

基于 MVMD-CapSA-DBN 的工业多元负荷分类研究

周孟然¹,张易平¹,汪胜和²,马金辉²,高博²,胡锋¹,朱梓伟¹,汪锐¹,刘宇¹

(1.安徽理工大学 电气与信息工程学院,安徽 淮南 232001;2.国网安徽省电力有限公司,合肥 230001)

摘要:针对多元电力负荷数据时间序列非平稳性、时序相关性和非线性等特性,为掌握电力负荷的变化规律和发展趋势,实现对电力负荷的科学管理,将工业多元负荷有功功率作为原始数据,提出 MVMD-CapSA-DBN 负荷分类模型.首先,利用改进停止准则的变分模态分解(Variational Mode Decomposition, VMD)将数据分解,得到较为平稳的多个数据分量;之后,提取各分量能量值作为特征;最后,将 0~1 标准化的数据作为特征向量,输入经卷尾猴搜索算法(Capuchin Search Algorithm, CapSA)优化参数后的深度置信网络(Deep Belief Nets, DBN)信号分类.实验证明,可实现对工业多元负荷数据的有效分类,整体准确率在 88.89%左右,部分负荷分类准确率可达 100%.

关键词:电力负荷;负荷分类;变分模态分解;深度信念网络;卷尾猴搜索算法

中图分类号:TM714

文献标志码:A

电力负荷的正常稳定运行以及实时监测对工厂稳定运行意义重大.为了保证电力系统的健康、经济、高效、可靠的运行,需要深入分析各类负荷特点,在此基础上进行需求侧管理,规划分时电价、移峰填谷等负荷管理工作,优化电网结构,提升电能利用效率,改善用户用电习惯^[1].

目前针对电力负荷预测分类精度提升的研究主要从两方面考虑:1)数据信息提取方面,从时频域分解数据信号,收集数据有效信息,挖掘其隐含信息、信号重构减小噪声干扰;2)对负荷预测及分类方法研究,包括机器学习、深度学习等方法进行负荷预测、分类研究,改进聚类算法、神经网络等方法.经验模态分解(Empirical Mode Decomposition, EMD)作为自适应分解方法,在信号分解中应用十分广泛,徐岩等人^[2]利用 EMD,分解时域信号并重构,有效消除较多噪声信息,接着提取信号特征进行分类,分类精度得到提高;研究者为解决冲击信号损失得问题,采用 EMD 结合稀疏分解特征提取方式,提高了分类准确度^[3].由于变分模态分解(Variational Mode Decomposition, VMD)^[4]能够很好克服模态混叠、端点效应等缺点,所以一经提出,就被应用到信号分解方面,其在电力负荷分解方面表现也很好.商立群等^[5]等针对光伏发电功率随机性和波动性较强的问题,为了提高预测精度,利用 VMD 对光伏发电功率序列进行平稳化处理,实验结果验证了其有效性和优越性;马宗彪等^[6]采用 VMD 对数据模态分解重构,改善了 FCM 聚类精度就收敛速度慢的问题,实现了电力负荷的模糊分类.但采用 VMD 对信号分解,其分解量根据经验人为确定,具有不确定性,可靠性低的缺点,因此本文提出停止准则对其改进,增加分解分量置信度.

近几年采用深度学习预测分类^[7-9]十分热门.其中深度置信网络^[10](Deep Belief Nets, DBN)作为分类器,用于图像处理,手写字识别等,其在信号分类方面也有广泛应用.张建宇等^[11]提出迁移诊断模型,构建特征识别参数,引入最大相关峭度反卷积方法,采用 DBN 对所研究的 3 类滚动轴承分类,准确率达到 95%.神经网络的参数设置对结果影响也很大.为对神经网络的参数合理设置,引入优化算法对使用的神经网络优化,程焕新等人^[12]利用循环神经网络对未来短期负荷预测,针对循环神经网络易陷入局部最优和全局搜索能力弱的缺点,利用改进后的粒子群算法优化循环神经网络的结点权值参数,有效提高预测准确度.

收稿日期:2022-10-18;**修回日期:**2022-12-29.

基金项目:国家重点研发计划(2018YFC0604503);安徽省自然科学基金能源互联网联合基金重点项目(2008085UD06);安徽省科技重大专项(201903a07020013);安徽高校自然科学研究重点项目(KJ2021A0470).

作者简介:周孟然(1965—),男,安徽淮南人,安徽理工大学教授,博士,博士生导师,研究方向为光电信息处理、模式识别等.

通信作者:张易平, E-mail:1437323718@qq.com.

然而,关于电力负荷优化、科学管理方面的研究仍缺少对具体负荷清晰分类的讨论,难以精准调控实时负荷.针对以上问题,提出 MVMD-CapSA-DBN 模型对工业电力负荷分类.首先采用停止准则改进传统 VMD^[13-15],有效确定 VMD 分解量,对信号分解后提取特征.根据采集的工业电力负荷数据,针对已知负荷类别分类问题选用 DBN 分类^[16].同时考虑 DBN 参数对结果影响较大的问题,提出利用卷尾猴搜索算法(Capuchin Search Algorithm, CapSA)^[17]优化对 DBN 影响较大的参数.

1 理论介绍

1.1 MVMD-CapSA-DBN 模型流程

针对工业多元电力负荷信号易受干扰、特征不明显的特点,建立基于 MVMD-CapSA-DBN 分类信号模型.图 1 为 MVMD-CapSA-DBN 流程图.首先,使用 MVMD 对多元负荷的功率信号分解,得到较为平稳的多个模态分量;之后使用 CapSA-DBN,得到最优参数的 DBN 神经网络,提取多元负荷经 MVMD 分解后的多个模态分量特征向量,输入优化后的 DBN 神经网络训练,通过 soft-max 进行分类.

该算法运用递归思想,改进了传统 VMD 算法模态分解数根据经验人为确定的不可靠性,分解分量数目的判定由各分量与原信号相关系数决定.确定分解模态数后,分解模态分量的能量值即为特征输出,大大降低了数据的特征维度,有利于提高神经网络的诊断速度.后采用卷尾猴搜索算法优化对 DBN 分类结果影响较大的参数,提高 DBN 分类准确度.

1.2 改进 VMD 介绍

1.2.1 VMD 原理

VMD 对于复杂非平稳时间序列信号的适应度非常好^[18],对电力负荷数据分解按下述公式.VMD 分解的问题实质是构建和求解变分问题,求解约束变分问题最优解

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial(t) \left\{ \left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right\} e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle, \quad (1)$$

其中, α 为惩罚因子; λ 为 Lagrange 乘子; $f(t)$ 为电力负荷功率信号; $\{u_k\} = \{u_1, u_2, \dots, u_K\}$ 为分解 K 个模态分量; $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_K\}$ 为中心频率; $\delta(t)$ 为单位脉冲函数; $*$ 为卷积运算.

采用交替方向乘子算法(Alternate Direction Method of Multipliers, ADMM)更新迭代求解增广 Lagrange 式(1)的鞍点,在频域内迭代更新 u_k, ω_k 及 λ .其迭代表达式如下

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i^n(\omega) + (\hat{\lambda}^n(\omega)/2)}{1 + 2\alpha(\omega - \omega_k^{n+1})^2}, \quad (2)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^n(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^n(\omega)|^2 d\omega}, \quad (3)$$

$$\hat{\lambda}^n(\omega) = \hat{\lambda}^{n-1}(\omega) + \tau(\hat{f}(\omega) - \sum_k \hat{u}_k^n(\omega)), \quad (4)$$

迭代式(2)~(4)至满足停止条件: $\hat{u}_k^{n+1} - \hat{u}_k^n < \epsilon$, ϵ 为精度.停止迭代,得到 K 个模态分量.

1.2.2 停止准则

VMD 分解的效果与分解模态数的取值具有十分相关性^[19],较小的模态分解数会过滤一些需要的重要特征信息,影响后续分类准确率;而模态分解数过大则会有模态重复.传统 VMD 的模态分解数一般由经验法确定,可靠性差.由于 K 值选择对于特征提取意义重大,所以提出一种基于 VMD 分解的停止准则确定 K 值.

采用 VMD 分解方法分解出的 K 个信号分量 IMF,其本质是原始信号的组成成分,也就是说分解出来的信号和原信号具有相关性.计算分解信号与原信号的相关系数 c_k ,确定最小相关系数 c_{\min} ,若小于阈值,停

止分解,见图 2.

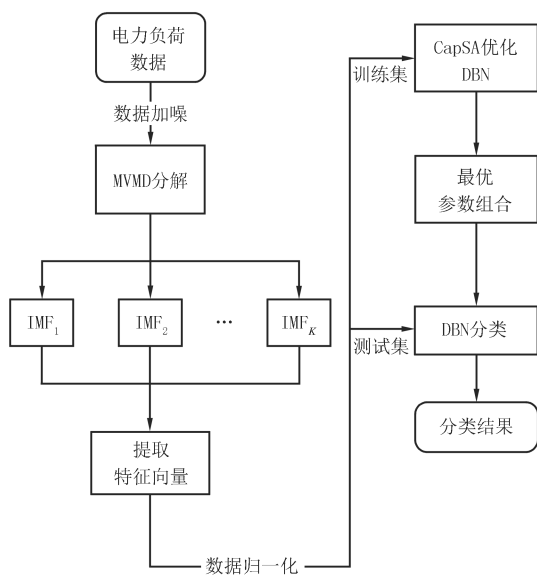


图1 MVMD-CapSA-DBN模型流程图

Fig.1 Flow Chart of MVMD-DBN Model

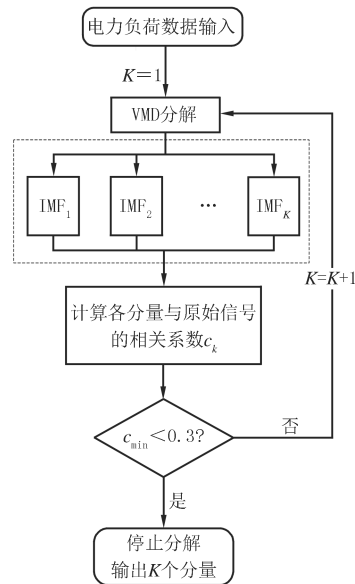


图2 MVMD流程图

Fig.2 Flow chart of MVMD

1.3 DBN 原理

DBN 由 Hinton 2006 年提出,以数层受限玻尔兹曼机(Restricted Boltzman Machine,RBM)为基本构成模块,最后一层连接分类器构成的半监督神经网络.由于其深度学习能力较强,在信号分类方面表现很好,被广泛应用分类问题.

经典 DBN 由多层 RBM 堆叠,最后一层连接 BP 网络构成,其经典结构如图 3.DBN 网络的训练过程是由上到下一层一层进行的,首先输入提取的电力负荷特征数据进行无监督预训练,第一层 RBM 充分训练后再训练下一层;无监督训练后利用 BP 网络进行有监督训练,将最后一层 RBM 的输出作为输入给连接的 BP 网络进行有监督反向微调训练;完成训练.这种训练方式有效避免陷入局部最大值,学习信号特征.DBN 的本质就是特征学习的过程.

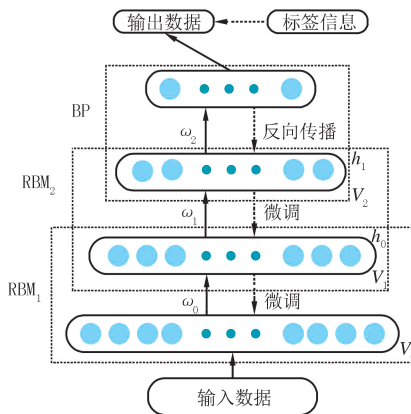


图3 DBN经典结构图

Fig.3 Classic structure diagram of DBN

1.4 CapSA 原理

CapSA 是于 2021 年提出的一种新型智能优化算法.该算法模拟猴子的动态行为.通过对卷尾猴在森林中游荡觅食时的行为进行建模,设计了算法的基本优化特性.具有寻优能力强,收敛速度快等特点.种群包括两种卷尾猴类型:领导者和追随者.追随者可能伴随领导者觅食,并追求类似的运动行为.其算法原理如下.

1)初始化种群

$$x^i = u_j + r \times (u_j - l_j), \tag{5}$$

式中,上标 i 指第 i 个个体,下标 j 指第 j 维, x 为个体的位置, u 为上边界, l 为下边界, r 为 $[0,1]$ 之间随机数.

2) 卷尾猴寿命指数

$$\tau = \beta_0 e^{-\beta_1 \left(\frac{k}{K}\right)^{\beta_2}}, \quad (6)$$

式中, k, K 为当前和最大迭代次数, $\beta_0 = 1, \beta_1 = 11, \beta_2 = 1$. 在全局和局部搜索过程中实现探索和开采之间的平衡.

第 i 只卷尾猴第 j 维速度

$$v_j^i = \rho v_j^i + \tau \alpha_1 (x_{\text{best}j}^i - x_j^i) + \tau \alpha_2 (F_j - x_j^i), \quad (7)$$

其中, x 表示个体当前位置; x_{best} 表示个体最佳位置; F 表示食物位置; $\alpha_1 = 1, \alpha_2 = 1; r_1, r_2$ 均为 $[0, 1]$ 之间随机数; $\rho = 0.7$.

3) 领导者 ($i < n/2$) 的位置

$$x_j^i = \begin{cases} \tau [l_j + \varepsilon (u_j - l_j)], & \varepsilon \leq 0.2, \\ F_j + \frac{P_{ef} P_{bf} (v_j^i)^2 \sin(2\theta)}{g}, & 0.2 < \varepsilon \leq 0.3, \\ x_j^i + v_j^i, & 0.3 < \varepsilon \leq 0.5, \\ F_j + \tau P_{bf} \sin(2\theta), & 0.5 < \varepsilon \leq 0.75, \\ F_j + \tau P_{bf} (v_j^i - v_{j-1}^i), & 0.75 < \varepsilon, \end{cases} \quad (8)$$

式中, ε 为 $[0, 1]$ 随机数; 卷尾猴在地面运动弹性概率 $P_{ef} = 9$; 平衡系数 $P_{bf} = 0.7$; 重力加速度 g 取 9.81 m/s^2 ; 跳跃角度 $\theta = 2/3r$.

4) 追随者 ($n/2 \leq i \leq n$) 位置

$$x_j^i = \frac{1}{2} (x_j^i + x_j^{i-1}), \quad (9)$$

卷尾猴位置更新的过程即为优化过程, 它们按照上述运动方式寻找食物, 一段寻优时间过后, 运动到食物周围, 最佳寻优位置即食物所在位置.

1.5 CapSA 优化 DBN

DBN 神经网络中各参数、隐含层数及隐含层神经元个数对结果均有影响^[20-22], 经实验显示, DBN 具有两层隐含层其深度学习效果已经很好, 所以模型确定隐含层为两层. 动量 m , 学习因子 α , 隐含层 RBM1 和 RBM2 的神经元个数对结果影响较大, 所以对 DBN 网络这 4 个参数进行寻优. 将 DBN 网络结果误差作为目标函数. CapSA-DBN 流程如下:

- 1) 设置 CapSA 参数, 算法初始化. 设置卷尾猴数量, 寻优范围, 变量个数和最大迭代次数.
- 2) 设置目标函数. 将 DBN 网络训练误差作为寻优条件.
- 3) 输入训练数据. 将经 MVMD 获得的特征向量矩阵归一化后, 取 70% 作为训练数据.
- 4) 根据式(5)初始化卷尾猴速度, 计算其适应度.
- 5) 当步骤 4) 没有满足条件, 根据式(6)更新寿命函数, 根据式(8)和(9)更新卷尾猴位置, 计算其适应度.
- 6) 重复步骤 5), 直至达到精度要求或者到达最大迭代次数.
- 7) 得到最优组合, 对 DBN 网络参数设置.

2 实验方法及结果

2.1 实验数据

本文使用的数据集为华东某地区水泥厂 2021 年 11 月的负荷实测数据. 本实验使用的数据集包括水泥厂二线粉磨车间和二线原料磨车间采集的不同电力负荷的有功功率, 对每个负荷每 5 min 采集一次功率数据, 每天共采集 288 个数据点, 每类负荷数据集大小为 30×288 . 负荷包括辊压机(定辊)主电机 (S_1)、水泥循环风机主电机 (S_2)、水泥粉磨主电机 (S_3)、废气处理排风机 (S_4)、窑尾高温风机 (S_5)、辊压机(动辊)主电机 (S_6) 共 6 种负荷装置. 其数据波形如图 4 所示. 根据采集信息, 水泥厂在 7 日、8 日原料磨车间和粉磨车间轮

休进行检修,因此舍弃为 0 的数据.

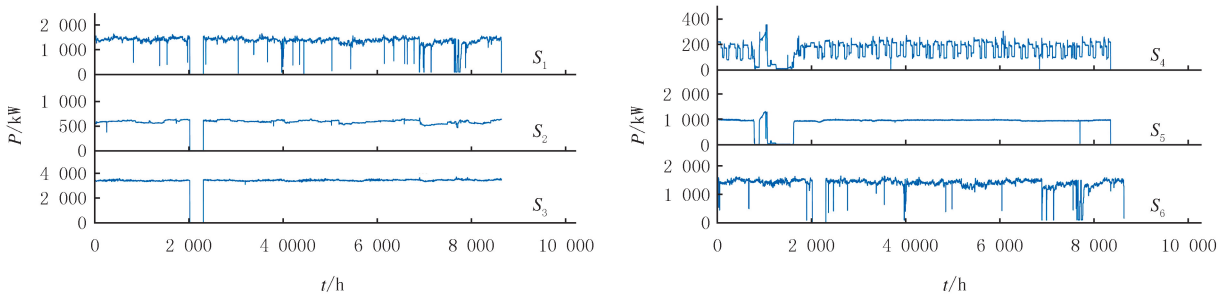


图4 多元负荷功率波形图

Fig.4 Multi-load power waveform diagram

2.2 实验方法

2.2.1 负荷数据 MVMD 分解

将每组数据采用 MVMD 分解.计算每种负荷有功功率数据原始波形与分解后 $K=3$ 组数据的相关系数 c_k ,如表 1 所示.

表 1 分解信号与原始信号的波形相关系数表

Tab. 1 Waveform correlation coefficient table of decomposed signal and original signal

分类	c_1	c_2	c_3
S_1	0.842 1	0.495 6	0.189 0
S_2	0.969 8	0.271 1	0.081 4
S_3	0.835 2	0.502 1	0.171 0
S_4	0.778 4	0.690 5	0.292 5
S_5	0.888 5	0.542 7	0.167 5
S_6	0.866 5	0.348 6	0.215 1

由表 1 可知,对 6 种负荷经 MVMD 分解过程中, $K=3$ 时, S_1 、 S_3 、 S_4 、 S_5 、 S_6 的 c_{\min} 均小于阈值 0.3,即停止分解; S_2 在 $K=2$ 时既满足停止条件,为了保证特征向量维度的一致性,方便后续神经网络向量输入,综合取分解分量 $K=3$.取 S_1 负荷观察其分解 3 层模态分量波形与频谱对应图,如图 5 所示.由图 5 可观察,负荷信号 S_1 经 3 层分解后,其高中低频谱均已被分解出,且没有出现模态混叠的现象,证明所提出的停止准则有效,在多元负荷分类中应用成功.

2.2.2 提取特征向量

根据上一小节,将各负荷删减数据为 0 的数据后,对共 29 d 的数据 MVMD 分解,提取各分量特征向量,计算各分量的能量值作为特征,得到特征向量大小为 174×3 的矩阵,并根据特征向量制作对应标签向量,标签矩阵大小为 174×6 .

2.2.3 CapSA 优化 DBN 网络

根据 1.5 小节所述,利用 CapSA 对 DBN 网络的动量 m 、学习因子 α 、以及隐含层 RBM1、RBM2 的神经元个数寻优.设置 CapSA 的初始参数如表 2.

表 2 CapSA 参数设置

Tab. 2 CapSA parameter settings

种群规模	最大迭代次数	搜索维度	变量上限	变量下限
30	50	4	[1 0.1 20 20]	[0 0 10 10]

设置好参数后,将 DBN 网络分类误差作为适应度函数,进行参数优化.CapSA 优化结果为 $\alpha=0.994 3$, $m=0.095 8$,RBM1 和 RBM2 的神经元个数分别为 15、17.

2.3 实验结果

将由 CapSA 优化得到的参数,对 DBN 网络参数设置,输入多元负荷特征向量与标签;其中 70%数据作

为训练集,30%的数据作为测试集,其分类结果平均正确率在 88.89% 以上.图 6 为 DBN 网络对多元负荷分类结果图,表 3 为各负荷根据图 6 分类结果所统计的分类准确度表.

根据图 6 以及表 3 的结果可以观察, S_6 的准确度相比较其他负荷较低,其分类模糊类为 S_1 .根据图 4 可以明显看出 S_6 与 S_1 的波形相似性很高,数据特征区分度不高,由于整体数据量不够,因此难以准确区分.

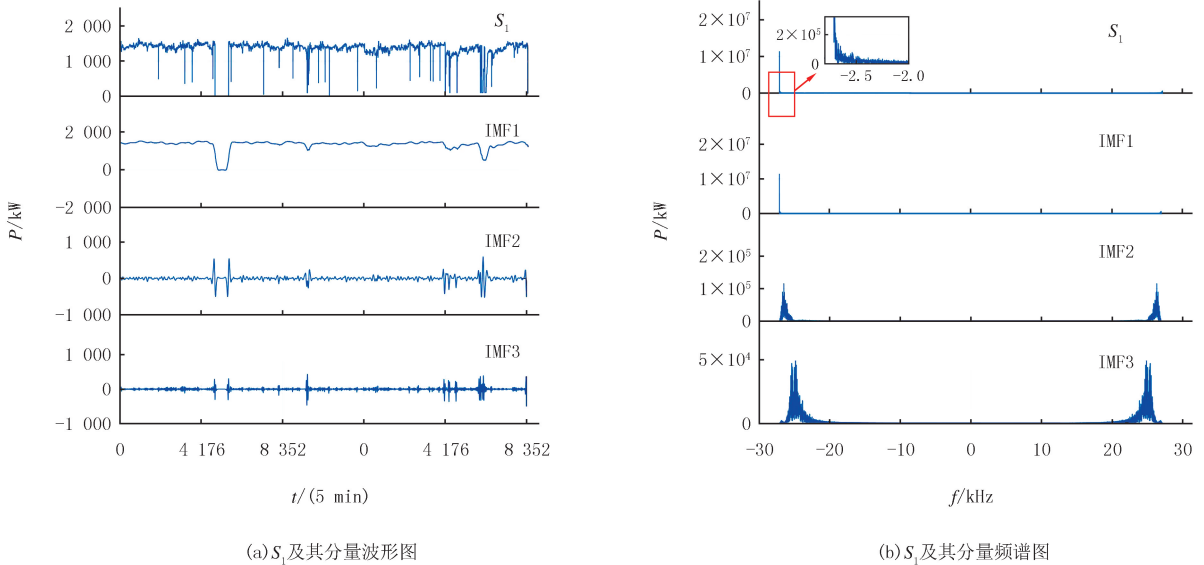


图5 S_1 负荷分解波形及其对应频谱图

Fig.5 S_1 load decomposition waveform and its corresponding spectrogram

为了验证本模型的准确性,采用不同优化算法对 DBN 参数进行优化,图 7 为 CapSA 优化算法与灰狼优化算法(GWO)、飞蛾火焰优化算法(MFO)对 DBN 参数优化的结果对比图.




图6 分类结果图

Fig.6 Classification result graph




图7 优化结果对比图

Fig.7 Comparison of optimization results

表 3 各负荷分类准确度

Tab. 3 Classification accuracy of each load

负荷类别	S_1	S_2	S_3	S_4	S_5	S_6
准确度/%	88.89	100	100	100	77.78	66.67

从图 7 可以明显观察出, CapSA 收敛速度更快,在经过 17 次迭代后,其结果已经达到最优 0.111 1,相比于 GWO 需要 41 次迭代才能达到最优,其速度更快;MFO 误差结果在第 17 次误差达到最优 0.148 1,相对 CapSA,其精度低了 33.30%.综合比较, CapSA 的整体效果最好.

3 结 论

本研究就工业生产中为合理调度用电负荷,对具体负荷的如何准确分类进行讨论.研究结果表明:1)通过停止准则确定变分模态分解的分解模态分量数,有效避免了传统变分模态分解的分解分量由人为确定的模糊性,使分解分量有依据,适应性更强,减少通过多次实验确定的不准确性同时也能提高分解速度;2)采用 CapSA 优化 DBN 算法,对比 GWO、MFO 优化结果, CapSA 收敛速度更快,较 GWO 减少迭代时间;优化更加有效,较 MFO 精度有所提高.但针对负荷曲线相似度高、数据少的负荷分类结果不理想,仍需改进,这是后续需要研究的方向.

参 考 文 献

- [1] 徐春华,陈克绪,马建,等.基于深度置信网络的电力负荷识别[J].电工技术学报,2019,34(19):4135-4142.
XU C H, CHEN K X, MA J, et al. Recognition of power loads based on deep belief network[J]. Transactions of China Electrotechnical Society, 2019, 34(19): 4135-4142.
- [2] 徐岩,向益锋,马天祥.基于 EMD-CNN-LSTM 混合模型的短期电力负荷预测[J].华北电力大学学报(自然科学版),2022,49(2):81-89.
XU Y, XIANG Y F, MA T X. Short-term power load forecasting method based on EMD-CNN-LSTM hybrid model[J]. Journal of North China Electric Power University(Natural Science Edition), 2022, 49(2): 81-89.
- [3] LIU Z Z, DING K, LIN H B, et al. A novel impact feature extraction method based on EMD and sparse decomposition for gear local fault diagnosis[J]. Machines, 2022, 10(4): 242.
- [4] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [5] 商立群,李洪波,侯亚东,等.基于 VMD-ISSA-KELM 的短期光伏发电功率预测[J].电力系统保护与控制,2022,50(21):138-148.
SHANG L Q, LI H B, HOU Y D, et al. Short-term photovoltaic power generation prediction based on VMD-ISSA-KELM[J]. Power System Protection and Control, 2022, 50(21): 138-148.
- [6] 马宗彪,许素安,朱少斌,等.基于特征加权模糊聚类的电力负荷分类[J].中国电力,2022,55(6):25-32.
MA Z B, XU S A, ZHU S B, et al. Power load classification based on feature weighted fuzzy clustering[J]. Electric Power, 2022, 55(6): 25-32.
- [7] 周开乐,杨善林.基于改进模糊 C 均值算法的电力负荷特性分类[J].电力系统保护与控制,2012,40(22):58-63.
ZHOU K L, YANG S L. An improved fuzzy C-means algorithm for power load characteristics classification[J]. Power System Protection and Control, 2012, 40(22): 58-63.
- [8] 石亮缘,周任军,张武军,等.采用深度学习和多维模糊 C 均值聚类的负荷分类方法[J].电力系统及其自动化学报,2019,31(7):43-50.
SHI L Y, ZHOU R J, ZHANG W J, et al. Load classification method using deep learning and multi-dimensional fuzzy C-means clustering [J]. Proceedings of the CSU-EPSA, 2019, 31(7): 43-50.
- [9] 贾志达,姜枫,王海鑫,等.基于 VMD 和 FCM 聚类方法的电网负荷分类[J].东北电力技术,2019,40(5):1-6.
JIA Z D, JIANG F, WANG H X, et al. Classification analysis of power system load based on VMD-FCM clustering[J]. Northeast Electric Power Technology, 2019, 40(5): 1-6.
- [10] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [11] 张建宇,任成功.基于深度信念网络的滚动轴承特征迁移诊断[J].振动、测试与诊断,2022,42(2):277-284.
ZHANG J Y, REN C G. Feature transferring diagnosis of rolling bearing based on deep belief network[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(2): 277-284.
- [12] 程换新,黄震.基于改进 PSO 优化 RNN 的短期电力负荷预测模型[J].电子测量技术,2019,42(20):94-98.
CHENG H X, HUANG Z. Short-term electric load forecasting model based on improved PSO optimized RNN[J]. Electronic Measurement Technology, 2019, 42(20): 94-98.
- [13] 许子非,岳敏楠,李春.优化递归变分模态分解及其在非线形信号处理中的应用[J].物理学报,2019,68(23):238401.
XU Z F, YUE M N, LI C. Application of the proposed optimized recursive variational mode decomposition in nonlinear decomposition[J]. Acta Physica Sinica, 2019, 68(23): 238401.
- [14] 王进花,胡佳伟,曹洁,等.基于自适应变分模态分解和集成极限学习机的滚动轴承多故障诊断[J].吉林大学学报(工学版),2022,52(2):318-328.
WANG J H, HU J W, CAO J, et al. Multi-fault diagnosis of rolling bearing based on adaptive variational modal decomposition and integrated extreme learning machine[J]. Journal of Jilin University(Engineering and Technology Edition), 2022, 52(2): 318-328.
- [15] 唐贵基,王晓龙.参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J].西安交通大学学报,2015,49(5):73-81.
TANG G J, WANG X L. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of roll-

- ing bearing[J].Journal of Xi'an Jiaotong University,2015,49(5):73-81.
- [16] TAMILSELVAN P,WANG P F.Failure diagnosis using deep belief learning based health state classification[J].Reliability Engineering & System Safety,2013,115:124-135.
- [17] BRAIK M,SHETA A,AL-HIARY H.A novel meta-heuristic search algorithm for solving optimization problems;capuchin search algorithm[J].Neural Computing and Applications,2021,33(7):2515-2547.
- [18] 张淑清,宿新爽,陈荣飞,等.基于变分模态分解和 FABP 的短期电力负荷预测[J].仪器仪表学报,2018,39(4):67-73.
ZHANG S Q,SU X S,CHEN R F,et al.Short-term load forecasting based on the VMD and FABP[J].Chinese Journal of Scientific Instrument,2018,39(4):67-73.
- [19] 胡威,张新燕,李振恩,等.基于优化的 VMD-mRMR-LSTM 模型的短期负荷预测[J].电力系统保护与控制,2022,50(1):88-97.
HU W,ZHANG X Y,LI Z E,et al.Short-term load forecasting based on an optimized VMD-m RMR-LSTM model[J].Power System Protection and Control,2022,50(1):88-97.
- [20] 黄书民,蒋林高,李志川,等.基于 PSO 寻优与 DBN 神经网络的电晕损耗预测[J].中国电力,2022,55(6):95-102.
HUANG S M,JIANG L G,LI Z C,et al.Corona loss prediction of UHV AC transmission line based on DBN neural network optimized by PSO[J].Electric Power,2022,55(6):95-102.
- [21] 齐洪方,黄定洪.基于 ISFLA 优化深度置信网络的滚动轴承故障诊断方法研究[J].机电工程,2021,38(1):62-68.
QI H F,HUANG D H.Rolling bearing fault diagnosis method based on DBN optimized by ISFLA[J].Journal of Mechanical & Electrical Engineering,2021,38(1):62-68.
- [22] HU F,ZHOU M R,LI M,et al.Joint feature selection of power load in time domain and frequency domain based on whale optimization algorithm[J].International Transactions on Electrical Energy Systems,2022,2022:1-13.

Research on industrial multiple load classification based on MVMD-CapSA-DBN

Zhou Mengran¹, Zhang Yiping¹, Wang Shenghe², Ma Jinhui², Gao Bo²,
Hu Feng¹, Zhu Ziwei¹, Wang Kun¹, Liu Yu¹

(1. School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, China;

2. State Grid Anhui Electric Power Co., Ltd., Hefei 230001, China)

Abstract: Aiming at the non-stationarity, time series correlation and nonlinearity of multiple power load data time series, in order to grasp the change law and development trend of power load and realize the scientific management of power load, this paper takes the active power of industrial multiple load as the original data. The MVMD-CapSA-DBN load classification model is proposed. First, the data is decomposed by Variational Mode Decomposition(VMD) with improved stopping criterion to obtain multiple data components that are relatively stable; then, the energy value of each component is extracted as a feature; Finally, the 0-1 normalized data is used as a feature vector and input into the Deep Belief Nets(DBN) signal classification after parameters are optimized by the Capuchin Search Algorithm(CapSA). Experiments show that the model in this paper can achieve effective classification of industrial multi-load data, the overall accuracy rate is about 88.89%, and the partial load classification accuracy rate can reach 100%.

Keywords: power load; load classification; variational model decomposition; Deep Belief Network; Capuchin Search Algorithm

[责任编辑 杨浦 刘洋]