

DOI: 10.19650/j.cnki.cjsi.J2311277

# 基于 VMD-NARX 的 MOSFET 剩余使用寿命预测方法\*

石欣,张夏恒,朱雅亲,梁飞,石浩天  
(重庆大学自动化学院 重庆 400044)

**摘要:**金属氧化物半导体场效应晶体管(MOSFET)剩余使用寿命预测能够防止因器件长时间导通出现性能逐渐退化或失效,但传统预测模型易忽略 MOSFET 退化参数的非线性细节特征而导致预测精度较差。本文提出一种基于变分模态分解与带外源输入的非线性自回归神经网络的 MOSFET 剩余使用寿命预测方法。首先采用变分模态分解将退化参数序列分解为多组含有非线性变化信息的特征分量。然后分别利用贝叶斯正则和 Levenberg-Marquardt 算法对预测网络进行优化。最终集成多组预测分量值获得 MOSFET 剩余使用寿命预测结果。实验结果表明,本文所提方法的均方根误差小于 0.003,平均绝对百分比误差小于 5%,均优于对比方法,剩余使用寿命预测平均偏差小于 5 min,验证了该方法的有效性。

**关键词:** MOSFET 剩余使用寿命预测;变分模态分解;NARX 神经网络;贝叶斯正则;Levenberg-Marquardt

中图分类号: TH165 文献标识码: A 国家标准学科分类代码: 510.40

## Method for predicting the remaining useful life of MOSFETs based on VMD-NARX

Shi Xin, Zhang Xiaoheng, Zhu Yaqin, Liang Fei, Shi Haotian  
(College of Automation, Chongqing University, Chongqing 400044, China)

**Abstract:** Remaining useful life prediction of metal oxide semiconductor field effect transistor (MOSFET) can prevent gradual degradation or lose efficacy of devices due to long-term conduction. However, the traditional prediction models are difficult to extract the detailed characteristics of nonlinear changes in MOSFETs degradation parameters, resulting in poor prediction accuracy. To address this issue, a remaining useful life prediction method for MOSFETs is proposed, which is based on variational mode decomposition and nonlinear auto-regressive model with exogenous inputs (NARX) neural networks with external inputs. Firstly, the degenerate parameter sequence is decomposed into multiple sets of characteristic components containing nonlinear change information using the VMD method. Secondly, the NARX prediction model is optimized by using Bayesian regularization and Levenberg-Marquardt algorithms, respectively. Finally, integrating multiple sets of feature component prediction values to obtain the remaining life prediction results of MOSFETs. The experimental results show that the root mean square error of the proposed method is less than 0.003, the mean absolute percentage error is less than 5%, all of which are better than the comparison method. The average error of remaining useful life prediction is less than 5 min, which evaluates the effectiveness of the method.

**Keywords:** MOSFET remaining useful life prediction; variational mode decomposition; NARX neural network; Bayesian regularity; Levenberg-Marquardt

## 0 引言

节能减排作为当今世界发展的主题之一,可通过使用电力电子器件以降低能耗,金属氧化物半导体场效应

晶体管(metal oxide semiconductor field effect transistor, MOSFET)作为控制或能量变换器件,因其电路简单、开关速度快、热稳定性好以及导通损耗低等优点,目前被广泛应用于交通、光伏发电与工业控制等领域<sup>[1]</sup>,可以大幅降低功率损耗和提高系统运行效率。随着 MOSFET 使用

收稿日期:2023-04-06 Received Date: 2023-04-06

\* 基金项目: 国家科技部国家重点研发计划(2018YFB1305501)项目资助

过程中导通时间增加,器件功率与性能将会随之衰退,剩余使用寿命(remaining useful life, RUL)也逐步缩短,从而会对整个系统的安全运行产生严重影响。因此, MOSFET 剩余使用寿命预测是保障设备安全稳定运行的基础,对降低能源消耗与运行成本具有重要价值。

设备处于长时间运行时,会导致电子元器件一些敏感功能参数发生一定规律的改变。通过研究电子元器件乃至电子系统完整寿命阶段的稳定性数据,可以对其做出可靠性判断和寿命预测分析。现阶段常用的寿命预测算法包括神经网络<sup>[2-9]</sup>、高斯回归<sup>[10]</sup>、卡尔曼滤波估计<sup>[11]</sup>、扩展卡尔曼滤波<sup>[12]</sup>、粒子滤波<sup>[12-14]</sup>以及无迹卡尔曼滤波<sup>[15-16]</sup>等,国内外学者已将这些方法大量用于各类器件、系统和设备的评估及寿命预测。Khera 等<sup>[17]</sup>采用人工神经网络对电力电子系统中的功率 MOSFET 进行了预测,通过将人工神经网络估计的导通电阻值与测试条件下的在线目标 MOSFET 的实验值进行比较,实时评估了所提出方法的性能。Wang 等<sup>[18]</sup>提出一种基于数据驱动的功率 MOSFET 热应力疲劳失效寿命预测方法,以导通电阻作为故障失效参数,将自回归综合移动平均模型应用于数据驱动的寿命预测,实验结果表明,数据驱动方法比非线性回归算法具有更高的预测精度与更好的稳定性。Zhao 等<sup>[19]</sup>提出一种通过充分利用潜在失效前兆来制定复合前兆的方法,以 SIC MOSFET 数据为基础对方法进行验证,根据退化模型直接优化 CFP 以提高预测性能,结果证明了该方法可以为给定 RUL 预测模型提供有效的故障前兆。Testa 等<sup>[20]</sup>建立了基于实验温度分布分析的功率 MOSFET 雪崩模式可靠性模型,将热力学分析结果与可靠性模型相结合,并基于 Coffin-Manson 定律,可以估计设备随时间的退化,并评估可靠性水平。Dusmez 等<sup>[21]</sup>设计了 MOSFET 自动加速老化平台,结合最小二乘法和卡尔曼滤波预测退化的功率 MOSFET 剩余寿命,结果证明可以实现有限数据的 RUL 估计。Witezak 等<sup>[22]</sup>提出基于 Takagi-Sugeno 多重模型的框架来预测功率 MOSFET 的健康状况,该方法可以数据驱动方式实现预测与故障诊断。Pugalenthi 等<sup>[23]</sup>提出使用前馈神经网络的数据驱动方法来预测具有大噪声的功率 MOSFET 器件,结果表明该方法对高噪声数据的不同退化趋势产生了较好的预测结果。

现有预测算法虽然可以实现对 MOSFET 的寿命预测,但是依然存在精度低和适用性差等问题。主要表现在一些特征提取算法仅仅提取数据的部分特征,忽略了数据的波动细节特征,部分数据预测算法会因预测网络复杂化出现结果过拟合,失去了原本数据应有的特征信息,且单一预测模型在面对非线性序列时泛化性能较差, MOSFET 型号、测试条件等也会导致模型预测精度低,稳定性有所降低。

针对上述问题,本文以 MOSFET 为研究对象,针对 MOSFET 长时间导通会引起性能失效问题,提出一种基于变分模态分解( variational mode decomposition, VMD)和带外源输入的非线性自回归( nonlinear autoregressive models with exogenous inputs, NARX)神经网络的 MOSFET 剩余寿命预测方法,通过变分模态分解得到多尺度特征分量,保留非线性数据的细节变化特征,利用贝叶斯正则与 Levenberg-Marquardt 算法分组优化 NARX 神经网络以提升预测精度,集成各组特征分量预测结果,实现 MOSFET 剩余使用寿命预测。

## 1 功率 MOSFET 性能退化参数分析

本文旨在探讨功率 MOSFET 器件剩余使用寿命预测方法,其前提是需要明确器件对应的失效特征参数。当功率 MOSFET 性能退化时,导通电阻( $R_{DS(on)}$ )、导通压降( $V_{DS(on)}$ )、栅极氧化物电容( $C_{OX}$ )、键合线电阻等参数都将发生变化,若性能退化参数的变化超过规定的失效阈值时,器件将会出现老化。由于材料的热膨胀系数不同, MOSFET 在高低温度反复波动下容易出现键合线突然脱落或断裂,导致无法在线直接获取键合线电阻合栅极氧化电容的完整数据,因此考虑到数据获取方式与数据完整性,难以将上述两个变量作为衡量 MOSFET 性能退化的稳定特征参数。导通压降作为 MOSFET 导通时漏极与源极间电压值,器件导通压降会随着功率循环次数的增加达到饱和,然后开始异常下降,利用导通压降的变化特性虽然可以反映器件的失效机理,但在小电流情况下,饱和压降值较小使得导通压降曲线在器件失效前变化不明显,难以反映 MOSFET 整个生命周期变化特性。导通电阻作为在 MOSFET 器件的栅极施加正向偏压使其导通后,漏极与源极之间有电流通过时总的等效电阻,它能够限制 MOSFET 结构的最大电流传导能力,并且具有变化明显、容易测量的优点,可以较为直观地反映器件从正常至失效的变化历程。考虑到部分参量无法在测试环境中进行连续数据采集,若综合多项特征参量将无法保持数据完整性,容易丢失器件失效点,且难以反映器件生命周期的变化规律,因此本文以导通电阻这一单变量为基础,研究 MOSFET 的退化过程。

由于功率 MOSFET 结构中漏源极之间的电流通路上的各部分电阻是串联的,所以导通电阻可以近似为在电流通路上各部分等效电阻之和。主要包括器件内部结构中的等效电阻和连接外部金属电极间的封装电阻, $R_{DS(on)}$ 的计算如式(1)所示。

$$R_{DS(on)} = R_{CS} + R_{n^+} + R_{CH} + R_A + R_{JFET} + R_D + R_{Sub} + R_{CD} \quad (1)$$

式中: $R_{CS}$ 为源极金属与 $n^+$ 区的接触电阻; $R_{n^+}$ 为 $n^+$ 源区

的等效电阻;  $R_{CH}$  为沟道电阻<sup>[24]</sup>,  $R_A$  为积累层电阻;  $R_{JFET}$  为 JFET 区的等效电阻;  $R_D$  为漂移区的等效电阻;  $R_{Sub}$  为  $n^+$  衬底的等效电阻;  $R_{CD}$  为封装电阻, 封装电阻包括键合线电阻、膜贴焊料电阻和接触电阻等。

由于制造的差异会导致原始状态下  $R_{DS(on)}$  的值因设备而异, 若直接依据  $R_{DS(on)}$  评估 MOSFET 退化性能无法保证结果的一致性, 而  $\Delta R_{DS(on)}$  不仅反映了  $R_{DS(on)}$  的实时变化情况, 也代表了器件从原始状态到失效状态的退化过程。因此应用导通电阻增量  $\Delta R_{DS(on)}$  来表示功率 MOSFET 器件的健康状态, 可以将其作为功率 MOSFET 器件的性能退化参数, 评估其真实健康状态, 建立剩余寿命预测模型。

在明确了 MOSFET 性能参数后, 可通过加速老化方法在短时间内对 MOSFET 进行可靠性评估, 记录加速老化过程中关键输出变量的测量结果, 以数据驱动方式建立 MOSFET 寿命预测模型, 得到功率器件的退化过程信息。

## 2 功率 MOSFET 寿命预测算法

### 2.1 基于变分模态分解的多尺度特征提取

通过对  $\Delta R_{DS(on)}$  数据进行特征提取可以分析其内含的变化规律。变分模态分解<sup>[25]</sup>作为一种完全非递归的变分模式信号分解模型, 将原始信号分解成多个变分模态函数 (variational mode function, VMF), 每个 VMF 都有自己的中心频率, 且解调过后每个模式下的信号都具有其对应的特征值。VMD 本质是构造和解决变分问题<sup>[26]</sup>, 根据实际信号的频域特性, 最终得到合适的 VMF 分量。从 VMF 中提取特征值可以表示  $\Delta R_{DS(on)}$  时间序列的高低频信息, 并且信号频带是通过自适应分割完成的, 能够有效避免模式混叠, 因此采用 VMD 方法对  $\Delta R_{DS(on)}$  数据进行分解可以实现多尺度特征提取。

为实现低频与高频的有效分离, VMD 算法不断寻找每种分量的最优中心频率与有效带宽, 首先对采样信号  $f_0$  进行降噪重构, 而采样信号一般由原始信号和独立的高斯噪声组成。VMD 需要把原始信号  $r(t)$  分解成多个子信号的和, 保证各个分量与输入信号的频率相等, 对原始信号  $r(t)$  的模态函数  $u_k(t)$  进行 Hilbert 变换, 得到  $[\delta(t) + j/\Pi t] \times u_k(t)$ , 再通过在各模态分量中引入中心频率  $\omega_k(t)$  将其调制到基频带, 进而得到  $\{[\delta(t) + j/\Pi t] \times u_k(t)\} e^{-j\omega_k t}$ 。

为了保证每个时间点的重构信号尽量接近原始信号, 通过带宽估计在对应的时间点处添加重构约束如式(2)所示。

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \left\| \sum_{k=1}^K \partial_t \left[ \left( \delta(t) + \frac{j}{\Pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right. \\ \left. \text{s. t. } r(t) = \sum_{k=1}^K u_k(t) \right. \quad (2)$$

式中:  $\{u_k\}$  是模态函数的集合,  $\{\omega_k\}$  是中心频率的集合,  $K$  是分解的模态函数数量,  $\delta(t)$  是狄拉克函数,  $*$  是卷积算子。由于式(2)属于有约束变分算式, 需要引入惩罚因子  $\beta$  和拉格朗日乘数  $\lambda(t)$ , 将其转化成非约束变分算式(3)进行求解:

$$L(u_k, \omega_k, \lambda) = \beta \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\Pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| r(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left( \lambda(t) r(t) - \sum_{k=1}^K u_k(t) \right) \quad (3)$$

由于求解构造的变分公式, 需要将拉格朗日惩罚算子  $\xi$  代入式(3)中, 通过迭代将不断更新  $u_k^{n+1}$ 、 $\omega_k^{n+1}$ 、 $\lambda_k^{n+1}$  的值以此找到增广式的最优解。最终基于拉格朗日惩罚算子与梯度下降更新可以得到  $\lambda^{n+1}$  如式(4)所示。

$$\hat{\lambda}^{(n+1)}(\omega) = \hat{\lambda}^{(n)}(\omega) + \xi \left( \hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k^{(n+1)}(\omega) \right) \quad (4)$$

根据傅里叶等距变换与惩罚参数  $\beta$  可以得到  $\hat{u}_k^{(n+1)}$  如式(5)所示。

$$\hat{u}_k^{(n+1)}(\omega) = \frac{\hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\beta(\omega - \omega_k)^2} \quad (5)$$

对频域基函数进行积分可以得到中心频率  $\hat{\omega}_k^{(n+1)}$  如式(6)所示。

$$\hat{\omega}_k^{(n+1)} = \frac{\int_0^\infty \omega |\hat{u}_k^{(n+1)}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{(n+1)}(\omega)|^2 d\omega} \quad (6)$$

因此, VMD 分解需要初始化  $\{u_k^1\}$ 、 $\{\omega_k^1\}$ 、 $\{\lambda_k^1\}$  和  $n$ , 并选择合适的模态个数  $K$  和惩罚参数  $\alpha$ , 通过式(4) ~ (6) 对  $u_k^1$ 、 $\omega_k^1$ 、 $\lambda_k^1$  进行迭代更新。根据式(7)判断是否满足判断精度  $\sigma$ , 若不满足条件则返回式(3), 若满足则输出  $k$  个模态分量。

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{(n+1)} - \hat{u}_k^{(n)}\|^2}{\|\hat{u}_k^{(n)}\|^2} < \sigma \quad (7)$$

基于 VMD 算法可以对导通电阻变化量进行模态分解, 即可以得到  $k$  个特征分量。

### 2.2 带有外部输入的非线性自回归模型

NARX 神经网络是一种非线性自回归模型, 由静态神经元和网络输出反馈组成<sup>[27]</sup>。NARX 神经网络作为动态神经网络的一种形式, 具有反馈与记忆的功能, 通过反馈与记忆能力保留当前系统的输出值, 添加预测结果至下一时间点的预测中, 最终使网络不仅具有动态性而且保留的系统信息更加完整。

在标准 NARX 神经网络中, 其输出结果将被反馈到输入端, 由于训练过程中的期望输出是已知的, 因此也可以将期望输出反馈到输入端, 网络内部利用两个延迟模块 (tap delay lines, TDL) 对预测结果进行调整, 输入值再

经过网络期望值与权重相加传入下一层结构中,通过隐藏层计算得到输出结果,NARX 网络将输入层与输出层通过反馈层进行连接,使得整体结构可以及时调整输出结果,最终达到精准预测的目的。NARX 神经网络结构图如图 1 所示。

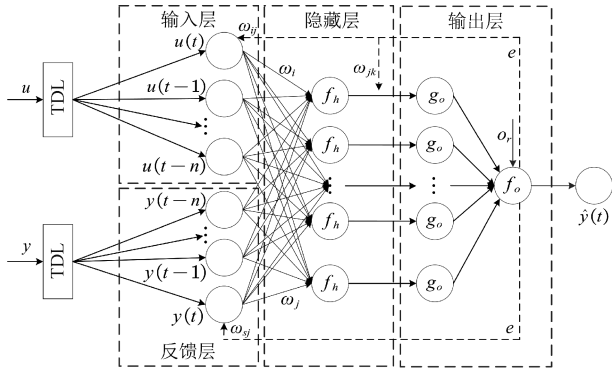


图 1 NARX 神经网络结构图

Fig. 1 Diagram of NARX neural network architecture

NARX 神经网络主要由输入层、隐藏层和输出层以及输入、输出延时构成,非线性系统中 NARX 的基本数学映射如式(8)所示。

$$y(t) = f(y(t-1), \dots, y(t-n), u(t-1), \dots, u(t-n)) \quad (8)$$

其中, \$y(t)\$ 和 \$u(t)\$ 分别作为离散时间步长下的模型输出与输入。

当前的 \$y(t)\$ 值取决于上一时刻 \$y(t)\$ 和 \$u(t)\$。对于单时间序列如式(9)所示。

$$y(t+1) = f \left[ \sum_{i=1}^N \omega_o f \left( \sum_{i=0}^{n_u} \omega_i u(t-i) + \sum_{j=0}^{n_y} \omega_j y(t-j) + b_i \right) + b_o \right] \quad (9)$$

式中: \$\omega\_o\$ 是输出层权重矩阵, \$\omega\_i\$ 是输入层权重矩阵, \$\omega\_j\$ 是隐藏层权重矩阵, \$b\_i\$ 是输入层阈值向量, \$b\_o\$ 是输出层阈值向量。

首先, NARX 神经网络初始化参数, 确定网络节点、隐藏层阈值、输出层阈值以及目标权重; 然后设置学习梯度、隐藏层传递函数 \$f\$ 与输出层传递函数 \$g\$。

进而可以依据式(10)计算隐藏层输出。

$$H_j = f \left( \sum_{i=1}^n \omega_{ij} u_i + \sum_{s=1}^m \omega_{sj} y_s - b_i \right) \quad (10)$$

式中: \$\omega\_{ij}\$ 是输出层更新后的权重矩阵, \$\omega\_{sj}\$ 是反馈层更新后的权重矩阵。

依据式(11)可以计算输出层输出。

$$O_k = g \left( \sum_{j=1}^n H_j \omega_{jk} - b_o \right) \quad (11)$$

式中: \$\omega\_{jk}\$ 是隐藏层更新后的权重矩阵。

每次迭代都会判断误差是否在阈值范围内,若误差满足该范围则输出预测结果,反之则对每层权重与阈值进行更新,返回网络中重新计算各层的结果,直至满足判断条件。

\$\Delta R\_{DS(on)}\$ 作为非线性时变的时序信号,将 NARX 网络应用于导通电阻变化的预测中可以实现对数据的动态响应。

### 2.3 基于 VMD 和优化 NARX 神经网络预测方法

基于 VMD 多尺度特征提取与 NARX 网络动态响应特性,本文将 2.1 中的 VMD 和 2.2 中的 NARX 神经网络进行级联,并利用贝叶斯正则(Bayesian regularization, BR)<sup>[28]</sup>与列文伯格-马夸尔特(Levenberg-Marquardt, LM)<sup>[29]</sup>算法分组优化预测结果,构建功率 MOSFET 寿命预测模型,提高功率 MOSFET 的寿命预测精度。

#### 1) VMD-NARX 预测网络

由于 NARX 递归预测会一直积累误差, NARX 的学习能力过强可能会湮灭预测数据中的噪声信息,导致网络性能下降,泛化能力变差。针对预测过程中的过拟合与梯度下降过快等问题,本文将 VMD 分解方法引入 NARX 神经网络中,根据 VMF 分量的变化特点采用分组优化预测模型的权重。VMD-NARX 预测网络如图 2 所示。




图 2 VMD-NARX 预测网络结构图

Fig. 2 Diagram of VMD-NARX prediction network architecture

首先基于 VMD 方法将时间序列分解成多组平稳模态分量,然后按照一定比例将模态分量划分为训练集与测试集,将数据集分别代入 NARX 模型进行训练。使用

优化器以提升模型预测精度,将BR和LM算法作为NARX模型的优化函数,对每组需要预测的VMF分量进行两次优化。各组VMF分量将根据预测值与实际值之间的拟合度以及预测误差选出最优模型权重优化方法,其中以VMF分量的拟合优度作为衡量预测曲线与实际数据拟合度的指标,以均方根误差作为衡量预测误差的指标。每个特征分量经过优化NARX模型后将得到对应

的预测值,最终将各组特征分量的预测值叠加能够得出 $\Delta R_{DS(on)}$ 的预测结果。

### 2) 预测方法框架

基于MOSFET的 $\Delta R_{DS(on)}$ 数据,将变分模态分解与NARX神经网络结合,利用BR和LM算法优化神经网络,形成功率MOSFET剩余寿命预测方法,方法框架如图3所示。

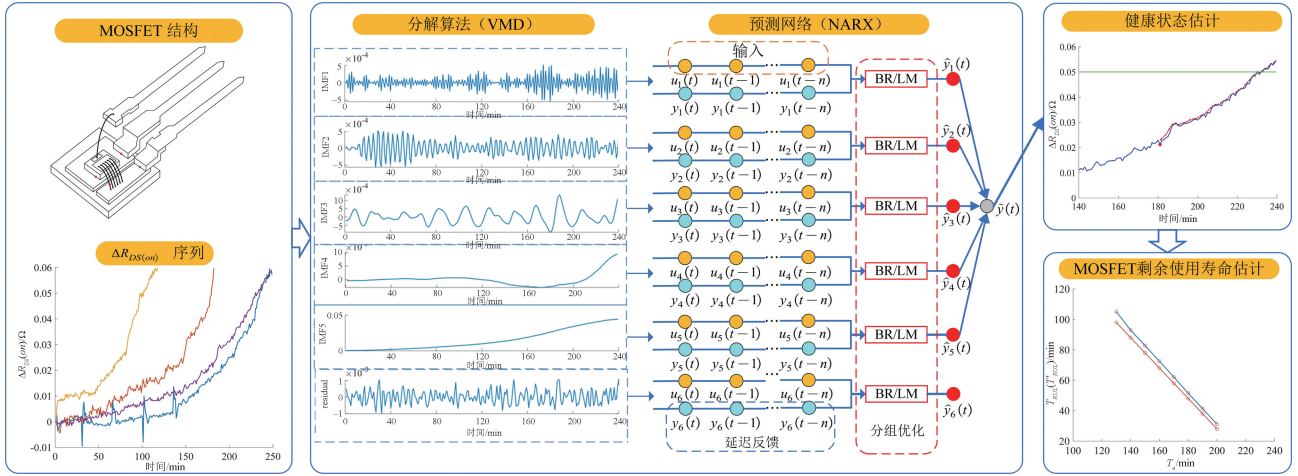


图3 预测方法实现结构图

Fig. 3 Diagram of prediction method implementation architecture

具体步骤如下。

(1) 构建MOSFET退化参数序列。输入任意型号的功率MOSFET的电气量,计算其导通电阻值。依据相邻两组导通电阻值计算出 $\Delta R_{DS(on)}$ ,经过滑动时间窗构建 $\Delta R_{DS(on)}$ 时间序列。

(2) 提取MOSFET $\Delta R_{DS(on)}$ 特征值。采用VMD方法对 $\Delta R_{DS(on)}$ 数据进行多尺度分解,得到对应的模态函数与残差分量。

(3) 构建NARX动态神经网络分组优化模型。将模态分量与残差分量分别输入到NARX神经网络中,引入BR与LM函数对每组预测分量进行两次优化并记录优化结果,以拟合优度与均方根误差衡量两种训练函数下的优化效果,然后各组分量对比两次优化指标的结果选择符合其变化特征的最优训练函数,得到每组分量的最优预测值。

(4) 将各组预测后的模态分量值进行叠加得到最终的MOSFET退化趋势预测结果。

(5) 记录实际退化曲线与预测退化曲线在不同老化时间下达到失效阈值所对应的时间,最终实现对MOSFET剩余使用寿命的精准预测。

### 2.4 评价指标

仅根据预测曲线与实际曲线的变化趋势还无法准确评估模型的准确性,因此为了定量评价模型的预测性能,

本文采用均方根误差(root mean square error, RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)、决定系数(R-squared,  $R^2$ )作为预测模型的评价指标。 $RMSE$ 表示误差平方的期望值,如式(12)所示; $MAPE$ 表示实际值与预测值之差的绝对值占实际值的百分比的平均值,如式(13)所示; $R^2$ 则反映预测值与实际值间的相关性,如式(14)所示。其中 $RMSE$ 和 $MAPE$ 均能描述模型的预测精度, $MAPE$ 可以反映实际值与预测值间的相对大小, $RMSE$ 反映实际值与预测值间的绝对大小,且 $RMSE$ 易于横向比较模型预测性能, $R^2$ 则可以描述模型的拟合程度,能客观反映模型预测效果的优劣。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\bar{R}(i) - R(i))^2} \quad (12)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|\bar{R}(i) - R(i)|}{R(i)} \times 100\% \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (R(i) - \bar{R}(i))^2}{\sum_{i=1}^N (R(i) - \bar{R}(i))^2} \quad (14)$$

式中: $N$ 为预测序列中的数据个数, $\bar{R}(i)$ 和 $R(i)$ 为第 $i$ 个 $\Delta R_{DS(on)}$ 的预测值和实际值, $\bar{R}(i)$ 为 $\Delta R_{DS(on)}$ 实际值的平均值。其中, $RMSE$ 、 $MAPE$ 值越小,表明模型预测精度越高, $R^2$ 越大,表明拟合效果越好。通过 $RMSE$ 、 $MAPE$ 和

$R^2$  可以较为全面地评价本文方法与其他预测方法之间的对比结果。

### 3 分析与讨论

#### 3.1 功率 MOSFET 数据集

本文使用的功率 MOSFET 数据来自 NASA 研究中心公开的功率 MOSFET 热过载老化数据集<sup>[30]</sup>, 该数据集包含在恒定温度下功率 MOSFET 器件加速老化过程中的栅极电压、漏极-源极电压、漏极电流等关键电气参数数据。功率 MOSFET 的老化状态在运行过程中很难直接观测, 但可通过器件的电气参数特征判断 MOSFET 的运行状态, 本文通过计算数据集中漏-源极电压与漏极电流的比值计算出器件的导通电阻, 以导通电阻变化量  $\Delta R_{DS(on)}$  作为反应器件运行状态的特征参数。选择具有稳定运行时间特征的器件数据得到如图 4 所示的  $\Delta R_{DS(on)}$  时间变化曲线。

图 4 所示的  $\Delta R_{DS(on)}$  变化轨迹代表了器件因老化失效而导致的退化过程, 4 组器件在热应力下加速老化, 其  $\Delta R_{DS(on)}$  随时间呈指数增量变化<sup>[18]</sup>, 当达到失效阈值时器件开始老化。MOSFET 热过载老化试验通过施加 PWM 栅极电压加速器件开断频率, 对同一型号的 42 个 MOSFET 器件分别进行多次热过载试验。根据多组试验对样本失效点统计表明, 虽然器件间初始导通电阻值与失效时间不同, 但是多数器件在导通电阻增量为  $0.05 \Omega$ <sup>[12]</sup> 后出现突变增长, 且在此时刻开始器件出现老化迹象。因此为保证实验器件具有统一失效判别标准, 本文在 MOSFET 失效点统计的基础上设定实验数据的失效阈值为  $0.05 \Omega$ , 当  $\Delta R_{DS(on)} = 0.05 \Omega$  时判定器件开始老化。本文基于 VMD-NARX 分组优化模型预测 MOSFET 剩余寿命, 将在尽可能保持原始数据变化特性的前提下, 精准得出  $\Delta R_{DS(on)}$  预测值首次达到失效阈值的时间, 并探究 MOSFET 剩余寿命的变化规律。




图 4 各组  $\Delta R_{DS(on)}$  时间变化曲线

Fig. 4 Time change curve of  $\Delta R_{DS(on)}$

#### 3.2 导通电阻变化量 VMD 分解

首先, 将各组实验器件的  $\Delta R_{DS(on)}$  序列进行 VMD 分解。以 No. 36 功率 MOSFET 为例, 对 VMD 算法参数进行枚举寻优, 得到 6 组 VMD 分量, 其中包含 5 组本征模态分量和 1 个残差分量 (residual), 分解结果如图 5 所示。经过逐次分解的特征分量能够更加明显地反映  $\Delta R_{DS(on)}$  的变化趋势, 且不同频率下的模态分量所包含的信息特征也更为明显, 通过提取各模态分量的有效波动信息能有效保留预测结果的变化特性。

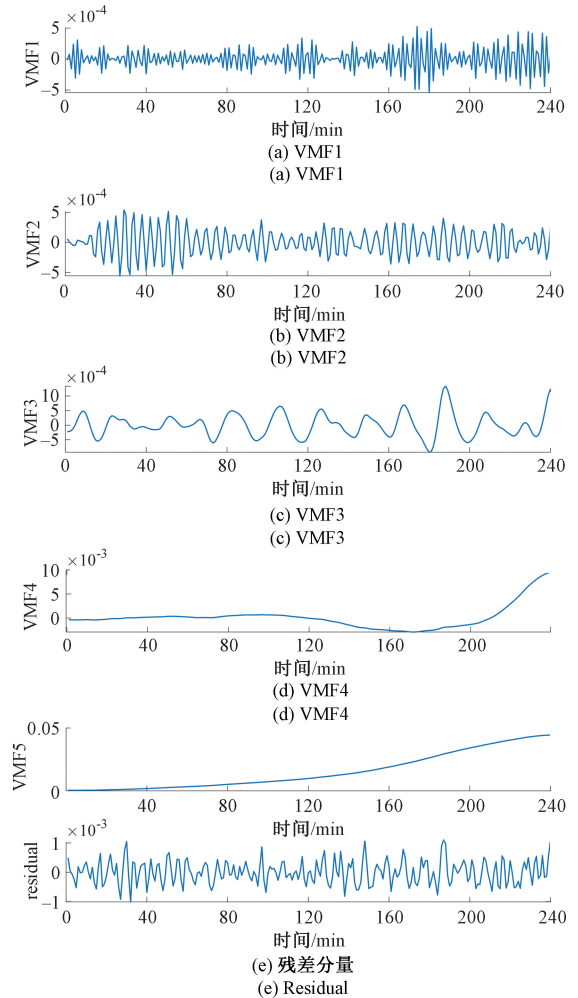


图 5  $\Delta R_{DS(on)}$  VMD 分解结果 (No. 36)

Fig. 5  $\Delta R_{DS(on)}$  VMD decomposition result (No. 36)

#### 3.3 模型预测分析

通过 VMD 方法得到多组特征分量后, 分别将特征分量输入到相互独立的 NARX 神经网络中进行训练, 再基于分组优化的思想解决因训练样本个数少而出现预测结果过拟合问题, 选取 BR 和 LM 作为训练函数实现对特征分量的分组优化, 分组优化时对每组预测分量进行两次优化, 取两次优化预测精度最小且拟合度高的优化方法作为该特征分量的最佳优化器。

在模型测试阶段,以 No. 36 的  $\Delta R_{DS(on)}$  数据为例,取前 180 组数据为训练集,后 60 组数据作为测试集。为了消除结果偶然性,重复 10 次训练,取各组特征分量在 BR 和 LM 优化算法下的均方根误差平均值与拟合优度平均值作为最终的精度结果,结果如表 1 所示。对比各组分量的  $RMSE$  和  $R^2$  可以看出,6 组分量的  $RMSE$  均小于 1%, 各组特征分量在 2 种优化算法下的精度存在明显差异,VMF1、VMF2 和残差分量经 LM 优化后预测误差更小,且预测值与实际值的拟合度更高,说明 LM 对这 3 组分量的优化效果优于 BR,而 VMF3、VMF4 和 VMF5 经过 BR 优化后预测误差更小,实际值与预测值的拟合度更高,说明 BR 对这 3 组分量的优化效果优于 LM。因此,根据特征分量变化特性进行分组优化预测可以有效提升预测精度。

表 1 分量优化精度对比结果

Table 1 Comparison results of the optimization accuracy of component

特征分量	优化方法	$RMSE$	$R^2$
VMF1	BR	$2.255 \times 10^{-4}$	0.434 4
	LM	$1.053 \times 10^{-4}$	0.832 1
VMF2	BR	$1.534 \times 10^{-4}$	0.486 8
	LM	$9.066 \times 10^{-5}$	0.875 6
VMF3	BR	$6.184 \times 10^{-5}$	0.986 6
	LM	$1.599 \times 10^{-4}$	0.941 2
VMF4	BR	$2.053 \times 10^{-4}$	0.989 6
	LM	0.001 2	0.872 1
VMF5	BR	$4.714 \times 10^{-4}$	0.995 0
	LM	0.001 5	0.853 9
residual	BR	$3.750 \times 10^{-4}$	0.297 3
	LM	$2.622 \times 10^{-4}$	0.435 9

6 组特征分量分组优化后的预测结果如图 6 所示,其中,实线代表模型实际值,虚线代表模型预测值。根据图 6 可以看出,各组分量经过 NARX 网络分组优化后得到的结果具有非线性时序映射能力,在完整的时间区间内可以保持良好的预测性能,其中 VMF3、VMF4 和 VMF5 预测结果经 BR 优化后的预测值能够实现对实际值较好的非线性跟随。

本文将各组特征分量预测结果进行叠加,得到如图 7 所示的 MOSFET 退化过程预测结果。

为了更为直观地体现本文方法的有效性,图 8 中展示了 BR、LM 以及 LM+BR 分组优化 3 种方式的预测结果。可见,本文采用 VMD-NARX 模型分组优化输出的  $\Delta R_{DS(on)}$  预测值变化趋势与实际  $\Delta R_{DS(on)}$  变化趋势保持高度一致,基于 LM 优化预测结果超前于实际结果,基于

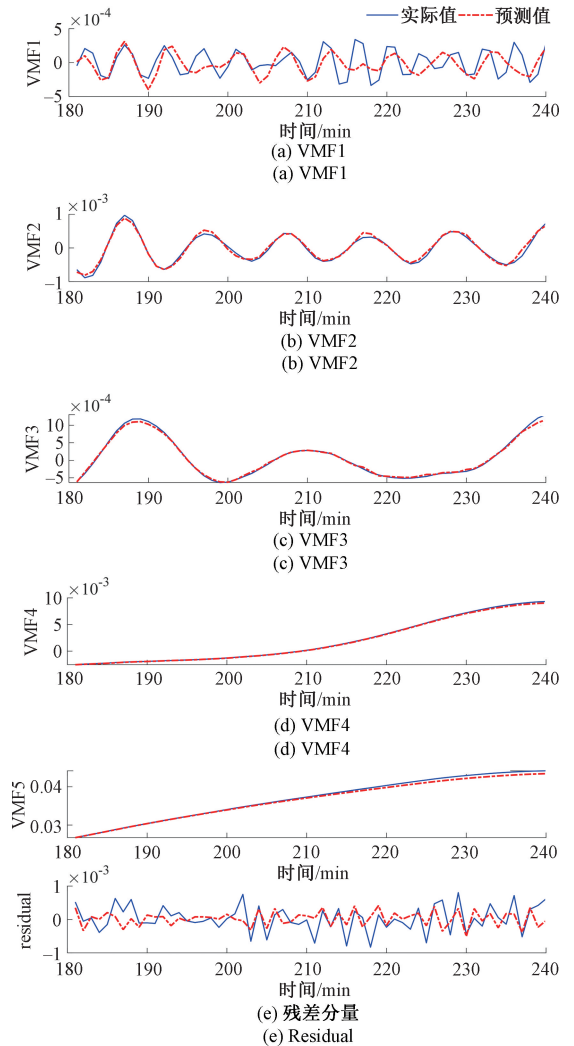



图 6 分量优化预测结果

Fig. 6 Component optimization prediction results

BR 优化预测结果和基于 LM 和 BR 组合优化预测结果则滞后于实际结果,但利用单一优化算法 BR 或 LM 对 NARX 神经网络优化后的预测值与实际值之间存在较大的偏差,说明分组优化的预测效果优于单一优化的预测效果。因此,本文提出的方法对  $\Delta R_{DS(on)}$  非线性变化趋势有较好的适应能力,可以准确预测出  $\Delta R_{DS(on)}$  从退化开始到失效阈值前的变化趋势,进而得出达到故障阈值对应的失效时间,因此依据分解出的模态分量可以有效保留  $\Delta R_{DS(on)}$  在预测过程中存在的剧烈波动,可以较为准确地实现对  $\Delta R_{DS(on)}$  的微小变化预测。在后续连续时间间隔预测过程中将采用 VMD-NARX 分组优化的方法实现功率 MOSFET 寿命的预测。


### 3.4 预测精度对比

为了进一步验证本文提出的 VMD-NARX 预测方法的有效性和泛化性能,选择 No. 9、No. 22 和 No. 36 数据



(a) 不同优化方法的退化全过程预测结果

(a) Prediction results of degradation entire processes for different optimization methods



(b) 不同优化方法的退化局部过程预测结果

(b) Prediction results of degradation local processes for different optimization methods

图7 不同优化方法的退化过程预测结果 (No. 36)

Fig. 7 Prediction results of degradation processes using different optimization methods (No. 36)

进行多组对比实验,3组数据均设定训练集与测试集的比例为3:1,并将本文方法与Celaya等<sup>[12]</sup>提出的单一时序预测方法扩展卡尔曼滤波(extended Kalman filter, EKF)估计、粒子滤波(particle filter, PF)估计,以及组合时序预测模型VMD-BP、VMD-LSTM等方法进行对比分析。基于No. 9、No. 22和No. 36的 $\Delta R_{DS(on)}$ 数据,多种预测方法的精度对比结果如表2所示。

通过上述评价结果可以看出,面对 $\Delta R_{DS(on)}$ 的非线性变化趋势时,单一预测模型EKF和PF因其滤波估计特性所展示的预测效果要优于BP、LSTM以及NARX模型,但部分组合预测模型的预测精度要高于单一预测模型,其中VMD-BP、VMD-LSTM模型的RMSE与MAPE结果均小于BP、LSTM模型,可见结合VMD分解的特征值可以进一步提升单一预测模型的精度,验证了VMD多尺度分解的有效性。相较于前7种预测模型的精度指标,本文所提出的VMD-NARX分组优化模型在3组器件中的RMSE均最小,且均小于0.005,说明其预测精度最高。在No. 9器件中,本文方法的MAPE相较于VMD-BP和VMD-LSTM模型降低了7.3%和6.8%,在No. 22器件中,本文方法的MAPE相较于VMD-BP和VMD-LSTM模型降低了16.4%和23.5%,在No. 36器件中,本文方法的MAPE相较于VMD-BP和VMD-LSTM模型降低了1.5%

表2 多种预测方法精度对比

Table 2 Comparison of accuracy of various prediction methods

MOSFET 器件	预测方法	RMSE	MAPE/%
No. 9	EKF	0.005 8	11.2
	PF	0.007 5	15.9
	BP	0.020 1	39.8
	LSTM	0.019 2	45.1
	NARX	0.006 2	14.1
	VMD-BP	0.005 6	10.3
	VMD-LSTM	0.005 2	9.8
	VMD-NARX(LM 优化)	0.005 1	9.1
	VMD-NARX(BR 优化)	0.004 8	8.3
	本文方法	<b>0.001 6</b>	<b>3.0</b>
No. 22	EKF	0.008 6	12.1
	PF	0.010 3	18.5
	BP	0.033 9	58.1
	LSTM	0.026 6	52.5
	NARX	0.015 2	26.1
	VMD-BP	0.013 1	20.7
	VMD-LSTM	0.015 7	27.8
	VMD-NARX(LM 优化)	0.012 0	17.6
	VMD-NARX(BR 优化)	0.004 2	6.3
	本文方法	<b>0.002 6</b>	<b>4.3</b>
No. 36	EKF	0.001 7	3.2
	PF	0.001 2	2.4
	BP	0.009 3	16.8
	LSTM	0.006 2	16.2
	NARX	0.003 3	6.9
	VMD-BP	0.002 9	5.4
	VMD-LSTM	0.005 7	11.1
	VMD-NARX(LM 优化)	0.001 8	3.6
VMD-NARX(BR 优化)	0.001 5	3.2	
本文方法	<b>0.000 72</b>	<b>1.5</b>	

和9.6%,可见VMD-NARX模型对比其他组合模型具有较高的预测精度。而利用本文方法的预测精度又高于VMD-NARX(LM优化)模型或VMD-NARX(BR优化)模型,可见利用BR和LM分组优化NARX神经网络可以进一步提升预测精度,因此利用VMD与分组优化NARX神经网络可以实现对多种型号下MOSFET退化趋势的高精度预测。


### 3.5 寿命预测结果分析

本文采用VMD-NARX作为功率MOSFET的预测模型,定义 $T_a$ 为器件开始老化的时间, $T_{th}$ 、 $T'_{th}$ 为 $\Delta R_{DS(on)}$ 达




到故障阈值  $\Delta R_{th}$  的实际时间和预测时间,  $T_{EoL}$ 、 $T'_{EoL}$  为器件的实际失效时间与预测失效时间,  $T_{RUL}$ 、 $T'_{RUL}$  为器件的实际剩余使用寿命与预测剩余使用寿命, 实际使用寿命计算如式 (15) 所示。


$$T_{RUL} = T_{th} - T_a, T'_{RUL} = T'_{th} - T_a \quad (15)$$




(a) MOSFET 退化趋势预测结果 ( $T_a=130$ )  
(a) MOSFET degradation trend forecast results ( $T_a=130$ )




(b) MOSFET 退化趋势预测结果 ( $T_a=140$ )  
(b) MOSFET degradation trend forecast results ( $T_a=140$ )




(c) MOSFET 退化趋势预测结果 ( $T_a=150$ )  
(c) MOSFET degradation trend forecast results ( $T_a=150$ )




(d) MOSFET 退化趋势预测结果 ( $T_a=160$ )  
(d) MOSFET degradation trend forecast results ( $T_a=160$ )




(e) MOSFET 退化趋势预测结果 ( $T_a=170$ )  
(e) MOSFET degradation trend forecast results ( $T_a=170$ )



(f) MOSFET 退化趋势预测结果 ( $T_a=180$ )  
(f) MOSFET degradation trend forecast results ( $T_a=180$ )



(g) MOSFET 退化趋势预测结果 ( $T_a=190$ )  
(g) MOSFET degradation trend forecast results ( $T_a=190$ )



(h) MOSFET 退化趋势预测结果 ( $T_a=200$ )  
(h) MOSFET degradation trend forecast results ( $T_a=200$ )

以 No. 36 器件测试本文方法提供的寿命信息, 定义 No. 36 器件在 130、140、150、160、170、180、190、200 时刻开始老化。将  $T_a$  之前的时序数据作为训练集,  $T_a$  之后的时序数据作为测试集进行预测, 得到如图 8 所示不同老化时间下器件退化过程预测结果。

图 8 各老化时间下退化趋势预测结果

Fig. 8 Prediction results of degradation trend at various aging times

根据图8中结果可知,本文提出的方法对不同老化时间下的 MOSFET 退化趋势预测结果可以做到较好地跟随实际变化趋势,由于  $T_a$  的连续增加,模型预测过程中训练集由最初 130 组数据增加至最终 200 组数据,从中可提取的信息也逐渐增多。其中,如图 8(a) 所示  $T_a = 130$  时预测失效时间与实际失效时间还存在较大偏差,且整体预测变化趋势滞后于实际值,但随着  $T_a$  的增大,预测值与实际值之间的误差在逐渐减小,如图 8(b)~(f) 所示,预测失效时间已逐步向实际失效时间靠近,二者间的差距在逐渐缩小,直至  $T_a = 190$  与  $T_a = 200$  时预测失效时间与实际失效时间高度重合,如图 8(g) 和(h) 所示时,此时预测退化趋势整体已超前于实际变化趋势。可见利用本文方法可以实现不同老化时间下精确预测 MOSFET 的退化趋势。

结合各  $T_a$  时刻  $\Delta R_{DS(on)}$  预测结果,可以计算出器件的实际使用寿命与预测使用寿命,以器件 No. 36、No. 22 和 No. 9 为例,其  $\Delta R_{DS(on)}$  对应的  $T_{th}$  分别为 228、180 和 235 min,进而可以得到如表 3、4 和 5 所示的  $T'_{th}$ 、 $T_{RUL}$ 、 $T'_{RUL}$  的预测结果。

表 3 MOSFET 剩余寿命预测结果 (No. 36)  
Table 3 MOSFET RUL prediction results (No. 36)

$T_a$	$T'_{th}$	$T_{RUL}$	$T'_{RUL}$	误差
130	235.1	98	105.1	7.1
140	232.9	88	92.9	4.9
150	232.8	78	82.8	4.8
160	232.5	68	72.5	4.5
170	232.1	58	62.1	4.1
180	232.0	48	52.0	4.0
190	231.9	38	41.3	3.3
200	231.1	28	31.1	3.1

表 4 MOSFET 剩余寿命预测结果 (No. 22)  
Table 4 MOSFET RUL prediction results (No. 22)

$T_a$	$T'_{th}$	$T_{RUL}$	$T'_{RUL}$	误差
100	183.6	79	83.6	4.6
110	180.9	69	70.9	1.9
120	181.8	59	61.8	2.8
130	181.5	49	51.5	2.5
140	180.8	39	40.8	1.8
150	180.5	29	30.5	1.5
160	181.1	19	21.1	2.1
170	180.2	9	10.2	1.2

根据 3 组器件的剩余寿命预测结果可以看出,随着  $T_a$  的增加,可以提取的  $\Delta R_{DS(on)}$  信息随之增加,进而导致  $T'_{th}$  在不断减小,最终得到的预测剩余使用寿命也呈现下降趋势,说明预测精度随着可提取的特征值增加而有所提高。3 组器件在不同老化时间下的  $T_{RUL}$  与  $T'_{RUL}$  间的平

表 5 MOSFET 剩余寿命预测结果 (No. 9)

Table 5 MOSFET RUL prediction results (No. 9)

$T_a$	$T'_{th}$	$T_{RUL}$	$T'_{RUL}$	误差
150	237.5	85	87.5	2.5
160	240.3	75	80.3	5.3
170	237.8	65	67.8	2.8
180	237.4	55	57.4	2.4
190	237.3	45	47.3	2.3
200	236.9	35	36.9	1.9
210	236.8	25	26.8	1.8
220	236.7	15	16.7	1.7




图 9 MOSFET 剩余寿命变化趋势

Fig. 9 Trend of remaining life of MOSFET

均偏差均小于 5 min,说明针对 3 组型号不同的器件数据该模型可以保持较高的预测精度。结合 3 组器件剩余寿命预测结果可以得到如图 9 所示的变化趋势。

由图 9 可知,3 组器件预测剩余寿命变化整体上呈现下降趋势,剩余寿命随着老化时间增加而逐渐减少。因此就功率 MOSFET 使用寿命而言,器件处于寿命衰减的早期,性能下降缓慢,但不影响其正常工作,可以在其老化期间对器件性能进行实时监测,而在器件处于严重老化时,需要保证在达到失效阈值以前及时替换 MOSFET 器件,可以利用本文提出的预测方法对多组 MOSFET 进行训练得到平均剩余寿命结果,然后在实际运行过程中依据预测结果提前 0.5 或 1 min 更换 MOSFET 以保证系统的稳定运行。

## 4 结 论

本文提出了一种基于变分模态分解和 NARX 神经网络的 MOSFET 剩余使用寿命预测方法,以  $\Delta R_{DS(on)}$  作为器件退化性能指标可以反映 MOSFET 从健康状态至失效阈值的全过程变化情况。变分模态分解可以将  $\Delta R_{DS(on)}$  分解为多组特征分量,有效提取了  $\Delta R_{DS(on)}$  的内含特征量,从而保留了数据的非线性变化细节特征。NARX 神

神经网络可以实现对特征分量的有效预测,采用贝叶斯正则和 Levenberg-Marquardt 算法优化 NARX 神经网络进行建模,实现了对每组模态分量的精准预测。通过集成各模态分量的预测结果解决了单一预测模型精度低,泛化能力差的问题。除此之外通过本文方法得到的预测结果能够保留非线性数据的细小变化趋势。基于 NASA 研究中心的 MOSFET 公开数据进行实验验证,将本文所提出方法与多种主流预测方法进行横向对比。3 组器件实验结果显示,本文提出方法  $RMSE$  均不超过 0.003,  $MAPE$  均不超过 5%,相较于对比方法,本文方法在 No. 9 器件下的  $RMSE$  和  $MAPE$  分别降低了 0.003 2~0.018 5、5.3%~42.1%;在 No. 22 器件下的  $RMSE$  和  $MAPE$  分别降低 0.001 6~0.031 3、2%~53.8%;在 No. 36 器件下的  $RMSE$  和  $MAPE$  分别降低 0.000 48~0.008 58、0.9%~15.3%。基于本文方法 3 组 MOSFET 在连续老化时间下  $T_{RUL}$  与  $T'_{RUL}$  间的平均偏差均小于 5 min。综上所述,本文所提出方法相比主流预测方法具有较高的预测精度与较强的泛化能力。

## 参考文献

- [ 1 ] 许泓,任荣杰. 碳化硅器件在节能减排领域的应用展望[J]. 中国能源, 2018, 40(8): 43-47.  
XU H, REN R J. Application prospect of silicon carbide devices in the field of energy conservation and emission reduction[J]. China Energy, 2018, 40(8): 43-47.
- [ 2 ] 魏孟,王桥,叶敏,等. 基于 NARX 动态神经网络的锂离子电池剩余寿命间接预测[J]. 工程科学学报, 2022, 44(3): 380-388.  
WEI M, WANG Q, YE M, et al. An indirect remaining useful life prediction of lithium-ion batteries based on a NARX dynamic neural network [J]. Chinese Journal of Engineering, 2022, 44(3): 380-388.
- [ 3 ] 张明宇,王琦,于洋. 基于 LSTM-DHMM 的 MOSFET 器件健康状态识别与故障时间预测[J]. 电子学报, 2022, 50(3): 643-651.  
ZHANG M Y, WANG Q, YU Y. Health status identification and fault time prediction of MOSFET device based on LSTM-DHMM [J]. Acta Electronica Sinica, 2022, 50(3): 643-651.
- [ 4 ] CHENG Y W, HU K, WU J, et al. Autoencoder quasi-recurrent neural networks for remaining useful life prediction of engineering systems [J]. IEEE/ASME Transactions on Mechatronics, 2021, 27 ( 2 ): 1081-1092.
- [ 5 ] LI X, XU Y, LI N, et al. Remaining useful life prediction with partial sensor malfunctions using deep adversarial networks [J]. IEEE/CAA Journal of Automatica Sinica, 2023, 10(1): 121-134.
- [ 6 ] 常家康,吕宁,詹跃东. 基于 XGBoost-RFECV 算法和 LSTM 神经网络的 PEMFC 剩余寿命预测[J]. 电子测量与仪器学报, 2022, 36(1): 126-133.  
CHANG J K, LYU N, ZHAN Y D. Prediction of PEMFC remaining life based on XGBoost-RFECV algorithm and LSTM neural network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 ( 1 ): 126-133.
- [ 7 ] WANG C, LI Z, OUTBIB R, et al. A novel long short-term memory networks-based data-driven prognostic strategy for proton exchange membrane fuel cells [J]. International Journal of Hydrogen Energy, 2022, 47(18): 10395-10408.
- [ 8 ] 张加劲. 基于注意力机制和 CNN-BiLSTM 模型的航空发动机剩余寿命预测[J]. 电子测量与仪器学报, 2022, 36(8): 231-237.  
ZHANG J J. Remaining useful life estimation of aeroengine based on CNN-BiLSTM and attention mechanism [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 231-237.
- [ 9 ] 黄凯,丁恒,郭永芳,等. 基于数据预处理和长短期记忆神经网络的锂离子电池寿命预测[J]. 电工技术学报, 2022, 37(15): 3753-3766.  
HUANG K, DING H, GUO Y F, et al. Prediction of remaining useful life of lithium-ion battery based on adaptive data preprocessing and long short-term memory network [J]. Transactions of China Electrotechnical Society, 2022, 37(15): 3753-3766.
- [ 10 ] 段俊峰,李宁,唐求,等. 基于 CK-GPR 的多应力环境智能电表剩余寿命预测[J]. 仪器仪表学报, 2021, 42(4): 102-110.  
DUAN J F, LI N, TANG Q, et al. Remaining useful life prediction of smart meter based on CK-GPR in multi-stress environment [J]. Chinese Journal of Scientific Instrument, 2021, 42(4): 102-110.
- [ 11 ] ZHANG N, XU AI D, WANG K, et al. Remaining useful life prediction of lithium batteries based on extended kalman particle filter[J]. IEEE Transactions on Electrical and Electronic Engineering, 2021, 16 ( 2 ): 206-214.
- [ 12 ] CELAYA J R, SAXENA A, SAHA S, et al. Prognostics of power MOSFETs under thermal stress accelerated aging using data-driven and model-based methodologies [C]. Annual Conference of the PHM Society, 2011: 443-452.
- [ 13 ] RAGHAVAN N, FREY D D. Particle filter approach to lifetime prediction for microelectronic devices and systems with multiple failure mechanisms [J]. Microelectronics Reliability, 2015, 55(9-10): 1297-1301.
- [ 14 ] XIE G, PENG X, LI X, et al. Remaining useful life prediction of lithium-ion battery based on an improved particle filter algorithm [J]. The Canadian Journal of

- Chemical Engineering, 2020, 98(6): 1365-1376.
- [15] XU Y H, ZHANG H G, YANG F B, et al. State of charge estimation of supercapacitors based on multi-innovation unscented kalman filter under a wide temperature range [J]. International Journal of Energy Research, 2022, 46(12): 16716-16735.
- [16] 景博, 崔展博, 孙宏达, 等. 失效物理与数据驱动融合的燃油泵在线寿命预测[J]. 仪器仪表学报, 2022, 43(3): 68-76.  
JING B, CUI ZH B, SUN H D, et al. Online life prediction of the fuel pump based on failure physics and data-driven fusion [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 68-76.
- [17] KHERA N, KHAN S A. Prognostics of aluminum electrolytic capacitors using artificial neural network approach [J]. Microelectronics Reliability, 2018, 81: 328-336.
- [18] WANG X, WEI W, ZHANG Y, et al. A data-driven lifetime prediction method for thermal stress fatigue failure of power MOSFETs [J]. Energy Reports, 2022, 8(3): 467-473.
- [19] ZHAO SH, CHEN SH W, YANG F, et al. A composite failure precursor for condition monitoring and remaining useful life prediction of discrete power devices [J]. IEEE Transactions on Industrial Informatics, 2020, 17(1): 688-698.
- [20] TESTA A, DE CARO S, RUSSO S. A reliability model for power MOSFETs working in avalanche mode based on an experimental temperature distribution analysis [J]. IEEE Transactions on Power Electronics, 2012, 27(6): 3093-3100.
- [21] DUSMEZ S, DURAN H, AKIN B. Remaining useful lifetime estimation for thermally stressed power MOSFETs based on on-state resistance variation [J]. IEEE Transactions on Industry Applications, 2016, 52(3): 2554-2563.
- [22] WITCZAK M, MRUGALSKI M, LIPIEC B. Remaining useful life prediction of MOSFETs via the takagi-sugeno framework [J]. Energies, 2021, 14(8): 2135.
- [23] PUGALENTHI K, PARK H, RAGHAVAN N. Prognosis of power MOSFET resistance degradation trend using artificial neural network approach [J]. Microelectronics Reliability, 2019, 100-101(3): 113467.
- [24] SAITO W, NISHIZAWA S I. Assist gate MOSFETs for improvement of on-resistance and turn-off loss trade-off [J]. IEEE Electron Device Letters, 2020, 41(7): 1060-1062.
- [25] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE transactions on Signal Processing, 2013, 62(3): 531-544.
- [26] 王冉, 后麒麟, 石如玉, 等. 基于变分模态分解与集成深度模型的锂电池剩余寿命预测方法 [J]. 仪器仪表学报, 2021, 42(4): 111-120.  
WANG R, HOU Q L, SHI R Y, et al. Remaining useful life prediction method of lithium battery based on variational mode decomposition and integrated deep model [J]. Chinese Journal of Scientific Instrument, 2021, 42(4): 111-120.
- [27] MARCJASZ G, UNIEJEWSKI B, WERON R. On the importance of the long-term seasonal component in day-ahead electricity price forecasting with NARX neural networks [J]. International Journal of Forecasting, 2019, 35(4): 1520-1532.
- [28] LIANG X Y, BAO N SH, ZHANG J, et al. Evaluation of battery modules state for electric vehicle using artificial neural network and experimental validation [J]. Energy Science & Engineering, 2018, 6(5): 397-407.
- [29] OSSAI C I, EGWUTUOHA I P. Real-time state-of-health monitoring of lithium-ion battery with anomaly detection, Levenberg-Marquardt algorithm, and multiphase exponential regression model [J]. Neural Computing and Applications, 2021, 33(4): 1193-1206.
- [30] CELAYA J R, SAXENA A, SAHA S. MOSFET thermal overstress aging data set, NASA ames prognostics data repository [C]. NASA Ames Research Center, Moffett Field, 2010.

## 作者简介



石欣(通信作者), 分别在 2000 年、2003 年和 2010 年于重庆大学获得学士、硕士和博士学位。现为重庆大学教授、博士生导师, 主要研究方向为智能控制、无线传感网络。

E-mail: shixin@cqu.edu.com

**Shi Xin** (Corresponding author) received his B. Sc. M. Sc. and Ph. D. degrees both from Chongqing University in 2000, 2003 and 2010, respectively. He is currently a professor and a Ph. D. advisor at Chongqing University. His main research interests include intelligent control and wireless sensor network.



张夏恒, 2022 年于重庆邮电大学获得学士学位, 现为重庆大学硕士研究生, 主要研究方向为故障诊断与寿命预测、分布式机器学习。

E-mail: 1776801443@qq.com

**Zhang Xiaoheng** received his B. Sc. degree from Chongqing University of Posts and Telecommunications in 2022. He is currently a master student at Chongqing University. His main research interests include fault diagnosis and remaining useful life prediction, distributed machine learning.