第 51 卷 第 3 期：1220-1232 高电压技术 Vol.51, No.3: 1220-1232
2025 年 3 月 31 日 High Voltage Engineering March 31, 2025
DOI: 10.13336/j.1003-6520.hve.20232054

融合流-热场耦合仿真与 EEMD-LSTM 网络的油浸式变压器热点温度快速预测方法

杨子坚[1]，司马文霞[1]，杨　鸣[1]，黎文浩[2]，袁　涛[1]，孙魄韬[1]
（1. 输变电装备技术全国重点实验室(重庆大学电气工程学院)，重庆 400044;
2. 南方电网科学研究院有限责任公司，广州 510700）

摘　要：快速准确地预测变压器热点温度是实现变压器状态检测、故障预测以及动态增容的重要前提，其关键是实现变压器热点温度动态预测以及提高热点温度预测模型的抗噪性能。该文通过流-热场耦合仿真计算，获取不同环境温度和负载变化工况的热点温度训练样本，采用长短期记忆网络(long short-term memory network，LSTM)构建深度学习模型，从而实现热点温度动态预测。采用集成经验模态分解(ensemble empirical mode decomposition，EEMD)降低输入数据中的噪声干扰，提高深度学习模型抗噪性能。以 20 MVA/110 kV 油浸式变压器为对象进行分析，并搭建变压器热点温升试验平台进行模型有效性验证，EEMD-LSTM 网络预测的热点温度相比试验结果的平均误差仅有 1.35 ℃，引入幅值为 5 ℃的随机噪声后，最大误差仅增大 0.47 ℃。结果表明：基于 EEMD-LSTM 网络的深度学习模型能够实现变压器热点温度动态预测，同时具有良好的抗噪性能，对变压器负荷能力动态评估与动态增容的研究具有重要意义。

关键词：热点温度；流-热场耦合仿真；长短期记忆网络；集成经验模态分解；油浸式变压器

Rapid Prediction Method of Hot Spot Temperature of Oil-immersed Transformer Combining Flow-thermal Coupling Simulation and EEMD-LSTM Network

YANG Zijian[1], SIMA Wenxia[1], YANG Ming[1], LI Wenhao[2], YUAN Tao[1], SUN Potao[1]
(1. State Key Laboratory of Power Transmission Equipment Technology, School of Electrical Engineering, Chongqing University, Chongqing 400044, China; 2. China Southern Power Grid Electric Power Research Institute, Guangzhou 510700, China)

Abstract：Fast and accurate prediction of hot spot temperature is an important precondition for condition detection, fault prediction and dynamic overload of transformers. The key is to realize dynamic prediction of transformer hot spot temperature and improve anti-noise performance of the hot spot temperature prediction model. In this paper, the hot spot temperature training samples of different ambient temperature and load change conditions are obtained through flow-thermal field coupling simulation calculation. The long short-term memory network (LSTM) is used to construct a deep learning model so as to realize the dynamic prediction of hot spot temperature. The ensemble empirical mode decomposition (EEMD) is used to reduce the noise interference in the input data, improving the anti-noise performance of the deep learning model. A 20 MVA/110 kV oil-immersed transformer is taken as example for analysis, and an experimental platform of transformer hot spot temperature rise is built to verify the validity of the model. The average error of the hot spot temperature predicted by the EEMD-LSTM network compared with the experimental results is only 1.35 ℃. After introducing random noise with amplitude of 5 ℃, the maximum error only increases by 0.47 ℃. The results show that the deep learning model based on EEMD-LSTM network can realize the dynamic prediction of transformer hot spot temperature, and it has good anti-noise performance, which is of great significance to the study of dynamic evaluation of transformer load capacity and dynamic capacity increase.

Key words：hot spot temperature; flow-thermal coupling simulation; long short-term memory network; ensemble empirical mode decomposition; oil-immersed transformer

基金资助项目：国家自然科学基金 (51977018)。
Project supported by National Natural Science Foundation of China(51977018).

0　引言

过热故障是变压器运行中面临的严重故障之一，会缩短变压器寿命，甚至引起变压器烧毁，造成重大经济损失[1-2]。实时准确地预测变压器热点温度是保证其安全运行的重要前提[3]，也为变压器动态增容决策[4]提供了关键的温度约束条件。变压器热点温度的获取方法主要包括：直接测温法、热路模型法、数值仿真分析法以及智能算法[5]。

通过布置温度传感器，可以直接测量变压器的内部温度[6]。例如：分布式光纤温度传感器的最大测量误差已小于 1 ℃[7]。然而，传感器安装数量和位置受限，无法获得变压器内部全局温度场分布，因此测得的温度不一定是变压器内部的最高温度。热路模型法将变压器内部传热过程转换成电路模型，从而估计出热点温度[8]。然而，热路模型同样无法获得温度场分布，在实际应用中预测精度有限。

数值计算法主要通过有限元法或有限体积法计算变压器内部温度[9]。有限元算法需要同时对时间和空间域进行离散，导致流-热场耦合计算过于复杂，收敛性不佳[10]。有限体积法在求解流体传热时，在迭代中不断预测和修正，可显著提高仿真的收敛性和准确度[11]。然而，数值计算法计算时间长，大型变压器单工况计算耗时达数小时甚至数天，无法满足热点温度实时预测的需求。

近年来，采用智能算法预测变压器热点温度成为研究热点。传统神经网络，如反向传播神经网络(back propagation neural network，BPNN)[12]、支持向量机(support vector machine，SVM)[13]、遗传算法(genetic algorithm，GP)[14]等，能够提取出热点温度与负载率、环境温度和顶层油温等输入特征量之间的映射关系。然而，变压器负载率动态变化将造成热点温度产生动态变化，这些网络因缺乏存储和处理过去时刻热点温度信息的单元，在稳态温度预测时具有极高的准确度，但动态温度预测准确度将变差[15]。有学者采用长短期记忆网络(long short-term memory network，LSTM)对地铁站用干式变压器的热点温度动态进行预测，通过对网络结构的修正，实现对过去热点温度信息的存储和处理，从而预测热点温度动态变化[16]。由于大型变压器工作环境温度范围宽，且动态增容时变压器负荷会在短时间内突变，通过变压器试验和现场运行取得的数据难以覆盖多因素组合下的复杂运行状态，不利于深度学习网络的准确训练和泛化提升[17]。

将数值仿真计算法与深度学习网络相结合，能够同时保证温度预测的准确性和快速性[18]。目前，该方法已在海水温度预测、电池热失效预测等领域取得一定进展，但在变压器热点温度实时预测方面研究较少[19]。有学者以 100 kVA/10 kV 变压器为对象，采用有限元仿真与 BP 神经网络相结合的方法，将前一时刻热点温度也作为输入特征量，实现了负载突变情况下热点温度变化趋势的实时预测[20]。然而，该网络虽然考虑了前一时刻的热点温度，但难以利用更长时间的热点温度信息，预测精度有待提高，且在大容量变压器中的应用效果也需进一步研究；此外，实际监测数据中存在噪声，造成深度学习网络预测准确度下降。

综上所述，现有热点温度预测方法还存在以下问题：首先，通过变压器试验和现场运行获取的训练数据工况覆盖有限，难以高效训练深度学习网络，泛化性能有待提高；其次，仅将前一时间点的热点温度信息纳入网络训练，难以充分利用热点温度的历史信息，变压器热点温度动态预测精度和时间长度有待提高；最后，实际监测数据的噪声会降低深度学习网络预测精度。

针对以上问题，本文以 20 MVA/110 kV 油浸式变压器为研究对象，构建流-热场耦合仿真模型，采用有限体积算法仿真得到不同环境温度和负载变化工况下的大量热点温度样本。同时采用 LSTM 网络，有效利用热点温度的历史信息，准确提取出热点温度动态演变与环境温度、负载变化、顶层油温等可测特征量的复杂关联关系，实现了变压器热点温度的动态预测。此外，引入集成经验模态分解(ensemble empirical mode decomposition，EEMD)算法优化 LSTM 网络，降低了噪声对热点温度预测效果的干扰，提高了网络的抗噪性能。

1　变压器热点温度仿真模型的构建

本文以 20 MVA/110 kV 三相油浸式变压器为研究对象，变压器的电学和结构参数如表 1 所示。仿真建模和计算流程如图 1 所示，主要方法为：首先，通过有限元算法求取不同负载率下的绕组和铁芯的发热功率密度，将其输入至温度仿真模型中；接着，通过有限体积算法仿真得到变压器内部温度分布。最后，提取出不同环境温度和负载变化条件下的热点温度和顶层油温样本。

1.1 变压器损耗计算

变压器的铁芯损耗主要与硅钢片厚度、铁芯磁通密度有关，绕组损耗主要与负载电流、导线电导率有关[21]。为简化建模和计算，本文构建的热损耗计算模型仅考虑了铁芯、绕组、变压器油和油箱结构，变压器热损耗计算模型如图 2 所示。

本文通过控制输入绕组低压侧和高压侧电流大小来控制负载率大小。IEEE 标准指出，变压器工作时的负载率 k 一般在 60%~120%之间[22]。通过变压器热损耗计算模型，计算不同负载率下变压器铁芯和绕组的功率损耗密度，为变压器温度场计算模型提供热源损耗数据。

1.2 变压器温度场计算

1.2.1 变压器流-热场耦合仿真模型的建立

变压器的散热片和油道结构会影响变压器的油流情况，从而影响到变压器内部温度分布[23]。因此，本文构建的温度场计算模型考虑了散热片、压板、绝缘挡板、油道等结构。

由于大型变压器 3 维模型网格数量众多，仿真计算耗时极长，难以满足大量工况仿真需求。对变压器进行 2 维等效可在保证一定准确度的前提下大幅降低仿真复杂性，加快仿真速度[24]。因此，本文采用 2 维等效模型来计算变压器内部温度分布，仿真模型如图 3 所示。

为保证 2 维模型结构的等效性，本文在建模前做了以下假设[24]：

1）变压器绕组为对称结构，附近的温度场和流场对称分布，绕组温度沿圆周方向无明显梯度变化，因此可把 3 维计算转化成 2 维轴对称计算。

2）三相绕组结构对称、热力学条件相同，绕组间的相互影响极小(可忽略)，因此可以把三相问题转化成单相问题进行计算。

3）绕组的温度分布仅由发热量、绕组附近变压器油的流动路径与流速决定。

此外，本文采用模型等效散热面积与实际散热器散热面积相等的方法来解决变压器结构中散热器与铁芯的对称轴不重合的问题。

1.2.2 网格剖分

本文采用三角形网格与四边形网格相结合的方法进行网格剖分。对于油箱内部的不规则区域，采用三角形网格剖分提高计算精度。对于变压器绕组、绝缘挡板、铁芯等规则区域，采用四边形网格剖分提高计算效率。其中，变压器绕组顶部区域的剖分结果如图 4 所示，网格单元数量约为 50 万个。以网格单元质量、纵横比和偏度为标准来评估网格质量[11]。网格质量指标的参考值以及本文变压器模型剖分网格质量各指标的实际值如表 2 所示，表明本文剖分的网格具有较高质量。

表 1 油浸式变压器的电学及结构参数

Table 1 The eletrical and structure parameters of oil-immersed transformer

变压器参数	数值
容量/MVA	20
额定电压/kV	110/10.5
额定电流/A	104.97/1 099.71
高/低压线圈内径/mm	357/278
高/低压线圈外径/mm	419/339
高/低压绕组高度/mm	749/769
油箱尺寸/	3 572 mm×1 464 mm×2 335 mm
铁芯叠片总厚度/mm	496
铁芯高度/宽度/窗高/mm	1 990/2 860/950
铁芯柱宽度/间距/mm	520/1 170

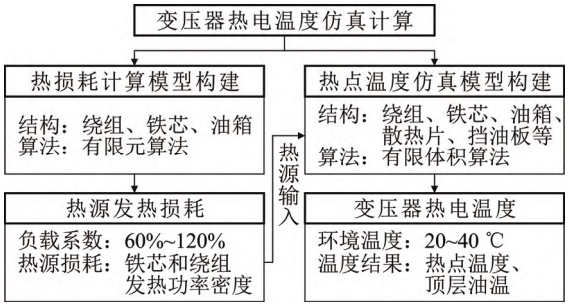

图 1 变压器热点温度仿真建模与计算流程

Fig.1 Process of transformer hot spot temperature simulation modeling and calculation

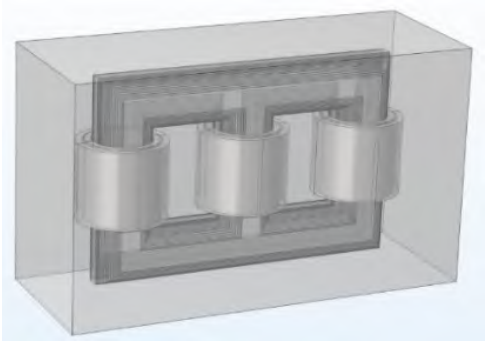

图 2 20 MVA 三相油浸式变压器热损耗计算模型

Fig.2 Calculation model of 20 MVA three-phase oil-immersed transformer heat loss

1.2.3 仿真条件的设置

在流-热场耦合仿真的边界条件方面，主要对初始温度、壁面边界条件、对流换热系数和材料参数进行设置。具体设置过程[20]如下：

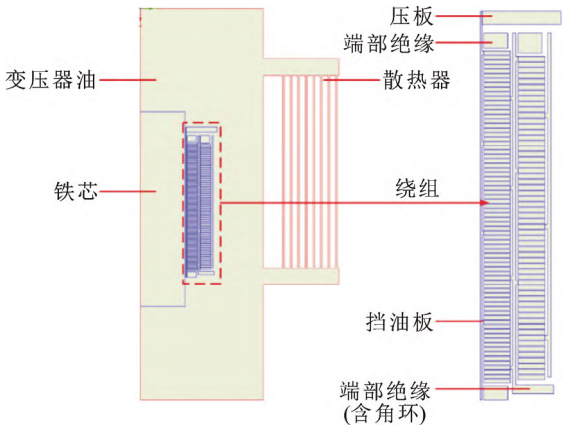

图 3　变压器温度场仿真模型

Fig.3　Simulation model of transformer temperature field

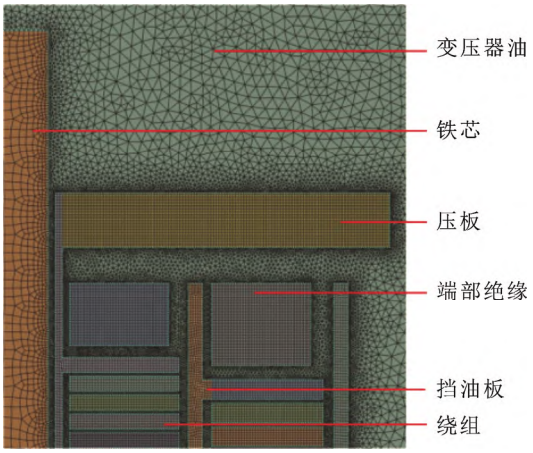

图 4　绕组顶部附近局部网格剖分示意图

Fig.4　Local grid diagram near the top of winding

1）设置环境温度为 20~40 ℃，变压器油温、油箱和散热片壁面温度初始值与环境温度一致。

2）设置油箱壁和铁芯表面为无滑移，绕组和散热片壁面为 Navier 滑移。

3）将油箱顶面和底面的对流换热系数 h 设为 4 W/(m^2·K)，侧面的对流换热系数 h 设为 6 W/(m^2·K)，散热片的对流换热系数 h 设为 12 W/(m^2·K)。

4）设置变压器的绕组、铁芯、变压器油、油箱和挡油板的材料参数，材料参数如表 3 所示。其中，θ 表示温度。

1.2.4　仿真方法

本文重点关注变压器热点温度在负载率突变情况下随时间的演变规律，因此先通过稳态仿真求取变压器在特定环境温度和负载率下的稳态温度场分布，然后以稳态仿真的结果为初始条件进行瞬态仿真，设置阶跃函数实现负载率的突变，求解热点温度的动态演变。例如，当负载率 k 从 80%上升至 100%时，首先通过稳态仿真求取负载率 80%时变压器达到稳态后的温度分布，然后以稳态仿真的结果为初始条件进行瞬态仿真，负载率在 1 h 后突变至 100%，继续运行 12 h，得到负载率变化后热点温度的变化情况。将时间步长设置为 1 min，并保存每分钟的温度结果，为深度学习网络训练提供足够样本。在仿真计算速度方面，采用 64 核超算进行计算后，单工况用时约为 2 h，能满足大量工况仿真需求。

表 2　网格质量标准参考值与实际值

Table 2　Reference and real value of grid quality standard

网格质量标准	参考值[11]	实际值
单元质量	平均值不低于 0.7， 最小值不低于 0.5	平均值：0.96 最小值：0.57
偏度	要求在 5 以内， 3 以内更好	平均值：1.21 最大值：2.89
纵横比	最大值在 0.8 以内	最大值：0.69 平均值：0.07

表 3　变压器材料参数

Table 3　Transformer material parameters

材料	参数	数值
绕组	密度/(kg·m^{-3})	8 800
	热导率/(W·m^{-1}·K^{-1})	395
	比热容/(J·kg^{-1}·K^{-1})	370
铁芯	密度/(kg·m^{-3})	7 650
	热导率/(W·m^{-1}·K^{-1})	45
	比热容/(J·kg^{-1}·K^{-1})	460
变压器油	密度/(kg·m^{-3})	$1\,055.04-0.58\theta-(6.41\times10^{-5})\theta^2$
	热导率/(W·m^{-1}·K^{-1})	$0.134-(8.05\times10^{-5})\theta$
	比热容/(J·kg^{-1}·K^{-1})	$-13\,408.15+123.044\,2\theta-0.335\,4\theta^2+(3.125\times10^{-4})\theta^3$
	动力黏度/(Pa·s)	$91.452-1.332\theta+(7.777\times10^{-3})\theta^2-(2.273\times10^{-5})\theta^3+(3.324\times10^{-8})\theta^4-(1.946\,3\times10^{-11})\theta^5$
油箱	密度/(kg·m^{-3})	7 860
	热导率/(W·m^{-1}·K^{-1})	35
	比热容/(J·kg^{-1}·K^{-1})	475
挡油板	密度/(kg·m^{-3})	1 150
	热导率/(W·m^{-1}·K^{-1})	0.2
	比热容/(J·kg^{-1}·K^{-1})	2 039

2　变压器温度预测深度学习模型构建

2.1　训练数据结构

本文通过变压器温度场瞬态仿真，得到时间尺度 t 为 0~780 min，负载率变化范围为 60%~120%，环境温度变化范围为 20~40 ℃时的热点温度数据库。在该数据库中，作为深度学习网络的输入特征量有 3 个，分别是负载率 k、环境温度 θ_{amb} 和顶层

油温θ_{top}；输出特征量为变压器绕组热点温度θ。因此，训练数据的输入特征向量可表示为：

$$\boldsymbol{X}=\left[\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_i,\cdots,\boldsymbol{X}_C\right] \tag{1}$$

式中：C=30，代表工况数。第 i 个工况下的输入特征量可表示为：

$$\boldsymbol{X}_i=\left[\boldsymbol{k}^i,\boldsymbol{\theta}^i_{amb},\boldsymbol{\theta}^i_{top}\right] \tag{2}$$

式中：$\boldsymbol{k}^i$、$\boldsymbol{\theta}^i_{amb}$、$\boldsymbol{\theta}^i_{top}$ 分别为第 i 个工况下 t 分钟内的负载率、环境温度和顶层油温，可表示为：

$$\boldsymbol{k}^i=\left[k^i_0,k^i_1,\cdots,k^i_{t-1},k^i_t\right]^{\mathrm{T}} \tag{3}$$

$$\boldsymbol{\theta}^i_{amb}=\left[\theta^i_{amb,0},\theta^i_{amb,1},\cdots,\theta^i_{amb,t-1},\theta^i_{amb,t}\right]^{\mathrm{T}} \tag{4}$$

$$\boldsymbol{\theta}^i_{top}=\left[\theta^i_{top,0},\theta^i_{top,1},\cdots,\theta^i_{top,t-1},\theta^i_{top,t}\right]^{\mathrm{T}} \tag{5}$$

热点温度特征向量可以表示为 $\boldsymbol{y}=[\boldsymbol{y}_1,\boldsymbol{y}_2,\cdots,\boldsymbol{y}_i,\cdots,\boldsymbol{y}_C]\in\mathbf{R}^{C\times t}$，$\boldsymbol{y}_i$ 为第 i 个训练工况下 t 分钟内的热点温度，可表示为：

$$\boldsymbol{y}_i=\left[\theta^i_0,\theta^i_1,\cdots,\theta^i_{t-1},\theta^i_t\right]^{\mathrm{T}} \tag{6}$$

训练数据库包含的变压器运行工况如图 5 所示，训练数据库结构如图 6 所示，其中，环境温度条件共 3 种，负载变化条件共 10 种，每个工况下的顶层油温和绕组最高温度数据有 781 组，一共有 23 430 组训练数据。

由于输入特征量之间数据大小差异较大，在训练过程中会带来较大波动，导致收敛速度慢，甚至无法收敛。为解决该问题，采用 min-max 归一化方法对负载率 k 之外的特征量进行归一化处理[19]：

$$\tilde{x}^{(i)}_k=\frac{x^{(i)}_k-x^{(i)}_{min}+\varepsilon}{x^{(i)}_{max}-x^{(i)}_{min}+\varepsilon} \tag{7}$$

式中：$x^{(i)}_k$ 为第 k 个样本的第 i 个特征量的原始值；$x^{(i)}_{max}$、$x^{(i)}_{min}$ 分别为第 i 个特征量所在样本中的最大值和最小值；ε为防止分母为 0 引入的微小值，为 $\tilde{x}^{(i)}_k$ 第 k 个样本的第 i 个温度特征量的归一化值。

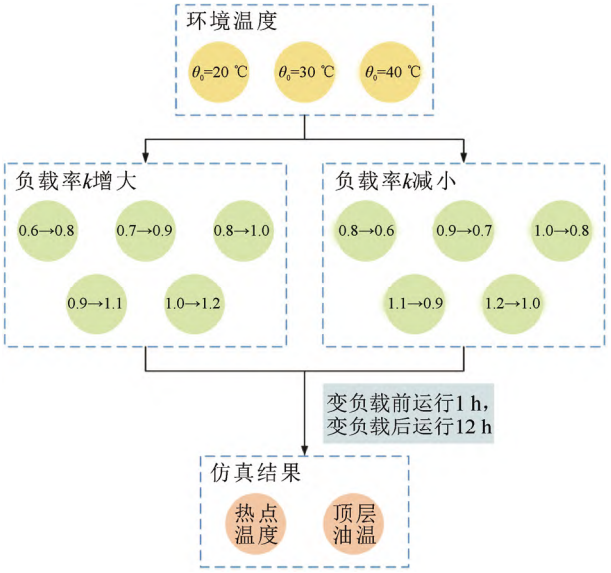

图 5 训练数据包含的运行工况

Fig.5 Operation conditions contained in the training data

输入特征量 输出特征量

工况	时间	负载率k	环境温度θ_{amb}	顶层油温θ_{top}	热点温度θ
1	0	k^1_0	$\theta^1_{amb,0}$	$\theta^1_{top,0}$	θ^1_0
	1	k^1_1	$\theta^1_{amb,1}$	$\theta^1_{top,1}$	θ^1_1
	⋮	⋮	⋮	⋮	⋮
	779	k^1_{779}	$\theta^1_{amb,779}$	$\theta^1_{top,779}$	θ^1_{779}
	780	k^1_{780}	$\theta^1_{amb,780}$	$\theta^1_{top,780}$	θ^1_{780}
⋮					
n	0	k^n_0	$\theta^n_{amb,0}$	$\theta^n_{top,0}$	θ^n_0
	1	k^n_1	$\theta^n_{amb,1}$	$\theta^n_{top,1}$	θ^n_1
	⋮	⋮	⋮	⋮	⋮
	779	k^n_{779}	$\theta^n_{amb,779}$	$\theta^n_{top,779}$	θ^n_{779}
	780	k^n_{780}	$\theta^n_{amb,780}$	$\theta^n_{top,780}$	θ^n_{780}

图 6 数据库结构

Fig.6 Structure of database

2.2 融合 EEMD 与 LSTM 的深度学习模型构建

2.2.1 集成经验模态分解(EEMD)

模态分解法(EMD)[25]常用于处理非平稳时间序列。基于 EMD，在输入特征序列 $\boldsymbol{X}(t)$中插入高斯白噪声序列，即为集成经验模态分解(EEMD)，可保证输入特征序列 $\boldsymbol{X}(t)$分解后得到的特征模态函数(intrinsic mode function，IMF)的唯一性。EEMD 算法充分利用高斯白噪声频率分布均衡的特点，取多次 EMD 分解后得到的 IMF 平均值消除加入的白噪声，从而改善模态混叠问题，显著降低了数据中的噪声对深度学习网络预测效果的干扰。EEMD 的具体步骤如下：

1）在原始输入特征序列 $\boldsymbol{X}(t)$中反复加入满足正态分布的白噪声序列 $\boldsymbol{n}_i(t)$：

$$\boldsymbol{X}_i(t)=\boldsymbol{X}(t)+\boldsymbol{n}_i(t) \tag{8}$$

式中：$\boldsymbol{n}_i(t)$为第 i 次加入的白噪声序列；$\boldsymbol{X}_i(t)$为加入 i 次白噪声序列后的热点温度序列。

2）对加入白噪声后的输入特征序列 $\boldsymbol{X}_i(t)$进行 EMD 分解，得到 IMF 分量 $\boldsymbol{C}_{i,j}(t)$和余项 $\boldsymbol{o}_i(t)$。

$$\boldsymbol{X}_i(t)=\sum_{j=1}^{J}\boldsymbol{C}_{i,j}(t)+\boldsymbol{o}_i(t) \tag{9}$$

式中：$\boldsymbol{C}_{i,j}(t)$为在热点温度序列中第 i 次加入白噪声后，通过 EMD 分解得到的第 j 个 IMF 分量；J 为分解的 IMF 分量数。

3）考虑不相关随机序列均值为零的特点，取各分量平均值抵消重复白噪声对 IMF 分量的影响：

$$\boldsymbol{C}_j(t)=\frac{1}{N}\sum_{i=1}^{N}\boldsymbol{C}_{i,j}(t) \tag{10}$$

式中：$\boldsymbol{C}_j(t)$为 EEMD 分解后得到的第 j 个 IMF 分量；N 为白噪声序列数。

4）在进行多次 EEMD 分解后，得到输入特征序列的最终变换结果，从而抵消噪声的影响：

$$\tilde{\boldsymbol{X}}(t)=\sum_{j=1}^{J}\boldsymbol{C}_j(t)+\boldsymbol{R}(t) \tag{11}$$

式中：$\boldsymbol{C}_j(t)$能够反映不同时间段热点温度的高低变化的趋势；$\boldsymbol{R}(t)$为经过多次分解后产生的总余项。

2.2.2　基于 LSTM 的深度学习模型

循环神经网络(recurrent neural networks，RNN)广泛用于时间序列的预测，例如语音识别、股价预测及电力需求方面预测[26]，因此也可用于随时间变化的热点温度序列预测。RNN 网络的主要结构如图 7 所示。

图 7(a)为基本 RNN 网络结构。在输入层中，特征量 $\boldsymbol{X}_t$ 包含 t 时刻的环境温度、负载率以及顶层油温。输出层中，时刻 t 的隐藏变量 $\boldsymbol{H}_t$，不仅取决于该时刻的输入特征参量 $\boldsymbol{X}_t$，也受前一时刻输出的隐藏变量 $\boldsymbol{H}_{t-1}$ 的影响，表达式如下：

$$\boldsymbol{H}_t=\sigma\left(\boldsymbol{X}_t\boldsymbol{w}_{\mathrm{xt}}+\boldsymbol{H}_{t-1}\boldsymbol{w}_{\mathrm{ht}}\right)+\boldsymbol{b} \tag{12}$$

式中：$\boldsymbol{w}_{\mathrm{xt}}$ 和 $\boldsymbol{w}_{\mathrm{ht}}$ 分别为 $\boldsymbol{X}_t$ 和 $\boldsymbol{H}_{t-1}$ 的权重；$\boldsymbol{b}$ 为偏置常数；σ 为隐藏层激活函数。

将前一时刻隐藏变量作为热点温度历史信息考虑后，网络可处理较短时间步长内的热点温度信息。然而，由于 RNN 单元只考虑了前一时间步的热点温度，因此在时间尺度较长的情况下，网络的预测精度会明显下降。此外，RNN 单元不会丢弃无用历史信息，导致时间尺度变长时，特征量的权重参数剧增，引起训练过程中的梯度衰减或爆炸问题。

在基本 RNN 网络的基础上，通过引入了输入门 $\boldsymbol{I}_t$、遗忘门 $\boldsymbol{F}_t$、输出门 $\boldsymbol{O}_t$、候选记忆细胞 $\hat{\boldsymbol{C}}_t$ 和记忆细胞 $\boldsymbol{C}_t$，即可得到长短期记忆网络(LSTM)，LSTM 网络的单元结构如图 7(b)所示。

LTSM 每个单元对热点温度信息的处理可以表示为：

$$\boldsymbol{I}_t=\sigma\left(\boldsymbol{X}_t\boldsymbol{W}_{\mathrm{xi}}+\boldsymbol{H}_{t-1}\boldsymbol{W}_{\mathrm{hi}}+\boldsymbol{b}_{\mathrm{i}}\right) \tag{13}$$

$$\boldsymbol{F}_t=\sigma\left(\boldsymbol{X}_t\boldsymbol{W}_{\mathrm{xf}}+\boldsymbol{H}_{t-1}\boldsymbol{W}_{\mathrm{hf}}+\boldsymbol{b}_{\mathrm{f}}\right) \tag{14}$$

$$\boldsymbol{O}_t=\sigma\left(\boldsymbol{X}_t\boldsymbol{W}_{\mathrm{xo}}+\boldsymbol{H}_{t-1}\boldsymbol{W}_{\mathrm{ho}}+\boldsymbol{b}_{\mathrm{o}}\right) \tag{15}$$

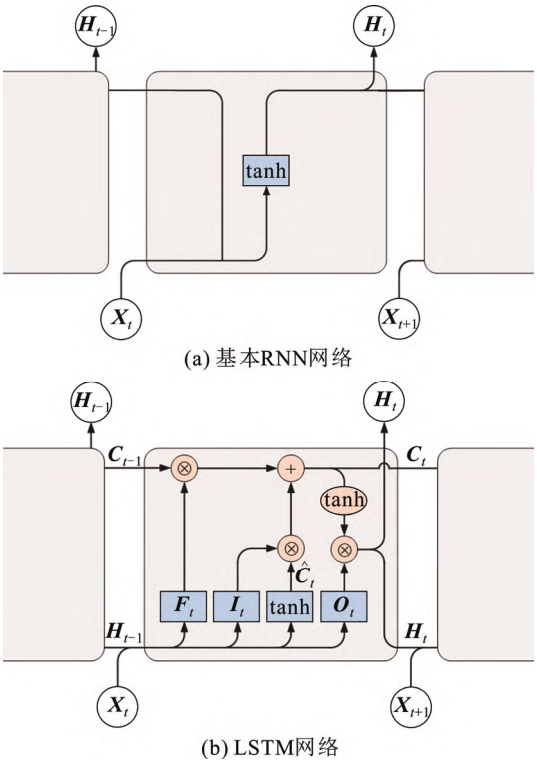

(b) LSTM网络

图 7　循环神经网络 RNN 结构

Fig.7　Structure of RNNs

$$\hat{\boldsymbol{C}}_t=\tanh\left(\boldsymbol{X}_t\boldsymbol{W}_{\mathrm{xc}}+\boldsymbol{H}_{t-1}\boldsymbol{W}_{\mathrm{hc}}+\boldsymbol{b}_{\mathrm{c}}\right) \tag{16}$$

$$\boldsymbol{C}_t=\boldsymbol{F}_t\otimes\boldsymbol{C}_{t-1}+\boldsymbol{I}_t\otimes\hat{\boldsymbol{C}}_t \tag{17}$$

$$\boldsymbol{H}_t=\boldsymbol{O}_t\otimes\tanh\left(\boldsymbol{C}_t\right) \tag{18}$$

式中：$\boldsymbol{W}_{\mathrm{xi}}$、$\boldsymbol{W}_{\mathrm{xf}}$、$\boldsymbol{W}_{\mathrm{xo}}$ 和 $\boldsymbol{W}_{\mathrm{hi}}$、$\boldsymbol{W}_{\mathrm{hf}}$、$\boldsymbol{W}_{\mathrm{ho}}$ 分别为输入门、遗忘门和输出门的权重参数；$\boldsymbol{b}_{\mathrm{i}}$、$\boldsymbol{b}_{\mathrm{f}}$、$\boldsymbol{b}_{\mathrm{o}}$ 分别为输入门、遗忘门和输出门的偏差参数；$\hat{\boldsymbol{C}}_t$ 为候选记忆细胞；⊗代表矩阵中对应元素相乘。

记忆细胞 $\boldsymbol{C}_t$ 用于存储变压器热点温度的历史信息，从而实现长时间尺度下变压器热点温度的准确预测；输入门 $\boldsymbol{I}_t$ 和遗忘门 $\boldsymbol{F}_t$ 可以更新记忆细胞中的有用信息、丢弃无用信息，从而解决训练过程中出现梯度衰减或爆炸的问题。

为准确预测负载率变化时变压器绕组上的最高温度随时间的演变特性，本文以 LSTM 网络为核心进行深度学习模型的构建，深度学习模型代码用 Python 3.7 编写，深度学习模型的结构如图 8 所示。

图 8 中，$\dot{\boldsymbol{x}}_t$ 为第 t 分钟时的监测量经过 EEMD 分解后的结果。L_1 和 L_2 为 LSTM 网络隐藏层传递函数。$\hat{\boldsymbol{X}}$ 为监测数据，表达式如下：

$$\hat{\boldsymbol{X}}=\left[\hat{\boldsymbol{x}}_0,\ \hat{\boldsymbol{x}}_1,\ \cdots,\ \hat{\boldsymbol{x}}_{t-1},\ \hat{\boldsymbol{x}}_t\right]^{\mathrm{T}} \tag{19}$$

式中：$\hat{\boldsymbol{x}}_t$ 为第 t 分钟时的监测量，包含 t 分钟时刻

的负载率 k_t、环境温度 $\theta_{amb,t}$ 和顶层油温 $\theta_{top,t}$ 的监测值，表达式如下：

$$\hat{\boldsymbol{x}}_t = \left[k_t,\ \theta_{amb,t},\ \theta_{top,t}\right] \tag{20}$$

$\hat{\boldsymbol{y}}$ 为 EEMD-LSTM 网络预测的热点温度，包括 t 分钟内的热点温度和未来 τ 分钟的热点温度预测值，表达式如下：

$$\hat{\boldsymbol{y}} = \left[\hat{\theta}_0,\ \hat{\theta}_1,\ \cdots,\ \hat{\theta}_t,\ \hat{\theta}_{t+\tau}\right] \tag{21}$$

式中：τ 的大小可以根据实际需要在 EEMD-LSTM 网络构建时进行设置。

3 仿真结果及深度学习模型预测结果

3.1 变压器热点温度稳态仿真结果

仿真不同负载率和环境温度下变压器稳态状况时的热点温度分布，可为负载突变时变压器热点温度随时间变化的瞬态仿真提供初始数据。仿真迭代过程的收敛图如图 9 所示。由图 9 可知，仿真迭代次数达到 5 000 左右时，残差基本稳定且残差值小于 10^{-4}，证明了仿真的收敛性良好。

从仿真结果中选取环境温度为 30 ℃，负载率分别为 90%、100%和 110%时，变压器热点温度分布图，可得到变压器热点温度分布规律，以及热点温度随负载率的变化规律。低压绕组轴向变压器热点温度随高度的变化如图 10 所示，温度分布随负载率的变化规律如图 11 所示。

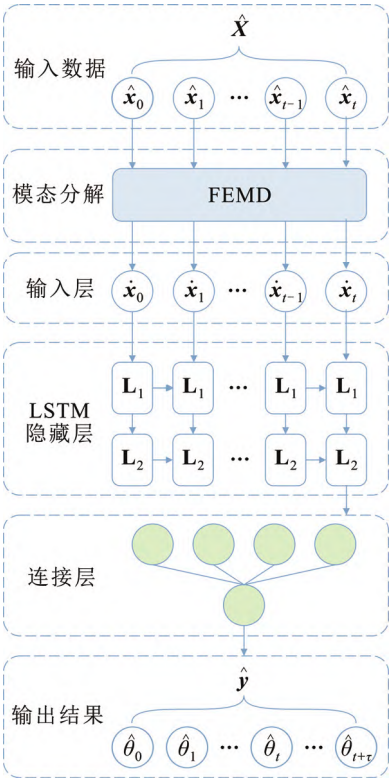

图 8 基于 LSTM 网络的深度学习模型结构

Fig.8 Structure of deep learning model based on LSTM

从图 10、图 11 可知，沿绕组轴向上，变压器温度随高度呈现上升趋势，在接近绕组顶部位置时达到最大值。由于变压器绕组和底油之间发生的是对流传热，因此变压器绕组与底油交界面附近温度变化显著。变压器顶油区域会保留较高温升，一定程度上能反映绕组热点温度的变化情况。环境温度

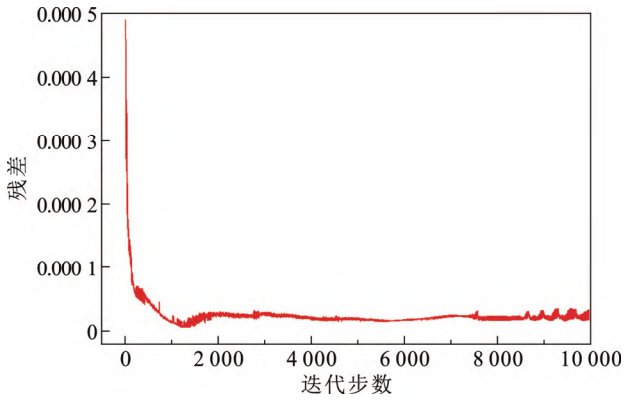

图 9 仿真计算收敛图

Fig.9 Convergence diagram of simulation

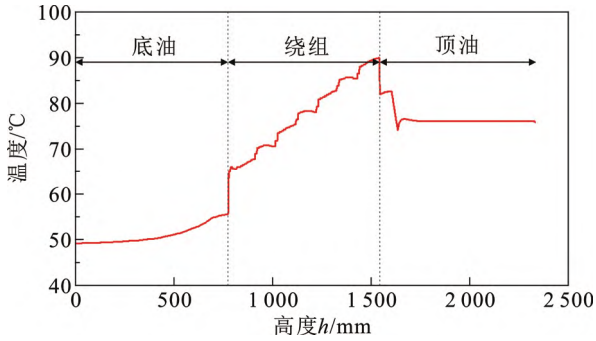

图 10 变压器低压绕组轴向高度温度分布

Fig.10 Temperature distribution of transformer low-voltage winding with axial height

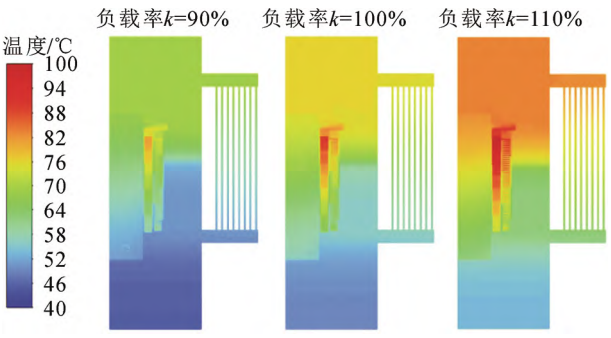

图 11 负载率 90%~110%时变压器内部温度分布

Fig.11 Temperature distribution of transformer when the load rate is 90%~110%

为 30 ℃，负载率为 90%、100%、110%时，变压器的热点温度分别为 81.4、90.0、99.2 ℃，顶层油温分别为 69.0、75.9、83.4 ℃。随着负载率上升，热点温度和顶层油温均以较快速度上升。

从仿真结果中选取负载率为 100%，环境温度分别为 20、30、40 ℃时，变压器热点温度分布如图 12 所示，热点温度分别为 82.3、90.0、98.0 ℃，顶层油温分别为 67.5、75.9、84.5 ℃。热点温度和顶层油温随环境温度升高而上升。通过仿真得到的变压器内部温度分布规律以及绕组上的热点温度符合变压器运行的实际情况[22]。

3.2　变压器流场分布结果

借助流线轨迹分析功能可得变压器内部流场分布情况，如图 13 所示。变压器内部大部分区域油流速很低，小于 0.70 cm/s，较高的油流速主要分布在顶油区域、散热器入口以及绕组竖直油道附近。最大油流速约为 3.52 cm/s。

3.3　负载率变化时热点温度的动态变化

从仿真结果中选取环境温度 30 ℃，负载率分别从 100%上升至 120%和从 100%下降到 80%时的热点温度随时间变化趋势曲线，如图 14 所示。

从图 14 可以看出，变压器热点温度在负载变化初期迅速上升或下降，之后变化速度减慢，并在负载率改变 10 h 左右后趋于稳定，符合正常情况下负载突变时的热点温度变化规律[22]。

3.4　基于 EEMD-LSTM 模型的热点温度预测结果

为评估 EEMD-LSTM 模型的预测效果，首先，通过损失函数变化曲线评估深度学习网络的训练效果；然后，将仿真所得热点温度随时间变化的曲线与 EEMD-LSTM 网络的预测结果进行对比，评估模型的热点温度预测效果；最后，将 EEMD-LSTM 网络与其他网络的预测效果进行比较，证明 EEMD-LSTM 网络具有更好的预测效果。

3.4.1　深度学习网络的训练

为保证深度学习网络达到最好的训练效果，在进行多次模型参数调整后，最终选择网络的隐藏层数为 3，节点数分别为 64、16 和 4，训练算法采用 Adam 算法，训练次数为 400。训练误差函数变化曲线如图 15 所示。其中，误差函数表达式如下：

$$L=\frac{1}{n}\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2 \tag{22}$$

式中：n 为训练数据样本数；y_i 和 $\hat{y}_i$ 分别为时间步 i 的变压器绕组热点温度 θ 的仿真值和深度学习模型

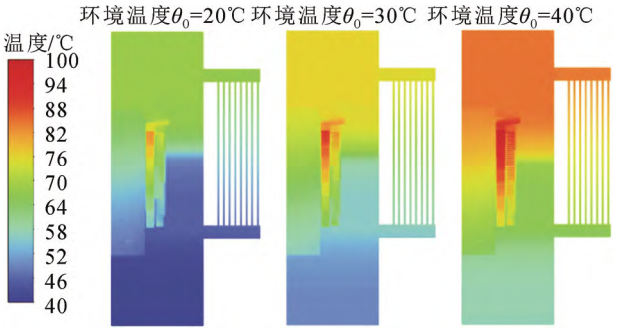

图 12　环境温度 20~40 ℃时，变压器内部温度分布

Fig.12　Temperature distribution of transformer under different ambient temperatures

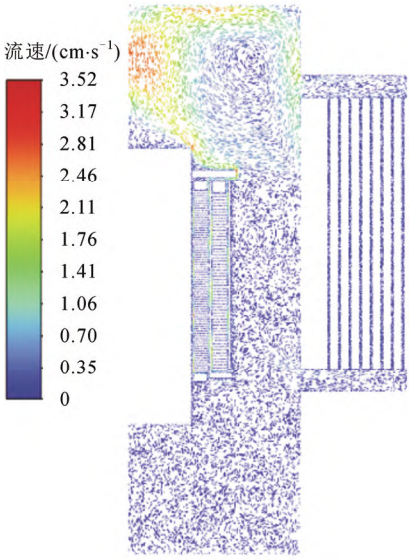

图 13　变压器流场分布仿真结果

Fig.13　Simulation results of the fluid field of transformer

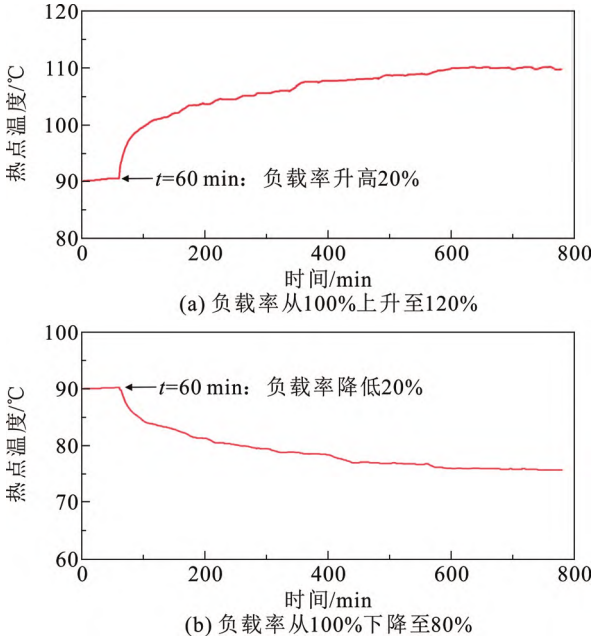

图 14　热点温度随时间的变化曲线

Fig.14　Hot spot temperature curves with time

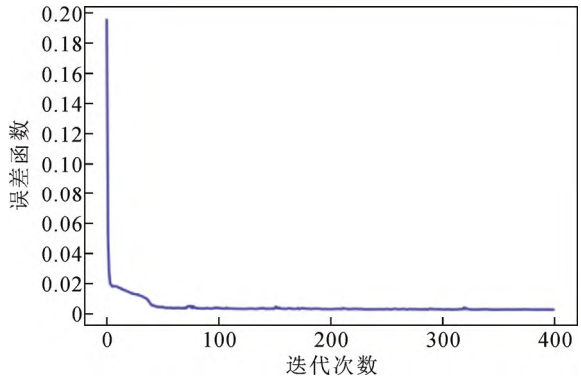

图 15 误差函数随迭代次数的变化曲线

Fig.15 Curve of the error as a function of iteration

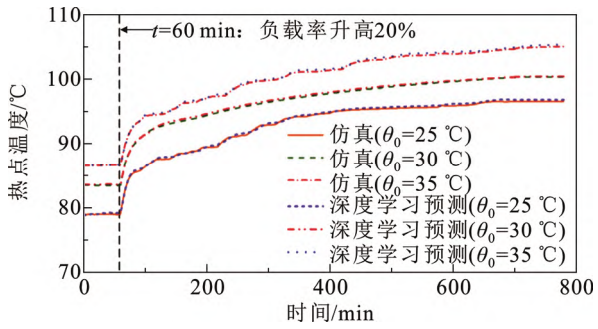

图 16 负载率从 95%上升至 115%时，深度学习模型预测与仿真计算所得热点温度对比

Fig.16 Hot spot temperature calculated by deep learning model compared with simulation when the load rate rises from 95% to 115%

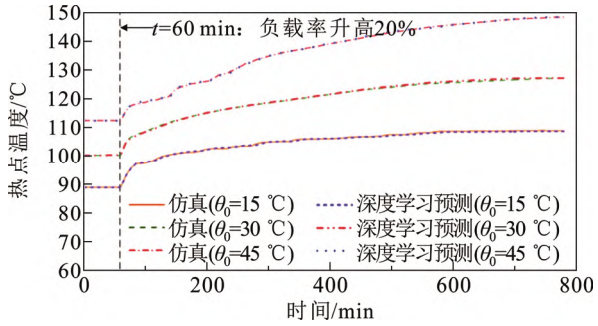

图 17 负载率从 110%上升至 130%时，深度学习模型预测与仿真计算所得热点温度对比

Fig.17 The hot spot temperature calculated by deep learning model compared with simulation when the load rate rises from 110% to 130%

预测值归一化后的结果。

3.4.2 模型预测效果

为验证 EEMD-LSTM 模型对变压器热点温度演变特性的预测能力，先采用训练数据范围覆盖的工况进行验证。环境温度分别为 25、30、35 ℃，负载率从 95%上升至 115%时，仿真所得热点温度曲线与深度学习模型预测温度曲线如图 16 所示。运行条件为：在负载率 95%时温度达到稳定状态下先运行 1 h，然后将负载率突增至 115%继续运行 12 h。由图 16 可知，在训练数据覆盖的工况内，本文构建的 EEMD-LSTM 模型热点温度预测的最大误差和平均误差分别为 0.32 ℃和 0.16 ℃，证明了模型具有较好的预测精度。

为了进一步验证 EEMD-LSTM 模型的外推能力，采用训练数据之外的负载变化工况进行验证。环境温度分别为 15、30、45 ℃，负载率从 110%上升至 130%时，仿真所得热点温度曲线与深度学习模型预测温度曲线如图 17 所示。运行条件为：在负载率 110%时温度达到稳定状态下先运行 1 h，然后将负载率突增至 130%继续运行 12 h。由图 17 结果可知，模型热点温度预测的最大误差和平均误差分别为 0.49 ℃和 0.20 ℃，仍然具有很高的预测精度，也证明了本文构建的模型在训练数据工况外也具有一定的外推能力。

3.4.3 不同深度学习网络预测效果对比

为证实本文所构建深度学习模型相比传统深度学习模型具有更好的预测效果和抗噪性能，在不给数据加噪声的情况下，将 EEMD-LSTM 网络与支持向量回归网络(support vector regression，SVR)、BPNN 和传统 LSTM 网络的预测效果进行对比，接着引入幅值为 5 ℃的随机噪声序列，再将不同网络的预测效果进行对比。其中，运行条件为：环境温度 30 ℃，在负载率 110%时温度达到稳定状态下先运行 1 h，然后将负载率突增至 130%继续运行 12 h。不同网络学习训练过程的迭代收敛曲线如图 18 所示。由图 18 可知，EEMD-LSTM 网络的误差函数收敛最快，SVR、BPNN、LSTM 和 EEMD-LSTM 网络的最终迭代误差分别为 0.012 8、0.011 0、0.003 1、0.002 2，表明了 EEMD-LSTM 网络具有更好训练效果。加入噪声前后，仿真所得热点温度曲线与深度学习模型预测温度曲线分别如图 19 和图 20 所示。温度预测的最大误差和平均误差的对比结果如表 4 所示。结果表明：本文构建的 EEMD-LSTM 模型相比其他模型，具有更好的温度预测效果。加入噪声后，EEMD-LSTM 网络的温度预测误差增大较小，仅增大了 0.47 ℃，而其他网络预测误差显著增大，证明了 EEMD-LSTM 网络具有较好的抗噪性能。

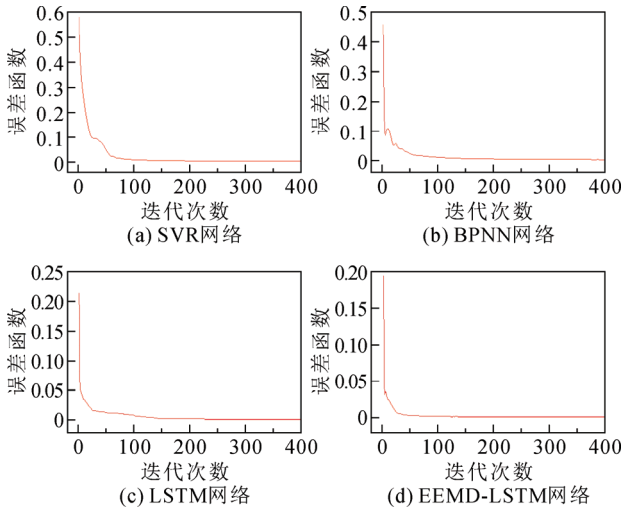

图 18　不同深度学习模型的学习训练过程

Fig.18　Training process of different deep learning model

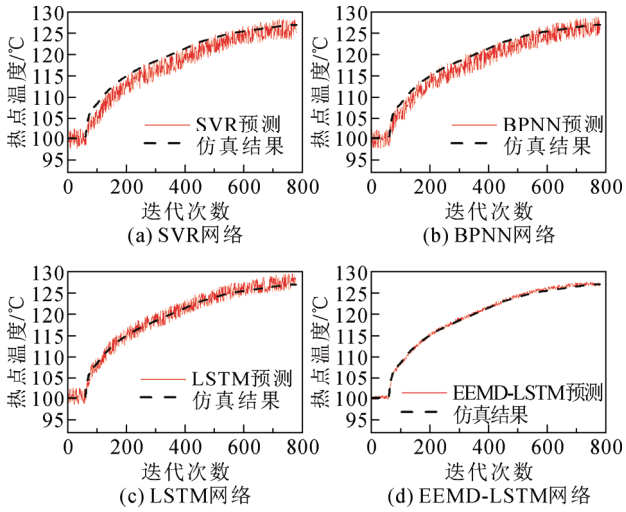

图 20　不同深度学习模型的抗噪性能

Fig.20　Anti-noise ability of different deep learning model

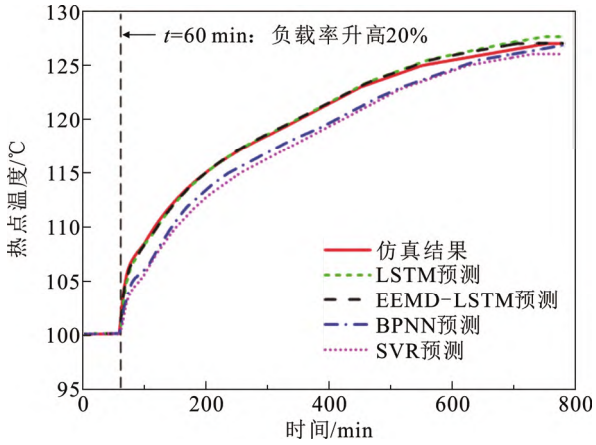

图 19　不同深度学习模型预测热点温度与仿真计算所得热点温度对比

Fig.19　The hot spot temperature calculated by different deep learning model compared with simulation

表 4　不同网络的预测结果

Table 4　Prediction results of different network

模型网络	温度预测无噪声数据/℃		温度预测数据混入噪声/℃	
	最大误差	平均误差	最大误差	平均误差
SVR	2.89	1.56	5.27	1.97
BPNN	2.65	1.25	4.90	1.65
LSTM	0.84	0.31	2.68	1.07
EEMD-LSTM	0.49	0.20	0.96	0.31

表 5　试验用变压器的主要参数

Table 5　Parameters of experimental transformer

变压器参数	数值
容量/kVA	30
额定电压/kV	10/0.4
额定电流/A	1.73/43.3
高压线圈内径/mm	209/147
高压线圈外径/mm	243/181
低压线圈内径/mm	147/85
低压线圈外径/mm	173/111
高/低压绕组高度/mm	110/116
油箱尺寸	850 mm×410 mm×480 mm
铁芯叠片总厚度/mm	132/80
铁芯高度/宽度/窗高/mm	310/440/150
铁芯柱宽度/间距/mm	80/180

3.5　仿真模型与深度学习模型有效性的实验验证

20 MVA 大型变压器温度达到稳定的时间极长，单工况运行时间在 30 h 以上，且大型变压器设备成本高，试验电价昂贵，因此大型变压器试验难度大。

本文采用 30 kVA/10 kV 的三相变压器进行试验，并运用本文提出的方法对试验用变压器进行仿真建模，以及构建温度预测深度学习模型。试验用变压器的主要参数见表 5。变压器实物结构及其流-热场耦合仿真模型分别如图 21、图 22 所示。其中，试验用变压器绕组为层式结构，且无挡油板结构。

采用荧光光纤测温系统获取变压器热点温度和顶层油温。由于变压器热点温度位于接近低压绕组顶部处[23]，因此在每个低压绕组距离顶部 3 mm 位置分别布置 2 路测温探头，取其最大值作为热点温度；在距离油箱顶部 5 mm 位置布置 1 路测温探头来获取顶层油温。光纤传感器布置示意图如图 23 所示。该光纤温度传感器的测温范围为–20~260 ℃，测温精度为±0.5 ℃。

现场试验设备布置如图 24 所示。通过负载电

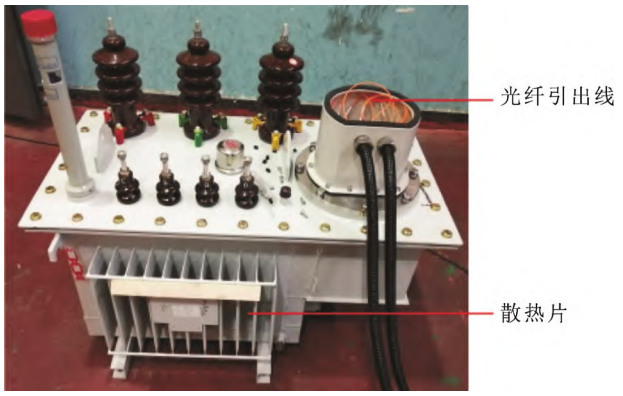

图 21 变压器实物

Fig.21 Real transformer

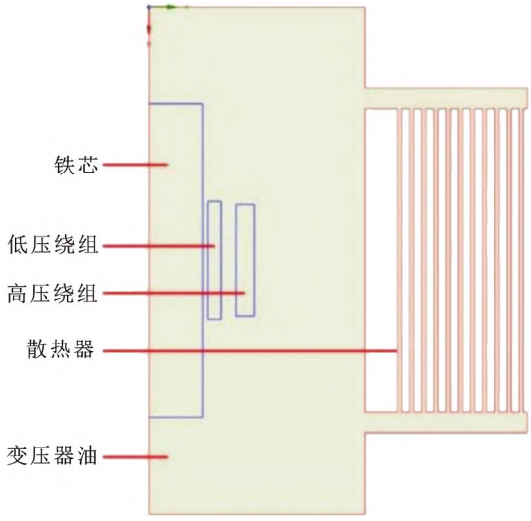

图 22 试验用变压器的 2 维等效模型

Fig.22 2D equivalent model of experimental transformer

流控制台给变压器加载。光纤传感探头通过变压器箱顶的贯通器和法兰组件向外引出，与光纤传感装置的主机相连，光纤传感装置的主机对传感器采集到的数据进行处理，并显示各个探头测得的温度。光纤传感主机通过 USB/RS-485 转换器与计算机相连，将采集到的温度数据存储到计算机中。

本文试验包含两种工况：负载率从 100%上升至 120%；负载率从 100%下降至 80%。运行条件为：变压器在负载率 100%条件下运行至热点温度达到稳定状态，然后将负载率升高或降低 20%，再次运行至热点温度达到新的稳定状态。仿真计算所得热点温度曲线、EEMD-LSTM 网络反演所得热点温度曲线与试验测得热点温度曲线如图 25 所示。仿真热点温度与实测热点温度间的最大误差为 2.43 ℃，平均误差为 1.12 ℃，证明了本文仿真建模方法的有效性。EEMD-LSTM 网络预测热点温度与实测热点温

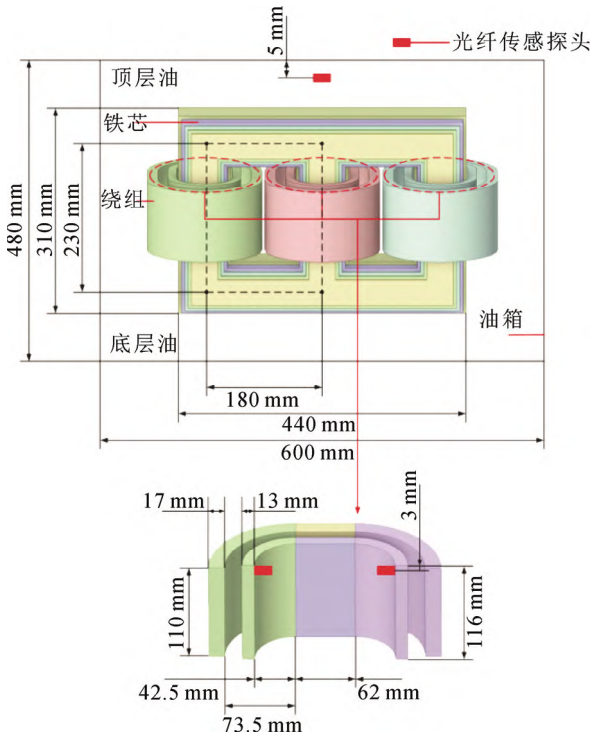

图 23 光纤传感探头布置位置

Fig.23 Arrangement location of the optical fiber sensor

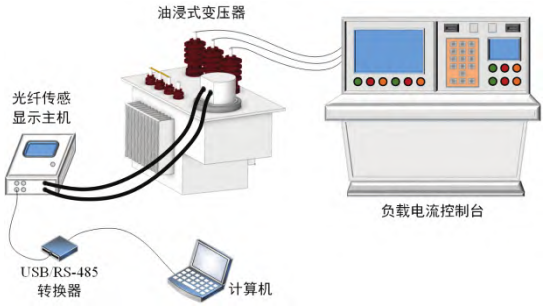

图 24 试验设备

Fig.24 Experimental setup

度间的最大误差为 2.81 ℃，平均误差为 1.35 ℃，进一步验证了 EEMD-LSTM 网络能满足热点温度动态预测需求。

4 结论

本文以 20 MVA 油浸式变压器为对象，通过流-热场耦合仿真，得到变压器内部温度场分布，并获取不同环境温度和负载率变化条件下的大量温度数据样本。提出 EEMD 优化 LSTM 网络的方法，构建了深度学习模型，实现了变压器热点温度的实时准确预测。主要结论如下：

1）通过构建变压器流-热场耦合仿真模型，仿真得到不同环境温度和负载变化条件下的变压器热

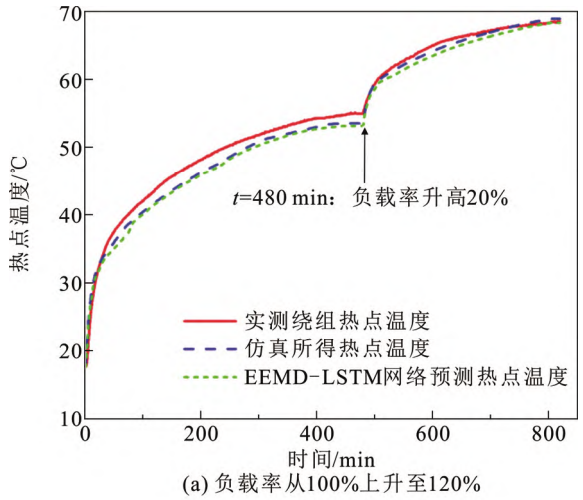

(a) 负载率从100%上升至120%

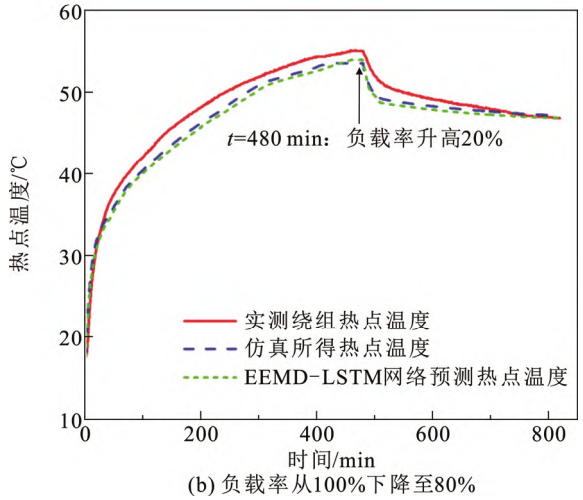

(b) 负载率从100%下降至80%

图 25　试验结果

Fig.25　Experimental results

点温度和顶层油温数据，进而为温度预测深度学习模型的训练提供大量多工况组合训练数据。通过变压器热点温升试验对仿真模型进行验证，结果表明仿真所得热点温度曲线与试验测得的热点温度曲线平均误差为 1.12 ℃，证明了流-热场耦合仿真模型能够为深度学习模型提供可靠训练数据。

2）以负载率、环境温度、顶层油温时间序列作为输入特征量，采用 EEMD 优化过的 LSTM 网络构建热点温度预测的深度学习模型。通过测试表明 EEMD-LSTM 模型预测的热点温度与仿真所得热点温度的最大误差和平均误差分别为 0.49 ℃和 0.20 ℃，相比 SVR、BPNN 及传统 LSTM 模型具有更高的准确性。

3）通过在热点温度数据中引入幅值 5 ℃的随机噪声来验证 EEMD-LSTM 模型的抗噪性能。结果表明，本文方法与仿真结果相比，引入噪声后的最大误差为 0.96 ℃，平均误差为 0.31 ℃，相比 SVR、BPNN 及传统 LSTM 模型具有更好的抗噪性能。

参考文献　References

[1] 郭红兵，杨　玥，孟建英. 电力变压器典型故障案例分析[M]. 北京：中国水利水电出版社，2019：54-58.
GUO Hongbing, YANG Yue, MENG Jianying. Typical fault case analysis of power transformer[M]. Beijing, China: China Water and Power Press, 2019: 54-58.

[2] 江秀臣，许永鹏，李曜丞，等. 新型电力系统背景下的输变电数字化转型[J]. 高电压技术，2022，48(1)：1-10.
JIANG Xiuchen, XU Yongpeng, LI Yaocheng, et al. Digitalization transformation of power transmission and transformation under the background of new power system[J]. High Voltage Engineering, 2022, 48(1): 1-10.

[3] 侯验秋，丁　一，包铭磊，等. 电–气耦合视角下德州大停电事故分析及对我国新型电力系统发展启示[J]. 中国电机工程学报，2022，42(21)：7764-7774.
HOU Yanqiu, DING Yi, BAO Minglei, et al. Analysis of Texas black-out from the perspective of electricity-gas coupling and its enlightenment to the development of China's new power system[J]. Proceedings of the CSEE, 2022, 42(21): 7764-7774.

[4] LI Y X, WANG Y, CHEN Q X. Optimal dispatch with transformer dynamic thermal rating in ADNs incorporating high PV penetration[J]. IEEE Transactions on Smart Grid, 2021, 12(3): 1989-1999.

[5] ALVAREZ D L, RIVERA S R, MOMBELLO E E. Transformer thermal capacity estimation and prediction using dynamic rating monitoring[J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1695-1705.

[6] LIU Y P, LI X Y, LI H, et al. Spatially continuous transformer online temperature monitoring based on distributed optical fibre sensing technology[J]. High Voltage, 2022, 7(2): 336-345.

[7] 刘云鹏，李　欢，高树国，等. 分布式光纤传感在大型变压器温度和绕组变形监测中的应用研究[J]. 中国电机工程学报，2022，42(16)：6126-6135.
LIU Yunpeng, LI Huan, GAO Shuguo, et al. Research on application of distributed optical fiber sensing in monitoring of temperature and winding deformation of large transformer[J]. Proceedings of the CSEE, 2022, 42(16): 6126-6135.

[8] LI M Y, WANG Z Z, ZHANG J S, et al. Temperature rise test and thermal-fluid coupling simulation of an oil-immersed autotransformer under DC bias[J]. IEEE Access, 2021, 9: 32835-32844.

[9] 杨　帆，郝翰学，王鹏博，等. 电力装备多物理场数值计算发展现状[J]. 高电压技术，2023，49(6)：2348-2364.
YANG Fan, HAO Hanxue, WANG Pengbo, et al. State of the art of multiphysics simulation technology for power equipment[J]. High Voltage Engineering, 2023, 49(6): 2348-2364.

[10] 荆澜涛，董雪情，杨　超，等. 面向数字孪生应用的变压器温度场有限元降阶建模方法研究[J]. 高电压技术，2023，49(6)：2408-2419.
JING Lantao, DONG Xueqing, YANG Chao, et al. Research on finite element reduced order modeling method of transformer temperature field for digital twin application[J]. High Voltage Engineering, 2023, 49(6): 2408-2419.

[11] CHI C, YANG F, XU C, et al. A multi-scale thermal-fluid coupling model for ONAN transformer considering entire circulating oil systems[J]. International Journal of Electrical Power & Energy Systems, 2022, 135: 107614.

[12] LIU J F, DING Z S, FAN X H, et al. A BPNN model-based AdaBoost algorithm for estimating inside moisture of oil-paper insulation of

power transformer[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2022, 29(2): 614-622.

[13] LI S Y, XUE J, WU M Z. Prediction of transformer top oil temperature based on improved weighted support vector regression based on particle swarm optimization[C] // 2021 International Conference on Advanced Electrical Equipment and Reliable Operation. Beijing, China: IEEE, 2021: 1-5.

[14] ZHOU L J, WANG J, WANG L J, et al. A method for hot-spot temperature prediction and thermal capacity estimation for traction transformers in high-speed railway based on genetic programming[J]. IEEE Transactions on Transportation Electrification, 2019, 5(4): 1319-1328.

[15] QIN Z M, LIU D, HUA H C, et al. Privacy preserving load control of residential microgrid via deep reinforcement learning[J]. IEEE Transactions on Smart Grid, 2021, 12(5): 4079-4089.

[16] LI C, CHEN J, XUE C J, et al. Simultaneous multispot temperature prediction of traction transformer in urban rail transit using long short-term memory networks[J]. IEEE Transactions on Transportation Electrification, 2023, 9(3): 4552-4561.

[17] ZOLLANVARI A, KUNANBAYEV K, BITAGHSIR S A, et al. Transformer fault prognosis using deep recurrent neural network over vibration signals[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.

[18] NALAJAM P K, VARADARAJAN R. A hybrid deep learning model for layer-wise melt pool temperature forecasting in wire-arc additive manufacturing process[J]. IEEE Access, 2021, 9: 100652-100664.

[19] LI D, LIU P, ZHANG Z S, et al. Battery thermal runaway fault prognosis in electric vehicles based on abnormal heat generation and deep learning algorithms[J]. IEEE Transactions on Power Electronics, 2022, 37(7): 8513-8525.

[20] 倪子瞻，盛戈皞，张立静，等. 基于多物理场仿真和神经网络算法相结合的油浸式变压器热点温度动态反演方法[J]. 高电压技术，2023，49(6)：2466-2477.
NI Zizhan, SHENG Gehao, ZHANG Lijing, et al. Dynamic inversion method of hot spot temperature of oil-immersed transformer based on combination of multiphysics simulation and neural network algorithm[J]. High Voltage Engineering, 2023, 49(6): 2466-2477.

[21] RODRIGUES T F, MEDEIROS L H, OLIVEIRA M M, et al. Evaluation of power transformer thermal performance and optical sensor positioning using CFD simulations and temperature rise test[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-11.

[22] IEEE Standards Association. IEEE guide for loading mineral-oil-immersed transformers and step-voltage regulators: C57.91-2011[S]. New York, USA: IEEE Power & Energy Society, 2011.

[23] GEZEGIN C, OZGONENEL O, DIRIK H. A monitoring method for average winding and hot-spot temperatures of single-phase, oil-immersed transformers[J]. IEEE Transactions on Power Delivery, 2021, 36(5): 3196-3203.

[24] YATSEVSKY V A. Hydrodynamics and heat transfer in cooling channels of oil-filled power transformers with multicoil windings[J]. Applied Thermal Engineering, 2014, 63(1): 347-353.

[25] HAO H B W, YU F H, LI Q L. Soil temperature prediction using convolutional neural network based on ensemble empirical mode decomposition[J]. IEEE Access, 2021, 9: 4084-4096.

[26] BEDI J, TOSHNIWAL D. Deep learning framework to forecast electricity demand[J]. Applied Energy, 2019, 238: 1312-1326.

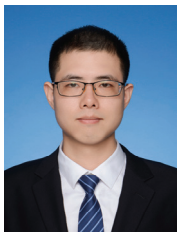

杨子坚
1998—，男，硕士生
主要从事变压器热点温度预测与负荷能力评估方面的研究工作
E-mail: 790938922@qq.com

YANG Zijian

司马文霞
1965—，女，博士，教授，博导
主要从事电磁暂态感知、建模、分析与防护；电网雷电致灾机理与接地防护技术；电力装备绝缘失效机制与防御技术方面的研究工作
E-mail: cqsmwx@cqu.edu.cn

SIMA Wenxia
Ph.D., Professor

杨　鸣(通信作者)
1987—，男，博士，教授，博导
主要从事交直流电网电磁暂态特性分析与防护、变压器类装备电磁暂态建模与应用、新型直流装备电磁暂态建模与应用方面的研究工作
E-mail: cqucee@cqu.edu.cn

YANG Ming
Ph.D., Professor
Corresponding author

收稿日期　2023-11-19　修回日期　2024-02-20　　编辑　卫李静