

考虑概率区间的微电网 短期负荷多目标预测方法

于昕妍,沈艳霞,陈 杰,纪志成

(江南大学物联网技术应用教育部工程研究中心,江苏无锡 214122)

摘 要: 微电网负荷随机性强、波动大,负荷单点预测已经难以满足微电网稳定运行需要. 提出一种考虑概率区间的微电网短期负荷多目标预测方法,以循环神经网络为预测模型,以逼近理想解排序策略、网格筛选策略对基本多目标人工蜂群算法进行改进,优化循环神经网络的权值和阈值,避免单目标区间预测中惩罚系数难以选择的问题,对历史负荷数据进行记忆并修正预测结果,有效提高微电网短期负荷区间预测准确性与可靠性. 仿真结果表明,本文所构建的考虑概率区间的微电网短期负荷多目标预测方法,预测性能优越、结果准确,可为微电网安全经济调度提供决策依据.

关键词: 微电网; 区间预测; 循环神经网络; 人工蜂群算法

中图分类号: TM715 **文献标识码:** A **文章编号:** 0372-2112 (2017)04-0930-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2017.04.023

A Multi-Objective Prediction Method for Short-Term Microgrid Load Considering Interval Probability

YU Xin-yan, SHEN Yan-xia, CHEN Jie, JI Zhi-cheng

(Engineering Research Center of Internet of Things Technology Application Ministry of Education, Jiangnan University, Wuxi, Jiangsu 214122, China)

Abstract: Load of microgrid has characteristics of strong randomness and large fluctuation, so that single point prediction cannot satisfy the need of microgrid operating stability. In this paper, a modified multi-objective optimization prediction intervals (PIs) method for microgrid load is proposed, recurrent neural network (RNN) is adopted to build load prediction model, technique for order preference by similarity to an ideal solution and the grid selection strategy are introduced to modify multi-objective artificial bee colony algorithm (MMOABC), which optimizes the RNN prediction model, improving the accuracy and reliability of microgrid short-term load intervals prediction. The experiment results show that the proposed method for microgrid load has superior performance, which can provide the decision-making basis for the safety and economy of microgrid operation.

Key words: microgrid; prediction intervals; recurrent neural network; artificial bee colony

1 引言

微电网是将分布式电源、储能装置、能量转换装置及监控、保护装置等联结起来向用户供电的小型分散系统^[1-4]. 微电网负荷的精确预测是微电网运行和能量管理的重要基础,将直接影响微电网运行策略^[5-7].

与大电网环境相比,微电网负荷随机性强,历史负荷曲线相似度低,负荷总体波动较大^[8],短期负荷预测更加困难. 目前,国内外关于微电网负荷预测已经取得

了部分成果,文献[9]考虑用电特征不确定性提出基于核函数极限学习机的微电网短期负荷预测方法,能够有效针对不同容量类型的用户侧微电网进行短期负荷预测;文献[10]对微电网负荷时间序列进行经验模态分解,运用扩展卡尔曼滤波及核函数极限学习机的组合模型对短期负荷预测进行预测,预测效果较为满意;文献[11]提出微电网剩余负荷的概念,并建立混合智能模型,准确对微电网剩余负荷进行预测. 但以上方法均为单一点预测,只给出一个确定的数值,无法确定

收稿日期:2016-07-11;修回日期:2016-10-14;责任编辑:马兰英

基金项目:国家自然科学基金(No. 61579167, No. 61572237);高等学校博士学科点专项科研基金(No. 20130093110011)

预测结果可能的波动范围^[12]. 而微电网系统中蕴含了诸多不确定因素,使得决策工作存在风险,在决策时必须考虑电力需求的不确定性,因此实现区间预测更加符合客观需求^[13]. 文献[14]运用组合预测模型通过马尔科夫转移矩阵进行区间预测,并考虑曲线相似性提高区间预测精度;文献[15]将聚类算法和混沌时间序列方法相结合,有效地进行短期负荷概率性区间预测. 最典型的成果是 2011 年 Khosravi 等^[16]通过比较 Delta 法、Bayesian 法与 MVE 法进行区间预测,提出一种基于神经网络的简易区间预测模型(Lower Upper Bound Estimation, LUBE),实现快速精确地区间预测^[17]. 之后 Quan 等^[18]将该模型运用到负荷区间预测研究,预测效果较为满意. 然而 Khosravi 与 Quan 所使用的区间预测模型本质上是通过对惩罚系数将多目标优化问题转化为单目标优化问题,而惩罚函数的选择与数据集、算法关系较大,且以经验取值为主,在一定程度上制约了概率区间预测的研究.

本文在 Khosravi、Quan 等人的研究基础上,提出一种考虑概率区间的微电网短期负荷多目标预测方法,采用循环神经网络(Recurrent Neural Networks, RNN)为预测模型,对历史负荷数据进行记忆并应用于预测结果修正,针对原单目标区间预测方法中惩罚系数难以选择的问题,直接对置信度与预测区间进行多目标预测;以逼近理想解排序策略、网格筛选策略对基本多目标人工蜂群算法(Multi-Objective Artificial Bee Colony, MOABC)进行改进,优化循环神经网络的权值和阈值,提高算法的效率,保证解分布的均匀性,进而有效提高微电网短期负荷区间预测准确性与可靠性.

2 基于 RNN 的微电网负荷概率区间预测模型

不同于传统前向反馈神经网络(Feed-forward Neural Networks, FNN),RNN 中存在承接层与隐含层连接,神经元在当前时刻的输出可以在下一时刻直接作用于自身,即每个神经元的输出是该时刻输入和所有历史时刻输入共同作用的结果,达到对时间序列建模的目的,在预测领域取得了较好的效果^[19,20].

采用 RNN 对微电网负荷区间进行预测,以预测点前多个时刻的实际负荷作为输入,采用 C-C 相空间重构法确定输入层节点数 q ;前一时刻承接层的输出作为当前时刻隐含层的输入,采用 Kolmogorov 法确定隐含层节点数 k 与承接层节点数 h ;输出层为负荷预测区间上下界. 如图 1 所示,基于 RNN 的预测模型结构为 $q-k(h)-2$.

基于 RNN 的负荷区间预测模型网络能对预测点之前较多的负荷信息进行记忆并应用于当前负荷预测输




图1 基于RNN的负荷区间预测模型

出计算中,即隐含层之间的节点不再无连接而是有连接的,隐含层的输入不仅包括输入层的输出还包括上一时刻承接层的输出.

3 预测区间评价指标

以预测区间作为优化目标^[18],通过两个指标分别衡量预测区间的可靠性和准确性. 预测区间覆盖率(Prediction Intervals Coverage Probability, PICP) P 反映了预测区间的可靠性:

$$P = \frac{1}{N} \sum_{i=1}^N c_i \quad (1)$$

其中, N 为样本个数, c_i 为布尔变量.

$$c_i = \begin{cases} 1, & \xi_i \in [L_i, U_i] \\ 0, & \xi_i \notin [L_i, U_i] \end{cases} \quad (2)$$

ξ_i 为实际负荷, L_i 为预测下界, U_i 为预测上界. 假设预测的理想情况为所有目标点都落在预测区间内,只需将预测带宽放大到预测边界,则失去了预测意义. 因此,引入预测区间平均带宽(Prediction Intervals Normalized Average Width) W 作为第二个评价标准以衡量预测区间的准确度:

$$W = \frac{1}{NR} \sum_{i=1}^N (U_i - L_i) \quad (3)$$

其中, R 为检验样本的目标值范围,即样本最大值与最小值之差.

在电网实际调度中,需同时提高预测结果的准确性和可靠性, P 越大表示可靠性越高, W 越小表示准确性越高,即:

$$\begin{cases} \text{Maximize: } P \\ \text{Minimize: } W \end{cases} \quad (4)$$

在求解该优化问题时,两个性能指标是相互矛盾的,提高预测区间的可靠性会导致准确性的下降,反之亦然. 为了解决这一问题,传统的做法是利用惩罚系数将多目标优化问题转换为单目标优化问题,然而目前惩罚系数的取值方法多依靠经验取值,惩罚系数如果选取不合理,所得的单目标优化问题最优解并不能代表该问题的最优解,难以保证微电网负荷概率预测的可靠性和准确性. 因此,本文构建了一种微电网负荷区间预测多目标优化准则,将式(4)转化为多目标最小化

问题求解:

$$\begin{cases} \text{Minimize: } \alpha = 1 - P \\ \text{Minimize: } W \end{cases} \quad (5)$$

考虑到微电网负荷功率对微电网调度及经济安全运行的实际需要,假设区间预测指标 P 不小于 80%, W 不超过 30%,得到以下约束条件:

$$\begin{cases} 80\% \leq P \leq 100\% \\ 0 \leq W \leq 30\% \end{cases} \quad (6)$$

4 基于改进 MOABC 的微电网负荷区间多目标优化算法

微电网具有较强的负荷时间序列随机性与不确定性,传统多目标算法寻优能力不佳.多目标人工蜂群算法是一种结合蜜蜂采蜜行为的群智能优化算法,具有设置参数少、收敛速度快和求解精度高等优点.因此本文构建微电网负荷区间预测多目标优化模型,通过逼近理想解排序策略、网格筛选策略对多目标人工蜂群算法进行改进^[21-24],提出改进多目标人工蜂群算法(Modified Multi-Objective Artificial Bee Colony, MMO-ABC),用以优化循环神经网络的权值和阈值,实现多目标区间预测模型的寻优,以提高微电网短期负荷区间预测准确性与可靠性.

4.1 逼近理想解排序策略

设 f_j^* 和 f_j^0 分别为当前所有蜜蜂寻找蜜源过程中获得的第 j 个蜜源最大值和最小值, $j = (1, 2, \dots, m)$, m 为蜜源个数;设正理想解 X^* 与负理想解 X^0 分别对应目标向量 $Y^* = (f_1^*, f_2^*, \dots, f_m^*)$ 与 $Y^0 = (f_1^0, f_2^0, \dots, f_m^0)$. 令解集中第 i 个蜜源与正理想解及负理想解的距离分别为 $dis(i, X^*) = \sqrt{\sum_{j=1}^m (f_j(i) - f_j^*)^2}$ 与 $dis(i, X^0) = \sqrt{\sum_{j=1}^m (f_j(i) - f_j^0)^2}$, 则第 i 个蜜源综合评价指数为 $TOP_i = dis(i, X^0) / (dis(i, X^0) + dis(i, X^*))$, 取 TOP 最大的蜜源 x_j^{best} 为全局最优蜜源. 利用逼近理想解排序策略确定全局最优蜜源可以使得所有蜜源更快地靠近 Pareto 前沿,同时这个全局最优蜜源就是“理想解”.

4.2 网格筛选策略

根据非支配蜜源的分布,计算个体所属的网格以及其到网格中心的距离,只选择距离网格中心最近的蜜源进行保留,从而在选择最优个体的同时保证蜜源分布的均匀性.

4.3 基于 MMOABC 的微电网短期负荷概率区间多目标优化算法

步骤 1 参数初始化. 设置 RNN 结构 $q - k(h) - 2$ 、MMOABC 种群数 $nPop$ 、最大迭代次数 $nMax$, 外部档案存储个数 $nRep$, 蜜源淘汰最大迭代次数 $nMaxTrial$, 对微

电网负荷集进行归一化,分为训练集(85%)和测试集(15%).

步骤 2 蜜源初始化. 随机生成 $NP = nPop/2$ 个 S 维蜜源 $X_i = \{x_{i1}, x_{i2}, \dots, x_{iS}\}$, 其中 i 为蜜源编号, S 为需优化的 RNN 的权值阈值维数,根据产生的蜜源构建 RNN 概率区间预测模型,根据式(1)和式(3)计算各蜜源的 P 和 W 指标,并根据式(5)转化为 α 和 W 形式.

步骤 3 Pareto 支配选择. 当满足 $\alpha_i \leq \alpha_j, W_i \leq W_j$ 且等号不同时成立时,称第 i 个蜜源支配第 j 个蜜源,记作 $i > j$. 选择支配其他蜜源又不被其他任一蜜源支配的蜜源进入外部档案保存,记录各蜜源支配其他蜜源的个数为 nPa_i .

步骤 4 雇佣蜂更新. 采用逼近理想解排序策略确定确定全局最优蜜源,并将其他蜜源与之进行交叉又产生新蜜源,公式为:

$$v_{ij} = x_{ij} + R * (x_{ij} - x_j^{best}) \quad (7)$$

其中, x_j^{best} 为最优蜜源, v_{ij} 为第 i 个蜜源的第 j 个分量更新后的值, R 为 $[-1, 1]$ 间的一个随机数. 计算新蜜源的性能指标 P 和 W , 判断新蜜源性能指标是否支配原蜜源,如果是,则保留新蜜源,否则继续选择原蜜源.

步骤 5 概率选择. 计算各蜜源与参考点(0,0)间的欧式距离 D_i . 接着根据支配信息及与参考点的距离计算各个蜜源适应度:

$$F = \frac{nPa_i}{nPa_{\max}} \times \left(1 - \frac{nIt}{nMax}\right) + D_i \times \frac{nIt}{nMax} \quad (8)$$

其中, nPa_i 和 nPa_{\max} 分别为第 i 个蜜源支配其他蜜源的个数和支配其他蜜源的最大数量, nIt 为当前迭代次数. 根据适应度信息可以计算出各蜜源选择概率:

$$prob_i = \frac{F_i}{\sum_{i=1}^{NP} F_i} \quad (9)$$

步骤 6 跟随蜂更新. 跟随蜂通过式(9)计算得到的蜜源的概率与轮盘赌进行比较,判断是否进行进一步深度搜索,若是,则按步骤四对该蜜源进行进一步搜索. 由式(9)可知,当支配其他蜜源个数越多,则该蜜源被选择深度搜索的概率也更大.

步骤 7 侦察蜂淘汰不良蜜源. 如果一个蜜源在 $nMaxTrial$ 内没有进入外部档案,则被认为是不良蜜源,予以淘汰. 并通过网格筛选策略,计算个体所属的网格以及其到网格中心的距离,只选择距离网格中心最近的蜜源进行保留,从而在选择最优个体的同时保证蜜源分布的均匀性.

步骤 8 判断是否到达最大迭代次数. 若未达到最大迭代次数,转步骤 3,雇佣蜂返回蜂巢分享蜜源信息;若已达到最大迭代次数,输出蜜源.

5 算例分析

为验证本文提出的考虑概率区间的微电网短期负荷多目标预测方法的有效性,选取加州大学尔湾分校机器学习数据库(<http://archive.ics.uci.edu/ml/datasets>)于 2009 年采集的北欧某微电网负荷序列,该微电网负荷包括 168 户居民、1 家木材加工厂与其他商业配套等.本文选取其中 5000 组负荷数据进行研究,采样间隔为 1 小时,进行归一化处理,其中前 85% 作为训练集,后 15% 作为测试集.综合相关预测研究,短期预测输入层节点数一般设置为 4 最佳,即以预测点前 4 个负荷数据为 RNN 模型输入.由于预测结果为一置信区间,即预测上下界,因此输出层节点数为 2.此时预测模型可确定为 $4-k(h)-2$,而 RNN 的承接层节点数 h 一般设置小于等于隐含层节点 k 的数值,此处假设 $h=k$,此时通过相空间重构法与 Kolmogorov 法再确定隐含层和承接层的节点数,即可得出 RNN 的预测模型结构为 $4-7(7)-2$.并设置 MMOABC 算法相关参数完成对该预测模型进行寻优.

5.1 多目标优化与传统单目标优化区间预测性能的对比分析

本文选取人工蜂群(Artificial Bee Colony, ABC)算法在不同惩罚函数下对单目标优化预测模型进行优化、拟合并对测试集进行预测,再分别采用非支配排序

遗传算法 NSGA2-RNN^[25]、多目标人工蜂群算法 MO-ABC-RNN^[26]和本文提出的 MMOABC-RNN 算法对多目标优化预测模型进行优化、拟合并预测,并对预测结果进行分析与性能比较.单目标区间预测优化准则参考文献[17],设置 3 种不同惩罚系数 $\eta_1 = 10, \eta_2 = 50, \eta_3 = 100$ 进行区间预测.设置 MOABC 算法、MMOABC 算法和 ABC 算法的种群数 $nPop$ 为 40,最大迭代次数 $nMax$ 为 200,淘汰最大迭代次数 $nMaxTrial$ 为 50,MMO-ABC 算法的外部存储档案个数 $nRep$ 为 20.设置 NSGA2-RNN 模型交叉率为 0.8,变异率为 0.2.为了统一比较多目标预测结果与单目标预测结果性能指标的优劣,将多目标预测结果选出满足某一置信度中的可靠性指标 P 最小的一组与单目标结果进行比较,并且在求解同一惩罚系数和置信度下的最优解时,重复求解 10 次取其平均值.表 1 给出三种不同惩罚系数下单目标优化和三种多目标优化预测结果的可靠性指标 P 和准确性指标 W .图 2 给出各负荷预测模型在不同置信度(0.99, 0.95, 0.90, 0.85, 0.80)下预测区间带,用颜色加以区分.图 2(a) - 2(c) 为单目标 ABC-RNN 模型在三个不同惩罚系数下预测区间,图 2(d) - (f) 为 NSGA2-RNN 模型、MOABC-RNN 模型和 MMOABC-RNN 模型的负荷预测区间.

表 1 不同惩罚系数下 ABC-RNN 模型及多目标预测模型预测结果性能对比

预测模型	置信度		0.99		0.95		0.90		0.85		0.80	
	预测指标		P	W	P	W	P	W	P	W	P	W
ABC-RNN $\eta_1 = 10$ $\eta_2 = 50, \eta_3 = 100$			0.966	0.271	0.932	0.246	0.886	0.219	0.862	0.192	0.800	0.138
			0.982	0.265	0.956	0.240	0.901	0.196	0.858	0.187	0.802	0.143
			0.967	0.300	0.955	0.278	0.903	0.241	0.851	0.235	0.818	0.211
NSGA2-RNN			0.990	0.205	0.952	0.187	0.911	0.151	0.855	0.132	0.822	0.118
MOABC-RNN			0.991	0.162	0.961	0.128	0.948	0.114	0.878	0.099	0.836	0.091
MMOABC-RNN			0.992	0.122	0.966	0.109	0.940	0.100	0.881	0.081	0.845	0.077

仅从单目标预测模型 ABC-RNN 预测结果性能指标来看,当惩罚系数为 10 时,由于惩罚系数过小,虽然满足可靠性要求 P ,但 W 指标略大;当惩罚系数为 100 时,基本满足置信度要求,而此时准确性指标 W 过大,即预测区间宽度过大,尤其在 0.99 置信度情况下,宽度为预设值 30%,未能有效寻优;当惩罚系数为 50 时,基本能够满足指标 P ,0.99 置信度除外,该置信度下 ABC-RNN 均无法保证满足 P ,且准确性指标 W 较其他惩罚函数下基本有所提升;但当置信度为 0.80 时,惩罚系数为 10 的模型预测结果准确性指标 W 却较惩罚系数为

50 的结果更优,说明了即使同一组数据同一算法的惩罚系数选择也受实际置信度要求的影响,实际负荷预测中更是复杂多变,运用单目标进行预测的结果受惩罚系数影响较大.从图 2(a) ~ 图 2(c) 可以看出,惩罚系数为 50 的 ABC-RNN 单目标预测区间显著小于惩罚系数分别为 10、100 的预测区间,尤其在置信度高情况下优势更加明显,而图 2(c) 给出的惩罚系数为 100 的预测区间的下边界呈一直线,未能有效寻优,基本失去预测意义.

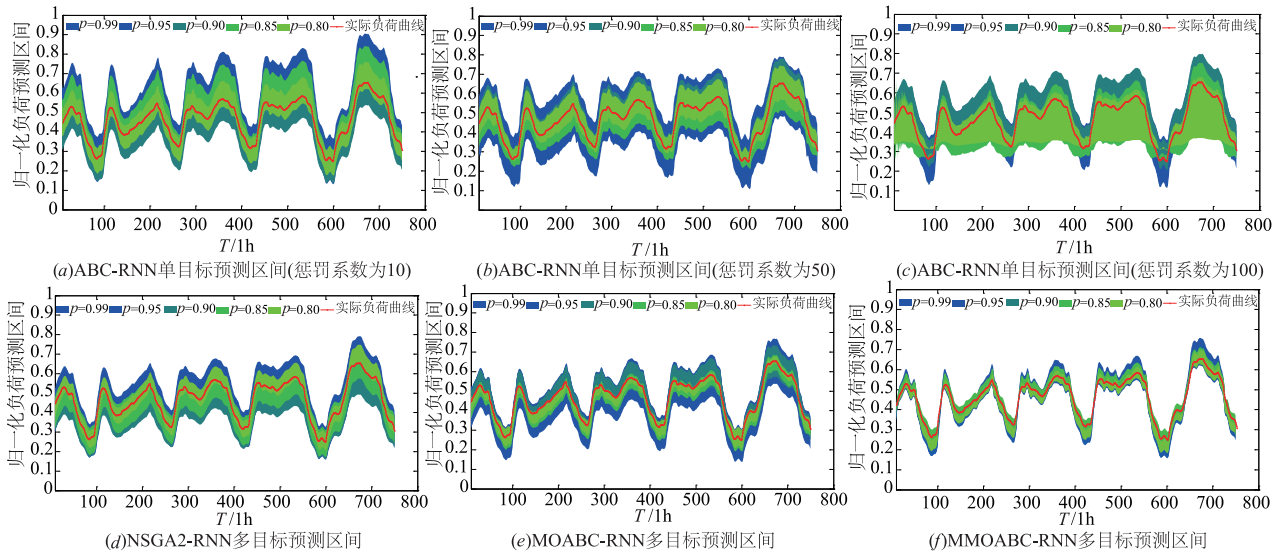


图2 三种惩罚系数下单目标预测与多目标预测微电网负荷功率预测区间

从三种多目标优化负荷区间预测模型结果来看, NSGA2-RNN、MOABC-RNN 与 MMOABC-RNN 预测结果均满足可靠性要求 P , 在此基础上, MMOABC-RNN 预测结果的准确性指标 W 均较其他 2 种多目标算法有所提升, 约提升 17% ~ 38%, 且随着可靠性 P 的升高而提升更为明显. NSGA2-RNN 与 MOABC-RNN 预测模型结果在不同置信度下表现各有优劣, 但稳定性较差. 图 2(e) 给出的 MOABC-RNN 多目标预测区间略优于图 2(d) 给出的 NSGA2-RNN 多目标预测区间, 但这 2 种多目标预测模型结果均显著优于惩罚系数为 50 的 ABC-RNN 单目标预测区间. 图 2(f) 给出的 MMOABC-RNN 多目标预测区间均优于其他任一预测模型, 且在高置信度下, 并没有因为置信度的升高而显著拓宽预测带宽, 如当 0.99 置信度下仅略宽于 0.90 置信度下的预测带宽, 仅在波动显著处略微增加.

5.2 多目标优化算法负荷区间预测结果性能分析

图 3 给出了 NSGA2-RNN 模型、MOABC-RNN 模型和 MMOABC-RNN 模型的负荷概率区间预测结果. 从中可以看出, 三种模型的预测平均带宽指标 W 从小到大依次为 MMOABC-RNN 模型、MOABC-RNN 模型、NS-




图3 三种多目标模型预测性能比较

GA2-RNN 模型, MMOABC-RNN 模型略优于 MOABC-RNN 模型, 而 MMOABC-RNN 模型、MOABC-RNN 模型均显著优于 NSGA2-RNN 模型. 随着置信度指标的增大, 尤其置信度在 0.98 以上时, NSGA2-RNN 模型在求解过程中陷入了局部最优, 由于改进过程中应用逼近理想排序策略使得所有蜜源更快地靠近 Pareto 前沿, 同时在概率选择时进行了优化, 避免了分布性失衡, 因此 MMOABC-RNN 模型的预测平均带宽指标 W 优于 MOABC-RNN 模型, 获得了更良好的性能.

图 4 为 3 种多目标模型的外部档案存储个数随迭代次数变化曲线. 在迭代过程中, 未达到存储上限时, 外部档案存储解的个数呈螺旋上升为最佳情况, 如果解的个数呈直线上升趋势说明算法的开发能力过强而探索能力不足, 有可能陷入局部最优. 并且, 当外部档案存储解的个数达到上限时应尽量保持最大值, 此时若发生较大波动会影响解的分布性能. 从图中可以看出, 相比于 MOABC-RNN 模型和 NSGA2-RNN 模型, MMOABC-RNN 模型所求的外部档案存储解的个数未呈现直线上升且在达到最大值时波动较小, 因此 MMOABC-RNN 的微电网负荷概率区间预测模型不仅具有良好的开发能力和探索能力, 且求解过程避免了局部最




图4 三种多目标区间预测模型动态性能对比

优问题,求得的解集分布性能良好.

6 结论

本文针对目前微电网负荷单点预测不能满足电力决策要求,基于循环神经网络构建了一种微电网负荷概率区间预测模型,针对单目标预测过程中惩罚系数难以选择的问题,将多目标人工蜂群算法引入并通过逼近理想解排序策略与网格筛选策略进行改进,以优化负荷概率区间预测模型,结果表明:(1)引入多目标算法对微电网短期负荷进行区间预测,避免惩罚函数选取的问题,同时可以计算出多个置信度下的预测区间.(2)通过逼近理想解排序策略、网格筛选策略方法对 MOABC 进行改进,寻优过程中具有更为良好的收敛性能、分布性能和动态性能.(3)本文提出的概率区间多目标预测方法能够有效对微电网负荷进行概率区间预测,可靠性高、准确性优,能够满足电力决策时的不确定性要求.

参考文献

- [1] 张永明,邓盛川,齐维贵. 局域支持向量回归与误差区间估计的概率预报方法及其应用研究[J]. 电子学报, 2010,38(01):190-194.
Zhang Yong-ming, Deng Sheng-chuan, Qi Wei-gui. Probabilistic prediction approach based on local support vector regression and interval estimation of its error [J]. Acta Electronica Sinica, 2010,38(01):190-194. (in Chinese)
- [2] 孙孝峰,吕庆秋. 低压微电网逆变器频率电压协调控制[J]. 电工技术学报, 2012,27(8):77-84.
Sun Xiao-feng, Lv Qin-qiu. Improved PV control of grid-connected inverter in low voltage micro-grid [J]. Transactions of China Electrotechnical Society, 2012,27(8):77-84. (in Chinese)
- [3] 鲁宗相,王彩霞,闵勇,等. 微电网研究综述[J]. 电力系统自动化, 2007,31(19):100-107.
Lu Zong-xiang, Wang Cai-xia, Min Yong, et al. Overview on microgrid research [J]. Automation of Electric Power Systems, 2007,31(19):100-107. (in Chinese)
- [4] 茆美琴,周松林,苏建徽. 基于风光联合概率分布的微电网概率潮流预测[J]. 电工技术学报, 2014,19(02):55-63.
Mao Mei-qin, Zhou Song-lin, Su Jianhui. Probabilistic power flow forecasting of microgrid based on joint probability distribution about wind and irradiance [J]. Transactions of China Electrotechnical Society, 2014,19(02):55-63. (in Chinese)
- [5] 陈益哲,张步涵,王江虹,等. 基于短期负荷预测的微网储能系统主动控制策略[J]. 电网技术, 2011,35(08):35-40.
Chen Yi-zhe, Zhang Bu-han, Wang Jiang-hong, et al. Active control strategy for microgrid energy storage system based on short-term load forecasting [J]. Power System Technology, 2011,35(08):35-40. (in Chinese)
- [6] 周念成,邓浩,王强钢,等. 光伏与微型燃气轮机混合微电网能量管理研究[J]. 电工技术学报, 2012,27(01):74-84.
Zhou Nian-cheng, Deng Hao, Wang Qianggang, et al. Energy management strategy of PV and micro-turbine hybrid micro-grid [J]. Transactions of China Electrotechnical Society, 2012,27(01):74-84. (in Chinese)
- [7] 刘小平,丁明,张颖媛,等. 微网系统的动态经济调度[J]. 中国电机工程学报, 2011,31(31):77-84.
Liu Xiao-ping, Ding Ming, Zhang Ying-yuan, et al. Dynamic economic dispatch for microgrids [J]. Proceedings of the CSEE, 2011,31(31):77-84. (in Chinese)
- [8] Amjady N, Keynia F, Zareipour H. Short-term load forecast of microgrids by a new bilevel prediction strategy [J]. IEEE Transactions on Smart Grid, 2010,1(3):286-294.
- [9] 刘念,张清鑫,刘海涛. 基于核函数极限学习机的微电网短期负荷预测方法[J]. 电工技术学报, 2015,30(08):218-224.
Liu Nian, Zhang Qing-xin, Liu Haitao. Online short-term load forecasting based on ELM with kernel algorithm in micro-grid environment [J]. Transactions of China Electrotechnical Society, 2015,30(08):218-224. (in Chinese)
- [10] 汤庆峰,刘念,张建华,等. 基于 EMD-KELM-EKF 与参数优选的用户侧微电网短期负荷预测方法[J]. 电网技术, 2014,38(10):2691-2699.
Tang Qing-feng, Liu Nian, Zhang Jian-hua, et al. A short-term load forecasting method for micro-grid based on EMD-KELM-EKF and parameter optimization [J]. Power System Technology, 2014,38(10):2691-2699. (in Chinese)
- [11] 陈民铀,朱博,徐瑞林,等. 基于混合智能技术的微电网剩余负荷超短期预测[J]. 电力自动化设备, 2012,32(05):13-18.
- [12] 万昆,柳瑞禹. 区间时间序列向量自回归模型在短期电力负荷预测中的应用[J]. 电网技术, 2012,36(11):77-81.
Wan Kun, Liu Rui-yu. Application of interval time-series vector autoregressive model in short-term load forecasting [J]. Power System Technology, 2012,36(11):77-81. (in Chinese)
- [13] 康重庆,夏清,张伯明. 电力系统负荷预测研究综述与发展方向的探讨[J]. 电力系统自动化, 2004,28(17):1-11.
- [14] 张弘,朱永佳,范磊磊,等. 基于马尔科夫修正的中长期电力负荷组合区间预测[J]. 华东电力, 2013,41(01):

- 33 - 36.
- Zhang Hong, Zhu Yong-jia, Fan Lei-lei, et al. Mid-long term load interval forecasting based on Markov modification[J]. East China Electric Power, 2013, 41(01): 33 - 36. (in Chinese)
- [15] 方仍存, 周建中. 应用聚类算法和混沌理论的短期负荷概率性区间预测[J]. 电网技术, 2010, 36(11): 65 - 69.
- Fang Reng-cun, Zhou Jian-zhong. Probabilistic interval forecasting of short-term load on the basis of clustering algorithm and chaos theory[J]. Power System Technology, 2010, 36(11): 65 - 69. (in Chinese)
- [16] Khosravi A, Nahavandi S, Creighton D, et al. Comprehensive review of neural network-based prediction intervals and new advances[J]. IEEE Transactions on Neural Networks, 2011, 22(9): 1341 - 1356.
- [17] Khosravi A, Nahavandi S, Creighton D, et al. Lower upper bound estimation method for construction of neural network-based prediction intervals[J]. IEEE Transactions on Neural Networks, 2011, 22(3): 337 - 346.
- [18] Quan H, Srinivasan D, Khosravi A. Short-term load and wind power forecasting using neural network-based prediction intervals[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(2): 303 - 315.
- [19] SI Yujing, LI Ta, PAN Jieli, YAN Yonghong. A prefix tree based n-best list re-scoring strategy for recurrent neural network language model[J]. Chinese Journal of Electronics, 2014, 23(1): 70 - 74.
- [20] Chen P A, Chang L C, Chang F J. Reinforced recurrent neural networks for multi-step-ahead flood forecasts[J]. Journal of Hydrology, 2013, 497: 71 - 79.
- [21] 陈杰, 沈艳霞, 陆欣. 基于信息反馈和改进适应度评价的人工蜂群算法[J]. 智能系统学报, 2016, 02: 172 - 179.
- Chen Jie, Shen Yan-xia, Lu Xin. Artificial bee colony algorithm based on information feedback and an improved fitness value evaluation[J]. CAAI Transactions on Intelligent Systems, 2016, 02: 172 - 179. (in Chinese)
- [22] 周黎, 周承恩, 李海滨. 寻求“理想”解的改进多目标粒子群优化算法[J]. 控制与决策, 2015, 30(09): 1653 - 1659.
- Zhou Li, Zhou Cheng-en, Li Hai-bin. Improved multi-objective particle swarm optimization algorithm that can give “ideal” solution[J]. Control and Decision, 2015, 30(09): 1653 - 1659. (in Chinese)
- [23] Chen J, Yang D. Constrained handling in multi-objective optimization based on quantum-behaved particle swarm optimization. [A]. International Conference on Natural Computation ICNC 2010 [C]. Yantai, Shandong, China, 2010. 3887 - 3891.
- [24] 高海兵, 高亮, 周驰, 等. 基于粒子群优化的神经网络训练算法研究[J]. 电子学报, 2004, 32(09): 1572 - 1574.
- Gao Hai-bing, Gao Liang, Zhou Chi, et al. Particle swarm optimization based algorithm for neural network learning [J]. Acta Electronica Sinica, 2004, 32(09): 1572 - 1574. (in Chinese)
- [25] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182 - 197.
- [26] Akbari R, Hedayatzadeh R, Ziarati K, et al. A multi-objective artificial bee colony algorithm[J]. Swarm & Evolutionary Computation, 2012, 2(1): 39 - 52.

作者简介



于昕妍 女, 1993 年生, 硕士研究生, 主要研究方向为智能优化算法、微电网能量管理。



沈艳霞 (通信作者) 女, 1973 年生, 教授、博士, 主要研究方向为群智能算法、风电系统优化、轻工装备智能制造等。

E-mail: shenyx@jiangnan.edu.cn