

DOI: 10.19783/j.cnki.pspc.200897

# 基于卷积神经网络的电力系统低频振荡主导模态特征定性辨识

秦心筱<sup>1</sup>, 张昌华<sup>1</sup>, 徐子豪<sup>1</sup>, 李乾宇<sup>1</sup>, 魏俊<sup>2</sup>, 叶圣永<sup>2</sup>

(1. 电子科技大学机械与电气工程学院, 四川 成都 611731;

2. 国网四川省电力公司经济技术研究院, 四川 成都 610072)

**摘要:** 低频振荡严重威胁电网的安全稳定运行。传统低频振荡辨识方法大都将被测信号视作平稳信号或进行平稳化处理, 忽略了信号的非平稳特性。但在高比例新能源和电力电子设备的电力系统中, 低频振荡参数具有大范围时变的特性, 传统辨识方法难以准确识别。提出了一种基于卷积神经网络(CNN)的电力系统低频振荡辨识方法。首先对原始信号进行时域特征提取作为预处理操作, 然后将 16 个时域特征的信号分别送入训练好的 CNN 网络, 最后由全连接层综合各个网络的输出得到最终辨识结果。仿真实验表明, 该方法可以快速准确地辨识出低频振荡信号的频率和衰减因子, 具有很好的抗噪性。且与 Prony 方法相比, 它能够辨识振荡过程中是否引入了新的振荡模态。

**关键词:** 电力系统; 低频振荡; 卷积神经网络; Prony; 非平稳性; 新能源发电

## Research on qualitative identification of a low frequency oscillations dominant mode in power system based on a convolutional neural network

QIN Xinxiao<sup>1</sup>, ZHANG Changhua<sup>1</sup>, XU Zihao<sup>1</sup>, LI Qianyu<sup>1</sup>, WEI Jun<sup>2</sup>, YE Shengyong<sup>2</sup>

(1. School of Mechanical and Electrical Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China; 2. State Grid Sichuan Economic Research Institute, Chengdu 610072, China)

**Abstract:** Low Frequency Oscillation (LFO) seriously threatens the stability and security of a power grid. Most traditional LFO identification methods regard the measured signals as stationary signals or process them as stationary signals. This ignores their non-stationary characteristic. However, in a power system with high proportion of renewables and power electronics, LFO parameters have a wide range of time-varying characteristics. Traditional methods find it difficult to identify them accurately. This paper proposes a low frequency oscillation identification method based on a Convolutional Neural Network (CNN). First, the time domain features of the original signals are extracted as a preprocessing operation. Then, 16 signals of different time-domain characteristics are sent to the trained CNN networks. Finally, the full connection layer synthesizes the outputs of each network to obtain the final identification results. Simulation results show that this method can identify the frequency and damping factor of LFO signals quickly and accurately, and has good anti-noise performance. In contrast to the Prony method, it can identify whether a new oscillation mode is introduced in the process of oscillation.

This work is supported by the Key Research and Development Program of Sichuan Science and Technology Department (No. 2019YFG0142) and Science and Technology Project of State Grid Sichuan Electric Power Economic and Technological Research Institute (No. SGSCJY00GHJS2000015).

**Key words:** power system; low frequency oscillation; convolutional neural network (CNN); Prony; non-stationary; renewable energy

## 0 引言

随着电网规模日渐扩大、长距离交直流系统互

联、可再生能源并网发电比例的提高, 电力系统低频振荡的潜在危险日益显现, 电力系统发生低频振荡的现象层出不穷, 严重危及电力系统的安全稳定运行。如: 2003 年美加联合电网因线路跳闸引起输送功率振荡, 最终导致大面积停电事故<sup>[1]</sup>; 2008 年云南文山地区因其东部电网 110 kV 线路跳闸导致系统发生欠阻尼低频振荡; 2010 年贵州思林发电厂

基金项目: 四川省科技厅重点研发计划资助(2019YFG0142); 国网四川省电力公司经济技术研究院科技项目资助(SGSCJY00GHJS2000015)

在升负荷过程中因电力系统稳定器异常退出, 导致欠阻尼低频振荡<sup>[2-3]</sup>。低频振荡的发生, 往往会触发输电线路的距离保护, 严重时则会损坏设备, 甚至导致系统解列。因此, 低频振荡一直是电力工作者所关心的问题。

低频振荡特征辨识是低频振荡抑制的前提。目前电力系统低频振荡特征辨识主要是模态辨识, 对应的方法可以分为基于模型的方法和基于实测信号的方法<sup>[4]</sup>。由于无需系统精确的模型和参数, 后者在电力系统中得到了广泛应用。常见的算法有基于快速傅里叶变换(FFT)<sup>[5]</sup>、经验模式分解<sup>[6]</sup>、Prony<sup>[7]</sup>、希尔伯特-黄变换(HHT)<sup>[8]</sup>的算法以及近年来发展起来的借助旋转不变技术估计信号参数(Estimation of Signal Parameters via Rotational Invariance Technique, ESPRIT)<sup>[9-11]</sup>、矩阵束方法(Matrix Pencil algorithm, MP)<sup>[12-13]</sup>和随机子空间方法(Stochastic Subspace Identification, SSI)<sup>[14-15]</sup>等。经过多年的研究与改进, 这些方法可以较为准确地获取系统的模态, 在抗噪性上也有一定的效果, 但大都将被测信号视作平稳信号, 在辨识的数学机理上忽略了信号的非平稳特性<sup>[16-17]</sup>。不仅如此, 这些方法往往要求采集数十秒的数据才可辨识<sup>[5-15]</sup>。随着可再生能源并网比例的提高以及大量的电力电子设备接入电网, 由于可再生能源出力往往具有随机性、间歇性和不可控性以及电力电子设备有别于传统同步发电机的快速动态响应特性<sup>[18-20]</sup>, 系统状态灵活多变, 振荡的频率、阻尼或稳定性受诸多因素影响, 具有大范围时变的特征<sup>[21]</sup>。在这种背景下, 数十秒采样时间内的信号近似平稳的假设难以成立, 亟需发展新的低频振荡辨识方法来适应电力系统的发展。

近年来, 深度学习(Deep Learning, DL)发展迅猛, 在众多领域已经得到了成功的应用。在低频振荡辨识方面, 也有学者开展了探索性的研究。文献[3,22]使用深度学习算法分别辨识低频振荡的阶数和振荡模式是区域振荡还是局部振荡。文献[23]提出指数型衰减正弦神经网络(Exponentially Damped Sinusoids Neural Network, EDSNN)的辨识方法。本文基于卷积神经网络(Convolutional Neural Network, CNN), 从定性的角度提出了一种低频振荡快速辨识的方法, 兼顾了辨识的快速性与准确性。通过仿真分析, 验证了本文算法的辨识精度和抗噪性能, 并以振荡过程中引入新的振荡模态为例, 验证了算法在辨识非平稳信号方面的能力。所做研究, 对于非平稳低频振荡信号的辨识具有一定的借鉴意义。

## 1 卷积神经网络的原理

卷积神经网络(Convolutional Neural Networks, CNN)是深度学习最具代表性的算法之一。该算法以卷积运算为基础, 结合传统层级神经网络实现特征自动提取、数据降维并最终达到识别参数的目的。迄今为止, CNN 在人脸识别、语音辨识等领域取得了空前的成功<sup>[24]</sup>, 在电力领域也已有应用<sup>[25]</sup>。

### 1.1 CNN 网络的结构

在结构上, 卷积神经网络由输入层、卷积层、池化层、激活函数层、全连接层和输出层组成。输入层为预处理后的数据, 输出层为最终结果, 卷积层、池化层与激活函数层共同组成 CNN 的一个隐藏层。一个 CNN 网络一般由多个隐藏层组成。

#### 1) 卷积层

卷积层是整个 CNN 中最重要的一层。卷积层是将原始数据映射到隐层的特征空间。它将输入数据或上一层的输出与多个卷积核(convolution kernel)进行卷积运算。每个卷积核产生的输出可以表示为

$$Y_{i,j} = \sum_{m=1}^M \sum_{n=1}^N x_{i+m-1,j+n-1} k_{m,n} \quad (1)$$

式中:  $i=1,2,3,\dots,I$ ;  $j=1,2,3,\dots,J$ ;  $I=P-M+1$ ,  $J=Q-N+1$ ,  $P$ 、 $Q$  是输入矩阵  $X$  的尺寸;  $k_{m,n}$  是  $M \times N$  的卷积核  $K$  的第  $m$  行、第  $n$  列的元素,  $x_{i+m-1,j+n-1}$  是输入矩阵  $X$  中的第  $i+m-1$  行、第  $j+n-1$  列的元素。每个卷积核都会产生一个  $I \times J$  的输出矩阵  $Y$ 。

#### 2) 激活函数

为了使神经网络能适用于非线性模型, 通常在卷积层后加入激活函数层。一般情况下, 选取 tanh 函数作为激活函数, tanh 函数是一个 0 均值函数, 其输出和输入保持非线性单调上升和下降的关系, 且输出值保持在(-1,1)范围内。其特征方程为

$$\tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

#### 3) 池化层

池化层是 CNN 有别于传统神经网络的重要特征之一, 也是 CNN 高效率的原因之一<sup>[24]</sup>。CNN 的池化层可以缩小数据尺寸, 减少全连接层的参数, 达到减小计算量, 加速训练的作用。池化方式一般有最大池化和平均池化两种。将池化前的矩阵划分为多个尺寸相同的池化区域, 最大池化将每个池化区域的最大值组成新的尺寸更小的矩阵; 平均池化将每个池化区域的平均值组成新的尺寸更小的矩阵。本文使用平均池化方法, 公式为

$$u = \frac{1}{S_R} \sum_{i,j \in R} y_{i,j} \quad (3)$$

式中,  $S_R$  是池化区域面积, 即池化区域元素个数。

#### 4) 全连接层

和卷积层仅对局部特征提取不同, 全连接层是将特征空间映射到样本的标记空间, 可以将众多局部特征组合分析得到最终结果。全连接层结构如图 1<sup>[3]</sup>, 其输出可以表示为

$$h_n = b_n + \sum_{m=1}^M v_m \times w_{mn} \quad (4)$$

式中:  $h_n$  是输出神经元的值;  $v_m$  是输入神经元的值;  $w_{mn}$  是链接权值;  $b_n$  是偏置。

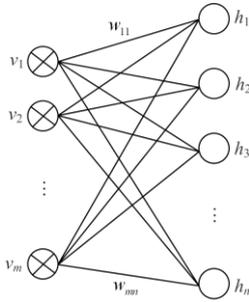


图 1 全连接层结构

Fig. 1 Structure of full connection layer

### 1.2 CNN 网络的训练

#### 1) 参数更新方法

CNN 网络参数更新采用当前广泛应用的反向传播(Back Propagation, BP)算法。网络训练分为信息正向传播和误差反向传播两个过程。正向传播时, 待训练的输入信号经过卷积层等隐藏层得到输出值; 反向传播时, BP 算法根据网络输出值与训练样本实际值的误差调整网络权重  $w_{mn}$  和卷积核参数<sup>[20]</sup>。BP 网络的参数更新过程如图 2。

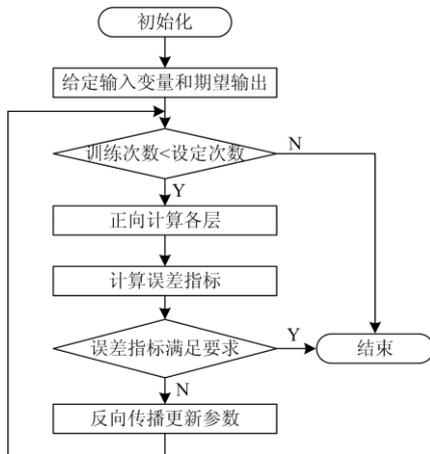


图 2 BP 网络参数更新过程

Fig. 2 Process of BP network parameter updating

#### 2) 正则化

当 CNN 网络的表征力过强, 会产生训练集识别效果好于测试集识别效果的过拟合现象<sup>[3]</sup>。为了防止 CNN 网络产生过拟合现象, 需要对 CNN 网络中的全连接层引入正则化(regularization)。

本文的正则化选择 dropout 随机失活的方法。dropout 随机失活方法是在每一次的训练中以概率  $p$  舍弃神经元及其链接的权值, 每次舍弃的神经元又是随机的, 从而防止过拟合, 提升模型泛化能力。

### 2 基于 CNN 的电力系统低频振荡特征辨识

低频振荡信号频率范围为 0.1~2.5 Hz<sup>[3]</sup>。一般而言, 其数学描述可为

$$x(t) = \sum_{i=1}^q A_i e^{-\alpha_i t} \sin(\omega_i t + \theta_i) \quad (5)$$

式中:  $A_i$  为幅值;  $\alpha_i$  为衰减系数;  $\omega_i = 2\pi \times f_i$  为角频率;  $\theta_i$  为初始相位;  $q$  为低频振荡信号的阶数。

#### 2.1 低频振荡参数识别流程

参数识别流程图如图 3, 原始信号通过信号预处理得到  $n$  个二维特征矩阵。 $n$  的大小和信号预处理所选取的特征有关(本文  $n$  为 16)。将这  $n$  个矩阵分别作为  $n$  个二维 CNN 网络的输入, CNN 网络的输出再作为全连接层的输入, 最后进入 softmax 分类器进行分类。

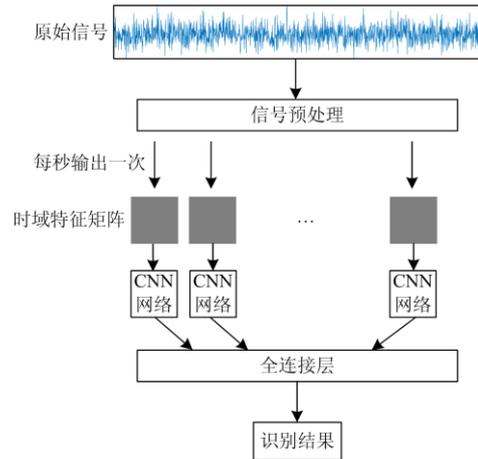


图 3 特征识别流程

Fig. 3 Process of characteristic identification

其中, 信号预处理操作中, 5 s 原始信号可以产生一组特征数据。每秒输出一组数据并进入 CNN 网络识别。这个过程持续进行, 从而实现了滑窗取样的效果。CNN 网络则负责进行深层次的特征提取。softmax 是进行多目标分类的函数, 它以概率的形式输出, 概率最大的那一项即为输入所属的类别, 最终输出层个数即为设定的分类数, 从而实现了定

性的辨识。

### 2.2 信号预处理

信号预处理是对原始信号的第一次时域特征提取,同时还可以在一定程度上滤除噪声的影响。低频振荡信号本身是一种时域信号,可以通过时域特征提取作为预处理操作<sup>[26]</sup>。对于某一时间序列  $x$ ,这里选取的时域特征见表 1。

表 1 时域统计特征

Table 1 Statistic characteristics of time domain

特征描述	定义	特征描述	定义
最大值	$s_1 = \max(x)$	方差	$s_9 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$
最小值	$s_2 = \min(x)$	峭度	$s_{10} = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)s_4^2}$
峰峰值	$s_3 = s_1 - s_2$	变异系数	$s_{11} = \frac{s_7}{s_4}$
均值	$s_4 = \frac{1}{n} \sum_{i=1}^n x_i$	峰值因子	$s_{12} = \frac{s_1}{s_6}$
绝对值平均	$s_5 = \frac{1}{n} \sum_{i=1}^n  x_i $	波形因子	$s_{13} = \frac{s_6}{s_5}$
均方根	$s_6 = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$	脉冲因子	$s_{14} = \frac{s_1}{s_5}$
标准差	$s_7 = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$	方根幅值	$s_{15} = (\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i })^2$
偏斜度	$s_8 = \frac{s_4^3}{s_7^3}$	裕度指标	$s_{16} = \frac{s_1}{s_{15}}$

时域特征虽然不能直接体现低频振荡的频率、衰减因子等参数,但时域特征随着时间的变化可以作为低频振荡参数的表征。如  $s_1, s_3$  等体现信号幅值的时域特征量的变化可以反映振荡信号衰减因子。因此,相比于直接进行图像处理,时域特征提取有利于提高 CNN 网络训练的效率和准确率。针对低频振荡识别的预处理操作过程(图 4)如下:

- 1) 对于原始信号  $x$ ,构造长度为 1 s 的采样窗,每隔 0.04 s 抽取一次采样窗数据。
- 2) 按照表 1 计算每个采样窗数据的时域特征量。产生 16 个时域特征随时间变化的序列,实现特征提取和部分滤波的功能。
- 3) 对于每个时域特征序列,再构造长度为 4 s 的采样窗(包含 5 s 原始信号的信息),每隔 1 s 取一次采样窗数据。
- 4) 将采样窗数据转化为矩阵,得到 16 个  $10 \times 10$  的矩阵。

### 2.3 CNN 网络的训练样本

如表 2 所示,低频振荡对应的频率范围是 (0.1,2.5),将其均分为 12 类,每类包含的频率范围是 0.2 Hz,对应标签 1~12。衰减因子预设的范围是

(-0.5,0.5),将其分为四类:强衰减、弱衰减、弱发散、强发散,对应标签 1~4。采样时间 5 s,通过网络训练分别验证待测信号是否存在某一类频率的信号以及辨识信号主导模态的衰减因子。

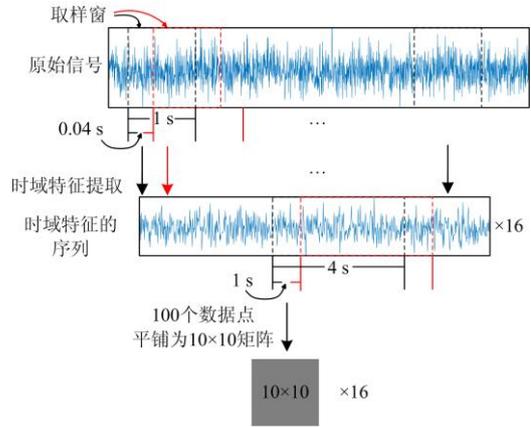


图 4 预处理操作过程

Fig. 4 Process of preprocessing operation

表 2 参数的分类

Table 2 Classification of parameters

标签	频率/Hz	标签	频率/Hz	标签	衰减因子
1	(0.1, 0.3)	7	(1.3, 1.5)	1	(-0.5, -0.2)
2	(0.3, 0.5)	8	(1.5, 1.7)	2	(-0.2, 0)
3	(0.5, 0.7)	9	(1.7, 1.9)	3	(0, 0.2)
4	(0.7, 0.9)	10	(1.9, 2.1)	4	(0.2, 0.5)
5	(0.9, 1.1)	11	(2.1, 2.3)	—	—
6	(1.1, 1.3)	12	(2.3, 2.5)	—	—

## 3 仿真分析

### 3.1 CNN 算法的参数辨识结果

#### 1) 理想信号的辨识结果

按照上述分类方法,随机生成不带噪声的理想信号样本进行训练和测试。训练样本 5 000 个,测试样本 500 个,训练 100 次。得到的结果如表 3。可以看出,该算法对低频振荡的频率和衰减因子辨识准确率均在 92% 以上。

表 3 CNN 网络测试结果

Table 3 CNN testing results

标签	准确率(频率)	标签	准确率(频率)	标签	准确率(衰减)
1	94.5%	7	92.1%	1	95.1%
2	93.7%	8	92.7%	2	92.2%
3	93.4%	9	92.2%	3	92.5%
4	93.1%	10	93.6%	4	95.9%
5	92.0%	11	95.1%	—	—
6	92.0%	12	92.6%	—	—

#### 2) 加噪声信号的辨识结果

为了验证抗噪性, 在原始信号中分别添加 20 dB 和 10 dB 噪声, 分类方法不变, 将带有不同强度噪声的训练信号输入网络, 得到的结果如表 4 和表 5。

表 4 20 dB 噪声下测试结果

Table 4 Testing results with 20 dB noise

标签	准确率(频率)	标签	准确率(频率)	标签	准确率(衰减)
1	93.9%	7	92.0%	1	93.9%
2	93.4%	8	92.5%	2	91.7%
3	93.0%	9	92.3%	3	92.2%
4	92.6%	10	93.1%	4	95.0%
5	91.5%	11	93.7%	—	—
6	92.1%	12	91.7%	—	—

表 5 10 dB 噪声下测试结果

Table 5 Testing results with 10 dB noise

标签	准确率(频率)	标签	准确率(频率)	标签	准确率(衰减)
1	93.4%	7	91.7%	1	92.3%
2	92.8%	8	92.0%	2	91.0%
3	92.5%	9	92.1%	3	91.4%
4	92.3%	10	91.9%	4	94.6%
5	91.1%	11	93.4%	—	—
6	91.9%	12	91.5%	—	—

根据上述实验结果可见该算法具有较好的抗噪性, 对于添加了强度为 20 dB 噪声的信号, 准确率几乎无影响; 对于添加了 10 dB 噪声的信号, 各项准确率仅下降 1%~2%。

### 3) 对非平稳信号辨识能力的测试

考虑到高比例新能源并网系统状态多变, 振荡特性复杂, 为了验证该算法能否辨识出系统在振荡过程中叠加新的振荡模态, 构造如式(6)的测试信号。

$$s(t) = 0.6e^{0.12t} \sin(2\pi \times 0.84t + \pi) + 0.7e^{-0.15t} \sin(2\pi \times 1.21t + \frac{\pi}{3}) + 0.8e^{0.3(t-5)} \sin(2\pi \times 1.58(t-5) + \frac{\pi}{4})\varepsilon(t-5) + \eta(t) \quad (6)$$

式中:  $\varepsilon(t-5)$  是阶跃信号;  $\eta(t)$  是 10 dB 噪声, 三个模态对应的频率标签分别为 4、6、8。其图像如图 5 所示。从  $t=4$  s 时开始, 每隔 1 s 检测一次信号频率, 检测结果如表 6。

从表 6 可以看出, 对于频率标签为 4 的模态, 由于其为一幅值发散的模态, 故从第 4 s 开始, 一直可以被检测出来。对于频率标签为 6 的模态, 在第 7 s 时未被检测出来, 因为此时其幅值衰减了 65%。

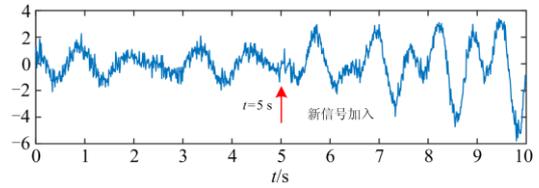


图 5 非平稳的测试信号

Fig. 5 Non-stationary test signal

表 6 新加信号辨识结果

Table 6 Results of identifying newly added signal

标签	1	2	3	4	5	6	7	8	9	10	11	12
$t=4$ s	×	×	×	√	×	√	×	×	×	×	×	×
$t=5$ s	×	×	×	√	×	√	×	×	×	×	×	×
$t=6$ s	×	×	×	√	×	√	×	×	×	×	×	×
$t=7$ s	×	×	×	√	×	×	×	×	×	×	×	×
$t=8$ s	×	×	×	√	×	×	×	√	×	×	×	×

(注: “×” 代表不存在, “√” 代表存在。)

对于频率标签为 8 的新加入的模态, 在其出现 3 s 后被检测出来, 因为此时其幅值因发散而显著增强。由此可见本文所提方法, 具备了辨识非平稳信号的能力。

### 3.2 CNN 算法与 Prony 算法的对比

鉴于 Prony 算法在 LFO 辨识中获得了广泛应用, 这里使用传统 Prony 方法与本方法进行对比, 分别验证对于理想信号、加噪声信号和新加信号两种方法辨识的差异, 以验证本文方法的有效性和抗噪性。对于式(6)的信号, 在不同时段利用两种方法进行辨识, 得到的结果如表 7 所示。

表 7 两种方法辨识结果对比

Table 7 Comparison of the results of two identification methods

	模态	频率/Hz	衰减因子	阻尼比/%
真实信号	1	0.84	0.12	-2.27
	2	1.21	-0.15	1.97
本文算法	1	0.7~0.9	0~0.2(主导)	—
	2	1.1~1.3		—
0~5 s Prony 算法	1	0.82	0.12	-2.33
	2	1.20	-0.13	1.72
本文算法 (含噪)	1	0.7~0.9	0~0.2(主导)	—
	2	1.1~1.3		—
Prony 算法 (含噪)	1	0.58	-1.15	—
	2	1.42	-1.39	—
真实信号	1	0.84	0.12	-2.27
	2	1.21	-0.15	1.72
3~8 s 本文算法	3	1.58	0.3	-3.01
	1	0.7~0.9	0.2~0.5(主导)	—
2	1.5~1.7	—		
Prony 算法	1	1.2	-0.71	—
	2	2.4	-3.3	—

从表 7 可见,对于未加噪声的理想信号, Prony 算法和本文算法都能较好地辨识出信号的主要特征,但本文算法在抗噪性和辨识非平稳信号(3~8 s)的能力上明显优于 Prony 算法。这在一定程度上表明本文算法在非平稳低频振荡信号辨识上的应用潜力。

### 3.3 10 机 39 节点系统的分析结果

采用新英格兰 10 机 39 节点作为分析对象,其系统接线图如图 6 所示。使用电力系统分析综合程序 PSASP 进行仿真和小干扰稳定分析,计算得到 11 个振荡模式的特征值,如表 8 所示。这里只考虑低频振荡频率范围内的 9 个模式。

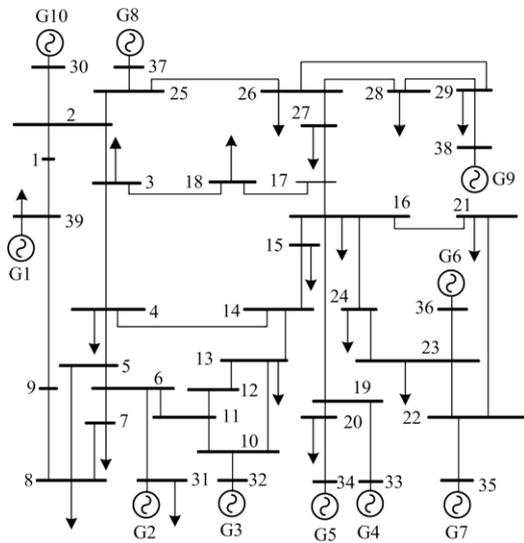


图 6 新英格兰 10 机 39 节点系统图

Fig. 6 New England 10-machine 39-bus system

在线路 16-21 靠近 21 节点处设置一持续 0.1 s 的三相短路,各发电机有功功率曲线如图 7 所示。采集短路后 5 s 的各发电机有功功率数据波形,将其预处理后分别送入训练好的辨识频率的 CNN 网络和辨识衰减因子的 CNN 网络进行识别,得到的结果如表 9 所示。

由表 9 可以看出,每个发电机的检测结果在 PSASP 的小干扰稳定分析结果中均有与之对应的模式。其中全部机组都参加了模式 8 的区间振荡模式,对应频率范围为 0.5~0.7 Hz,对应频率标签为 3。由图 7 可见,属于该振荡模式的发电机 G1 是所有发电机中振幅最大的,是最主要的区间振荡模式。CNN 算法辨识的 10 个机组均为强衰减,对应衰减因子标签为 1,与小干扰稳定分析结果一致。这些结果证明了本文所提算法的有效性。需要指出的是,CNN 算法从 G6 机组的功率振荡数据识别出了一个

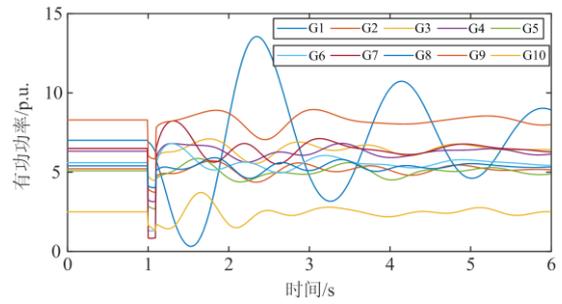


图 7 各发电机有功功率曲线

Fig. 7 Active power curve of various generators

表 8 特征值计算结果

Table 8 Results of eigenvalues computation

模式	实部	虚部	频率/Hz	阻尼比/%
1	-10.156 5	19.994 1	3.182 2	45.289 3
2	-8.553 3	18.441 8	2.935 1	42.074 8
3	-0.567 5	8.953 7	1.425 0	6.325 6
4	-0.536 2	8.840 6	1.407 0	6.053 9
5	-0.526 8	8.757 8	1.393 9	6.004 8
6	-0.490 8	7.361 1	0.980 5	6.652 3
7	-0.479 4	7.225 0	0.886 4	6.621 4
8	-0.549 9	7.024 2	0.565 0	7.804 8
9	-0.498 5	6.160 9	0.980 5	8.064 4
10	-0.474 2	5.569 3	0.886 4	8.483 2
11	-0.310 4	3.550 1	0.565 0	8.710 2

表 9 CNN 算法的辨识结果

Table 9 Identification results with CNN method

发电机	f1/Hz	f2/Hz	f3/Hz	衰减因子	频率标签
G1	0.5~0.7	—	—	-0.2~-0.5	3
G2	0.5~0.7	0.9~1.1	—	-0.2~-0.5	3,5
G3	0.5~0.7	0.9~1.1	—	-0.2~-0.5	3,5
G4	0.5~0.7	—	—	-0.2~-0.5	3
G5	0.5~0.7	0.9~1.1	—	-0.2~-0.5	3,5
G6	0.1~0.3	0.5~0.7	—	-0.2~-0.5	1,3
G7	0.5~0.7	0.9~1.1	1.3~1.5	-0.2~-0.5	3,5,7
G8	0.5~0.7	1.3~1.5	—	-0.2~-0.5	3,7
G9	0.5~0.7	0.7~0.9	0.9~1.1	-0.2~-0.5	3,4,5
G10	0.5~0.7	1.1~1.3	—	-0.2~-0.5	3,6

0.1~0.3 Hz 的模式。虽然 CNN 网络中体现其结果可信度的分类器输出的概率仅为 76.54%,但 PSASP 的理论计算结果中缺乏与之对应的模式。这是下一步应该注意和研究的问题。

## 4 总结与展望

高比例新能源和电力电子设备电力系统中的低频振荡现象更加复杂,难以满足传统辨识方法中低频振荡信号可近似视作平稳信号的要求。本文基

于人工智能中的卷积神经网络, 从定性的角度提出了一种电力系统低频振荡特征的快速辨识的方法。它能够在短时间内(5 s)对低频振荡信号的主要参数做出定性的评价, 具有很好的抗噪性能, 且能够辨识系统当前振荡过程中是否引入了新的振荡模态, 在一定程度上具备了辨识非平稳信号的能力。这种快速地定性辨识低频振荡的频率和衰减因子, 可为在线应用的低频振荡抑制设备提供技术依据, 也可为调度人员采取措施赢得时间, 有利于提高电力系统的安全稳定运行水平。

在下一步研究中, 将进一步围绕低频振荡信号本质上非线性、非平稳特性展开研究, 尝试将定性的特征快速辨识与定量的模态识别结合起来, 进一步提高快速辨识的精度和速度, 同时从机理上研究避免定性算法引入新模态的途径, 获取更为准确的辨识结果。

### 参考文献

- [1] 胡学浩. 美加联合电网大面积停电事故的反思和启示[J]. 电网技术, 2003, 27(9): 2-6.  
HU Xuehao. Rethinking and enlightenment of large scope blackout in interconnected North America power grid[J]. Power System Technology, 2003, 27(9): 2-6.
- [2] 梅勇, 张俊峰, 周剑, 等. “7·6”思林水电厂功率振荡事件分析及改进措施[J]. 电力系统自动化, 2018, 42(16): 187-191.  
MEI Yong, ZHANG Junfeng, ZHOU Jian, et al. Analysis and improvement measures on power oscillations in Silin Hydropower Plant on July 6, 2017[J]. Automation of Electric Power Systems, 2018, 42(16): 187-191.
- [3] 王颖凯. 基于深度学习算法的电力系统低频振荡模式识别[D]. 广州: 华南理工大学, 2017.  
WANG Yingkai. Analysis of low frequency oscillations based on deep learning[D]. Guangzhou: South China University of Technology, 2017.
- [4] ZHANG A Q, ZHANG L L, LI M S, et al. Identification of dominant low frequency oscillation modes based on blind source separation[J]. IEEE Transactions on Power Systems, 2017, 32(6): 4774-4782.
- [5] 竺炜, 马建伟, 曾喆昭, 等. 分段傅里叶神经网络的低频振荡模式识别方法[J]. 电力系统保护与控制, 2012, 40(15): 40-45.  
ZHU Wei, MA Jianwei, ZENG Zhezao, et al. Low frequency oscillation mode recognition based on segmental Fourier neural network algorithm[J]. Power System Protection and Control, 2012, 40(15): 40-45.
- [6] 苏安龙, 孙志鑫, 何晓洋, 等. 基于多元经验模式分解的电力系统低频振荡模式辨识[J]. 电力系统保护与控制, 2019, 47(22): 113-125.  
SU Anlong, SUN Zhixin, HE Xiaoyang, et al. Identification of power system low frequency oscillation mode based on multivariate empirical mode decomposition[J]. Power System Protection and Control, 2019, 47(22): 113-125.
- [7] 丁蓝, 薛安成, 李津, 等. 基于窗口滑动改进 Prony 算法的电力系统低频振荡识别[J]. 电力系统自动化, 2010, 34(22): 24-28.  
DING Lan, XUE Ancheng, LI Jin, et al. A moving-window Prony algorithm for power system low frequency oscillation identification[J]. Automation of Electric Power Systems, 2010, 34(22): 24-28.
- [8] 葛维春, 殷翔翔, 葛延峰, 等. 基于 MEMD 和 HHT 的电力系统低频振荡模式识别方法研究[J]. 电力系统保护与控制, 2020, 48(6): 124-135.  
GE Weichun, YIN Xiangxiang, GE Yanfeng, et al. Estimating low frequency oscillation mode in power systems using multivariate empirical mode decomposition and Hilbert-Huang transform[J]. Power System Protection and Control, 2020, 48(6): 124-135.
- [9] JIN T, LIU S Y. Mode identification of low-frequency oscillations in power systems based on fourth-order mixed mean cumulant and improved TLS-ESPRIT algorithm[J]. IET Generation Transmission & Distribution, 2017, 11(15): 3739-3748.
- [10] PHILIP J G, JAIN T. Analysis of low frequency oscillations in power system using EMO ESPRIT[J]. International Journal of Electrical Power & Energy Systems, 2018, 95: 499-506.
- [11] TRIPATHY P, SRIVASTAVA S C, SINGH S N. A modified TLS-ESPRIT-based method for low frequency mode identification in power systems utilizing synchrophasor measurements[J]. IEEE Transactions on Power Systems, 2011, 26(2): 719-727.
- [12] 金涛, 刘对. 基于广义形态滤波与改进矩阵束的电力系统低频振荡模态辨识[J]. 电工技术学报, 2017, 32(6): 3-13.  
JIN Tao, LIU Dui. Power system low frequency oscillation identification based on the generalized morphological method and improved matrix pencil algorithm[J]. Transactions of China Electrotechnical Society, 2017, 32(6): 3-13.
- [13] 王宇静, 于继来. 电力系统振荡模态的矩阵束辨识法[J]. 中国电机工程学报, 2007, 27(19): 12-17.  
WANG Yujing, YU Jilai. Matrix pencil method of oscillation modes identification in power systems[J]. Proceedings of the CSEE, 2017, 27(19): 12-17.

- [14] 赵妍, 李志民, 李天云. 低频振荡模态参数辨识的共振稀疏分解 SSI 分析方法[J]. 电工技术学报, 2016, 31(2): 136-144.  
ZHAO Yan, LI Zhimin, LI Tianyun. Low frequency oscillation modal parameter identification using resonance-based sparse signal decomposition and ssi method[J]. Transactions of China Electrotechnical Society, 2016, 31(2): 136-144.
- [15] PHILIP J G, JAIN Y. An improved stochastic subspace identification based estimation of low frequency modes in power system using synchrophasors[J]. International Journal of Electrical Power & Energy Systems, 2019, 109: 495-503.
- [16] 易建波, 黄琦, 丁理杰, 等. 提升经验模态分解检测低频振荡模式精度的改进算法研究[J]. 电力系统保护与控制, 2013, 41(22): 71-78.  
YI Jianbo, HUANG Qi, DING Lijie, et al. Research on an improved algorithm to enhance the detection accuracy of low-frequency oscillation modes by empirical mode decomposition[J]. Power System Protection and Control, 2013, 41(22): 71-78.
- [17] 蔡国伟, 杨德友, 张俊丰, 等. 基于实测信号的电力系统低频振荡模态辨识[J]. 电网技术, 2011, 35(1): 59-65.  
CAI Guowei, YANG Deyou, ZHANG Junfeng, et al. Mode identification of power system low-frequency oscillation based on measured signal[J]. Power System Technology, 2011, 35(1): 59-65.
- [18] 马宁宁, 谢小荣, 贺静波, 等. 高比例新能源和电力电子设备电力系统的宽频振荡研究综述[J]. 中国电机工程学报, 2020, 40(15): 4719-4731.  
MA Ningning, XIE Xiaorong, HE Jingbo, et al. Review of wide-band oscillation in renewable and power electronics highly integrated power systems[J]. Proceedings of the CSEE, 2020, 40(15): 4719-4731.
- [19] 和萍, 陈婕, 耿斯涵, 等. FACTS 装置对含风电互联系统低频振荡特性分析[J]. 电力系统保护与控制, 2020, 48(8): 86-95.  
HE Ping, CHEN Jie, GENG Sihan, et al. Analysis of FACTS device on low-frequency oscillation characteristics of a power system with wind farm integration[J]. Power System Protection and Control, 2020, 48(8): 86-95.
- [20] HU Jiabing, WANG Bo, WANG Weisheng, et al. Small signal dynamics of DFIG-based wind turbines during riding through symmetrical faults in weak AC grid[J]. IEEE Transactions on Energy Conversion, 2017, 32(2): 720-730.
- [21] 谢小荣, 刘华坤, 贺静波, 等. 电力系统新型振荡问题浅析[J]. 中国电机工程学报, 2018, 38(10): 2821-2828, 3133.  
XIE Xiaorong, LIU Huakun, HE Jingbo, et al. On new oscillation issues of power systems[J]. Proceedings of the CSEE, 2018, 38(10): 2821-2828, 3133.
- [22] 王学健. 基于智能计算的电力系统低频振荡模式辨识的研究[D]. 广州: 华南理工大学, 2017.  
WANG Xuejian. Study on mode identification of low frequency oscillation in power system based on intelligent computing[D]. Guangzhou: South China University of Technology, 2017.
- [23] SHEN Zhongting, DING Renjie. A novel neural network approach for power system low frequency oscillation mode identification[C] // 2019 IEEE International Symposium on Circuits and Systems (ISCAS), May 26-29, 2019, Sapporo, Japan: 1-5.
- [24] 吴正文. 卷积神经网络在图像分类中的应用研究[D]. 成都: 电子科技大学, 2015.  
WU Zhengwen. Application research of convolution neural network in image classification[D]. Chengdu: University of Electronic Science and Technology of China, 2015.
- [25] 吴涛, 赖菲. 基于 LeNet-5 模型的太阳能电池板缺陷识别分类[J]. 热力发电, 2019, 48(3): 120-125.  
WU Tao, LAI Fei. Identification and classification of defects in solar cells based on LeNet-5 model[J]. Thermal Power Generation, 2019, 48(3): 120-125.
- [26] ZHAO Wenjing, SHANG Liquan, SUN Jinfang. Power quality disturbance classification based on time-frequency domain multi-feature and decision tree[J]. Protection and Control of Modern Power Systems, 2019, 4(4): 337-342. DOI: 10.1186/s41601-019-0139-z.

收稿日期: 2020-07-28; 修回日期: 2020-09-18

作者简介:

秦心筱(2000—), 男, 本科生, 研究方向为人工智能技术及其在电力系统中的应用; E-mail: qinxinxiao@std.uestc.edu.cn

张昌华(1975—), 男, 通信作者, 博士, 副教授, 研究方向为智能电网、配电网稳定性与优化运行, 电动汽车并网技术、虚拟电厂; E-mail: zhangchanghua@uestc.edu.cn

徐子豪(1997—), 男, 硕士研究生, 研究方向为电力系统稳定与控制。

(编辑 姜新丽)