

基于动态响应特征学习的综合负荷模型构成在线辨识

程颖¹, 董炜¹, 姜震韬², 汤奕², 冯长有³

(1. 国网浙江省电力有限公司电力科学研究院, 杭州 310014;

2. 东南大学 电气工程学院, 南京 210096;

3. 国家电网有限公司国家电力调度控制中心, 北京 100031)

摘要: 负荷构成的实时精确辨识对电力系统仿真分析具有重要意义。当前基于传统优化方法的辨识过程难以处理多维时序特征且计算耗时高, 导致辨识精度不足, 无法满足在线应用。对此, 融合注意力机制的特征加权能力与 CNN(卷积神经网络)的特征提取能力, 提出一种适用于有源综合负荷模型的负荷构成在线辨识方法。首先, 从机理层面提出了含光伏和储能的有源综合负荷模型; 然后, 构建融合多尺度卷积与注意力机制的特征提取网络, 并行捕捉异构负荷特征并突出关键信息; 最后, 以负荷节点间参数的全域灵敏度之比作为评价指标, 筛选出关键负荷节点并针对目标节点进行辨识。算例结果表明, 与现有方法相比, 所提方法具有较高的辨识精度和鲁棒性, 可满足电力系统在大部分运行场景下的在线安全分析需求。

关键词: 综合负荷模型; 构成辨识; 卷积神经网络; 注意力机制; 深度学习

DOI: 10.19585/j.zjdl.202603008

开放科学(资源服务)标识码(OSID):



Online composition identification of integrated load models based on dynamic response feature learning

CHENG Ying¹, DONG Wei¹, JIANG Zhentao², TANG Yi², FENG Changyou³

(1. State Grid Zhejiang Electric Power Co., Ltd. Research Institute, Hangzhou 310014, China;

2. School of Electrical Engineering, Southeast University, Nanjing 210096, China;

3. National Power Dispatching and Control Center, State Grid Corporation of China, Beijing 100031, China)

Abstract: Real-time and accurate identification of load composition is of great significance for power system simulation and analysis. Current identification processes based on conventional optimization methods struggle to handle multidimensional temporal characteristics and are computationally intensive, leading to insufficient identification accuracy and an inability to meet the demands of online applications. To address this challenge, an online load composition identification method suitable for active integrated load models is proposed, integrating the feature weighting capability of attention mechanisms with the feature extraction capability of convolutional neural network (CNN). Firstly, an active integrated load model incorporating photovoltaics and energy storage is proposed from a mechanistic perspective. Subsequently, a feature extraction network integrating multi-scale convolution and attention mechanisms is constructed to capture heterogeneous load features in parallel and highlight critical information. Finally, key load nodes are screened based on the ratio of global parameter sensitivity among load nodes as an evaluation metric, and target nodes are identified accordingly. Case study results demonstrate that, compared to existing methods, the proposed approach achieves higher identification accuracy and robustness, meeting the requirements for online security analysis in most power system operational scenarios.

Keywords: integrated load model; composition identification; CNN; attention mechanism; deep learning

0 引言

负荷特性对电网稳定运行具有重要影响^[1-3]。

传统负荷模型无法准确反映其动态特性, 导致对系统动态响应分析和稳定性评估存在偏差。在临界情况下, 负荷模型的差异甚至会对分析结果产生质的影响^[4-6]。随着新型电力系统的建设, 负荷侧以光伏、储能为代表的分布式新能源和电力电子设备大量接入电网, 系统安全稳定问题愈发凸显, 建立能够准确反映负荷动态特性的等值模型

面临严峻挑战^[7-9]。

电力负荷模型依据其典型特性主要分为三类：静态负荷模型、动态负荷模型和综合负荷模型。静态负荷模型包括恒阻抗、恒电流和恒功率模型^[10-11]，描述有功、无功功率稳态值与电压及频率之间的函数关系，但无法表征状态量随时间变化的过程。动态模型将负荷的有功和无功功率表示为母线电压和时间的函数，典型动态模型包括感应电机负荷模型和指数恢复负荷模型^[12-13]，能够描述负荷在不同运行条件及扰动后的响应，但单一模型难以充分描述负荷的动态特性^[14]。因此，当前多数的负荷建模工作采用了综合负荷模型以准确表示负荷特征^[4,15]。随着大规模分布式电源并网以及海量电力电子设备的接入，简单的综合负荷模型已难以描述实际负荷的动态特性，负荷模型的精细化建模并准确描述其构成与动态特性，成为提升仿真精度的重要研究方向。

负荷模型的构成是对模型中各类负荷的类型、特性及其比例关系的系统性描述，是负荷建模任务中的核心参数之一。常规的电力系统负荷模型辨识方法主要包括三类：启发式优化方法、基于统计搜索技术的直接计算方法以及人工智能算法。以GA(遗传算法)、PSO(粒子群优化)为代表的启发式方法已被广泛用于负荷构成及模型内部参数辨识。文献[16]提出了一种结合GA和PSO的优化方法，用于辨识光伏逆变器的关键参数，从而提高其性能。文献[17]采用混沌海鸥优化算法提高了负荷辨识的精度，为电力系统的调度和管理提供了更加准确的参数支持。基于统计搜索的直接计算方法包括SVM(支持向量机)、KF(卡尔曼滤波)等。文献[18]使用SVM来改善负荷模型参数的泛化能力，提高了负荷模型在不同条件下的预测精度。文献[19]利用KF对实际电力系统进行静态负荷建模，并基于动态调整方法提升了负荷模型的精度和可靠性。上述方法在一些典型场景中取得了较好的效果，但仍存在以下问题：一方面，辨识过程依赖于系统大扰动或故障时的暂态响应，现实中此类场景极少发生，辨识结果不能充分反映电力负荷的时变特性；另一方面，该类方法计算复杂，每次辨识均需搜索全局最优参数，导致计算时间较长。为准确刻画负荷模型的时变

特性，需实现高频、低延迟的在线更新，传统长计算周期方法难以满足实时性与高效性需求。

近年来，深度学习因其强大的非线性映射能力和数据驱动特性逐渐被用于电力系统的各类参数辨识工作中，并在时效性方面取得了一定的突破^[20-24]。该方法通过时间序列模型学习参数的时变特性，适用于大规模复杂电网的负荷构成辨识任务。然而，现有研究多集中于单一深度学习模型的应用，未能充分利用电力负荷的多模态特征信息，导致模型实时辨识困难，且在复杂工况下的泛化能力受限^[25-28]。

针对上述问题，本文提出一种融合注意力机制和1D-CNN(一维卷积神经网络)的有源综合负荷模型构成辨识方法。将注意力机制引入多尺度卷积的1D-CNN，以深度捕捉模型的异构负荷特征，同时筛选出系统的关键区域与节点，以降低辨识难度。最后，通过在EPRI-36节点系统中测试，验证了所提方法的有效性。

1 综合负荷模型构成辨识框架

1.1 等值负荷模型结构

WECC CLM(西部电力协调委员会复合负荷模型)是北美电力系统广泛采用的一种动态负荷建模方法，旨在准确模拟电网中负荷的动态响应特性。本文在保留其主要动态特性和准确性的前提下，减少了参数数量和计算复杂度。

通过等值电路变换，将多台三相感应电机在单母线上聚合为一台具有相同结构但参数不同的等效电机，并保留其原有的动态特性。电力电子型负荷通常包括电动汽车充电桩和各类电子设备，这些负荷通过逆变器并网的BESS(电池储能系统)供电，其动态特性与常规电池储能系统相近，因此采用标准电池储能模型进行替代。单相感应电机对系统动态影响有限，故将其忽略。配电网中分布式电源的动态特性主要由变流器决定，且分布式光伏比例远大于其他电源类型，因此采用具有相同等值结构的单极式光伏模型。最后，保留WECC CLM中的变电站、馈线等部分，以模拟实际配电网中调压、拓扑变化等事件发生后等值负荷的参数变化。因此，本模型由馈线、变电站和负荷三部分组成，如图1所示，其中等值负荷部分

由单极式光伏、电池储能、动态负荷和静态负荷组成。

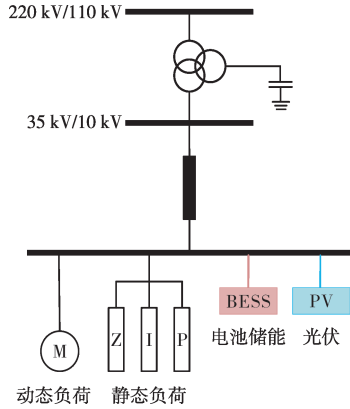


图 1 综合负荷等值模型

Fig.1 Equivalent integrated load model

综合负荷模型的构成是模型中各类负荷的功率配比, 其对模型内部机理及外特性的影响最大。设定模型的构成包括三类负荷的有功占比参数 α 、 β 、 γ , 其与模型端口有功功率注入量的关系如式 (1) 所示:

$$\begin{cases} P_{PV} = \alpha \times S_{PV_B} \\ P_{IM} = \beta \times (P_{bus} + P_{PV}) \\ P_{BESS} = \gamma \times S_{BESS_B} \end{cases} \quad (1)$$

式中: S_{PV_B} 为配电网中光伏的总容量; S_{BESS_B} 为配电网中电力电子负荷 BESS 总量; P_{bus} 为综合负荷模型除变压器及线路损耗外总消耗的有功功率。

1.2 负荷构成辨识框架

1.2.1 样本数据集构建

负荷响应轨迹特征由系统仿真模型决定。为使其贴近实际运行数据, 并提升样本多样性与覆盖性, 需合理规划扰动设置及扰动下的样本生成过程。

1) 扰动设置

为满足系统在线安全分析的需求, 分别在负荷节点中设置各类负荷功率随机波动叠加以及大扰动故障下的噪声注入, 如图 2 所示。同时, 为保证算法的辨识精度, 目标节点本身不注入波动。

2) 样本随机生成

采用蒙特卡洛法生成样本, 以覆盖负荷模型的全部参数。将待辨识节点的负荷构成设为标签, 其模型参数在设定区间内随机生成。非关键区域

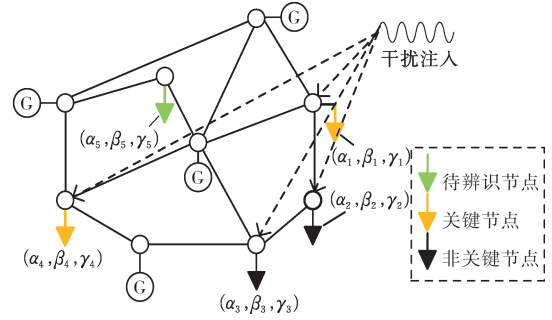


图 2 基于扰动的系统仿真拓扑

Fig.2 System simulation topology based on disturbances

参数取典型值, 以降低计算复杂度。样本中各类负荷节点参数的取值及属性如表 1 所示。

表 1 样本生成中的变量属性设置

Table 1 Variable attribute settings for sample generation

名称	字段	取值
待辨识负荷构成	目标值	区间随机生成
待辨识负荷其他参数	特征值	区间随机生成
其他关键节点参数	特征值	区间随机生成
非关键节点参数	特征值	典型值
小扰动参数	特征值	区间随机生成

1.2.2 辨识总体框架

将负荷模型的负荷构成参数及其余模型参数等信息作为一个组合特征量 μ , 不同的输入特征量导致模型响应轨迹显示出不同的轨迹形态特征 η , 即 μ 与综合负荷模型的电气量响应轨迹间存在着映射关系 f 。对于有源综合负荷模型, 其内部负荷构成参数相对于其他内部参数具有较高的灵敏度, 对模型响应轨迹的变化影响最大。

本文构建的有源综合负荷模型构成辨识框架如图 3 所示, 主要包含三个阶段: 训练数据集的构建、模型离线训练和在线应用辨识。

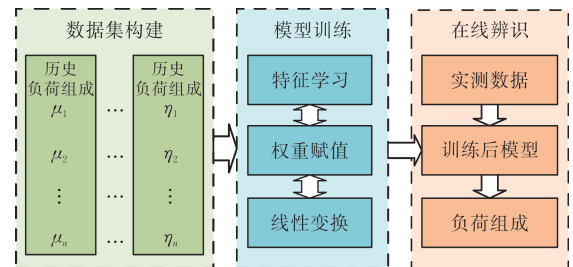


图 3 有源综合负荷模型构成辨识框架

Fig.3 Framework for composition identification of active integrated load models

首先, 在系统设定的随机小扰动或大扰动下, 对不同历史负荷构成及其响应轨迹进行采样, 形成样本数据集。然后, 将该数据集输入到已构建的待训练负荷辨识模型中进行模型自训练, 实现轨迹形态特征 η 与负荷构成参数间的隐式映射关系拟合。在应用阶段, 将系统实测的电气量响应轨迹输入到训练后的模型中, 网络快速辨识并输出负荷模型构成参数, 从而完成负荷构成辨识任务。

2 融合注意力机制和 CNN 的负荷构成辨识

各类负荷在扰动下的响应特性差异显著, 其时序特征表现出非一致性。若采用统一建模, 易掩盖关键动态差异, 进而影响模型判别与泛化性能。为此, 本文构建了一种融合多尺度卷积与注意力机制的辨识模型, 并行捕捉异构负荷特征并突出关键信息, 以增强辨识模型的识别能力及物理可解释性。

2.1 1D-CNN

近年来, 1D-CNN 因其强大的特征提取能力而在电力系统中得到广泛应用。区别于多维 CNN, 电力系统中的运行数据通常为一维时间序列, 在系统暂态稳定评估、非侵入式负荷分解等工作任务中, 常采用 1D-CNN 从海量数据中提取关键特征。

2.2 注意力机制原理

1D-CNN 在处理复杂数据时, 常会忽略一些重要的全局信息或长距离依赖关系, 并对不重要的特征进行冗余计算。因此, 亟需引入一种动态机制以调整权重, 减少低权重特征的计算。

注意力机制通过动态计算输入数据中每个部分的重要性权重, 使模型专注于对输出结果最关键的信息进行处理, 从而有效提升特征提取的性能。

将注意力机制作为 1D-CNN 的一个附加模块, 在模型进行卷积操作时, 通过滑动窗口提取不同局部特征, 生成对应的二维特征图。根据特征图的重要性权重分配算力, 并实时反馈执行效果以指导特征图权重的更新。具体实施步骤如下:

1) 对卷积时生成的每个特征图进行池化操作, 并将其加权为一个实数, 组合成特征权重向量:

$$z_c = \frac{1}{H \times M} \sum_{i=1}^H \sum_{j=1}^M u_c(ij) \quad (2)$$

式中: u_c 为卷积结果; H 和 M 分别为特征图的长和宽; z_c 为每个特征图的重要性权重。

2) 通过全连接操作 ReLU 激活函数, 将权重赋予每个特征类别, 得到加权后的特征图:

$$s = \sigma(\Gamma z_c) \quad (3)$$

式中: σ 为激活函数; Γ 为全连接操作。

3) 最后, 根据式(4)指导特征图权重的更新:

$$x_c = s_c u_c \quad (4)$$

式中: s_c 为所有特征图的权重向量。

2.3 融合注意力机制的 1D-CNN 算法

本文设计了一种融合注意力机制的 1D-CNN 用于提取负荷的时序状态特征, 网络结构如图 4 所示。

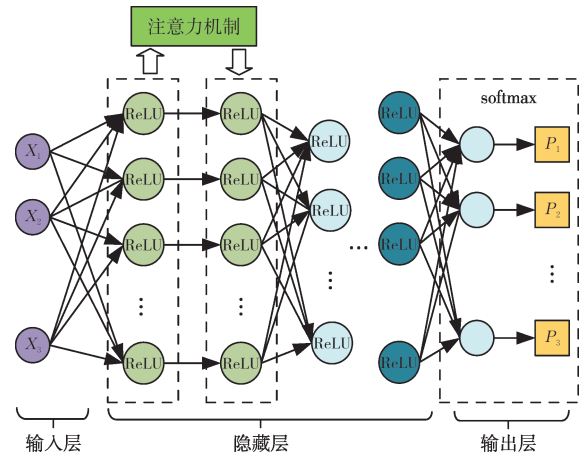


图4 融合注意力机制的 1D-CNN 结构

Fig.4 Structure of the 1D-CNN integrated with attention mechanism

1D-CNN 由输入层、卷积层、池化层、全连接层和输出层组成。输入层对电力系统中原始的时间序列数据作归一化处理, 这种标准化处理有助于后续高效地进行特征提取和负荷辨识。

卷积层通过捕捉时间序列中的时序关系、周期性波动和突变等重要特征信息, 实现对上层输出的卷积操作。为适应不同类型负荷在动态响应特性上的频率差异, 采用多尺度卷积核并行捕捉异构负荷特征。同时, 基于非线性激活函数构造出卷积结果的输出特征, 其数学表达为:

$$y_i^{l+1}(j) = K_i^l * x^l(j) + b_i^l \quad (5)$$

式中: $x^l(j)$ 为第 l 层的第 j 个局部区域; b_i^l 为第 i

层卷积核的偏差; K_l^i 为第 i 层卷积核的权值; $y_i^{l+1}(j)$ 为第 i 帧 $l+1$ 层第 j 个神经元的输入。

引入注意力机制,在卷积层充分挖掘特征信息生成特征图后,根据其对构成辨识任务的贡献动态调整权重,以突出关键特征信息。同时,采用 ReLU 函数作为激活函数,将卷积层输出转化为非线性函数,实现复杂数据的拟合。当输入值大于 0 时,该函数的导数值始终为 1,从而有效克服了梯度弥散的问题。

$$a_i^{l+1}(j) = f(y_i^{l+1}(j)) = \max\{0, y_i^{l+1}(j)\} \quad (6)$$

式中: $y_i^{l+1}(j)$ 为卷积层的输出数据; $a_i^{l+1}(j)$ 为 $y_i^{l+1}(j)$ 的激活值。

池化层通过下采样操作降低神经网络的空间维度,增强模型的鲁棒性并防止过拟合。本文采用最大池化方法,保留感知域中的最大值作为输出,舍弃无关值,从而实现降采样。最大池化公式如下:

$$P_i^{l+1}(j) = \max_{(j-1)W+1 \leq t \leq jW} \{q_i^l(t)\} \quad (7)$$

式中: $q_i^l(t)$ 为第 l 层特征中第 t 个神经元的值; W 为池化区域的宽度; $P_i^{l+1}(j)$ 为 $l+1$ 层神经元值。

输出层使用 softmax 激活函数,将卷积网络提取的特征映射到最终任务的结果形式,其输出为目标节点的负荷构成参数。

2.4 系统关键负荷节点筛选方法

在电力系统中,通常包含多个负荷节点。当全网负荷过多时,辨识所有负荷模型的构成参数将会产生严重的维度灾难。因此,需要筛选出与目标节点相关性较大的节点与参数,划定关键区域与关键节点,而剩余负荷模型的参数固定为典型值。

对于含有 N 个参数的负荷模型,电力系统关键负荷节点筛选的计算步骤如下:

1) 在 $0 \sim 1$ 范围内生成一个长度为 N 的随机列向量,并将其按各参数上下限映射为具体参数向量 $\hat{\theta}$ 。

2) 将 $\hat{\theta}$ 输入到仿真模型,在给定小干扰下进行仿真,输出相应的综合负荷端口的有功和无功功率,并基于给定上下限对其归一化,得到响应轨迹 $O(\hat{\theta})$ 。

3) 将 $\hat{\theta}$ 中第 i 个参数 θ_i 改为 $\theta_i + \delta$, 再次仿真

获得 $O(\hat{\theta}_i)$, 按式(8)计算,重复此步骤,直至计算完所有参数 $\hat{\theta}$ 上的局部灵敏度,获取灵敏度向量:

$$\nabla_{\theta_i} O = |O(\hat{\theta}_i) - O(\hat{\theta})| / 2\delta T \quad (8)$$

式中: T 为采样总数; $O(\hat{\theta}_i)$ 是将 $\hat{\theta}$ 中第 i 个参数 θ_i 改为 $\theta_i + \delta$ 并再次仿真获得的响应轨迹; δ 为一极小随机数。

4) 重复上述步骤,获取若干样本,对这些样本取平均,作为本模型的所有参数在小干扰下对于端口动态响应的 GSA(全域灵敏度) $\nabla_{\theta} O_{\text{global}}$ 。

5) 将本节点响应 O 对该节点下负荷参数与其他负荷节点参数的 GSA 之比作为评价指标:

$$K_{n \rightarrow m} = \frac{1}{N} \sum_{i=1}^N \frac{\nabla_{\theta_i, m} O_{m, \text{global}}}{\nabla_{\theta_i, n} O_{m, \text{global}}} \quad (9)$$

式中: m 和 n 为节点编号。

显然,外部节点的 GSA 不可能大于本节点,故 $K \in (0, 1)$ 。在针对节点 m 进行负荷建模前,在给定小扰动下计算全网所有负荷节点对应的 K 值,筛选出 K 较大的节点作为关键节点,而剩余节点为非关键节点,在辨识过程中忽略其参数变化。

3 算例分析

3.1 算例设置

3.1.1 系统配置

在 PSASP 中搭建 EPRI-36 节点系统以测试辨识算法,以 3 号母线下的负荷节点为辨识目标,系统拓扑如图 5 所示。

将系统中的所有静态负荷节点模型替换为有源综合负荷模型,模型中的电池储能容量、光伏装机容量、等值变压器容量分别设置为 100 MVA、300 MVA、500 MVA,其余模型参数在筛选出关键负荷节点前设置为调整范围的中间值。实验在配备 AMD Ryzen 74 800U with Radeon Graphics 处理器和 16.0 GB RAM 内存的笔记本电脑上完成。

3.1.2 扰动设置

1) 随机小扰动

采用正弦波模型叠加的方法来模拟多种负荷波动源的综合影响。

$$P = \sum_{i=1}^N a_i \times \sin(\omega_i t + \delta_i) \quad (10)$$

式中: $a_i \sim U[0, 0.1 \times P_0]$, $\omega_i \sim U[0, 100\pi]$,




图5 EPRI-36节点系统拓扑

Fig.5 Topology of the EPRI-36 node system

$\delta_i \sim U[0, \pi]$, P_0 为节点潮流初值, 本文设置 $N=10$, ω_i 与 ω_{i+1} 按0.25~0.5倍率递进。

此外, 引入阶跃函数模型来模拟实际系统中因设备启停或电动汽车充电等事件造成的突发性负荷波动, 表达式如下:

$$P = \Delta P \times u(t - t_0) \quad (11)$$

式中: ΔP 为负荷变化量; $u(t - t_0)$ 为单位阶跃函数, 表示在 t_0 时刻发生负荷跳变。

2) 大扰动下噪声注入

分别在系统中BUS3与BUS2之间以及Bus9与Bus13之间的交流线路中段设置一次单相短路故障和一次单相断线故障。同时, 考虑到实际系统中通常存在测量误差和环境干扰, 将仿真生成的电气量数据叠加白噪声, 其概率密度函数为:

$$p(x) = \frac{1}{\sqrt{2\pi\delta^2}} \exp\left[-\frac{x^2}{2\delta^2}\right] \quad (12)$$

式中: x 为随机变量, 表示具体的噪声幅值; δ 为标准差, 描述噪声的波动幅度, 本文设置 $\delta=0.005$ 。

3.1.3 训练样本集生成

训练前, 通过循环调用仿真生成训练样本集。每次仿真前, 按表2的设定随机生成扰动参数和负荷模型参数。单次仿真时长为5s, 采样周期为0.01s。仿真结束后生成以下数组:

1) 待辨识负荷随机生成的样本标签, 即等值模型负荷构成。

2) 量测曲线4条, 包括等值变压器高压侧注入有功功率和无功功率, 3号母线上的电压和频率。

鉴于实际配电网中未必能够在短期内监测并记录大量的暂态扰动数据, 因此生成样本数量设定为1000组, 以贴合实际情况。

表2 负荷构成参数分布范围

Table 2 Parameter distribution ranges for load composition

负荷	参数	经典值	设定区间
构成	α	0.2	[0, 1]
	β	0.4	[0, 1]
	γ	0.1	[0, 1]

3.1.4 网络参数设置

网络架构及参数设置如表3所示。输入层的数据维度为 4×500 , 表示输入仿真生成的含500个采样点的 V 、 P 、 Q 、 F 时序响应曲线。

表3 1D-CNN参数设置

Table 3 Parameter settings for 1D-CNN

层类型	参数	激活函数
输入层	Gaussian Noise=0.000 01	—
	BN=True	—
卷积池化层	filters=256, kernel size=5, padding='same'	ReLU
全连接层	—	ReLU
输出层	—	—

卷积层引入Same Padding以避免边缘信息丢失。从卷积层输出的特征数据经Flatten扁平化后进入全连接层, 经线性变换后输出辨识结果。

为避免过拟合, 采用Adam优化器训练网络, 初始学习率为0.001。从1000组样本数据集中选择前80%为训练集, 后20%作为测试集。

损失函数在CNN中是模型优化和训练的核心, 用来衡量模型辨识结果与实际标签之间的差距。本文设定其为负荷构成的平均绝对误差, 具体定义如下:

$$L = \frac{1}{3} (|\alpha - \hat{\alpha}| + |\beta - \hat{\beta}| + |\gamma - \hat{\gamma}|) \quad (13)$$

式中: $\hat{\alpha}$ 、 $\hat{\beta}$ 、 $\hat{\gamma}$ 为网络辨识结果。

3.2 关键负荷节点筛选

采用1.2节中所述的筛选方法, 分析各节点对目标负荷节点所在3号母线上响应的影响程度。在同一组包含500个随机小扰动场景的场景库下, 分

别计算系统8个负荷节点下有源综合负荷模型各参数的GSA,结果如图6所示。




图6 各负荷模型参数对本母线响应的全域灵敏度结果
Fig.6 Global sensitivity analysis results of various load model parameters on local bus response

由图6可知,本母线负荷模型参数的变化对本母线响应的影响,相较于其他负荷节点更为显著。根据系统拓扑图6中节点位置分布,影响程度主要取决于负荷节点间的电气距离,同时在相近距离下,距离发电机组节点越近,其负荷参数的影响更大。根据式(9)计算出关键程度的评价指标K,结果如图7所示。




图7 节点评价指标K值结果
Fig.7 Results of the node evaluation index K-value

可以看出,各节点的重要程度变化趋势呈均匀下降。这是由于目标负荷位于系统拓扑的边缘位置,其余节点与其距离按一定梯度增大,取δ为0.1。因此,在辨识过程中,将节点18、节点23、节点16的负荷构成及内部参数取为典型值。

3.3 训练结果与构成辨识效果

3.3.1 损失函数变化

在Python3.10中分别搭建了本文提出的融合

注意力机制的1D-CNN、无卷积的ANN(人工神经网络)和传统1D-CNN。将预先生成的1000组样本数据集分别导入这三种网络进行训练,并记录训练过程中三种网络的平均损失变化,结果如图8所示。




图8 网络损失函数变化曲线
Fig.8 Variation curve of the network loss function

观察可知,在前200轮的迭代训练中,三种网络的损失变化均呈快速下降的趋势,这表明神经网络算法对响应数据的特征提取有着不错的效果。从400轮开始,三种网络的损失变化呈收敛态势。在随后的500轮训练中,ANN的平均损失逐渐下降到0.17,传统CNN和本文所提1D-CNN的平均损失分别下降到0.08和0.06左右。这表明相对于无卷积层的ANN,CNN能够更有效地辨识暂态轨迹中的短暂特征,并以更小的误差辨识负荷构成。同时,注意力机制的引入增强了模型对关键特征的关注,从而表现出比传统网络更好的效果。

为检验训练好的模型对负荷构成辨识效果的提升,从测试集随机选取一个样本,并计算辨识值和真实值的误差,结果如表4所示。

表4 负荷构成辨识误差对比

Table 4 Comparison of load composition identification errors

参数	辨识值	实际值	误差/%
α	0.556 1	0.578 4	3.9
β	0.723 5	0.786 6	1.4
γ	0.231 2	0.247 1	6.3

可见,所提算法对于负荷构成辨识具有良好的效果,能够有效捕捉各类负荷变化的关键特征,且辨识误差均能稳定控制在7%以内。

3.3.2 小扰动下模型负荷辨识效果

为了进一步分析所提方法在电力系统负荷辨识任务中的普遍性和稳定性,从测试集中随机抽取80组样本导入训练好的模型,绘制其辨识结果与真实值之间的误差分布图进行对比分析,结果如图9—11所示。




图9 负荷构成 β 辨识误差分布

Fig.9 Distribution of load composition β identification errors




图10 负荷构成 α 辨识结果分布

Fig.10 Distribution of load composition α identification results

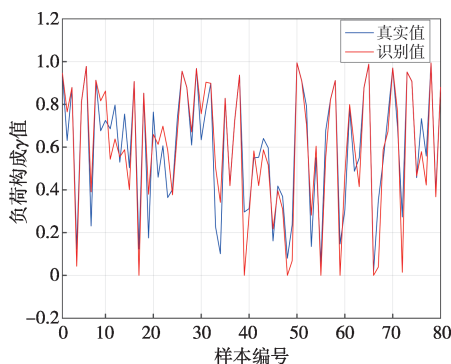


图11 负荷构成 γ 辨识结果分布

Fig.11 Distribution of load composition γ identification results

由图9可知,综合负荷构成 β 的辨识结果普遍分布在真实值附近,辨识精度达到96%。这表明

该方法不仅辨识精度较高,而且能够保持良好的稳定性,属于理想的辨识效果。

相比于图9的理想分布情况,分布式电源参数 α 和电池储能构成参数 γ 的辨识误差相对较大,个别误差甚至超过13%。这是因为电池储能与光伏模型具有较强的波动性和非线性特征,不容易通过固定的卷积核模式直接捕捉。后续可以通过优化时序建模能力来提高这类负荷的辨识精度。

3.3.3 拟合度仿真校验

对于有源综合负荷模型,负荷构成参数的轨迹灵敏度各不相同,因此负荷构成的辨识误差不能等同于响应轨迹误差。为检验辨识误差造成的响应误差,将表4中的辨识值和实际值分别输入仿真系统,生成 V 、 P 、 Q 的暂态响应轨迹,与实际轨迹对比拟合度,结果如图12所示。

观察可知,在系统中众多模型参数及扰动均变化的情况下,三类负荷构成的辨识轨迹与实际轨迹仍能保持较高的拟合度,且变化趋势基本一致。这说明所提方法在响应特性层面具备较好的准确性与适应性。最后,计算出测试集中200组样本的波形平均拟合度,结果如表5所示。

由表5可知,基于本文所提算法的任一电气量轨迹拟合度均优于ANN和传统CNN,其平均拟合度为96.1%,显示出较好的拟合效果。

3.3.4 大扰动下模型性能分析

针对大扰动场景下含噪声注入的运行数据,进行模型输出响应与实际仿真结果的对比分析。采用与前文相同的方法计算,选取负荷构成 β 的辨识误差分布及电压响应轨迹拟合度进行对比,结果如图13、图14所示。

观察可知,相比于小扰动工况,模型在大扰动及噪声注入条件下的参数辨识误差略有增加,但仍处于可控范围内,且模型依然保持较高的响应一致性。这表明所提方法具有良好的泛化能力与鲁棒性。

3.4 在线辨识耗时评估

为验证所提方法在实际系统中的在线应用可行性,对不同模型的训练时间与在线辨识耗时进行了评估分析,结果如表6所示。

观察可知,PSO每次辨识均需搜索全局最优参数,平均耗时高达137 min。相比之下,改进型CNN与ANN在1 000轮次下的训练耗时分别为




图 12 负荷构成辨识前后响应轨迹拟合度

Fig.12 Fitting degree of response trajectories before and after load composition identification

表 5 测试集的轨迹平均拟合度

Table 5 Average trajectory fitting degree of the test set

网络	电压	有功	无功	平均
改进 CNN	97.4	95.5	96.3	96.1
传统 CNN	95.8	93.7	94.5	94.6
ANN	93.4	92.8	92.6	92.9

117 min 和 123 min, 训练过程为一次离线完成, 训练完成后单次辨识耗时分别为 0.016 s 和 0.018 s, 达到毫秒级响应速度。所提改进型 CNN 在训练耗时、模型稳定性和特征提取能力方面均优于传统 ANN, 满足电力系统在各类运行场景下的在线安




图 13 大扰动下 β 辨识误差分布

Fig.13 Distribution of β identification errors under significant disturbances




图 14 电压响应轨迹拟合度

Fig.14 Fitting degree of voltage response trajectories

表 6 不同辨识方法耗时统计

Table 6 Time consumption statistics of different identification methods

网络	训练时间	辨识时间
改进 CNN	117 min	0.016 s
ANN	123 min	0.018 s
PSO	—	137 min

全分析需求。

4 结论

本文针对当前负荷模型构成参数的辨识精度问题, 提出一种融合注意力机制和 CNN 的有源综合负荷模型构成辨识方法, 得出以下结论:

1) 所提算法在随机小扰动和大扰动下对有源综合负荷模型的构成辨识精度高于 ANN 和传统 CNN, 且在线辨识阶段达到毫秒级响应, 满足实际系统在线辨识的需求。

2) 分布式电源和电池储能构成辨识误差相对于其他负荷较大。在后续研究中, 可以通过优化

时序建模能力来提高这类负荷的辨识精度。

参考文献

- [1] 陈国平,李明节,许涛,等.关于新能源发展的技术瓶颈研究[J].中国电机工程学报,2017,37(1):20-27.
CHEN Guoping, LI Mingjie, XU Tao, et al. Study on technical bottleneck of new energy development [J]. Proceedings of the CSEE, 2017, 37(1): 20-27.
- [2] 孙华东,李佳豪,李文锋,等.大规模电力系统仿真用新能源场站模型结构及建模方法研究(二):机电暂态模型[J].中国电机工程学报,2023,43(6):2190-2202.
SUN Huadong, LI Jiahao, LI Wenfeng, et al. Research on model structures and modeling methods of renewable energy station for large-scale power system simulation(II): electromechanical transient model [J]. Proceedings of the CSEE, 2023, 43(6): 2190-2202.
- [3] 陈忠玉,徐晋,汪可友,等.计及跟随型和支撑型分布式光伏的广义综合负荷模型及两阶段参数聚合等效方法[J].电力自动化设备,2023,43(3):86-93.
CHEN Zhongyu, XU Jin, WANG Keyou, et al. Generalized composite load model and two-stage parameter aggregation and equivalent method considering grid-following and grid-forming distributed photovoltaic [J]. Electric Power Automation Equipment, 2023, 43(3): 86-93.
- [4] 鞠平,郭德正,曹路,等.含主动负荷的综合电力负荷建模研究综述与展望[J].河海大学学报(自然科学版),2020,48(4):367-376.
JU Ping, GUO Dezheng, CAO Lu, et al. Review and prospect of modeling on generalized synthesis electric load containing active loads [J]. Journal of Hohai University (Natural Sciences), 2020, 48(4): 367-376.
- [5] 徐重酉,王明月,刘天元,等.非理想通信环境下主动配电网柔性负荷建模与优化控制方法[J].浙江电力,2023,42(11):104-113.
XU Chongyou, WANG Mingyue, LIU Tianyuan, et al. A modeling and optimal control method of flexible load in the active distribution networks in non-ideal communication environments [J]. Zhejiang Electric Power, 2023, 42(11): 104-113.
- [6] 王国春,许洪强,冯长有,等.新一代在线安全分析技术架构及未来展望[J].电力系统自动化,2023,47(24):110-120.
WANG Guochun, XU Hongqiang, FENG Changyou, et al. Technical architecture and future prospect for new generation of online security analysis [J]. Automation of Electric Power Systems, 2023, 47(24): 110-120.
- [7] 舒印彪,张智刚,郭剑波,等.新能源消纳关键因素分析及解决措施研究[J].中国电机工程学报,2017,37(1):1-9.
SHU Yinbiao, ZHANG Zhigang, GUO Jianbo, et al. Study on key factors and solution of renewable energy accommodation [J]. Proceedings of the CSEE, 2017, 37(1): 1-9.
- [8] 郭剑波,王铁柱,罗魁,等.新型电力系统面临的挑战及应对思考[J].新型电力系统,2023(1):32-43.
GUO Jianbo, WANG Tiezhu, LUO Kui, et al. Development of new power systems: challenges and solutions [J]. New Type Power Systems, 2023(1): 32-43.
- [9] LAN T K, SUN H D, WANG Q, et al. Synthesis load model with renewable energy sources for transient stability studies [J]. IEEE Transactions on Power Systems, 2024, 39(1): 1647-1663.
- [10] 周佩朋,李光范,孙华东,等.基于频域阻抗分析的直驱风电场等值建模方法[J].中国电机工程学报,2020,40(增刊1):84-90.
ZHOU Peipeng, LI Guangfan, SUN Huadong, et al. Equivalent modeling method of PMSG wind farm based on frequency domain impedance analysis [J]. Proceedings of the CSEE, 2020, 40(S1): 84-90.
- [11] ARIF A, WANG Z Y, WANG J H, et al. Load modeling: a review [J]. IEEE Transactions on Smart Grid, 2018, 9(6): 5986-5999.
- [12] HISKENS I A. Nonlinear dynamic model evaluation from disturbance measurements [J]. IEEE Transactions on Power Systems, 2001, 16(4): 702-710.
- [13] HUANG Q H, HUANG R K, PALMER B J, et al. A generic modeling and development approach for WECC composite load model [J]. Electric Power Systems Research, 2019, 172: 1-10.
- [14] ZHAO J B, WANG Z Y, WANG J H. Robust time-varying load modeling for conservation voltage reduction assessment [J]. IEEE Transactions on Smart Grid, 2018, 9(4): 3304-3312.
- [15] 胡心远.考虑多扰动场景的广义综合负荷模型参数辨识方法研究[D].天津:天津大学,2022.
HU Xinyuan. Study on parameter identification method of generalized composite load model considering multi-scenario disturbance [D]. Tianjin: Tianjin University, 2022.
- [16] 徐岩,靳伟佳,朱晓荣.基于遗传粒子群算法的光伏并网逆变器参数辨识[J].太阳能学报,2021,42(7):103-109.
XU Yan, JIN Weijia, ZHU Xiaorong. Parameter identification of photovoltaic grid-connected inverter based on gapso [J]. Acta Energetica Solaris Sinica, 2021, 42(7): 103-109.
- [17] 盛四清,关皓闻,雷业涛,等.基于混沌海鸱优化算法的含光伏发电系统负荷模型参数辨识[J].太阳能学报,2022,43(7):64-72.
SHENG Siqing, GUAN Haowen, LEI Yetao, et al. Parameter identification of load model of photovoltaic power gen-

- eration system based on chaotic seagull optimization algorithm[J]. Acta Energetica Solaris Sinica, 2022, 43(7): 64-72.
- [18] MA J, DONG Z Y, ZHANG P. Using a support vector machine (SVM) to improve generalization ability of load model parameters [C]//2009 IEEE/PES Power Systems Conference and Exposition. March 15-18, 2009, Seattle, WA, USA: IEEE, 2009: 1-8.
- [19] LEE S H, SON S E, LEE S M, et al. Kalman-filter based static load modeling of real power system using K-EMS data[J]. Journal of Electrical Engineering and Technology, 2012, 7(3): 304-311.
- [20] 虞殷树, 陈东海, 朱耿, 等. 基于改进关联分析的行业短期电力负荷预测[J]. 浙江电力, 2023, 42(11): 29-38.
YU Yinshu, CHEN Donghai, ZHU Geng, et al. A short-term power load forecasting method for industrial sectors based on an improved correlation analysis [J]. Zhejiang Electric Power, 2023, 42(11): 29-38.
- [21] 杨莹, 刘启航, 赵为光, 等. 基于深度强化学习的光氢储新能源汽车充电站优化调度[J]. 电力需求侧管理, 2025, 27(4): 92-97.
YANG Ying, LIU Qihang, ZHAO Weiguang, et al. Optimization scheduling of photovoltaic-hydrogen-storage for new energy vehicle charging station based on deep reinforcement learning[J]. Power Demand Side Management, 2025, 27(4): 92-97.
- [22] 刘斯亮, 郑泽南, 张勇军, 等. 计及灰数据的知识-数据驱动低压有源配电网潮流计算[J]. 电测与仪表, 2025, 62(6): 2-10.
LIU Siliang, ZHENG Zenan, ZHANG Yongjun, et al. Knowledge-data-driven power flow calculation for low-voltage active distribution network considering gray data [J]. Electrical Measurement & Instrumentation, 2025, 62(6): 2-10.
- [23] 李钟平, 向月. 深度强化学习驱动的风储系统参与能量-调频市场竞争策略[J]. 电力工程技术, 2025, 44(3): 30-42.
LI Zhongping, XIANG Yue. Deep reinforcement learning-driven bidding strategy for wind-storage systems in energy and frequency regulation markets [J]. Electric Power Engineering Technology, 2025, 44(3): 30-42.
- [24] 王建军, 潘佳音, 赵珍珠, 等. 基于特征时间双注意力机制的短期光伏发电预测深度学习模型研究[J]. 智慧电力, 2025, 53(4): 81-87.
WANG Jianjun, PAN Jiayin, ZHAO Zhenzhu, et al. A deep learning model for short-term photovoltaic power generation forecasting based on dual feature-temporal attention mechanism [J]. Smart Power, 2025, 53(4): 81-87.
- [25] 戴瑞成, 董翔, 赵璧, 等. 基于混合深度学习的变电站巡检机器人目标识别算法研究[J]. 智慧电力, 2025, 53(3): 117-123.
DAI Ruicheng, DONG Xiang, ZHAO Bi, et al. Research on target recognition algorithm for substation inspection robot based on hybrid deep learning [J]. Smart Power, 2025, 53(3): 117-123.
- [26] 翟乐庆, 刘益青, 魏元健, 等. 基于同步提取变换和卷积神经网络的有源配电网单相接地故障选线方法[J]. 山东电力技术, 2025, 52(2): 65-77.
ZHAI Leqing, LIU Yiqing, WEI Yuanjian, et al. A single-phase grounding fault line selection method for active distribution network based on synchroextracting transform and convolutional neural network [J]. Shandong Electric Power, 2025, 52(2): 65-77.
- [27] 焦昊, 赵佳伟, 韦磊, 等. 基于深度迁移学习的电力系统暂态状态估计[J]. 电力建设, 2025, 46(1): 97-106.
JIAO Hao, ZHAO Jiawei, WEI Lei, et al. Transient state estimation for power system based on deep transfer learning [J]. Electric Power Construction, 2025, 46(1): 97-106.
- [28] 白云鹏, 张志艳, 许才, 等. 基于多头注意力机制改进图神经网络的新能源电力系统风险评估[J]. 电力建设, 2025, 46(1): 147-157.
BAI Yunpeng, ZHANG Zhiyan, XU Cai, et al. Risk assessment of renewable energy power systems via graph multi-attention networks [J]. Electric Power Construction, 2025, 46(1): 147-157.

收稿日期: 2025-06-05; 修回日期: 2025-08-04

作者简介:

程颖(1995), 女, 工学硕士, 工程师, 主要从事电网运行方式分析计算的研究工作。

(本文编辑: 方明霞)