal of Chinese Society of Power Engineering, 2013, 33(4): 272-277.
- [6] 邵峰, 周胜男. 汽轮机低压缸效率的分析与计算[J]. 汽轮机技术, 2012, 54(3): 177-179.
SHAO Feng, ZHOU Shengnan. The analysis and calculation to get the efficiency of turbine LP cylinder[J]. Turbine Technology, 2012, 54(3): 177-179.
- [7] 王建国, 赵帅, 王广雨. 提高汽轮机排汽焓在线预测精度的 GA-Elman 神经网络算法[J]. 热力发电, 2014, 43(10): 90-94.
WANG Jianguo, ZHAO Shuai, WANG Guangyu. A GA-Elman neural network algorithm which can improve online prediction accuracy of exhaust enthalpy for steam turbines[J]. Thermal Power Generation, 2014, 43(10): 90-94.
- [8] 蔡杰进, 马晓茜. 支持向量机在电站汽轮机排汽焓在线预测中的应用[J]. 电力系统自动化, 2006, 30(18): 77-82.
CAI Jiejing, MA Xiaolian. Online forecasting of steam turbine exhaust enthalpy based on support vector machine

- method[J]. Automation of Electric Power Systems, 2006, 30(18): 77-82.
- [9] 吴俊杰, 侯宏娟, 杨勇平. 神经网络算法在汽轮机排汽焓估算中的应用[J]. 热力发电, 2014, 43(8): 125-130. WU Junjie, HOU Hongjuan, YANG Yongping. Application of neural network algorithm in steam turbine's exhaust enthalpy estimation[J]. Thermal Power Generation, 2014, 43(8): 125-130.
- [10] SMOLENSKY P. Information processing in dynamical systems: foundations of harmony theory[R]. Colorado University at Boulder Department of Computer Science, 1986: 204-208.
- [11] 张春霞, 姬楠楠, 王冠伟. 受限波尔兹曼机[J]. 工程数学学报, 2015(2): 159-173. ZHANG Chunxia, JI Nannan, WANG Guanwei. Restricted Boltzmann machines[J]. Chinese Journal of Engineering Mathematics, 2015(2): 159-173.
- [12] FISCHER A, IGEL C. Training restricted Boltzmann machines: an introduction[J]. Pattern Recognition, 2014, 47(1): 25-39.
- [13] HINTON G E. A practical guide to training restricted Boltzmann machines//Neural networks: tricks of the trade[M]. Springer, Berlin, Heidelberg, 2012: 599-619.
- [14] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [15] NARASIMHAN S, MAH R S H, TAMHANE A C, et al. A composite statistical test for detecting changes of steady states[J]. AIChE Journal, 1986, 32(9): 1409-1418.
- [16] NARASIMHAN S, KAO C S, MAH R S H. Detecting changes of steady states using the mathematical theory of evidence[J]. AIChE Journal, 1987, 33(11): 1930-1932.
- [17] CAO S, RHINEHART R R. An efficient method for on-line identification of steady state[J]. Journal of Process Control, 1995, 5(6): 363-374.
- [18] JIANG T, CHEN B, HE X, et al. Application of steady-state detection method based on wavelet transform[J]. Computers & Chemical Engineering, 2003, 27(4): 569-578.

(责任编辑 刘永强)