



## 适用于电网异常负荷动态判别的 CNN 阈值模型

毛钧毅, 韩 松, 李洪乾

(贵州大学 贵州大学电气工程学院, 贵阳 550025)

**摘 要:** 为提高在负荷波动性较大场景下对异常负荷判别的适应性, 提出一种适用于电网异常负荷动态判别的卷积神经网络阈值模型。利用时序历史负荷数据训练卷积神经网络模型进行负荷预测, 并根据预测负荷值计算电网未来的状态变量数据, 通过该状态变量数据源矩阵的构造, 依次构建其窗口矩阵、标准矩阵以及样本协方差矩阵, 进而设定基于样本协方差矩阵最大特征值的动态阈值, 利用该阈值对当前时刻的最大特征值进行越限判定, 实现对电网异常负荷的动态判别。借助 Matlab R2014a 和 PST 软件工具, 在 IEEE50 机 145 母线标准系统中进行仿真测试, 结果表明, 与传统阈值模型相比, 该阈值模型在动态电网中对 MESCM 指标的异常判定适应性更强、准确性更高。

**关键词:** 卷积神经网络; 动态阈值; 负荷预测; 样本协方差矩阵; 最大特征值; 异常负荷动态判别

开放科学(资源服务)标志码(OSID):



**中文引用格式:** 毛钧毅, 韩松, 李洪乾. 适用于电网异常负荷动态判别的 CNN 阈值模型[J]. 计算机工程, 2020, 46(6): 308-313.

**英文引用格式:** MAO Junyi, HAN Song, LI Hongqiang. CNN threshold model suitable for dynamic judgment examination of abnormal load in power grid[J]. Computer Engineering, 2020, 46(6): 308-313.

## CNN Threshold Model Suitable for Dynamic Judgment Examination of Abnormal Load in Power Grid

MAO Junyi, HAN Song, LI Hongqiang

(School of Electrical Engineering, Guizhou University, Guiyang 550025, China)

**[Abstract]** In order to improve the adaptability to abnormal load judgment in scenarios where loads fluctuate greatly, this paper proposes a threshold model with convolutional neural network suitable for the dynamic judgment of abnormal load of power grid. The Convolutional Neural Network (CNN) model is trained with historical load data in time series for load prediction, and based on the predicted loads, the future state variable data in power grid can be calculated. Based on the construction of the state variable data source matrix, its window matrix, standard matrix and sample covariance matrix are subsequently obtained. Then the dynamic threshold based on the maximum eigenvalue of the sample covariance matrix is set, and the threshold is used for the overdue judgment of the maximum eigenvalue at the current time, so as to implement dynamic judgment of abnormal load in power grid. With the help of software tools including Matlab R2014a and PST, simulation tests are performed on the IEEE50 machine 145 bus standard system. Results show that compared with the traditional threshold model, the proposed threshold model is more adaptable and accurate for the judgment of abnormal MESCM indicators in dynamic power grid.

**[Key words]** Convolutional Neural Network (CNN); dynamic threshold; load forecasting; sample covariance matrix; maximum eigenvalue; dynamic judgment of abnormal load

**DOI:** 10.19678/j.issn.1000-3428.0056250

### 0 概述

随着云计算、物联网、移动互联网等信息技术快

速演进以及同步相量测量、广域测量系统 (Wide Area Measurement System, WAMS) 的广泛应用, 电力数据呈现出高随机、多耦合以及典型的“4V”等特

**基金项目:** 国家自然科学基金 (51567006); 贵州省普通高等学校科技拔尖人才支持计划 (2018036); 贵州省科学技术基金 (黔科合基础 [2019]1100)。

**作者简介:** 毛钧毅 (1995—), 男, 硕士研究生, 主研方向为电力系统大数据分析; 韩 松 (通信作者), 教授、博士; 李洪乾, 硕士研究生。

**收稿日期:** 2019-10-11 **修回日期:** 2019-11-14 **E-mail:** 15242819@qq.com

征<sup>[1]</sup>。从数据驱动的角度出发,借助大数据技术与深度学习理论,有效挖掘和充分应用海量电网数据的信息,已成为现阶段电力系统大数据建设的发展趋势<sup>[2-4]</sup>。

随机矩阵理论(Random Matrix Theory, RMT)是一种通过从高维角度理解复杂系统的行为特大数据分析的方法。一方面,在基于 RMT 的电力系统分析理论与方法研究发展中,单环定律的平均谱半径(Mean Spectral Radius, MSR)指标已在配电网运行状态相关性分析<sup>[5]</sup>、电网薄弱环节辨识<sup>[6]</sup>以及电力系统不可见单元的检测<sup>[7]</sup>等方面的应用取得初步成果。相较于 MSR,基于 M-P 定律的样本协方差矩阵最大特征值(Maximum Eigenvalue of Sample Covariance Matrix, MESCM)指标不仅能实现相同的应用,且更适用于低信噪比场景<sup>[8-9]</sup>,在大规模电网中的计算效率更高<sup>[10]</sup>。然而,上述文献对电网进行态势评估大多在负荷波动较小的场景下开展,尚未对此类方法在具有周期性变化规律、波动性较大等特征的日负荷曲线动态电网中的适用性开展研究,如基于 MESCM 或 MSR 指标的阈值模型未能充分考虑数据波动性、静态阈值对指标判定的可靠性偏低等。另一方面,近年来,卷积神经网络(Convolutional Neural Network, CNN)<sup>[11]</sup>作为深度学习理论的模型之一,由于其强大的学习潜力以及优越的特征提取能力,已逐渐被引入到电力系统各个领域的研究中<sup>[12-15]</sup>。文献[13]利用 CNN 对时频谱进行特征提取,从而实现局部放电类型的识别。文献[14]将 CNN 用于提取输入信息特征,与强化学习相结合实现电网运行到控制策略的直接映射。文献[15]依据 CNN 具有局部提特征获取、权值区域及二次抽样共享等特点,深入挖掘时间序列之间的相关特征,进而实现超短期风电的预测并取得较好的预测效果。

为研究基于数据驱动的电网态势感知理论与方法,本文利用 CNN 模型进行负荷预测,从已确定电网的网络构架以及相应机组的出力和开机方式角度使用预测负荷值,设定一种基于 MESCM 的动态阈值,进而提出适用于电网异常负荷动态判别的 CNN 阈值模型。

## 1 基于随机矩阵理论的 MESCM 原理

### 1.1 考虑噪声的 PMU 数据源矩阵的预处理

在广域测量系统中,相量测量单元(Phasor Measurement Unit, PMU)能采集海量具有统一时间戳的状态变量数据,如电压和功角量测数据,使得电力系统的主控中心在每个采样时刻均能采集到从各个 PMU 中上传的状态变量数据。将各个采样时刻的数据按照时间顺序排列,构成一个二维矩阵,即数据源矩阵  $\mathbf{X}_D$ ,如式(1)所示:

$$\mathbf{X}_D = \begin{pmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,t_i} & \cdots \\ x_{2,1} & x_{2,2} & \cdots & x_{2,t_i} & \cdots \\ \vdots & \vdots & & \vdots & \\ x_{N,1} & x_{N,2} & \cdots & x_{N,t_i} & \cdots \end{pmatrix} \quad (1)$$

由于传输过程中  $\mathbf{X}_D$  会受到随机噪声的干扰,则定义异常检测模型为:

$$\mathbf{X}_D = \mathbf{X}_S + \mathbf{X}m_z \times \boldsymbol{\eta}_z \quad (2)$$

其中,  $\mathbf{X}_S$  为未受噪声污染的信号矩阵,  $m_z$  为噪声幅值,  $\boldsymbol{\eta}_z$  为噪声矩阵<sup>[8]</sup>。

在得到受随机噪声所影响的数据源矩阵  $\mathbf{X}_D$  后,采用滑动窗口技术生成  $N \times T$  维窗口数据矩阵  $\mathbf{X}$ ,根据 M-P 定律对矩阵  $\mathbf{X}$  按式(3)逐行转换为标准化的非 Hermitian 矩阵  $\mathbf{X}_n$ :

$$\mathbf{X}_n = (\mathbf{x}_{i,j} - \mu(\mathbf{x}_i)) \times (\sigma(\mathbf{x}_{ni}) / \sigma(\mathbf{x}_i)) + \mu(\mathbf{x}_{ni}) \quad (3)$$

$$1 \leq i \leq N, 1 \leq j \leq T$$

其中,  $\mathbf{x}_i = (x_{i,1}, x_{i,2}, \cdots, x_{i,T})^T$ ,  $\mu(\mathbf{x}_i)$ 、 $\sigma^2(\mathbf{x}_i)$  分别为行向量  $\mathbf{x}_i$  的均值和标准差,  $\mu(\mathbf{x}_{ni})$ 、 $\sigma(\mathbf{x}_{ni})$  分别为非 Hermitian 矩阵行向量  $\mathbf{x}_{ni}$  的均值和标准差。

### 1.2 基于 M-P 定律的 MESCM 指标

随机矩阵通常是一种高维以及各个元素独立同分布的矩阵, RMT 则是以此为研究对象,描述其特征值、奇异值以及相关参数的渐进行为的一种理论<sup>[16]</sup>。它主要涉及两个定律,即 M-P (Marchenko-Pastur) 定律与单环定律,本文采用 M-P 定律,其原理描述如下:

设  $\mathbf{X}_n = \{\mathbf{x}_{i,j} | 1 \leq i \leq N, 1 \leq j \leq T\}$  为一个  $N \times T$  维的随机矩阵,且每一个元素均独立同分布。当均值  $\mu(\mathbf{x}) = 0$ 、方差  $\sigma^2(\mathbf{x}) < \infty$  时,  $\mathbf{X}_n$  的样本协方差矩阵  $\mathbf{S}$  为:

$$\mathbf{S} = \frac{1}{N} (\mathbf{X}_n \times \mathbf{X}_n^H) \quad (4)$$

其中,  $\mathbf{X}_n^H$  为随机矩阵的共轭转置。当矩阵满足维容比  $c (N/T = c \in (0, 1])$  不变时,样本协方差矩阵  $\mathbf{S}$  的验谱分布函数(Empirical Spectral Distribution, ESD)服从 M-P 定律,如式(5)所示:

$$f_{\text{mp}(x)} = \begin{cases} \frac{\sqrt{(b-\lambda)(\lambda-a)}}{2\pi\lambda c\sigma^2}, & a \leq \lambda \leq b \\ 0, & \text{其他} \end{cases} \quad (5)$$

其中,  $a = \sigma^2(1 - \sqrt{c})^2$ ,  $b = \sigma^2(1 + \sqrt{c})^2$ ,  $\sigma^2$  为刻度参数,  $\sigma^2 = 1$ ,  $a$  和  $b$  分别表示谱密度函数中特征值的理论下、上确界。

进一步地,若式(4)中  $\mathbf{X}_n$  的各元素均为独立同分布的变量,且均值为 0、方差为 1 时,  $\mathbf{X}_n$  的样本协方差矩阵  $\mathbf{S}$  的特征值分布收敛于 M-P 定律。本文以  $\lambda_{\max}$  表示样本协方差矩阵  $\mathbf{S}$  的最大特征值,即 MESCM 指标。

## 2 适用于异常负荷检测的 CNN 阈值模型

### 2.1 CNN 原理

CNN 是一种适用于处理具有网格状拓扑结构

的数据的前馈人工神经网络模型。典型的 CNN 由卷积层、池化层、全连接层构成,其层间结构如图 1 所示。卷积层具有权值共享和局部连接的特点,能降低模型的复杂性,并减少过拟合的风险;而对于池化,其执行二次抽样或局部平均,以降低输出对数据波动的灵敏性,并提高模型的泛化能力。因此,与全连接神经网络相比,CNN 具有权值参数少、鲁棒性好、泛化能力强与可并行学习等优点<sup>[17]</sup>。

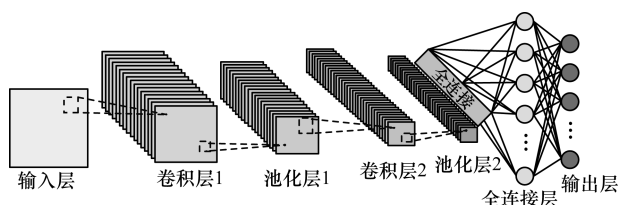


图 1 CNN 网络结构

Fig. 1 CNN network structure

## 2.2 CNN 超短期负荷预测模型结构

超短期负荷预测是利用最新负荷信息,对未来 5 min ~ 1 h 内的电力负荷进行实时预测,能够在跟踪电力系统负荷变化,是动态电网安全监测的依据<sup>[18]</sup>。区别于图像领域的二维 CNN,本文采用一维 CNN 处理序列数据<sup>[19]</sup>。其中模型的输出向量  $y_{n+m}$  ( $m=1,2,\dots,i$ ) 是  $n$  时刻后  $m$  个预测值,而输入向量  $x_{n-k+1}$  ( $k=1,2,\dots,j$ ) 是包括  $n$  时刻的  $k$  个历史负荷数据值。由此,利用滑动窗口方法对时序历史负荷数据逐一构建训练样本  $\{x_{n-k+1}, y_{n+m}\}$ ,从而完成对 CNN 负荷预测模型的训练,并采用试错法的方式确定输入的历史数据个数  $k$  值以提高预测精准度。

为更有效地提取历史负荷的时序特征,本文建立一种两层 CNN 模型,包括 2 个卷积层、2 个平均池化层、1 个全连接层、1 个输出层,以及在每个卷积层及全连接层后加入 ReLU 激活函数,如图 2 所示,训练时采用 Adam 算法进行参数优化。

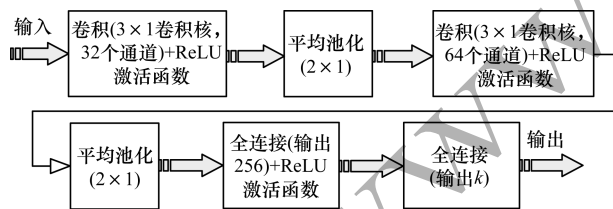


图 2 两层 CNN 时序负荷预测模型结构

Fig. 2 Two-layer CNN time-series load forecasting model structure

## 2.3 MESCM 预测模型

因遭受噪声、负荷波动性较大等因素的影响,电网运行过程实则是一个动态非平稳过程,对于由状态变量数据计算出的 MESCM 指标在无异常发生时刻也是处于动态变化的。于是,为了有效地判定 MESCM 指标的非平稳趋势,需要设定能够响应 MESCM 指标变化的动态阈值。

考虑到电力负荷预测对保证动态电网的安全和可靠运行具有重要作用,利用 CNN 预测模型根据实时负荷数据求出预测负荷值  $y$ ,再通过已确定电网的网络结构以及相应机组的出力和开机方式计算出电网未来的状态变量数据矩阵  $X_{D,P}$ ;进一步地,计算出预测的样本协方差矩阵  $S_P$  的最大特征值  $\lambda_{\max,P}$ ,从而设定 MESCM 指标的动态阈值并对电网运行状态进行实时检测。根据上述过程,定义基于 CNN 模型的动态阈值函数为:

$$\begin{cases} \lambda_{\max,P} = \text{MESCM}(y) \\ \gamma = \alpha \cdot \lambda_{\max,P} \end{cases} \quad (6)$$

其中,  $\text{MESCM}(\cdot)$  为 MESCM 指标的计算模型,  $\alpha$  ( $0 \leq \alpha$ ) 为比例系数,可根据滑动窗宽度  $T$  进行调整<sup>[8]</sup>,但随机噪声的强弱、窗口数据矩阵维度的大小以及 CNN 预测模型的精准度会对阈值模型的可靠性造成较大的影响。为此,结合异常扰动分级告警思路,该阈值考虑 28% 的裕度,选取  $\alpha = 1.28$ 。当实时的 MESCM 指标越过阈值  $\gamma$  时,即  $\lambda_{\max} \geq \gamma$ ,则可判定电网有异常扰动事件发生。

此外,当上述动态阈值判定有异常扰动时,为了使基于预测负荷值的动态阈值不受异常扰动数据的影响,而导致误判、漏判的现象发生,利用支持向量机对实时的扰动负荷数据进行预处理后再输入到 CNN 模型中。支持向量回归算法中的结构风险函数具有较好的平滑性,可以通过  $\varepsilon$  不敏感损失函数的作用来控制异常扰动数据对回归模型的影响,从整体上考虑回归曲线的平滑性,从而在负荷预测时减少异常扰动数据对 CNN 模型的干扰<sup>[20]</sup>。

## 3 本文方法步骤与流程

基于 CNN 阈值模型的电网异常负荷检测的具体步骤如下:

**步骤 1** 获取实时负荷数据,由训练好的 CNN 模型进行负荷预测。

**步骤 2** 根据已确定电力系统,使用预测负荷值计算出电网未来的状态变量数据,从而由式(1)构造预测的数据源矩阵  $X_{D,P}$ 。

**步骤 3** 由式(2)和式(3),对矩阵  $X_{D,P}$  进行预处理,再结合式(4)获得样本协方差矩阵  $S_P$ ,计算并筛选出矩阵  $S_P$  的最大特征值  $\lambda_{\max,P}$ 。

**步骤 4** 根据矩阵  $S_P$  的最大特征值  $\lambda_{\max,P}$ ,由式(9)设定动态阈值  $\gamma$ 。

**步骤 5** 获取当前时刻的电网状态变量数据,通过重复步骤 3 计算出实时  $S$  的最大特征值  $\lambda_{\max}$ ,作为电网异常负荷检测指标。

**步骤 6** 判断  $\lambda_{\max} \geq \gamma$  是否成立,若成立,则判定电网负荷出现异常扰动;否则重复步骤 2 ~ 步骤 6。

基于 CNN 模型的电网异常负荷检测流程如图 3 所示。

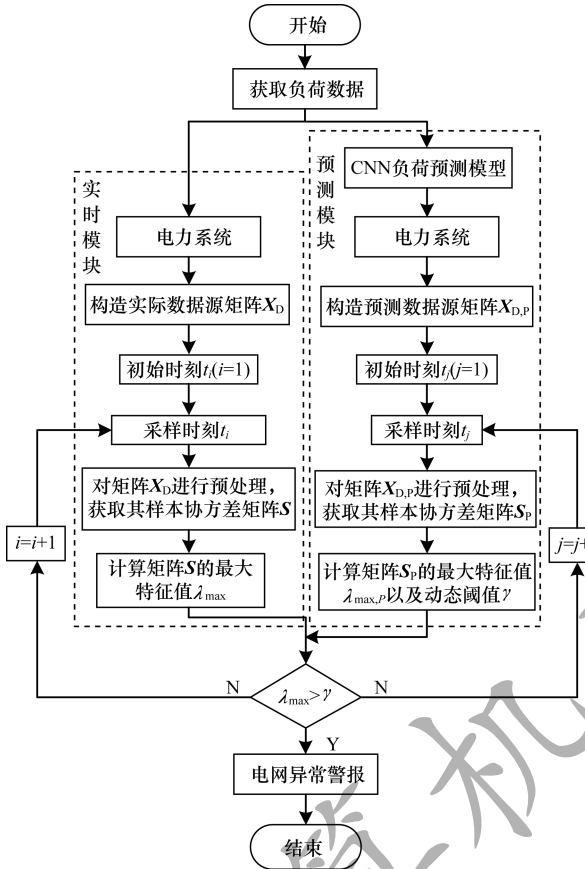


图 3 基于 CNN 模型的电网异常负荷检测流程

Fig. 3 CNN model-based grid abnormal load detection procedure

#### 4 算例分析

为验证本文提出的适用于电网异常负荷动态判别的 CNN 阈值模型的有效性,以 IEEE50 机标准系统开展时域仿真获取测试数据。一方面,对于 CNN 阈值模型,根据试错法选取历史负荷数据值  $k=14$ ,再利用 CNN 模型预测未来 5 min ( $m=5$ ) 的负荷值,从而计算出相应的预测阈值对 MESCM 指标进行实时监测;另一方面,借助 Power System Toolbox (PST) Version 3.0 工具软件,以一个 IEEE50 机 145 母线系统<sup>[21]</sup>进行仿真测试,其中假设系统每个负荷节点有功负荷的变化规律与日负荷曲线相符,负荷采用 1 440 点日负荷形式,且通过三次样条插值函数法<sup>[22]</sup>获取每个 0.15 min 的负荷伪量测,进而模拟 0.11 Hz<sup>[7]</sup> 的采样率。根据第 3 节方法步骤在 Matlab R2014a 软件中编制算法程序,以验证所提方法的有效性。

##### 场景 1 负荷异常扰动测试。

为模拟实时测试中噪声干扰,在该系统信号中引入高斯噪声源,其中信噪比  $\rho = (40 \pm 0.3)$  dB,并设置系统中 66 号母线的负荷发生异常扰动变化,具体如表 1 所示。

表 1 合成的异常负荷  
Table 1 Synthetic abnormal load

母线编号	采样时刻 $t_i$	负荷变化量/MW
Bus-66	1 ~ 4 800	无变化
	4 801 ~ 5 200	100
	5 201 ~ 9 600	无变化
其他母线	1 ~ 9 600	无变化

按照第 3 节的步骤 1 和步骤 2,利用 CNN 模型对获取的负荷数据进行预测,从而通过 IEEE50 机 145 母线系统计算出预测负荷值对应的系统状态变量数据,其中选取系统除平衡节点 145 外的其他 144 个节点的电压幅值和发电机功角数据构成 193 维数据源矩阵进行分析。然后设置滑动窗口  $T=300$ ,则维容比  $c=0.64 \in (0,1]$ ,由步骤 3 分别计算出标准的非 Hermitian 矩阵、样本协方差矩阵,进而根据步骤 4 设定 MESCM 指标的动态阈值。当采集到当前时刻的数据源矩阵时,通过步骤 5,可以计算得到实时的 MESCM 指标。

按照时间序列依次对每个滑动窗口数据进行计算,可得出一天的 MESCM 指标以及对应的动态阈值曲线,同时,计算出文献[8]所提出的 Spiked 阈值模型和式(5)中边界阈值与本文所提出的 CNN 阈值模型进行对比,如图 4 所示。

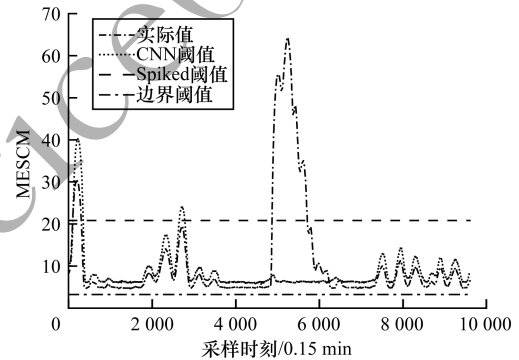


图 4 MESCM 指标及阈值模型计算结果 1

Fig. 4 MESCM indicator and threshold model calculation results 1

观察图 4 并结合表 1 可以发现,因在  $t_{4\ 801} \sim t_{5\ 200}$  采样时刻内 66 号母线有功负荷突然增长 100 MW,系统随机性被打破,从而使得 MESCM 指标数值急剧增加,越过了 CNN 阈值以及 Spiked 阈值,说明这种阈值模型能够有效判定 MESCM 指标的异常变化。而边界阈值  $a$  仅与维容比  $c$  有关,且忽略了噪声、负荷波动的影响,故未能有效地判定异常。然而,由于波动性负荷行为的影响,电网运行过程则是一个动态非平稳过程,因此 MESCM 指标或会在未发生异常阶段出现急剧增长现象,如在  $t_1 \sim t_{400}$  采样时刻系统处于正常波动状态并未设置异常扰动,但

MESCM 指标此时段内却突然增大,明显越过 Spiked 模型阈值,导致误判现象的发生。而 MESCM 并未突破 CNN 阈值,表明该阈值模型在适应 MESCM 指标非异常的波动变化的同时,能够判定出 MESCM 指标的异常扰动变化。

此外,将本文所提阈值模型应用于随机矩阵理论的单环定律中,其中各参数与上述相同,但由于 MESCM 与 MSR 指标计算方式存在差异性,则在此设置式(6)中的比例系数  $\alpha$  为 0.98。根据大数据分析,可获得 MSR 指标及各阈值的变化曲线,如图 5 所示。

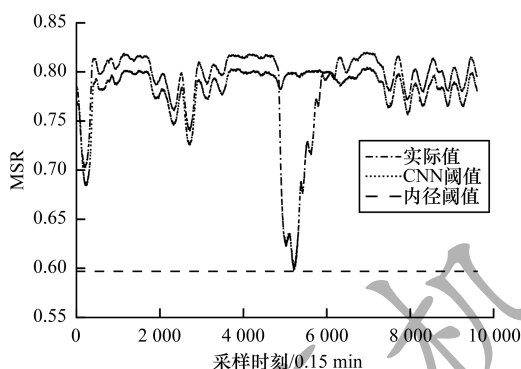


图 5 MSR 指标及阈值模型计算结果

Fig. 5 MSR indicator and threshold model calculation results

由图 5 可知,在  $t_{4801}$  至  $t_{5200}$  采样时间段内随着异常扰动的发生,特征分布出现“坍塌”现象,MSR 指标跌落至最低值 0.597 8,但并未偏离内径限值,而在  $t_{4801}$  采样时刻越过了 CNN 阈值模型,证明该阈值也能够对 MSR 指标的异常变化进行有效判定。

**场景 2** 低信噪比场景下不同幅值异常扰动测试。

设置系统中 66 号母线的负荷异常扰动变化为表 1 的 30%,并在  $\rho = (25 \pm 0.3)$  dB 的低信噪比场景下进行测试,其他参数均与场景 1 相同,继而根据第 3 节步骤可得到图 6。

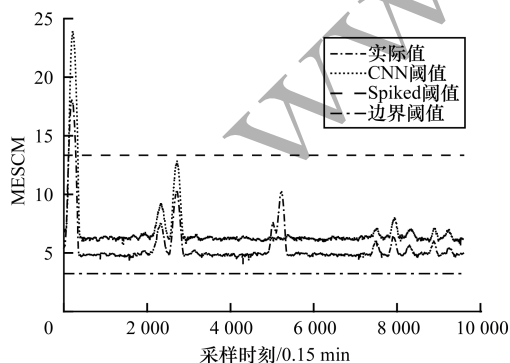


图 6 MESCM 指标及阈值模型的计算结果 2

Fig. 6 MESCM indicator and threshold model calculation results 2

对比图 4 与图 6 可知,在低信噪比场景下,由于强噪声的影响以及异常负荷幅值的降低,图 6 中的 MESCM 指标相比于图 4 的 MESCM 指标整体降低了 51%,同时,与信噪比  $\rho$  相关的 Spiked 阈值由 20.8 近似下降至 13.3,但在  $t_{4801} \sim t_{5200}$  采样时间段内 MESCM 指标并未越过 Spiked 模型阈值,从而导致了漏判现象的发生。此时,CNN 阈值模型仍能判定出 MESCM 指标的异常变化,表明了基于 CNN 阈值模型的 MESCM 指标适用于低信噪比场景下不同幅值异常负荷的扰动判别。

## 5 结束语

本文提出一种适用于电网异常负荷动态判别的 CNN 阈值模型。基于 MESCM 方法与原理,利用 CNN 实现历史负荷数据到动态阈值的映射,以及在负荷波动性较大的电网中 MESCM 对异常负荷的监测。借助 Matlab R2014a 和 PST 软件工具,通过一个 IEEE50 机 145 母线标准系统的算例验证了该方法的有效性,相较于传统阈值模型,在动态电网中本文所提的阈值模型对 MESCM 指标的异常判定适应性更强,准确性更高。下一步将利用级联 CNN 实现从电气量测数据至阈值模型的直接映射,以提高对异常负荷识别的快速性。

## 参考文献

- [1] LI Duanchao, WANG Song, HUANG Taigui, et al. Key technologies of line loss and stealing electricity prediction analysis based on big data platform[J]. Power System Protection and Control, 2018, 46(5): 143-151. (in Chinese)  
李端超,王松,黄太贵,等.基于大数据平台的电网线损与窃电预警分析关键技术[J].电力系统保护与控制,2018,46(5):143-151.
- [2] BHATTARAI B P, PAUDYAL S, LUO Y, et al. Big data analytics in smart grids: state-of-the-art, challenges, opportunities, and future directions[J]. IET Smart Grid, 2019, 2(2): 141-154.
- [3] WU Kehe, ZHU Yayun, LI Haoyang, et al. Real-time prediction framework for power grid time-series data based on storm[J]. Computer Engineering, 2017, 43(4): 8-14. (in Chinese)  
吴克河,朱亚运,李皓阳,等.基于 Storm 的电网时间序列数据实时预测框架[J].计算机工程,2017,43(4):8-14.
- [4] HOSSAIN E, KHAN I, UN-NOOR F, et al. Application of big data and machine learning in smart grid, and associated security concerns: a review[J]. IEEE Access, 2019, 7: 13960-13988.
- [5] XU Xinyi, HE Xing, AI Qian, et al. A correlation analysis method for power systems based on random matrix theory[J]. IEEE Transactions on Smart Grid, 2017, 8(4): 1811-1820.

- [6] LIU Wei, ZHANG Dongxia, DING Yucheng, et al. Power grid vulnerability identification methods based on random matrix theory and entropy theory [J]. Proceedings of the Chinese Society for Electrical Engineering, 2017, 37(20): 5893-5901. (in Chinese)  
刘威, 张东霞, 丁玉成, 等. 基于随机矩阵理论与熵理论的电网薄弱环节辨识方法[J]. 中国电机工程学报, 2017, 37(20): 5893-5901.
- [7] HE X, QIU R C, CHU L, et al. Invisible units detection and estimation based on random matrix theory[EB/OL]. [2019-09-10]. <https://arxiv.org/abs/1710.10745?context=stat.AP>.
- [8] HAN Song, ZHOU Zhongqiang, LI Hongqian. Spiked population model based abnormal state detection of power system in low SNR environment[C]//Proceedings of 2018 International Conference on Power System Technology. Guangzhou, China: [s. n.], 2018: 125-136.
- [9] ZHOU Zhongqiang, HAN Song. MESCM based abnormal state detection of power system in low SNR environment[J]. Power System Protection and Control, 2019, 47(8): 113-119. (in Chinese)  
周忠强, 韩松. 基于样本协方差矩阵最大特征值的低信噪比环境电网异常状态检测[J]. 电力系统保护与控制, 2019, 47(8): 113-119.
- [10] LI Hongqian, HAN Song, ZHOU Zhongqiang. Efficient abnormal load identification in large-scale power system employing Rayleigh quotient and parallel computing technology[J]. Power System Protection and Control, 2019, 47(23): 37-43. (in Chinese)  
李洪乾, 韩松, 周忠强. 利用 Rayleigh 熵和并行计算的大规模电网异常负荷快速识别[J]. 电力系统保护与控制, 2019, 47(23): 37-43.
- [11] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 23: 1097-1105.
- [12] LIN Junhao, ZHANG Yan, ZHAO Teng, et al. Structure strength assessment method of distribution network based on improved convolution neural network and network topology feature mining[J]. Proceedings of the Chinese Society for Electrical Engineering, 2019, 39(1): 84-96. (in Chinese)  
林君豪, 张焰, 赵腾, 等. 基于改进卷积神经网络拓扑特征挖掘的配电网结构坚强性评估方法[J]. 中国电机工程学报, 2019, 39(1): 84-96.
- [13] ZHANG Chongyuan, YUE Haotian, WANG Boyun, et al. Pattern recognition of partial discharge ultrasonic signal based on similar matrix BSS and deep learning CNN[J]. Power System Technology, 2019, 43(6): 1900-1906. (in Chinese)  
张重远, 岳浩天, 王博闻, 等. 基于相似矩阵盲源分离与卷积神经网络的局部放电超声信号深度学习模式识别方法[J]. 电网技术, 2019, 43(6): 1900-1906.
- [14] LIU Wei, ZHANG Dongxia, WANG Xinying, et al. A decision making strategy for generating unit tripping under emergency circumstances based on deep reinforcement learning [J]. Proceedings of the Chinese Society for Electrical Engineering, 2018, 38(1): 109-119. (in Chinese)  
刘威, 张东霞, 王新迎, 等. 基于深度强化学习的电网紧急控制策略研究[J]. 中国电机工程学报, 2018, 38(1): 109-119.
- [15] JU Yun, SUN Guangyu, CHEN Quanhe, et al. A model combining convolutional neural network and light GBM algorithm for ultra-short-term wind power forecasting [J]. IEEE Access, 2019, 7: 28309-28318.
- [16] O'ROURKE S. A note on the Marchenko-Pastur law for a class of random matrices with dependent entries [J]. Electronic Communications in Probability, 2012, 17: 18-26.
- [17] LI Wenting, WANG Meng. Identifying overlapping successive events using a shallow convolutional neural network[EB/OL]. [2019-09-10]. <https://www.researchgate.net/publication>.
- [18] TANG Conglan, LU Jiping, XIE Yingzhao, et al. Improved data stream on-line segmentation based ultra short-term load forecasting [J]. Power System Technology, 2014, 38(7): 2014-2020. (in Chinese)  
唐聪岚, 卢继平, 谢应昭, 等. 基于改进数据流在线分割的超短期负荷预测[J]. 电网技术, 2014, 38(7): 2014-2020.
- [19] KIM J, MOON J, HWANG E, et al. Recurrent inception convolution neural network for multi short-term load forecasting[J]. Energy and Buildings, 2019, 194: 328-341.
- [20] WANG Lei, ZHANG Ruiqing, SHENG Wei, et al. Regression forecast and abnormal data detection based on support vector regression [J]. Proceedings of the Chinese Society for Electrical Engineering, 2009, 29(8): 92-96. (in Chinese)  
王雷, 张瑞青, 盛伟, 等. 基于支持向量机的回归预测和异常数据检测[J]. 中国电机工程学报, 2009, 29(8): 92-96.
- [21] RONG Na, LI Zetao, HAN Song. Improved relative-locality index of electromechanical oscillation mode and its adaptability [J]. Electric Power Automation Equipment, 2017, 37(2): 140-144. (in Chinese)  
荣娜, 李泽滔, 韩松. 改进的机电振荡模式相对局域性指标及其适应性[J]. 电力自动化设备, 2017, 37(2): 140-144.
- [22] ZHAO Hui. Simulation of typical daily load curve by spline interpolation [J]. Power System Technology, 1998, 22(5): 41-43. (in Chinese)  
赵晖. 用样条插值法模拟典型日负荷曲线[J]. 电网技术, 1998, 22(5): 41-43.