

DOI: 10.19783/j.cnki.pspc.250075

基于深度残差网络和改进时序卷积神经网络的宽频振荡监测

赵妍¹, 吴昊鑫¹, 赵宗罗², 陈运², 周波², 李强强²

(1. 东北电力大学电气工程学院, 吉林 吉林 132012; 2. 国网浙江省电力有限公司杭州市富阳区供电公司, 浙江 杭州 310000)

摘要: 宽频振荡严重威胁电网安全稳定运行。为此, 提出一种基于深度残差网络(residual network, ResNet)和改进的时序卷积神经网络(improved temporal convolutional network, ITCN)的宽频振荡监测方法。首先, 利用 ResNet 结构对宽频振荡信号在时间上进行卷积, 滑动捕捉时间序列的相邻局部特征, 通过残差块的堆叠实现振荡信号多尺度特征的压缩提取。然后, 利用 ITCN 结构通过膨胀因果卷积对压缩特征进行扩展, 在保证计算效率的同时逐层引入较大的感受野, 进一步提取时间序列中蕴含的中长期依赖特性, 两者结合实现了对全局特征的提取。最后, 在 TCN 结构中嵌入注意力机制(Attention), 对信号中重要特征进行加权分配, 更好地捕捉全局模式和长期依赖特性。仿真和实测结果验证了 ResNet-ITCN 模型可以出色地完成宽频振荡参数检测任务并且对振荡类型进行识别, 实现了对宽频振荡的监测。

关键词: 宽频振荡; 深度残差网络; 改进时序卷积神经网络; 注意力机制; 滑窗监测

Wideband oscillation monitoring based on deep residual network and improved temporal convolutional neural network

ZHAO Yan¹, WU Haoxin¹, ZHAO Zongluo², CHEN Yun², ZHOU Bo², LI Qiangqiang²

(1. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China; 2. State Grid Zhejiang Electric Power Co., Ltd., Hangzhou Fuyang District Power Supply Company, Hangzhou 310000, China)

Abstract: Wideband oscillations pose severe threat to the safe and stable operation of power systems. To address this issue, a wideband oscillation monitoring method based on deep residual network (ResNet) and improved temporal convolutional neural network (ITCN) is proposed. First, the ResNet structure is used to convolve wideband oscillation signals, capturing adjacent local features of the time series through sliding windows. The multi-scale features of the oscillation signals are extracted and compressed by stacking the residual blocks. Then, the ITCN structure applies dilated causal convolutions to expand the compressed features, introducing progressively larger receptive fields while maintaining computational efficiency. This enables further extraction of medium- and long-term dependencies in the time series, and the combination of both networks facilitates comprehensive global feature extraction. Finally, an attention mechanism is embedded into the TCN structure to assign adaptive weights to important signal features, thereby improving the capture of global patterns and long-term dependencies. Simulation and real-world measurements verify that the ResNet-ITCN model can successfully detect wideband oscillation parameters and identify oscillation types, achieving effective wideband oscillation monitoring.

This work is supported by the National Natural Science Foundation of China (No. U24B2084).

Key words: wideband oscillation; deep residual network; improved temporal convolutional neural network; attention mechanism; sliding-window monitoring

0 引言

进入 21 世纪以来, 随着“双碳”目标和新型电

力系统的相继提出, 电力系统的电力电子化程度日益增长^[1], 海量的电力电子设备与电网交互使电力系统的动态响应具有了非线性和强耦合性特征, 电力系统易出现宽频振荡现象, 严重威胁电网安全稳定运行^[2-4]。世界各地频繁出现宽频振荡事件。例如, 我国沽源地区风电场发生 3~10 Hz 的类低频振荡事

基金项目: 国家自然科学基金项目资助(U24B2084); 国网浙江省电力有限公司科技项目资助(5211HZ240001)

件^[5]; 新疆哈密直驱风电机组与弱交流电网相互作用, 在电流中出现次/超互补分量^[6]; 欧洲北海海上风电项目出现 100~1000 Hz 中高频振荡^[7-8]。

电力系统本身是复杂的非线性系统, 而电力电子设备的应用进一步增强了系统的非线性。在此背景下, 含有多电力电子设备的大规模互联电网, 其宽频振荡动态过程无法被简单地视为各子系统振荡的线性叠加, 而是不同时间尺度问题相互作用、相互耦合的结果。宽频振荡具有频率范围、幅频时变的特点^[9-12], 这就给宽频振荡信号的监测带来了巨大的挑战。

宽频振荡监测包括监测是否发生低频、次/超、中高频振荡。发生振荡时应能触发告警, 同时启动录波, 并将振荡的频率、幅值或衰减因子等参数上传到主站。根据识别的振荡类型和参数, 结合系统的具体情况, 分析振荡发生的原因, 预测振荡的发展趋势, 从源、网两侧出发提出针对性的抑制措施, 提升系统的稳定性。

目前宽频振荡监测方法主要包括传统算法和人工智能算法两类。传统算法以信号处理类算法为代表, 由于单一的信号处理方法很难对宽频振荡复杂的非线性、强耦合特征进行准确处理, 因此多采用组合方法。例如, 变分模态分解法和最小二乘旋转不变技术结合^[13]、加 RV-M 阶窗函数的插值离散傅里叶变换(discrete Fourier transform, DFT)方法^[14-15]、小波变换和傅里叶变换(fast Fourier transform, FFT)结合^[16]、小波去噪与扩展 Prony 结合^[17]、同步压缩广义 S 变换和改进稀疏时域法结合^[18]。传统算法能对单一类型的振荡实现较为准确的监测, 但是很难适用于其他振荡类型, 普适性差。且上述算法均存在定阶困难、计算复杂和抗噪性差的问题, 在实际应用时需要改进内核或与其他算法相结合^[19], 不适用于宽频振荡信号的监测。

目前人工智能算法在该领域的应用主要以机器学习为主, 包括支持向量机(support vector machine, SVM)、朴素贝叶斯(naive bayes, NB)、k-邻近算法(k-nearest neighbor, KNN)、决策树类等。机器学习模型简单, 可解释性强, 依赖特征工程, 因此多采用与传统方法相结合, 以互补处理宽频振荡问题。文献[20]对同步相量测量单元(synchrophasor measurement unit, PMU)测量的数据提取 3 个能反映次同步振荡和干扰水平的特征, 根据特征采用 SVM 自适应地选择分类器, 提高了实际电网在低、高干扰输入下的参数检测精度, 但无法实现振荡模态的全局监测, 且处理时间较长。文献[21]采用同步提取变换(synchroextracting transform, SET)结合希尔伯特变

换检测次同步振荡模态参数, 利用 NB 实现次同步振荡在线预警。SET 辨识衰减因子误差较大, NB 对于噪声较为敏感且对非线性的适应能力差。文献[22]利用对角化低密度奇偶校验码对子站数据提取压缩特征, 极大地减少了宽频振荡的数据传输量, 使用 KNN 进行振荡监测。但 KNN 依赖于每个样本与所有数据点的距离, 因此在大数据集监测中, KNN 的计算负担较重, 对硬件的要求较高。传统机器学习完成振荡监测任务需要结合特征工程。人工设计的特征需要利用领域知识, 很难全面反映振荡的复杂特性, 制约了模型性能。而且大部分传统机器学习模型只能处理简单的非线性关系, 若使用该方法扩展到高维空间处理非线性问题, 会使计算复杂度急剧上升。

深度学习是近年来备受关注的算法, 其核心在于神经网络的应用, 相比于机器学习可自动提取特征, 具有处理高维非线性问题的能力。深度学习算法根据其结构不同, 侧重于对不同类型问题进行处理。将深度学习算法进行组合, 形成一个端到端的处理框架, 不需要人工特征提取, 更适用于非线性、非平稳、强耦合特征的宽频振荡信号监测。文献[23]将卷积神经网络(convolutional neural network, CNN)与注意力机制相结合, 利用 CNN 提取局部特征的优势和注意力机制对通道特征自适应的特点, 成功从主站 PMU 的同步相量数据中检测出次/超同步振荡的模态参数。文献[24]利用自编码器的数据压缩与解码能力, 实现宽频振荡信号从子站到主站的传输, 并结合长短记忆神经网络(long short-term memory, LSTM)完成宽频振荡的广域定位。文献[25]利用格拉姆角差场(Gramian angular difference field, GADF)的二维特征图提取宽频振荡信号的时频特征, 然后采用 CNN 完成振荡类型的识别。上述深度学习算法, CNN 擅长提取局部空间特征, 能有效捕捉宽频振荡中的非平稳特征, 但网络层数较少, 对于复杂的振荡信号深层特征提取不充分, 另外对信号全局信息的理解能力差, 对于具有强时间依赖性的宽频振荡时序信号特征提取不理想。LSTM 在处理长时间序列时性能会变差, 计算复杂度高, 需要更多的参数和计算量, 增加了训练的难度和时间。

基于此, 本文提出一种基于深度残差网络和改进时序卷积神经网络的宽频振荡组合监测模型。首先, 利用 ResNet 网络实现对宽频振荡信号多尺度特征的压缩提取, 在兼顾振荡的底层通用特征的基础上, 提取更深层次的细节特征, 实现对宽频振荡特征的准确表示。然后, 在 TCN 结构中嵌入注意力机制(Attention), 得到改进时序卷积神经网络(improved

temporal convolutional network, ITCN), 利用 ITCN 结构通过膨胀因果卷积, 对 ResNet 输出的压缩特征进行扩展, 在保证计算效率的同时逐层引入较大的感受野, 进一步提取时间序列中蕴含的中长期依赖特性, 两者结合实现了对全局特征的提取。最后, Attention 增强了模型对关键振荡特征的表达能力, 精准捕捉信号中的细微变化和动态模式, 使 ITCN 结构能够出色地完成宽频振荡参数检测任务并且对振荡类型进行识别, 最终实现对宽频振荡信号的监测。

1 基本理论

1.1 深度残差网络

深度残差网络(ResNet)是在 2015 年提出的一种深度卷积神经网络架构, 其基本单元是残差块(residual block), 残差块的结构见图 1。

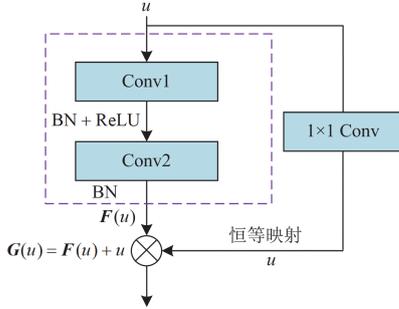


图 1 残差块结构

Fig. 1 Residual block structure

在图 1 中, 传统的神经网络直接拟合输入到输出的映射, 而 ResNet 的残差块通过引入跳跃连接的方式, 在主路卷积层的旁边新增一条分支卷积层, 即 1×1 的卷积, 来实现恒等映射。恒等映射后残差块的输出为 $G(u)$ 。恒等映射通道为神经网络反向传播提供了更直接的路径, 这种直接的梯度传播路径有助于避免梯度消失或爆炸的问题, 并使得网络的训练更加稳定^[26]。

本文使用 ResNet-18 网络模型来处理宽频振荡数据, 使用了 8 个残差块叠加而成, 具体的结构和参数如图 2 所示。

在图 2 中, ResNet-18 的主体由 4 个 Layer 构成, 每个 Layer 包含 2 个残差块, 每个残差块均通过主路卷积层和分支卷积层相连。

ResNet 通过残差块的堆叠增加模型的深度, 利用较深的结构提取信号中的深层局部特征。通过层间跳跃的连接方式将底层的通用特征直接映射到高层, 使得网络可以同时学习不同层次的特征, 有助于捕捉数据的多尺度特征。结构中的最大池化层(Max pool)突出信号的重要特征, 并减少输入的维度。

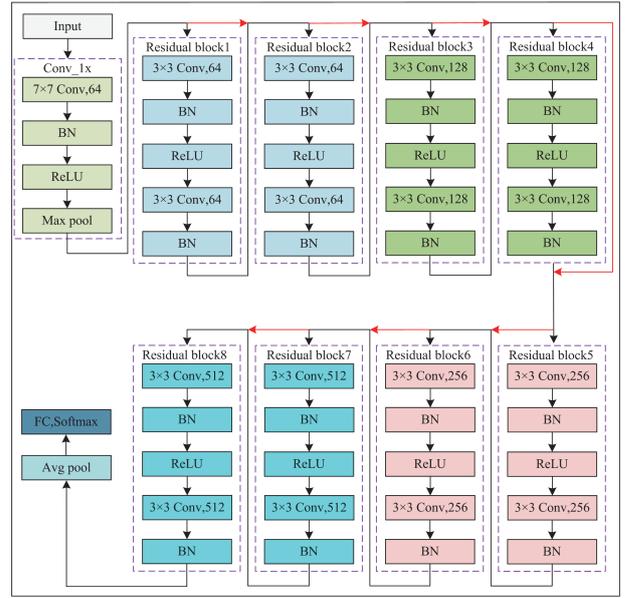


图 2 ResNet-18 结构图

Fig. 2 ResNet-18 structure diagram

平均池化层(Avg pool)保留平均化的总体特征, 避免特征丢失, 同时有助于去除噪声。

每个卷积核层后面的批归一化层(batch normalization, BN)用于有效地加速神经网络的训练, 提高训练的稳定性, 如式(1)所示。

$$y_h = \gamma \frac{x_h - \frac{1}{m} \sum_{h=1}^m x_h}{\sqrt{\frac{1}{m} \sum_{h=1}^m (x_h - \frac{1}{m} \sum_{h=1}^m x_h)^2 + \varepsilon}} + \beta \quad (1)$$

式中: x_h 为第 h 个输入特征值; m 为输入特征值的数量; ε 为一很小正数, 防止分母为 0; γ 为缩放系数; β 为平移系数; y_h 为经过批归一化层的输出特征值。

修正线性单元(rectified linear unit, ReLU)层在 BN 层后面, 激活函数的定义为

$$\text{ReLU}(x) = \max(0, x) \quad (2)$$

式中: x 为输入 ReLU 层的特征值。

激活函数使得每层的 Layer 输出信号的值都大于等于 0, 引入非线性避免梯度消失, 从而使模型能够学习宽频振荡信号中复杂的非线性特征。

ResNet 网络经过上述结构可以实现对宽频振荡信号多尺度特征的压缩提取, 同时引入非线性使其更好地适应宽频振荡信号。

1.2 改进的时序神经网络

时序卷积神经网络(temporal convolutional network, TCN)是 CNN 的变体, 通过多堆栈膨胀因果卷积来获取时间序列中的局部特征和长期依赖关

系, 常用于处理时间序列和序列建模任务。本节对 TCN 进行改进, 在其膨胀因果卷积后添加了 Attention 层, 下文将改进 TCN 模型结构简写为 ITCN。ITCN 结构如图 3 所示。

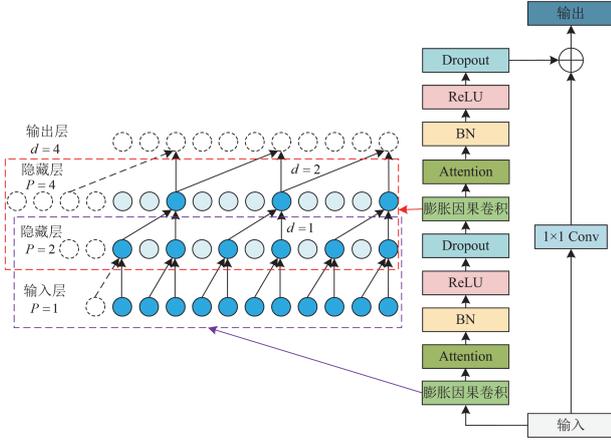


图 3 ITCN 结构图

Fig. 3 ITCN structure diagram

在图 3 中, ITCN 的结构主要包括膨胀因果卷积、Attention 层、批归一化层(BN)、修正线性单元(ReLU)、随机失活(Dropout)。 d 为膨胀系数, P 为填充。其中最核心的是膨胀因果卷积, 按其作用分为膨胀卷积和因果卷积。

膨胀卷积: 在每层的卷积运算中引入膨胀系数, 从而在保持参数数量不变的情况下, 使得每层滤波器可获得更大的感受野, 提取的空间特征更加准确^[27]。

因果卷积: 通过在卷积操作中加入填充(P)确保输出的当前时间步依赖于当前及之前的输入。

ITCN 是在其内部的膨胀因果卷积后添加了注意力机制, 即 Attention 层。Attention 的核心思想是根据输入数据的重要性来进行加权计算, 图 4 为 Attention 结构图。

首先, 计算输入信号的注意力权重。

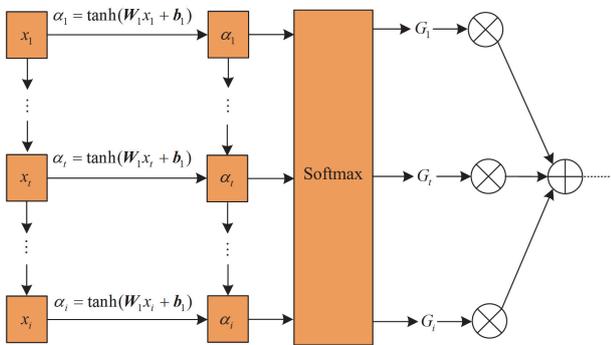


图 4 Attention 结构图

Fig. 4 Attention structure diagram

$$\alpha_i = \tanh(W_1 x_i + b_1) \quad (3)$$

式中: x_i 表示第 i 个输入特征; α_i 表示第 i 个输入特征的注意力权重; W_1 、 b_1 分别为权重和偏置矩阵。

对所有输入特征的注意力权重进行 Softmax 权重分配, 得到新的权重 G_i 为

$$G_i = \frac{\exp(\alpha_i)}{\sum_{i=1}^N \exp(\alpha_i)} \quad (4)$$

式中: N 表示输入特征的数量。

将输入特征 x_i 与新的权重 G_i 相乘, 得到

$$Z = \sum_{i=1}^N G_i x_i \quad (5)$$

式中: Z 表示输出结果。

通过加权输出, 使得模型的输出集中在最重要的一些特征上, 即输入信号的关键部分。根据其目标(如频率、幅值或衰减因子)的重要性得到不同的权重, 这样模型可以自动关注最相关的部分。

ITCN 结构中同样用到了分支卷积层来实现恒等映射, 与之前 ResNet 的分支卷积层共同配合, 使得模型经过多层卷积仍能保持较好的性能。

1.3 归一化和反归一化

宽频振荡检测任务通常涉及多种不同振荡模态分量, 特征数据(特征频率、幅值)可能跨越多个数量级。对输入数据进行归一化处理, 防止某些特征在训练过程中占据主导地位, 影响对全局特征的关注。本文采用的 Min-Max 表示为

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (6)$$

式中: X 为原始数据; X' 为归一化后的数据; X_{\max} 和 X_{\min} 分别为特征值的最大、最小值。

输出特征的反归一化如式(7)所示。

$$y = y' \times (X'_{\max} - X'_{\min}) + X'_{\min} \quad (7)$$

式中: y' 为模型预测后的归一化结果; y 为反归一化后的数据; X'_{\max} 和 X'_{\min} 分别为归一化时的最大、最小值。

1.4 ResNet-ITCN 模型结构

ResNet-ITCN 模型结构图如图 5 所示。

1) 将宽频振荡信号(节点电压、支路电流或有功功率等)按照式(6)进行归一化。

2) 归一化结果输入到 ResNet-ITCN 模型中, 通过 ResNet 网络实现对宽频振荡信号多尺度特征的压缩提取。通过 ITCN 网络在提取时间序列中长期依赖特性的同时, 对信号中重要特征进行加权分配。

3) 输出后的信号按照式(7)反归一化到原始尺度, 输出频率幅值或衰减因子, 完成参数检测任务,

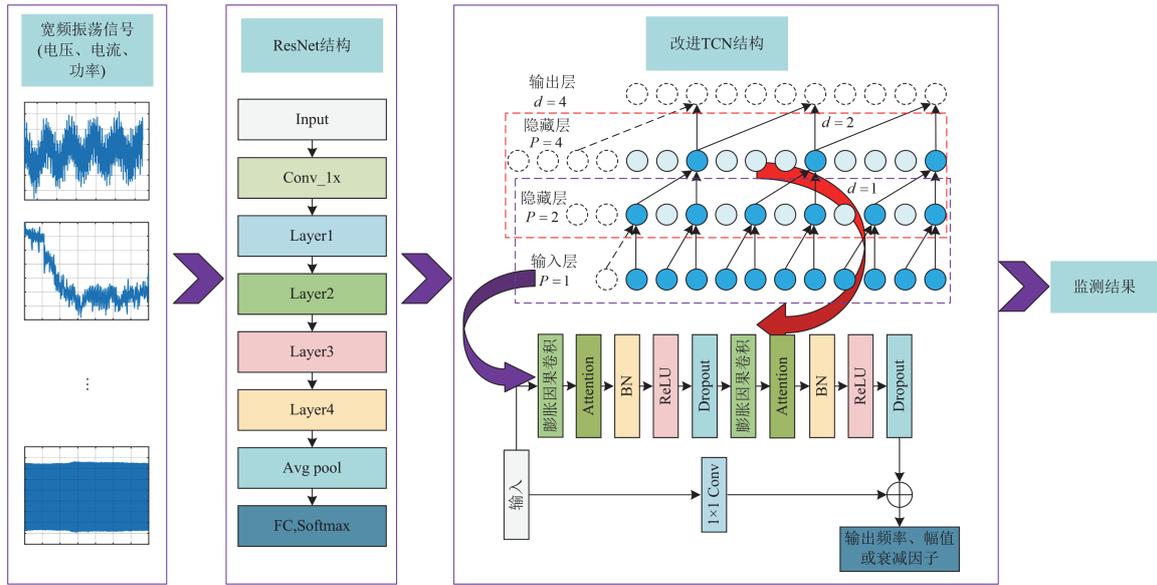


图 5 ResNet-ITCN 结构图

Fig. 5 ResNet-ITCN structure diagram

并且对振荡类型进行识别,实现对宽频振荡的监测。

1.5 宽频振荡监测流程图

监测流程如图 6 所示。

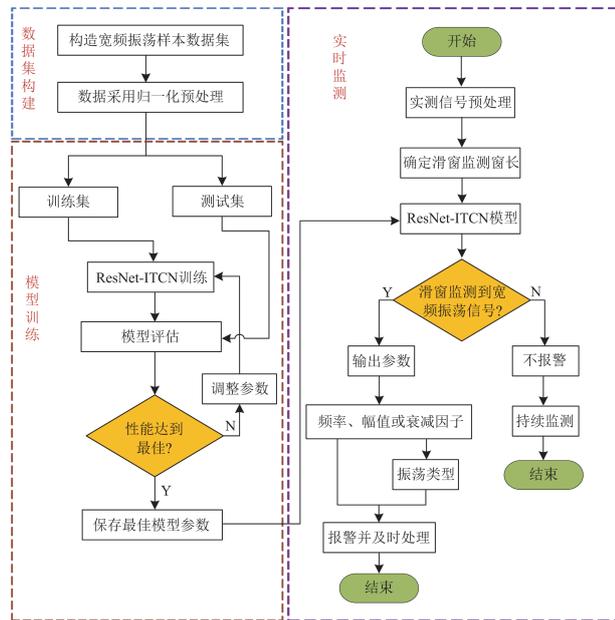


图 6 ResNet-ITCN 宽频振荡监测流程图

Fig. 6 ResNet-ITCN wide-frequency oscillation monitoring flow chart

本流程图分为 3 个部分,分别为样本数据集构建、模型训练及实时监测。核心为实时监测模块。具体为:对采集到的实测电力信号进行预处理(电流、电压、有功功率等),将其送入训练好的模型进

行滑窗监测。ResNet-ITCN 对振荡信号进行参数检测并且识别振荡类型。当滑窗监测到振荡信号时,输出频率、幅值或衰减因子,进行告警处理并采取干预措施;若未监测到宽频振荡信号,则继续持续监测。

2 算例验证

2.1 样本数据集来源

样本数据集来源包括:现场已获得的历史宽频振荡数据和仿真信号构造数据。本文所用的仿真构造数据由多个振荡模态叠加而成。采样频率为 12.8 kHz,其中幅值取值为 1~100 p.u.,衰减因子取值为-1~1 p.u.,频率取值为 0.1~2500 Hz,覆盖低频、次/超、中高频振荡,各个频段的模态信号随机组合得到宽频振荡信号,低频段输出频率和衰减因子,其余频段输出频率和幅值。在上述样本集中,随机抽取 3000 条数据构成数据集。

将训练集和测试集按照 8:2 的比例进行划分,送入 ResNet-ITCN 模型中进行训练。模型的学习率设为 0.001,正则化权重系数为 0.001,优化器采用 AdamW,训练轮次为 200 轮,损失函数使用面对异常值保持稳定的 Huber 损失函数。

2.2 模型评估结果

选用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、决定系数(R^2) 3 个指标来评估模型的性能。ResNet-ITCN 模型的参数监测评估效果如表 1 所示。

表 1 评估结果

Table 1 Evaluation result

评估指标	评估结果			
	幅值	频率	衰减因子	综合
MAE	1.281	1.328	0.028	0.768
RMSE	1.506	2.385	0.035	1.785
R^2	0.995	0.998	0.996	0.997

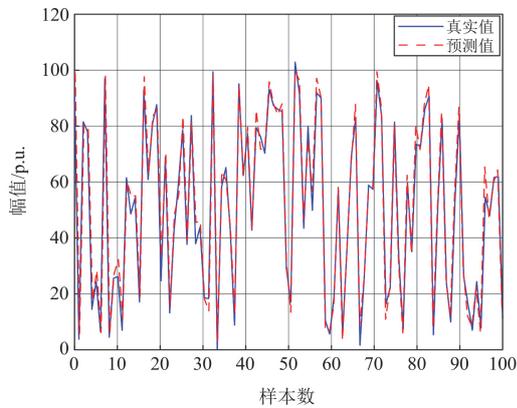
根据表 1 可以看出, 除频率的 RMSE 略高外, 其余指标均符合要求, 特别是 R^2 接近 1, 说明本文模型对于此回归问题的拟合性较好, 在中高频频段内由于频率数值较大造成 RMSE 略高。

为了验证预测的幅值、频率和衰减因子是否达到预期效果, 本文随机抽取 100 条数据, 分别对其幅值、频率和衰减因子的真实值和预测值生成曲线, 如图 7 所示。

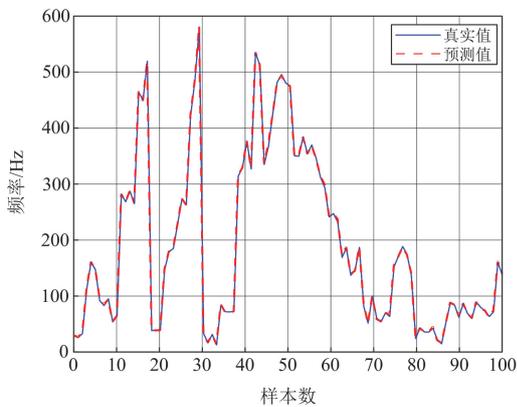
由图 7 可以看出, 经过本文模型预测的频率值基本与真实值一致, 幅值和衰减因子个别有偏差但仍允许在范围内。

2.3 振荡类型识别结果评估

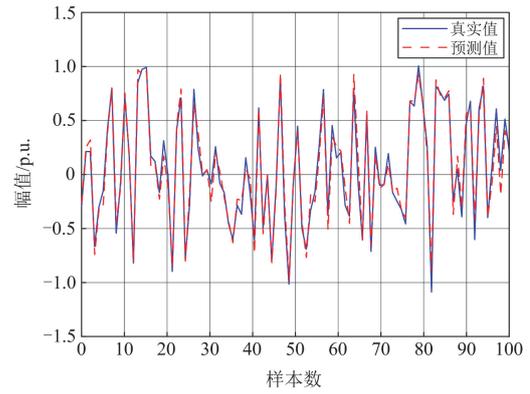
在 ResNet-ITCN 模型最后加一个频率分析模块, 用来判断测试集中预测的 600 条信号识别的振荡类型是否与仿真的 600 条信号的已知振荡类型一



(a) 幅值真实值与预测值



(b) 频率真实值与预测值



(c) 衰减因子真实值与预测值

图 7 真实值与预测值曲线

Fig. 7 Curves of true and predicted values

致, 标签的设置如表 2 所示。振荡类型的判断结果准确率如图 8 所示。

表 2 标签设置

Table 2 Label settings

标签名称	振荡类型	频率范围/Hz
1	低频振荡	0.1~2.5
2	次同步振荡	2.5~45
3	超同步振荡	55~95
4	中高频振荡	100~2500

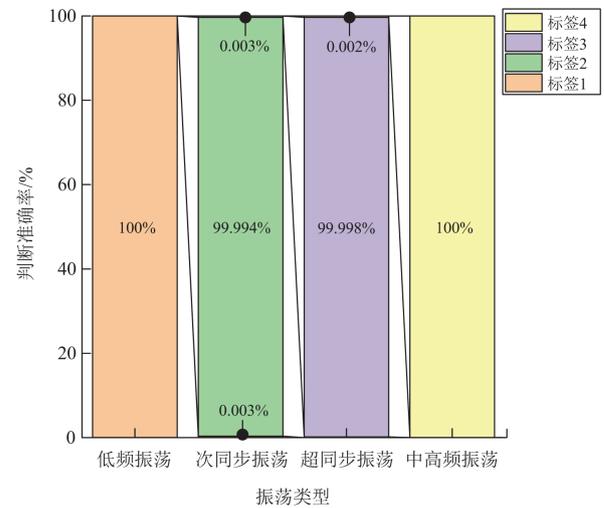


图 8 各振荡类型判断结果准确率

Fig. 8 Accuracy of judgment results for each oscillation type

2.4 对比实验

2.4.1 ResNet 和 CNN 特征提取对比

本文 ResNet 模块采用 1 层 Conv_1x 和 4 层 Layer。随机抽取一条宽频振荡信号作为输入信号, 然后对 Conv_1x 和每层 Layer 的输出信号分别进行 FFT 分析。图 9 为输入信号, 图 10 和图 11 分别为

Conv_1x 层信号及 FFT 分析和每层 Layer 输出信号的 FFT 分析。

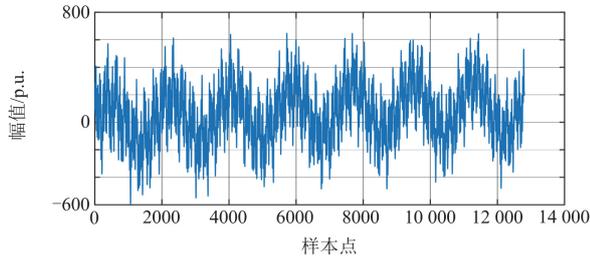


图 9 输入信号
Fig. 9 Input signal

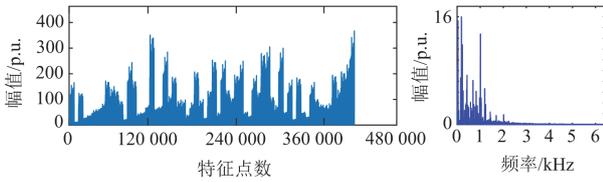


图 10 Conv_1x 层信号及 FFT 分析
Fig. 10 Conv_1x layer signal and FFT analysis

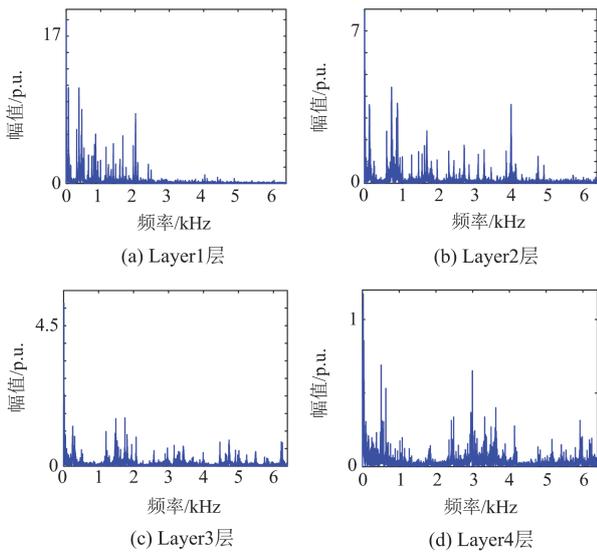


图 11 ResNet 每层输出的 FFT 分析

Fig. 11 FFT analysis of ResNet output at each layer

结合图 9、图 10 和图 11，输入信号首先在时间轴上经过 Conv_1x，滑动提取振荡信号的局部特征，这一层的输出是振荡模式中能量较强的底层中低频通用特征。然后经过 ResNet 的 4 层 Layer，进一步提取其深层细节特征。因此，每个 Layer 层输出的频率成分越来越丰富，幅值越来越小。经过 Layer 层提取到更多的、能量相对较弱的中高频细节特征。同时，残差块的层间跳跃连接方式将 Conv_1x 获得的底层通用特征直接映射到 Layer1—Layer4。到

Layer4 时，模型同时学习到底层的通用特征和深层的细节特征，完成了对振荡信号的多分辨率分析，实现了振荡特征的准确表示。

图 12 为 CNN 每个 Layer 层输出信号的 FFT 分析结果。CNN 层数与 ResNet 层数一致，其核心区别在于移除了 ResNet 中的跳跃连接。

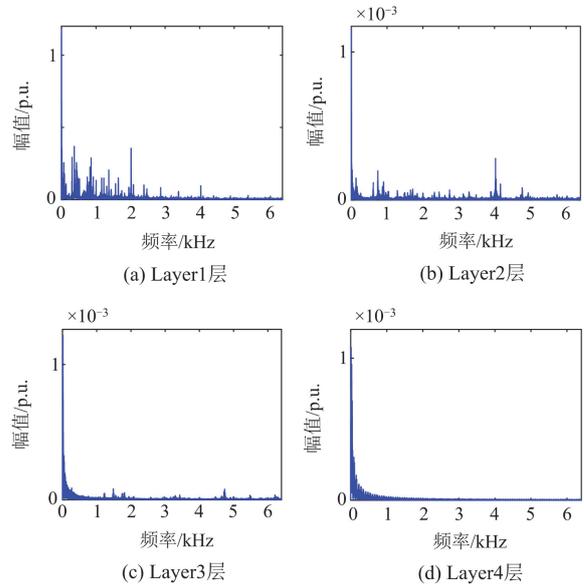


图 12 CNN 每层输出的 FFT 分析

Fig. 12 FFT analysis of CNN output at each layer

由图 12 可以看出，CNN 在每层 Layer 提取的特征明显没有 ResNet 丰富，相较于 ResNet 丢失很多特征。卷积操作本质上是一种局部特征提取机制，每个卷积层只能看到其感受野范围内的信息。CNN 与 ResNet 层数一致，通过网络堆叠扩大了感受野，但由于没有跳跃连接，出现了过拟合的问题，导致信息在传递过程中丢失，底层通用特征部分丢失，多尺度特征提取能力减弱。另外，随着层数的增加易出现梯度消失，因此 CNN 无法实现对振荡特征的准确表示。

2.4.2 本文方法和其他深度学习方法的对比

为了验证本文模型在深度学习领域是否具有优势，本文选取了以下模型进行对比试验：ResNet、ResNet-TCN、ResNet-ILSTM、CNN-ITCN。ResNet 结构与本文中选用的结构一样，均采用 ResNet-18 的结构，LSTM 结构有两层隐藏层，每层的神经元个数为 100，并且将其也嵌入 Attention 层，形成改进 LSTM，简称为 ILSTM，CNN 的层数与 ResNet 层数一致，移除 ResNet 中的跳跃连接。训练方法均与本文方法一致。

1) 纵向对比

将 ResNet、ResNet-TCN 和 ResNet-ITCN 进行损失率对比, 如图 13 所示。

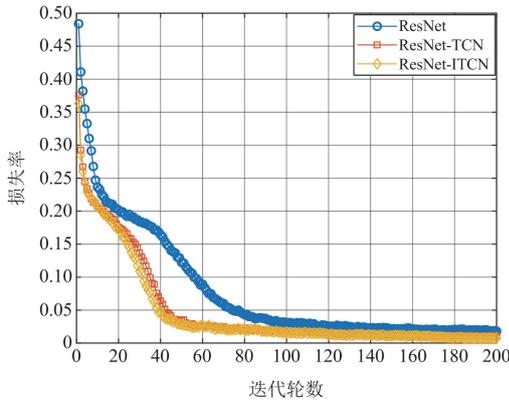


图 13 纵向对比损失率曲线

Fig. 13 Curves of longitudinal comparison loss rate

由图 13 可知, ResNet 的收敛速度最慢, 达到稳定后的损失率最高, 本文方法最优。宽频振荡信号通常包含多种频率的振荡模态, 信号的特征涉及不同时间尺度的信息。ResNet 和 TCN 相结合, 准确地获得振荡信号的多分辨率特征和时间的长期依赖关系。加入注意力机制的 ResNet-ITCN, 对膨胀因果卷积的输出结果进行权重分配, 在进行参数检测时更关注 ResNet 重构特征中的重要部分, 而不是简单地对所有特征进行无差别处理, 因此模型的收敛速度更快, 稳定后的损失率更低。

2) 横向对比

随机抽取同一频段(55~95 Hz)的 30 条宽频振荡信号, 分别采用 ResNet-ITCN、ResNet-ILSTM 和 CNN-ITCN 3 种模型进行频率参数检测, 得到 3 个模型预测值和实际值的拟合曲线, 如图 14 所示。

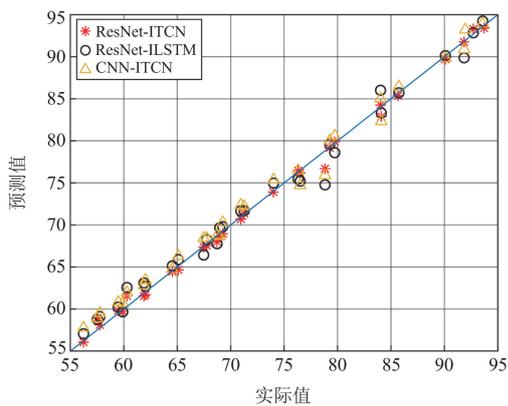


图 14 模型预测值和实际值拟合曲线

Fig. 14 Fitting curve of model predicted and actual values

由图 14 可知, Attention 层的加入提高了参数检测的准确性。ITCN 中的膨胀卷积通过采用指数

增长的膨胀率, 使得网络即使在较浅的层数下, 也能覆盖更广的时间跨度, 从而让模型在深层能同时捕获短期与长期的依赖关系, 较低的膨胀率使模型关注振荡的高频成分, 较高的膨胀率则有助于捕获振荡信号中的低频成分, 对应于长时间依赖。通过调整膨胀率, 能够实现对振荡模态信息的精准捕获, 用于解决其宽频域、多模态的问题。因果卷积逐步分析信号中的各频率成分特征, 有助于深入理解这些成分之间的交互、耦合关系。ILSTM 在处理长时间序列时性能会变差, 易出现过拟合或梯度不稳定的问题, 影响模型效果。CNN 随着网络层数加深, 没有跳跃连接, 导致低层特征部分丢失, 对特征提取不准确。因此, 本文模型的拟合曲线优于 ResNet-ILSTM 和 CNN-ITCN。

3) 各种方法的评估指标对比

图 15 和图 16 为上述 4 种对比模型与本文模型有关幅值、频率和衰减因子的 MAE 与 RMSE 评估结果对比图。图中衰减因子的 MAE 和 RMSE 进行了 50 倍的放大。根据图 15 和图 16, 在纵向对比和

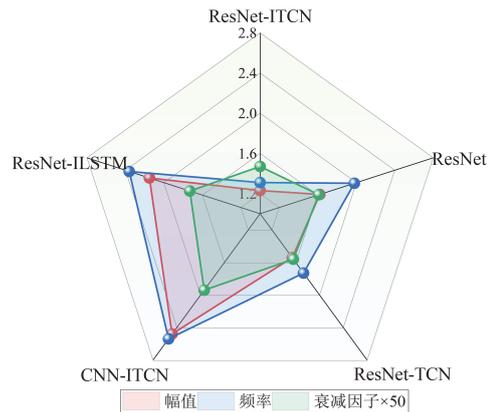


图 15 MAE 评估结果对比图

Fig. 15 Comparison chart of MAE evaluation results

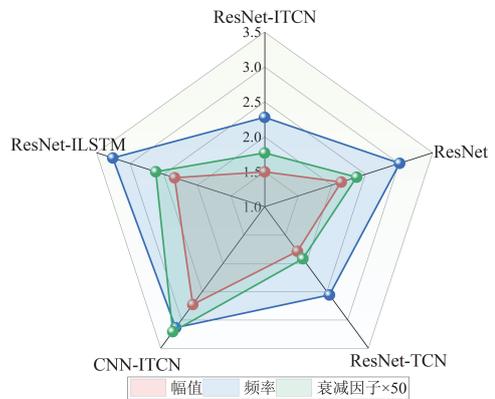


图 16 RMSE 评估结果对比图

Fig. 16 Comparison of RMSE evaluation results

横向对比中, 本文模型各项性能均比较优异。由于上述 5 个模型的 R^2 均达到较高值, 本文不进行 R^2 的对比。

2.5 鲁棒性测试

为了测试本文模型的鲁棒性, 分别将 20~50 dB 的噪声注入到输入信号中, 进行鲁棒性测试, 测试结果如图 17 所示。

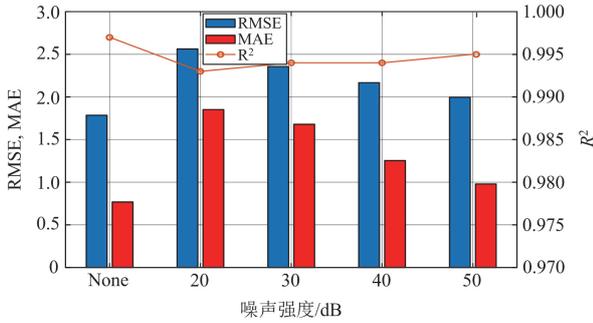


图 17 不同噪声干扰下的指标对比

Fig. 17 Comparison of indicators under different noise interference

根据上述对比指标可以看出, 在噪声强度达到 20 dB 时, 评估指标仍在允许的范围。这是由于本文模型 ResNet 中的平均池化层通过计算局部区域的平均值来保留总体特征, 有助于去除高斯白噪声。ITCN 结构中的膨胀因果卷积通过引入膨胀因子, 关注更大范围的信息, 有助于滤除局部噪声信号, 因此本文模型的鲁棒性符合要求。

3 仿真与实例验证

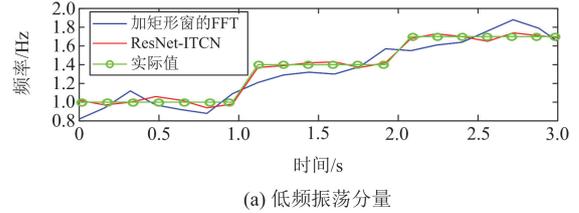
3.1 仿真验证

为进一步验证所提方法的有效性, 构造如式(8)所示的信号, 信号的采样频率为 3200 Hz。

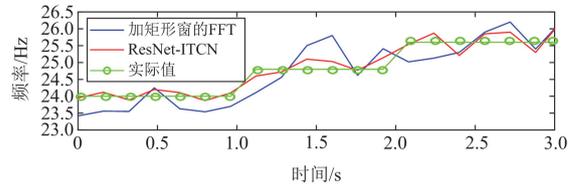
$$X(t) = \begin{cases} 8e^{0.05t} \cos\left(2\pi t + \frac{\pi}{6}\right) + 6e^{0.1t} \cos\left(48\pi t + \frac{\pi}{4}\right) & 0 \leq t < 1 \\ 6e^{0.05t} \cos\left(2.8\pi t + \frac{\pi}{6}\right) + 4e^{0.1t} \cos\left(49.6\pi t + \frac{\pi}{4}\right) & 1 \leq t < 2 \\ 4e^{0.05t} \cos\left(3.4\pi t + \frac{\pi}{6}\right) + 2e^{0.1t} \cos\left(51.2\pi t + \frac{\pi}{4}\right) & 2 \leq t < 3 \end{cases} \quad (8)$$

按照文献[28]的 FFT 方法和本文方法对式(8)信号的频率进行滑窗参数辨识, 窗函数选为矩形窗, 长度为 0.16 s, 辨识结果如图 18 和表 3 所示。

由图 18 和表 3 可以看出, 本文方法的频率辨识精度优于经典的 FFT 方法。FFT 方法本质上是全局分析, 无法准确表示振荡信号时频局部特性, 不能准确捕捉到非平稳振荡信号频率变化的细节特征。因此 FFT 的频率辨识结果与实际值相比误差较大。而本文方法是一种多尺度特征分析方法, 两个模态频率的最大和最小相对误差均小于 FFT 方法, 其频率辨识结果与实际值接近, 满足文献[10]中提出的新型电力系统稳定控制对振荡参数精度级别的要求。



(a) 低频振荡分量



(b) 次同步振荡分量

图 18 本文方法与 FFT 方法对比

Fig. 18 Comparison of the proposed method and FFT method

表 3 辨识结果

Table 3 Identification result

评估指标	评估结果			
	FFT 方法		本文方法	
	低频振荡分量	次同步振荡分量	低频振荡分量	次同步振荡分量
最大相对误差/%	15.6	2.71	4.7	0.41
最小相对误差/%	5.2	0.96	1.1	0.26

3.2 实例验证

采用本文方法对某地含风电机组量测的宽频振荡信号进行监测, 实例 1 为某风电场 A 含有低频振荡的实测数据, 实例 2 为某风电场 B 含有次/超、中高频振荡的实测数据。

3.2.1 实例 1

图 19 为某风电场 A 实测的 60 s 振荡波形, 采样频率为 100 Hz。对该振荡信号进行实时监测, 分析时不考虑工频分量, 监测窗长为 6 s, 窗口重叠长度为 3 s。

通过对信号进行监测, 检测到了两个振荡模态: 低频振荡和次同步振荡模态, 具体频率监测结果如图 20 所示。

在图 20 中, 振荡模态的特征频率并不稳定,

而且持续时间也不同。低频振荡的频率范围为 0.636~0.645 Hz, 在整个 60 s 时间段都存在; 次同步振荡的频率范围为 25.78~25.84 Hz, 仅在 6~12 s 和 9~15 s 两个窗口监测到该振荡频率。同时对两个振荡模态的衰减因子进行监测, 如图 21 所示。

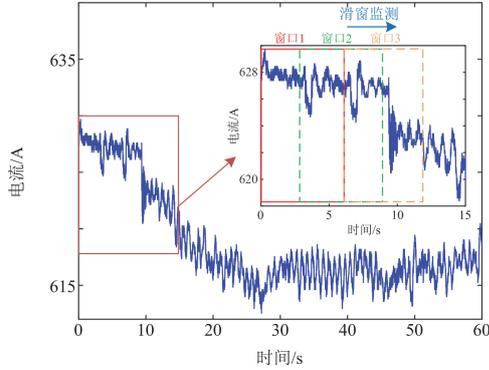


图 19 某风电场 A 实测低频振荡波形
Fig. 19 Measured low frequency oscillation waveform of a wind farm A

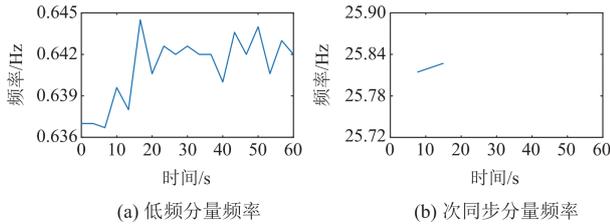


图 20 频率监测结果

Fig. 20 Frequency monitoring results

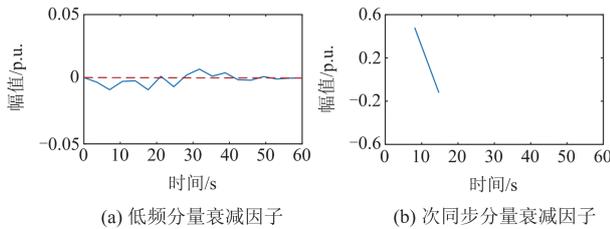


图 21 衰减因子监测结果

Fig. 21 Attenuation factor monitoring results

在图 21 中, 模态的衰减因子也呈现了时变特征。低频振荡模态的衰减因子在 0 左右波动, 呈现零阻尼或负阻尼状态, 会影响更大范围的系统。而次同步振荡通过局部调整快速衰减, 衰减因子变化较剧烈, 能量衰减较快。因此, 该振荡信号中的低频振荡模态为主导振荡模态, 需要发出报警信号并及时进行处理。

对每个窗口的参数预测值进行振荡类型的判别, 对于图 20 检测出来的两个振荡模态的振荡类型进行判断, 如表 4 所示。

表 4 振荡类型识别准确率

Table 4 Oscillation type recognition accuracy

类型	待预测数	预测正确数	准确率/%
低频振荡	19	19	100
次同步振荡	2	2	100

表 4 的结果表明, 检测到的振荡模态分量类型能够被准确识别。

通过对该时间段的实测信号进行频率切片小波变换(frequency slice wavelet transform, FSWT)来验证本文方法, 得到该信号的时频特性图, 如图 22 所示。

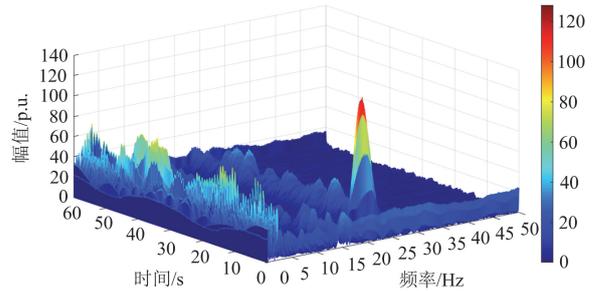


图 22 实测低频振荡信号 FSWT 分析 3D 图

Fig. 22 Measured low frequency oscillation signal FSWT analysis 3D diagram

图 22 验证了该实测信号中低频振荡模态并不是单独存在的, 还存在一个短时间出现并迅速衰减的次同步振荡分量。低频振荡模态能量较强, 为主导振荡模态; 次同步振荡分量在 10 s 左右出现并迅速衰减, 影响远不及低频振荡分量。

3.2.2 实例 2

图 23 为某风电场 B 发生次/超、中高频振荡的录波结果, 采样频率为 12.8 kHz, 时间为 60 s。同样对其进行 60 s 的监测, 分析时不考虑工频分量, 时窗长度为 2 s, 窗口重叠长度为 1 s, 共 60 个滑窗。

限于篇幅, 本文仅展示中间振荡最剧烈的 15~25 s 监测结果, 共监测到 5 个主要振荡模态, 次/超同步振荡模态监测结果如表 5 所示, 中高频振荡模态监测结果如表 6 所示。

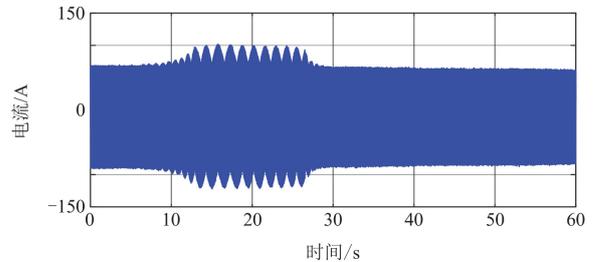


图 23 某风电场 B 实测次/超、中高频振荡波形

Fig. 23 Measured sub/synchronous and medium-high frequency oscillation waveform of wind farm B

表 5 15~25 s 次/超同步振荡监测结果

Table 5 15~25 s sub/synchronous oscillation monitoring results

监测时间/s	监测结果			
	模态 1		模态 2	
	频率/Hz	幅值/A	频率/Hz	幅值/A
15~17	26.88	18.66	74.91	25.14
16~18	26.66	19.47	73.67	27.06
17~19	26.56	20.08	74.32	29.31
18~20	26.14	23.38	74.67	31.52
19~21	26.94	23.53	74	33.6
20~22	27.11	25.19	73.94	34.5
21~23	26.47	26.78	74.75	37.06
22~24	26.05	27.06	75.82	38.38
23~25	26.11	28.48	75.91	38.47

表 6 15~25 s 中高频振荡监测结果

Table 6 15~25 s medium-high frequency oscillation monitoring results

监测时间/s	监测结果					
	模态 3		模态 4		模态 5	
	频率/Hz	幅值/A	频率/Hz	幅值/A	频率/Hz	幅值/A
15~17	103.21	11.36	251.56	8.24	355.42	15.92
16~18	104.72	11.47	248.91	7.99	354.84	15.56
17~19	104.75	10.72	249.65	6.73	349.56	13.84
18~20	103.32	10.39	—	—	345.23	13.62
19~21	104.06	9.36	—	—	353.89	13.11
20~22	105.03	10.27	252.69	5.27	354.92	12.27
21~23	104.43	12.08	247.64	7.08	347.32	10.8
22~24	104.75	13.02	249.38	7.42	345.97	8.37
23~25	102.63	13.19	247.31	8.19	348.56	8.69

由表 5 和表 6 可知, 共监测到 5 个主要振荡模态, 各模态的幅频时变。次/超同步振荡(模态 1 和模态 2)成对出现, 在系统中是耦合的, 幅值也相应较大, 这对模态是由于该地区的风力发电机组或 FACTS 等装置本身参数设置不合理, 导致与弱交流电网相互作用产生的, 为主导振荡模态, 严重影响了电网安全。中高频振荡存在一个二倍频(模态 3)和一对耦合、互补的谐波分量(模态 4 和模态 5)。这 3 个模态是电力电子高频开关器件与电网作用产生的谐波振荡成分, 中高频振荡的幅值比主导振荡模态小, 为次要振荡模态。对上述振荡类型进行判断, 如表 7 所示。

表 7 振荡类型判断

Table 7 Oscillation type judgment

类型	待判断数	判断正确数	准确率/%
次/超同步振荡	18	18	100
中高频振荡	25	25	100

对实测的振荡信号进行 FSWT 分析验证, 得到的时频图如图 24 所示。

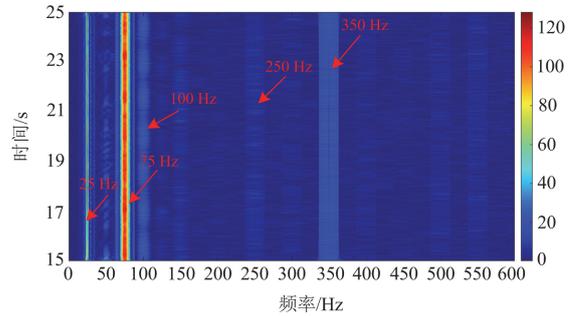


图 24 实测次/超、中高频振荡信号 FSWT 分析 2D 图

Fig. 24 2D diagram of measured sub/synchronous and medium-high frequency oscillation signals FSWT analysis

由图 24 分析可知, 25 Hz 和 75 Hz 即次/超同步振荡剧烈、幅值较大, 为主导模态。中高频段对应的幅值相对较小, 为次要模态, 验证结果与本文方法分析得到的结论一致。

4 结论

本文提出了一种基于 ResNet-ITCN 的宽频振荡监测方法, 主要结论如下。

1) ResNet-ITCN 模型能够很好地完成宽频振荡的监测问题。ResNet 利用较深的结构和残差连接, 在提取深层细节特征的同时结合底层通用特征, 实现了对宽频振荡信号的多尺度特征的准确表示。ITCN 通过膨胀因果卷积, 对 ResNet 输出的压缩特征进行扩展, 在保证计算效率的同时逐层引入较大的感受野, 进一步提取时间序列中蕴含的中长期依赖特性, 两者结合实现了对全局特征的提取, 同时有效处理宽频振荡每种模态的侧重特征, 参数检测更加精准。

2) 所提方法相较于其他模型(ResNet, ResNet-TCN, ResNet-ILSTM, CNN-ITCN)在振荡参数检测时具有更小的误差, 且所提方法具有良好的鲁棒性。

3) 经过两处风电场的实例验证, ResNet-ITCN 模型能够实现对不同振荡类型的宽频振荡信号的监测。

下一步将在现有工作的基础上, 进一步研究基于物理信息神经网络(physics-informed neural networks, PINN)的宽频振荡监测, 通过将已知的物理规律直接嵌入神经网络的损失函数, 从而约束模型的学习过程。提高预测精度、增强模型泛化性, 提高对宽频振荡物理本质的可解释性。同时, 基于宽频测量装置间谐波的实时测量数据, 本文方法可以拓展到

未来的预测和预警。

参考文献

- [1] 谢小荣, 贺静波, 毛航银, 等. “双高”电力系统稳定性的新问题及分类探讨[J]. 中国电机工程学报, 2021, 41(2): 461-475.
XIE Xiaorong, HE Jingbo, MAO Hangyin, et al. New issues and classification of power system stability with high shares of renewables and power electronics[J]. Proceedings of the CSEE, 2021, 41(2): 461-475.
- [2] 程静, 苏乐, 岳雷. 双馈风电并网系统的宽频振荡机理分析与抑制[J]. 电力系统保护与控制, 2023, 51(12): 1-13.
CHENG Jing, SU Le, YUE Lei. Mechanism analysis and suppression of broadband oscillation in a DFIG wind power grid-connected system[J]. Power System Protection and Control, 2023, 51(12): 1-13.
- [3] 游奕弘, 谢懿晗, 张华赢, 等. 基于 APF 模态切换的高频谐振有源阻尼镇定策略[J]. 供用电, 2023, 40(10): 10-18.
YOU Yihong, XIE Yihan, ZHANG Huaying, et al. APF mode switching based active damping stabilization strategy for high frequency resonance[J]. Distribution & Utilization, 2023, 40(10): 10-18.
- [4] 雷傲宇, 汪林光, 梅勇, 等. 多端柔性直流电网的中高频振荡特性分析[J]. 电网与清洁能源, 2023, 39(7): 55-60.
LEI Aoyu, WANG Linguang, MEI Yong, et al. An analysis of medium & high-frequency oscillation characteristics in multi-terminal flexible HVDC networks[J]. Power System and Clean Energy, 2023, 39(7): 55-60.
- [5] XIE Xiaorong, ZHANG Xu, LIU Huakun, et al. Characteristic analysis of subsynchronous resonance in practical wind farms connected to series-compensated transmissions[J]. IEEE Transactions on Energy Conversion, 2017, 32(3): 1117-1126.
- [6] LIU Huakun, XIE Xiaorong, HE Jingbo, et al. Subsynchronous interaction between direct-drive PMSG based wind farms and weak AC networks[J]. IEEE Transactions on Power Systems, 2017, 32(6): 4708-4720.
- [7] BUCHHAGEN C, RAUSCHER C, MENZE A, et al. BorWin1-first experiences with harmonic interactions in converter dominated grids[C] // Proceedings of International ETG Congress 2015, Die Energiewende-Blueprints for the New Energy Age, November 17-18, 2015, Bonn, Germany: 1-7.
- [8] CHEAH-MANE M, SAINZ L, LIANG Jun, et al. Criterion for the electrical resonance stability of offshore wind power plants connected through HVDC links[J]. IEEE Transactions on Power Systems, 2017, 32(6): 4579-4589.
- [9] 赵妍, 潘怡, 李亚波, 等. 基于 AVMD 多尺度模糊熵和 VPMCD 算法的宽频振荡分类[J]. 电力系统保护与控制, 2024, 52(13): 179-187.
ZHAO Yan, PAN Yi, LI Yabo, et al. Broadband oscillation classification based on AVMD multi-scale fuzzy entropy and the VPMCD algorithm[J]. Power System Protection and Control, 2024, 52(13): 179-187.
- [10] 谢小荣, 李浩志, 张丹, 等. 新型电力系统稳定器研究初探[J]. 电力系统自动化, 2024, 48(23): 156-166.
XIE Xiaorong, LI Haozhi, ZHANG Dan, et al. Preliminary study on stabilizer for new power systems[J]. Automation of Electric Power Systems, 2024, 48(23): 156-166.
- [11] 高磊, 张慧媛, 许军, 等. 海上柔性直流输电系统的宽频带振荡非同时性研究[J]. 电测与仪表, 2024, 61(7): 50-56.
GAO Lei, ZHANG Huiyuan, XU Jun, et al. Asynchronous characteristics research of wideband oscillation in offshore windfarms connected to MMC-HVDC[J]. Electrical Measurement & Instrumentation, 2024, 61(7): 50-56.
- [12] 王帅, 刘广军, 张博文, 等. 基于宽频等值电路的配电变压器局部放电电气定位研究[J]. 电网与清洁能源, 2023, 39(3): 40-47.
WANG Shuai, LIU Guangjun, ZHANG Bowen, et al. Research on partial discharge electrical localization of distribution transformers based on broadband equivalent circuit[J]. Power System and Clean Energy, 2023, 39(3): 40-47.
- [13] 李文博, 钱伟荣, 李淑蓉, 等. 改进自适应 VMD 和 TLS-ESPRIT 的风电系统次/超同步振荡参数辨识[J]. 高电压技术, 2025, 51(1): 146-157.
LI Wenbo, QIAN Weirong, LI Shurong, et al. Improved adaptive VMD and TLS-ESPRIT sub/sup-synchronous oscillation parameter identification for wind power systems[J]. High Voltage Engineering, 2025, 51(1): 146-157.
- [14] 马钺, 蔡东升, 黄琦. 基于 Rife-Vincent 窗和同步相量测量数据的风电次同步振荡参数辨识[J]. 中国电机工程学报, 2021, 41(3): 790-803.
MA Yue, CAI Dongsheng, HUANG Qi. Parameter identification of wind power sub-synchronous oscillation based on Rife-Vincent window and synchrophasor data[J]. Proceedings of the CSEE, 2021, 41(3): 790-803.
- [15] 李振华, 喻彩云, 蒋伟辉, 等. 基于五项 Rife-Vincent(I) 窗的四谱线插值 FFT 谐波分析方法[J]. 电测与仪表, 2023, 60(4): 78-84.
LI Zhenhua, YU Caiyun, JIANG Weihui, et al. Quadruple-spectrum-line interpolation FFT harmonic analysis method based on five-term Rife-Vincent(I) window[J]. Electrical Measurement & Instrumentation, 2023, 60(4): 78-84.
- [16] 马俊杰, 刘芳, 吴敏, 等. 基于类噪声小波分解的风电场次同步振荡辨识[J]. 电网技术, 2019, 43(4): 1294-1300.
MA Junjie, LIU Fang, WU Min, et al. Wind farm sub-

- synchronous oscillation mode identification based on wavelet decomposition of ambient noise signals[J]. Power System Technology, 2019, 43(4): 1294-1300.
- [17] 金涛, 刘对. 基于改进去噪性能的Prony算法电网低频振荡模态辨识研究[J]. 电机与控制学报, 2017, 21(5): 33-41.
JIN Tao, LIU Dui. Power grid low frequency oscillation recognition based on advanced Prony algorithm with improved denoising feature[J]. Electric Machines and Control, 2017, 21(5): 33-41.
- [18] 孙勇, 张鹏, 姜涛, 等. 基于同步压缩广义S变换的电力系统次/超同步振荡检测[J]. 电网技术, 2024, 48(10): 4002-4014.
SUN Yong, ZHANG Peng, JIANG Tao, et al. Detection of sub/supersynchronous oscillation in power system using synchrosqueezing generalized S-transform[J]. Power System Technology, 2024, 48(10): 4002-4014.
- [19] 王渝红, 王馨瑶, 廖建权, 等. 交直流电网宽频振荡产生、辨识及抑制研究综述[J]. 高电压技术, 2023, 49(8): 3148-3162.
WANG Yuhong, WANG Xinyao, LIAO Jianquan, et al. Review of generation, identification and suppression of wide-band oscillation in AC-DC power system[J]. High Voltage Engineering, 2023, 49(8): 3148-3162.
- [20] LIU Hao, QI Yuan, ZHAO Junbo, et al. Data-driven subsynchronous oscillation identification using field synchrophasor measurements[J]. IEEE Transactions on Power Delivery, 2022, 37(1): 165-175.
- [21] 赵妍, 崔浩瀚, 荣子超. 次同步振荡在线监测的同步提取变换和朴素贝叶斯方法[J]. 电力系统自动化, 2019, 43(3): 187-192.
ZHAO Yan, CUI Haohan, RONG Zichao. On-line monitoring of subsynchronous oscillation based on synchro extracting transform and naive Bayes method[J]. Automation of Electric Power Systems, 2019, 43(3): 187-192.
- [22] 冯双, 崔昊, 吴熙, 等. 基于对角化LDPC压缩感知和k-近邻算法的广域系统宽频振荡监测方法[J]. 电网技术, 2021, 45(8): 3025-3033.
FENG Shuang, CUI Hao, WU Xi, et al. Monitoring method of wide-band oscillation based on compressed sensing of diagonalizable LDPC and k-nearest Neighbour algorithm[J]. Power System Technology, 2021, 45(8): 3025-3033.
- [23] 陆友文, 崔昊, 陈佳宁, 等. 基于RA-CNN和同步相量的风电场次/超同步振荡参数智能辨识方法[J]. 中国电力, 2023, 56(4): 46-55, 67.
LU Youwen, CUI Hao, CHEN Jianing, et al. Intelligent identification method of wind farm sub-synchronous/supersynchronous oscillation parameters based on RA-CNN and synchrophasor[J]. Electric Power, 2023, 56(4): 46-55, 67.
- [24] 崔昊, 冯双, 陈佳宁, 等. 基于自编码器与长短期记忆网络的宽频振荡广域定位方法[J]. 电力系统自动化, 2022, 46(12): 194-201.
CUI Hao, FENG Shuang, CHEN Jianing, et al. Wide-area location method of wide-band oscillations based on autoencoder and long short-term memory network[J]. Automation of Electric Power Systems, 2022, 46(12): 194-201.
- [25] 赵妍, 唐文石, 聂永辉, 等. 基于格拉姆角差场和卷积神经网络的宽频振荡分类方法[J]. 电网技术, 2022, 46(11): 4364-4372.
ZHAO Yan, TANG Wenshi, NIE Yonghui, et al. Broadband oscillation classification method based on GADF-AlexNet[J]. Power System Technology, 2022, 46(11): 4364-4372.
- [26] 赵启, 王建, 林丰恺, 等. 基于格拉姆角场与ResNet的输电线路故障辨识方法[J]. 电力系统保护与控制, 2024, 52(10): 95-104.
ZHAO Qi, WANG Jian, LIN Fengkai, et al. Transmission line fault identification method based on Gramian angular field and ResNet[J]. Power System Protection and Control, 2024, 52(10): 95-104.
- [27] 李载源, 潘超, 孟涛. 基于风速属性优化聚类的时序卷积特征聚合风速预测[J]. 智慧电力, 2023, 51(10): 1-8.
LI Zaiyuan, PAN Chao, MENG Tao. Time series convolution feature aggregation based wind speed prediction considering wind speed attribute optimization clustering[J]. Smart Power, 2023, 51(10): 1-8.
- [28] 庞浩, 李东霞, 俎云霄, 等. 应用FFT进行电力系统谐波分析的改进算法[J]. 中国电机工程学报, 2003, 23(6): 50-54.
PANG Hao, LI Dongxia, ZU Yunxiao, et al. An improved algorithm for harmonic analysis of power system using FFT technique[J]. Proceedings of the CSEE, 2003, 23(6): 50-54.

收稿日期: 2025-01-18; 修回日期: 2025-04-27

作者简介:

赵妍(1974—), 女, 博士, 副教授, 硕士生导师, 研究方向为电力系统稳定分析与控制、电力系统故障分析和信号处理; E-mail: zjb_112006@163.com

吴昊鑫(2001—), 男, 通信作者, 硕士研究生, 研究方向为人工智能在电力系统中的应用。E-mail: wuhaoxin656@163.com

(编辑 许威)