

基于卷积自注意力聚类算法的高比例新能源电力系统典型运行方式提取

付小标¹, 姜旭¹, 李欣蒙², 李云鹏¹, 刘鑫³, 吴嘉锴²

(1. 国网吉林省电力有限公司, 长春 130021; 2. 东北电力大学电气工程学院, 吉林 吉林 132012; 3. 国网长春供电公司, 长春 130021)

摘要: 传统基于人工经验制定的典型方式包含的运行场景多样性有限, 难以全面表征高比例新能源电力系统复杂的运行边界, 依此进行方式安排可能使系统存在安全风险盲区。对此提出了基于卷积神经网络和自注意力机制的典型运行方式提取方法。首先利用卷积神经网络构建自动编码器模型, 智能提取高比例新能源电网运行变量间复杂的空间耦合关系。其次基于提取的电网运行特征引入特征聚类层, 将其与自动编码器模型联合优化实现聚类。然后通过提出的新能源-负荷-传统能源组合模式指标及聚类效果评价指标表征运行方式聚类结果。最后对以类中心为代表的方式样本集进行拓展并开展静态安全评估。算例结果表明, 该方法能够有效挖掘电网高维运行变量的空间相关性和复杂组合模式, 在此基础上开展的安全校核有助于区别化表征不同方式间高比例新能源电力系统的安全风险, 为新型电力系统典型运行方式的制定提供有力支持。

关键词: 新能源电力系统; 运行方式聚类; 自动编码器; 空间相关性

Typical Operation Mode Extraction of High Proportion New Energy Power System Based on Convolutional Self-Attention Clustering Algorithm

FU Xiaobiao¹, JIANG Xu¹, LI Xinmeng², LI Yunpeng¹, LIU Xin³, WU Jiakai²

(1. State Grid Jilin Electric Power Supply Company, Changchun 130021, China; 2. School of Electrical Engineering, Northeast Electric Power University, Jilin, Jilin 132012, China; 3. State Grid Changchun Electric Power Supply Company, Changchun 130021, China)

Abstract: The traditional approach based on human experience has limited diversity in operating scenarios, making it difficult to fully characterize the complex operating boundaries of high proportion new energy power systems. Operation model arranging based on this approach may result in safety risk blind spots in the system. This article proposes a typical operation mode extraction method based on convolutional neural networks and self-attention mechanisms. Firstly, an autoencoder model is constructed using convolutional neural networks to intelligently extract complex spatial coupling relationships between variables in the operation of high proportion new energy grids. Secondly, based on the extracted operational characteristics of the power grid, a feature clustering layer is introduced, which is jointly optimized with an autoencoder model to achieve clustering. Then, the clustering results of the operation mode are characterized by the proposed indicators of the new energy-load-traditional energy combination mode and the clustering effect evaluation indicators. Finally, the sample set represented is expanded by class centers and static security assessments are conducted. The calculation results show that this method can effectively explore the spatial correlation and complex combination patterns of high-dimensional operating variables in the power grid. The safety verification carried out on this basis helps to differentiate and characterize the safety risks of high proportion new energy power systems between different modes, providing strong support for the formulation of typical operating modes of new power systems.

Key words: new energy power system; operation mode clustering; automatic encoder; spatial correlation

基金项目: 国家自然科学基金重点项目(52337004); 国网吉林省电力公司科技项目(SGJL0000DKS2300267)。

Foundation item: Supported by the Key Projects of National Natural Science Foundation of China (52337004); the Science and Technology Project of State Grid Jilin Electric Power Company (SGJL0000DKS2300267)。

0 引言

传统电力系统运行方式主要受负荷和季节性水电出力的影响,火电出力及负荷具有相对固定的模式,方式人员可以“冬大冬小、夏大夏小、丰水枯水”作为年度典型运行场景的选取准则。随着电力系统中新能源渗透率迅速升高,新能源出力不确定性使得传统以负荷为主导的系统运行特征去典型化,新能源发电空间分布特性受风光资源分布不均等影响,不同区域的风电、光伏等资源出力特征存在差异,特定区域内线路或设备上潮流较重,且新能源波动性加剧了区域间潮流频繁转移,导致现有典型方式难以全面覆盖高比例新能源电力系统安全运行边界^[1-5]。因此挖掘新能源出力空间分布特性与系统安全边界的关联关系对增强典型运行方式构建的全面性和复杂性有重要的意义^[6]。

为将风电、光伏等新能源运行特征纳入典型运行方式制定考量,运行人员安排高比例新能源电力系统典型方式时对区域间风电及光伏设置不同发电同时率,统筹水电和火电等传统能源安排出力配比,构建新能源出力场景典型运行方式集,虽然通过出力场可以区分其多样性,但方式样本数量有待进一步提高,且方式中配比场景选取精细化水平低,区间断面潮流约束及区域内方式安排仍依赖工程人员的运行经验,大量存在风险的运行方式未被发掘,在运行策略制定时带有潜在的运行风险。

数据驱动方法已成为当前运行分析研究重要方向。其中能够从电力系统海量高维度运行数据中进行数据降维,提取具有代表性的模式的聚类算法是电力系统数据驱动方法研究的关键领域。当前各种聚类算法主要从方式特征构造和聚类数据相似性量度等方面探索开展典型运行方式提取。如文献[7]运用主成分分析方法降维并通过K-means聚类算法提取电网典型运行方式。文献[8]使用主成分分析法和核主成分分析法进行数据降维并基于高斯混合分布模型的原理提出了K-means改进聚类算法,从而提取电网典型运行方式。文献[9]将聚类方法和生产模拟方法相结合,选取表征电力系统运行的特征变量,运用主成分分析降维并通过改进均值聚类算法提取电网典型运行方式,弥补了单一使用生产模拟时可供参考运行场景不足的问题。文献[10]提出一种可以考虑场景间的时空相关性的分层聚类方

法选取典型场景,基于欧式空间的全局相似性的聚类方法根据数据点之间的距离将数据划分为类簇来进行场景削减,适合处理距离能够直接代表相似性的情况,面对更复杂的强非线性特高维运行数据时,有研究使用基于深度聚类提取运行方式,如借助卷积神经网络(convolutional neural network, CNN)从特征变量上局部捕捉特征相关性并实现降维^[11-13]。文献[14]利用深度聚类算法实现运行时序数据降维并提取典型运行方式。故现阶段的聚类算法研究中尚缺少对区域间高维运行变量相似性的充分挖掘,在全面表征新能源系统出力组合模式的空间分布特性上仍有较大局限。

而自注意力机制(self-attention transformer, SAT)能使模型在处理序列数据时动态地关注输入序列中不同位置的信息,捕捉特征变量的全局相关性^[15-16]。因此,本文提出了卷积自注意力聚类算法(convolutional self-attention clustering, CSAC)用于捕捉电网高维运行变量空间相关性以及对海量运行变量间复杂组合模式划分。算例结果表明,本文提出的CSAC算法可以有效挖掘高比例新能源电力系统运行特征组合模式,并通过安全校核提取多种组合模式下具有不同潜在风险的典型运行方式,可为高比例新能源电力系统运行方式制定提供决策依据。

1 高比例新能源电力系统典型运行方式提取基本架构

基于卷积自注意力聚类算法的高比例新能源电力系统典型运行方式提取架构如图1所示。

首先,对高比例新能源电力系统历史运行样本的特征进行划分,即先对系统进行分区,然后将各区域运行特征按风、光、荷、水、火排列,得到特征预处理后的运行数据样本集。再应用CNN结合自注意力机制(self-attention transformer, SAT)构成自编码器(auto encoder, AE)提取运行数据的空间相关特征同时实现特征降维、挖掘电网高维运行数据的空间相关性,并表征电网运行深层次特征。随后提出特征聚类层,联合AE模型和特征聚类层构成CSAC算法生成运行方式集并提出新能源-负荷-传统能源组合模式指标评价聚类效果。最后,使用N-1静态安全分析对运行方式集进行校验并提取典型运行方式。




图1 基于卷积网络聚类算法的高比例新能源电力系统典型运行方式提取架构

Fig. 1 Architecture for typical operation mode extraction in high-penetration new energy power systems based on convolutional network clustering algorithm

2 基于卷积网络聚类算法的高比例电力系统典型运行方式提取方法

2.1 运行方式特征分析及数据结构预处理

电力系统运行方式是由发电机组出力大小、线路潮流、节点负荷大小等电力系统要素的组合决定的电力系统运行状态，主要表现为发电机组出力、节点负荷大小等电气量运行规律的变化，选择同一时刻的负荷有功功率、新能源及传统能源有功功率出力作为特征变量构成运行方式样本。

长时间尺度下，同一区域内相同类型新能源电站的出力变化趋于一致^[17]。负荷受环境或社会因素影响产生相关性，水电、火电为响应负荷需求及新能源消纳需求调整出力，表现出有功功率出力的相关性^[18-20]。为便于后续CNN卷积层提取特征相关性，对原始数据集进行预处理时将高维特征分区排列后将属于同一区域的特征按风电、光电、负荷、水电、火电有功功率数据依次排布。

设第 m 个运行样本中第 i 个区域中第一个风电场有功功率出力为 $p_{m1,i}^w$ ，全部风电场有功出力构成向量为 $\mathbf{P}_{m,i}^w$ ，表示如下。

$$\mathbf{P}_{m,i}^w = [p_{m1,i}^w, p_{m2,i}^w, \dots] \quad (1)$$

设第 m 个运行样本中第 i 个区域中第一个光伏电场有功出力为 $p_{m1,i}^{pv}$ ，全部光伏电场有功出力构成向量为 $\mathbf{P}_{m,i}^{pv}$ ，表示如下。

$$\mathbf{P}_{m,i}^{pv} = [p_{m1,i}^{pv}, p_{m2,i}^{pv}, \dots] \quad (2)$$

设第 m 个运行样本中第 i 个区域中第一个负荷有功出力为 $p_{m1,i}^d$ ，全部负荷有功大小构成向量为 $\mathbf{P}_{m,i}^d$ ，表示如下。

$$\mathbf{P}_{m,i}^d = [p_{m1,i}^d, p_{m2,i}^d, \dots] \quad (3)$$

设第 m 个运行样本中第 i 个区域中第一个水电场有功出力为 $p_{m1,i}^h$ ，全部水电场有功出力构成向量为 $\mathbf{P}_{m,i}^h$ ，表示如下。

$$\mathbf{P}_{m,i}^h = [p_{m1,i}^h, p_{m2,i}^h, \dots] \quad (4)$$

设第 m 个运行样本中第 i 个区域中第一个火电场有功出力为 $p_{m1,i}^{th}$ ，全部火电场有功出力构成向量为 $\mathbf{P}_{m,i}^{th}$ ，表示如下。

$$\mathbf{P}_{m,i}^{th} = [p_{m1,i}^{th}, p_{m2,i}^{th}, \dots] \quad (5)$$

已知某省方式数据共存在 M 个样本，并可划分为 I 个区域，运行方式样本集预处理后的任意一个运行方式样本向量为 $\mathbf{P}_m$ ，表示如下。

$$\mathbf{P}_m = [\mathbf{P}_{m,1}^w, \mathbf{P}_{m,1}^{pv}, \mathbf{P}_{m,1}^d, \mathbf{P}_{m,1}^h, \mathbf{P}_{m,1}^{th}, \dots, \mathbf{P}_{m,i}^w, \mathbf{P}_{m,i}^{pv}, \mathbf{P}_{m,i}^d, \mathbf{P}_{m,i}^h, \mathbf{P}_{m,i}^{th}] \quad (6)$$

2.2 CSAC算法原理

为从历史数据中挖掘电网高维运行变量的空间相关性和复杂组合模式，在现有研究的基础上，本文基于AE模型智能提取高比例新能源电网运行变量间复杂的空间耦合关系，提出了联合优化AE模型和特征聚类层的CSAC算法。

CSAC算法具体内容如下：构建预处理后的运行方式样本矩阵 $\mathbf{P}$ ， $\mathbf{P}=[\mathbf{P}_1^T, \mathbf{P}_2^T, \dots, \mathbf{P}_m^T, \dots, \mathbf{P}_M^T]^T$ ，作为算法输入数据，其中 $\mathbf{P}_m^T$ 为运行方式样本向量 $\mathbf{P}_m$ 的转置。算法的目标是基于提取出的深层次特征以及特征相似性，将 M 个运行方式样本分成 J 类。CSAC算法主要包括两个部分：AE模型和特征聚类层。其中，AE模型实现运行方式样本中空间相关变量的深层次特征提取及数据降维^[21]。特征聚类层依据深层特征基于欧式距离计算特征相似性实现特征聚类，得到类中心。算法主要框架如图2所示。

其中，AE模型由两部分组成：编码器和解码器。编码器提取输入数据中的深层次特征，并通过神经网络的非线性映射能力将输入数据以尽量低的




图2 CSAC算法的主要框架

Fig. 2 Main framework of the CSAC algorithm

特征损失映射到低维特征空间, 解码器将低维的深层次特征通过反映射重构回原始输入数据。本文设计的AE结构如图3所示。




图3 AE结构

Fig. 3 Structure of AE

AE的输入数据为运行方式序列 $\mathbf{P}$ 为充分提取运行方式样本中空间相关变量的深层次特征, 采用CNN结合自注意力机制构成AE模型。CNN可以模仿人类的视觉感知机制, 对于结构预处理后的输入数据, 代表相同类型的源/荷变量具有较强空间相关性, 因此可以通过CNN层有效识别。为了使神经网络从全局上进一步捕捉高维变量空间相关性, 在编码器部分采用自注意力机制在特征变量全局上对特征进行动态权重分配, 捕捉运行数据的长距离依赖关系, 更精确的得到高维耦合变量的深层次特征。将自注意力机制的特征归一化注意力权重设为 $A(\mathbf{Q}, \mathbf{K}, \mathbf{V})$, 计算如下^[22]。

$$A(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{a}}\right)\mathbf{V} \quad (7)$$

式中: $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$ 分别为输入映射到查询、键和值空间的权重矩阵; $\text{softmax}(\cdot)$ 为归一化指数函数; a 为输入序列的权重。

求出SAT的特征归一化注意力权重后, 将其输出设为 $\mathbf{O}$, 其计算式为:

$$\mathbf{O} = A(\mathbf{Q}, \mathbf{K}, \mathbf{V}) \cdot \mathbf{V} \quad (8)$$

在编码器部分通过使用一维卷积神经网络(1D convolutional neural network, 1D CNN)来高效辨识高维度数据相关特征。首先输入预处理后的 M 行运行方式样本作为编码器的原始数据, 通过数据重塑将原始数据二维数据形式塑造成适用于一维卷积神经网络模型输入处理格式的 M 个一维数据形式。由于不同量纲的特征可能导致算法对异常值的敏感性不一致, 将预处理后的数据归一化得到 $\mathbf{P}'_m$ 。随后使用1D CNN模型对 M 个一维数据即 M 个运行方式样本批提取多维相关变量的深层次特征, 并实现多维变量的数据降维。为尽可能保留运行方式样本的数据信息, 神经网络中的池化层采用平均池化, 激活层采用校正线性单元(rectified linear unit, ReLU)对输入数据进行初步相关特征提取和数据降维。随后将1D CNN层的输出作为SAT的输入进行权重分配, 从特征变量全局上捕捉相关变量的深层次特征。SAT的输出即为编码层得到的多维相关变量的深层次特征 $\mathbf{H}_m$, $1 \leq m \leq M$ 。在解码器部分, 通过上采样层(up-sample layer)结合卷积层重构出 M 个一维数据 $\hat{\mathbf{P}}'_m$, 最后通过数据重塑为 M 行的二维数据形式, 并将重塑数据反归一化作为解码器的输出^[23]。

AE的损失函数 L_{rec} 为未反归一化的重构输出数据与归一化的原始输入数据的均方误差(mean square error, MSE), 计算式如下。

$$L_{\text{rec}} = \frac{1}{M} \sum_{m=1}^M \left\| \mathbf{P}'_m - \hat{\mathbf{P}}'_m \right\|^2 \quad (9)$$

CSAC算法的另一组成部分特征聚类层是依据AE模型提取出来的深层次特征 $\mathbf{H}_m$ 计算特征相似性从而划分原始数据的聚类类别并得到相应类别的聚类中心^[24-26]。特征聚类层将原始数据分成 J 个类簇, 设聚类中心为 $\mathbf{C}_j$, $1 \leq j \leq J$, 进而基于欧氏距离计算 $\mathbf{H}_m$ 与 $\mathbf{C}_j$ 的相似性, 将特征聚类层的损失函数 L_s 定义为簇内样本与簇中心的欧式距离平方和。计算式如下。

$$L_s = \sum_{m=1}^M \sum_{j=1}^J s_{mj} \left\| \mathbf{H}_m - \mathbf{C}_j \right\|^2 \quad (10)$$

式中 s_{mj} 为样本是否属于类别 j 的判别值, 是为1, 不是为0。

CSAC 算法的损失函数 L 由编码重构损失 L_{rec} 和特征聚类层损失 L_s 构成, 定义其表达式如下。

$$L = (1 - \lambda)L_{\text{rec}} + \lambda L_s \quad (11)$$

式中: λ 为预先设置的损失权重值; L_s 为特征聚类层损失。为防止聚类层训练时过度扭曲 AE 模型编码空间, λ 设为 0.1。

2.3 CSAC 算法实施流程

CSAC 算法的具体流程如下。

1) 深层次特征空间初始化。独立预训练 AE 模型, 目标为最小化编码重构损失 L_{rec} 。训练完成后将预处理后的数据输入到 AE 模型中, 得到数据的初始深层次特征表达 H_m^0 , $1 \leq m \leq M$ 。

2) 聚类中心初始化。基于初始深层次特征表达, 以欧式距离为相似性度量, 采用均值聚类算法得到初始聚类中心 C_j^0 , $1 \leq j \leq J$ 。

3) 模型训练。在训练 CSAC 模型时, 计算损失函数 L 后进行反向传播, 不断更新 AE 模型及 AE 模型中的参数。使用兰德系数计算训练结果的相似性^[21], 若兰德系数大于 0.99, 即认为两次聚类结果一致, 若聚类结果连续 5 次一致, 则认为模型收敛, 此时的聚类结果为最终聚类结果并停止训练。

4) 重构运行方式样本。将特征聚类层中的聚类结果通过 AE 的解码器解码重构即可得到运行方式的 J 类模式, 聚类中心为代表性运行方式。

2.4 聚类效果评价指标建立

聚类后类内新能源有功功率波动越小、负荷波动越小、潮流方向一致率越大说明聚类后各运行方式簇的空间耦合特征越相似, 则聚类效果越好。故从发电侧、负荷侧、潮流方向特征出发定义聚类效果评价指标。

定义平均类内新能源有功功率波动率为所有运行方式簇类内新能源有功功率波动率的平均值, 以此衡量聚类后的新能源有功功率波动程度。平均类内负荷波动率 σ_r 表达式如下所示。

$$\sigma_r = \frac{\sum_{j=1}^J (R_{j, \max} - R_{j, \min})}{R_{\max} - R_{\min}} \quad (12)$$

式中: $R_{\max}$ 、 $R_{\min}$ 分别为数据集中新能源有功出力总和的最大值、最小值; $R_{\max, j}$ 、 $R_{\min, j}$ 分别为数据集第 j 类中新能源有功出力总和的最大值、最小值。

定义平均类内负荷波动率为所有运行方式簇类

内负荷波动率的平均值, 以此衡量聚类后的负荷波动程度。平均类内负荷波动率 σ_d 表达式如下所示。

$$\sigma_d = \frac{\sum_{j=1}^J (D_{j, \max} - D_{j, \min})}{D_{\max} - D_{\min}} \quad (13)$$

式中: $D_{\max}$ 、 $D_{\min}$ 分别为数据集中负荷总和的最大值、最小值; $D_{\max, j}$ 、 $D_{\min, j}$ 分别为数据集第 j 类中负荷总和的最大值、最小值。

定义平均类内断面有功功率方向一致率为所有运行方式簇类内断面有功功率方向一致率的平均值, 以此衡量聚类后的断面有功功率方向的一致程度, 评估运行方式间在潮流空间分布的差异。平均类内断面有功功率方向一致率 σ_1 表达式如式(14)所示。

$$\sigma_1 = \frac{\sum_{j=1}^J \frac{N_{\text{lcon}, j}}{N_{\text{all}, j}}}{J} \quad (14)$$

式中: $N_{\text{all}, j}$ 为第 j 类运行方式簇的样本数量; $N_{\text{lcon}, j}$ 为第 j 类运行方式簇中运行方式断面有功方向与类中心一致的样本数量。

2.5 聚类结果的空间耦合特征表征

基于 CSAC 算法得到的各运行方式簇具有相似的空间耦合特征, 即同类别的发电能源有功功率变量或者负荷变量的大小在同一运行方式簇中是相似的, 则同一运行方式簇不同种类变量总和大小相近, 具有相同的新能源-负荷-传统能源组合模式。所以将某一时刻同类别变量总和与所有时刻同类别变量总和最大值之比定义为新能源-负荷-传统能源组合模式指标 α 。以第 m 个运行时刻中第 i 个区域风电出力占比 $\alpha_{m, i}^{\text{wtotal}}$ 为例, 设该地区共有 b 个风电场, 表达式如式(15)所示。

$$\alpha_{m, i}^{\text{wtotal}} = \frac{\sum_{k=1}^b p_{m, i}^{\text{kw}}}{\max \left\{ \sum_{k=1}^b p_{1, i}^{\text{kw}}, \sum_{k=1}^b p_{2, i}^{\text{kw}}, \dots \right\}} \quad (15)$$

式中: $p_{m, i}^{\text{kw}}$ 为第 m 个运行时刻第 i 个区域的第 k 个风电场的出力; b 为该区域风电场数量。

对指标设置 3 个区间范围, 当占比小于 35 % 时负荷为谷荷、风光水火小发, 大于 35 % 小于 65 % 时负荷为腰荷、风光水火中发, 大于 65 % 时负荷为峰荷、风光水火大发。从而通过计算新能源-负荷-传统能源组合模式指标实现聚类结果的空间耦合特征表征。

2.6 运行方式的拓展和典型性识别方法

对于同一类簇的运行方式,由于处于每个类边缘的样本点与聚类中心的特征差异较大,类中心无法代表类簇内所有样本的安全特征,需要对样本集进行合理拓展,形成较为全面的运行方式样本集。因此,本文从每一种运行方式簇中根据欧式距离从大到小的原则提取出5个边缘点,与聚类中心联合构成待校核运行方式样本集。

为对运行方式的典型性进行刻画,本文对待校核样本集进行 $N-1$ 静态安全校验,定义线路负载率 β 表达式如下所示。

$$\beta = \frac{P_1}{\sqrt{3} UI \cos \theta} \quad (16)$$

式中: P_1 当前时刻下 $N-1$ 后的线路有功功率; U 为当前时刻线路额定电压; I 为当前时刻线路额定电流;功率因数 $\cos \theta$ 取值0.95。

为体现运行方式静态安全风险倾向程度,将电力系统 $N-1$ 后线路的有功负载率超过90%的电力线路数目 Z 作为衡量指标,重载线路越多,电力系统安全风险倾向越高。

综合静态安全分析结果和运行方式的数量合理性,提出以下两点典型运行方式约简原则:如无任何重载现象的运行方式无需被重点关注;由相同的组合模式导致电网存在安全隐患的运行方式应被合并。基于约简原则处理后的典型运行方式更容易导致线路的重载问题,影响电力系统的安全稳定运行,即被认定为典型方式。

3 算例分析

采用东北某省级电网2023年历史运行数据作为典型方式提取的样本集。该运行样本集的采样间隔为1h,全年共8760个样本,涵盖了该省9个行政区域的负荷、风电场、光伏电站、水电厂、火电厂有功功率出力,每个样本有202维特征。依据本文2.1节的样本集构建方法得出预处理后的运行方式样本集作为本算例的数据基础。

3.1 CSAC算法参数设置及训练

CSAC算法中的AE模型需要首先被预训练,AE模型的学习率为0.011,批训练次数为1000;按10:1的比例在总数据集中随机选取876个运行方式样本作为训练集,总数据集为测试集。该模型具有202维输入,64维输出,可以将8760个运行

样本经过特征提取降维为64维特征数据。

为评估AE模型的训练效果,选取测试集中的某样本,将运行样本数据与AE模型重构后的数据绘制如图4所示,可见通过解码器有效重构了原始数据,其编码可以作为运行方式深层次特征的表征。也验证了AE模型能够通过编码器有效提取高维耦合变量的深层次特征并进行融合和保留。




图4 运行样本重构结果

Fig. 4 Reconstitution results of sample operation

同时,设置CSAC中的特征聚类层学习率为0.01,批训练次数为100。

3.2 最优聚类数选取

为揭示聚类数对聚类效果的影响,在此应用2.4节的聚类效果评价指标对聚类效果进行评价,如图5—7所示。




图5 平均类内新能源有功波动率随J值变化

Fig. 5 Variation of the average intra-cluster active power fluctuation rates of renewable energy with J




图6 平均类内负荷波动率随J值变化

Fig. 6 Variation of the average intra-cluster load fluctuation rates with J




图7 平均类内断面有功功率方向一致率随J值变化

Fig. 7 Variation of the average intra-cluster active power flow direction consistencies with J

由图5—7可知,类内新能源波动率和类内负荷波动率随着聚类数 J 的增加而减小,类内断面有功方向一致率随着 J 值的增加而增大。但在聚类数超过30后,聚类效果评价指标变化明显趋缓,这说明此时类内样本的差异度已经较小,因此在此选取30为最优聚类数。

3.3 运行方式聚类结果分析

CSAC模型训练至收敛后,将特征聚类层输出的聚类结果通过AE的解码器解码重构即可得到30类运行方式簇。计算新能源-负荷-传统能源组合指标,刻画运行方式的聚类结果。将聚类结果展示在表1中,在此列出类中样本数量占比前35%的运行

方式簇。基于2.5节的评价指标,在此用F表示峰荷或大发,Y表示腰荷或中发,G表示谷荷或小发,“—”表示出力为0或停机,如表1所示。

表1 聚类后运行方式统计结果

Tab. 1 Statistical results of operation modes after clustering

方式序号 (占百分比/%)	特征类别	各区域间厂站出力占比组合								
		1	2	3	4	5	6	7	8	9
1(8.1)	风	G	F	F	G	F	—	—	—	—
	光	G	G	G	G		—	—	—	—
	荷	G	Y	F	F	F	F	F	F	Y
	水	—	—	—	G	—	G	Y		G
	火	Y	Y	Y	Y	F	Y	Y	Y	Y
2(7.65)	风	G	G	G	G	G	—	—	—	—
	光	G	G	Y	F		—	—	—	—
	荷	Y	G	Y	Y	F	F	F	Y	Y
	水	—	—	—	Y	—	G	G		G
	火	Y	G	Y	Y	F	F	Y	F	G
3(7.46)	风	F	G	F	G	G	—	—	—	—
	光	G	Y	F	F	—	—	—	—	—
	荷	G	G	Y	Y	Y	F	F	Y	Y
	水	—	—	—	F	—	Y	F		F
	火	G	G	G	G	Y	G	G	Y	G
4(5.74)	风	F	F	G	G	G	—	—	—	—
	光	G	Y	F	F	—	—	—	—	—
	荷	G	G	Y	Y	Y	F	F	Y	Y
	水	—	—	—	F	—	Y	F	—	F
	火	G	G	G	G	Y	G	G	Y	G
5(5.19)	风	G	Y	Y	G	G	—	—	—	—
	光	G	G	G	G	—	—	—	—	—
	荷	G	G	F	Y	Y	F	Y	Y	Y
	水	—	—	—	G	—	G	G		G
	火	Y	F	Y	Y	Y	Y	Y	Y	Y

为直观展示本文方法对运行方式的新能源-负荷-传统能源组合模式的识别效果并从区域分布角度揭示不同类簇之间的差异,以表1中的运行方式簇1和簇2为例绘制风光水组合配比模式箱型图如图8所示。同时,使用k-均值聚类算法同样将输入数据聚成30类作为对照,选取类内样本数最多的运行方式簇,其风光水组合配比模式如图9所示。比较可知,经CSAC方法聚类后更容易将风光水配比相近的运行特征聚合在一起,使得各类簇能凸显运行方式的空间差异性。而使用均值聚类算法得到的变量占比区间范围跨度较大,无法体现高维运行变量复杂组合模式。

另外,从新能源有功波动率、类内负荷波动





图8 CSAC聚类后运行方式簇的变量占比组合

Fig. 8 Variable proportion combinations of operation mode clusters after CSAC




图9 k-means聚类后运行方式簇1的变量组合模式

Fig. 9 Variable combination patterns of cluster 1 after k-means

率、断面有功功率方向一致率的角度比较CSAC方法和传统均值聚类方法在运行方式识别方面的效果差异,如表2所示。

从表中数据可看出CSAC方法的新能源有功功率波动率和类内负荷波动率较均值聚类算法减小,

表2 聚类效果比较

Tab. 2 Comparison of clustering results				%
算法	新能源有功功率波动率	类内负荷波动率	断面有功功率方向一致率	
均值聚类	26.7	25.6	19.0	
CSAC	53	46	95	

而断面有功方向一致率显著增强,体现出更佳的运行方式识别效果。

3.4 典型运行方式的提取与分析

对运行方式集进行拓展,计算特征聚类层聚类结果中同一类簇的数据点与聚类中心的欧式距离,选取最远的5个运行样本,联合聚类中心,共拓展到180个样本,将其输入到AE模型解码器部分,重构出180个运行方式样本作为待校核样本集,将具体运行方式静态安全风险指标即 $N-1$ 后重载线路数 Z 及对应的负荷需求和能源出力组合情况列成表,经约简后共识别出22个具有重载风险倾向的运行方式,详见表3(仅展示9个区域中前8个区域的能源占比组合信息)。

从表中可以看出,经校验后180个运行方式中可识别出22个具有不同程度重载风险的典型运行方式,对应了8种新能源占比组合模式,这说明相较于其余组合模式,具有这8种空间运行特征的运行方式类型更容易出现线路的重载问题,影响电力系统的安全可靠运行,故认定其典型性,为典型运行方式。

为比较本文方法在电网复杂运行边界识别中的有效性,采用相同的样本拓展方法,对 k -均值聚类结果拓展得到180个运行方式,同样进行 $N-1$ 静态安全校验,经过仿真计算, k -均值聚类算法并未提取出CSAC算法校核提取出的典型运行方式1、12和22,即存在未能甄别出的重载风险。

4 结语

本文提出了一种基于卷积神经网络和自注意力机制的典型运行方式识别方法,实现高比例新能源电力系统典型运行方式的有效提取。本方法为处理高维运行数据的降维与复杂变量之间的空间耦合问题提供了有效的解决方案。仿真结果表明,相较于传统的 K -means算法,本文方法在新能源-负荷-传统能源的组合模式中表现出更好的类簇区分效果,

表 3 具有重载风险倾向的典型运行方式

Tab. 3 Typical operation modes with static security risk

方式序号	Z	特征类别	tendency							
			不同负荷需求下相关能源占比组合							
			1	2	3	4	5	6	7	8
1	12	风	F	F	F	G	F	--	--	--
		光	Y	Y	Y	Y	--	--	--	--
		荷	G	Y	Y	Y	Y	Y	Y	F
		水	--	--	--	Y	--	G	Y	--
		火	G	G	G	G	Y	G	Y	G
2,3	2,4	风	F	F	F	G	F	--	--	--
		光	G	Y	F	Y	--	--	--	--
		荷	G	G	Y	Y	Y	F	Y	Y
		水	--	--	--	F	--	G	G	--
		火	G	G	G	G	G	G	G	G
4,5	2,4	风	F	G	F	G	G	--	--	--
		光	G	Y	F	F	--	--	--	--
		荷	G	G	Y	Y	Y	F	F	Y
		水	--	--	--	F	--	Y	F	--
		火	G	G	G	G	Y	G	G	Y
6,7	2,2	风	F	F	G	G	G	--	--	--
		光	G	Y	F	F	--	--	--	--
		荷	G	G	Y	Y	Y	F	F	Y
		水	--	--	--	F	--	Y	F	--
		火	G	G	G	G	Y	G	G	Y
8,9,10,11	5,3,3,3	风	G	G	G	G	G	--	--	--
		光	F	F	Y	F	--	--	--	--
		荷	G	F	Y	F	Y	Y	F	F
		水	--	--	--	F	--	Y	F	--
		火	G	Y	G	Y	F	F	F	G
12,13,14	5,4,4	风	F	F	F	F	F	--	--	--
		光	G	G	Y	Y	--	--	--	--
		荷	G	Y	F	Y	F	F	Y	Y
		水	--	--	--	G	--	Y	G	--
		火	G	F	G	G	Y	G	G	G
15,16,17,18	8,3,3,3	风	G	G	G	G	G	--	--	--
		光	G	G	G	G	--	--	--	--
		荷	Y	F	F	Y	F	F	Y	F
		水	--	--	--	F	--	G	F	--
		火	Y	G	F	Y	F	Y	Y	G
19,20,21,22	1,2,2,2	风	G	G	G	G	F	--	--	--
		光	G	G	G	G	--	--	--	--
		荷	G	Y	Y	Y	Y	F	Y	F
		水	--	--	--	G	--	G	Y	--
		火	F	G	Y	F	F	F	F	G

特别是在新能源渗透率较高的情况下,本文提出的卷积自注意力聚类算法的类簇划分不仅能够更加准

确地捕捉电网运行变量的空间相关性,还能关联不同运行场景下的静态安全风险,为后续的电力系统运行方式制定提供了有力支持,为将来进一步探索高比例新能源电力系统的运行模式划分及其安全稳定评估提供了新的思路 and 方向。

参考文献

- [1] 康重庆,姚良忠. 高比例可再生能源电力系统的关键科学问题与理论研究框架[J]. 电力系统自动化,2017,41(9):1-11.
KANG Chongqing, YAO Liangzhong. Key scientific issues and theoretical research framework for power systems with high proportion of renewable energy [J]. Automation of Electric Power Systems, 2017, 41(9): 1-11.
- [2] 辛保安,单葆国,李琼慧,等. “双碳”目标下“能源三要素”再思考[J]. 中国电机工程学报,2022,42(9):3117-3126.
XIN Baoan, SHAN Baoguo, LI Qionghui, et al. Rethinking of the “three elements of energy” toward carbon peak and carbon neutrality [J]. Proceedings of the CSEE, 2022, 42(9): 3117-3126.
- [3] 邓韦斯,孟子超,王皓怀,等. 新能源功率预测特性分析及精度提升措施[J]. 南方电网技术,2023,17(2):11-23.
DENG Weisi, MENG Zichao, WANG Haohuai, et al. Renewable energy power prediction characteristics analyses and accuracy improvement measures [J]. Southern Power System Technology, 2023, 17(2): 11-23.
- [4] 毛安家,马静,蒯圣宇,等. 高比例新能源替代常规电源后系统暂态稳定与电压稳定的演化机理[J]. 中国电机工程学报,2020,40(9):2745-2756.
MAO Anjia, MA Jing, KUAI Shengyu, et al. Evolution mechanism of transient and voltage stability for power system with high renewable penetration level [J]. Proceedings of the CSEE, 2020, 40(9): 2745-2756.
- [5] 李静轩,周明,朱凌志,等. 可再生能源电力系统运行灵活性需求量化及优化调度方法[J]. 电网技术,2021,45(7):2647-2656.
LI Jingxuan, ZHOU Ming, ZHU Lingzhi, et al. Flexibility requirement quantifying and optimal dispatching for renewable integrated power systems [J]. Power System Technology, 2021, 45(7): 2647-2656.
- [6] XU Yan, YIN Minghui, DONG Zhaoyang, et al. Robust dispatch of high wind power-penetrated power systems against transient instability [J]. IEEE Transactions on Power Systems, 2017, 33(1): 174-186.
- [7] HOU Qingchun, DU Ershun, ZHANG Ning, et al. Impact of high renewable penetration on the power system operation mode: a data-driven approach [J]. IEEE Transactions on Power Systems, 2020, 35(1): 731-741.
- [8] 赵泓博. 电网典型运行方式提取模型与算法研究[D]. 北京:华北电力大学,2020.
- [9] 侯庆春,杜尔顺,田旭,等. 数据驱动的电力系统运行方式分析[J]. 中国电机工程学报,2021,41(1):1-12, 393.
HOU Qingchun, DU Ershun, TIAN Xu, et al. Data-driven power system operation mode analysis [J]. Proceedings of the CSEE, 2021, 41(1): 1-12, 393.
- [10] LIU Yixian, SIOSHANSI R, CONEJO A J. Hierarchical

- clustering to find representative operating periods for capacity-expansion modeling [J]. IEEE Transactions on Power Systems, 2018, 33(3): 3029 – 3039.
- [11] 郭庆来, 兰健, 周艳真, 等. 基于混合智能的新型电力系统运行方式分析决策架构及其关键技术[J]. 中国电力, 2023, 56(9): 1 – 13.
- GUO Qinglai, LAN Jian, ZHOU Yanzhen, et al. Architecture and key technologies of hybrid-intelligence-based decision making of operation modes for new type power systems [J]. Electric Power, 2023, 56(9): 1 – 13.
- [12] 景惠甜, 韩丽, 高志宇. 基于卷积神经网络特征提取的风电功率爬坡预测[J]. 电力系统自动化, 2021, 45(4): 98 – 105.
- JING Huitian, HAN Li, GAO Zhiyu, Wind power ramp forecast based on feature extraction using convolutional neural network [J]. Automation of Electric Power Systems, 2021, 45(4): 98 – 105.
- [13] OEHMCKE S, ZIELINSKI O, KRAMER O. Input quality aware convolutional LSTM networks for virtual marine sensors [J]. Neurocomputing, 2018, 275(2): 2603 – 2615.
- [14] 庄颖睿, 程林, 齐宁, 等. 基于深度时间聚类的微电网典型场景生成方法[J]. 电力系统自动化, 2023, 47(20): 95 – 103.
- ZHUANG Yingrui, CHENG Lin, QI Ning, et al. Typical scenario generation algorithm for microgrid based on deep temporal clustering [J]. Automation of Electric Power Systems, 2023, 47(20): 95 – 103.
- [15] LÓPEZ P R, DORTA D V, PREIXENS G C, et al. Pay attention to the activations: a modular attention mechanism for fine-grained image recognition [J]. IEEE Transactions on Multimedia, 2020, 22(2): 502 – 514.
- [16] 时志雄, 朱峰, 刘舒, 等. 基于1DCNN-DACLSTM模型的风电超短期功率预测方法[J]. 电子器件, 2024, 47(1): 194 – 200.
- SHI Zhixiong, ZHU Feng, LIU Shu, et al. Ultra-short-term forecasting of wind power based on 1DCNN-DACLSTM model [J]. Chinese Journal of Electron Devices, 2024, 47(1): 194 – 200.
- [17] 康文韬, 霍永胜. 计及风电、光伏不确定性和相关性的潮流特性分析[J]. 现代电力, 2022, 39(2): 246 – 252.
- KANG Wentao, HUO Yongsheng, Analysis on the power flow characteristics considering uncertainty and correlation of wind power and photovoltaic station [J]. Modern Electric Power, 2022, 39(2): 246 – 252.
- [18] 李春燕, 杨强, 魏蔚, 等. 计及风速与负荷相关性的配电网重构方法[J]. 电力自动化设备, 2016, 36(2): 148 – 153.
- LI Chunyan, YANG Qiang, WEI Wei, et al. Distribution network reconfiguration considering correlation between wind-speed and load [J]. Electric Power Automation Equipment, 2016, 36(2): 148 – 153.
- [19] LENG S P, LIU K P, RAN X H, et al. An affine arithmetic based model of interval power flow with the correlated uncertainties in distribution system [J]. IEEE Access, 2020, 8(22): 60293 – 60304.
- [20] 陈宇辛, 江岳文. 考虑变量相关性的改进场景优化法区间潮流计算[J]. 电力自动化设备, 2022, 42(3): 161 – 167.
- CHEN Yuxin, JIANG Yuewen. Interval power flow calculation with improved scenario optimization method considering correlation of variables [J]. Electric Power Automation Equipment, 2022, 42(3): 161 – 167.
- [21] MICHELUCCI U. An introduction to autoencoders [EB/OL]. [2022 – 12 – 20]. <https://arxiv.org/abs/2201.03898>.
- [22] 李士哲, 王霄慧, 刘帅. 考虑多变量相关性改进的风电场Transformer中长期预测模型[J]. 智慧电力, 2024, 52(4): 62 – 68, 107.
- LI Shizhe, WANG Xiaohui, LIU Shuai. Improved transformer medium and long term prediction model of wind farm considering multivariate correlation [J]. Smart Power, 2024, 52(4): 62 – 68, 107.
- [23] 来杰, 王晓丹, 向前, 等. 自编码器及其应用综述[J]. 通信学报, 2021, 42(9): 218 – 230.
- LAI Jie, WANG Xiaodan, XIANG Qian, et al. Review on autoencoder and its application [J]. Journal on Communications, 2021, 42(9): 218 – 230.
- [24] WANG J, ZHAO J, CHENG T. SGAAE-AC: a semi-supervised graph attention autoencoder for electroencephalography (eeg) age clustering [J]. Applied Sciences, 2024, 14(13): 5392 – 5392.
- [25] 虞伟, 黄浩, 金晨星, 等. 基于多头自注意力特征变换和CNN-LSTM的超短期风电功率预测 [J/OL]. 南方电网技术, 1 – 10 [2024 – 12 – 05]. <http://kns.cnki.net/kcms/detail/44.1643.tk.20241205.0934.002.html>.
- YU Wei, HUANG Hao, JIN Chenxing, et al. Ultra-short-term wind power forecasting based on multi-head self-attention feature transform and CNN-LSTM [J/OL]. Southern Power System Technology, 1 – 10 [2024 – 12 – 05]. <http://kns.cnki.net/kcms/detail/44.1643.tk.20241205.0934.002.html>.
- [26] 王文森, 杨晓西, 刘阳, 等. 基于层次聚类分析的变压器油中溶解气体在线监测数据异常检测[J]. 高压电器, 2023, 59(1): 142 – 147.
- WANG Wensen, YANG Xiaoxi, LIU Yang, et al. Anomaly detection of online monitoring data of dissolved gases in transformer oil based on hierarchical cluster analysis [J]. High Voltage Apparatus, 2023, 59(1): 142 – 147.

收稿日期: 2024-09-24; 网络首发日期: 2025-01-20

作者简介:

付小标(1979), 男, 高级工程师, 硕士, 研究方向为电力系统分析运行和电力系统智能技术;

姜旭(1977), 男, 高级工程师, 博士, 从事电力系统分析、调度运行工作;

吴嘉锴(1988), 男, 通信作者, 实验师, 硕士, 研究方向为电力系统运行方式规划, wujiakai@126.com。