



电网技术  
Power System Technology  
ISSN 1000-3673, CN 11-2410/TM

## 《电网技术》网络首发论文

题目: 基于 CWT 和 Patchtst 的新能源次/超同步振荡快速在线检测与定时  
作者: 刘崇茹, 孔令然, 苏晨博, 房佳姝, 董浩云  
DOI: 10.13335/j.1000-3673.pst.2025.0864  
收稿日期: 2025-06-13  
网络首发日期: 2025-11-05  
引用格式: 刘崇茹, 孔令然, 苏晨博, 房佳姝, 董浩云. 基于 CWT 和 Patchtst 的新能源次/超同步振荡快速在线检测与定时[J/OL]. 电网技术.  
<https://doi.org/10.13335/j.1000-3673.pst.2025.0864>



**网络首发:** 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

**出版确认:** 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

# 基于 CWT 和 Patchtst 的新能源次/超同步振荡 快速在线检测与定时

刘崇茹<sup>1</sup>, 孔令然<sup>1</sup>, 苏晨博<sup>1, 2\*</sup>, 房佳姝<sup>3</sup>, 董浩云<sup>1</sup>

(1. 新能源电力系统国家重点实验室(华北电力大学), 北京市 昌平区 102206;

2. 清华大学电机工程与应用电子技术系, 北京市 海淀区 100084;

3. 电子科技大学机械与电气工程学院, 四川省 成都市 611731)

## A Fast On-Line Detection and Timing Method for New Energy Sub-/Super-Synchronous Oscillation Based on CWT and Patchtst

LIU Chongru<sup>1</sup>, KONG Lingran<sup>1</sup>, SU Chenbo<sup>1, 2\*</sup>, FANG Jiashu<sup>3</sup>, DONG Haoyun<sup>1</sup>

(1. State Key Lab. for Alternate Electrical Power System with Renewable Energy Sources

(North China Electric Power University), Changping District, Beijing 102206, China;

2. Department of Electrical Engineering, Tsinghua University, Haidian District, Beijing 100084, China;

3. School of Mechanical and Electrical Engineering, University of Electronic Science and Technology of China, Chengdu 611731, Sichuan Province, China)

**ABSTRACT:** The access of new energy power generation equipment to the power grid is easy to cause sub-/super-synchronous oscillation problems. The traditional oscillation detection and identification algorithm faces the problems of insufficient timeliness and difficult modeling. The existing machine learning oscillation identification algorithm is based on the data set after the oscillation occurs, which is difficult to be applied online in real time. In this paper, an online oscillation detection method based on short-time sliding window sampling is proposed to realize the online rapid identification of whether the oscillation occurs and the specific time, which can be used to control the online input of machine learning oscillation identification method or other oscillation suppression strategy. The proposed method first constructs the oscillation time-frequency feature extraction process based on the Continuous Wavelet Transform (CWT) algorithm to capture the oscillation information in the window. After that, a neural network model based on Patch Time Series Transformer (Patchtst) is constructed to analyze the results of CWT feature extraction, judge whether the oscillation occurs in the window and obtain the specific time when the oscillation occurs. Finally, the effectiveness of the proposed method is verified by the simulation of multiple direct-drive wind farms and the experiment of grid-connected photovoltaic measured data. The results show that the model based on the simulation data of part of wind farms not only has high accuracy, also shows strong versatility in the face of other wind farms data, data under the condition of partial wind farm removal and field measured

photovoltaic data, which has practical engineering value.

**KEY WORDS:** sub-/super-synchronous oscillation; new energy power system; machine learning; oscillation detection; continuous wavelet transform

**摘要:** 新能源发电设备接入电网容易引发次/超同步振荡问题。传统振荡检测辨识算法面临时效性不足、建模困难等问题,而现有机学习振荡辨识算法基于振荡发生后数据集建立,难以在线实时应用。本文提出一种基于短时滑窗采样的振荡在线检测方法,实现振荡是否发生以及发生具体时间的在线快速识别,可以用以控制机器学习振荡辨识方法或其他振荡抑制策略的在线投入。所提方法首先构建基于连续小波变换算法(Continuous Wavelet Transform, CWT)的振荡时频特征提取过程,捕捉窗内振荡发生信息。之后,构建基于片段时序Transformer(Patch Time Series Transformer, Patchtst)的神经网络模型,对 CWT 特征提取结果进行分析,判断窗内振荡是否发生以及获取振荡发生具体时间。最后,通过多直驱风电场站仿真并网算例以及现场光伏实测数据实验,验证了所提方法有效性。结果表明,基于局部场站仿真数据建立的模型,模型不仅具备较高的精度,并且面对其他场站数据、部分场站切除工况下数据以及现场实测光伏数据时,模型均展现出较强通用性,模型具有工程实用价值。

**关键词:** 次/超同步振荡; 新能源电力系统; 机器学习; 振荡检测; 连续小波变换

**DOI:** 10.13335/j.1000-3673.pst.2025.0864

基金项目: 国家自然科学基金项目(U23B20126)。

Project Supported by National Natural Science Foundation of China (U23B20126).

## 0 引言

在“双高背景”下，新能源发电并网容量不断提升，系统电力电子化程度不断加深，系统惯量降低，系统各环节之间动态交互引发的次/超同步振荡问题愈发凸显<sup>[1][2]</sup>。快速准确的次/超同步振荡在线检测，是实现振荡快速抑制的关键环节。

现有研究通常将振荡检测问题等价于振荡频率等参数的辨识问题，通过识别信号中是否有振荡谐波含量作为检测振荡是否发生的标准<sup>[3][4]</sup>，对应的振荡检测方法<sup>[5]</sup>主要分为频谱分析法和非频谱分析法。频谱分析法基于快速傅里叶变换(Fast Fourier Transform, FFT)建立振荡检测系统<sup>[6]</sup>，并已经集成同步相量测量装置(synchrophasor measurement unit, PMU)和测控装置，推进 FFT 技术工程实用化<sup>[7]</sup>。FFT 类方法目前最短采样窗长为 2s，但仍然无法反映百毫秒内传播并发的新型振荡的特性<sup>[5]</sup>。非频谱类方法包括 Prony 算法<sup>[8]</sup>、特征值求解<sup>[9]</sup>和轨迹拟合算法<sup>[10]</sup>等，此类方法较频谱类方法能够明显缩短采样窗长，但面临参数整定困难、需要精确建模等问题，对日益复杂的新型电力系统适用性较差。

机器学习算法具备无需精确建模、响应速度快等优势，为解决振荡检测问题提供新的思路，并在振荡参数辨识方面取得了一些进展。例如，文献[11]通过同步提取变换方法得到振荡模态，送入朴素贝叶斯方法进行振荡频段分类；文献[12]-[14]分别应用卷积神经网络、长短期记忆网络以及支持向量机算法进行振荡参数的辨识。文献[15]针对振荡发生初始阶段运行数据进行分析，采样窗长降低至 0.2s，显著降低了振荡发生至振荡辨识完成所需时间。

机器学习算法基于振荡发生后的数据集建立，因此，此类算法在线应用时需要首先准确判断振荡是否发生。判断振荡发生后，针对振荡发生后波形分析，才能保证在线数据与离线训练数据分布统一性，从而保证在线应用算法精度。由于机器学习算法的泛化性能约束，如果将振荡未发生时的数据送入机器学习算法，可能会错误输出一个振荡频率，引发后续振荡抑制措施误动。

次/超同步振荡问题具备强周期性特征，实现远距离周期性信号交互，有利于提升振荡检测精度。片段时序 Transformer 模型(Patch Time Series Transformer, Patchtst)<sup>[16]</sup>是一种高效时序建模神经网络。与卷积网络、循环神经网络相比，Patchtst 的自注意力机制可以有效捕捉振荡周期性信号远距离时间点之间的特征依赖关系；同时，Patchtst

的通道独立及片段划分过程，显著减少自注意力点乘运算计算规模，更好满足在线运算时效性需求。

振荡发生起始初期，信号数据与稳态时刻相比变化微小，不利于神经网络学习分类。连续小波变换(Continuous Wavelet Transform, CWT)<sup>[17][18]</sup>是一种时频分析方法，能够显著增强振荡/稳定样本之间的差异性。CWT 与神经网络配合可以为后续振荡检测和定时任务提供更具判别性的特征，有助于提升神经网络学习精度。

因此，本文提出一种基于 CWT 与 Patchtst 相结合的振荡在线检测算法，快速判断振荡是否发生并准确获取振荡发生时间，为在线过程中机器学习振荡辨识算法以及后续抑制措施投入提供判别条件。本文主要贡献如下：

(1) 提出一种基于短时滑窗移动的振荡在线检测与定时方法，滑窗步长设定为 0.2s，具备很好的时效性。

(2) 构建基于 CWT 信号时频特征提取过程，捕捉振荡发生相关特征，有效提升振荡发生前后数据差异，有利于神经网络学习。

(3) 构建适用于振荡检测定时的 Patchtst 神经网络模型，实现振荡发生信息的高效轻量化检测。

## 1 振荡在线检测与定时方法

### 1.1 问题概述

当电力系统发生振荡时，各节点电压电流等运行数据可以看作 50Hz 基频波、次/超同步振荡正弦波信号以及随机波动叠加而成，可以表示为：

$$f_{ss0}(t) = A_{50} \sin(2\pi f_{50}t + \varphi_{50}) + A_{sub} \sin(2\pi f_{sub}t + \varphi_{sub})e^{-\lambda_{sub}t} + A_{sup} \sin(2\pi f_{sup}t + \varphi_{sup})e^{-\lambda_{sup}t} + n(t) \quad (1)$$

式中， $A_{50}$ ,  $f_{50}$ ,  $\varphi_{50}$  分别为基频幅值、频率、以及相角， $n(t)$  为随机波动。 $A_{sub}$ ,  $f_{sub}$ ,  $\varphi_{sub}$ ,  $\lambda_{sub}$  分别为次同步分量振荡模态幅值、频率、相角以及衰减因子， $A_{sup}$ ,  $f_{sup}$ ,  $\varphi_{sup}$ ,  $\lambda_{sup}$  分别为超同步分量振荡模态幅值、频率、相角以及衰减因子。由于新能源内部电力电子变流器控制环节作用，振荡次同步分量和超同步分量共同存在，并且两者之间存在频率耦合关系，具体关系为  $f_{sub} + f_{sup} = 2f_{50}$ <sup>[5]</sup>。

当系统处于稳态时，运行数据中只有基频分量以及随机波动，并没有振荡模态分量，如式(2)所示：

$$f_{stable}(t) = A_{50} \sin(2\pi f_{50}t + \varphi_{50}) + n(t) \quad (2)$$

从数据特征角度上，振荡数据与稳态数据存在



明显分布差异,与稳态数据相比,振荡数据中叠加了次/超同步振荡正弦波。现有机器学习类振荡辨识算法通常基于振荡发生后数据建立,更加注重挖掘次/超同步振荡正弦波的特性,样本构建过程并未考虑稳态数据特征。因此,此类算法在线应用过程中,面向稳态数据时表现难以保证。

本文采用基于卷积神经网络建立振荡主导频率辨识模型进行测试发现:经过振荡样本(振荡发生后 0-0.2s 运行数据<sup>[15]</sup>)训练,算法在振荡样本上表现出的预测频率平均偏差仅为 1.41Hz,但是面对稳态样本时,输出振荡频率平均误差为 43.60Hz,输出振荡频率集中于 93-94Hz 范围,并未输出 50Hz 的真实频率,明显产生了误判。部分振荡和稳态样本输出频率偏差如图 1 所示:




图 1 振荡与稳态样本主导辨识频率偏差

Fig. 1 Dominant identification frequency deviation of oscillation and steady state samples

## 1.2 基于滑窗移动的振荡在线检测与定时

为解决上述问题,本文提出基于短时滑窗移动的振荡在线检测与定时方法。在线运行过程中,不断滑窗采集 A 相电流  $I_a$  运行数据(如图 2 所示),送入机器学习算法进行分析以完成两项任务。第一项任务为分析判断窗内是否发生振荡,本文称之为“振荡检测任务”;第二项任务在判断窗内发生振荡时投入,分析振荡在窗内发生具体时间(如图 2 中时间  $t$ ),本文称之为“振荡定时任务”。




图 2 次/超同步振荡在线实时检测与定时数据滑窗

Fig. 2 Data sliding window of sub-/super-synchronous oscillation online detection and timing

为满足检测的实时快速性需求,本文设计滑窗

长度  $l_1$  为 0.24s,每次滑窗移动步长  $l_2$  为 0.2s。滑窗长度和滑动步长设置的具体原因详见第 2 节。

为方便后续说明,本文将滑窗内未发生振荡称为“稳态窗口样本”,滑窗内发生振荡称为“振荡窗口样本”。

## 2 基于 CWT 的信号时频特征提取

连续小波变换<sup>[17][18]</sup>是一种时频联合分析方法,通过动态调整小波函数的尺度和位置对信号进行多尺度分析,从而精确提取信号的局部时频特征,十分适合捕捉振荡发生前后信号的时频变化特征。

### 2.1 CWT 方法概述

CWT 核心思想在于通过缩放和平移小波函数来与信号进行卷积运算,以获取局部信号在时间和频率上的特征。对于信号  $x(t)$ , CWT 公式可以表示为:

$$CWT(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi^* \left( \frac{t-b}{a} \right) dt \quad (3)$$

其中,  $a$  为小波函数的尺度参数,用于控制小波的伸缩,与输出频率成反比;  $b$  为小波函数的时域位移参数;  $\psi(t)$  表示小波函数,  $\psi^*(t)$  表示其复共轭。

复数 Morlet 小波(Complex Morlet Wavelet, cmor)在基础 Morlet 函数基础上引入复数概念,可以同时提取信号的幅值和相位信息,十分适合用于分析振荡信号。cmor 小波函数可表示为:

$$\psi(t) = \frac{1}{\sqrt{\pi F_b}} e^{j2\pi F_c t} e^{-t^2/F_b} \quad (4)$$

其中,  $F_b$  是带宽参数,控制小波的时频分辨率;  $F_c$  为中心频率参数,控制小波的主频率。

### 2.2 面向振荡检测与定时的 CWT 方法

基于 CWT 方法,本文构建面向振荡检测与定时问题的振荡信号时频特征提取过程如图 3 所示:




图 3 振荡检测与定时 CWT 特征提取方法流程图

Fig. 3 Flow chart of CWT feature extraction method for oscillation detection and timing

本文设计基于 CWT 的振荡特征提取方法主要包括三个步骤：

步骤 1：对如图 3(a)所示的电气运行时序数据进行 CWT 变换。本文在 *cmor* 小波函数中， $F_b$  取值为 0.5,  $F_c$  取值为 1, CWT 变换频率范围为 4-100Hz, 对应次/超同步振荡频率范围。变换后结果如图 3(b)所示。

步骤 2：CWT 结果存在边界效应，当卷积位置靠近信号起始和末尾阶段时，小波函数范围会超出信号边界，边界处结果失真，如图 3(b)白线外侧区域。当信号在边界发生振荡时，边界效应会掩盖真实特征，导致难以准确提取振荡发生信息。为避免边界效应干扰，本文只截取图 3(b)白线内侧中间时段作为后续分析对象，如图 3(c)所示。本文设计滑窗长度  $l_1$  为 0.24s, 截取窗内中间 0.2s 特征，因此设计每次滑窗移动步长  $l_2$  为 0.2s, 由此保证滑窗采样中任意时刻发生的振荡都可以位于截取中间段内，避免时段遗漏。

步骤 3：经 CWT 变换后，数据规模十分庞大，为提升后续神经网络计算效率，对数据进行降维处理：

首先进行频段划分，每一频段内同一时间步元素取平均值，可以表示为：

$$x^{(1)}(t, B_i) = \frac{1}{N_i} \sum_{f \in B_i} x(t, f) \quad (5)$$

其中， $x(t, f)$  表示 CWT 结果中时间步  $t$ 、频率  $f$  处数值； $x^{(1)}(t, B_i)$  表示降维后在时间步  $t$ 、频段  $B_i$  处数值； $B_i$  为划分的第  $i$  个频段，本文设计划分频段为 {4-14Hz, 15-24Hz, 25-34Hz, 35-44Hz, 45-54Hz, 55-64Hz, 65-74Hz, 75-84Hz, 85-100Hz}； $N_i$  表示频段  $B_i$  所包括频率数量。

之后，为消除不同量级影响，对每一频段所有时间步数值进行归一化处理，得到最终结果如图 3(d)所示。归一化处理可以表示为：

$$x^{(2)}(t, B_i) = \frac{x^{(1)}(t, B_i) - \min(x^{(1)}(B_i))}{\max(x^{(1)}(B_i)) - \min(x^{(1)}(B_i))} \quad (6)$$

其中， $x^{(2)}(t, B_i)$  表示归一化后在时间步  $t$ 、频段  $B_i$  处数值； $\max(x^{(1)}(B_i))$ 、 $\min(x^{(1)}(B_i))$  分别表示频段划分后频段  $B_i$  中的最大值与最小值。

### 2.3 CWT 特征提取有效性分析

2.2 节中图 3 展示的是振荡窗口样本经 CWT 特征提取结果，图 4 展示了稳态窗口样本经 CWT 特征提取结果。




图 4 稳态样本 CWT 特征提取结果

Fig. 4 Steady-state sample CWT feature extraction result

对比两图可以发现，两类样本数据波形图差异并不明显，振荡窗口样本波形并未显示出明显的多频率叠加振荡特征。然而经 CWT 提取后，两类样本特征差异十分显著，稳态窗口样本呈现出一定的周期性变化，而振荡窗口样本在振荡发生前后呈现较大变化差异。两类样本特征的显著差异，更加有利于神经网络学习分类，并且振荡窗口样本在振荡发生前后的差异，有利于振荡发生时间的识别。

## 3 基于 Patchtst 的振荡检测与定时

### 3.1 基于 Patchtst 的神经网络模型概述

Patchtst 模型<sup>[16]</sup>基于 Transformer 模型<sup>[19][20]</sup>建立，引入通道独立性以及片段划分，计算更加轻量化，更加适用于振荡的在线检测与定时任务。本文设计基于 Patchtst 神经网络模型结构如图 5 所示：




图 5 Patchtst 模型示意图

Fig.5 Schematic diagram of Patchtst model

(1) 面向 CWT 结果频段的通道划分

本文使用经 CWT 特征提取后得到的时频矩阵  $X \in \mathbb{R}^{B \times T}$  作为 Patchtst 算法输入特征, 其中  $B$  和  $T$  代表频段数量以及时间步总数。对于输入特征  $X$ , 首先按照频段进行通道划分, 形成  $B$  个单变量序列  $X_i \in \mathbb{R}^{1 \times T}$ ,  $i=1, 2, \dots, B$ 。通过通道独立, 隔离频段之间相互干扰, 同时降低计算复杂度。

### (2) 面向 CWT 结果时序的片段划分

每个频段序列  $X_i$  被划分为  $n$  个片段  $X_{i,j} \in \mathbb{R}^{1 \times L}$ , 其中  $L$  为片段长度。本文划分片段无重叠区域, 片段长度  $L=T/n$ 。本文 CWT 分析窗口长度 0.2s, 对应 10 个基频 50Hz 周期, 本文按照基频周期进行片段划分, 即  $n=10$ 。

### (3) 基于 Transformer 的特征提取

完成划分后, 将每个片段特征  $X_{i,j}$  映射至  $d$  维特征空间。同时为保持特征之间相对位置信息, 每个片段嵌入位置编码, 位置编码具体采用正弦位置编码形式。完成位置嵌入后, 所有片段送入 Transformer 编码器, 通过多头注意力机制捕捉片段内周期性特征依赖, 进行高效的特征提取, 形成输出片段特征  $Y_{i,j}$ 。

### (4) 基于卷积网络的片段/通道交互及输出

经过 Transformer 模块后, 每个通道所有片段特征  $Y_{i,j}$  经过卷积神经网络进行融合, 捕捉各片段周期特征之间特征关系, 形成对应通道特征  $Y_i \in \mathbb{R}^{1 \times T}$ ; 之后, 所有通道特征经过另一个卷积层, 捕捉各频段之间特征关系, 形成经提取后的全局特征  $Y$ ; 特征  $Y$  进入输出层, 得到最终输出。

## 3.2 基于 Patchtst 的振荡检测及定时模型

在利用 CWT 进行振荡时频特征提取后, 本文构建两个基于 Patchtst 的神经网络模型, 分别用以完成振荡检测以及定时任务, 两个模型仅输出层结构不同, 其余部分网络结构保持一致。

第一个模型为振荡检测模型, 用于对窗内是否发生振荡进行判断分类, 是一个二分类模型, 输出层神经元个数为 2。模型训练阶段, 模型以交叉熵函数作为损失函数  $loss_1$ , 使用振荡窗口样本和稳定窗口样本共同作为训练样本, 用以模型训练。

$$loss_1 = -\frac{1}{n} \sum_{i=1}^n [y_i \log(p_i) + (1-y_i) \log(1-p_i)] \quad (7)$$

式中,  $y_i$  为第  $i$  个样本窗内是否发生振荡标签,  $p_i$  为模型预测概率,  $n$  为样本总数。

第二个模型为振荡定时模型, 在第一个振荡定时模型判断窗内发生振荡时投入, 用于拟合输出窗内振荡发生具体时间, 是一个拟合模型, 输出层神经元个数为 1。模型训练阶段, 模型以平均绝对百

分比误差函数作为损失函数  $loss_2$ , 训练样本只取振荡窗口样本。

$$loss_2 = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| * 100 \quad (8)$$

式中,  $y_i$  为第  $i$  个样本振荡发生时间实际值,  $y'_i$  为第  $i$  个样本振荡发生时间预测值。

## 3.3 Patchtst 模型与振荡检测与定时任务的适配性分析

振荡问题存在强周期性时序特征。Patchtst 模型基于 Transformer 进行振荡特征提取。与传统卷积 CNN 网络相比, Transformer 通过点乘方式实现不同位置特征之间的交互, 有效捕捉振荡周期性信号远距离时间点之间的特征依赖关系, 十分适用于分析次/超同步振荡检测与定时问题。

但正由于 Transformer 涉及矩阵点乘运算, 当时序数据采样频率较大时, 尤其是经过 CWT 变换后, 特征矩阵的维度变为  $B \times T$  (其中  $B$  和  $T$  代表频段数量以及时间步总数), 矩阵运算规模大, 所需计算时间显著增加, 难以满足在线快速性需求。Patchtst 通过通道独立以及片段划分的方式, 降低点乘运算输入矩阵维数, 提高计算速度, 更加适用于振荡在线检测定时。并且, 通过频段划分通道可以有效保留各频段时序特征, 同时避免不同频段之间无关特征交互干扰; 而按基频 50Hz 周期划分片段能有效捕捉振荡在每一工频周期内的全局周期性特征, 有利于振荡检测与定时。

## 4 算法流程

本文设计的振荡在线检测方法应用流程如图 6 所示, 分为“离线训练”以及“在线应用”两部分。




图 6 振荡在线检测与定时算法应用流程

Fig.6 Application process of oscillation online detection and timing method



### (1) “离线训练”阶段：

通过系统历史振荡数据或者仿真生成振荡数据，构建离线训练样本集。对于每组振荡数据，设定采样频率为 2kHz，采样窗长为 0.24s，不断改变采样窗起始时间，获取稳态样本集以及振荡样本集。两类样本经过本文第 2 节所述 CWT 过程进行时频特征提取。使用稳态和振荡窗口样本 CWT 结果对振荡检测网络进行训练，使用振荡窗口样本 CWT 结果对振荡定时网络进行训练。通过不断迭代，对两个网络进行梯度更新。本文设计网络模型的详细参数如表 1 所示。

表 1 网络参数设置

Table 1 Net parameters setting-up

| 网络层         | 网络参数                  |
|-------------|-----------------------|
| 映射 Linear   | 输出单元=32               |
| Transformer | 层数=2, 多头注意力头数=4       |
| 片段交互 Conv   | 滤波器数=1, 卷积核尺寸=3, 步长=1 |
| 通道交互 Conv   | 滤波器数=1, 卷积核尺寸=3, 步长=1 |
| 检测模型输出层     | 输出单元=2                |
| 定时模型输出层     | 输出单元=1                |

振荡检测模型以预测准确率  $A_{cc}$  作为性能评价指标，准确率数值越高，表示检测精度越高。准确率  $A_{cc}$  定义如式(9)所示。

$$A_{cc} = \frac{TP + TN}{T} \times 100\% \quad (9)$$

其中， $T$  为样本总数， $TP$  为模型预测和实际标签均为稳态的样本数量， $TN$  为模型预测和实际标签均为振荡发生的样本数量。

振荡定时模型以模型预测振荡发生时间  $t'_i$  与振荡实际发生时间  $t_i$  之间的平均绝对误差(Mean Absolute Error, MAE)作为评价指标，MAE 数值越低，表示定时精度越高。MAE 定义如式(10)所示：

$$MAE = \frac{1}{n} \sum_{i=1}^n |t'_i - t_i| \quad (10)$$

### (2) “在线应用”阶段：

电力系统在线运行过程，通过滑窗移动实时采集运行数据，将数据进行 CWT 时频特征提取。首先将 CWT 结果送入振荡检测模型，若判断未发生振荡，则继续滑窗采样；若判断发生振荡，将继续送入振荡定时模型，输出振荡发生时间预测。检测与定时的结果可以用于控制在线过程振荡辨识或抑制措施投入。

## 5 算例分析

本节通过直驱风电场仿真数据以及现场光伏实测数据，验证所提算法的精度以及通用性。本节在 PSCAD/EMTDC 仿真系统中构建四个场站并网

算例如图 7 所示。




图 7 四场站系统并网示意图

Fig.7 Four-station grid-connected system diagram

### 5.1 样本生成

在仿真算例中，不断调整各场站出力（0.8-1.0p.u.），使系统运行于不同工况。在不同工况下，于仿真时间 1.2-1.22s 范围内（模拟振荡起始于不同相位），随机时间设置场站参数改变扰动激发次/超同步振荡。本文共构建次/超同步振荡场景 192 个，均源自于自然谐振，造成振荡的原因是控制环节或系统电容/电感之间的能量交换。次/超同步振荡频率范围为 5-12Hz/88-95Hz。

本文选取分析对象为单一场站的出口 A 相电流运行数据。然而系统场站数量较多，样本构建难以覆盖所有场站，且每一场站单独训练模型训练成本较高。因此，本文使用系统中局部场站数据进行训练，构建系统场站通用振荡检测定时模型，训练后的模型可以直接应用于其他场站数据。

(1) 训练样本生成：本文选取场站 1 及场站 2 出口 A 相电流数据（图 7 中  $I_1$  和  $I_2$ ），用于网络训练。如第 4 节所述，设定采样频率为 2kHz，采样窗长为 0.24s，每个振荡场景下，多次设置不同采样窗口起始时间，以获取不同稳态及振荡发生样本。针对  $I_1$  和  $I_2$ ，各自获取 960 个稳态窗口样本，以及 1728 个振荡窗口样本，振荡样本中振荡时间覆盖窗内 0.02-0.22s。所有样本按照 7: 3 的比例随机划分训练集与验证集，用于神经网络训练及评估。

(2) 其他场站通用性测试样本生成：本文选取场站 3 和场站 4 出口 A 相电流数据（图 7 中  $I_3$  和  $I_4$ ），用于测试模型面对系统其他场站数据的通用性。与训练样本相同，每个振荡场景下，多次设置不同采样窗口起始时间，获取不同稳态及振荡发生样本。 $I_3$  和  $I_4$  变量样本分布与训练样本相同。

### 5.2 算法与 FFT 时效性对比

由于本文所提方法依赖于滑窗数据采集，因此所提方法时效性（振荡发生到实现振荡检测定时所需时间）受滑窗位置影响。图 8 展示了其中一个样本在振荡发生前后不同时刻 FFT 分析结果。该样本

1.2s 时发生振荡(如图中红线所示)。如 2.2 节所述,本文所提算法窗长为 0.24s(图 8 中绿色框),为避免 CWT 边界效应,仅截取窗内 0.02-0.22s 数据(图 8 中黄色框)作为分析窗进行检测定时。滑窗移动过程中,当振荡发生时间恰好位于分析窗起始位置时(如图 8 所示),所提方法所需采集振荡发生后时序数据最长,此种情况下所提方法时效性最差。

但即便在此范围内,FFT 分析结果与振荡发生前结果相比并无明显变化。因此,在所提方法所需采样窗内,FFT 算法无法检测到振荡发生。可以证明,本文所提算法时效性优于 FFT 算法。




图 8 振荡发生前后 FFT 结果

Fig. 8 FFT results before and after oscillation

进一步考虑算法所需计算时间,表 2 展示了所提算法与 FFT 算法在线应用过程中计算所需时间。所提算法计算时间包括数据读取(.npz 文件)、CWT 特征提取、检测模型与定时模型计算。计算程序采用 python 语言基于 Pytorch 框架建立,计算机处理器为 Intel(R) Core(TM) i7-8700 CPU @ 3.20GHz。

如表 2 所示,尽管本文所提算法计算时间大于 FFT 所需计算时间,但本文算法计算总时间 0.1585s,低于本文设计滑窗移动步长 0.2s,在线过程中并不会因计算时间而产生时间滞后,可以满足在线应用需求。

表 2 所提算法与 FFT 算法在线应用计算时间对比

Table 2 Comparison of calculation time between the proposed method and FFT for online application

| 算法   | 所需时间/s |
|------|--------|
| FFT  | 0.0256 |
| 所提算法 | 0.1585 |

此外,在数据采集方面,本文所提算法与 FFT 算法一致,均仅需采集单一电气量数据(A 相电流),并不会增加数据采集成本。

### 5.3 算法精确度分析

训练过程中,检测与定时模型学习率分别为 0.002 与 0.001,迭代次数与批大小均为 50。经过训

练,模型最终在验证集上检测精度  $A_{cc}$  达到 99.75%,定时任务精度 MAE 达到 0.0155s,时间误差限制在一个工频周期内,证明所述算法可以很好的完成振荡检测与定时任务。

将振荡发生预测时间之后 0~0.2s 的数据,送入上文 1.1 节所述的基于卷积神经网络的振荡主导频率辨识模型进行分析,模型预测频率平均偏差为 1.91Hz,与训练样本预测频率平均误差相比仅增加 0.50Hz,由此可以证明本文所提振荡检测定时算法可以保证振荡辨识类算法的在线应用。

表 3 在线应用所需计算时间

Table 3 Calculation time required for online application

| 模型              | 所需时间/s |
|-----------------|--------|
| CWT+Transformer | 0.2238 |
| 所提算法            | 0.1585 |

表 3 展示了在线应用过程中,所提算法与 CWT + Transformer 计算所需时间对比。如表 3 所示,本文所提算法计算总时间为 0.1585s,低于本文设计滑窗移动步长 0.2s,可以满足在线滑窗分析时间要求。而 Transformer 算法则难以满足滑窗时间需求。由此可以证明 Patchtst 模型较 Transformer 模型计算更加轻量化,更好满足在线时效性需求。

为验证本文所提 CWT 时频特征提取过程有效性,本文设计无 CWT 过程、运行数据直接通过 Patchtst 模型进行检测与定时的算法作为对比实验。对比实验输入为一维时序数据,没有通道划分及通道交互过程,其余部分与所提算法结构相同。对比结果如表 4 所示。可以看出,通过 CWT 过程,检测精度  $A_{cc}$  提升 9.73%,定时 MAE 误差降低 0.0057s,由此可以证明 CWT 过程对检测与定时任务精度有较强的提升能力。

表 4 有无 CWT 过程检测与定时准确度对比

Table 4 Comparison of detection and timing accuracy with and without CWT process

| 实验           | 检测 $A_{cc}/\%$ | 定时 MAE/s |
|--------------|----------------|----------|
| Patchtst     | 90.02          | 0.0212   |
| CWT+Patchtst | 99.75          | 0.0155   |

为进一步验证 CWT 过程对于振荡检测任务有效性,本文使用 t-SNE 算法<sup>[21]</sup>对经 CWT 过程前后振荡发生窗口与稳态窗口样本分布进行可视化分析。

图 9(a)展示了未进行 CWT 过程原始振荡与稳态数据特征分布,图 9(b)展示了经过 CWT 变换过程后振荡与稳态样本特征分布。对比可知,在未进行 CWT 过程时,振荡与稳态样本波形数据分布较为分散,有较大重叠区域。经过 CWT 过程后,振



荡与稳态样本分布各自形成更为紧密的聚集，两者重叠区域减少。结果表明 CWT 能够提高振荡与稳态样本间的差异，更加利于后续神经网络分类。




图 9 CWT 前后振荡与稳态样本特征分布

Fig. 9 The distribution of oscillation and steady-state sample characteristics before and after CWT

此外，为验证模型决策机制的可信度与合理性，本文基于梯度分析方法开展了模型可解释性研究。图 10(a)-(b)分别展示了一组具有代表性的稳态窗口样本和振荡窗口样本的梯度分布可视化结果，其中颜色强度反映了输入特征片段对模型决策的重要性（红色越深，表明越为重要）。




图 10 两类样本模型输出对输入特征梯度

Fig.10 Model output versus input feature gradient of two type sample

分析结果表明：图 10(a)所示的稳态样本中，各通道的关键特征片段（红色区域）并无明显集中区域；而图 10(b)的振荡样本则表现出关键片段集中于信号后段。从物理角度来说，稳态窗口样本中各时段数据特征差异较小（如图 4(d)CWT 特征提取结果），因此模型无需关注特定时段；相反，振荡窗口样本在振荡发生后呈现显著的数据变化

（如图 3(d)CWT 特征提取结果），振荡后的特征对振荡检测具有决定性作用，模型理应重点关注振荡发生后数据特征。可视化结果与这一物理机理高度吻合，有效验证了模型的可信度。

为验证本文所提基于 Patchtst 神经网络检测与定时性能，本文设计深度信念网络（Deep Belief Network, DBN）<sup>[22]</sup>以及 Transformer 网络作为对比神经网络，分别设置三种模型的有/无 CWT 实验。表 5 对比了 6 种实验的检测与定时精度。

| 表 5 不同算法检测与定时准确度对比                                                          |                 |          |          |
|-----------------------------------------------------------------------------|-----------------|----------|----------|
| Table 5 Comparison of detection and timing accuracy of different algorithms |                 |          |          |
| 序号                                                                          | 实验              | 检测 Acc/% | 定时 MAE/s |
| 1                                                                           | DBN             | 81.28    | 0.0448   |
| 2                                                                           | CWT+DBN         | 97.58    | 0.0404   |
| 3                                                                           | Transformer     | 63.05    | 0.0446   |
| 4                                                                           | CWT+Transformer | 99.75    | 0.0223   |
| 5                                                                           | Patchtst        | 90.02    | 0.0212   |
| 6                                                                           | CWT+Patchtst    | 99.75    | 0.0155   |

根据表 5 可以看出，除与实验 4 检测精度持平外，对比其他算法，本文所提算法（实验 6）检测与定时最为精确。另外，单独对比第 1、3、5 组实验，及第 2、4、6 组实验，可以发现无论有无 CWT 过程，与 DBN 以及 Transformer 模型相比，本文应用的 Patchtst 神经网络精度均保持最高，由此可以证明本文所提 Patchtst 可以更高性能地完成振荡检测与定时任务。此外，分别对比三种网络结构下有/无 CWT 实验，可以发现三种网络结构下，CWT 特征提取过程均可以提高检测与定时任务精度。

#### 5.4 其他场站通用性分析

如 5.1 节所示，本文构建了场站 3 与场站 4 出口 A 相电流窗口采样测试样本，用以测试基于局部场站数据训练好的模型面向其他场站数据的通用性。表 6 展示了表 5 中不同训练好的模型处理测试样本的检测与定时精度。

| 表 6 不同模型其他场站通用性对比                                                          |                 |          |          |
|----------------------------------------------------------------------------|-----------------|----------|----------|
| Table 6 Comparison of universality of other wind farms in different models |                 |          |          |
| 序号                                                                         | 模型              | 检测 Acc/% | 定时 MAE/s |
| 1                                                                          | DBN             | 81.32    | 0.0455   |
| 2                                                                          | CWT+DBN         | 96.69    | 0.041    |
| 3                                                                          | Transformer     | 64.29    | 0.0448   |
| 4                                                                          | CWT+Transformer | 98.74    | 0.0239   |
| 5                                                                          | Patchtst        | 87.17    | 0.0235   |
| 6                                                                          | CWT+Patchtst    | 98.74    | 0.0162   |

由表 6 可以看出，基于所提算法训练好的模型（实验 6）在面向场站 3 和场站 4 通用性测试样本时，检测精度维持在 98.74%，定时 MAE 误差维持在 0.0162s。除与实验 4 检测精度持平外，所提算法

检测与定时精度均高于其他算法实验,展现出更好的其他场站通用性。

### 5.5 场站切除工况下通用性分析

现实工程中,新能源场站可能因检修或故障等原因而从系统中切除,此时振荡检测定时模型应该依旧保持适用性。因此,为验证在某一场站切除情况下,训练后的模型依旧具备通用性。本文设计切除图 7 中的场站 4,在此情况下,参照上述方法引发振荡,共获取 48 个振荡场景,针对  $I_1$ 、 $I_2$  和  $I_3$  进行窗口采样,各自获取 240 个稳态窗口样本,以及 432 个振荡发生窗口样本。表 7 展示了表 5 中不同训练好的模型处理此类样本的检测与定时精度。

| 表 7 场站切除情况下不同模型通用性对比<br>Table 7 Comparison of universality of different models in the case of station resection |                 |          |          |
|-----------------------------------------------------------------------------------------------------------------|-----------------|----------|----------|
| 序号                                                                                                              | 实验              | 检测 Acc/% | 定时 MAE/s |
| 1                                                                                                               | DBN             | 80.75    | 0.0453   |
| 2                                                                                                               | CWT+DBN         | 87.95    | 0.0464   |
| 3                                                                                                               | Transformer     | 64.29    | 0.045    |
| 4                                                                                                               | CWT+Transformer | 88.74    | 0.0258   |
| 5                                                                                                               | Patchtst        | 89.98    | 0.0315   |
| 6                                                                                                               | CWT+Patchtst    | 90.43    | 0.0214   |

由表 7 可以看出,所提算法模型在面向场站切除工况样本时,尽管检测与定时精度有所下降,但依旧高于其他模型,所提模型展现出更好的场站切除工况下通用性。

### 5.6 其他场景通用性验证

本文使用山东某地区 10kV 配电网系统中实际光伏逆变器实测 A 相电流振荡数据作为模型输入(如图 11 所示),用以验证所训练好的模型面向现场实际振荡的通用性。现场引发振荡时,频率为 28/72Hz,振荡引发机理为光伏出力改变,振荡频率和产生机理与上文仿真振荡数据存在差异。但是不论是仿真数据还是实测数据,利用所提方法均能实现准确快速的振荡检测定时。表 8 展示了表 5 中不同训练好的模型处理实测数据样本的检测与定时精度。






图 11 光伏现场实测装备示意图


Fig. 11 The schematic diagram of photovoltaic field measurement equipment



(a) 实测数据波形图



(b) 稳态窗口CWT结果



(c) 振荡窗口CWT结果

图 12 实测数据波形图与两类样本 CWT 特征提取结果  
Fig. 12 The waveform of the measured data and the CWT feature extraction results of the two types of samples

表 8 不同模型实测光伏数据检测与定时精度对比  
Table 8 Comparison of data detection and timing accuracy of PV power measured data in different models

| 序号 | 实验              | 检测 Acc/% | 定时 MAE/s |
|----|-----------------|----------|----------|
| 1  | DBN             | 85.71    | 0.0729   |
| 2  | CWT+DBN         | 92.86    | 0.0781   |
| 3  | Transformer     | 64.29    | 0.0479   |
| 4  | CWT+Transformer | 92.86    | 0.0467   |
| 5  | Patchtst        | 35.71    | 0.0654   |
| 6  | CWT+Patchtst    | 100      | 0.0246   |

由表 8 可以看出,所提算法模型在面向实测数据时,振荡检测正确率达到 100%,定时精度为 0.0246,检测与定时依旧均高于其他模型,所提模型展现出更好的实测数据通用性。

## 6 结论

为实现次/超同步振荡在线快速检测,本文提出一种基于 CWT+Patchtst 模型的短时滑窗振荡检测与定时方法,用以判断振荡是否发生及识别发生具体时间,具备很好的时效性以及通用性。本文主要结论如下:

1) 基于 CWT 算法构建时频特征提取过程,有效提升稳态窗口样本与振荡窗口样本之间差异,有利于神经网络学习。

2) 基于 Patchtst 神经网络构建适用于振荡在线检测与定时的神经网络模型, 有效提升振荡检测与定时精度。

3) 通过算例分析, 证明了基于局部风场仿真数据训练的所提算法模型展现出较高的精度, 同时模型具备其他场站、场站切除工况下以及现场光伏实测数据的通用性。

本文所提对振荡样本进行 CWT 时频特征提取方法, 可扩展至振荡辨识与定位问题之中。

## 参考文献

- [1] 胡光, 庄可好, 高晖胜, 等. 低惯量交流系统并网变流器次/超同步振荡分析[J]. 电工技术学报, 2024, 39(08): 2250-2264.  
Hu Guang, Zhuang Kehao, Gao Huisheng, et al. Sub/Super Synchronous Oscillation Analysis of Grid-Connected Converter in Low Inertia AC System[J]. Transactions of China Electrotechnical Society, 2024, 39(08): 2250-2264 (in Chinese).
- [2] Wang Yuzhi, Wang Liang, Jiang Qirong. Impact of Synchronous Condenser on Sub/Super-Synchronous Oscillations in Wind Farms[J]. IEEE Transactions on Power Delivery, 2021, 36(4): 2075-2084.
- [3] Surinkaw T, Shah R, Nadarajah M, et al. Forced Oscillation Detection Amid Communication Uncertainties[J]. IEEE Systems Journal, 2021, 15(3): 4644-4655.
- [4] 于鹏, 郭国先, 杨晓明, 等. 基于多元经验模态分解的风电并网系统次同步振荡检测[J]. 可再生能源, 2024, 42(06): 781-788.  
Yu Peng, Guo Guoxian, Yang Xiaoming, et al. Subsynchronous oscillation detection in wind power system using multivariate empirical mode decomposition[J]. Renewable Energy Resources, 2024, 42(06): 781-788 (in Chinese).
- [5] 张晓雪, 张放, 史静舒. 基于同步相量的次/超同步振荡参数辨识探究: 非频谱分析方法的契机和挑战[J]. 中国电机工程学报, 2025, 45(12): 4578-4593.  
Zhang Xiaoxue, Zhang Fang, Shi Jingshu. Research on Sub/Supersynchronous Oscillation Parameter Identification Based on Synchrophasor: The Potential Opportunities and Challenges of Non-spectral Analytical Techniques[J]. Proceedings of the CSEE, 2025, 45(12): 4578-4593 (in Chinese).
- [6] Wen He, Guo Siyu, Teng Zhaozheng, et al. Frequency Estimation of Distorted and Noisy Signals in Power Systems by FFT-Based Approach[J]. IEEE Transactions on Power Systems, 2014, 29(2): 765-774.
- [7] 吴艳平, 姚建国, 常乃超, 等. 多功能宽频测量装置的设计与实现[J]. 电力系统自动化, 2020, 44(20): 136-141.  
Wu Yanping, Yao Jianguo, Chang Neichao, et al. Design and Implementation of Multi-functional Wide-frequency Measurement Device[J]. Automation of Electric Power Systems, 2020, 44(20): 136-141 (in Chinese).
- [8] Yalcin N A, Vatansever F. A New Hybrid Method for Signal Estimation Based on Haar Transform and Prony Analysis[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-9.
- [9] 王杨, 晁苗苗, 谢小荣, 等. 基于同步相量数据的次同步振荡参数辨识与实测验证[J]. 中国电机工程学报, 2022, 42(03): 899-909.  
Wang Yang, Chao Miaomiao, Xie Xiaorong, et al. Identification of Subsynchronous Oscillation Parameters and Field Tests Based on PMU Data[J]. Proceedings of the CSEE, 2022, 42(03): 899-909 (in Chinese).
- [10] 张放, 刘军, 李佳欣, 等. 基于同步相量轨迹拟合的电力系统次同步/超同步振荡的实时参数辨识[J]. 中国电机工程学报, 2023, 43(04): 1413-1426.  
Zhang Fang, Liu Jun, Li Jiaxin, et al. Real-time Parameter Identification With Synchrophasor Trajectory Fitting Technique for Subsynchronous/Supersynchronous Oscillations in Power Systems[J]. Proceedings of the CSEE, 2023, 43(04): 1413-1426 (in Chinese).
- [11] 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(03): 187-192.  
Zhao Yan, Cui Haohan, Rong Zichao. On-line Monitoring of Subsynchronous Oscillation Based on Synchroextracting Transform and Naïve Bayes Method[J]. Automation of Electric Power Systems, 2019, 43(03): 187-192 (in Chinese).
- [12] Chen Junan, Chen Yingjie, Luo Feng, et al. Intelligent Identification Method of Sub/Super-synchronous Oscillation Parameters Based on CNN and Synchrophasor[C]. 2024 9th Asia Conference on Power and Electrical Engineering (ACPEE), Shanghai, China, 2024: 1412-1416.
- [13] Ye Shenyong, Wei Jun, Xu Zihao, et al. LSTM-Based Rapid Identification of Dominant Low Frequency Oscillation Modal Features in Power System[C]. 2020 IEEE 4th Conference on Energy Internet and Energy System Integration (EI2), Wuhan, China, 2020: 2455-246.
- [14] 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.
- [15] Fang Jiashu, Kong Lingran, Li Aobing, et al. A Novel Transfer Learning Method for Sub/Super-Synchronous Oscillation Mode Identification in Power Systems[J]. IEEE Internet of Things Journal, 2025, 12(11): 18385-18396.
- [16] Nie Y, Nguyen N, Sinthong P, et al. A time series is worth 64 words: long-term forecasting with transformers[C]. The Eleventh International Conference on Learning Representations, ICLR 2023, Kigali, Rwanda, 2023.
- [17] 胡从强, 曲娜, 张帅, 等. 连续小波变换和具有注意力机制的深度残差收缩网络在低压串联电弧故障检测中的应用[J]. 电网技术, 2023, 47(05): 1897-1905.  
Hu Congqiang, Qu Na, Zhang Shuai, et al. Application of Continuous Wavelet Transform and Deep Residual Shrinkage Network With Attention Mechanism in Detection of Low Voltage Series Arc Fault[J]. Power System Technology, 2023, 47(05): 1897-1905 (in Chinese).
- [18] Wan Tianyu, Zhang Meng, Wang Guodong, et al. Harmonic Extraction Method With Continuous Wavelet Transform Based on the Prior Knowledge of Wavelength Modulation Spectroscopy and Shift Strategy[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-12.
- [19] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]. Proceedings of the 31st International Conference on Neural Information Processing Systems Long Beach: Curran Associates Inc., 2017: 6000-6010.
- [20] 房佳殊, 刘崇茹, 苏晨博, 等. 基于自注意力 Transformer 编码器的多阶段电力系统暂态稳定评估方法[J]. 中国电机工程学报, 2023, 43(15): 5745-5759.  
Fang Jiashu, Liu Chongru, Su Chenbo, et al. Multi-stage Transient Stability Assessment of Power System Based on Self-attention Transformer Encoder[J]. Proceedings of the CSEE, 2023, 43(15): 5745-5759 (in Chinese).
- [21] Van der Maaten L, Hinton G. Visualizing Data Using TSNE[J]. Journal of Machine Learning Research, 2008, 9(Nov): 2579 - 2605.
- [22] Wu Shuang, Zheng Le, Hu Wei, et al. Improved Deep Belief Network and Model Interpretation Method for Power System Transient Stability Assessment[J]. Journal of Modern Power Systems and Clean Energy, 2020, 8(1): 27-37.





刘崇茹

收稿日期: 2025-06-13。

作者简介:

刘崇茹(1977), 女, 博士, 教授, 博士生导师, 研究方向为交直流混合输电系统分析与仿真、运行与控制, E-mail: ; chongru.liu@ncepu.edu.cn

孔令然(2001), 男, 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: donald202209@163.com。

苏晨博(1991), 男, 通信作者, 博士, 研究方向为新能源并网系统稳定、控制及仿真研究, E-mail: scb2636@foxmail.com。

(责任编辑 马晓华)

中国知网

# 附录 A

在仿真算例中, 本文使用风电场单机模型系统进行建模, 风机内部结构采用如图 A1 所示的典型直驱风机简化结构:




图 A1 直驱风机电路及控制环节结构图

Fig. A1 Topology and control of PMSG

图中,  $C_{dc}$  表示直流电容,  $L_g$  和  $C_f$  分别表示交流测电容和电感,  $R_d$  表示接地电阻,  $u_{dc}$  表示直流电压,  $u_{abc}$  和  $i_{abc}$  分别表示交流侧三相电压和电流,  $P_{in}$  为输入功率,  $m_a, m_b, m_c$  表示 PWM 生成的调制信号。PLL、DVC 和 CC 分别表示锁相环、电压外环和电流内环控制环节, 具体控制结构如图 A2 所示。仿真模型相关参数设置如表 A1 所示。




图 A2 PLL, DVC, CC 控制环节图

Fig. A2 Control of PLL, DVC, CC

表 A1 风机参数统计表

Table A1 Statistical table of PMSG

| 系统环节 | 参数名称       | 数值              |
|------|------------|-----------------|
| 拓扑参数 | $C_{dc}$   | 15000 $\mu$ F   |
|      | $L_g$      | 0.00015H        |
|      | $C_f$      | 500 $\mu$ F     |
|      | $R_d$      | 0.06 $\Omega$   |
| PLL  | 增益系数 $K_p$ | 50              |
|      | 积分系数 $K_i$ | 100             |
| DVC  | 增益系数 $K_1$ | 1               |
|      | 积分系数 $T_1$ | 0.02            |
| CC   | 增益系数 $K_2$ | 0.5             |
|      | 积分系数 $T_2$ | 0.05            |
| 电网   | $L_{f1}$   | 0.00025H        |
|      | $L_{f2}$   | 0.0001H         |
|      | $L_{f3}$   | 0.0002H         |
|      | $L_{f4}$   | 0.00015H        |
|      | $L_1$      | 0.1H            |
|      | $Z_2$      | 0.1349 $\Omega$ |