

# 基于流线和 SVR 的变压器热点温度反演方法

全 好, 阮江军, 龚若涵, 陈荆洲, 金 颀, 文 武

(武汉大学电气工程学院, 湖北 武汉 430072)

**摘要:** 变压器热点温度是影响变压器运行状态、物理条件和绝缘寿命的重要因素之一。为了避免植入光纤测量热点温度时造成不良影响, 本文通过推导传热学方程, 提出了一种基于流线和支向量回归机(SVR)的热点温度反演方法。以 10kV 单相变压器模型为例, 进行了不同热源、对流换热系数和环境温度的温度场数值计算, 并提取了三类主流线, 研究了不同流线点数目、位置 and 不同流线根数下的热点温度反演结果, 得出了选取同时流经热点和变压器外壳附近的流线时, 热点温度反演精度最高的结论。此外, 在众多该类流线中, 仅选择一条流线并在该流线上选择温差最大的两个点所对应的外壳点作为温度测点时, 热点温度反演误差最小, 误差均在  $\pm 0.5^{\circ}\text{C}$  以内。该方法实现了特征量测量非植入, 比传统方法具有更高的精度, 并为变压器状态实时监测、热点温度计算提供了一种新途径。

**关键词:** 流线; 支向量回归机; 非植入; 热点温度; 反演模型

**DOI:** 10. 12067/ATEEE1803030      **文章编号:** 1003-3076(2018)11-0023-09      **中图分类号:** TM411

## 1 引言

变压器作为电力系统中最重要设备之一, 数量众多, 结构复杂, 直接关系到供电的可靠性和安全性。变压器内部各部件所达到的最高温度即为热点温度, 是影响变压器运行状态、物理条件和绝缘寿命的重要因素之一。为了保证变压器设备在运行中的安全性和高效性, 避免在运行过程中出现故障, 对变压器热点的在线监测至关重要。国内外变压器热点测量方法主要有直接测量法和间接测量法。直接测量法利用光纤传感器的耐腐蚀、抗电磁干扰、体积小和测量精度高等优点, 通过将光纤传感器埋设在绕组导线上直接测量热点温度。但对于实际运行中的变压器, 采用光纤传感器植入变压器测量热点温度的弊端和隐患不容忽视: ①由于敷设传感器时需要对外壳进行打孔, 可能会造成变压器油渗漏和潮湿环境下测温油槽进水并积聚的后果<sup>[1]</sup>; ②由于传感器的埋设会影响油流分布<sup>[2]</sup>, 且当变压器运行工况不同时还需重复测量, 测量成本高; ③由于热点位置的不确定性, 测量结果不一定是热点温度。以上问题都限制了植入式光纤测温系统在变压器热点温度

测量中的推广使用, 因此提出了非植入的热点温度间接测量方法。

间接测量法主要包括热模拟法、热路模型法和数值计算法。热模拟法是由负载导则 IEC 354<sup>[3]</sup> 推导得出的简化形式, 由测量得到的顶层油温和绕组相对于顶层油温的温升得到绕组热点温度, 具有较大误差。热路模型法<sup>[4]</sup> 将变压器内传热过程类比电路模型, 建立起反映变压器物理过程的顶层油温和热点温度计算模型, 使用时需要变压器的传热参数。数值计算法<sup>[5,6]</sup> 通过建立变压器模型, 利用有限元积分法解决边界值问题, 但由于变压器模型通常都很复杂, 模型网格数多, 存在变压器温度场计算量大、计算效率低的问题。

因此, 为了简单、高效地检测运行中的变压器热点温度, 采用人工智能算法, 根据变压器运行数据对热点温度进行反演成为了当今研究的热潮。目前采用的人工智能算法主要有 Kalman 数字滤波<sup>[7,8]</sup>、BP 神经网络算法<sup>[9-15]</sup>、遗传算法<sup>[16-20]</sup> 和支向量回归机 (Support Vector Regression, SVR)<sup>[21,22]</sup>。Kalman 数字滤波不仅可以给实测数据去噪, 还原精确的热点温度值, 还可以预测出缺失的观测值, 但若给定的

收稿日期: 2018-03-12

**作者简介:** 全 好(1995-), 女, 江西籍, 硕士研究生, 研究方向为变压器状态评估;  
阮江军(1968-), 男, 湖北籍, 教授, 博士, 研究方向为高电压与绝缘技术、电磁场数值分析及其工程应用。

系统初值不确定会造成最终热点温度估计值的变化率超出预计范围。文献[8]采用卡尔曼滤波从观测的热点温度数据中提取了真实值,利用主成分分析法进行输入特征量的降维并结合BP神经网络法对变压器的热点温度进行预测。但BP神经网络有着网络收敛速度慢、学习速率不易确定的弱点。

支持向量回归机将学习问题最终转化为一个凸二次规划的优化问题,解决了传统神经网络方法无法避免的局部极值问题。文献[21]应用支持向量回归机,以变压器负载电流、环境温度、顶层油温、底层油温、油箱上死角温度、油箱下死角温度6个特征量对热点温度进行预测,研究结果表明,支持向量回归机的预测精度高于神经网络算法。但是文献[21]中温度特征量需要热电偶植入变压器中进行测量。因此,本文在文献[21]的基础上,根据传热模型推导,提出了一种基于流线的壳测温点选取方法,在热点反演工作中,仅采用变压器外壁的外壳点进行温度反演,规避了植入光纤所带来的问题。

在实际应用中,SVR的参数选取直接关系到反演精度,遗传算法是一种采用生物遗传学的启发式算法,可以在复杂的参数搜索空间中较为迅速地找到最优解,因此本文利用遗传算法对SVR进行参数寻优。同时,本文针对流线法,研究了不同流线类型、流线数目和流线上特征温度点选取方式对反演结果的影响。将反演结果与文献[21]提出的方法进行对比,论证了模型的反演精度,使其可以更好地应用于工程实际。

## 2 反演方法原理和理论基础

### 2.1 反演方法理论基础

#### 2.1.1 流线传热传质模型

流线是指同一时刻,不同流体质点所组成的曲线,曲线上流体质点的速度方向与曲线的切线方向一致<sup>[23]</sup>。因而流线表示该时刻流场中质点的速度方向,如图1所示。迹线是指同一流体质点在不同时刻的速度方向,在温度达到稳态时,迹线与流线重合。




图1 流线图

Fig. 1 Streamline diagram

变压器中油流的热量会随着流体质点的运动而传递,根据热传导定律可知,单位时间内通过单位截面积所传递的热量 $q_n$ ,正比于当地垂直于截面方向上的温度变化率,热量传递的方向与温度升高的方向相反,即

$$q_n = -k \frac{\partial T}{\partial n} \quad (1)$$

式中, $q_n$ 表示单位时间内通过单位面积的流体热量; $k$ 表示传导系数; $\partial T/\partial n$ 表示热流方向上的温度梯度(K/m);负号表示热流方向始终与温度梯度的正向方向相反。

对于每一个流线微元,若单元的长度为 $\Delta x$ ,如图2所示,并作出如下假设:①在流线方向上,热量的传播方式为热对流和热传导;在流线的法向方向上,热量的传播方式仅为热传导;②已知流线上贴近外壳处的微元末点温度 $T_n$ 、导热系数 $k$ ,对流换热系数 $h$ 和流速 $v_1$ 未知,而第一个微元的初始温度 $T_0$ 为待求量。




图2 流线微元热量传导过程

Fig. 2 Heat conduction process of flow line microelement

根据能量守恒定律,稳态场中该微元能量守恒,则有:

$$dQ_0 - dQ'_1 - dQ_1 = 0 \quad (2)$$

又根据对流传热定律,可以得到流动时间 $dt$ 内,切向散热量为:

$$dQ_1 = (kS \frac{\Delta T}{\Delta x} + \alpha S \Delta T) dt \quad (3)$$

式中, $\alpha$ 为热对流系数,是一个与流速有关的变量,即 $\alpha = f(v)$ 。将式(3)代入式(2)中即可得到:

$$dQ_0 - dQ'_1 = [kS \frac{\Delta T}{\Delta x} + f(v) S \Delta T] dt \quad (4)$$

式(4)两边同时除以 $dt$ ,并令 $dQ_0/dt = P_0$ , $dQ'_1/dt = P'_1$ ,则有:

$$P_0 - P'_1 = kS \frac{\Delta T}{\Delta x} + f(v) S \Delta T \quad (5)$$

通过式(5)即可得到流线微元的稳态热路分布参数模型,如图3所示。

在实际应用中需要将微元模型转化为适宜计算的集中参数模型,将流线微元扩展为流经长度 $x_0$ 至




图3 流线微元的稳态热路分布参数模型

Fig. 3 Distribution parameter model of steady state heat path model of streamline element

$x_1$  之间的流线 ( $x_0 < x_1$ ), 并设  $x_0$  处的温度为  $T_0$ ,  $x_1$  处的温度为  $T_1$ , 则流经热阻  $R$  的热功率  $P_R$  经积分可表示为:

$$P_R = \frac{kS \int_{T_0}^{T_1} \partial T}{\int_{x_0}^{x_1} \partial x} + f(v) S \int_{T_0}^{T_1} \Delta T$$

$$= \frac{kS(T_1 - T_0)}{x_1 - x_0} + f(v) S(T_1 - T_0) \quad (6)$$

将式(6)类比于电阻和电容, 得到面积为  $S$ 、长度为  $x$  的流线微元热阻表达式为:

$$R = \frac{x}{kS + f(v)Sx} \quad (7)$$

集中参数近似处理引入了一定的误差, 采用集中热阻处理时要求该处流速波动足够小, 若流速变化太大, 则必须将其分为多个集中元件, 从而减小误差。得到最终的变压器油域中单条流线稳态热路模型如图4所示。




图4 流线稳态分布参数热路模型

Fig. 4 Thermal path model of steady distribution parameter of streamline

在流线稳态分布参数热路模型中, 由于热阻值和法向热通量的未知, 无法通过解析计算从外壳温度求得热点温度。但是易知热点到外壳间的热量大部分都是沿着流线方向传递, 因此只要沿着流线寻找和热点温度具有固定规律的外壳点, 利用支持向量回归机器学习, 即对热点温度进行反演。

### 2.1.2 SVR 理论及参数寻优方法

支持向量分类机建立一个超平面将观察样本中属于不同类型的数据正确分开<sup>[24]</sup>, 而回归机利用支

持向量构造一个最优超平面使求得的数据最接近于该平面<sup>[25]</sup>。假设存在一个训练集为  $(\mathbf{x}_i, y_i)$ ,  $\mathbf{x}_i$  是一个具有  $m$  个特征的向量, 当数据是线性可分的, 建立的最优超平面为:

$$y_i = \mathbf{x}_i^T \mathbf{w} + b \quad (8)$$

式中,  $\mathbf{w}$  为一个  $m$  行的向量, 为各特征量的权值矩阵, 也表示最优超平面的法向量;  $b$  为偏置,  $b \in R$ 。建立的超平面如图5所示, 使所有样本点中离该超平面的“最大偏差”最小。




图5 最优超平面原理图

Fig. 5 Schematic of optimal hyperplane

其数学描述为: 设  $S = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m\}$ , 为包含  $m$  个特征的数据集合, 且  $\mathbf{x}_i \in R, i = 1, 2, \dots, m$ , 另有  $\Omega = \{f|f: S \rightarrow y_i\}$ , 对于给定的回归函数  $f \in \Omega$ , 训练样本的值与其实际值的偏差不超过给定误差  $\epsilon$ , 数据点与超平面的偏差为  $\text{Margin}(f)$ , 则反问题的求解可归纳为:

$$e_{\text{mse}} = \min_{f \in \Omega} \{ \max [\text{Margin}(f)] \} \quad (9)$$

式中,  $e_{\text{mse}}$  为表征训练的 SVR 模型的拟合准确率, 通常采用均方误差来表示。  $e_{\text{mse}}$  越小, 则所有样本点中离该超平面的“最大偏差”越小, 训练样本的反演精度越高。求解回归机中最优回归超平面同样等价于求解分类机中最大分类间隔, 因此求解函数  $f$  归结为如下的规划问题:

$$\begin{cases} \min \langle \mathbf{w} \cdot \mathbf{w} \rangle = \min \frac{1}{2} \|\mathbf{w}\|^2 \\ y_i - (\mathbf{x}_i^T \mathbf{w} + b) \leq \epsilon \quad i = 1, 2, \dots, l \\ y_i - (\mathbf{x}_i^T \mathbf{w} + b) \geq -\epsilon \quad i = 1, 2, \dots, l \end{cases} \quad (10)$$

当存在  $\epsilon$  带外的样本时, 可以引入松弛变量  $\xi$  和  $\xi^*$ , 即允许一部分的样本超出约束范围, 此时得到的最优超平面为广义最优超平面。为了控制训练集上的识别错误数, 引入惩罚系数  $C$ , 对松弛变量加以控制, 则求解函数  $f$  归结为如下的规划问题:

$$\begin{cases} \min \langle \mathbf{w} \cdot \mathbf{w} \rangle = \min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s. t.} \\ y_i - (\mathbf{x}_i^T \mathbf{w} + b) \leq \varepsilon + \xi_i \\ y_i - (\mathbf{x}_i^T \mathbf{w} + b) \geq -\varepsilon - \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0 \end{cases} \quad (11)$$

通过引入非负的 Lagrange 乘子,可以得到 SVR 的拟合函数(回归函数):

$$f(\mathbf{x}) = \sum_{i=1}^l (\mathbf{a}_i^* - \mathbf{a}_i) (\mathbf{x}_i^T \cdot \mathbf{x}) + b \quad (12)$$

式中,  $(\mathbf{x}_i^T \cdot \mathbf{x})$  为向量  $\mathbf{x}_i^T$  与向量  $\mathbf{x}$  的内积;  $\mathbf{a}_i$ 、 $\mathbf{a}_i^*$  为引入非负的 Lagrange 乘子;  $b$  为偏置参数。

对于非线性支持向量回归,可以把样本  $\mathbf{x}$  通过非线性映射  $\Phi(\mathbf{x})$  映射到高位特征空间,并在其中求解最优回归函数。通过该映射,由原来的对应于输入空间的训练集  $T = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_l, y_l)\}$  可以得到对应于高维空间的新的训练集  $\bar{T} = \{(\Phi(\mathbf{x}_1), y_1), (\Phi(\mathbf{x}_2), y_2), \dots, (\Phi(\mathbf{x}_l), y_l)\}$ 。因此,在最优回归函数中采用适当的核函数  $K(\mathbf{x}_i, \mathbf{x})$  代替高维空间中的向量内积  $\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x})$ ,就可以实现某一线性变换后的线性拟合。回归函数的法向量和回归函数变为:

$$\mathbf{w} = \sum_{i=1}^l (\mathbf{a}_i^* - \mathbf{a}_i) \Phi(\mathbf{x}_i) \quad (13)$$

$$f(\mathbf{x}) = \sum_{i=1}^l (\mathbf{a}_i^* - \mathbf{a}_i) K(\mathbf{x}_i, \mathbf{x}) + b \quad (14)$$

在支持向量回归机中,由于核函数的引入,实现了把非线性回归转化为高维空间线性回归的功能,因此核函数在非线性回归中起着重要作用。本文选用径向基函数(RBF)<sup>[26]</sup>:

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-\gamma \|\mathbf{x} - \mathbf{x}_i\|^2) \quad \gamma > 0 \quad (15)$$

式中,核参数  $\gamma > 0$ ;  $\|\mathbf{x}_i - \mathbf{x}_j\|$  为欧式范数。

由 SVR 原理可知,惩罚系数  $C$  和核函数参数  $\gamma$  决定了 SVR 的曲线拟合准确率。本文基于  $k$  折交叉思想,采用遗传算法(GA)进行参数寻优。GA 算法是一种采用生物遗传学的启发式算法,可以在复杂的参数搜索空间中较为迅速地找到最优解<sup>[22]</sup>。

### 2.1.3 误差分析方法

误差分析是变压器温度反演的重要步骤之一。

通过误差分析,可以对反演模型的优劣进行科学评价,指导模型反演结果的合理应用。本文采用以下几种常用的误差指标对反演结果进行误差分析<sup>[24]</sup>。

(1) 均方根误差(Root Mean Squared Error, RMSE)

$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (A_i - P_i)^2} \quad (16)$$

式中,  $A_i$  为第  $i$  个测试样本的实际值;  $P_i$  为第  $i$  个测试样本的反演值;  $N$  为预测样本的个数。

(2) 平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)

$$e_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{A_i - P_i}{A_i} \right| \quad (17)$$

(3) 均方百分比误差(Mean Square Percentage Error, MSPE)

$$e_{\text{MSPE}} = \frac{1}{N} \sqrt{\sum_{i=1}^N \left( \frac{A_i - P_i}{A_i} \right)^2} \quad (18)$$

## 2.2 基本原理和实现流程

### 2.2.1 基本原理

流线表示该时刻流场中质点的速度方向,在温度达到稳态时,流线与迹线重合,因此根据变压器中油介质的流线选择温度点进行热点反演具有说服力。然而试验测量油流中的热点温度难度较大,且若测量的光纤随液体浮动容易造成测温点温度出现较大偏差。为解决上述问题,找到流线点对应的外壳点,直接采用外壳上的测温点进行热点反演。

为使 SVR 模型具备更强的学习能力,采用正交设计的原则选取训练样本。根据 6 因素 5 水平(低压热源功率  $P_1$ , 高压热源功率  $P_2$ , 底面换热系数  $h_1$ , 顶层换热系数  $h_2$ , 侧面换热系数  $h_3$ , 环境温度  $T_0$ ) 进行正交表排列,选出了 25 组训练样本,训练样本集如表 1 所示,表 1 中同时列出热点温度  $T$ 。并随机选取了 7 组测试样本,如表 2 所示。

对 32 组样本的计算结果进行处理后,发现热点温度都出现在绕组的 1~3 饼之间。在 32 组计算结果中,换热系数是不可测量的系数,因此以低压热源功率、高压热源功率、外壳测温点温度作为 SVR 输入参量,以热点可能出现的绕组温度作为 SVR 的输出参量,最后取三层绕组温度最大值作为热点温度,由此建立起变压器热点温度反演模型。



表 1 训练样本集  
Tab.1 Training samples

样本 编号	$P_1$ /W	$P_2$ /W	$h/(W/(m^2 \cdot K))$			$T_0$ /℃	$T$ /℃
			$h_1$	$h_2$	$h_3$		
1	30	40	4	8	10	10	59.34
2	30	50	6	10	12	15	64.45
3	30	60	8	12	14	20	70.17
4	30	70	10	14	16	25	76.31
5	30	80	12	16	18	30	82.67
6	40	40	6	12	16	30	74.77
7	40	50	8	14	18	10	56.70
8	40	60	10	16	10	15	76.10
9	40	70	12	8	12	20	85.42
10	40	80	4	10	14	25	93.81
11	50	40	8	16	12	25	79.03
12	50	50	10	8	14	30	88.40
13	50	60	12	10	16	10	69.18
14	50	70	4	12	18	15	77.64
15	50	80	6	14	10	20	101.95
16	60	40	10	10	18	20	73.86
17	60	50	12	12	10	25	94.76
18	60	60	4	14	12	30	103.29
19	60	70	6	16	14	10	82.22
20	60	80	8	8	16	15	91.21
21	70	40	12	14	14	15	77.47
22	70	50	4	16	16	20	86.05
23	70	60	6	8	18	25	95.10
24	70	70	8	10	10	30	121.22
25	70	80	10	12	12	10	97.60

表 2 测试样本集  
Tab.2 Test samples

样本 编号	$P_1$ /W	$P_2$ /W	$h/(W/(m^2 \cdot k))$			$T_0$ /℃	$T$ /℃
			$h_1$	$h_2$	$h_3$		
1	78	53	17	13	12	27	102.04
2	47	73	9	9	11	16	90.60
3	62	45	10	11	13	18	81.66
4	32	47	11	6	9	36	90.70
5	24	26	7	8	10	18	53.45
6	86	21	9	12	16	9	71.25
7	25	89	7	13	15	18	78.79

2.2.2 实现流程

本文提出的基于流线和 SVR 的变压器热点温度反演方法的实现流程如图 6 所示。

具体步骤如下：

(1)温度场数值仿真得到训练样本的温度分布和流线图。在所有流线中合理选取代表性流线,并根据流线轨迹选择变压器外壳测温点。结合已知的其他三个特征量形成温度场特征集,进行归一化处

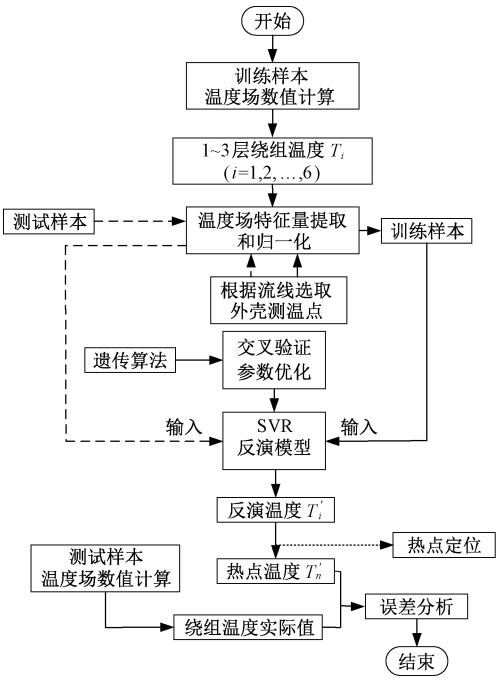


图 6 变压器热点温度反演方法流程图  
Fig.6 Flow chart of transformer hot spot temperature inversion method

理,作为 SVR 模型训练样本的输入。

(2)基于训练样本集,采用 SVR 建立绕组热点的反演模型,并采用遗传算法<sup>[21]</sup>进行参数优化,得到最优参数对 SVR 进行训练。

(3)将测试样本的低压热源功率、高压热源功率、外壳测温点温度依次输入训练好的 SVR 模型中,得到三层绕组温度,取其中的最大值为该组测试样本的热点温度。

(4)将温度场数值计算得到的测试样本温度值作为实际值,与反演值进行对比,并采用均方误差  $e_{mse}$ 、均方根误差  $e_{RMSE}$ 、平均绝对百分比误差  $e_{MAPE}$  和均方百分比误差  $e_{MSPE}$  四个指标来评价模型的性能和反演效果。当  $e_{mse}$  越小说明模型的性能越好,当  $e_{RMSE}$ 、 $e_{MAPE}$  和  $e_{MSPE}$  越小,说明反演效果越好。

3 最佳流线的选择方法

变压器中油介质热量的传递大部分是沿着流线的方向,然而变压器中存在着无数条的流线,并不是每一条流线都能够反映热点到外壁的散热过程。为了从错综复杂的流线中挑选出热点热量传递的主路径,首先对流线进行观察和分类,从不同的散热路径中选取主流线。然后通过对比不同流线类型、流线数目和流线上特征温度点选取方式下的热点反演误

差,总结最优流线选取方法并采用该方法对热点温度进行反演。

3.1 主流线的选取

以单相 10kV 变压器为例,由变压器温度场计算可以得到 25 个训练样本,变压器油流速分布图如图 7 所示。

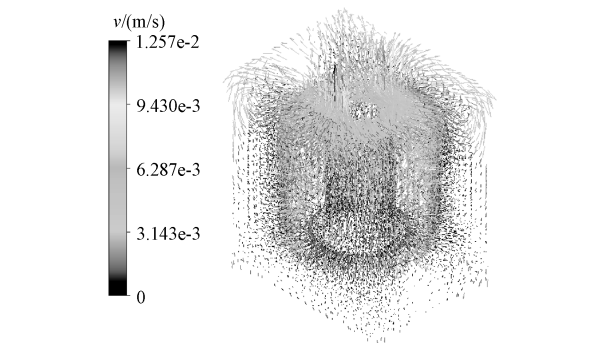


图 7 变压器流速图  
Fig. 7 Transformer velocity diagram

观察变压器的总体流线,将主流线分为三类:①从变压器底端到绕组热点的流线;②从绕组上层热油到变压器中下部的流线;③在变压器上层热油附近循环流动的流线。三类主流线图如图 8 所示。




图 8 三类主流线图

Fig. 8 Three types of main streamline graphs

为对比三类流线的反演误差,在每一类流线中随机选择两根进行反演工作。每根流线上选择温差最大的两个流线点,根据变压器模型的对称性,每个流线点均选择离其最近的三个面的外壳测温点温度与其对应,得到热点的反演误差如表 3 所示。

由表 3 可知,前两类流线的反演效果较好,第三类流线反演误差较大。这是因为前两类流线同时流经了热点和外壳附近,因此在流线的选择时,应在第一、二类流线中进行选择。

3.2 流线点位置和个数的选取

将两类流线进行编号,每类流线包含两根流线,1 号流线和 2 号流线为第一类流线,3 号流线和 4 号流线为第二类流线,分别在四条流线上采用两种

表 3 三类流线温度反演误差对比

Tab. 3 Error comparison of three types of streamline temperature inversion

流线类别	$e_{RMSE}/^{\circ}C$	$e_{MAPE}(\%)$	$e_{MSPE}(\%)$	$e_{mse}/(^{\circ}C)^2$
1	0.1153	0.1255	0.0707	0.0067
	0.1162	0.1265	0.0705	0.0069
2	0.1199	0.1216	0.0757	0.0053
	0.1099	0.1286	0.0611	0.0066
3	1.6918	2.0062	1.0410	0.2177
	1.8110	2.1566	1.1265	0.2111

方法进行流线点位置的选取,具体如下:  
(1)按照等间距的方式在流线上选点,选择 2 ~ 5 个点,利用外壳点(6 ~ 15 个)反演热点,反演误差如图 9 所示。其中  $n$  为流线点个数。

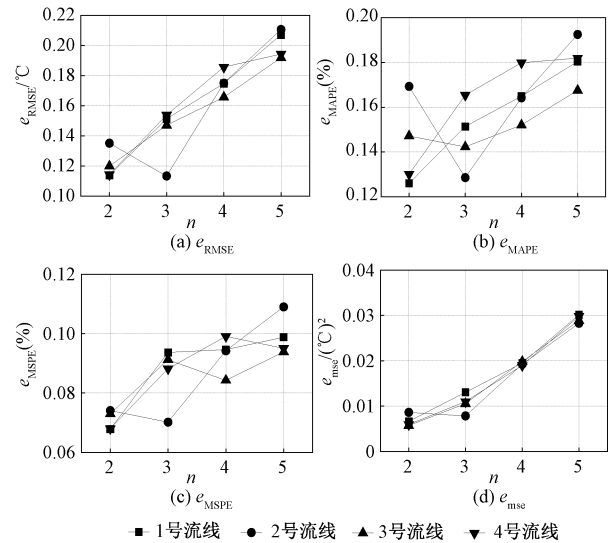


图 9 按照距离选择外壳点时的反演误差图  
Fig. 9 Inversion error in choosing shell point according to distance

(2)按照等温差的方式在流线上选点,选择 2 ~ 5 个点,利用外壳点(6 ~ 15 个)反演热点时的误差,结果如图 10 所示。

由图 9 可知,等距离选择流线点时,不同流线的反演误差无明显规律;而由图 10 可见,按照温差选择流线点时,不同流线的反演误差具有相同规律性,均随着流线点个数的增加反演误差呈增长趋势,其中选择温差最大的 2 个流线点时的反演误差均最小。由图 10(d)可知,当选择 2 个流线点时表征训练模型 SVR 的拟合准确率参数  $e_{mse}$  也最小,因此在单条流线上选择流线点时,按照温度梯度进行选择,并且选择温差最大的两个流线点进行温度反演效果最佳。

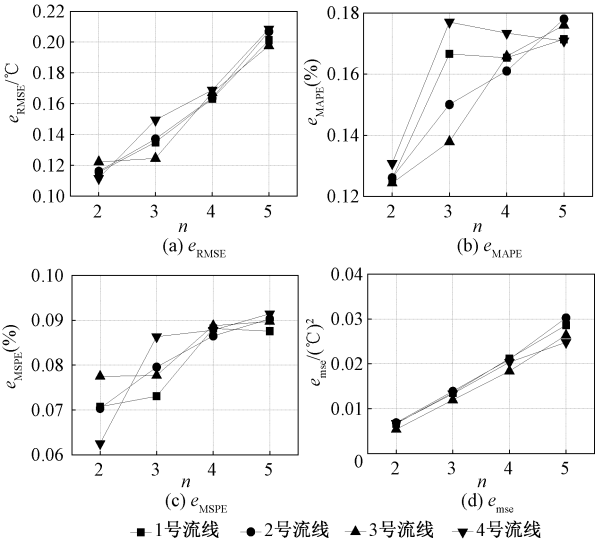


图 10 按照温差选择外壳点时的反演误差  
Fig. 10 Inversion error in choosing shell point according to temperature gradient

3.3 流线数目的选取

由 3.2 节可知,对于单条流线,按照温差选择流线点具有一定的规律。且选择流线上温差最大的两个点时,热点温度反演误差最小。因此当采用多条流线进行反演时,同样根据温差进行流线点的选取,在每条流线上选择温差最大的 2 个流线点,对比不同流线数目对反演误差的影响,结果如图 11 所示。其中  $i$  为流线数目。




图 11 流线数目对变压器热点反演误差的影响  
Fig. 11 Influence of number of streamlines on inversion error of transformer hot spot

由图 11 可知,采用多条流线进行温度反演时,由于不同流线的温度数据之间相关性强,当外壳点数目增多时数据冗余反而造成反演误差增大,因此在众多的流线中,仅选择一条主流线进行热点的温度反演效果最佳。

4 最佳流线反演误差

根据第 3 节分析,得到最佳流线的选取方法,归纳如下:

- (1)选取的流线需流经热点和外壳附近。
- (2)在众多流线中,有且仅选择一条流线进行热点反演。
- (3)流线上选取温差最大的两个流线点作为特征流线点,并选择离流线点最近的三个面的外壳点温度对流线点温度进行表征。

根据上述方法选取了一条流线进行热点温度反演;同时按照文献[21]中特征量的选取方式,以负载电流、环境温度、顶层油温、底层油温、油箱上死角温度、油箱下死角温度 6 个特征量对热点温度进行反演,得到两种方法下 7 组测试样本热点温度的反演误差,结果如图 12 所示。其中,  $k$  为测试样本编号,  $\Delta T$  为反演温差。由图 12 可知,相比于文献[21]选取的外壳测温点,采用流线法选取外壳特征点进行热点反演时,反演误差更加平稳,且 7 组测试样本误差均在  $\pm 0.5^{\circ}C$  以内。因此本文算法具有更高的热点反演精度。




图 12 流线法与传统方法对热点反演误差对比  
Fig. 12 Error comparison between streamline method and traditional method for hot spot inversion

5 结论

本文对变压器油温度场进行了计算,通过分析油流传热机理,得到流线稳态分布参数热路模型,提出基于流线和支撑向量回归机的绕组热点温度反演模型。为得到最佳的流线和最优的外壳测温点选择方法,对比了不同流线点数目、位置 and 不同流线根数下热点反演误差,得到了以下结论:

(1)根据变压器油流程图选取主流线,可将错综复杂的流线进行分类。在主流线选取方面,应该尽量选取温差较大的主流线,这样可以整个模型中获得更全面的温度信息,反演效果更好。不宜选择多条流线同时进行反演,避免小模型中的输入量冗余。

(2)在流线上选取温差最大的两个流线点作为特征流线点,并选择离流线点最近的三个外壳点作为外壳测温点。采用选取的最佳流线进行热点温度反演,反演误差均在 $\pm 0.5^{\circ}\text{C}$ 以内。

(3)流线法实现了特征量的完全非植入测量,且相比于传统方法具有更高的反演精度,能够更好地满足工程要求。

本文为变压器绕组热点反演提供了一种新方法。然而对于复杂变压器,流线的选取需考虑更多因素,在后续研究中,还需对反演模型进一步优化,以实现该方法的工程应用。

## 参考文献 (References):

- [1] 张本宇 (Zhang Benyu). 电力变压器温度控制器典型故障的分析与研究 (Analysis and study on typical faults of power transformer temperature controller) [D]. 武汉: 武汉大学 (Wuhan: Wuhan University), 2017.
- [2] 苏小平 (Su Xiaoping). 油浸式变压器绕组热点温度计算模型及预测方法研究 (Research on calculation model and prediction method of winding hot spot temperature in oil immersed transformer) [D]. 重庆: 重庆大学 (Chongqing: Chongqing University), 2012.
- [3] IEC 60076-7, Power transformers - Part 7: Loading guide for oil-immersed power transformers [S].
- [4] 陈伟根, 李孟励, 孙才新, 等 (Chen Weigen, Li Mengli, Sun Caixin, et al.). 变压器绕组热点温度热电类比计算模型仿真分析 (A neural network improvement method for hot spot temperature prediction of transformer windings) [J]. 重庆大学学报 (Journal of Chongqing University), 2010, 33 (12): 8-13.
- [5] Gong R, Ruan J, Chen J, et al. A 3-D coupled magneto-fluid-thermal analysis of a 220 kV three-phase three-limb transformer under DC bias [J]. Energies, 2017, 10 (4): 422.
- [6] Gong R, Ruan J, Chen J, et al. Analysis and experiment of hot-spot temperature rise of 110 kV three-phase three-limb transformer [J]. Energies, 2017, 10 (8): 1079.
- [7] 奚红娟, 冯浩, 郑贺伟 (Xi Hongjuan, Feng Hao, Zheng Hewei). 一种变压器绕组热点温度预测的神经网络改进方法 (A neural network improvement method for hot spot temperature prediction of transformer windings) [A]. 中国电机工程学会年会 (Annual Conference of Chinese Society of Electrical Engineering) [C]. 2013. 1-6.
- [8] 修春波, 任晓, 李艳晴, 等 (Xiu Chunbo, Ren Xiao, Li Yanqing, et al.). 基于卡尔曼滤波的风速序列短期预测方法 (A short-term prediction method of wind speed series based on Kalman filter) [J]. 电工技术学报 (Transactions of China Electrotechnical Society), 2014, 29 (2): 253-259.
- [9] Daponte P, Grimaldi D, Piccolo A, et al. A neural diagnostic system for the monitoring of transformer heating [J]. Measurement, 1996, 18 (1): 35-46.
- [10] Tylavsky D J, He Q, Si J, et al. Transformer top-oil temperature modeling and simulation [J]. IEEE Transactions on Industry Applications, 2000, 36 (5): 1219-1225.
- [11] He Q, Si J N, Tylavsky D J. Prediction of top-oil temperature for transformers using neural networks [J]. IEEE Transactions on Power Delivery, 2000, 15 (4): 1205-1211.
- [12] Tylavsky D J, He Q, McCulla G A, et al. Sources of error in substation distribution transformer dynamic thermal modeling [J]. IEEE Transactions on Power Delivery, 2000, 15 (1): 178-185.
- [13] Galdi V, Ippolito L, Piccolo A, et al. Neural diagnostic system for transformer thermal overload protection [J]. IEEE Proceedings - Electric Power Applications, 2000, 147 (5): 415-421.
- [14] Pradhan M K, Ramu T S. On-line monitoring of temperature in power transformers using optimal linear combination of ANNs [A]. Conference Record of the 2004 IEEE International Symposium on Electrical Insulation [C]. Indianapolis, USA, 2004. 70-73.
- [15] Nguyen H, Baxter G W, Reznik L. Soft computing techniques to model the top-oil temperature of power transformers [A]. International Conference on Intelligent Systems Applications to Power Systems (ISAP) [C]. Taiwan, 2007. 1-6.
- [16] Tang W H, Zeng H, Nuttall K I, et al. Development of power transformer thermal models for oil temperature prediction [M]. Berlin: Springer-Verlag, 2000. 195-204.
- [17] 李龙, 魏靖, 黎灿兵, 等 (Li Long, Wei Jing, Li Canbing, et al.). 基于人工神经网络的负荷模型预测 (Load model prediction based on artificial neural network) [J]. 电工技术学报 (Transactions of China Electrotechnical Society), 2015, 30 (8): 225-230.
- [18] 张彼德, 裴子春, 袁宇春, 等 (Zhang Bide, Pei Zi-chun, Yuan Yuchun, et al.).



- chun, Yuan Yuchun, et al.). 基于遗传算法优化的BP神经网络的变压器油中气体预测 (The prediction of gas-in-oil in a transformer based on BP neural network optimized by genetic algorithm) [J]. 西华大学学报 (自然科学版) (Journal of Xihua University (Natural Science Edition)), 2010, 29 (2): 145-147.
- [19] Perez R, Matos E, Fernandez S. Identification of the non-linear model proposed by the MIT for power transformers by applying genetic algorithms [J]. IEEE Latin America Transactions, 2009, 7 (6): 636-642.
- [20] Perez R, Alfonso E M, Fernandez S. Parameter estimation and validation of power transformers top oil temperature model by applying genetic algorithms [J]. Revista Tecnica de la Facultad de Ingenieria Universidad del Zulia, 2009, 32 (3): 266-275.
- [21] 陈伟根, 滕黎, 刘军, 等 (Chen Weigen, Teng Li, Liu Jun, et al.). 基于遗传优化支持向量机的变压器绕组热点温度预测模型 (Prediction model of transformer winding hot spot temperature based on genetic optimization support vector machine) [J]. 电工技术学报 (Transactions of China Electrotechnical Society), 2014, 29 (1): 44-51.
- [22] 滕黎 (Teng Li). 油浸式变压器热路计算及热点温度遗传支持向量机预测研究 (Calculation of thermal path of oil immersed transformer and prediction of hot spot temperature by genetic support vector machines) [D]. 重庆: 重庆大学 (Chongqing: Chongqing University), 2012.
- [23] 张捷迁 (Zhang Jieqian). 真实流体力学 (Real fluid mechanics) [M]. 北京: 清华大学出版社 (Beijing: Tsinghua University Press), 1986.
- [24] 邱志斌, 阮江军, 黄道春, 等 (Qiu Zhibin, Ruan Jiangjun, Huang Daochun, et al.). 直流导线和阀门金具的电晕起始电压预测 (Prediction on corona onset voltage of DC conductors and valve hall fittings) [J]. 电工技术学报 (Transactions of China Electrotechnical Society), 2016, 31 (12): 80-89.
- [25] 张健文, 王恩俊, 陈焕栩, 等 (Zhang Jianwen, Wang Enjun, Chen Huanxu, et al.). 基于自回归模型和超球面支持向量机的局部放电模式识别 (Partial discharge pattern recognition based on autoregression model and hypersphere support vector machine) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2016, 35 (9): 29-34.
- [26] 赵立权, 龙艳 (Zhao Liquan, Long Yan). 基于改进的SVM的电能质量复合扰动分类 (Classification of multiple power quality disturbances based on improved SVM) [J]. 电工电能新技术, 2016, 35 (10): 63-68.

## Transformer hot-spot temperature inversion method based on streamline and support vector regression

QUAN Yu, RUAN Jiang-jun, GONG Ruo-han, CHEN Jing-zhou, JIN Qi, WEN Wu  
(School of Electrical Engineering, Wuhan University, Wuhan 430072, China)

**Abstract:** The transformer hot-spot temperature is one of the important factors influencing the running state, physical condition and insulation life of the transformer. In order to avoid the adverse effects of optical fiber implant on hot spot temperature, a method of hot-spot temperature inversion and streamline based on SVR and streamline is proposed through the analysis of the thermodynamic equations in oil circulating. Taking a 10kV single-phase transformer model as an example, the numerical temperature field calculation of different heat source, heat transfer coefficient and environmental temperature is carried out. Then, three kinds of main streamlines are extracted, and the inversion results of hot-spot temperature under different streamline points number and location, together with different streamline root number have been studied. It is concluded that choosing streamline which is through the hot spot and the transformer shell at the same time can get better inversion results. In addition, in a number of these streamlines, only choosing one streamline and selecting two points of the maximum difference in temperature can get better results. It can obtain the minimum error and the error was within 0.5 degrees by using the shell point corresponding streamline point to invert the hot spot temperature. This method realizes that the measurement of the characteristic quantity is completely non-implantable, has a higher precision than the traditional method, and provides a new approach for monitoring transformer condition constantly and predicting the hot spot temperature as well.

**Key words:** streamline; support vector regression; non-implantable; hot temperature; inversion model