



引用格式:蔡宜伦,周兴飞,张润芝,等. 基于轻量多尺度时间卷积网络模型的开关电源退化预测研究[J]. 海南大学学报(自然科学版中英文), DOI: 10.65658/j.hndk.2026020301.

Citation: CAI Yilun, ZHOU Xingfei, ZHANG Runzhi, et al. Research on degradation prediction of switching power supplies based on a lightweight multi-scale temporal convolutional network model[J]. Natural Science of Hainan University, DOI: 10.65658/j.hndk.2026020301.

Open Access

## 基于轻量多尺度时间卷积网络模型的 开关电源退化预测研究

蔡宜伦<sup>1</sup>, 周兴飞<sup>2</sup>, 张润芝<sup>2</sup>, 张育玮<sup>2</sup>, 王兴坚<sup>2,3</sup>✉

(1. 北京宇航系统工程研究所 总体设计部, 北京 101160; 2. 北京航空航天大学 自动化科学与电气工程学院, 北京 100191; 3. 天目山实验室, 浙江 杭州 310023)

**摘要:** 针对物理模型驱动方法依赖机理先验、典型循环神经网络在复杂非平稳退化信号建模中存在训练效率低和计算负荷大的问题, 本研究提出一种面向开关电源退化预测的轻量多尺度时间卷积网络模型。该模型在时间卷积网络结构基础上, 利用多尺度膨胀卷积协同建模纹波电压信号中的短时波动特征与长期退化趋势, 并引入 Dropout 正则化、Huber 损失函数与早停机制, 以提升模型在小样本、强噪声条件下的泛化能力和训练效率。基于所搭建的电容退化试验平台, 采集正常、过压和高温等多应力条件下的开关电源纹波电压数据, 对所提 LMS-TCN 模型进行验证。试验结果表明, 所提 LMS-TCN 模型在预测精度和收敛效率方面均具有明显优势, 能够较好适应开关电源退化预测中的在线实时应用需求, 为开关电源寿命评估与预测性维护提供了一种高效可行的新方案。

**关键词:** 开关电源; 退化预测; 时间卷积网络; 可靠性评估

**中图分类号:** V438<sup>+</sup>.4; TP802<sup>+</sup>.1 **文献标志码:** A

**DOI:** 10.65658/j.hndk.2026020301 **CSTR:** 32403.14.hndk.2026020301

## Research on degradation prediction of switching power supplies based on a lightweight multi-scale temporal convolutional network model

CAI Yilun<sup>1</sup>, ZHOU Xingfei<sup>2</sup>, ZHANG Runzhi<sup>2</sup>, ZHANG Yuwei<sup>2</sup>, WANG Xingjian<sup>2,3</sup>✉

(1. Beijing Aerospace Systems Engineering Research Institute, General Design Department, Beijing 101160, China; 2. School of Automation Science and Electrical Engineering, Beihang University, Beijing 100191, China; 3. Tianmushan Laboratory, Hangzhou 310023, China)

**Abstract:** To address the dependence of physics-model-driven methods on prior mechanism knowledge, as well as the low training efficiency and high computational burden of typical recurrent neural networks in modeling complex non-stationary degradation signals, this paper proposes a lightweight multi-scale temporal convolutional network model for degradation prediction of switching power supplies. Built upon the temporal convolutional network architecture, the proposed model employs multi-scale dilated convolutions to jointly model short-term fluctuation features and long-term degradation trends in ripple signals. Dropout regularization, Huber loss, and an early stopping mechanism are further introduced to improve the

**Received:** 2026-02-03; **Revised:** 2026-05-15; **Accepted:** 2026-05-17.

✉ **Corresponding author(s):** WANG Xingjian, E-mail: wangxj@buaa.edu.cn.

generalization ability and training efficiency of the model under small-sample and strong-noise conditions. Based on the established capacitor degradation experimental platform, ripple data of switching power supplies under multiple stress conditions, including normal, overvoltage, and high-temperature conditions, are collected to validate the proposed LMS-TCN model. Experimental results show that the proposed LMS-TCN model achieves clear advantages in prediction accuracy and convergence efficiency, and can well meet the requirements of online real-time degradation prediction of switching power supplies, providing an efficient and feasible solution for their life assessment and predictive maintenance.

**Keywords:** switching power supply; degradation prediction; temporal convolutional network; reliability assessment

## 0 引言

开关电源作为高效电能转换的核心单元,已广泛应用于智能工程机械、航空航天等高可靠性领域<sup>[1]</sup>,其运行状态直接决定整个电子系统的功能完整性与稳定性。一旦发生故障,可能导致系统性能退化乃至完全失效,造成重大经济损失与安全事故<sup>[2]</sup>。随着电子设备向高功率密度与高集成度持续演进,对开关电源的长期可靠运行提出了更为严格的要求。因此,开展其全寿命周期的健康状态监测与预测性维护,对于降低运维成本、提升系统可靠性与产品附加值具有重要意义<sup>[3]</sup>。

开关电源的性能退化主要源于内部关键元器件的渐进性失效<sup>[4]</sup>。在实际运行中,开关电源的驱动信号及整流端电压均为高频方波信号,易激发电路中电感、电容网络的谐振。尤其在开关瞬态过程中,功率器件周边会产生显著的电压与电流尖峰,导致输出纹波电压增大。值得注意的是,电感-电容(LC)滤波电容在长期运行中会因电解液挥发与等效串联电阻上升而发生容值衰减与损耗增加<sup>[5]</sup>,进一步加剧输出电压波动,严重影响系统稳定性。因此,如何准确提取电容退化所引发的纹波电压特征,并据此实现健康状态评估与剩余寿命预测,已成为该领域的关键研究方向<sup>[6]</sup>。

目前,开关电源健康监测与寿命预测方法主要分为物理模型驱动与数据驱动两类<sup>[7]</sup>。物理模型方法基于电路理论与失效机理构建退化模型,并采用卡尔曼滤波等进行状态跟踪与预测<sup>[8]</sup>,虽具有明确的物理意义,但严重依赖精确模型先验,对多变工况与不同拓扑结构的泛化能力有限。数据驱动方法则直接从历史监测数据中挖掘退化规律,例如借助小波变换、经验模态分解等进行特征提取,或采用支持向量回归、灰色系统理论等进行寿命推断<sup>[9]</sup>。然而,现有数据驱动方法在捕捉长期依赖关系、处理多退化耦合机制以及抗噪声干扰方面仍存在不足,制约了其在复杂工业场景中的稳健性与适用性<sup>[10]</sup>。

近年来,机器学习为时序预测提供了新的解决路径。根据建模技术的演进,可将其分为3类:(1)基于浅层模型的机器学习方法。此类方法在早期研究中主要采用支持向量回归(support vector regression, SVR)、灰色系统理论、人工神经网络(artificial neural network, ANN)等进行寿命推断。Klass等<sup>[11]</sup>提出一种基于支持向量机的电池健康状态估计方法,用于电动汽车锂离子电池的健康状态(state of health, SOH)估计。Driscoll等<sup>[12]</sup>构建了基于电池充电参数特征提取的ANN模型。总体而言,上述浅层机器学习方法在捕捉长期依赖关系、处理多退化耦合机制以及抗噪声干扰方面仍存在不足,制约了其在复杂工业场景中的稳健性与适用性。(2)循环神经网络及其变体针对时序依赖性问题,长短期记忆网络(long short-term memory, LSTM)及其变体被广泛应用于退化预测。Wang等<sup>[13]</sup>提出一种基于动态LSTM的卫星锂离子电池间接剩余寿命预测方法。Xu等<sup>[14]</sup>采用改进的卷积神经网络-长短期记忆网络(convolutional neural network-long short-term memory, CNN-LSTM)模型对锂离子电池健康状态进行估计。Khumprum等<sup>[15]</sup>提出深度神经网络方法预测电池SOH剩余使用寿命(remaining useful life, RUL)。尽管LSTM在序列建模中表现优异,但其循环结构导致训练效率低下,且难以并行计算,在长序列预测中易出现梯度消失问题。(3)时间卷积网络与注意力机制。近年来,时间卷积网络(temporal convolutional network, TCN)被提出,其

应用范围愈发广泛,优点在于能够有效兼顾长序列建模效率与并行计算效率<sup>[16]</sup>。Hewage 等<sup>[17]</sup>将 TCN 用于气象站时间序列数据的天气预报任务。在工业预测领域, Olschewski 等<sup>[18]</sup>研究了基于机器学习的碳化硅(silicon carbide, SiC)功率模块状态监测方法,并对比了 LSTM 和分块时间序列 Transformer(patch time series transformer, PatchTST)等多种架构的剩余寿命估计性能,发现 PatchTST 架构可实现 5% 以内的 RUL 估计误差,但也指出模型在训练分布外的泛化能力不足。

为增强 TCN 的特征提取能力,研究者开始探索注意力机制与 TCN 的融合。Lin 等<sup>[19]</sup>提出一种基于通道注意力和时间注意力的双重注意力 TCN 框架(channel attention and temporal attention based temporal convolutional network, CATA-TCN),用于航空发动机剩余寿命预测,通过通道注意力筛选关键传感器信号,时间注意力聚焦性能退化关键时点,显著提升了预测精度。Xiao 等<sup>[20]</sup>进一步提出不确定性感知的深度变分注意力网络,通过注意力权重的随机化实现模型不确定性估计,增强故障诊断模型的可信度。Zhong 等<sup>[21]</sup>将自注意力机制与轻量级 CNN 结合,用于滚动轴承故障诊断。

尽管 TCN 及注意力增强 TCN 在工业预测中展现出潜力,但其用于开关电源退化预测时仍面临若干挑战<sup>[22]</sup>: (1)电源内部多退化路径之间存在耦合效应,单一特征提取机制难以充分刻画; (2)动态负载下监测信号非平稳、噪声突出,影响特征一致性表达; (3)TCN 模型参数量较大、训练周期较长,不利于在线部署与实时预测; (4)多数方法对预测结果的不确定性评估不足,限制了其在工程决策中的可信度。

针对上述问题,本研究提出一种轻量多尺度时间卷积网络(lightweight multi-scale temporal convolutional network, LMS-TCN)模型。与现有 LSTM、TCN 及一般深度时序预测方法相比,所提模型围绕开关电源纹波电压退化信号“高频局部波动与低频长期演化并存”的特点,对网络结构与训练策略进行针对性设计。在保留 TCN 并行计算和长时依赖建模优势的基础上,主要从多尺度特征提取、轻量化稳健训练和多工况试验验证 3 个方面展开研究。

## 1 开关电源模型及退化原理分析

**1.1 开关电源分析** 典型开关电源系统结构如图 1 所示,主要包括输入整流滤波电路、DC-DC 变换电路、整流滤波输出电路、电压电流反馈取样电路、比较放大电路和开关控制电路。220 V 工频交流输入输入经整流滤波后送入 DC-DC 变换电路,通过整流滤波输出获得稳定直流;同时,输出端电压、电流信号经反馈取样和比较放大后作用于开关控制电路,实现对输出电压的闭环调节。




图 1 开关电源系统结构图

为保障开关电源的高可靠运行,其核心在于实现对电能形式的有效转换与精确调控。通常,开关电源首先将 220 V 工频交流输入经输入整流滤波转换为含有 100 Hz 纹波电压的脉动直流电压,随后输入至 DC-DC 变换电路。该电路通常由功率开关器件、高频变压器及滤波电感、电容等组成,其核心功能是通过控制开关器件的导通与关断,将直流电压转换为高频脉冲方波,并利用脉宽调制(pulse width modulation, PWM)技术调节占空比,从而精确控制传输至输出端的能量。

DC-DC 变换电路不仅决定了电源的拓扑结构,还承担了电气隔离、电压变换与高效能量传递等关键任务,是影响整机性能的核心环节。在闭环控制条件下,反馈网络实时采样输出电压并与参考电压进行比较,通过补偿器动态调节 PWM 占空比,以抑制输入电压波动或负载变化引入的扰动,显著提升系统的稳态精度与动态响应能力。

DC-DC 变换电路在实际工作中受到变压器漏感、开关管结电容以及 PCB 分布参数等寄生因素的显著影响<sup>[23]</sup>。在高频开关信号激励下,这些寄生参数易引发谐振现象,不仅会带来电磁兼容性问题,还可能造成严重后果:(1)寄生谐振通过变压器耦合至输出端,导致输出电压纹波及噪声显著增大;(2)若寄生谐振频率位于控制环路带宽附近,可能削弱闭环稳定裕度,甚至诱发电路振荡,威胁电源的长期可靠运行。因此,有效抑制寄生谐振并优化闭环动态特性,是提升开关电源综合性能的关键挑战。

为应对上述问题,现代开关电源设计普遍采用拓扑优化、先进控制与寄生参数协同管理相结合的系统化方法。例如,引入有源钳位或软开关技术以降低开关损耗与器件应力,并结合布局优化与缓冲吸收电路设计来有效阻尼谐振振荡。综上所述,稳定性控制与输出电压纹波抑制是开关电源设计中必须统筹解决的核心问题,需通过多维度 and 跨层次的协同优化,才能在实现高功率密度与高效率的同时,确保低纹波电压输出与长期运行可靠性。

**1.2 开关电源退化分析** 开关电源模块的输出端常采用铝电解电容器作为输出滤波元件,其结构主要由铝壳、卷绕式电芯、橡胶密封件和端子引线组成。其中,卷绕式电芯由阳极铝箔、电解纸及阴极铝箔经卷绕工艺制成,是实现电荷存储与滤波功能的关键部分。铝电解电容器在长期运行中的性能退化与最终失效,主要源于温度应力引起的电解液持续挥发:在高温工作环境下,电解纸所含电解液逐渐蒸发,并在铝电解电容器内部产生气体,导致铝电解电容器电气性能逐步劣化直至失效<sup>[24]</sup>。该退化过程直接体现为关键参数的变化,即电容值随退化加剧而下降,同时等效串联电阻相应上升。

根据电容的结构特点建立其等理想电容 $C_{out}$ 的退化模型,其随时间和温度的变化关系:

$$C_{out}(T, V_c, t) = C_{out}(0) \cdot \exp(-A \cdot t) \quad (1)$$

$$A = A_0 \cdot \exp\left(-\frac{E_a}{K T_c}\right) \cdot \exp\left(\beta \cdot \left(\frac{V_c}{V_{c_{rated}}}\right)\right) \quad (2)$$

其中, $C_{out}(T, V_c, t)$ 表示在温度 $T$ 、工作电压 $V_c$ 和运行时间 $t$ 下输出的电容值; $C_{out}(0)$ 表示初始输出电容值; $A$ 为退化速率参数; $A_0$ 为退化模型的基准退化系数; $E_a$ 为活化能参数; $K$ 是玻尔兹曼常数(约为 $8.62 \times 10^{-5} \text{eV} \cdot \text{K}^{-1}$ ); $T$ 为绝对温度, $K$ ;  $t$ 为运行时间; $V_c$ 为电容器两端的实际工作电压; $V_{c_{rated}}$ 为电容器额定电压; $\alpha$ 和 $\beta$ 为电压应力相关的经验系数。选取 $C_{out}(T, V_c, t)$ 作为电容器性能退化特征,用于表征并预测未来电容器的退化状态。

## 2 基于 LMS-TCN 模型的电源纹波电压预测方法

**2.1 LMS-TCN 模型框架** 针对电源输出的时间序列纹波电压信号具有明显的非线性、非平稳性以及多时间尺度耦合特征的问题,本研究提出的 LMS-TCN 模型为复杂退化纹波电压建模提供了一种有效途径。LMS-TCN 模型的整体预测框架图(如图 2 所示)主要包括:数据预处理、多尺度时序特征提取、关键时段加权表征、稳健训练策略和预测结果输出等关键环节。该模型在保持 TCN 并行计算优势的同时,进一步提升了复杂退化演化过程的建模能力。

**2.2 LMS-TCN 模型内部原理** 长期以来,序列建模任务主要依赖于循环神经网络(recurrent neural network, RNN)及其变体,如 LSTM 与门控循环单元(gated recurrent unit, GRU)。然而,RNN 类模型在处理长时间序列时通常存在梯度消失、梯度爆炸以及长期依赖建模困难等问题,且其循环结构限制了并行计算效率。相比之下,TCN 采用一维卷积结构进行序列特征提取,在部分序列建模任务中表现出较好的预测性能。TCN 不仅能够缓解 RNN 类模型常见的梯度消失和梯度爆炸问题,还可利用卷积结构支持并行计算,从而提高模型训练与推理效率。

TCN 模型的主要特点有因果卷积、膨胀卷积和残差连接。

因果卷积的核心思想是保证模型在预测当前时刻输出时,仅利用当前时刻及其历史时刻的输入信息,而不依赖未来时刻的信息。即对于上一层 $t$ 时刻的值,只依赖于下一层 $t$ 时刻及其之前的值。与卷积神经网络的不同之处在于:因果卷积无法看到未来的数据,即为单向的结构而非双向。即根据给定输入序

列  $x_1, x_2, \dots, x_T$  预测  $y_1, y_2, \dots, y_T$ 。特别指出,在预测  $y_T$  时仅能使用已观测信息  $x_1, x_2, \dots, x_T$  而不能使用  $x_{T+1}, x_{T+2}, \dots$ 。膨胀卷积通过在标准卷积核中引入稀疏采样间隔,在不增加参数量或降低特征图分辨率的前提下,实现了感受野的指数式扩展。对于滤波器  $F = (f_1, f_2, \dots, f_k)$ , 序列  $X = (x_1, x_2, \dots, x_T)$ , 在时刻  $x_i$  处的膨胀卷积运算定义:

$$(F_{*d}X)_{(x_i)} = \sum_{k=1}^K f_k x_{i-(K-k)d} \quad (3)$$




图2 LMS-TCN 模型预测框架图

其中,  $d$  表示膨胀率。针对开关电源退化过程中多时间尺度特征耦合的特性,即同时存在开关频率级别的高频纹波电压扰动与电容老化引发的缓慢漂移趋势,本研究在 TCN 的残差块中采用了膨胀率逐层递增的层级化设计(设定  $d \in 1, 2, 4, 8$ )。使用膨胀率逐层递增的层级化设计可以使得浅层网络聚焦于局部高频细节,深层网络则有效捕获长程时序依赖,尤其是电容容值衰减的全局演化趋势。此设计使模型无需引入额外的并行分支,即可实现对退化信号不同频域分量的自适应解耦与融合,从而为后续的剩余寿命预测提供了鲁棒且丰富的特征表示。

残差连接是一种有效的训练深层网络的方法,使得网络可以以跨层的方式传递信息。残差路径为梯度反向传播提供了捷径,可以有效缓解梯度消失问题。快捷路径确保原始输入信息能直接传递到后续层,与经过卷积变换后的特征进行融合,这有助于模型结合不同层次的特征做出更准确的判断。本研究采用的 LMS-TCN 模型中,每个残差块的输出:

$$o = \text{Activation}(z^{(l)} +) \text{Conv}1 \times 1(z^{(l-1)}) \quad (4)$$

其中,  $1 \times 1$  卷积用于调整通道维度,确保残差连接两端的特征维度一致,从而保证跳跃连接能够进行逐元素相加。 $z^{(l-1)}$  表示第  $l-1$  层的输入特征,  $z^{(l)}$  表示第  $l$  层卷积变换后的中间特征表示。

在此基础上,模型中还引入了 Dropout 正则化。Dropout 是一种有效的正则化技术,主要用于防止过拟合并提升模型的泛化能力。其核心思想是在训练过程中,以一定概率随机屏蔽部分神经元的输出,使其激活值变为 0,从而打破神经元之间的复杂共适应关系。在 LMS-TCN 模型中每个卷积层后引入 Dropout 层:

$$z_{drop}^{(l)} = \text{Dropout}(z^{(l)}, p = 0.1) \quad (5)$$

并采用梯度裁剪控制更新幅度:

$$\mathbf{g} \leftarrow \text{clip}(\mathbf{g}, -0.1, 0.1) \quad (6)$$

其中,  $\mathbf{g}$  表示反向传播过程中计算得到的梯度;  $\text{clip}()$  表示梯度裁剪函数, 用于将梯度限制在给定范围内。当梯度小于  $-0.1$  时取  $-0.1$ , 当梯度大于  $0.1$  时取  $0.1$ , 从而避免梯度过大导致模型训练不稳定。

为了进一步提升 LMS-TCN 模型的可解释性, 使预测结果能够反映输入序列中关键时间步的贡献, 在模型的输出端引入一个轻量级的时间注意力机制。针对最后一个残差块的输出  $\mathbf{z}^{(L)} \in \mathbf{R}^{T \times C}$  (其中  $T$  为时间步长,  $C$  为通道数), 首先通过一个全连接层计算每个时间步的注意力得分:

$$\mathbf{e}_t = \tanh(\mathbf{W}_e \mathbf{z}_t^{(L)} + \mathbf{b}_e) \quad (7)$$

其中,  $\mathbf{z}_t^{(L)}$  为第  $t$  个时间步的特征向量。随后通过 softmax 函数对得分进行归一化, 得到注意力权重:

$$\alpha_t = \frac{\exp(e_t)}{\sum_{i=1}^T \exp(e_i)} \quad (8)$$

最后将加权后的特征向量  $\tilde{\mathbf{z}} = \sum_{i=1}^T \alpha_i \mathbf{z}_i^{(L)}$  作为全局表示, 输入至输出层执行预测任务。

引入注意力机制不仅能够自动聚焦于开关电源退化的关键时段, 而且后续通过可视化注意力权重, 可以直观地解释模型的决策依据。本研究模型更关注在有限数据条件下实现预测精度、训练效率和工程部署可行性的平衡。

**2.3 LMS-TCN 模型流程** 首先对于初始试验采集的纹波电压序列  $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$  进行数据标准化处理:

$$\hat{x}_t = \frac{x_t - \mu}{\sigma} \quad (9)$$

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (10)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (11)$$

然后进行滑动窗口的构建。给定输入长度  $L$  和输出长度  $H$ , 构建特征  $\mathbf{F}^{(k)}$  和标签  $\mathbf{Y}^{(k)}$ :

$$\mathbf{F}^{(k)} = [\hat{x}_k, \hat{x}_{k+1}, \dots, \hat{x}_{k+L-1}]^T \in \mathbf{R}^{L \times 1} \quad (12)$$

$$\mathbf{Y}^{(k)} = [\hat{x}_{k+L}, \hat{x}_{k+L+1}, \dots, \hat{x}_{k+L+H-1}]^T \in \mathbf{R}^H \quad (13)$$

其中,  $k = 1, 2, \dots, N - L - H + 1$ .

为了 TCN 前向传播, 将  $\mathbf{F}^{(k)}$  输入 TCN, 其第  $l$  层膨胀卷积输出:

$$\mathbf{z}^{(l)} = \sigma(\mathbf{W}^{(l)} *_d \mathbf{z}^{(l-1)} + \mathbf{b}^{(l)}) \quad (14)$$

其中,  $*_d$  表示膨胀因子为  $d$  的因果卷积,  $\sigma$  为 ReLU 激活函数,  $d = 2^{l-1}$  随层数指数增长。取最后一层时序维度的末尾特征, 经全连接层映射为预测值:

$$\hat{\mathbf{Y}}^{(k)} = \mathbf{W}_{out} \mathbf{z}_{:, -1}^{(L)} + \mathbf{b}_{out} \quad (15)$$

对预测结果进行反标准化, 即可得到实际纹波电压预测值。最后进行损失计算与反向传播, 采用 Huber 损失函数进行优化:

$$L_\delta(y, \hat{y}) = \begin{cases} \frac{1}{2}(y - \hat{y})^2, & |y - \hat{y}| \leq \delta \\ \delta|y - \hat{y}| - \frac{1}{2}\delta^2, & \text{其他} \end{cases} \quad (16)$$

其中,  $\delta$  为阈值参数, 取  $\delta = 1.0$ 。

### 3 退化试验设计

**3.1 开关电源退化试验台设计** 为验证 LMS-TCN 模型在开关电源退化预测中的准确性、泛化能力和工程适用性, 设计并搭建了一套可模拟开关电源中铝电解电容退化过程的试验平台, 如图 3 所示。该平台以开关电源整流滤波电路中的关键铝电解电容为研究对象, 通过将原电路中的铝电解电容替换为高精度可调数字电容器, 并利用外部程控信号连续调节其等效电容值, 从而在试验条件下模拟铝电解电容在实际运行过程中的容量衰减过程。

退化状态的注入主要通过调节电磁干扰 (electromagnetic interference, EMI) 滤波模块中

LC 滤波电容的容值实现。试验中, 依据电容失效模型预设一系列离散且渐变的容值参数序列, 动态、分阶段地改变平台工作状态, 从而模拟从健康状态到完全失效的全寿命周期退化过程。在此过程中, 利用高采样率数据采集系统同步实时捕获输出纹波电压、关键点电压和电流波形等多通道时序信号, 构建全面反映电源性能演化的退化特征数据集。

基于上述试验平台采集的输出纹波电压、关键节点电压和电流波形等多通道时序信号, 构建了不同退化状态下的开关电源退化特征数据集。该数据集用于后续 LMS-TCN 模型的训练与验证, 以评估模型在电解电容退化预测任务中的适用性。

**3.2 试验数据采集** 为了研究不同电容退化对于纹波电压变化的影响, 试验中设置不同的退化条件对电容进行退化注入, 并多次采集数据, 如表 1 所示。

表 1 退化注入试验条件

| 故障电容种类  | 初始容值/ $\mu\text{F}$ | 退化条件 | 额定电压/V | 退化注入电压/V | 温度/ $^{\circ}\text{C}$ |
|---------|---------------------|------|--------|----------|------------------------|
| LC 滤波电容 | 470                 | 正常   | 28     | 28       | 25                     |
|         |                     | 过压   | 28     | 36       | 25                     |
|         |                     | 高温   | 28     | 28       | 70                     |

针对 LC 滤波电容注入退化后所采集的试验数据如图 4 所示, 选取采样频率为 100 Hz, 采集获得其中交流分量中纹波电压进行数据分析。




图 4 LC 滤波电容退化试验数据

**3.3 模型训练策略与参数设置** 为确保 LMS-TCN 模型在开关电源退化预测中的精度与泛化能力, 采用以下训练策略和参数设置:

(1) 数据划分 针对每组退化试验数据, 按照时间顺序划分为训练集 (70%)、验证集 (15%) 和测试集

(15%)。验证集用于超参数优化和早停判断,测试集仅在最终评估时使用。

(2)超参数调优 采用贝叶斯优化算法对 LMS-TCN 模型关键超参数进行自动搜索,优化目标为验证集上的 Huber 损失函数。搜索范围包括:TCN 层数 {2, 3, 4, 5}、每层卷积核数 {32, 64, 128}、膨胀率组合 {[1, 2, 4, 1, 2, 4, 8, 1, 2, 4, 8, 16]}、Dropout 率 {0.05, 0.10, 0.20} 和初始学习率 {0.001, 0.005, 0.010}。最终确定的超参数为:TCN 层数为 4, 每层卷积核数为 64, 膨胀率为 [1, 2, 4, 8], Dropout 率为 0.10, 初始学习率为 0.001, 批大小为 32。

(3)损失函数 选用 Huber 损失函数( $\delta=1.0$ )作为优化目标。该损失函数结合了均方误差(mean squared error, MSE)在误差较小时的平滑性与平均绝对误差(mean absolute error, MAE)对异常值的鲁棒性,能够有效应对纹波电压信号中偶发的尖峰噪声,避免梯度剧烈波动。

(4)正则化与优化策略 除 Dropout 外,引入  $L_2$  正则化以抑制过拟合。此外,采用梯度裁剪策略,将梯度范数上限设定为 0.1,从而限制参数更新幅度并提升训练稳定性。优化器选用自适应矩估计(adaptive moment estimation, Adam)算法。

(5)早停机制 在训练过程中监控验证集损失,若连续 20 个 epoch 验证损失未下降,则停止训练并恢复至验证损失最低时的模型权重,以进一步抑制过拟合并减少不必要的计算开销。

## 4 试验结果分析

**4.1 LMS-TCN 模型预测结果展示** 为验证所提 LMS-TCN 模型在开关电源退化预测任务中的有效性和工程适用性,基于前述试验平台,采集了 3 组表征不同退化阶段的电源输出纹波电压时序数据。该纹波电压时序数据具有显著的非平稳性、强波动性和多频段耦合特征,信息复杂度高,对预测模型的表征与泛化能力提出了较高要求。每组数据均分别采用 LMS-TCN 模型、TCN 模型、LSTM、GRU 和 Transformer 进行训练与预测,并从预测精度、收敛效率和工程可行性等多个维度进行综合对比分析。

不同模型在相同试验条件下对纹波电压序列的预测结果对比(如图 5 所示),步长 0.01 s。从图 5 中可知,LMS-TCN 模型在不同退化条件下均能较好跟踪纹波电压的整体变化趋势,尤其在退化后期纹波电压波动增强、局部尖峰增多的阶段,仍能保持较高的预测一致性。这说明采用多尺度膨胀卷积能够有效兼顾局部突变信息与长期退化演化信息,避免了在复杂波形预测中出现局部平滑过度或峰值跟踪滞后问题。




图 5 3 种退化条件下 LC 滤波电容的纹波电压预测值与实际值对比

除定性对比外,进一步从绝对误差分布层面对 LMS-TCN 模型进行了分析。LMS-TCN 模型在 100 个连续时间步长上的预测绝对误差分布直方图,如图 6 所示。由图 6 可知,LMS-TCN 模型的绝对误差主要集中在较小误差区间,且大部分样本的绝对误差小于 0.006 V,表明该模型在不同退化条件下均能够较好地跟踪输出纹波电压的变化趋势,整体预测偏差较小,预测稳定性较好。

LMS-TCN 模型性能优异的主要原因在于 2 个方面:(1)膨胀率逐层递增的层级化设计扩大了模型对不同时间尺度信息的感受野,使其能够更充分地提取与退化相关的纹波电压特征;(2)Dropout 和早停机制抑制了小样本条件下的过拟合,使 LMS-TCN 模型在保证精度的同时减少了无效迭代次数,从而提高了训练效率。因此,LMS-TCN 模型不仅在预测结果上更接近真实退化过程,也更符合在线预测场景对效率与稳定性的要求。




图 6 3 种退化条件下 LMS-TCN 模型预测误差分布

**4.2 预测结果分析** LMS-TCN 模型、TCN 模型、LSTM、GRU、Transformer 的性能通过均方误差 (mean squared error, MSE)、平均绝对误差 (mean absolute error, MAE) 和决定系数 (coefficient of determination,  $R^2$ ) 进行衡量比较:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (19)$$

其中,  $y_i$  为归一化后的实际电容退化指标值,  $\hat{y}_i$  为预测值。

各模型在  $MSE$ 、 $MAE$  和  $R^2$  性能指标 (如表 2 所示) 用于评估预测值与实际值之间的偏差, 衡量预测模型对退化趋势预测的准确性与鲁棒性。

表 2 3 种退化条件下不同模型在的预测性能对比

| 退化条件 | 模型          | $MSE$    | $MAE$   | $R^2$   |
|------|-------------|----------|---------|---------|
| 正常退化 | LMS-TCN     | 0.000 12 | 0.002 0 | 0.987 9 |
|      | TCN         | 0.000 18 | 0.003 0 | 0.922 3 |
|      | LSTM        | 0.000 28 | 0.004 2 | 0.893 6 |
|      | GRU         | 0.000 26 | 0.003 5 | 0.897 8 |
|      | Transformer | 0.000 19 | 0.003 2 | 0.913 4 |
| 过压退化 | LMS-TCN     | 0.000 11 | 0.002 2 | 0.990 5 |
|      | TCN         | 0.000 16 | 0.002 7 | 0.914 9 |
|      | LSTM        | 0.000 24 | 0.003 1 | 0.920 2 |
|      | GRU         | 0.000 22 | 0.002 9 | 0.904 6 |
|      | Transformer | 0.000 20 | 0.002 6 | 0.938 8 |
| 高温退化 | LMS-TCN     | 0.000 10 | 0.002 4 | 0.984 9 |
|      | TCN         | 0.000 15 | 0.002 8 | 0.895 2 |
|      | LSTM        | 0.000 18 | 0.003 0 | 0.924 2 |
|      | GRU         | 0.000 16 | 0.003 2 | 0.905 6 |
|      | Transformer | 0.000 15 | 0.002 5 | 0.944 6 |

从表 2 中可以看出, LMS-TCN 模型在 3 种退化条件均取得了最优结果。尤其相较于 TCN 模型而言, LMS-TCN 模型在  $MSE$ 、 $MAE$  和  $R^2$  指标上均有提升, 经计算平均分别提升约 32.6%、22.4% 和 7.8%。这表明 LMS-TCN 模型不仅能够提高预测精度, 而且在不同退化条件下具有较好的适应性和稳定性。因

此, LMS-TCN 模型在正常退化、过压退化和高温退化条件中均保持较低的预测误差, 说明该模型对不同退化条件下的输出纹波电压变化具有一定适应性。

综合预测曲线、误差分布及评价指标结果可知, LMS-TCN 模型在 3 种退化条件下均表现出较优的预测性能, 验证了所提模型对输出纹波电压退化趋势的建模有效性。

**4.3 计算性能分析** 为评价 LMS-TCN 模型在在线监测场景中的工程适用性, 在边缘计算平台上对其计算性能进行测试。硬件平台采用 NVIDIA Jetson TX2, 其 CPU 为双核 Denver 2 和四核 ARM Cortex-A57, GPU 为 256 核 Pascal 架构, 内存容量为 8 GiB。软件环境配置为 PyTorch 1.10 和 CUDA 10.2。

将训练完成的 LMS-TCN 模型部署至 Jetson TX2, 并以长度为 1 000 个时间步的连续纹波电压序列作为输入进行推理测试。测试结果表明, LMS-TCN 模型单次前向传播的平均延迟为 4.2 ms, 对应推理吞吐量为  $238 \text{ 个样本} \cdot \text{s}^{-1}$ 。推理过程中监测到的 GPU 侧和 CPU 侧内存占用分别约为 185 和 120 MiB。

在线监测场景中, 若以 10 kHz 采样率采集纹波电压数据, 则 100 ms 时间窗口内对应 1 000 个采样点。本研究测试结果表明, LMS-TCN 模型完成单次推理的平均延迟为 4.2 ms, 远低于 100 ms 的评估时间窗口, 说明该模型能够满足在线状态评估对实时性的要求。

需要说明的是, Jetson TX2 属于边缘计算平台, 其计算资源高于常见微控制器。若将 LMS-TCN 模型进一步部署至资源更受限的平台, 仍可能面临存储空间和计算能力不足的问题。因此, 在后续应用中可结合知识蒸馏、模型剪枝或量化等方法进一步压缩模型规模, 以降低计算负载。总体来看, LMS-TCN 模型在 Jetson TX2 平台上的推理延迟和内存占用均处于较低水平, 具备应用于开关电源在线状态评估的潜力。

**4.4 基于预测结果的维护决策建议** 建立基于 LMS-TCN 模型预测结果的维护决策映射规则, 以便于模型输出能够直接指导现场维护。根据开关电源实际运行经验及电容失效机理, 将纹波电压的预测值划分为 3 个健康等级, 并给出相应的维护建议。

定义  $V_{pp}$  为实时监测的纹波电压峰值,  $V_{pp0}$  为系统健康基准下的初始纹波电压峰值。据此构建相对退化指标  $R$ , 其定义为

$$R = \frac{V_{pp}}{V_{pp0}} \quad (20)$$

基于历史试验的失效数据的统计分析, 设定 2 级预警阈值  $\theta_1 = 1.2$  和  $\theta_2 = 1.5$ 。利用模型预测未来时间窗口 100 个时间步内  $R$  的最大演化值  $\hat{R}_{\max}$ , 并依据以下准则进行健康状态分级与维护决策:

**健康状态** 若  $\hat{R}_{\max} < \theta_1$ , 表明设备处于正常运行区间, 判定为健康状态, 维持常规运行无需额外干预;

**注意状态** 若  $\theta_1 \leq \hat{R}_{\max} < \theta_2$ , 表明性能出现轻微退化趋势, 判定为注意状态, 建议纳入近期检修计划并进行重点监测;

**警告状态** 若  $\hat{R}_{\max} \geq \theta_2$ , 表明设备已接近或达到失效临界点, 判定为警告状态, 建议立即执行停机检修或组件更换程序, 以防故障发生。

为分析 LMS-TCN 模型在预测过程中的关注区域, 对正常退化样本的预测结果及对应注意力权重进行可视化, 结果如图 7 所示。图 7a 给出了纹波电压幅值预测结果, 图 7b 给出了对应时间步的注意力权重分布。从图 7 可以看出, LMS-TCN 模




图 7 LC 滤波电容正常退化预测结果与注意力权重分布

型在纹波电压波形变化较为明显的区段赋予了较高权重,说明其能够在一定程度上自动聚焦于与退化演化相关的关键时段。通过“预测结果+关注区段解释”的方式,LMS-TCN 模型可为开关电源预测性维护提供了更具可理解性的辅助依据。

## 5 结 论

针对开关电源退化预测中纹波电压信号多时间尺度耦合、样本规模有限以及在线应用对训练效率和部署性能要求较高等问题,提出了一种轻量多尺度时间卷积网络(LMS-TCN)模型。该模型通过采用膨胀率逐层递增的层级化设计并构建因果卷积残差结构,实现了对开关瞬态局部扰动与电容老化长期演化趋势的协同建模;同时结合 Dropout 正则化、Huber 损失函数、梯度裁剪和早停机制,提高了模型在复杂噪声环境下的训练稳定性与泛化能力。基于所搭建的电容退化试验平台,在正常退化条件、过压退化条件和高温退化条件三组数据上开展了退化预测验证。试验结果表明,与 TCN、LSTM、GRU 和 Transformer 模型相比,所提 LMS-TCN 模型在  $MSE$ 、 $MAE$  和  $R^2$  等评价指标上整体表现更优,能够较好地表征开关电源输出纹波电压随电容退化的变化趋势。进一步的 Jetson TX2 边缘计算平台测试结果表明,该模型具有较低的单次推理延迟和内存占用,具备应用于开关电源在线状态评估的潜力。

## 参考文献:

- [1] MATTOS E, ANDRADE A M S S, HOLLWEG G V, et al. A review of boost converter analysis and design in aerospace applications[J]. *IEEE Latin America Transactions*, 2018, 16(2): 305–313.
- [2] WANG H, BLAABJERG F. Reliability of capacitors for DC-link applications in power electronic converters—an overview[J]. *IEEE Transactions on Industry Applications*, 2014, 50(5): 3569–3578.
- [3] LAHYANI A, VENET P, GRELLLET G, et al. Failure prediction of electrolytic capacitors during operation of a switchmode power supply[J]. *IEEE Transactions on Power Electronics*, 1998, 13(6): 1199–1207.
- [4] CHEN Y M, WU H C, CHOU M W, et al. Online failure prediction of the electrolytic capacitor for LC filter of switching-mode power converters[J]. *IEEE Transactions on Industrial Electronics*, 2008, 55(1): 400–406.
- [5] Prasanth S, Sathik M H M, Sasongko F, et al. Online equivalent series resistance estimation method for condition monitoring of DC-link capacitors[C]//2017 IEEE energy conversion congress and exposition (ECCE). Cincinnati: IEEE, 2017: 1773–1780. doi:10.1109/ECCE.2017.8096009.
- [6] ZHU X L, ZHANG D L, LI A S, et al. An online noninvasive monitoring technique for the ESR of an output capacitor in switched-mode power supplies[J]. *IEEE Transactions on Power Electronics*, 2024, 39(11): 15045–15055.
- [7] LIU K L, SHANG Y L, OUYANG Q, et al. A data-driven approach with uncertainty quantification for predicting future capacities and remaining useful life of lithium-ion battery[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(4): 3170–3180.
- [8] CHANG Y, FANG H J, ZHANG Y. A new hybrid method for the prediction of the remaining useful life of a lithium-ion battery[J]. *Applied Energy*, 2017, 206: 1564–1578.
- [9] NUHIC A, TERZIMEHIC T, SOCZKA-GUTH T, et al. Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods[J]. *Journal of Power Sources*, 2013, 239: 680–688.
- [10] LIU H, LIU Z Y, JIA W Q, et al. Remaining useful life prediction using a novel feature-attention-based end-to-end approach[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(2): 1197–1207.
- [11] KLASS V, BEHM M, LINDBERGH G. A support vector machine-based state-of-health estimation method for lithium-ion batteries under electric vehicle operation[J]. *Journal of Power Sources*, 2014, 270: 262–272.
- [12] DRISCOLL L, DE LA TORRE S, GOMEZ-RUIZ J A. Feature-based lithium-ion battery state of health estimation with artificial neural networks[J]. *Journal of Energy Storage*, 2022, 50: 104584.

- [13] WANG C S, LU N Y, WANG S L, et al. Dynamic long short-term memory neural-network-based indirect remaining-useful-life prognosis for satellite lithium-ion battery[J]. *Applied Sciences*, 2018, 8(11): 2078.
- [14] XU H W, WU L F, XIONG S Z, et al. An improved CNN-LSTM model-based state-of-health estimation approach for lithium-ion batteries[J]. *Energy*, 2023, 276: 127585.
- [15] KHUMPRON P, YODO N. A data-driven predictive prognostic model for lithium-ion batteries based on a deep learning algorithm[J]. *Energies*, 2019, 12(4): 660.
- [16] Gopali S, Abri F, Siami-Namini S, et al. A comparison of TCN and LSTM models in detecting anomalies in time series data[C]//2021 IEEE international conference on big data (big data). Orlando: IEEE, 2021: 2415–2420. doi:10.1109/BigData52589.2021.9671488.
- [17] HEWAGE P, BEHERA A, TROVATI M, et al. Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station[J]. *Soft Computing*, 2020, 24(21): 16453–16482.
- [18] Olschewski J, Hoppe M, Kusmenko E, et al. Machine learning-based condition monitoring from power cycling data for silicon carbide power inverter modules[C]//2025 IEEE international reliability physics symposium (IRPS). Monterey: IEEE, 2025: 1–6. doi:10.1109/IRPS48204.2025.10983172.
- [19] LIN L, WU J L, FU S, et al. Channel attention & temporal attention based temporal convolutional network: a dual attention framework for remaining useful life prediction of the aircraft engines[J]. *Advanced Engineering Informatics*, 2024, 60: 102372.
- [20] XIAO Y M, SHAO H D, ZHANG H M, et al. Uncertainty-aware deep variational attention network: a trustworthy mechanical fault diagnostic model assisted by out-of-distribution detection[J]. *Engineering Applications of Artificial Intelligence*, 2025, 157: 111386.
- [21] ZHONG H Y, LYU Y, YUAN R, et al. Bearing fault diagnosis using transfer learning and self-attention ensemble lightweight convolutional neural network[J]. *Neurocomputing*, 2022, 501: 765–777.
- [22] FAN J, ZHANG K, HUANG Y P, et al. Parallel spatio-temporal attention-based TCN for multivariate time series prediction[J]. *Neural Computing and Applications*, 2023, 35(18): 13109–13118.
- [23] 王昊. DC-DC 开关电源寿命预测与预警技术研究 [D]. 成都: 电子科技大学, 2021. doi:10.27005/d.cnki.gdzku.2021.000521.
- Wang H. Research on life prediction and Early warning technology of DC-DC switching power supply[D]. Chengdu: University of Electronic Science and Technology of China, 2021. doi:10.27005/d.cnki.gdzku.2021.000521.
- [24] 汪亮, 熊剑, 张益舟, 等. 基于器件老化特性的开关电源寿命预测方法 [J]. 电子元器件与信息技术, 2025, 9(8): 10–14. doi:10.19772/j.cnki.2096-4455.2025.08.004.
- Wang L, Xiong J, Zhang Y Z, et al. Life prediction method of switching power supply based on device aging characteristics[J]. *Electronic Components and Information Technology*, 2025, 9(8): 10–14. doi:10.19772/j.cnki.2096-4455.2025.08.004. (查阅网上资料, 未找到本条文献的英文翻译信息, 请确认)

## 作者贡献声明

蔡宜伦负责研究构思与设计、数据收集与处理、论文撰写。周兴飞负责数据分析与解释、论文修改。张润芝负责协助数据分析, 润色论文。张育玮负责评审与修改。王兴坚负责经费与资源支持、指导与监督。全体作者均参与结果讨论。

## 利益冲突声明

作者声明, 其不存在已知的可能影响本论文所报告工作的竞争性经济利益或个人关系。

## AI 使用声明

本文未使用人工智能(AI)协助撰写。

## 伦理声明

不适用: 本文不涉及人类或动物的生物学研究。

## 电子补充材料

补充材料可在本文的在线版本中获取。

## 数据可用性

支持论文结论所需的所有数据均已包含在稿件或电子补充材料中。如需获取与本文相关的其他数据,可向通信作者提出申请。

## 作者简介

蔡宜伦(1997—),女,陕西西安人,北京宇航系统工程研究所工程师,研究方向:机械工程,健康管理与预测,视情维修。E-mail: [caiyl627@163.com](mailto:caiyl627@163.com)。

周兴飞(2002—),男,山西太原人,北京航空航天大学机械工程 2025 级博士研究生,研究方向:故障诊断,容错控制。E-mail: [zxf20375145@buaa.edu.cn](mailto:zxf20375145@buaa.edu.cn)。

张润芝(1999—),女,河南郑州人,北京航空航天大学机械工程 2024 级博士研究生,研究方向:机械工程,健康管理与预测,故障诊断,视情维修。E-mail: [rzzhang@buaa.edu.cn](mailto:rzzhang@buaa.edu.cn)。

张育玮(1994—),男,山西长治人,副教授,硕士生导师,研究方向:机电系统非线性控制,容错控制,无人系统运动控制,集群控制。E-mail: [zhangyuwei@buaa.edu.cn](mailto:zhangyuwei@buaa.edu.cn)。

王兴坚(1983—),男,浙江绍兴人,教授,博士生导师,研究方向:非线性控制、健康管理、容错控制和仿生机器人。E-mail: [wangxj@buaa.edu.cn](mailto:wangxj@buaa.edu.cn)。

(责任编辑:高 喆)



This is an open access article under the terms of the Creative Commons Attribution 4.0 International License (CC BY 4.0, <https://creativecommons.org/licenses/by/4.0/>).

© The Author(s) 2026. Published by Journal Editorial Department of Hainan University.