

变压器过热故障特征气体演化规律的 Wiener 模型

单 敬¹, 程养春¹, 刘孟君¹, 纪晓艺¹, 王 峰², 唐 毅³

(1. 华北电力大学高电压与电磁兼容北京市重点实验室, 北京 102206;

2. 中国电力科学研究院高压所, 北京 100192; 3. 国网山东省电力公司, 济南 250001)

摘 要: 电力设备缺陷各发展阶段遵循不同规律, 故障前夕缺陷发展过程实测数据稀缺。基于历史数据序列的人工智能预测方法解决不了新阶段的预测问题。基于传统可靠性理论的统计分析方法具有较好的实用性。该文基于可靠性理论中的性能退化轨道理论, 结合多台现场变压器过热故障前夕的油中溶解气体数据, 通过将退化轨道模型作为时间尺度转换函数与线性 Wiener 模型相结合, 构建了气体体积分数发展变化过程的非线性 Wiener 退化模型, 并给出模型参数求解步骤和方法。对现场数据分析结果表明, 变压器过热故障前夕主要特征气体体积分数发展变化整体服从指数规律, 以指数函数作为时间尺度变换函数可以构建非线性 Wiener 退化模型; 该模型对数据序列长度和时间间隔要求低, 能够同时反映气体体积分数发展过程的非线性趋势和随机性, 具备基于可靠性理论的可解释性。统计了过热故障变压器油中甲烷、乙烯和总烃体积分数的 Wiener 退化模型中各参数的概率密度分布函数。研究成果为气体体积分数预测和变压器过热故障概率测算提供了解释性好、准确度高、对检测数据量要求低的新方法。

关键词: 变压器; 过热故障; 油中溶解气体; 非线性 Wiener 过程模型; 退化轨道模型

Wiener Model of Characteristics Gas Evolution Law of Overheat Fault in Transformers

SHAN Jing¹, CHENG Yangchun¹, LIU Mengjun¹, JI Xiaoyi¹, WANG Feng², TANG Yi³

(1. Beijing Key Laboratory of High Voltage and EMC, North China Electric Power University, Beijing 102206, China;

2. High Voltage Institute, China Electric Power Research Institute, Beijing 100192, China;

3. State Grid Shandong Electric Power Company, Jinan 250001, China)

Abstract: The defect development stages of power equipment follow different laws, and the measured data of defect development process before the fault is scarce. The artificial intelligence prediction method based on historical data series can not solve the prediction problem in the new stage. The statistical analysis method based on traditional reliability theory has good practicability. Based on the performance degradation track theory in reliability theory, combined with the data of dissolved gas in oil before the overheating failure of several on-site transformers, this paper builds a nonlinear Wiener degradation model for the development process of gas volume fraction by combining the degraded track model as a time-scale conversion function with the linear Wiener model. Moreover, the steps and methods for solving the model parameters are also given. The analysis results of the field data show that the developments of the main characteristic gas volume fraction before transformer overheating faults obey the exponential law, and the nonlinear Wiener degradation model can be constructed by using the exponential function as the time scale transformation function. The model has low requirements on the length and time interval of data series, can reflect the nonlinear trend and randomness of gas volume fraction development process at the same time, and has the interpretability based on reliability theory. Finally, this paper statistically analyzes the probability density distribution functions of each parameter in the Wiener degradation model of methane, ethylene and total hydrocarbon volume fraction in transformer oil with overheating fault. The research results provide a new method with good interpretation, high accuracy and low data requirement for gas concentration prediction and transformer overheating fault probability calculation.

Key words: transformer; overheating failure; dissolved gas in oil; nonlinear Wiener process model; degenerate orbit model

0 引言

近年来,以人工智能等数字化技术为核心的“第四次工业革命”推动全球加速进入数字化时代。针对电力设备状态的大数据挖掘分析和人工智能诊断算法已得到较多研究和应用。人们希望通过研究设备劣化发展规律、预测设备状态量,进而预测设备故障、开展全寿命周期维护优化^[1]。由于实际设备故障案例和样本较少,很多情况下难以满足大数据分析和智能算法要求。最新的研究方向是将数据驱动与机理驱动相结合,促进电力设备缺陷辨识、故障预警智能算法的发展^[2]。其中,设备故障前夕状态量的发展演化规律研究非常重要,是实现设备故障预警的基础。

对于电力变压器而言,油中溶解气体是变压器绝缘系统中常见的局部放电缺陷和过热缺陷的重要标识物质,被广泛用于故障诊断和预警。各种预测算法很早就被用于气体体积分数预测,包括传统的时间序列、灰色预测理论、支持向量机回归模型、神经网络等^[3-4]。随着人工智能技术的发展和监测设备的大量部署,基于数据驱动机制的机器学习算法也得到应用,且与传统算法相互组合,形成了更加准确的预测算法^[5-10]。文献[5-6]综合了灰色理论、BP神经网络、遗传算法和卡尔曼预测算法等多种单项预测算法。文献[7]结合了灰色模型、变分模态分解和支持向量机。文献[8]利用时间序列模型进行预测,再利用基于网格搜索算法优化后的支持向量机模型进行缺陷诊断。文献[9]中粒子群算法结合长短期记忆网络(long short-term memory, LSTM)方法,克服了长短期记忆网络参数选取依靠经验的问题。然而,基于数据驱动的评估模型虽适用于持续跟踪设备运行状态及其发展趋势,但存在对原始样本要求高、可解释性不足等问题^[11]。

传统机器学习预测模型仅依靠状态量本身的历史数据,忽略了众多关联因素,所得预测效果在科学性和稳定性上都得不到保障。因此,近年来多种关联信息也被引入到状态量预测中。文献[12]选取各气体组分的强相关序列进行预测建模。文献[13-16]则应用时域卷积神经网络和图像卷积神经网络的组合,同时提取某一气体组分随时间变化规律和各气体组分之间的相关性。文献[17]用概率图模型挖掘变压器各状态量之间的关联规则,将此规则作为初始参数去优化径向基神经网络。文献[18]进

一步考虑变压器状态信息、电网运行和环境气象数据之间的复杂关联关系,通过栅格长短时记忆网络提取各参量之间蕴含的内在规律和关联关系,提高了预测模型的稳定性和准确性。此外,经验模态分解^[19]、变分模态分解^[20]、小波分解^[21]、分形理论、缓冲算子^[22-23]等方法被用于预处理历史数据时间序列,以应对缺陷发展演化过程中的随机性和波动性。

上述预测算法,处理对象是被预测变压器个体的油中溶解气体历史数据时间序列。其前提假设是被预测的发展演化过程自始至终符合同一规律,因而从历史数据中提取到的规律可被用来预测临近故障时的数值。然而,变压器发展过程会经历正常状态、注意状态、异常状态、严重状态等不同阶段,各阶段缺陷发展规律可能遵循不同规律。例如,文献[24]指出,各种预测模型拟合出来的故障率曲线具有较明显的稳定期和损耗期。由于稳定期与损耗期的规律不同,导致稳定期和损耗期数据相互影响,降低了预测精度。

鉴于不能采用一台设备的前一阶段数据为后一阶段建模,人们转向多台变压器数据统计分析,为各阶段单独建模。文献[24-25]引入“故障分界点”或“转折点”概念,为不同数据区间建立不同预测模型,并且采用多台变压器数据的统计规律识别分界点。文献[26]进一步将变压器状态划分为6个状态区间,利用云理论来表征各状态区间边界的模糊性,利用加权隐式半 Markov 退化模型来确定各状态区间之间的转移概率,最终利用状态转化概率来预测某台变压器下一阶段最有可能达到的状态区间。文献[27]也采用半 Markov 模型来统计状态转化概率。显然,采用变压器集合中多台变压器的历史数据得到的状态转化概率,是一种“平均”规律,能够避免仅靠单台变压器历史数据进行预测时可能遇到的数据异常波动带来的较大预测误差。但是,这个平均规律套用到某变压器个体上,预测误差取决于该个体与变压器集合中的平均值的差异。

综上所述,基于被预测变压器个体的历史数据时间序列的预测模型存在难以跨越不同状态区间的难题。此外,基于状态量时间序列的神经网络预测模型,本质上是一个“端到端”的“黑箱”模型,存在固有的可解释性欠缺问题^[28]。基于数据驱动的人工智能预测方法,找不到足够的数据来落实其对于设备故障前夕状态量发展趋势的预测。对于涉及多个发展阶段的状态量预测,最终还是需要回到基

于概率统计的可靠性理论。然而, 基于状态区间转移概率矩阵的预测模型, 在状态区间的数量与范围划分上存在主观性, 进而影响预测结果的准确性。总之, 鉴于故障案例少, 关于异常阶段变压器状态量发展规律和预测模型的研究成果较少。

本文基于可靠性理论中的退化轨道模型理论, 对于多台变压器故障前夕的油中溶解气体体积分数时间序列进行统计分析, 构建基于 Wiener 过程的退化模型, 同时表征了缺陷发展过程(特别是严重阶段)的非线性和随机性, 具备以可靠性理论和统计概率为基础的可解释性, 为处于严重状态的变压器的油中溶解气体体积分数的准确预测提供了新途径; 并且能够用于变压器数字孪生模型中缺陷发展过程的建模。

1 典型退化模型理论简介

退化过程模型通常较复杂, 当将该模型应用于寿命预测和可靠性评估时, 不同模型可能导致不同结果, 偏离真实模型的很小的扰动都可能导致严重的预测偏差。本章简介了退化轨道模型和 Wiener 退化过程模型的定义与性质。

1.1 性能可靠度

在可靠性理论^[29]中, 设备丧失规定功能, 对不可修设备称为失效, 对可修复设备通常称为故障。在谈及设备寿命时, 特指目前工作阶段的寿命, 不包括被修复后获得的新寿命。失效被认为是一个抽象的随机事件, 设备的状态通常被简化为两种离散状态: 正常状态和失效状态。基于失效的可靠性建模方法通过分析设备失效时间, 评估设备的寿命和可靠性。传统可靠度 R 可定义为:

$$R(t) = P\{T > t\} \approx \frac{n-r(t)}{n} \quad (1)$$

式中: T 为设备寿命; n 为实验设备数; $r(t)$ 为直到时刻 t 的失效设备数; P 函数表示括号内表达式成立的概率。这种基于失效的可靠性建模方法仅利用了失效时间数据, 而不关注设备故障过程中的状态演化。

反之, 基于退化的可靠性建模方法关注设备失效过程信息。首先选择与设备寿命或可靠度高度相关的特征变量(即状态量), 并使用数学模型来描述其随时间的变化(即性能退化过程, 通常是一个随机过程); 然后使用性能退化过程模型来描述设备失效过程, 并结合失效准则进行可靠性评估。具体地,

设 $X(\tau)$ 为设备在时刻 τ 的状态量取值, 设备性能要求为 Ω , t 为规定时间, 则设备可靠度定义为规定时间下 $X(\tau)$ 满足 Ω 的概率 P 。

$$R(t) = P\{X(\tau) \in \Omega, 0 \leq \tau \leq t\} \quad (2)$$

按这种方式定义的可靠度称为性能可靠度, 即对设备性能可靠性特征量的概率度量。

从当前变压器的状态评估规范标准来看, 变压器油色谱在线监测是目前最主要的监测手段之一。因此, 本文采用油中溶解气体体积分数作为状态量分析变压器性能退化发展规律, 建立气体体积分数 $X(t)$ 的概率分布函数(该分布函数随时间变化), 代入式(2)求得设备的可靠度。

1.2 退化轨道模型

在基于退化轨道的建模方法^[29]中, 用退化轨道描述 $X(t)$ 随时间 t 的变化, 函数形式如下所示:

$$X(t) = f(t, \boldsymbol{\beta}, \mathbf{b}) = f(t, \beta_1, \dots, \beta_p, b_1, \dots, b_q) \quad (3)$$

式中: f 为确定性函数, 称为退化函数; $\boldsymbol{\beta}$ 为对所有样本相同的固定参数向量, 称为固定效应; \mathbf{b} 为随机向量, 描述不同样本个体的特殊性, 称为随机效应; p 、 q 分别为固定参数、随机参数的维数。

利用退化轨道模型来分析变压器劣化过程, 形式简单, 且可以同传统的灰色预测等经验模型相互印证。构建退化轨道模型时, 首先根据经验、退化机理或者回归分析确定性函数 f 的形式; 然后, 在函数 f 的参数中引入随机项, 以描述不同设备间的差异, 并采用统计方法进行检验^[30]。但对于个体设备而言, 退化过程通过函数 f 进行确定性表征, 缺乏对退化过程中随机性的表征。

1.3 基于 Wiener 过程的退化模型

1.3.1 Wiener 过程简介

Wiener 过程由 Wiener 于 1918 年提出, 用于描述布朗运动的随机过程, 是概率论中最有用的随机过程之一。基于 Wiener 过程的退化模型是目前应用最广泛的性能退化模型, 其结构简单、失效时间分布具有解析形式, 便于对设备可靠度进行分析和计算。标准 Wiener 模型中, 假设零时刻花粉的位置为 0, 花粉的位移服从正态分布, 则 t 时刻花粉位置期望值为 0, 方差数值等于 t 。

1.3.2 Wiener 过程用于设备性能退化建模

Wiener 过程理论中, 假设设备在时间区间 $[t, t+\Delta t]$ 的性能退化量 $\Delta X = X(t+\Delta t) - X(t)$ 是许多相互独立的随机微小性能损失之和, 且这些微小损失的数

目与 Δt 成正比, 则 ΔX 服从正态分布。将这些随机微小性能损失看做布朗运动中的随机游走, 则退化过程可用带漂移的 Wiener 过程来描述。漂移量为 ΔX 正态分布的期望值。性能退化的随机性可理解为微小损失的数目围绕其期望值随机增加或者减小。当漂移速率显著大于扩散系数时, ΔX 取负值的概率很小, 可以忽略。此时性能退化过程为近似单调过程。

近年来, Wiener 过程与其他模型相结合, 用于解决更加复杂的退化过程^[31-33]。文献[31]提出一种新的时变温度条件下的退化模型, 其中退化过程采用 Wiener 过程建模, 协变效应采用 Arrhenius 方程建模。文献[32]提出一种包含随机时变协变量的非线性 Wiener 过程模型, 用 Ornstein-Uhlenbeck 过程对动态协变量建模, 并通过指数形式的协变量效应函数将其与时变退化速率联系起来。文献[33]提出一种基于二元非线性 Wiener 随机过程, 可反映变压器油纸绝缘联合退化行为。该模型首先基于非线性 Wiener 随机过程建立单性能退化模型, 然后基于 Copula 函数关联两个随机变量, 建立包含多个状态量和两类相关性能退化模型。

1.3.3 Wiener 退化过程基本理论

Wiener 过程可以描述退化过程的时间不确定性, 使得设备个体之间的差异更易描述, 并且在参数估计方面也较为简单。若连续时间随机过程 $\{W(t), t \geq 0\}$ 为 Wiener 过程或布朗运动过程时, 其具有如下性质^[29]:

1) $W(0)=0$ 。

2) $\{W(t), t \geq 0\}$ 有平稳独立增量, 即增量与时间起点无关。

3) 对任意 $t > 0$, $W(t)$ 服从正态分布, 均值为 0, 方差为 $\sigma^2 t$ 。其中, σ 为扩散参数, 描述退化过程中随机性的剧烈程度。

当 $\sigma=1$ 时, 该过程被称为标准 Wiener 过程或标准布朗运动过程。

对于一些不符合第 2) 条的过程, 若可以通过扣除一个非线性环节来使剩余部分符合第 2) 条, 则该过程能够通过带非线性漂移的 Wiener 过程来表示。

令 $X(t)$ 表示设备性能退化过程, 根据上述定义, 可将带非线性漂移的一元 Wiener 过程表示为:

$$X(t) = X(0) + \int_0^t \mu(t) dt + \sigma B(t) \quad (4)$$

式中: $\{B(t), t \geq 0\}$ 为标准的 Wiener 过程或者标准布朗运动过程, 其方差在数值上等于 t ; $\mu(t)$ 为漂移速率函数, 为随机变量, 描述个体设备退化速率差异。

当 $\mu(t)=\mu$ 时, 该过程变为线性漂移 Wiener 过程模型, 即:

$$X(t) = X(0) + \mu t + \sigma B(t) \quad (5)$$

若存在 t 的非负单调函数 $\tau=\Lambda(t)$, 则可将上述 Wiener 过程改写为:

$$X(t) = X(0) + \mu \Lambda(t) + \sigma B(\Lambda(t)) \quad (6)$$

则可通过时间尺度变换 (τ 替换 $\Lambda(t)$) 将非线性漂移 Wiener 退化过程转化为线性漂移 Wiener 过程:

$$X(\tau) = X(0) + \mu \tau + \sigma B(\tau) \quad (7)$$

若给定设备失效阈值为 $l(l > 0)$, 定义设备寿命 T 为退化过程 $\{X(t), t \geq 0\}$ 的某个退化量首次达到或者超过对应退化阈值 l 的时间, 则:

$$T = \text{Inf} \{t | \exists i = 1, \dots, s, X_i(t) \geq l_i\} \quad (8)$$

式中: i 为退化量序号; s 为退化量总数; $X_i(t)$ 为第 i 个退化量; l_i 为第 i 个退化量阈值; 函数 Inf 表示求最小值。

根据 Wiener 过程性质, 由式(8)可以推导得到寿命 T 在经过时间尺度变换后服从逆高斯分布, 即 $\Lambda(T) \sim \text{IG}(l/\mu, l^2/\sigma^2)$ 。当 $\Lambda(T)$ 对 T 可导时, 寿命 T 的概率密度函数^[29,32]为:

$$f_T(T) = \frac{l}{\sqrt{2\pi\sigma^2\Lambda(T)^3}} \exp\left(\frac{-(l - \mu\Lambda(T))^2}{2\sigma^2\Lambda(T)}\right) \left| \frac{d\Lambda(T)}{dT} \right| \quad (9)$$

1.3.4 Wiener 退化过程特点

从 Wiener 退化过程的定义可知其普适性和先进性。凡是特征量的增量与时间起点无关, 且服从正态分布过程, 均可用 Wiener 退化过程进行描述。电力设备许多种类的缺陷发展演化过程中, 状态量的增量符合正态分布, 因而 Wiener 退化过程在描述电力设备缺陷发展过程时具有较好的普适性。此外, 相对于灰色预测等算法, Wiener 退化过程包含了随机性, 更加准确; 相对于时间序列等算法而言, Wiener 退化过程具有灵活的时间尺度变换函数, 能够处理时间序列难以处理的指数规律, 并且量化了随机性表征, 不会出现时间序列面临的置信区间随提前预测时间急剧增大的情况, 因而 Wiener 退化过程具有较好的先进性。

1.4 其他退化过程模型

除退化轨道模型和 Wiener 过程模型外, 常见退化模型理论还有 Gamma 过程模型和 Poisson 过程模型等。Gamma 退化过程描述严格单调非负过程(即

状态量只能随时间单调变化), 且退化路径是不连续的跳跃过程, 适用于描述冲击应力造成的性能退化。Poisson 退化过程描述冲击应力造成的性能退化, 其中的冲击应力的强度或者速率服从 Poisson 过程。

2 Wiener 退化模型适用性分析

2.1 变压器劣化过程整体特性

变压器的性能退化主要来自绝缘系统老化和劣化。性能退化后期通常转化成局部放电缺陷和过热缺陷的发展演化过程。退化量增长到某种程度将会导致故障。退化量越大, 故障的可能性也越大。文献[34]统计了某省网 2000—2019 年共计 4 280 台 110 kV 及以上变压器的首次故障信息, 其中 2000 年(数据集 S1)和 2001 年(数据集 S2)投运的变压器故障率随运行时间的变化规律如图 1 所示。从首次故障率随运行时间的变化过程可推论, 变压器状态量随运行时间的变化有如下特点: 基本符合 Wiener 过程; 状态量的变化存在随机性; 状态量的增量基本与时间起点无关。

2.2 油中溶解气体发展过程特点

油中溶解气体来自过热、放电等缺陷。气体体积分数取决于产气速率和气体消散速率的暂态平衡过程。其中产气率取决于电流、电压等诱因的强度。电流、电压除稳态成分外, 还包含随机成分(源自多种影响因素的随机性)。从较长的时间尺度看, 气体体积分数随当前诱因单调变化, 且不受诱因的过去历程影响, 因而气体体积分数的随机成分也是正态分布, 满足 Wiener 过程。Wiener 过程中的非线性漂移量表征气体体积分数整体变化趋势, 对应于诱因中的稳态成分。

2.3 性能退化模型确定方法

偏离真实模型的很小扰动都可能导致严重的偏差。应根据退化过程特点选择合适的退化模型, 可根据退化量与时间的关系、样本路径的数学性质或退化过程的不确定性来确定退化模型[29]。

虽然退化轨道模型的函数形式和参数估计较简单, 但无法表征退化过程的随机性, 因此不适合变压器状态量变化过程建模。基于 Gamma 过程的模型要求退化过程严格单调非负, 变压器状态量变化过程不满足该条件。Wiener 过程模型比较适合于描述退化过程为非单调且呈增长趋势的情况, 同时能够描述退化过程中的随机效应。因此, 本文针对变压器油中溶解气体浓度变化过程的特点, 选择非




图 1 变压器故障率随运行时间的变化^[34]

Fig.1 Variation of transformer failure rate with operating time^[34]

线性 Wiener 退化模型对变压器劣化过程进行建模。

3 Wiener 退化模型的参数估计

3.1 参数估计步骤

3.1.1 线性 Wiener 退化模型参数估计

线性 Wiener 退化过程是非线性 Wiener 退化过程的基础。线性 Wiener 退化过程如式(5)所示。漂移参数 μ 表征了退化量的增长速率; 扩散参数 σ 表征了随机过程的剧烈程度。根据 Wiener 过程的性质, 退化增量 $\Delta X(t)$ 服从高斯分布, 即 $\Delta X(t) \sim N(\mu\Delta t, \sigma^2\Delta t)$ ^[29,32], 此时可以利用极大似然法对线性退化模型进行参数估计。

假设共有 n 组设备的退化数据, 设备 i 在时刻 t_{i1}, \dots, t_{im_i} 设备退化量为 X_{i1}, \dots, X_{im_i} , 记 $\Delta X_{ij} = X_{ij} - X_{i,j-1}$ 是设备 i 在时刻 $t_{i,j-1} \sim t_{ij}$ 之间的退化增量, $\Delta t_{ij} = t_{ij} - t_{i,j-1} (j=1, 2, \dots, m_i; i=1, 2, \dots, n)$ 为各设备退化量的测量间隔。则 Wiener 退化模型参数的似然函数^[25]为:

$$L(\mu, \sigma) = \prod_{i=1}^n \prod_{j=1}^{m_i} \frac{1}{\sqrt{2\sigma^2\pi\Delta t_{ij}}} \exp\left(-\frac{(\Delta X_{ij} - \mu\Delta t_{ij})^2}{2\sigma^2\Delta t_{ij}}\right) \quad (10)$$

对似然函数取对数, 并求偏导, 可得 μ 和 σ 的极大似然估计值^[25]为:

$$\hat{\mu} = \frac{\sum_{i=1}^n X_{im_i}}{\sum_{i=1}^n t_{im_i}} \quad (11)$$

$$\hat{\sigma}^2 = \frac{1}{\sum_{i=1}^n m_i} \left(\sum_{i=1}^n \sum_{j=1}^{m_i} \frac{(\Delta X_{ij})^2}{\Delta t_{ij}} - \frac{(\sum_{i=1}^n X_{im_i})^2}{\sum_{i=1}^n t_{im_i}} \right) \quad (12)$$

可以看出, 漂移参数的估计值与最后一个退化量和监测时间有关, 与监测次数和监测时间间隔无关; 扩散参数的估计值不仅与退化量和监测时间有关, 也与监测次数和时间间隔有关。若仅考虑单台

设备的性能退化轨道，则式(11)和式(12)退化为 $i=1$ 的情况。

3.1.2 非线性 Wiener 退化模型参数估计

非线性 Wiener 退化过程的退化增量 $\Delta X(\Delta \tau)$ 也服从高斯分布，且有 $\Delta X(\Delta \tau) \sim N(\mu \Delta \tau, \sigma^2 \Delta \tau)$ [32]。

因为 $\tau=A(t)$ 表征的是产品性能退化轨迹随时间变化的特性，所以本文采用退化轨道模型函数作为时间尺度变换函数，即可将非线性过程转为线性过程，具体执行步骤如图 2 所示，具体如下所述。

1) 根据经验或者退化过程的确定性描述，或者利用回归分析技术，为状态量建立轨道模型。

2) 将该轨道模型函数作为时间尺度变换函数进行时间变换，变换后构建线性 Wiener 模型。

3) 假设退化增量符合正态分布，利用极大似然原理估算 μ 和 σ 的数值。

4) 检验等时间间距的退化增量是否符合正态分布。若符合，则 Wiener 模型成立。

3.2 时间尺度变换函数求取

本文中的时间尺度变换函数为退化轨道函数。基于统计回归的方法，分别对收集到的每台故障变压器油中溶解气体体积分数时间序列数据建立退化轨道模型。选择均方根误差 λ_{RMSE} 和确定系数 $\lambda_{\text{R}2}$ 作为评价拟合优度的评价指标，计算式如式(13)和式(14)所示。

$$\lambda_{\text{RMSE}} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (13)$$

$$\lambda_{\text{R}2} = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (14)$$

式中： y_i 为退化量真实值； \hat{y}_i 为退化量估计值； \bar{y} 为退化量真实值的均值； m 为数据时间序列长度； λ_{RMSE} 衡量估计值与真实值之间的差异程度，该值越小说明曲线拟合程度越好； $\lambda_{\text{R}2}$ 反映模型对变量的解释能力，其值为[0,1]，该值越接近 1，说明数据拟合程度越好。

式(15)为基于某一台变压器油中溶解气体浓度的退化轨道函数所建立的时间尺度变换函数 $A(t)$ ，该函数为指数形式。

$$\tau = A(t) = a(e^{bt} - 1) \quad (15)$$

式中： a 表示该变压器的某一气体浓度退化轨道起始值； b 表示退化速率； t 为退化时间。该函数与退化轨道函数之间存在常数差异 a ，使 τ 的初值为零。

本文利用最小二乘法依次分析了现场 11 台变压器过热故障前夕油中溶解气体体积分数检测数据的变化过程，其中 500 kV 变压器 1 台，330 kV 变压器 1 台，220 kV 变压器 7 台，110 kV 变压器 2 台。鉴于过热故障的主要特征气体是甲烷和乙烯 [35-37]，且对应的变压器油中溶解气体体积分数注意值是总烃的体积分数注意值，本文重点分析了甲烷、乙烯和总烃的体积分数退化轨道。其中部分变压器的总烃体积分数退化轨道模型如图 3 所示，图

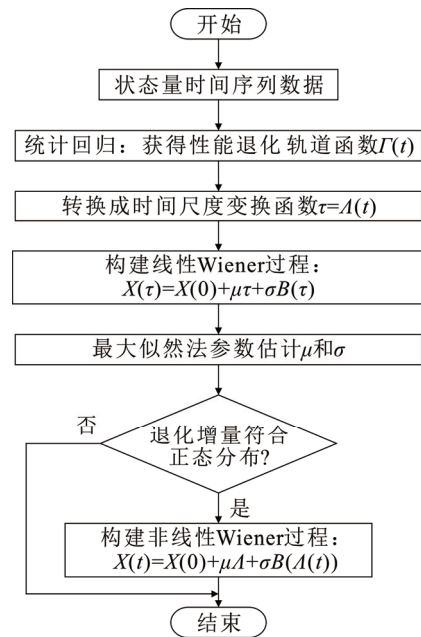


图 2 非线性 Wiener 过程模型建模流程图

Fig.2 The program chart of the nonlinear Wiener process model establishment




图 3 变压器过热故障的总烃浓度退化轨道模型

Fig.3 Degenerated orbit models of the total hydrocarbon concentration in transformers with overheating fault

中不同曲线表示不同的变压器。表 1 展示了总烃退化轨道模型参数和模型拟合度情况。其中中大部分确定系数 $\lambda_{R2}>0.9$, 说明过热故障前一段时间内总烃退化轨道模型符合指数规律。

3.3 算例

本节以 1 号变压器(220 kV)过热故障前夕油中溶解气体中总烃体积分数的为例, 介绍 Wiener 退化模型的构建。

3.3.1 构建退化轨道模型

根据已有经验, 首先确定总烃的退化轨道函数为指数形式, 然后利用最小二乘法等常用算法, 求得轨道模型中参数的具体数值, 可得式(16)所示模型。模型曲线如图 4 中指数退化轨道所示。

$$\Gamma(t) = ae^{bt} = 142.67e^{0.0387t} \quad (16)$$

式中: 模型参数 a 和 b 取值分别为 142.67 和 0.038 7; 指数模型拟合实际数据的均方根误差 λ_{RMSE} 为 127.10, 确定系数 λ_{R2} 为 0.94。其中 a 、 λ_{RMSE} 单位为 10^{-6} , b 单位为 d^{-1} 。

3.3.2 Wiener 退化模型参数求解

基于退化轨道模型, 确定时间尺度变换函数 $\tau=A(t)$ 。

$$\tau = A(t) = a(e^{bt} - 1) = 142.67e^{0.0387t} - 142.67 \quad (17)$$

对于单个设备而言, 无需考虑设备间的差异性, 则 $\mu=1$ 。此时, 仅需要求解表征性能退化过程中随机性的未知参数 σ 。在变换后的时间轴 τ 上取检测数据计算退化增量, 即 $\Delta X(\Delta \tau)$ 的值, 并对其统计分布模型进行建模和假设检验, 从而确定 σ 的具体数值。鉴于 Wiener 退化过程的 $\Delta X(\Delta \tau)$ 必须服从正态分布, 因此对于临近两次检测时间间隔 $\Delta \tau_j$, 首先假设与 $\Delta \tau_j$ 对应的增量 ΔX_j 服从正态分布, 即 $\Delta X_j \sim N(\Delta \tau_j, \sigma^2 \Delta \tau_j)$, 利用极大似然法计算正态分布模型中未知参数 σ 的估计值。各检测数据出现的极大似然函数为式(18)。对似然函数取极值求得 σ 的估计值, 如式(19)所示。式中 m' 为检测数据序列对应的退化量 ΔX 的数量。算得 σ 的估计值为 7.35, 单位为 10^{-6} 。

$$\ln L(\sigma) = \sum_{j=1}^{m'} \ln \left(\frac{1}{\sqrt{2\pi\Delta\tau_j}\sigma} \exp \left(-\frac{(\Delta X_j - \Delta\tau_j)^2}{2\sigma^2\Delta\tau_j} \right) \right) \quad (18)$$

$$\hat{\sigma} = \sqrt{\frac{1}{m'} \sum_{j=1}^{m'} \frac{(\Delta X_j - \Delta\tau_j)^2}{\Delta\tau_j}} \quad (19)$$

3.3.3 Wiener 退化过程符合性检验

该变压器总烃体积分数的退化过程是否符合

表 1 变压器过热故障的总烃退化轨道模型参数
Table 1 Parameters of the degenerated orbit models of the total hydrocarbon concentration in transformers with overhear fault

变压器序号	退化轨道模型参数		拟合优度参数	
	$a/10^{-6}$	b/d^{-1}	λ_{R2}	$\lambda_{RMSE}/10^{-6}$
1	142.67	0.038 7	0.92	127.10
2	157.28	0.016 7	0.91	106.68
3	64.18	0.039 6	0.92	290.88
4	63.39	0.019 8	0.93	284.18
5	404.78	0.002 4	0.98	18.31
6	240.37	0.002 6	0.91	35.11
7	160.75	0.005 0	0.91	33.61
8	560.52	0.010 3	0.99	5.09
9	252.91	0.047 4	0.89	43.92
10	201.67	0.012 5	0.88	95.86
11	4 228.17	0.019 8	0.73	329.83

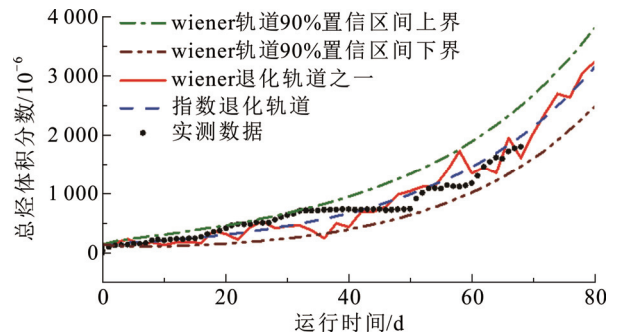


图 4 某 220 kV 变压器油中总烃浓度退化轨道模型
Fig.4 The degradation orbit model of total hydrocarbon concentration in the oil of a 220 kV transformer

Wiener 过程特点, 需要对 $\Delta X(\Delta \tau)$ 的正态分布假设进行检验。本文将采用常用的 Kolmogorov-Smirnov 检验(简称 K-S 检验)进行分布函数的非参数假设检验。在 K-S 检验中, 若 $P\{D < Pr\} \geq \alpha$, 则在 α 水平上, 符合正态分布假设。记 $P\{D < Pr\}$ 为 P 值。

令 $\Delta \tau=45$, 在总烃实测数据中寻找 $\Delta X(\Delta \tau)$ 序列, 并验证该序列的统计分布。总烃增量 $\Delta X(\Delta \tau)$ 的 K-S 检验结果如表 2 所示, 由统计量 D 、临界值 Pr 、 P 值 3 个参数可知, 在显著性水平为 0.05 情况下等间距 $\Delta \tau$ 的总烃增量服从正态分布, 且该正态分布的均值为 45.05, 近似等于 $\Delta \tau$; 方差为 3 192.2, 近似等于 $\sigma^2 \Delta \tau$ 。因此, 该退化过程符合 Wiener 过程。同时也说明经过时间变换后可以使用线性 Wiener 过程对变压器性能退化过程进行建模。

3.3.4 构建非线性漂移 Wiener 退化模型

将时间尺度转换函数 $A(t)$ 和 σ 的估计值代入式(7), 结合标准维纳过程 $B(\tau)$, 得到总烃体积分数的非线性漂移 Wiener 退化模型:

$$X(t) = X_0 + \mu a(e^{bt} - 1) + \sigma B(a(e^{bt} - 1)) = 142.67e^{0.0387t} + 7.35B(142.67(e^{0.0387t} - 1)) \quad (20)$$

该模型的参数有 a 、 b 、 μ 和 σ , 其中 a 和 b 表征设备性能在整个时间区间内的整体退化趋势, b 表征退化速率, σ 和 B 函数表征退化过程的随机性, μ 表征各设备之间性能退化的差异性。当独立分析单台设备时, $\mu=1$ 。由于指数形式的退化轨道 $I(t)$ 已是对数据序列的最佳拟合, 则 $X_0=a$ 。函数 $B(\tau)$ 为方差等于 τ 的随机过程。图 4 中的 Wiener 退化轨道曲线之一展示了一条包含随机性的 Wiener 退化过程样本, 同时在图中绘制出了随机过程 90%置信区间的上界和下界。

3.3.5 变压器故障概率预测

假设将总烃体积分数达到 l 作为变压器过热故障的诊断阈值, 将 l 的数值和 σ 的估计值及式(17)代入式(9), 得到该变压器的寿命概率分布函数。

$$f_T(t) = \frac{lbe^{bt}}{\sqrt{2\pi\sigma^2 a(e^{bt} - 1)^{1.5}}} \exp\left(-\frac{(l - ae^{bt} - a)^2}{2\sigma^2 a(e^{bt} - 1)}\right) \quad (21)$$

对式(21)进行积分, 即可求得 t 时刻该变压器的故障概率预测值。

4 过热缺陷的油中溶解气体发展特性统计分析

4.1 过热缺陷特征气体的 Wiener 退化模型

本文收集了现场 11 台变压器过热故障前夕油中溶解气体体积分数检测数据变化过程, 基本情况如表 3 所示。其中 1 号变压器的数据来自在线监测装置, 每天监测一次, 连续跟踪 69 天后变压器停运检修。其他变压器的数据来自离线检测装置, 检测时间间隔不固定, 整体上数据量较少。

由于本跟踪设备的气体体积分数已超过注意值, 设备处于注意状态, 跟踪检测数据应具有较高的准确度。现场检测数据所受到的现场干扰和人员操作误差均可作为随机性来源, 通过 Wiener 模型中的随机性来表征。故障类型均是高温过热, 发热原因包括导线接头不良、铁芯及夹件涡流、套管穿缆绝缘破损等, 涵盖变压器主要过热故障类型。

过热缺陷的主要特征气体是甲烷和乙烯, 各变

压器的甲烷和乙烯的体积分数变化过程与总烃相似。图 5 展示了部分变压器的总烃浓度跟踪检测数据。

利用上文所述 Wiener 退化模型给 11 台变压器过热故障前一段时间内气体体积分数发展过程建立非线性 Wiener 退化模型。由于篇幅有限, 图 6 仅展

表 2 某 220 kV 变压器总烃增量统计分布参数

Table 2 Statistical distribution parameters of total hydrocarbon increment for a 220 kV transformer

分布形式	分布模型参数		K-S 检验参数($\alpha=0.05$)P 值
	均值	方差	
正态分布	45.05	3 192.2	0.739

表 3 变压器过热故障发展过程案例基本情况

Table 3 Basic information of transformer overheating fault development process cases

变压器编号	电压等级/kV	跟踪时段/天数	检测记录数量	故障分析结论
1	220	69	69	三比值法诊断为高温过热
2	500	127	7	夹件引线螺丝松动或焊接不良, 局部短路或层间绝缘不良
3	220	104	8	B 相高压套管穿缆绝缘破损
4	220	210	7	分接开关烧蚀, A 触头变黑
5	110	232	13	三比值法诊断为高温过热
6	220	350	7	分接开关引线接头处螺丝松动并有烧痕, 高温过热
7	220	219	11	110 kV 引线连接部位导线各烧断股, 烧损总长度达 300 mm
8	220	29	5	三比值法诊断为高温过热
9	110	36	5	铁芯多点接地短路
10	330	128	17	110 kV 侧 C 相套管底部引线发热, 断股, 并烧黑
11	220	17	12	A 相上夹件磁屏蔽碰铁芯, 造成局部过热




图 5 过热故障前夕变压器油中总烃浓度跟踪检测数据

Fig.5 Tracking data of total hydrocarbon concentration in transformer oil before overheating failure

示了跟踪检测时间较长的 8 台变压器的主要特征气体甲烷、乙烯和总烃的发展曲线。

4.2 过热故障发展过程统计特性分布

利用处于正常或者异常状态的变压器的状态量数据预测变压器未来故障概率, 存在难以跨越不同状态区间的难题。仅能通过处于严重状态的状态量数据来预测未来故障概率。当变压器个体数据缺失或不足的情况下, 需要借助变压器集体规律来确定模型中的参数。此外, 鉴于缺陷发展过程具有显著的随机性, 当进行远期预测时, 需要综合考虑变

压器个体的数据及变压器集体规律。与现有其他预测模型相比, 非线性 Wiener 退化模型在提取变压器集体发展规律方面具有可解释、理论依据充分等优势。

例如, 对多个变压器模型参数取平均值, 作为集体模型参数; 将集体模型参数概率分布作为先验概率, 将变压器个体当前临时模型参数作为检测值, 利用贝叶斯公式求得变压器个体模型参数的后验概率; 将后验概率分布的期望值作为模型参数的最终取值, 从而能够得到更加准确的预测结果。

构建变压器状态量发展演化的数字孪生模型时, 也需要变压器油中溶解气体发展过程的统计特性。对 11 台变压器案例的非线性 Wiener 模型中的参数 a 、 b 、 σ 进行统计分析, 得到其概率密度分布函数类型和分布参数如表 4 所示。图 7 展示了总烃的 Wiener 模型中各参数的概率密度函数统计分析情况。

4.3 Wiener 退化模型准确度对比分析

为了体现 Wiener 退化模型的优点, 本文对比分析了 Wiener 退化模型、时间序列模型(季节性自回归差分移动平均模型)和径向基函数(radial basis function, RBF)神经网络模型对于现场检测数据的预测结果。时间序列模型和 RBF 神经网络均能较好地拟合处理数据间的非线性输入输出关系, 是常见趋势预测方法[8,38-40]。

本文选择了设备故障前一段时间内的数据用于构建性能退化模型, 从而避免了跨越不同状态区间的难题, 但随之而来的问题是可用数据的数量偏少。Wiener 退化模型对于已知数据记录的数量要

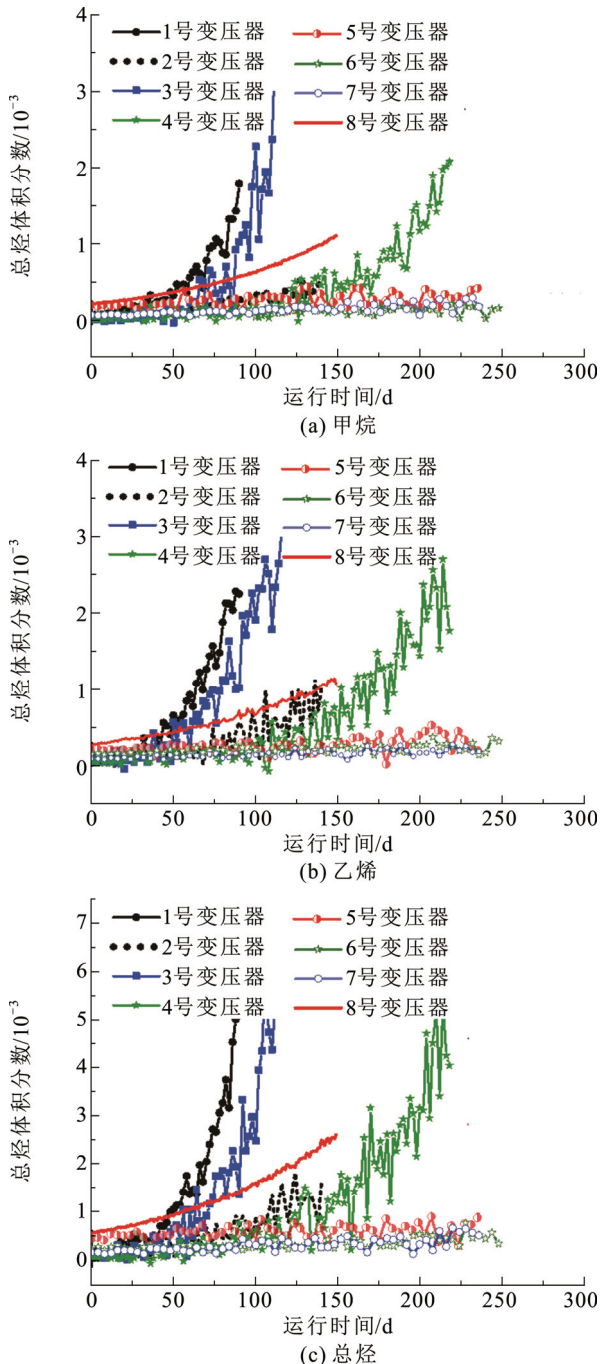


图 6 过热故障特征气体 Wiener 退化过程曲线

Fig.6 Wiener degradation curve of overheating gases

表 4 Wiener 模型各参数的统计分布

Table 4 Statistical distribution models of the parameters in the Wiener models of the characteristic gases

气体	Wiener 模型参数	Wiener 模型参数的统计分布		
		类型	均值位置 参数/ 10^{-6}	标准差尺度 参数/ 10^{-6}
甲烷	a	对数正态分布	4.34	1.42
	b	对数正态分布	-4.29	1.08
	σ	Weibull 分布	8.75	1.28
乙烯	a	对数正态分布	4.84	1.12
	b	对数正态分布	-4.35	1.06
	σ	正态分布	7.43	3.26
总烃	a	对数正态分布	5.49	1.16
	b	正态分布	0.019	0.016
	σ	Weibull 分布	13.48	1.60

求较低,即使仅有 5 个数据,也可以进行建模,而且不要求数据序列的时间间隔相等。因此,该模型能够依靠故障前夕非常少的数据量完成建模。时间序列模型和 RBF 神经网络模型需要较多的数据;而且要求数据序列的时间间隔相等,难以预测表 3 中绝大部分变压器,仅能用于 1 号变压器的数据序列。用 1 号变压器跟踪数据中的前 60 个数据构建

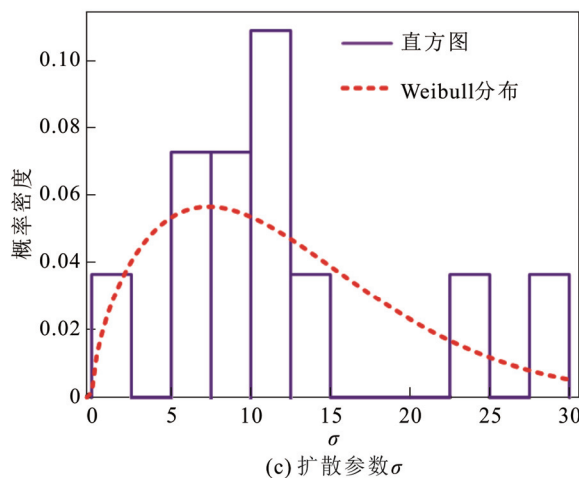




图 7 总烃 Wiener 退化模型中各参数的概率密度分布
Fig.7 Probability distribution of parameters in the Wiener degradation models

Wiener 退化模型、时间序列模型和 RBF 神经网络模型,再用所构建的模型预测之后的 9 个数据,结果如图 8 所示。

对比预测效果并结合各模型机理可知, Wiener 退化模型更加体现全局趋势,特别是还能够综合多台变压器的集体趋势与随机性。而时间序列模型仅能用于单台变压器的数据序列,且更容易受当前数据的影响。Wiener 退化模型中,随机性的方差与尺度时间 τ 成正比,使得预测值的 90% 置信区间宽度与 τ 的平方根成正比,小于时间序列预测值的置信区间。置信区间的大小对应于随机性的大小,进而影响到由式(9)表征的未来故障概率的大小。因此置信区间越小越好。对于复杂的退化过程, Wiener 退化模型与时间序列模型的预测结果准确度互有高低。RBF 神经网络模型的稳定性和通用性较差,需要针对不同的已知数据序列仔细调整模型参数,才能使预测期望值的偏差较小。

5 讨论

Wiener 过程要求随机性符合正态分布,反映在建模上要求性能退化增量 $\Delta X(\Delta \tau)$ 也服从正态分布。实际变压器油中溶解气体体积分数的诱因(如负荷电流等)可能存在非随机性变化(例如用电高峰期将增大负荷)。若这种非随机性分量变化较复杂,难以采用简单轨道函数来表征,进而难以找到合适的时间尺度变换函数,则难以建立准确的非线性 Wiener 退化过程模型。应设法消除或表征这种非随机性变化。此外,若非随机性诱因的变化速度太快,使得气体体积分数不仅与当前诱因相关,而且与诱因的历程相关,则 $\Delta X(\Delta \tau)$ 不服从正态分布,不能采用 Wiener 过程建模。

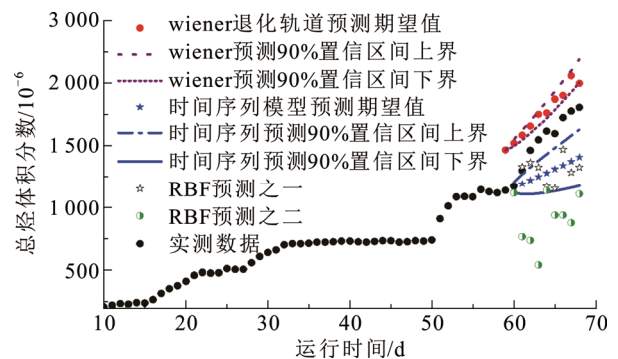


图 8 1 号变压器总烃发展趋势预测效果对比
Fig.8 Comparison of prediction effect of total hydrocarbon development trend in transformer No.1

电力设备故障数据非常少, 缺陷发展演化过程的随机性强, 不能仅依靠 1 台设备的自身数据进行预测。本文倡导的 Wiener 退化模型能够融合多台设备案例的整体规律和随机性, 非常适用于提取设备缺陷发展规律。然而, 缺陷发展过程中的非线性是需要处理的难点。本文提出了利用退化轨道的指数函数作为时间转换函数, 消除了非线性, 但退化轨道函数 $\Gamma(t)$ 的初值不为 0, 使得图 8 中 Wiener 退化轨道的初始预测值与最后一个实测数据间存在差异。该问题需要进一步研究处理。

涉及电力变压器本体的主要故障种类是过热故障和放电故障。鉴于所掌握的现场变压器故障数据有限, 其中过热故障样本数量多于放电故障, 因此本文仅分析了变压器过热故障发展演化规律。从现有故障案例分析结果来看, 过热缺陷的 Wiener 退化模型具有较好的普适性, 但是样本数量不多, 还需进一步积累。对于放电等其他种类的缺陷, 也需积累数据后进行分析。

对于电力设备故障预警而言, 重点在于对处于异常和严重状态的设备状态量的预测(而不是预测正常设备的状态量)。在现场应用中, 首先需要进行缺陷种类诊断, 然后再使用同类缺陷的预测模型进行预测。对于处于异常或者严重状态的变压器, 需首先通过三比值法等故障诊断方法判断缺陷种类。若缺陷属于过热, 再利用本文中关于过热缺陷的研究成果进行预测和预警。

6 结论

由于退化发展数据样本较少, 难以利用智能算法预测劣化发展情况, 因此本文基于现场故障数据建立了变压器过热缺陷的非线性 Wiener 退化模型, 并给出了模型参数的统计分布规律, 得到如下结论:

1) 变压器过热故障前夕油中溶解气体发展变化过程整体服从指数规律, 以该指数函数作为时间尺度变换函数, 能够构建气体体积分数的非线性 Wiener 退化过程。

2) 与时间序列模型和 RBF 神经网络相比, Wiener 退化过程对数据序列长度和时间间隔要求低, 能够依靠故障前夕非常少的数据量完成建模; 能够同时表征气体变化过程中的整体趋势和随机性, 具备以可靠性理论和统计概率为基础的可解释性, 非常适合预测设备故障概率。

3) 统计了过热故障变压器油中甲烷、乙烯和

总烃的 Wiener 退化模型中轨道参数概率密度的对数正态分布函数和扩散参数概率密度的威布尔分布函数, 可用于缺乏变压器个体数据时预测变压器的气体浓度, 以及用于构建变压器过热故障发展演化模型。

参考文献 References

- [1] 桂芳旭, 陈 衡, 赵欣悦, 等. 变压器全生命周期成本分析及优化[J]. 广东电力, 2024, 37(3): 44-53.
GUI Fangxu, CHEN Heng, ZHAO Xinyue, et al. Life cycle cost analysis and optimization of transformers[J]. Guangdong Electric Power, 2024, 37(3): 44-53.
- [2] 盛戈碑, 钱 勇, 罗林根, 等. 面向新型电力系统的数字化电力设备关键技术及其发展趋势[J]. 高电压技术, 2023, 49(5): 1765-1778.
SHENG Gehao, QIAN Yong, LUO Lingen, et al. Key technologies and development trends of digital power equipment for new type power system[J]. High Voltage Engineering, 2023, 49(5): 1765-1778.
- [3] 曾宏宇, 杨 冰, 许 涛, 等. 基于红外图像目标检测与温度特征提取的变压器套管发热缺陷识别[J]. 广东电力, 2023, 36(3): 99-106.
ZENG Hongyu, YANG Bing, XU Tao, et al. Heating defect recognition of transformer bushing based on infrared image target detection and temperature feature extraction[J]. Guangdong Electric Power, 2023, 36(3): 99-106.
- [4] 罗运柏, 于 萍, 宋 斌, 等. 用灰色模型预测变压器油中溶解气体的含量[J]. 中国电机工程学报, 2001, 21(3): 65-69.
LUO Yunbai, YU Ping, SONG Bin, et al. Prediction of the gas dissolved in power transformer oil by the grey model[J]. Proceedings of the CSEE, 2001, 21(3): 65-69.
- [5] 杨廷方, 刘 沛, 李 浙, 等. 应用新型多方法组合预测模型估计变压器油中溶解气体浓度[J]. 中国电机工程学报, 2008, 28(31): 108-113.
YANG Tingfang, LIU Pei, LI Zhe, et al. A new combination forecasting model for concentration prediction of dissolved gases in transformer oil[J]. Proceedings of the CSEE, 2008, 28(31): 108-113.
- [6] TAN X M, GUO C, WANG K, et al. A novel two-stage Dissolved Gas Analysis fault diagnosis system based semi-supervised learning[J]. High Voltage, 2022, 7(4): 676-691.
- [7] 肖怀硕, 李清泉, 施亚林, 等. 灰色理论-变分模态分解和 NSGA-II 优化的支持向量机在变压器油中气体预测中的应用[J]. 中国电机工程学报, 2017, 37(12): 3643-3653.
XIAO Huaihuo, LI Qingquan, SHI Yalin, et al. Prediction of dissolved gases in oil for transformer based on grey theory-variational mode decomposition and support vector machine improved by NSGA-II[J]. Proceedings of the CSEE, 2017, 37(12): 3643-3653.
- [8] 黄新波, 蒋卫涛, 朱永灿, 等. 基于时间序列和支持向量机的变压器故障预测[J]. 高电压技术, 2020, 46(7): 2530-2538.
HUANG Xinbo, JIANG Weitao, ZHU Yongcan, et al. Transformer fault prediction based on time series and support vector machine[J]. High Voltage Engineering, 2020, 46(7): 2530-2538.
- [9] 刘可真, 苟家冀, 骆 钊, 等. 基于粒子群优化-长短期记忆网络模型的变压器油中溶解气体浓度预测方法[J]. 电网技术, 2020, 44(7): 2778-2785.
LIU Kezhen, GOU Jiaqi, LUO Zhao, et al. Prediction of dissolved gas concentration in transformer oil based on PSO-LSTM model[J]. Power System Technology, 2020, 44(7): 2778-2785.
- [10] 廖才波, 杨金鑫, 胡 雄, 等. 数据与经验混合驱动下的变压器故

- 障分层诊断方法[J]. 高电压技术, 2023, 49(5): 1841-1850.
- LIAO Caibo, YANG Jinxin, HU Xiong, et al. Hierarchical diagnosis method for transformer faults driven by mixed data and experience[J]. High Voltage Engineering, 2023, 49(5): 1841-1850.
- [11] 廖才波, 蒋子豪, 杨金鑫, 等. 变压器健康状态实时预警方法及可解释性分析[J/OL]. 高电压技术, 2024: 1-11. <https://doi.org/10.13336/j.1003-6520.hve.20240770>.
- LIAO Caibo, JIANG Zihao, YANG Jinxin, et al. Real-time early warning method and interpretability analysis of transformer health condition[J/OL]. High Voltage Engineering, 2024: 1-11. <https://doi.org/10.13336/j.1003-6520.hve.20240770>.
- [12] 林湘宁, 黄京, 熊卫红, 等. 变压器油中溶解气体浓度的区间预测[J]. 电力自动化设备, 2016, 36(4): 73-77.
- LIN Xiangning, HUANG Jing, XIONG Weihong, et al. Interval prediction of dissolved-gas concentration in transformer oil[J]. Electric Power Automation Equipment, 2016, 36(4): 73-77.
- [13] LUO D S, FANG J, HE H Y, et al. Prediction for dissolved gas in power transformer oil based on TCN and GCN[J]. IEEE Transactions on Industry Applications, 2022, 58(6): 7818-7826.
- [14] 王玉伟, 余俊龙, 彭平, 等. 基于多模型融合的变压器故障在线检测方法[J]. 高电压技术, 2023, 49(8): 3415-3424.
- WANG Yuwei, YU Junlong, PENG Ping, et al. Online detection method for transformer faults based on multi-model fusion[J]. High Voltage Engineering, 2023, 49(8): 3415-3424.
- [15] 邹德旭, 徐赫, 权浩, 等. 基于 DGA 和改进 SMOTE 的小样本变压器故障诊断方法[J]. 广东电力, 2024, 37(7): 118-126.
- ZOU Dexu, XU He, QUAN Hao, et al. Small sample transformer fault diagnosis method based on DGA and enhanced SMOTE[J]. Guangdong Electric Power, 2024, 37(7): 118-126.
- [16] 黄欣, 郇嘉嘉, 赵敏彤, 等. 基于 DKG 和 IGCN 的电力变压器故障诊断方法[J]. 广东电力, 2023, 36(11): 146-156.
- HUANG Xin, HUAN Jijia, ZHAO Mintong, et al. Fault diagnosis method of power transformer based on DKG and IGCN[J]. Guangdong Electric Power, 2023, 36(11): 146-156.
- [17] SHENG G H, HOU H J, JIANG X C, et al. A novel association rule mining method of big data for power transformers state parameters based on probabilistic graph model[J]. IEEE Transactions on Smart Grid, 2018, 9(2): 695-702.
- [18] 代杰杰, 宋辉, 盛戈峰, 等. 考虑复杂关联关系深度挖掘的变压器状态参数预测方法[J]. 中国电机工程学报, 2019, 39(2): 621-628.
- DAI Jiejie, SONG Hui, SHENG Gehao, et al. A prediction method for power transformers state parameters based on deep association relation mining[J]. Proceedings of the CSEE, 2019, 39(2): 621-628.
- [19] WANG N N, LI W Y, LI Q Q, et al. Prediction of dissolved gas content in power transformer oil based on EMMD-CS-SVR model[C]//Proceedings of 2023 IEEE International Conference on Applied Superconductivity and Electromagnetic Devices (ASEMD). Tianjin, China: IEEE, 2023: 1-2.
- [20] DUAN Z J. Prediction of dissolved gas content in transformer oil based on BWO-VMD-IWTD-GRU model[C]//Proceedings of 2022 3rd International Conference on Electrical Engineering and Control Science (IC2ECS). Hangzhou, China: IEEE, 2023: 1395-1401.
- [21] WANG T L, YANG J G, LI J S, et al. Time series prediction of dissolved gas concentrations in transformer oil using ARIMA-NKDE method[C]//Proceedings of 2022 2nd International Conference on Electrical Engineering and Control Science (IC2ECS). Nanjing, China: IEEE, 2022: 129-133.
- [22] LIAO R J, BIAN J P, YANG L J, et al. Forecasting dissolved gases content in power transformer oil based on weakening buffer operator and least square support vector machine-Markov[J]. IET Generation, Transmission & Distribution, 2012, 6(2): 142-151.
- [23] LIAO R J, ZHENG H B, GRZYBOWSKI S, et al. Fuzzy information granulated particle swarm optimisation-support vector machine regression for the trend forecasting of dissolved gases in oil-filled transformers[J]. IET Electric Power Applications, 2011, 5(2): 230-237.
- [24] 吴广宁, 倪雪松, 宋臻杰, 等. 基于改进灰色组合模型的变电设备故障率预测[J]. 高电压技术, 2017, 43(7): 2249-2255.
- WU Guangning, NI Xuesong, SONG Zhenjie, et al. Prediction for substation equipment failure rate based on improved grey combination model[J]. High Voltage Engineering, 2017, 43(7): 2249-2255.
- [25] JIANG J, CHEN R Y, ZHANG C H, et al. Dynamic fault prediction of power transformers based on lasso regression and change point detection by dissolved gas analysis[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2020, 27(6): 2130-2137.
- [26] 周淦, 孙超, 安文斗, 等. 基于云推理及加权隐式半 Markov 模型的变压器故障预测[J]. 高电压技术, 2015, 41(7): 2268-2275.
- ZHOU Quan, SUN Chao, AN Wendou, et al. Transformer failure prediction based on cloud reasoning and weighted implicit semi-Markov model[J]. High Voltage Engineering, 2015, 41(7): 2268-2275.
- [27] JIANG J, CHEN R Y, CHEN M, et al. Dynamic fault prediction of power transformers based on hidden Markov model of dissolved gases analysis[J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1393-1400.
- [28] 谢庆, 张焯宇, 王春鑫, 等. 新一代人工智能技术在输变电设备状态评估中的应用现状及展望[J]. 高压电器, 2022, 58(11): 1-16.
- XIE Qing, ZHANG Xuanyu, WANG Chunxin, et al. Application status and prospect of the new generation artificial intelligence technology in the state evaluation of power transmission and transformation equipment[J]. High Voltage Apparatus, 2022, 58(11): 1-16.
- [29] 金光. 基于退化的可靠性技术——模型、方法及应用[M]. 北京: 国防工业出版社, 2014: 2-25.
- JIN Guang. Reliability technology based on degradation[M]. Beijing, China: National Defense Industry Press, 2014: 2-25.
- [30] FREITAS M A, COLOSIMO E A, DOS SANTOS T R, et al. Reliability assessment using degradation models: Bayesian and classical approaches[J]. Pesquisa Operacional, 2010, 30(1): 195-219.
- [31] XU X D, TANG S J, YU C Q, et al. Remaining useful life prediction of lithium-ion batteries based on wiener process under time-varying temperature condition[J]. Reliability Engineering & System Safety, 2021, 214: 107675.
- [32] ZHANG S Y, ZHAI Q Q, SHI X, et al. A wiener process model with dynamic covariate for degradation modeling and remaining useful life prediction[J]. IEEE Transactions on Reliability, 2023, 72(1): 214-223.
- [33] 赵洪山, 常杰英, 曲岳晗, 等. 基于二元非线性 Wiener 随机过程的变压器油纸绝缘剩余寿命预测方法[J]. 电工技术学报, 2023, 38(15): 4040-4049.
- ZHAO Hongshan, CHANG Jieying, QU Yuehan, et al. Residual life prediction method of transformer oil-paper insulation based on binary nonlinear wiener random process[J]. Transactions of China Electrotechnical Society, 2023, 38(15): 4040-4049.
- [34] 杨擎柱, 程养春, 李斐然, 等. 基于现场数据的变压器首次故障率研究[J]. 高电压技术, 2022, 48(5): 1855-1864.
- YANG Qingzhu, CHENG Yangchun, LI Feiran, et al. Study on the first failure rate of transformer based on field data[J]. High Voltage Engineering, 2022, 48(5): 1855-1864.
- [35] 国家能源局. 变压器油中溶解气体分析和判断导则: DL/T 722—2014[S]. 北京: 中国电力出版社, 2015.
- National Energy Administration. Guide to the analysis and the diagno-

sis of gases dissolved in transformer oil: DL/T 722—2014[S]. Beijing, China: China Electric Power Press, 2015.

- [36] XING Y D, HU Y Z, MA Y X, et al. Difference analysis of dissolved gas in natural ester insulating fluids under typical electrical and thermal faults: an experimental study[J]. High Voltage, 2023, 8(6): 1206-1214.
- [37] FENG D W, CHEN G, YAN X Y, et al. Molecular pyrolysis process and gas production characteristics of 3-element mixed insulation oil under thermal fault[J]. High Voltage, 2022, 7(6): 1130-1140.
- [38] 任双赞, 徐尧宇, 李 元, 等. 应用于油中溶解气体分析的深度信念网络与典型神经网络对比研究[J]. 高压电器, 2020, 56(9): 39-45. REN Shuangzan, XU Yaoyu, LI Yuan, et al. Comparison studies of deep belief network and typical neural network applied to analysis of dissolved gas in oil[J]. High Voltage Apparatus, 2020, 56(9): 39-45.
- [39] 李国栋, 王春红, 刘嘉城, 等. 基于 L-S-Seq2Seq 的双通道超短期电力负荷预测[J]. 电力信息与通信技术, 2023, 21(10): 56-65. LI Guodong, WANG Chunhong, LIU Jiacheng, et al. Dual-channel ultra-short-term power load forecasting based on L-S-Seq2Seq[J]. Electric Power Information and Communication Technology, 2023, 21(10): 56-65.
- [40] 肖小刚, 吕东晓, 彭利鸿, 鲁贤龙. 基于 LightGBM-Seq2Seq 的异常天气下的风电功率预测[J]. 电力信息与通信技术, 2024, 22(9): 62-69. XIAO Xiaogang, LYU Dongxiao, PENG Lihong, LU Xianlong. Wind

power forecasting based on LightGBM-Seq2Seq model under abnormal weather[J]. Electric Power Information and Communication Technology, 2024, 22(9): 62-69.



SHAN Jing

单 敬

1999—, 女, 硕士生

主要从事电力设备状态评估方面的研究工作

E-mail: shanjingddd@163.com



CHENG Yangchun

Ph.D., Professor

Corresponding author

程养春(通信作者)

1974—, 男, 博士, 教授, 博导

主要从事输变电装备故障诊断与状态评估理论、先进传感技术、智能输变电装备制造方面的研究工作

E-mail: chych@ncepu.edu.cn

收稿日期 2024-09-18 修回日期 2024-12-27 编辑 卫李静