

- 中文核心期刊
- 中国科技核心期刊
- RCCSE中国核心学术期刊

ISSN 1671-6833


CN 41-1339/T

CODEN ZDXGAN

郑州大学学报

工 学 版

JOURNAL OF ZHENGZHOU UNIVERSITY
ENGINEERING SCIENCE



2019.5

第40卷 第5期

Vo1.40 No.5

2019年9月出版

ISSN 1671-6833



郑州大学学报

工 学 版

JOURNAL OF ZHENGZHOU UNIVERSITY
ENGINEERING SCIENCE

编 委 会

特邀编委:

申长雨(中国科学院院士)

何季麟(中国工程院院士)

张孟杰(新西兰惠灵顿维多利亚大学)

刘炯天(中国工程院院士)

金耀初(英国萨里大学)

Kay Chen Tan (香港城市大学)

编委会主任:

邵国胜(郑州大学)

编委(按姓氏笔画为序):

王 凌(清华大学)

王忠勇(郑州大学)

公茂果(西安电子科技大学)

叶国田(郑州大学)

刘国际(郑州大学)

刘春太(郑州大学)

许 群(郑州大学)

李 杰(同济大学)

吴泽宁(郑州大学)

张 涛(北京航空航天大学)

陈伟能(华南理工大学)

陈德良(郑州大学)

单崇新(郑州大学)

贾 瑜(郑州大学)

郭院成(郑州大学)

梁 静(郑州大学)

董 林(郑州大学)

臧双全(郑州大学)

王亚明(郑州大学)

王宗敏(中原工学院)

左其亭(郑州大学)

刘 波(中国科学院数学与系统科学研究院)

刘金盾(郑州大学)

关绍康(郑州大学)

麦立强(武汉理工大学)

李勇平(上海应用物理所)

张 冰(郑州大学)

张少军(郑州大学)

陈静波(郑州大学)

庞新厂(郑州大学)

赵明皞(郑州大学)

高丹盈(河南工程学院)

唐 珂(南方科技大学)

梁长浩(合肥物质科学院)

韩一帆(郑州大学)

潘复生(重庆大学)

目 次

启发式多目标优化算法在能源和电力系统中的典型应用综述	
..... 朱晓东, 王 颖, 杨之乐, 郭媛君(1)	
深度学习在电力负荷预测中的应用综述 ... 朱俊丞, 杨之乐, 郭媛君, 于坤杰, 张建康, 穆晓敏(12)	
人工智能在电力系统中的应用综述 马 民, 秦 佳, 杨东升, 周博文, 庞永恒, 汉焕英(22)	
蓄电池储能运行控制对有源配电网影响研究	李 雪, 宋彦龙(31)
基于 GRU 网络的配电网故障数量等级预测方法	高金峰, 庞 昊, 杜耀恒(38)
基于 Bi-RNN 的风电机组主轴承温度预警方法研究	
..... 尹 诗, 侯国莲, 于晓东, 李 宁, 王其乐, 弓林娟(44)	
基于灰狼优化算法的多源互联电力系统负荷频率控制	侯国莲, 郭雅迪, 弓林娟(51)
基于 IGA 的配电系统运行损耗与可靠性优化	
..... 樊一娜, 梁 伟, 黄渝清, 赵东初, 陈圣博, 李 明(58)	
分布式储能参与电压暂降补偿的优化配置与控制策略	
..... 马 兴, 李俊杰, 黎 博, 谢 巍, 高盟凯, 陈民铀(64)	
基于风电可调节不确定代价的风光柴储联合优化调度	
..... 薛金花, 王德顺, 郁正纲, 李 红, 朱信舜, 窦春霞(72)	
基于多分辨率卷积神经网络的火焰检测	黄文锋, 徐珊珊, 孙 焱, 周 兵(79)
基于 BP-RBF 神经网络的组合模型预测港口物流需求研究	蔡婉贞, 黄 翰(84)
一种前景提取的行人模式识别检测算法	杨忠明, 李子龙, 胡音文, 黄 翰, 蔡昭权(91)

CONTENTS

A Survey of Featured Applications of Heuristic Multi-objective Optimization Algorithms in Power and Energy Systems	
.....	ZHU Xiaodong, WANG Ying, YANG Zhile, GUO Yuanjun (1)
Deep Learning Applications in Power System Load Forecasting: a Survey	
.....	ZHU Juncheng, YANG Zhile, GUO Yuanjun, Yu Kunjie, ZHANG Jiangkang, MU xiaomin (12)
Review on the Application of Artificial Intelligence in Power Systems	
.....	MA Min, QIN Jia, YANG Dongsheng, ZHOU Bowen, PANG Yongheng, HAN Huanying (22)
Study on the Influence of Battery Energy Storage Operation Control on Active Distribution Network	
.....	LI Xue, SONG Yanlong (31)
A Method for Predicting the Number of Faults in Distribution Network Based on GRU Neural Network	
.....	GAO Jinfeng, PANG Hao, DU Yaoheng (38)
Research on Temperature Prediction Method for Main Bearing of Wind Turbine Based on Bi-RNN	
.....	YIN Shi, HOU Guolian, YU Xiaodong, LI Ning, WANG Qile, GONG Linjuan (44)
Load Frequency Control of Multi-source Power System Based on Grey Wolf Optimization	
.....	HOU Guolian, GUO Yadi, GONG Linjuan (51)
Loss and Reliability Optimization for Power Distribution System Operation on Improved Genetic Algorithms	
.....	FAN Yina, LIANG Wei, HUANG Yuqing, ZHAO Dongchu, CHEN Shengbo, LI Ming (58)
Optimal Allocation and Control Strategy of Distributed Energy Storage System for Compensating Voltage Sag	
.....	MA Xing, LI Junjie, LI Bo, XIE Wei, GAO Mengkai, CHEN Minyou (64)
A Dispatching Strategy for Isolated Island Micro-grid Based on Adjustable Wind Power Uncertain Cost	
.....	XUE Jinhua, WANG Deshun, YU Zhenggang, LI Hong, ZHU Xinshun, DOU Chunxia (72)
Fire Detection Based on Multi-resolution Convolution Neural Network	
.....	HUANG Wenfeng, XU Shanshan, SUN Yi, ZHOU Bing (79)
A Model Based on the Combination of BP and RBF Neural Network for Port Logistic Demand Forecasting	
.....	CAI Wanzhen, HUANG Han (84)
A Pedestrian Model Recognition Detection Algorithm Based on Foreground Extraction	
.....	YANG Zhongming, LI Zilong, HU Yinwen, HUANG Han, CAI Zhaoquan (91)

文章编号: 1671-6833(2019)05-0001-12

启发式多目标优化算法在能源和电力系统中的 典型应用综述

朱晓东¹, 王颖¹, 杨之乐², 郭媛君²

(1. 郑州大学 电气工程学院, 河南 郑州 450001; 2. 中国科学院 深圳先进技术研究院, 广东 深圳 518000)

摘要: 能源与电力系统是现代社会人类生存和发展的基础, 在发电、热转换等能源传输和转化过程中存在着极大的低效和浪费, 造成日益严重的环境污染与资源消耗. 针对能源电力系统中的经济性、环保性及社会友好性等多个目标进行全面、综合的优化设计和运行调度, 是创造低碳智慧能源的必要途径. 基于启发式多目标优化算法具有灵活性高、适用范围广、求解效率高等特点, 经过数十年的发展, 现已成为工程优化领域的重要求解工具. 本文旨在系统地整理启发式多目标优化算法在求解电力和能源系统中典型问题的应用, 重点对6个典型问题的求解应用进行探讨、分析, 结合现阶段存在的问题, 指出该领域未来亟待研究和探索的方向.

关键词: 多目标优化; 电力系统; 能源系统; 帕累托最优解; 启发式优化算法

中图分类号: TU528.1

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.010

0 引言

能源和电力系统作为现代化国家生存发展的支柱和动力, 与社会经济高速稳定运行、生态环境可持续发展息息相关. 由于电力系统规模大、分布范围广、参与对象多, 致使该系统极其复杂, 具有高度的非线性和耦合性, 系统成本控制和经济性运行优化也变得非常困难^[1]. 另一方面, 基于化石能源的火力发电占比很高, 其大量能耗所造成的空气污染和碳排放严重威胁着全球气候状态和局部生态环境^[2]. 针对能源和电力系统的设计和运行, 提供高效灵活的优化工具, 对降低复杂能源系统运营成本、合理优化资源配置、控制环境影响因素等多个方面都具有重要意义. 考虑能源电力系统的规模和基数, 极小比例的性能优化与提高所创造的价值都是极为显著的.

在复杂庞大的电力能源系统中, 诸多典型复杂的多目标优化问题都还未得到有效解决, 大规模电力系统调度是其中一类较有代表性的应用问

题. 电力系统调度的优化是在若干个现实物理对象的运行约束条件下, 实现整个系统所需要的总费用、消耗能源总量及对环境产生的影响等多个目标的最优化. 电力系统的优化问题早在20世纪后期就已受到学术界的关注^[3]. 根据优化层次和时间尺度不同, 电力系统调度任务包括经济负荷分配 (economic load dispatch, ELD)、机组组合 (unit commitment, UC)、最优潮流 (optimal power flow, OPF)、分布式发电选址与定容 (optimal site and sizing of DG) 等4个不同时间尺度和运行状态下的优化问题. 文献[4-5]针对常见的进化算法在经济负荷与环境问题上的应用做了概述, 介绍了启发式算法在经济负荷分配优化中的优势. 文献[6-7]以及文献[8-9]分别对经济负荷调度和潮流分析中的优化方法进行了概述, 并指出其对于电力系统优化的意义. 随着可再生能源等高随机性对象的加入, 文献[10-11]对机组组合问题采用随机建模方法, 提出了相应的优化工具并进行最优求解. 除电力系统调度外, 其他能源应用

收稿日期: 2018-10-15; 修订日期: 2018-12-11

基金项目: 国家自然科学基金资助项目(51607177、61876169、61433012、U1435215); 国家博士后科学基金面上项目(2018M631005); 广东省自然科学基金博士启动项目(2018A030310671)

作者简介: 朱晓东(1970—), 男, 河南郑州人, 郑州大学副教授, 主要从事智能控制及智能信息处理方面的研究, E-mail: zhu_xd@zzu.edu.cn.

通信作者: 杨之乐(1987—), 男, 河南郑州人, 中国科学院深圳先进技术研究院助理研究员, 主要从事神经网络、进化计算等人工智能方法在能源及电力系统中的应用, E-mail: zl.yang@siat.ac.cn.

系统也普遍存在一些典型的多目标复杂优化问题,如混合动力汽车(hybrid electric vehicle, HEV)的能源管理同样存在着多种运行目标需要平衡和优化的问题.文献[13-14]概述了 HEV 的整车能量控制问题,针对 HEV 中的能源管理策略优化进行了全面探究.此外,具有混合整数复杂优化特点的换热器设计,也是能源领域典型的多目标优化问题^[15],得到了广泛的关注和应用尝试.

在能源和电力系统的多目标优化应用中,传统方法多是将其采用加权或者线性规划等方法转化为单目标优化问题,权重选择较为困难,对于实际工程中存在多个冲突目标的问题无法得到有效解决.随着启发式算法的不断发展以及在多目标优化问题上的成功应用,大量多目标优化算法应用于能源和电力系统中.笔者首先简要介绍了启发式多目标算法;随后,针对 6 个典型能源和电力系统多目标问题的求解应用进行了分析和综述;最后,结合现阶段存在的问题,指出该领域未来亟待研究和探索的方向.

1 启发式多目标优化算法概述

启发式算法又称为智能优化算法,在 20 世纪 80 年代末期开始发展,在迭代随机寻优的算法框架结构基础上,根据自然界和生活中常见的现象来构造算法逻辑,求解一个或者多个目标组合的最优值问题.早期出现的启发式算法主要有 1975 年提出的遗传算法(GA)^[16]、1995 年提出的粒子群优化算法(PSO)^[17]、差分进化算法(DE)^[18]以及近期提出的教学优化算法(TLBO)^[19]等,这些算法多数用来解决单目标问题,能实现优化的目标仅为一个.

多目标优化问题(Multi-objective optimization problems, MOP),构造多于一个且常常相互矛盾的优化目标,如式(1)所示:

$$\begin{aligned} \min y = f(x) &= [f_1(x) \quad f_2(x) \quad \cdots \quad f_n(x)] \\ n &= 1, 2, \cdots, N \\ g_i(x) &\leq 0, i = 1, 2, \cdots, k \\ h_j(x) &= 0, j = 1, 2, \cdots, k \\ x &= [x_1 \quad x_2 \quad \cdots \quad x_d \quad \cdots \quad x_D] \\ x_{d_{\min}} &\leq x_d \leq x_{d_{\max}}, d = 1, 2, \cdots, D. \quad (1) \end{aligned}$$

式中: N 为优化的目标个数; D 为决策变量的维度; $g_i(x)$ 、 $h_j(x)$ 为约束条件.

对于工程中的多目标问题,传统算法并不能有效进行求解,为了解决相互冲突或者相互影响的多目标问题,出现了启发式多目标优化算法.

1985 年提出的矢量评价遗传算法(VEGA)^[20],首次采用启发式算法解决含 MOP 的相关问题.随后,出现了一些在遗传算法框架基础上的 MOP 改进算法,如 MOGA^[21]、NPGA^[22]等.追溯启发式多目标优化算法的发展历程,可以将其分为两个阶段:第一阶段主要分为不基于 Pareto 优化和基于 Pareto 优化两部分;第二阶段是在第一阶段的基础上提出外部集的概念,对最优解较好的分布性做出改进.笔者对这两个阶段的发展进行简要回顾.

1.1 Pareto 相关算法

在基于 Pareto 优化的方法中,工程应用上较为典型的算法为 Deb 等人提出的基于非支配排序的遗传算法系列^[23](NSGA).

Deb 等^[24]在 1994 年根据 Goldberg 的建议,采用非支配排序的方法将种群进行排序,然后与遗传算法相结合,同时采用小生境和形态学方法进行最优个体选择,以此寻找多个 Pareto 最优点.该方法的优势在于最优解分布均匀,但是又存在计算效率较低、复杂度较高并缺少精英机制的缺陷.随后 Deb 等针对 NSGA 算法的这一缺陷对其进行改进,提出 NSGA-II 算法^[25],在原算法的基础上提出了拥挤度比较算子,在同一非支配层对个体进行拥挤度比较,选择拥挤度较大的个体,并引进精英策略,扩大采样空间,有效提高了寻找最优解的能力和算法速度,同时保存了种群的多样性,减少算法复杂度.NSGA-II 虽然有了很大的改进,但对于 3 个及 3 个以上目标进行优化时并不完全适用,针对超多目标的情况,他们提出了 NSGA-III 算法^[26-27].采用基于参考点的方法,结合 NSGA-II 框架,在选择最优个体时采用关联和小生境技术,能够有效地实现 3~15 个目标优化,并得到较好的 Pareto 解.一些算法在解决实际工程中的多目标优化问题有显著的优势,同时得到了业界的肯定.

另外一类算法是不基于 Pareto 优化的方法,较为典型的是 2007 年由张青富等提出的基于分解的多目标优化方法(MOEA/D)^[28].该方法采用标量化的思想,将多目标问题分解为多个标量子问题,并对各个子问题根据其相邻子问题进行同步优化,进而求出最优解.该方法在求解效率和精度上具有优势,已成为最具代表性的启发式多目标算法^[29].该算法在低维目标情况下,相比 NSGA-II 算法在时间复杂度、均匀性以及收敛性上优势突出;在某些高维度情况下其均匀性差于

NSGA-II.

1.2 基于外部集相关算法

智能优化算法发展的第二个阶段引入了外部集的概念,用来保存当代所有的非支配个体,保证寻找的 Pareto 解分布均匀,保持了种群的多样性.这一阶段提出的算法较多,常见的有文献[30]提出的强度帕累托进化算法(SPEA),在已有优化算法的基础上采用外部集合来存储非支配解,并根据个体的外部非支配点数量来评估适应性,同时结合聚类方法来控制非支配集的大小,因此可以保证选择阶段搜索的效率.随后,该课题组基于一种新的粒度分配策略针对 SPEA 算法存在的适应度分配不精确和多样性差的问题进行改进,结合密度估计方法和增强存档截断方法,提出了 SPEA-II 算法^[31],有效地加快了算法的收敛速度,增强了 Pareto 最优解的分布均匀性.此外,文献[32]提出的帕累托存档演化策略(PAES)也是一种采用外部集的方法,该算法被视为由一个 1+1 策略和一个外部存档方案构成,是相对简单的 MOEA 方法,在工程应用中有很好的表现.因其没有进化算法的交叉和选择步骤,同时结合归档法,使得算法在时间复杂度上明显少于其他算法.上述主流多目标优化算法在 Web of Science 数据库中的文献引用量如图 1 所示.




图1 主流多目标优化算法引用量

Fig.1 Citation times of key multi-objective optimization algorithms

2 启发式多目标优化算法在能源和电力系统中的典型应用

对于能源与电力系统,在多个时间尺度、规模和运行要求下对应不同的复杂系统多目标优化问题,包括经济负荷分配、机组组合、潮流优化、分布式发电选址与定容以及换热器设计和能源调度等复杂应用.采用启发式多目标优化方法对上述问题进行优化求解,可为大规模能源电力系统提供有效的优化工具,显著提升系统的经济性和环境友好性,因此得到了学术界的广泛关注.近年来,

以上 6 种典型应用多目标优化方法在 Web of Science 数据库的相关文章数量统计如图 2 所示.笔者将对主流优化算法在能源及电力系统中的典型优化问题进行概述和分析.




图2 典型能源与电力系统多目标优化应用的文章数据统计

Fig.2 The statistics of article for typical multi-objective applications in power and energy systems

2.1 经济负荷分配

在电力系统优化调度中,运行经济性指标是其中首要的考虑因素,而环境因素的重要性也日益突出.因此,多目标经济负荷分配问题是在满足系统负荷和运行约束等条件下,实现总发电成本以及总排放量或者燃料成本最优^[33].此类问题含有非线性、非凸和强约束等特点,如同时考虑阀点效应的含有不可导和多峰值等特性,将成为一种典型非线性组合优化问题.针对此类问题,文献[34]提出了多目标的教学优化算法(MOTLBO)与非支配排序法相结合,将燃料成本和排放两个冲突的目标在一定约束条件下优化,有效解决了最优经济调度和最小排放调度问题.此外,针对多目标优化问题,对已有多目标 PSO 算法进行改进也是一种行之有效的方法,文献[35-36]提出了 MOPSO 算法结合模糊自适应技术和自学习策略,文献[37]提出带有目标权重导向的 MOPSO 算法,这些方法均能够在有效的约束条件下找到最优调度解.文献[38]考虑在电力系统中加入风能,并且考虑充放电行为的强约束,将经济与排放作为优化目标,采用 PSO 和 TLBO 相结合的方法实现最优调度.文献[39]对 BBO 算法进行改进,提出了基于对立的 BBO 算法,实现了 NO_x 、 SO_x 等排放最小化和经济最优化.文献[40]将经济排放负荷调度问题转为一个约束动态多目标问题,采用非支配排序和记忆选择策略,提出了动态非支配排序的多目标生物地理优化方法

(Dy-NSBBO). 另外有学者提出将裸骨教学优化 BBTLBO 算法与 BBO 算法结合^[41], 将功率分配、燃料成本和排放作为目标进行优化. 文献[42]提出小生境遗传禁忌搜索混合算法, 应用于多目标负荷分配中. 常见的 NSGA-II 算法也被应用到调度优化问题中^[43], 将经济排放调度问题作为竞争不可补偿的目标进行优化, 有效地解决了非线性约束优化问题.

2.2 机组组合

随着用电需求的快速增加以及明显存在的峰谷效应, 对电力系统机组状态进行及时调整, 实现供需平衡和发电资源的合理利用对电力系统的经济性和综合效益极为重要. 机组组合优化问题在经济调度的基础上, 需要通过机组的启停调度, 在系统负荷需求和发电能力需求等约束条件下, 实现机组排放量以及发电总费用或者燃料成本等目标达到最优^[44]. 由于二进制开关变量融入了约束条件及目标函数特点, 多目标机组组合优化问题又被认为是多约束的非线性混合整数规划问题. 为有效求解该类问题, 文献[45]将机组的排放和运行费用作为目标, 将模拟进化算法和 NSGA-II 算法结合, 采用局部搜索策略, 运用加权和 λ 迭代法进行优化, 从而对机组运行状态进行控制. 文献[46]对人工蜂群算法 ABC 进行改进, 提出模糊二进制实数编码的人工蜂群算法, 将其应用于系统可靠性、燃料成本和排放的优化问题中, 在机组组合优化中表现良好. 还有学者将 MOEA/D 算法与 DE 算法结合^[47] 提出新的非均匀权向量 (NUWD) 分布策略, 三者进行集成, 在机组组合优化问题中得到了较好的应用效果. 文献[48]将用户能源最小化和系统稳定最大化作为机组组合优化目标, 提出了字典排序的多目标优化方法. 文献[49-50]对 PSO 进行改进, 将所提出的 CPSO 和 MOPSO 算法应用到非线性机组模型中, 实现多目标优化. 文献[51]提出了多目标量子启发二进制粒子群算法 (QBPSO), 将风力的随机性和不可控性因素考虑在内, 同时以成本和排放作为目标函数, 采用原-对偶内点法来解决机组组合中的调度问题. 此外, 有学者采用基于最优偏差的萤火虫算法调整模糊度隶属函数, 实现燃料成本和系统可靠性的多目标机组组合最优^[52].

2.3 潮流优化

潮流优化是电力系统短时调度平衡的重要问题, 其目标是在满足各种安全性约束的条件下, 求解最优的瞬时有功、无功功率, 实现网络损耗、燃

料成本、排放最小化等最优要求^[53]. 由于该类优化问题中的有功无功分量常伴有三角函数形式的向量, 呈现强非凸非线性的特点, 被认为是典型的 NP-hard 问题. 文献[54]针对此类问题, 对 TLBO 算法进行改进, 引入自适应小波变异策略与模糊聚类技术, 使系统的总成本和排放量最小. 文献[55]对 PSO 算法进行改进, 提出了混沌队列方法, 并且采用自适应概念调整 PSO 参数中的 IPSO, 实现电压稳定与成本、损耗等目标的最优化求解. 另外, 将多目标 PSO 算法与其他元启发式算法相结合, 也是一种有效的求解途径. 文献[56]提出一种将 MIPSO 和 TLBO 相结合具有鲁棒性的方法; 文献[57]将混合 PSO 算法与人工物理优化 (APO) 算法相结合, 提出 HPSO-APO 算法, 在实际潮流优化中具有较好的表现. 文献[58]提出了拟对立修正的 Jaya 方法 (QOJaya), 采用拟对立学习的智能策略, 同时引入模糊策略和外部精英库保存方法, 实现潮流最优. 文献[59]对蛙跳算法进行改进, 提出混合蛙跳算法 (MSLFA), 并将其应用于潮流优化中, 有效避免了陷入局部最优的问题. 另有研究将多目标和声搜索算法 (MOHS)^[60] 与快速非支配排序法和拥挤度距离相结合, 采用模糊机制能够得到真实且分布均匀的帕累托解集. 文献[61]对人工蜂群算法 (ABC) 进行改进, 提出了模糊的修正人工蜂群 (MABC), 能够在具有离散变量和连续变量的离散潮流中实现总实际功率损耗和电压偏差及损耗等目标的最优.

部分关于经济负荷分配 (ELD)、机组组合 (UC) 和潮流优化 (OPF) 的相关优化算法文献总结如表 1 所示.

2.4 分布式发电选址与定容

分布式发电是消纳局部新能源、减小线路损耗、提高电力系统灵活性的有效途径. 分布式电源的位置和容量对节点电压、线路潮流和可靠性均会产生影响, 科学有效地对其进行优化配置, 是保证分布式发电合理性的必要手段. 由于分布式电源 (DG) 具有间歇性和随机性的特点, 在实现电压偏差、功率及成本优化时, 需要考虑的约束条件较多, 且多数为强非线性^[62], 故该优化问题被认为是多约束多目标的非线性非连续规划问题. 文献[63]中采用综合多目标优化方法, 将 NSGA-II 算法与点估计方法 PEM 结合, 以总成本和总网络损耗以及客户的停电成本作为优化目标, 达到了预期效果. 文献[64]对 NSGA-II 算法进行改进, 为了增强全局最

表1 ELD、UC 及 OPF 相关优化算法
Tab.1 Optimization algorithm of ELD、UC and OPF

作者、参考文献	时间	优化算法(改进策略)	优化目标	应用
Basu 等 ^[43]	2008	NSGA-II	经济、燃料排放量	ELD
Rout 等 ^[34]	2011	MOTLBO(结合非支配排序算法)	燃料成本、燃料排放量	ELD
Cheng 等 ^[38]	2018	PSO-TLBO	总成本、燃料排放量	ELD
Bahmani 等 ^[35]	2013	MOPSO(结合模糊自适应策略)	总发电成本、燃料排放	ELD
李整等 ^[37]	2015	MOPSO(目标权重导向策略)	动态经济、燃料排放量	ELD
Lokeshgupta 等 ^[36]	2018	MOPSO	节能、减排	ELD
Bhattacharya 等 ^[39]	2011	对立的 BBO 算法(结合对立学习和 BBO 的迁徙学习)	NOX、SOX 的排放量、经济最优	ELD
Ma 等 ^[40]	2017	Dy-NSBBO(动态非支配排序的多目标生物地理优化)	燃料成本、燃料排放量	ELD
Ghoshal 等 ^[41]	2017	BBO-BBOTLBO	总发电成本、燃料排放量	ELD
汪佳等 ^[42]	2013	小生境遗传禁忌搜索混合算法	发电成本、污染排放、负荷调整	ELD
Salani ^[48]	2011	字典多目标优化算法	系统稳定性、用户能源	UC
Li 等 ^[45]	2013	模因进化算法(结合 NSGA-II)	机组污染物排放量、运行费用	UC
Simon 等 ^[52]	2013	基于最优偏差的萤火虫算法(调整模糊度隶属函数)	燃料成本、系统可靠性	UC
Simon 等 ^[46]	2015	模糊二进制实数编码的人工蜂群算法	燃料成本、排放量、系统可靠性	UC
Trivedi 等 ^[47]	2015	MOEA/D-DE(采用非均匀权向量)	最低成本、排放量	UC
Wu 等 ^[51]	2013	QBPSO	成本、排放量	UC
Shukla 等 ^[49]	2016	CPSO(采用带伪码加权改进)	成本最低、排放量	UC
Wang 等 ^[50]	2017	MOPSO	成本、系统可靠性、排放量	UC
Swarupde 等 ^[60]	2011	MOHS(结合非支配排序)	燃料成本、损失、电压稳定性指数	OPF
Niknam 等 ^[59]	2011	MSLFA	经济成本、排放量	OPF
Khorsandi 等 ^[61]	2013	MABC	实际功率损耗、电压偏差、总排放	OPF
Niknam 等 ^[55]	2012	PSO(采用混沌对列方法)	电压稳定性、成本损耗	OPF
Seifi 等 ^[54]	2014	TLBO(引进自适应小波变异策略)	总成本、排放量	OPF
Sahu 等 ^[56]	2017	MIPSO-TLBO	燃料成本、有源功率损耗、电压偏差	OPF
Teeparthi 等 ^[57]	2017	HPSO-APO	总成本、有功损耗、安全指标	OPF
Warid 等 ^[58]	2018	QOJaya(采用外部精英库保存策略)	燃料成本、实际功率损耗、电压稳定性指数	OPF

优搜索能力,引入了 DE 算法中的变异重组策略,提出 INSGA-II 算法,并采用分层聚类方法和改进的排序策略,在给定的目标条件下,该算法能够保持种群的多样性,并且得到了最优帕累托解集. MOEA/D 算法在分布式发电的选址和定容优化上也取得了较好的应用效果^[65],实现了分布式发电机(DGS)和并联电容有功和无功损耗的同步优化,达到了最优化选择 DGS 的规模和位置.文献[66]对蛙跳算法进行改进,提出洗牌蛙跳优化方法,并应用于 DGS 的选址和定容,以实际功率损耗和成本为优化目标,达到了理想的效果.文献[67]提出了 Pareto-front 非支配排序多目标粒子群优化算法(PFNDMOPSO),该方法在帕累托最优集中得到目标函数的数值输出结果,然后采用模糊决策模型选择出最终的解决方案,已在径向电网 DG 中得到应用.其他一些改进的启发式算法在 DG 选址和定容优化上也有应用,如帕累托前沿差分进化算法(PFDE)^[68].改进的协调搜索算法(IMOHS)^[69]以及改进的 PSO 算法^[70].另外一些组合类的优化方

法,如文献[71]提出的 GA 和 PSO 组合的方法、文献[72]提出的 GA 和帝国主义竞争算法(ICA)组合方法等都可实现 DG 选址和定容中的优化目标要求.该应用的相关算法及优化目标如表 2 所示.

2.5 换热器设计

换热器是一种对流传热及热传导的工业装置,是能源应用系统的典型组成部件.它能够使热量从热流体传递到冷流体,常用的换热器有管翅式和板翅式两种.管翅式换热器芯体为椭圆铝管和曲形铝带的间隔分布,流体通过椭圆铝管时散热,散热效率较高,体积较小;板翅式芯体为铝板通道和直角形波浪铝带的间隔分布,结构强度较高.对换热器进行设计优化,可有效提高换热效率及产品效能,同时节省成本、提高使用寿命^[73].已有相当数量的启发式多目标优化工具被用于求解换热器相关约束非线性规划问题.

文献[74-75]采用多目标 TLBO 算法将材料成本、效率、总压降等作为目标,对板翅式散热器进行优化设计,提高性能.文献[76]基于杜鹃的繁

表 2 DG 选址与定容相关优化算法

Tab.2 Optimization algorithms of optimal site and sizing for DG

作者、参考文献	时间	优化算法(改进策略)	优化目标	应用
Moradi 等 ^[71]	2010	GA-PSO	网络损耗、电压稳定性	DG 选址与定容
Yammani 等 ^[66]	2012	洗牌蛙跳算法	实际功率损耗、总成本	DG 选址与定容
Nekoei 等 ^[69]	2013	IMOHs	功率损耗、电压平衡	DG 选址与定容
Moradi 等 ^[72]	2014	GA-ICA	电压损耗、电压稳定性指数、平衡负荷	DG 选址与定容
Moradi 等 ^[68]	2014	PFDE	电压稳定性、功率损耗、网络电压变化	DG 选址与定容
Hosseini 等 ^[63]	2013	NSGA-II(结合 PEM)	总成本、总网络损耗、客户停电成本	DG 选址与定容
Sheng 等 ^[64]	2015	NSGA-II(引入 DE 中变异重组策略)	最小线损、最小电压成本、最大电压稳定裕度	DG 选址与定容
Mahesh 等 ^[67]	2016	PFNDMOPSO	功率损耗、电压稳定性	DG 选址与定容
Kaur 等 ^[70]	2017	PSO(采用模糊决策方法)	有功损耗、无功损耗、电压偏差	DG 选址与定容
Biswas 等 ^[65]	2017	MOEA/D	有功损耗、无功损耗	DG 选址与定容

殖行为提出多目标杜鹃搜索算法(IMOC)解决换热器中的优化问题,该算法能够以较高的精度、较低的不可逆性和较少的迭代次数获得优化目标的最优解.文献[77]采用 NSGA-II 算法和 ε -NTU 方法进行热力学建模,对含有连续变量和离散变量的目标进行优化,得到理想的帕累托最优解.文献[78]采用多目标遗传算法与 Kriging 响应面相结合,首先优化翅片高度、间距等参数,其次对总热流量和年度费用进行优化,取得了较好的结果.改进的 TLBO 算法在换热器优化设计中也取得了很好的应用,文献[79]采用改进的 TLBO 算法对换热器的效率和总成本进行优化;文献[80]提出的 MO-TLBO 方法提高了原有的搜索和开发能力,采用基于网格方法自适应评估外部归档中的非支配解决方案,进而实现设计中的多目标优化.文献[81]提出一种新的混合优化方法,将 PSO 和蜂群算法 BA 混合提出 BAHPSO 算法,在板翅式换热器设计中进行验证,证明了其准确性和有效性.

2.6 混合动力汽车能源管理策略

在政策刺激和科技快速进步的推动下,混合动力汽车(HEV)得到迅猛发展.因其多种能源供给所带来的经济性、舒适性和环境影响度的平衡策略选择问题,以及 HEV 中替代能源与内燃机(ICE)之间的功率分配问题,燃油量与排放量最小问题^[82]始终是困扰 HEV 厂商的主要难题.对 HEV 实施能源管理策略的多目标优化,可以显著提高混合动力汽车的性能,改善驾驶舒适感,提高燃油经济性并降低对环境的影响程度.

为了解决这类多目标约束非线性问题,在 2011 年,有学者提出了多目标自适应差分进化算法(MOSADE)^[83],采用外部精英归档方法保留非支配解,结合归一化最近邻距离的比较截断算子,有效解决了 HEV 燃料消耗和排放优化问题.文献

[84]采用 NSGA-II 算法对 HC、CO、NO_x 的排放与经济性 4 个目标同时进行优化,将 3 个部件的尺寸作为参数一起处理,实验表明该方法得到的帕累托最优解较为理想.另外,文献[85-86]采用 NSGA-II 算法对混合储能系统中的总成本、电池容量损失和部件尺寸等冲突性目标进行优化,得出的实验结果表明,该方法对于提高 HEV 的性能和降低成本有明显的帮助.PSO 算法的变体也在 HEV 能源管理策略方面取得了较好的应用,文献[87]提出了基于帕累托的多目标粒子群算法(PMOPSO),利用拥挤度距离概念来确定粒子的全局最优,有效解决了车辆成本和燃料消耗的优化问题.文献[88]提出基于 PSO 的综合性方法,将尾气排放、成本、燃油消耗多目标问题进行转化,采用 PSO 算法进行优化,通过实验证明了算法的有效性.对于 GA 进行改进,如基于多目标的遗传算法^[89]和自适应的遗传算法^[90]以及早期出现的 MOGA 算法^[91]均能够应用到能源管理策略中,实现控制参数、成本、燃油以及排放等问题的优化,有效提高混合动力汽车的性能.应用于换热器设计以及 HEV 能量管理策略中的相关算法及优化目标总结如表 3 所示.

3 结论及展望

能源和电力系统在国民经济中占据着重要地位,其日益突出的高耗能、高排放等问题期待更灵活有效的解决方法.智能启发式多目标优化方法已在能源与电力系统的系统和局部优化问题中得到了大量成功的应用,对系统的整体经济性能、环境友好性等方面都产生了积极影响.笔者首先对主流多目标优化算法进行了简要回顾,接着概括了能源和电力系统中不同层级的 6 个典型问题,包括经济负荷分配、机组组合、潮流优化、分布

表3 换热器设计与能源管理相关优化算法

Tab.3 Optimization algorithms for heat exchanger design and HEV powertrain management

作者、参考文献	时间	优化算法(改进策略)	优化目标	应用
Sanaye 等 ^[78]	2010	NSGA-II	效率、总成本	换热器设计
Rao 等 ^[76]	2013	TLBO(采用自适应教学因素)	效率、总成本	换热器设计
Rao 等 ^[74]	2015	MOTLBO	熵产生率、材料成本	换热器设计
Hajabollahi 等 ^[75]	2017	MOTLBO	效率、容积、总压降	换热器设计
Patel 等 ^[80]	2014	MO-ITLBO	总成本、总重量	换热器设计
Wang 等 ^[77]	2015	IMOC	效率、年度成本、泵浦功率	换热器设计
Wen 等 ^[79]	2016	MOGA(结合 Kriging 响应面)	总热流量、年度费用	换热器设计
Zarea 等 ^[81]	2018	BAHPSO	有效性、总年度成本	换热器设计
Poursamad 等 ^[90]	2006	GA(添加惩罚策略)	燃料消耗、排放量	HEV 能源管理策略
Fang 等 ^[89]	2006	MOGA	排放量、动力传动系数	HEV 能源管理策略
Huang 等 ^[91]	2007	MOGA	燃油消耗、排放量	HEV 能源管理策略
Wu 等 ^[88]	2008	综合 PSO	尾气排放、成本、燃油消耗	HEV 能源管理策略
Geng 等 ^[87]	2014	PMOPSO	车辆成本、燃油消耗	HEV 能源管理策略
Hu 等 ^[84]	2004	NSGA-II	HC、NO _x 、CO 排放量、总成本	HEV 能源管理策略
Buerger 等 ^[86]	2011	NSGA-II	燃料消耗、部件尺寸	HEV 能源管理策略
Song 等 ^[85]	2014	NSGA-II	总成本、容量损失	HEV 能源管理策略
Wu 等 ^[83]	2011	MOSADE(引进外部精英归档方法)	燃料消耗、排放量	HEV 能源管理策略

式发电选址与定容、换热器设计以及混合动力汽车能源管理策略,最后文章对各种多目标优化算法在相关典型问题上的应用做了综述回顾。

尽管已有大量的成功应用,启发式多目标算法在能源和电力领域的应用仍刚刚起步。在能源互联网和综合能源系统大发展的背景下,大量间歇性可再生能源以及多种能源形式的互联对传统的能源电力系统都提出了全新的挑战。启发式多目标优化算法也在不断发展,面向高维多目标、组合优化多目标等复杂问题的启发式新算法和新思路正不断涌现,这些新算法有望为能源和电力系统的优化应用问题提供更有力的求解工具并在更复杂、更贴近实际的多目标优化问题中取得更显著的应用效果。

参考文献:

- [1] KOTHARI D P. Power system optimization [C]//Computational Intelligence and Signal Processing (CISP), 2012 2nd National Conference on. IEEE, 2012: 18-21.
- [2] LIU Y, LI R, SONG X. Analysis of coupling degrees of urbanization and ecological environment in China [J]. Journal of natural resources, 2005, 20(1): 105-112.
- [3] 章美丹. 电力系统优化运行的相关问题研究 [D]. 杭州: 浙江大学, 2013.
- [4] 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.
- [5] PANIGRAHI T K, SAHOO A K, BEHERA A. A review on application of various heuristic techniques to combined economic and emission dispatch in a modern power system scenario [J]. Energy Procedia, 2017, 138: 458-463.
- [6] 李彩华, 郭志忠, 樊爱军. 电力系统优化调度概述 (I): 经济调度与最优潮流 [J]. 电力系统及其自动化学报, 2002, 14(2): 60-63.
- [7] HUNECAULT M, GALIANA F D. A survey of the optimal power flow literature [J]. IEEE transactions on Power Systems, 1991, 6(2): 762-770.
- [8] 肖俊明, 周谦, 瞿博阳, 等. 多目标进化算法及其在电力环境经济调度中的应用综述 [J]. 郑州大学学报(工学版), 2016, 37(2): 1-9.
- [9] 叶承晋, 黄民翔. 考虑暂态稳定性的多目标最优潮流 [J]. 中国电机工程学报, 2013, 33(10): 137-144.
- [10] ZHENG Q P, WANG J, LIU A L. Stochastic optimization for unit commitment—a review [J]. IEEE Transactions on Power Systems, 2015, 30(4): 1913-1924.
- [11] 张晓花, 赵晋泉, 陈星莺. 节能减排多目标机组组合问题的模糊建模及优化 [J]. 中国电机工程学报, 2010(22): 71-76.
- [12] 罗禹贡, 陈涛, 李志强. 智能混合动力电动轿车整车控制系统 [J]. 清华大学学报(自然科学版), 2010(8): 1271-1276.
- [13] 吴剑. 并联式混合动力汽车能量管理策略优化研究 [D]. 济南: 山东大学, 2008.
- [14] YANG Z, LI K, FOLEY A. Computational scheduling methods for integrating plug-in electric vehicles with power systems: A review [J]. Renewable & Sustainable Energy Reviews, 2015, 51: 396-416.

- [15] WANG Z, LI Y. Layer pattern thermal design and optimization for multistream plate-fin heat exchangers—A review [J]. *Renewable and Sustainable Energy Reviews*, 2016, 53: 500–514.
- [16] HOLLAND J H. *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence* [M]. MIT press, 1992.
- [17] EBERHART R, KENNEDY J. A new optimizer using particle swarm theory [C]//*Proceedings of the Sixth International Symposium on Micro Machine and Human Science*. IEEE, 2002: 39–43.
- [18] DAS S, SUGANTHAN P N. Differential evolution: a survey of the state-of-the-art [J]. *IEEE Transactions on Evolutionary Computation*, 2011, 15(1): 4–31.
- [19] RAO R. Review of applications of TLBO algorithm and a tutorial for beginners to solve the unconstrained and constrained optimization problems [J]. *Decision Science Letters*, 2016, 5(1): 1–30.
- [20] SCHAFER J D. Multiple objective optimization with vector evaluated genetic algorithms [C]//*Proceedings of the First International Conference on Genetic Algorithms and Their Applications*, Lawrence Erlbaum Associates. Inc., Publishers, 1985.
- [21] MURATA T, ISHIBUCHI H. MOGA: multi-objective genetic algorithms [C]//*Evolutionary Computation*, 1995., IEEE International Conference on. IEEE, 1995: 289.
- [22] HORN J, NAFPLIOTIS N, GOLDBERG D E. A Niched Pareto Genetic Algorithm for Multiobjective Optimization [M]//*A niched Pareto genetic algorithm for multiobjective optimization*. 1994.
- [23] DEB K, AGRAWAL S, PRATAP A, et al. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II [C]//*International Conference on Parallel Problem Solving From Nature*. Springer, Berlin, Heidelberg, 2000: 849–858.
- [24] SRINIVAS N, DEB K. Multiobjective optimization using nondominated sorting in genetic algorithms [J]. *Evolutionary Computation*, 1994, 2(3): 221–248.
- [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] DEB K, JAIN H. An evolutionary many-objective optimization algorithm using reference-point-based non-dominated sorting approach, part I: solving problems with box constraints [J]. *IEEE Transactions on Evolutionary Computation*, 2014, 18(4): 577–601.
- [27] JAIN H, DEB K. An Evolutionary Many-objective optimization algorithm using reference-point based non-dominated sorting approach, part II: handling constraints and extending to an adaptive approach [J]. *IEEE Transactions on Evolutionary Computation*, 2014, 18(4): 602–622.
- [28] ZHANG Q F, LI H. MOEA/D: A multi-objective evolutionary algorithm based on decomposition [J]. *IEEE Transactions on evolutionary computation*, 2007, 11(6): 712–731.
- [29] TRIVEDI A, SRINIVASAN D, SANYAL K, et al. A survey of multiobjective evolutionary algorithms based on decomposition [J]. *IEEE Transactions on Evolutionary Computation*, 2017, 21(3): 440–462.
- [30] ZITZLER E, THIELE L. Multiobjective evolutionary algorithms: a comparative case study and the strength Pareto approach [J]. *IEEE Transactions on Evolutionary Computation*, 1999, 3(4): 257–271.
- [31] ZITZLER E, LAUMANN M, THIELE L. SPEA2: Improving the strength Pareto evolutionary algorithm [J]. *TIK-report*, 2001, 103.
- [32] KNOWLES J, CORNE D. The Pareto Archived Evolution Strategy: A New Baseline Algorithm for Pareto Multiobjective Optimisation [C]. *Proc. 1999 Congress on Evolutionary Computation*. 1999.
- [33] MAHOR A, PRASAD V, RANGNEKAR S. Economic dispatch using particle swarm optimization: A review [J]. *Renewable and sustainable energy reviews*, 2009, 13(8): 2134–2141.
- [34] KRISHNANAND K R, PANIGRAHI B K, ROUT P K, et al. Application of multi-objective teaching-learning-based algorithm to an economic load dispatch problem with incommensurable objectives [C]//*International Conference on Swarm, Evolutionary, and Memetic Computing*. Springer, Berlin, Heidelberg, 2011: 697–705.
- [35] BAHMANI-FIROUZI B, FARJAH E, AZIZIPANAH-ABARGHOEE R. An efficient scenario-based and fuzzy self-adaptive learning particle swarm optimization approach for dynamic economic emission dispatch considering load and wind power uncertainties [J]. *Energy*, 2013(50): 232–244.
- [36] LOKESHGUPTA B, SIVASUBRAMANI S. Multi-objective dynamic economic and emission dispatch with demand side management [J]. *International Journal of Electrical Power & Energy Systems*, 2018(97): 334–343.
- [37] 李整, 秦金磊, 谭文, 等. 基于目标权重导向多目标粒子群的节能减排电力系统优化调度 [J]. *中国*

- 电机工程学报, 2015 (S1): 67-74.
- [38] CHENG T, CHEN M, WANG Y, et al. Adaptive robust method for dynamic economic emission dispatch incorporating renewable energy and energy storage [J]. Complexity, 2018, 47(2): 1145-1151.
- [39] BHATTACHARYA A, CHATTOPADHYAY P K. Oppositional Biogeography-Based Optimization for multi-objective Economic Emission Load Dispatch [C]//India Conference. IEEE, 2011: 1-6.
- [40] MA H, YANG Z, YOU P, et al. Multi-objective biogeography-based optimization for dynamic economic emission load dispatch considering plug-in electric vehicles charging [J]. Energy, 2017, 135: 101-111.
- [41] GHOSHAL S, MAITY D, BANERJEE S, et al. Solution of multi-objective emission & economic dispatch using bare bones TLBO algorithm & biogeography based optimization algorithm [C]//Electrical, Computer and Communication Technologies (ICECCT), 2017 Second International Conference on. IEEE, 2017: 1-6.
- [42] 汪佳, 姚建刚, 孙谦, 等. 改进算法在电力系统多目标负荷分配中的应用 [J]. 电力系统及其自动化学报, 2013, 25(1): 107-111.
- [43] BASU M. Dynamic economic emission dispatch using nondominated sorting genetic algorithm-II [J]. International Journal of Electrical Power & Energy Systems, 2008, 30(2): 140-149.
- [44] PADHY N P. Unit commitment-a bibliographical survey [J]. IEEE Transactions on Power Systems, 2004, 19(2): 1196-1205.
- [45] LI Y F, PEDRONI N, ZIO E. A Memetic Evolutionary Multi-Objective Optimization Method for Environmental Power Unit Commitment [J]. IEEE Transactions on Power Systems, 2013, 28(3): 2660-2669.
- [46] CHANDRASEKARAN K, SIMON S P. Multi-objective unit commitment problem with reliability function using fuzzified binary real coded artificial bee colony algorithm [J]. Iet Generation Transmission & Distribution, 2012, 6(10): 1060-1073.
- [47] TRIVEDI A, SRINIVASAN D, PAL K, et al. Enhanced Multiobjective Evolutionary Algorithm Based on Decomposition for Solving the Unit Commitment Problem [J]. IEEE Transactions on Industrial Informatics, 2017, 11(6): 1346-1357.
- [48] SALANI M, GIUSTI A, CARO G D, et al. Lexicographic multi-objective optimization for the unit commitment problem and economic dispatch in a microgrid [C]//IEEE Pes International Conference and Exhibition on Innovative Smart Grid Technologies. IEEE, 2011: 1-8.
- [49] SHUKLA A, SINGH S N. Multi-objective unit commitment with renewable energy using hybrid approach [J]. Iet Renewable Power Generation, 2016, 10(3): 327-338.
- [50] WANG B, ZHOU M, WATADA J. Unit commitment optimization with pricing support for ultra-low emissions: A multi-objective approach [C]// IEEE International Conference on Control Science and Systems Engineering. IEEE, 2017: 692-697.
- [51] WU X, ZHANG B, LI J, et al. Solving power system unit commitment with wind farms using multi-objective quantum-inspired binary particle swarm optimization [J]. Journal of Renewable & Sustainable Energy, 2013, 5(2): 341-347.
- [52] CHANDRASEKARAN K, SIMON S P. Optimal Deviation Based Firefly Algorithm Tuned Fuzzy Design for Multi-Objective UCP [J]. IEEE Transactions on Power Systems, 2013, 28(1): 460-471.
- [53] HUNEALT M, GALIANA F D. A survey of the optimal power flow literature [J]. IEEE Transactions on Power Systems, 1991, 6(2): 762-770.
- [54] SHABANPOUR-HAGHIGHI A, SEIFI A R, NIKNAM T. A modified teaching-learning based optimization for multi-objective optimal power flow problem [J]. Energy Conversion and Management, 2014, 77: 597-607.
- [55] NIKNAM T, NARIMANI M R, AGHAEI J, et al. Improved particle swarm optimisation for multi-objective optimal power flow considering the cost, loss, emission and voltage stability index [J]. IET Generation, Transmission & Distribution, 2012, 6(6): 515-527.
- [56] SAHU S, BARISAL A K, KAUDI A. Multi-objective optimal power flow with DG placement using TLBO and MIPS0: A comparative study [J]. Energy Procedia, 2017(117): 236-243.
- [57] TEEPARTHI K, KUMAR D M V. Multi-objective hybrid PSO-APO algorithm based security constrained optimal power flow with wind and thermal generators [J]. Engineering Science and Technology, an International Journal, 2017, 20(2): 411-426.
- [58] WARID W, HIZAM H, MARIUN N, et al. A novel quasi-oppositional modified Jaya algorithm for multi-objective optimal power flow solution [J]. Applied Soft Computing, 2018, 65: 360-373.
- [59] NIKNAM T, NARIMANI M R, JABBARI M, et al. A modified shuffle frog leaping algorithm for multi-objective optimal power flow [J]. Energy, 2011, 36(11): 6420-6432.
- [60] SIVASUBRAMANI S, SWARUP K S. Multi-objective

- harmony search algorithm for optimal power flow problem [J]. *International Journal of Electrical Power & Energy Systems*, 2011, 33(3) : 745–752.
- [61] KHORSANDI A, HOSSEINIAN S H, GHAZANFARI A. Modified artificial bee colony algorithm based on fuzzy multi-objective technique for optimal power flow problem [J]. *Electric Power Systems Research*, 2013, 95(95) : 206–213.
- [62] SABOORI H, HEMMATI R, GHIASI S M S, et al. Energy storage planning in electric power distribution networks—A state-of-the-art review [J]. *Renewable and sustainable energy reviews*, 2017, 79: 1108–1121.
- [63] DEHGHANIAN P, HOSSEINI S H, MOEINI-AGHTAIE M, et al. Optimal siting of DG units in power systems from a probabilistic multi-objective optimization perspective [J]. *International Journal of Electrical Power & Energy Systems*, 2013, 51: 14–26.
- [64] SHENG W, LIU K Y, LIU Y, et al. Optimal placement and sizing of distributed generation via an improved nondominated sorting genetic algorithm II [J]. *IEEE Transactions on Power Delivery*, 2015, 30(2) : 569–578.
- [65] BISWAS P P, MALLIPEDDI R, SUGANTHAN P N, et al. A multiobjective approach for optimal placement and sizing of distributed generators and capacitors in distribution network [J]. *Applied Soft Computing*, 2017, 60: 268–280.
- [66] YAMMANI C, MAHESWARAPU S, MATAM S. Multiobjective optimization for optimal placement and size of dg using shuffled frog leaping algorithm [J]. *Energy Procedia*, 2012, 14: 990–995.
- [67] MAHESH K, NALLAGOWNDEN P, ELAMVAZUTHI I. Advanced Pareto front non-dominated sorting multi-objective particle swarm optimization for optimal placement and sizing of distributed generation [J]. *Energies*, 2016, 9(12) : 982.
- [68] MORADI M H, TOUSI S M R, ABEDINI M. Multi-objective PFDE algorithm for solving the optimal siting and sizing problem of multiple DG sources [J]. *International Journal of Electrical Power & Energy Systems*, 2014, 56: 117–126.
- [69] NEKOOEI K, FARSANGI M M, NEZAMABADI-POUR H, et al. An improved multi-objective harmony search for optimal placement of DGs in distribution systems [J]. *IEEE Transactions on smart grid*, 2013, 4(1) : 557–567.
- [70] KAUR N, JAIN S K. Multi-Objective Optimization Approach for Placement of Multiple DGs for Voltage Sensitive Loads [J]. *Energies*, 2017,(10) : 711–717.
- [71] MORADI M H, ABEDINI M. A combination of genetic algorithm and particle swarm optimization for optimal DG location and sizing in distribution systems [J]. *International Journal of Electrical Power & Energy Systems*, 2010, 34(1) : 66–74.
- [72] MORADI M H, ZEINALZADEH A, MOHAMMADI Y, et al. An efficient hybrid method for solving the optimal siting and sizing problem of DG and shunt capacitor banks simultaneously based on imperialist competitive algorithm and genetic algorithm [J]. *International Journal of Electrical Power & Energy Systems*, 2014, 54: 101–111.
- [73] QUOILIN S, VAN DEN BROEK M, DECLAYE S, et al. Techno-economic survey of Organic Rankine Cycle (ORC) systems [J]. *Renewable and Sustainable Energy Reviews*, 2013, 22: 168–186.
- [74] RAO R V, WAGHMARE G G. Multi-objective design optimization of a plate-fin heat sink using a teaching-learning-based optimization algorithm [J]. *Applied Thermal Engineering*, 2015, 76: 521–529.
- [75] HAJABDOLLAHI H. Comparison of stationary and rotary matrix heat exchangers using teaching-learning-based optimization algorithm [J]. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, 2018, 232(4) : 493–502.
- [76] WANG Z, LI Y. Irreversibility analysis for optimization design of plate fin heat exchangers using a multi-objective cuckoo search algorithm [J]. *Energy Conversion and Management*, 2015, 101: 126–135.
- [77] SANAYE S, HAJABDOLLAHI H. Multi-objective optimization of shell and tube heat exchangers [J]. *Applied Thermal Engineering*, 2010, 30(14–15) : 1937–1945.
- [78] WEN J, YANG H, TONG X, et al. Configuration parameters design and optimization for plate-fin heat exchangers with serrated fin by multi-objective genetic algorithm [J]. *Energy conversion and management*, 2016, 117: 482–489.
- [79] RAO R V, PATEL V. Multi-objective optimization of heat exchangers using a modified teaching-learning-based optimization algorithm [J]. *Applied Mathematical*, 2013, 37(3) : 1147–1162.
- [80] PATEL V, SAVSANI V. Optimization of a plate-fin heat exchanger design through an improved multi-objective teaching-learning based optimization (MO-ITL-BO) algorithm [J]. *Chemical Engineering Research & Design*, 2014, 92(11) : 2371–2382.
- [81] ZAREA H, KASHKOOL F M, SOLTANI M, et al. A

- novel single and multi-objective optimization approach based on Bees Algorithm Hybrid with Particle Swarm Optimization (BAHPSO): application to thermal-economic design of plate fin heat exchangers [J]. International Journal of Thermal Sciences, 2018, 129: 552-564.
- [82] PANDAY A, BANSAL H O. A review of optimal energy management strategies for hybrid electric vehicle [J]. International Journal of Vehicular Technology, 2014, 2014.
- [83] WU L, WANG Y, YUAN X, et al. Multiobjective optimization of HEV fuel economy and emissions using the self-adaptive differential evolution algorithm [J]. IEEE Transactions on Vehicular Technology, 2011, 60 (6): 2458-2470.
- [84] HU X, WANG Z, LIAO L. Multi-objective optimization of HEV fuel economy and emissions using evolutionary computation [R]. SAE Technical Paper, 2004.
- [85] SONG Z, LI J, HAN X, et al. Multi-objective optimization of a semi-active battery/supercapacitor energy storage system for electric vehicles [J]. Applied Energy, 2014, 135: 212-224.
- [86] BUERGER S, LOHMANN B, MERZ M, et al. Multi-objective optimization of hybrid electric vehicles considering fuel consumption and dynamic performance [C]//Vehicle Power and Propulsion Conference. IEEE, 2011: 1-6.
- [87] GENG B, MILLS J K, SUN D. Combined power management/design optimization for a fuel cell/battery plug-in hybrid electric vehicle using multi-objective particle swarm optimization [J]. International Journal of Automotive Technology, 2014, 15(4): 645-654.
- [88] WU J, ZHANG C H, CUI N X. PSO algorithm-based parameter optimization for HEV powertrain and its control strategy [J]. International Journal of Automotive Technology, 2008, 9(1): 53-59.
- [89] FANG L C, QIN S Y. Concurrent Optimization for Parameters of Powertrain and Control System of Hybrid Electric Vehicle Based on Multi-Objective Genetic Algorithms [C]//SICE-ICASE, 2006. International Joint Conference. IEEE, 2006: 2424-2429.
- [90] MONTAZERI-GH M, POURSAMAD A, GHALICHI B. Application of genetic algorithm for optimization of control strategy in parallel hybrid electric vehicles [J]. Journal of the Franklin Institute, 2006, 343 (4): 420-435.
- [91] HUANG B, WANG Z, XU Y. Multi-objective genetic algorithm for hybrid electric vehicle parameter optimization [C]//Intelligent Robots and Systems, 2006 IEEE/RSJ International Conference on. IEEE, 2006: 5177-5182.

A Survey of Featured Applications of Heuristic Multi-objective Optimization Algorithms in Power and Energy Systems

ZHU Xiaodong¹, WANG Ying¹, YANG Zhile², GUO Yuanjun²

(1. School of Electrical Engineering, Zhengzhou University, Zhengzhou 450001, China; 2. Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518000, China)

Abstract: Power and energy systems are the foundation of human survival and development in modern society. They played an indispensable role in daily production and life. However, significant inefficiencies and wastes found in the process of energy transmission and transformation, such as power generation and energy conversion, could result in increasingly environmental pollution and resource consumption. In order to create a low-carbon energy future, it was a necessary way to optimize the design and operation of energy and power systems aiming at maximization to the economic, environmental and social friendly benefit. After decades of development, Multi-objective heuristics optimization algorithms with characteristics of high flexibility, wide application range and high efficiency, have become crucial tools in the solving various engineering optimization. This paper aimed to systematically reviewing state-of-the-art heuristic based multi-objective optimization algorithms for solving six typical problems in power and energy systems. Comprehensive discussions on the methodologies and a brief insight on future research direction have also been proposed.

Key words: Multi objective optimization; power system; energy system; Pareto optimal solution; heuristic optimization algorithm

文章编号: 1671-6833(2019)05-0012-10

深度学习在电力负荷预测中的应用综述

朱俊丞¹, 杨之乐², 郭媛君², 于坤杰³, 张建康⁴, 穆晓敏⁴

(1. 郑州大学 产业技术研究院, 河南 郑州 450001; 2. 中国科学院 深圳先进技术研究院, 广东 深圳 518000; 3. 郑州大学 电气工程学院, 河南 郑州 450001; 4. 郑州大学 信息工程学院, 河南 郑州 450001)

摘要: 在综合能源系统和能源互联网的高速发展中, 电力负荷预测对电力系统的经济安全运行具有重要的作用. 传统的负荷预测模型方法已在电力系统中取得了广泛应用, 传统方法的简单计算模型对于高随机性、大数据背景下的动态负荷预测精度无法保证. 近年来, 在计算工具不断升级和训练数据量大规模提升的背景下, 深度学习方法在电力负荷预测领域的应用得到了广泛重视. 对多种深度学习方法在负荷预测领域中的应用进行了叙述分析, 回顾了循环神经网络(RNN)、长短期记忆网络(LSTM)、深度置信网络(DBN)、卷积神经网络(CNN)等不同深度学习预测模型. 对比于传统的负荷预测方法, 深度学习具有更高的预测精度, 对于各种外部影响因素具有更好的鲁棒性.

关键词: 深度学习; 电力系统; 负荷预测; 人工神经网络; LSTM

中图分类号: TU528.1

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.005

0 引言

自第二次工业革命之后, 电力负荷的稳定供应是维持社会正常运转的基本要求. 近年来, 由于石油等化石能源的短缺和全球碳排放造成的气候变暖的影响, 可再生能源^[1]成为全世界研究的重要方向. 由于电力系统的稳定运行具有负荷平衡的强约束性, 精确多时间尺度的电力负荷预测, 对于保证电力系统经济、安全和可靠运行具有重要作用. 另一方面, 在节能减排压力和电力市场逐步放开的背景推动下, 各发电和用电企业对于负荷预测精度的要求越来越高, 精准的负荷预测有利于各发电企业合理安排调度计划, 保证时刻为大众提供高质量电能的情况下对电力设备等进行完善的维护和检查, 也能够帮助用电企业采取主动措施提高用电质量和经济性. 传统的电力负荷预测方法包括时间序列法^[2]、趋势外推法^[3]、回归分析法^[4]等. 近年来, 大规模间歇性新能源发电系统以及电动汽车和需求侧响应等新型负荷类型的广泛接入所带来的高度随机性和动态变化特性, 对传统的负荷预测方法提出了极大挑战.

随着人工神经网络(artificial neural networks, ANN)广泛应用于图像识别、语音识别等领域, ANN对于非线性结构具有很强的自适应能力, 自主学习能力和泛化能力, 这些都是其他算法所不具备的特点. 文献[5-7]都是ANN在负荷预测领域的应用. 文献[8]是一篇关于人工神经网络在负荷预测领域应用的综述, 选用1991—1999年所有相关的文献, 证明了ANN在负荷预测领域取得了较好的效果, 笔者将重点介绍2000年以后与ANN相关的预测模型.

针对浅层神经网络存在的问题, 即神经元个数人为决定, 学习速度慢并且容易陷入局部最优等, 近年来, 随着硬件算力的极速倍增, 深度学习(deep learning)方法在图像语义分割^[9]、图像分类^[10]、目标检测^[11]等领域都取得了广泛应用, 在负荷预测领域也取得了关注. 深度学习的灵感来源于ANN, 是机器学习领域的一个分支. 深度学习方法构建的网络结构更为复杂, 具有更多的隐藏层和循环结构, 使其具备了更强的学习能力、自适应能力、容错能力、自主推理能力和泛化能力等. 笔者接下来对近年来人工神经网络在负荷预测方

收稿日期: 2018-09-15; **修订日期:** 2018-12-21

基金项目: 国家自然科学基金资助项目(51607177、61876169、61806179、61433012、U1435215); 广东省自然科学基金项目(2018A030310671); 国家博士后科学基金面上项目(2018M631005)

通信作者: 郭媛君(1986—), 女, 河北保定人, 中国科学院深圳先进技术研究院助理研究员, 博士, 主要从事机器学习、人工智能方法在能源及电力系统中的应用, E-mail: yj.guo@siat.ac.cn.

向的发展和深度学习方法在该方向的应用进行详细介绍.

1 传统电力负荷预测方法

早在20世纪80年代,世界各国研究者就开始针对负荷预测(load forecasting, LF)问题展开研究.负荷值是某一时间点或者时间段的电量或功率采样,最初对于LF问题的研究是基于1976年Box等^[2]提出的时间序列预测方法,被命名为Box-Jenkins.该方法对于负荷预测模型的输入要求较低,仅考虑了历史数据的时间序列输入,没有考虑影响负荷的其他因素,无法达到对负荷预测的要求.文献[12]提供了一种负荷峰值模型,该模型首次将天气、湿度等外部因素考虑在内.基于Box-Jenkins的方法,文献[13]提出了自回归滑动平均模型(auto-regressive and moving average model)预测方法.Juberias等^[4]建立了自回归积分滑动平均模型(autoregressive integrated moving average model)实现负荷预测.2002年,Haida等^[15]把多种影响负荷预测的因素考虑在内,提出了一种多元线性回归分析法,建立了负荷预测模型.

随后机器学习(machine learning)方法被用于负荷预测,文献[16]使用支持向量机的方法进行负荷预测,2005年,Niu等^[17]将ANN与SVM结合进行负荷预测,建立的模型在预测精度和计算速度上均有提升,2013年,Wei等^[18]结合主成分分析(principal component analysis)和最小二乘支持向量机(LS-SVM)的方法进行负荷预测,该模型可以有效减少预测模型的输入维数,提高学习速度和精度.

2 基于神经网络的方法

从20世纪90年代以来,有关ANN在LF领域的研究逐渐深入,许多优化算法、数学理论和模型被应用于ANN.本节概述了几种用于LF的经典神经网络模型和基于模型的优化与变体.

2.1 径向基函数神经网络模型

径向基函数(RBF)对于非线性模型的逼近效果良好,由于负荷受到实时电价因素的影响,Zhang等^[19]在2008年将RBF神经网络与自适应神经模糊系统(ANFIS)结合,建立了预测模型,该模型首先使用RBF网络预测负荷,不考虑电价因素,然后根据实时电价的变化,使用ANFIS系统微调结果,该模型克服了RBF网络的缺陷.2013

年,文献[20]将支持向量回归(support vector regression)、径向基函数神经网络(RBFNN)和双扩展卡尔曼滤波器(DEKF)结合构建负荷预测模型,使用SVR确定RBFNN的结构和初始参数,用DEKF优化参数,最后采用优化后的模型预测负荷.文献[21]通过PSO算法优化RBF网络构建预测模型,和传统RBF模型相比,具有更好的实用性.针对PSO算法容易陷入局部最优解的问题,很多学者致力于提高其性能,提出了许多PSO算法的变体.文献[22]提出一种改进型PSO算法优化RBF网络,通过对比,该模型有效解决了PSO算法容易陷入局部最优解的问题,相比于传统RBF预测模型具有更快的收敛速度,平均百分比误差可以控制在1.2%以内.

2.2 BP神经网络模型

在众多ANN算法中,Rumelhart等^[23]提出的误差反向传播算法(back propagation, BP)最为常用,但是BP算法存在迭代周期长、收敛速度慢等问题.2005年,马建伟等^[24]将人工鱼群算法与BP算法结合,应用于电力系统短期负荷预测,人工鱼群算法可以有效地克服局部最优,获得全局最优值.先由人工鱼群算法训练神经网络的权值,再用人工鱼群神经网络进行负荷预测,有效提高了BP神经网络的预测精度.随后出现了各种改进的BP神经网络,文献[25]提出了一种共轭梯度BP算法,应用于峰值负荷预测.峰值负荷预测是在输入中考虑预测日之前的峰值负荷信息对于预测结果的影响.2013年,Khan等^[26]提出了一种递归笛卡尔遗传规则进化人工神经网络(RCGPANN)用于峰值负荷预测,该模型可以预测一年中各个季节的不同负荷模式.2014年,何川等^[27]针对预测模型输入变量过多导致训练效率低下的问题,将独立分量分析(ICA)方法和主成分分析(PCA)方法对数据进行降维,提高BP网络预测模型的训练效率并提高预测精度.2018年,张凤林等^[28]使用信赖域算法优化BP神经网络的权值参数,将预测模型应用于新能源并网方面,得到了良好的效果.

传统BP算法收敛速度慢,导致网络训练效率较低,而使用PSO算法很好地解决了该问题.文献[29-30]使用PSO算法优化神经网络构建的预测模型,性能优于BP神经网络预测模型.文献[31]提出一种MPSO算法与BP算法结合的MPSO-BP预测模型,通过实验对比,该模型改善了BP神经网络的泛化能力,预测精度高,对电力

系统短期负荷具有良好的预测能力.

2.3 其他神经网络模型

由于电力负荷受到节假日因素影响,2000年, Kim 等^[32]针对该问题将模糊推理方法与 ANN 结合进行负荷预测,将节假日分成 5 种不同类型,每天使用 5 个 ANN 模型和 2 个模糊推理模型进行预测,得到了较为准确的预测结果.2001 年,史德明等^[33]首次将灰色模型(gray model)和 ANN 结合进行负荷预测,取得了较传统 ANN 更为理想的效果.文献[34]将灰色模型与 Elman 神经网络结合进行负荷预测.文献[35]提出了一种组合式神经网络,首先采用模糊聚类分析法将数据分成若干类别,然后对每一类别建立 ANN 预测模型,最终通过模式识别的方法得出预测结果.文献[36-37]将小波分析和神经网络结合,负荷预测精度较高.2011 年, Nose-Filho 等^[38]将广义回归神经网络(GRNN)用于负荷预测,同年,他们在 GRNN 的基础上进一步提出了 M-GRNN, MR-GRNN 预测模型, M-GRNN 具有良好的泛化能力、稳定性, MR-GRNN 可以减少输入数量,避免了影响预测结果的冗余.文献[39]将遗传算法(genetic algorithm)和灰色神经网络结合对实时电价条件下的负荷进行预测.2017 年,文献[40]将小波分解和二阶灰色神经网络结合(ADF)提高负荷预测的准确性.文献[41]结合混沌搜索遗传算法(CGA)与模拟退火(SA)算法并应用于模糊神经网络,称为 FCS,该算法消除了传统 ANN 的缺陷.针对传统神经网络进行负荷预测时,负荷曲线峰值两侧的预测误差很大,针对这个问题,文献[42-43]将粗糙集理论和神经网络结合进行电力负荷预测,使用神经网络得出预测结果后,再使用粗糙集理论对数据进行处理,提高预测精度.

1995 年, Kennedy 等^[44]提出粒子群优化算法(particle swarm optimization, PSO),在全世界的优化算法研究中引起了强烈的反响,该算法无需调节过多参数,容易实现.2017 年, Hao 等^[45]基于神经网络的方法构建预测区间(PI),应用并扩展了上下限估计方法(LUBE),以使用 NN 模型构建 PI 并且提出了一种新的公式,将主要的多目标问题转化为受约束的单目标问题,与代价函数相比,这种公式更接近实际问题并且参数更少,通过 PSO 算法优化模型得出预测模型,该模型应用于短期负荷预测和风力发电预测,实验结果表明,该模型可以构建高质量的预测区间.

尽管 ANN 已经成为负荷预测中最强大最精

准的非线性模型之一,但是对于网络结构和参数的确定对于用户来讲仍然是一大难题,这限制了它的广泛应用.2009 年,针对这一问题, Mao 等^[46]提出了一种自组织模糊神经网络(SOFNN)与双层优化方法结合的预测方法, SOFNN 可以自动确定模型的结构和参数,而双层优化方法自动选择最佳的预训练参数以确保识别出最佳的模糊神经网络,这提高了神经网络的实用性,并且预测效果良好.

ANN 的强大学习能力使它成为负荷预测领域的研究热点,全世界的学者也都致力于不断提高预测模型的准确性,但是由于浅层学习的局限性,无法充分利用历史数据进行学习和知识吸收,难以通过结合了优化算法和理论达到复杂预测问题的精度要求.随着深度学习的发展,其在电力系统负荷预测领域的研究也逐渐深入,接下来本文将重点介绍深度学习方法在负荷预测领域的应用及发展.

3 基于深度学习的方法

深度学习模型起源于文献[47],是由“深度学习之父”Hinton 提出的,能沟通多层可表征或不可表征的中间层达到数据的深度信息挖掘和吸收的作用.深度模型通过学习非线性结构来实现对复杂函数的逼近,达到预期的预测效果,具有极强的泛化能力和自适应能力.近年来深度学习方法搭建负荷预测模型的文献数量及相关文献来源如统计图 1 所示.2016 年, Ryu 等^[48]注意到负荷预测领域中需求侧能源管理这一因素的重要性,提出了基于深度神经网络(deep neural networks, DNN)的负荷预测模型,通过和传统方法相比,平均绝对百分比误差(mean absolute percent error)和均方根误差(root mean square error)得到了有效降低. MAPE 和 RMSE 是负荷预测中用于评估预测性能的重要指标,其公式如下:

$$MAPE = \frac{1}{N} \sum_{n=1}^N \left(\left| \frac{\hat{y} - y}{y} \right| \times 100 \right), \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (\hat{y} - y)^2}, \quad (2)$$

式中: N 为样本数量; \hat{y} 为目标函数; y 为输入函数.

文献[49]是深度学习方法在智能电网负荷预测领域应用的一篇综述,收集整理了 2014—2016 年的相关文献,并对深度学习各个网络模型做了逐一介绍,当时关于深度学习方法在

负荷预测领域的应用文献较少,近两年增长趋势明显.表1为近年来各个深度学习模型的文献统

计.本章下面将对于每个不同的模型在LF方面的应用做详细介绍.




图1 深度学习方法负荷预测模型文献数量及主要来源

Fig.1 Deep learning method load forecasting model literature quantity and main source

表1 基于深度学习方法搭建负荷预测模型的文献统计

Tab.1 Literature statistics table for building load forecasting models based on deep learning method

作者及参考文献	年份	方法及模型
Vermaak J 等 ^[49]	2002	RNN
邹政达等 ^[50]	2005	ACO-RNN
Qiu X 等 ^[63]	2015	SVR-DBN
Ryu S 等 ^[47]	2016	DNN
Amarasinghe K 等 ^[54]	2016	LSTM
Kong W 等 ^[55]	2017	LSTM
Gensler A 等 ^[60]	2017	Auto-LSTM
Qiu X 等 ^[65]	2017	EMD-DBN
Shi H 等 ^[51]	2017	DRNN
Li L 等 ^[70]	2017	CNN
Dong X 等 ^[71]	2017	Kmeans-CNN
Shi H 等 ^[52]	2017	PDRNN
Ouyang T 等 ^[64]	2017	Copula-CNN
Zheng H 等 ^[59]	2017	EMD-LSTM
Lu K 等 ^[62]	2018	MS-GRU
Chen K 等 ^[73]	2018	DRN
Zhang X 等 ^[69]	2018	RBM-Elman
Kong W 等 ^[56]	2018	LSTM
Bouktif S 等 ^[58]	2018	GA-LSTM
Kuo P H 等 ^[72]	2018	DeepEnergy
梁智等 ^[66]	2018	VMD-PSO-DBN
陈卓等 ^[57]	2018	LSTM
史佳琪等 ^[68]	2018	DBN
孔祥玉等 ^[67]	2018	DBN
Kumar J 等 ^[61]	2018	LSTM

3.1 递归神经网络负荷预测模型

由于负荷预测受到多方面的因素影响,如天气、电价、节假日等,这些因素难以量化,造成了传统预测模型的预测精度不够高,由此可知,预测模型的选用越接近实际结果的生成过程,预测效果

越好.2002年,Vermaak和Botha^[50]将递归神经网络(recurrent neural networks,RNN)用于短期负荷预测,其结构如图2所示,由于RNN的动态特性,该模型可以较好地捕获输入数据的特性.




图2 RNN结构示意图

Fig.2 Diagram of RNN structure

随着RNN的发展和对影响LF的因素考虑越全面,企业和客户对于预测准确性的要求越来越高,全世界的学者都在致力于提升模型的精度和效率:2005年,邹政达等^[51]通过蚁群算法对RNN网络的初始化权重进行优化,构建了改进型的RNN预测模型,结果显示该模型收敛速度较快,预测精度较传统RNN预测模型高.2017年,Shi等^[52]通过不同层次的负荷预测对深度学习方法进行了全面的评估,并采用两个极端情况实例验证了方法的有效性:①以新英格兰电力负荷数据为例,对区域负荷需求进行聚类;②以爱尔兰的100个单体家庭为例,对家庭的需求进行分类.通过测试,深度递归神经网络与浅层神经网络相比,在聚类水平上MAPE提高了23%,在分类水平上RMSE提高了5%.同年,Shi等^[53]针对家庭负荷预测的高波动性和不确定性,提出了一种汇集深度递归神经网络(PDRNN),它将一组客户的负荷配置文件按批次输入到一个输入池中,并在来自爱

尔兰的 920 名客户数据上进行了测试,相比于经典 RNN 预测模型, RMSE 降低了 6.5%。

3.2 长短时记忆网络负荷预测模型

由于 RNN 只能对较短的时间序列数据进行记忆,随着数据量增大,时间间隔增长, RNN 会丢失之前输入的重要信息,引起梯度消失而导致预测模型失效。针对 RNN 的这一问题,文献[54]所提出的长短时记忆网络(long-short term memory, LSTM)可以提供一种有效的解决方案。该网络通过传递转移函数来处理输入的时间序列,相比于 RNN, LSTM 增加了输入门(Γ_i)、遗忘门(Γ_f)和输出门(Γ_o),输入门决定隐藏层信息是否进行更新,遗忘门决定更新后的信息是否包含上一时刻的信息,输出门决定输出更新后信息的哪个部分。其参数迭代更新公式为:

$$\Gamma_f = \sigma(\omega_f [a^{(t-1)}, x^{(t)}] + b_f); \quad (3)$$

$$\Gamma_i = \sigma(\omega_i [a^{(t-1)}, x^{(t)}] + b_i); \quad (4)$$

$$\Gamma_o = \sigma(\omega_o [a^{(t-1)}, x^{(t)}] + b_o); \quad (5)$$

$$\tilde{C}^{(t)} = \tanh(\omega_c [a^{(t-1)}, x^{(t)}] + b_c); \quad (6)$$

$$C^{(t)} = \Gamma_i \cdot \tilde{C}^{(t)} + \Gamma_f \cdot C^{(t-1)}; \quad (7)$$

$$a^{(t)} = \Gamma_o \cdot \tanh(C^{(t)}) M. \quad (8)$$

其网络结构如下图所示。

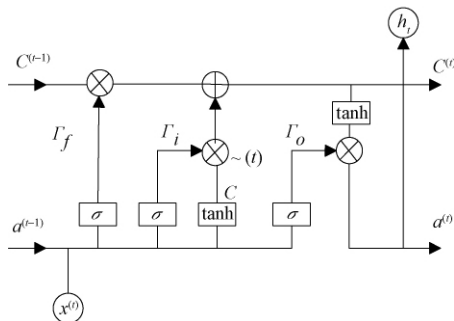


图3 LSTM 网络结构示意图

Fig.3 Diagram of LSTM structure

个人住宅的负荷预测问题在未来的电网规划和运营中发挥着越来越重要的作用,由于单个能源用户的高波动性和不确定性,负荷预测是一个棘手的问题。2016 年,Marino 等^[55]使用标准 LSTM 架构和 S2S-LSTM 架构对个人住宅的负荷进行预测,以一分钟和一小时作为时间步长进行了实验,结果证明标准 LSTM 架构无法在以一分钟为步长的情况下精准预测结果,而 S2S 在两种时间步长下均表现良好。2017 年, Kong 等^[56]也将 LSTM 网络应用于个人住宅的负荷预测并取得了良好的效果。2018 年, Kong 等^[57]就 meter-level 负荷预测展开研究,将住宅的能源消耗与居民的行为联系在

一起,例如在早餐后洗澡或者在洗衣结束时干燥大量衣物等,如果可以感知到这样的行为模式,预测结果将更加准确,作者将能源设备的能量消耗输入到预测器中,经过实验, LSTM 网络在输入设备能量消耗序列的情况下 MAPE 最低。文献[58]也将 LSTM 网络应用于短期负荷预测,与传统 ARIMA 模型相比, MAPE 从 9.74% 下降到 5.76%。

将各种算法与网络模型结合的方式一直是负荷预测领域的热点研究方向, Bouktif S 等^[59]为了更加容易的选择预测模型,将机器学习算法与 LSTM 网络结合,通过训练几种线性和非线性的 ML 算法,选择最好的作为基本算法,使用 wrapper 和 embedded 特征选择方法选择最佳特征,最后使用遗传算法选出最佳时间间隔和 LSTM 网络层数,实验结果表明,使用各种算法选择出的参数训练出的预测模型比人工调试参数的预测模型具有更高的精度。文献[60]将经验模态分解(Empirical Mode Decomposition)和类似日选择的方法与 LSTM 网络结合,将极端梯度增强的加权 K 均值算法用于评估预测日和历史天数之间的相似性, EMD 方法用于将 SD 负荷分解为本征模态函数(intrinsic mode function, IMF)和残差函数,分离的 LSTM 网络用于预测每个 IMF 和残差函数,最终结果表明 SD-EMD-LSTM 可以准确预测用电负荷。文献[61]将 AutoEncoder 和 LSTM 结合,提出了 Auto-LSTM 预测模型,在可再生能源预测领域进行负荷预测,与传统模型、人工神经网络模型和深度置信网络(deep belief networks)进行对比,新的预测模型取得了更高的精度。2018 年, Kumar 等^[62]发现,尽管云计算带来很大的收益,但是由于没有遇到任何挑战和问题,导致云系统脆弱并且成本高昂,他们使用 LSTM 网络对云计算中心的工作负荷进行预测,该方法有效地解决了云计算中心动态资源扩展和功耗的问题,可以使云系统面临考验时及时做出相应措施,同时可以降低云计算成本。

门控循环单元(gated recurrent unit)是 LSTM 网络的一种变体,它将 LSTM 的输入门与遗忘门结合,使结构变得更加简单。文献[63]建立了一种多层自标准化门控循环单元模型(MS-GRU)用于 STLFI,并且引入缩放指数线性单元(SELU)作为激活函数来压缩隐藏状态以计算模型的输出,这种方式可以克服梯度爆炸和梯度消失等问题。模糊聚类均值(FCM)算法用于选择类似日。通过与

其他 RNN 模型对比,MS-GRU 模型的预测精度更高。

3.3 深度置信网络负荷预测模型

DBN 是由 Hinton^[46] 提出的无监督高效学习算法,由一系列受限的玻尔兹曼机(restricted boltzmann machine)堆叠而成,具有很强大的数据拟合能力,其结构如图 4 所示。




图 4 DBN 结构示意图

Fig.4 Diagram of DBN structure

Qiu 等^[64]在 2015 年时首次提出将 DBN 用于时间序列预测,并且通过支持向量回归模型来拟合输出,将模型应用在三个电力负荷需求数据集,一个人工时间序列数据集和三个回归数据集,充分展示了 DBN 模型的优势.2017 年,Ouyang 等^[65]将深度置信网络用于负荷预测,首先通过 Box-Cox 变换处理负荷数据,为了量化电价和温度两个参数的功率和服的尾部依赖性,拟合参数 Copula 模型并计算峰值负荷的阈值,接下来建立 DBN 网络来预测每小时的负荷.经过实际数据证实提出的模型效果优于以往的模型.文献[66]将 EMD 算法和 DBN 网络结合构建负荷预测模型,通过 EMD 将负荷数据序列分解为 IMF,通过 DBN 预测 IMF 的趋势,最后将所有 IMF 的预测结果通过无偏或加权求和组合起来得到聚合输出,通过与 9 种预测模型对比,该模型具有更高的精度.文献[67]将变分模态分解(VMD)、PSO 算法和 DBN 网络结合构建预测模型.文献[68]使用高斯-伯努利RBM作为 DBN 的第一个模块,并采用列文伯格-马夸尔特(LM)算法对预训练阶段得到的初始网络参数进行优化,该模型与传统方法相比具有更好的预测精度.文献[69]提出了基于深度结构多任务学习的短期电、热、气负荷联合预测方法,将 DBN 与多任务回归层结合,DBN 用于提取高级特征,多任务回归层作为有监督学习方法输出预测结果,该模型应用在园区型综合能源系统中,取得了良好的效果.随着 DBN 在负荷预测领域越来越流行,2018 年,Zhang 等^[70]提出

了一种基于 RBM 和 Elman 神经网络的新型深度学习框架,和经典 DBN 预测模型、Elman 预测模型相比,该模型可以显著改善预测精度。

3.4 卷积神经网络负荷预测模型

卷积神经网络(convolutional neural networks, CNN)是一种前馈神经网络,经常用于处理网格数据拓扑,而时间序列属于一维的网格数据,所以 CNN 不仅可以应用于图像、视频、语音等领域,也可用于负荷预测。

2017 年,Li 等^[71]将数值预测问题转化为图像处理任务,使用 CNN 模型底输入数据执行精确的聚类,然后考虑温度、湿度、风速等外部影响因素,使用另外一个神经网络来预测负荷.同年,Dong 等^[72]将 CNN 和 K 均值聚类算法结合,提出一种新型预测模型,使用 K 均值算法将大数据集聚集成小的子集,然后使用子集训练 CNN,最终得出预测结果,该模型效果并且具有良好的扩展性.2018 年,Kuo 等^[73]提出了一种 DeepEnergy 模型来预测负荷,该模型结构由三个一维的卷积层和三个池化层组成,最后由一个全连接层连接输出层,经过测试,该模型的 MAPE 和 CV-RMSE 分别为 9.77% 和 11.66%,具有很高的精度。

近期,Chen 等^[74]提出了一种不同于以往模型的新预测模型,该模型基于深度残差网络,深度残差网络在图像识别领域也取得了良好的效果,该网络在负荷预测领域的研究还会进一步展开。

4 结论与展望

针对 21 世纪以来人工神经网络和深度学习方法在电力系统负荷预测领域方面的应用和发展进行综述和回顾.在高速发展的智能化信息时代,精准的负荷预测已经成为电力领域必不可少的一环,从人工神经网络到机器学习再到深度学习,对于负荷预测模型的构建不断趋近实际情况.从现有的预测模型来看,基于 LSTM、CNN、DBN、RNN 等深度学习方法所构建的预测模型效果明显优于人工神经网络和传统机器学习算法构建的模型,而通过将智能优化算法等领域方法与深度学习网络结合的预测模型实际应用价值更高,对难以量化的外部因素的学习效果很强,并且拥有良好的扩展性。

除传统的负荷预测外,间歇性可再生能源和电动汽车^[75]等对象包含因素更为复杂,但目前采用深度学习方法对其出力和负荷预测的相关研究还十分有限.全面有效的深度学习方法,有望成为

智能电网研究的新方向.将人工智能算法应用于新能源领域,是人工智能新的典型应用场景,也为打造我国的低碳能源未来提供新的智能化解决方案.

参考文献:

- [1] TURNER J A. A realizable renewable energy future [J]. Science, 1999, 285(5428) : 687-689.
- [2] Box Gep G, Box G, Jenkins G. Time series analysis: forecasting and control [J]. Journal of Time, 1976, 31 (4) : 238-242.
- [3] 李金颖, 牛东晓. 非线性季节型电力负荷灰色组合预测研究 [J]. 电网技术, 2003, 27(5) : 26-28.
- [4] CHEN C, ZHOU J N. Appncation. of regression analysis in power system load forecasting [J]. Advanced Materids Research, 2014 (960/961) : 1516-1522.
- [5] PARK D C, ELSHARKAWI M A, MARKS R J I, et al. Electric load forecasting using an artificial neural network [J]. IEEE Transactions on Power Systems, 1991, 6(2) : 442-449.
- [6] KANDIL N, WAMKEUE R, SAAD M, et al. An efficient approach for short term load forecasting using artificial neural networks [J]. International Journal of Electrical Power & Energy Systems, 2006, 28(8) : 525-530.
- [7] ZHANG G, PATUWO B E, HU M Y. Forecasting with artificial neural networks: The state of the art [J]. International Journal of Forecasting, 1998, 14 (1) : 35-62.
- [8] HIPPERT H S, PEDREIRA C E, SOUZA R C. Neural networks for short-term load forecasting: a review and evaluation [J]. IEEE Transactions on Power Systems, 2001, 16(1) : 44-55.
- [9] SHELHAMER E, LONG J, DARRELL T. Fully Convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4) : 640-651.
- [10] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C] // International Conference on Neural Information Processing Systems. Curran Associates Inc. 2012: 1097-1105.
- [11] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C] // IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2014: 580-587.
- [12] CORPENING S L, REPPEN N D, RINGLEE R J. Experience with weather sensitive load models for short and long-term forecasting [J]. IEEE Transactions on Power Apparatus Systems, 1973, 92(6) : 1966-1972.
- [13] HAGAN M T, BEHR S M. The time series approach to short term load forecasting [J]. Power Systems IEEE Transactions on, 1987, 2(3) : 785-791.
- [14] JUBERIAS G, YUNTA R, MORENO J G, et al. A new ARIMA model for hourly load forecasting [C] // Transmission and Distribution Conference. IEEE, 1999: 314-319.
- [15] HAIDA T, MUTO S. Regression based peak load forecasting using a transformation technique [J]. IEEE Transactions on Power Systems, 2002, 9(4) : 1788-1794.
- [16] CHEN B J, CHANG M W, LIN C J. Load forecasting using support vector Machines: a study on EUNITE competition 2001 [J]. IEEE Transactions on Power Systems, 2004, 19(4) : 1821-1830.
- [17] NIU D X, QIANG W, LI J C. Short term load forecasting model using support vector machine based on artificial neural network [C] // International Conference on Machine Learning and Cybernetics. IEEE, 2005: 4260-4265.
- [18] WEI R R, WEI Z Z, RONG R, et al. Short term load forecasting based on PCA and LS-SVM [J]. Advanced Materials Research, 2013, 756-759: 4193-4197.
- [19] ZHANG Y, ZHOU Q, SUN C, et al. RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment [J]. IEEE Transactions on Power Systems, 2008, 23 (3) : 853-858.
- [20] KO C N, LEE C M. Short-term load forecasting using SVR (support vector regression) -based radial basis function neural network with dual extended Kalman filter [J]. Energy, 2013, 49(49) : 413-422.
- [21] 陆宁, 周建中, 何耀耀. 粒子群优化的神经网络模型在短期负荷预测中的应用 [J]. 电力系统保护与控制, 2010, 38(12) : 65-68.
- [22] 师彪, 李郁侠, 于新花, 等. 基于改进粒子群-径向基神经网络模型的短期电力负荷预测 [J]. 电网技术, 2009, 33(17) : 180-184.
- [23] RUMELHART D E, MCCLELLAND J L. Parallel Distributed Processing [M] // Parallel distributed processing /. The MIT Press, 1986: 45 - 76.
- [24] 马建伟, 张国立. 人工鱼群神经网络在电力系统短期负荷预测中的应用 [J]. 电网技术, 2005, 29 (11) : 36-39.
- [25] SAINI L M, SONI M K. Artificial neural network-based peak load forecasting using conjugate gradient

- methods [J]. IEEE Transactions on Power System, 2002, 17(3): 907-912.
- [26] KHAN G M, KHATTAK A R, ZAFARI F, et al. Electrical load forecasting using fast learning recurrent neural networks [J]. IEEE Transactions on Power System, 2013, 38(2): 1-6.
- [27] 何川, 舒勤, 贺含峰, 等. ICA 特征提取与 BP 神经网络在负荷预测中的应用 [J]. 电力系统及其自动化学报, 2014, 26(8): 40-46.
- [28] 张凤林, 陈峦, 姚亮, 等. 基于信赖域法改进的 BP 网络在新能源并网方面的研究 [J]. 可再生能源, 2018(1): 43-50.
- [29] ZHAOYU P, LI S, HONG Z, et al. The application of the PSO based BP network in short-term load forecasting [J]. Physics Procedia, 2012, 24(16): 626-632.
- [30] BASHIR Z A, EL-HAWARY M E. Applying wavelets to short-term load forecasting using PSO-based neural networks [J]. IEEE Transactions on Power Systems, 2009, 24(1): 20-27.
- [31] 师彪, 李郁侠, 于新花, 等. 改进粒子群-BP 神经网络模型的短期电力负荷预测 [J]. 计算机应用, 2009, 29(4): 1036-1039.
- [32] KIM K H, YOUN H S, KANG Y C. Short-term load forecasting for special days in anomalous load conditions using neural networks and fuzzy inference method [J]. IEEE Transactions on Power Systems, 2000, 15(2): 559-565.
- [33] 史德明, 李林川, 宋建文. 基于灰色预测和神经网络的电力系统负荷预测 [J]. 电网技术, 2001, 25(12): 14-17.
- [34] 张健美, 周步祥, 林楠, 等. 灰色 Elman 神经网络的电网中长期负荷预测 [J]. 电力系统及其自动化学报, 2013, 25(4): 145-149.
- [35] 陈耀武, 汪乐宇, 龙洪玉. 基于组合式神经网络的短期电力负荷预测模型 [J]. 中国电机工程学报, 2001, 21(4): 79-82.
- [36] 邵能灵, 侯志俭. 小波模糊神经网络在电力系统短期负荷预测中的应用 [J]. 中国电机工程学报, 2004, 24(1): 24-29.
- [37] 王玉龙, 崔玉, 李鹏, 等. 基于小波分析改进的神经网络模型电力系统负荷预测 [J]. 电网与清洁能源, 2015, 31(2): 16-20.
- [38] NOSE-FILHO K, LOTUFO A D P, MINUSSI C R. Short-term multinodal load forecasting in distribution systems using general regression neural networks [C]// PowerTech, 2011 IEEE Trondheim. IEEE, 2011: 1-7.
- [39] 葛少云, 贾鸥莎, 刘洪. 基于遗传灰色神经网络模型的实时电价条件下短期电力负荷预测 [J]. 电网技术, 2012, 36(1): 224-229.
- [40] LI B, ZHANG J, HE Y, et al. Short-term load-forecasting method based on wavelet decomposition with second-order gray neural network model combined with ADF test [J]. IEEE Access, 2017, (99): 1-11.
- [41] LIAO G C, TSAO T P. Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short-term load forecasting [J]. IEEE Transactions on Evolutionary Computation, 2006, 10(3): 330-340.
- [42] PANG Q, ZHANG M. Very Short-term load forecasting based on neural network and rough set [C]//International Conference on Intelligent Computation Technology and Automation. IEEE, 2010: 1132-1135.
- [43] 庞清乐. 基于粗糙集理论的神经网络预测算法及其在短期负荷预测中的应用 [J]. 电网技术, 2010(12): 168-173.
- [44] KENNEDY J, EBERHART R C. Particle swarm optimization [C]. International symposium on neural networks, 1995: 1942-1948.
- [45] HAO Q, SRINIVASAN D, KHOSRAVI A. Short-term load and wind power forecasting using neural network-based prediction intervals [J]. IEEE Transactions on Neural Networks & Learning Systems, 2017, 25(2): 303-315.
- [46] MAO H, ZENG X J, LENG G, et al. Short-term and midterm load forecasting using a bilevel optimization model [J]. IEEE Transactions on Power Systems, 2009, 24(2): 1080-1090.
- [47] HINTON G E, OSINDERO S, TEH Y W, et al. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527-1554.
- [48] RYU S, NOH J, KIM H, et al. Deep neural network based demand side short term load forecasting [J]. Energies, 2016, 10(1): 3.
- [49] ALMALAQ A, EDWARDS G. A review of deep learning methods applied on load forecasting [C]//IEEE International Conference on Machine Learning and Applications. IEEE, 2017: 511-516.
- [50] VERMAAKJ, BOTH A E C. Recurrent neural networks for short-term load forecasting [J]. IEEE Transactions on Power Systems, 2002, 13(1): 126-132.
- [51] 邹政达, 孙雅明, 张智晟. 基于蚁群优化算法递归神经网络的短期负荷预测 [J]. 电网技术, 2005(03): 59-63.
- [52] SHI H, XU M, MA Q, et al. A whole system assessment of novel deep learning approach on short-term load forecasting [J]. Energy Procedia, 2017, 142:

- 2791-2796.
- [53] SHI H, XU M, LI R. Deep learning for household load forecasting-a novel pooling deep RNN [J]. IEEE Transactions on Smart Grid, 2017, 9(5): 5271-5280.
- [54] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural computation, 1997, 9(8): 1735-1780.
- [55] MARINO D L, AMARASINGHE K, MANIC M. Building energy load forecasting using deep neural networks [C]// IECON 2016-42 nd Annual Conference of the IEEE Industrial Electromls Society. IEEE. 2016: 7046-7051.
- [56] KONG W, DONG Z Y, JIA Y, et al. Short-term residential load forecasting based on LSTM recurrent neural network [J]. IEEE Transactions on Smart Grid, 2017, 10(1): 841-851.
- [57] KONG W, DONG Z Y, HILL D J, et al. Short-term residential load forecasting based on resident behaviour learning [J]. IEEE Transactions on Power Systems, 2018, (3302): 1087-1088.
- [58] 陈卓, 孙龙祥. 基于深度学习 LSTM 网络的短期电力负荷预测方法 [J]. 电子技术, 2018(1): 39-41.
- [59] BOUKTIF S, FIAZ A, OUNI A, et al. Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: comparison with machine learning approaches [J]. Energies, 2018, 11(7): 1636-1641.
- [60] ZHENG H, YUAN J, CHEN L. Short-term load forecasting using EMD-LSTM neural networks with a xgboost algorithm for feature importance evaluation [J]. Energies, 2017, 10(8): 1168.
- [61] GENSLER A, HENZE J, SICK B, et al. Deep learning for solar power forecasting: an approach using AutoEncoder and LSTM neural networks [C]// IEEE International Conference on Systems, Man, and Cybernetics, 2017: 2858-2865.
- [62] KUMAR J, GOOMER R, SINGH A K. Long short term memory recurrent neural network (LSTM-RNN) based workload forecasting model for cloud datacenters [J]. Procedia Computer Science, 2018, (125): 676-682.
- [63] LU K, ZHAO Y, WANG X, et al. Short-term electricity load forecasting method based on multilayered self-normalizing GRU network [C]// IEEE Conference on Energy Internet and Energy System Integration, 2018: 1-5.
- [64] QIU X, ZHANG L, REN Y, et al. Ensemble deep learning for regression and time series forecasting [C]// Computational Intelligence in Ensemble Learning, 2015: 1-6.
- [65] OUYANG T, HE Y, LI H, et al. A deep learning framework for short-term power load forecasting [J]. Arxiv Preprint 2017, 21(3): 1711-1178.
- [66] QIU X, REN Y, SUGANTHAN P N, et al. Empirical mode decomposition based ensemble deep learning for load demand time series forecasting [J]. Applied Soft Computing, 2017, 54(C): 246-255.
- [67] 梁智, 孙国强, 李虎成, 等. 基于 VMD 与 PSO 优化深度信念网络的短期负荷预测 [J]. 电网技术, 2018, 42(2): 598-606.
- [68] 孔祥玉, 郑锋, 鄂志君, 等. 基于深度信念网络的短期负荷预测方法 [J]. 电力系统自动化, 2018, 42(5): 133-139.
- [69] 史佳琪, 谭涛, 郭经, 等. 基于深度结构多任务学习的园区型综合能源系统多元负荷预测 [J]. 电网技术, 2018, 42(3): 698-707.
- [70] ZHANG X, WANG R, ZHANG T, et al. Short-term load forecasting using a novel deep learning framework [J]. Energies, 2018, 11(6): 1554-1159.
- [71] LI L, OTA K, DONG M. Everything is image: CNN-based short-term electrical load forecasting for smart grid [C]// International Symposium on Pervasive Systems, Algorithms and Networks & 2017, International Conference on Frontier of Computer Science and Technology & 2017 Third International Symposium of Creative Computing. IEEE Computer Society, 2017: 344-351.
- [72] DONG X, QIAN L, HUANG L. Short-term load forecasting in smart grid: A combined CNN and K-means clustering approach [C]// IEEE International Conference on Big Data and Smart Computing, 2017: 119-125.
- [73] KUO P H, HUANG C J. A high precision artificial neural networks model for short-term energy load forecasting [J]. Energies, 2018, 11(1): 213.
- [74] CHEN K, CHEN K, WANG Q, et al. Short-term load forecasting with deep residual networks [J]. IEEE Transactions on Smart Grid, 2018 (1014): 3943-3952.
- [75] CHAN C, CHAU K. Modern electric vehicle technology [M], Oxford University Press on Demand, 2001.

Deep Learning Applications in Power System Load Forecasting: a Survey

ZHU Juncheng¹, YANG Zhile², GUO Yuanjun², Yu Kunjie³, ZHANG Jiangkang⁴, MU xiaomin⁴

(1.Institute of industrial technology, Zhengzhou University, Zhengzhou 450001, China; 2.Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518000, China; 3.School of Electrical Engineering, Zhengzhou University, Zhengzhou, 450001, China; 4.School of Information Engineering, Zhengzhou University, Zhengzhou, 450001, China)

Abstract: In the rapid development of integrated energy systems and energy network, power load forecasting played an important role in the economic and safe operation of energy and power systems. The traditional load forecasting modelling methods have been widely used in power systems. However, the simple computational model structure limited by traditional methods could not guarantee the dynamic load prediction accuracy under high randomness and big data background. In recent years, in the context of the continuous upgrading of computing tools and the increasing large-scale of training data volume, the application of deep learning methods in the field of power system load forecasting attracted extensive attentions. This paper analyzed the applications of various deep learning methods in the field of load forecasting, and reviewed the Recurrent Neural Network (RNN), Long- and Short-Term Memory Network (LSTM), Deep Belief Network (DBN), and Convolutional Neural Network (CNN). Compared with the traditional load forecasting method, the deep learning method showed higher prediction accuracy and better robustness to various external influences.

Key words: Deep learning; power system; load forecasting; artificial neural network; LSTM

文章编号: 1671-6833(2019)05-0022-09

人工智能在电力系统中的应用综述

马 民¹, 秦 佳², 杨东升², 周博文², 庞永恒², 汉焕英²

(1. 国网辽宁省电力有限公司 阜新供电公司, 辽宁 阜新 123000; 2. 东北大学 信息科学与工程学院, 辽宁 沈阳 110000)

摘要: 电力系统的发展程度是一个国家经济水平的重要评判指标. 随着分布式可再生能源的不断接入与电网规模的不断扩大, 电力系统正逐渐趋于复杂化, 电力数据呈现出多源、异构、大量等典型的大数据特性, 这对电力问题的分析处理方法提出了更高的要求. 人工智能(artificial intelligence, AI)是未来科技进步的关键, 我国已将推进人工智能发展提升为国家战略并将电力系统定为人工智能主要应用领域之一, 人工智能的发展也为电力系统规划设计、仿真模拟、协调控制、预测估计、诊断识别等问题提供了强有力的工具. 本文从近几年世界各国人工智能政策需求入手, 主要讨论了以感知预测、管理控制、安全维护为主的人工智能在电力系统中的主要应用方向; 以人工智能自身应用短板为基础, 剖析了人工智能技术在电力应用领域的不足之处, 深入挖掘了人工智能在不同电力应用方向的问题所在; 并着眼于人工智能大局发展趋势, 对电力智能化发展提出建议与展望.

关键词: 人工智能; 电力系统; 感知预测; 管理控制; 安全维护

中图分类号: TM769

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.012

0 引言

自“人工智能”概念被正式提出以来, 人工智能经历了“两起两落”, 直至2006年, Hinton在神经网络深度学习领域取得的突破使人类又一次看到了机器赶超人类的希望, 也标志着“人工智能”又一次突飞猛进^[1]. 目前, 世界各国都在围绕人工智能相关技术积极布局. 从2016年起, 美国在政府的大力支持下, 先后成立了“机器学习与人工智能分委员会”(subcommittee on machine learning and artificial intelligence, MLAI), 出台《为人工智能的未来做好准备》《人工智能、自动化与经济报告》国家咨询报告, 发布了《国家人工智能研发战略规划》. 2017年10月, 英国政府网站发布报告《在英国发展人工智能》, 并于11月发布《产业战略: 建设适应未来的英国》白皮书. 而早在2013年, 在汉诺威工业博览会上, 德国就正式提出以建设智能工厂为核心的“工业4.0战略”^[2-3].

为抢抓人工智能发展的重大战略机遇, 构筑

我国人工智能发展的先发优势, 我国先后出台了《中国制造2025》《新一代人工智能发展规划》等二十余项人工智能及其相关产业发展政策. 其中, “人工智能在不同领域的深度融合与具体应用”是我国政策导向的核心所在. 《中国制造2025》中明确指出要“以加快新一代信息技术与制造业深度融合为主线、以推进智能制造为主攻方向”; 《新一代人工智能发展规划》更是将“推动人工智能与各行业融合创新”作为我国科技兴国战略部署的重点任务之一^[4-5].

电力系统是我国人工智能突破发展的重点领域之一. 自20世纪80年代提出专家系统法以来, 人工智能算法在电力系统中的应用探索从未停歇. 然而, 传统人工智能方法大多存在计算复杂、周期较长、学习困难等问题. 目前, 随着人工智能算法的有效改进, 多源异构大数据模式逐渐形成, 不断积累数据量, 人工智能在电力系统中的应用又迎来了全新的机遇与挑战^[6-7].

笔者主要介绍了人工智能算法在电力系统中的应用方向, 对其中3个主要方向进行详细阐述,

收稿日期: 2018-11-01; 修订日期: 2019-03-29

基金项目: 国家自然科学基金资助项目(61703081、61433004); 辽宁省自然科学基金资助项目(20170520113); 中央高校基本科研基金(N160402003); 新能源电力系统国家重点实验室开放课题(LAPS17013)

作者简介: 马民(1968—), 男, 辽宁沈阳人, 国网辽宁省电力有限公司高级工程师, 主要从事电力系统人工智能应用研究, E-mail: 529984634@qq.com.

并在此基础上总结了人工智能在电力系统中应用的不足之处并提出了改进措施。

1 人工智能概述与在电力系统中的应用方向

人工智能也称作机器智能,是指由人工制造出来的系统所表现出来的智能,即为了实现感知、学习、推理、规划、交流、操控物体,通过普通计算机实现的智能。人工智能的实现方法丰富,主要包括引领三次高潮的专家系统(expert systems, ESs)、人工神经网络(artificial neural networks, ANN)、深度学习(deep learning, DL)以及持续推动学科发展的模糊逻辑(fuzzy logic, FL)、遗传算法(genetic algorithm, GA)、机器学习(machine learning, ML)、多智能体(multi-agent system, MAS)、博弈论(game theory, GT)等。

电力系统是由发电、输电、变电、配电、用电等环节组成的电能生产与消费系统,电力系统的规模和技术高低已成为一个国家经济发展水平的标志之一。智能电网(smart grid)的提出对电力系统运行提出了新的要求,也为人工智能方法在电力系统中的应用提供了方向。目前,人工智能技术在电力系统中的应用逐渐从单一的技术应用向多样化的技术应用方向发展,涵盖了负荷、新能源发电、微网、需求侧管理、电网安全与稳定、网络安全、设备管理等多个场景,每个场景衍生出多个研究。笔者将人工智能技术在电力系统中的应用方向概括为感知预测、管理控制、安全维护3个方面加以阐述,图1为人工智能在电力系统的应用方向框架。

2 人工智能技术应用于电力系统感知预测

感知预测是指对环境元素的感知,对当前形势的理解,以及对未来状况的投影。电力系统感知预测主要包括负荷预测、可再生能源发电预测、稳定裕度预测、电压谐波预测、发电机频率预测等。自电力系统概念形成之日起,负荷预测就是研究的重中之重,也是其他电力研究的基础,而随着电网规模逐步扩大与分布式电网结构的形成,可再生能源发电预测逐渐兴起。

2.1 负荷预测

1975年,Dillon等人首次利用人工神经网络(artificial neural network, ANN)的自学习功能进行负荷预测,并在第五次PSCC(电力系统计算)会议上宣读了成果,这次尝试虽然只停留在理论

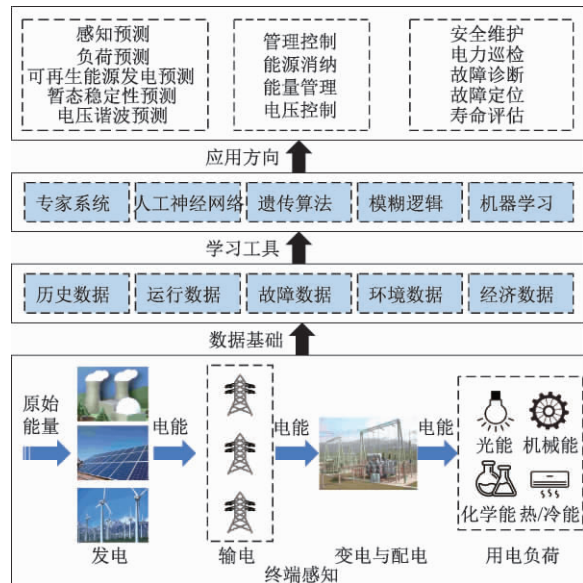


图1 人工智能在电力系统的应用方向

Fig.1 Application direction of artificial intelligence in power system field

研究阶段,但拉开了人工智能在电力系统感知预测领域的序幕^[8]。为了打破ANN训练时间过长、提高预测精度与容错性,文献[9-11]通过优化训练方式、改进数据获取与网络参数选择方法、对历史数据进行预处理,加深了ANN的应用深度。文献[12-13]将ANN与自适应算法相结合,有效提高了模型的训练速度,文献[14-15]利用模糊逻辑对不明确对象的校正功能,修正了预测结果。

ANN主要应用于短期负荷预测,即用当天的气温、天气晴朗度、风向风力、峰谷负荷及相关负荷等预测当天的负荷大小,获得了较好的预测结果,而ANN在中长期负荷预测的研究还比较少,这是因为短期变化可认为是一个平稳的随机过程,而中长期负荷预测通常会有大的转折,不是一个平稳过程^[16]。针对上述问题,文献[17]将支持向量机(support vector machines, SVM)应用到负荷中长期预测当中,取得了良好的预测效果。在此基础上,文献[18-19]提出了支持向量机回归修正模型,文献[20]在支持向量机模型上引入了经验模式分解与卡尔曼滤波,均在增加算法精度上获得一定突破,并在实际数据库上得以验证。

智能电网背景下电力系统数据呈现出多源异构的大数据特性,数据量大、复杂程度高,智能传感技术的发展使得负荷预测数据采样频率提高,这为深度学习在电力负荷预测领域的应用提供了契机也提出了要求。长短时记忆神经网络(long short-term memory, LSTM)利用其特殊的网络结构,可以实现时间序列预测分析,即利

用过去一段时间内某事件时间的特征来预测未来一段时间内该事件的特征,图2为LSTM神经网络模块结构图.和传统回归分析模型的预测不同,这是一类相对比较复杂的预测建模问题,模型依赖于事件发生的先后顺序,预测精度高,且同时适用于短期、中期、长期预测^[21-22],预测流程如图3所示.

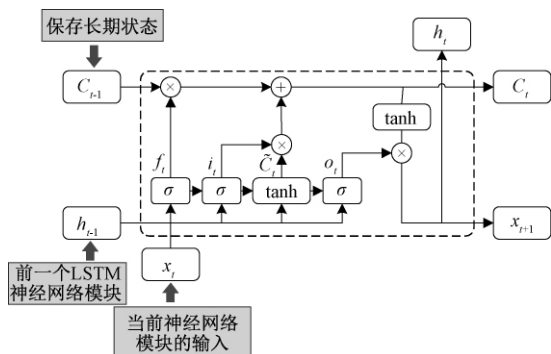


图2 LSTM神经网络模块结构图

Fig.2 Module structure diagram of LSTM

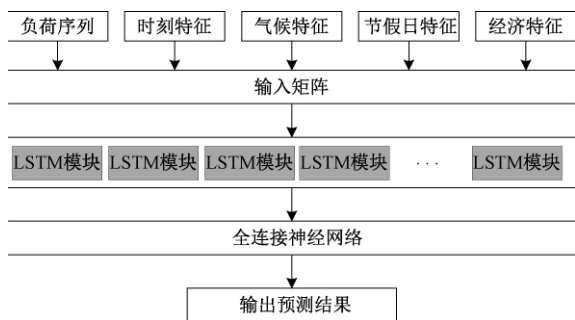


图3 LSTM负荷预测流程图

Fig.3 Flow chart of load forecasting by LSTM

2.2 再生能源发电预测

高比例可再生能源成为智能电网未来发展的一个突出特征,风电和光伏作为当前较为成熟的可再生能源发电技术,具有较强的波动性和随机性^[23].早期的风电、光伏发电功率预测主要依赖于统计学理论,随着研究的深入,小波变换、人工神经网络、支持向量机等方法逐渐融入其中,可以在地形复杂、风向或光照随机散乱的情况下初步实现分级预测^[24-28].

与负荷预测原理相似,LSTM同样可以有效应用在风电、光伏发电功率预测中,除此之外,其他深度学习方法在可再生能源发电领域也有很多尝试:文献[29-30]基于深度置信网络(deep belief network, DBN)有效提取了复杂风速和光伏数据序列的非线性结构和不变性特征,进而对风电和光伏功率进行预测;文献[31-32]利用深度卷积神经网络(deep convolutional neural network,

DCNN)对光照数据进行特征提取,提高了预测的准确度和速度;文献[33]通过稀疏自动编码器(sparse autoencoder, SAE)将粗糙神经网络纳入深度学习模型以预测不确定性风速,从而提高模型的鲁棒性和预测精度^[23].

3 人工智能技术应用于电力系统管理控制

电力系统的管理控制技术主要由规划和运行控制两方面组成,规划是电力系统安全经济运行的必要手段,运行控制是为了电力系统的有功与无功出力时刻与负荷保持平衡,以保证优质经济的电能供应^[34].

3.1 能源消纳与能量管理

在能源结构变革、新能源产业高速发展、分布式可再生能源高比例渗透的环境下,对能源的规划调度逐渐成为重点研究领域.文献[35]在区域综合能源系统的背景下,基于多智能体系(multi-agent systems, MAS)搭建包含主管层、区域层、设备层的3层交互结构,实现空间尺度上不同实体的相互作用,提高了能源消纳率与能源使用效率.随着微电网大范围接入电网,一定区域内的多个微电网互联形成多微电网系统,文献[36-37]为了实现电力市场的管理以及交互,搭建了多微电网系统中的多智能体模型,文献[38-39]则将博弈论的思想应用于人工智能领域,采取合作博弈的手段,以各微电网网损最小为目标进行能量管理^[40].在智能电网、微电网、多能源互联系统、微能源网等多种现代综合能源应用场景中,电力系统的管理控制已经逐渐从单一或少量目标的最优控制发展为复杂场景下多层多区最优化问题.人工智能技术的引入恰恰为解决这一问题带来了契机.

3.2 电压控制

在电力系统中,通过人工智能能够有效提高电压的控制效率,电压控制是一个复杂的过程,不仅需要计算相应电压的潮流结果,还需预测未来的电流负荷,这些在智能电网的控制下能够轻松实现^[41].专家系统、人工神经网络、遗传算法、模糊逻辑等较为成熟的人工智能算法已经广泛应用于电压控制领域中^[42-47];文献[48]提出了基于多智能体协调的二级电压控制,文献[49]通过多智能体建立一种适用于分散自治控制的最优控制律,获得了含光伏发电的电压最优控制性能.

4 人工智能技术应用于电力系统安全维护

为了使电力系统突然发生扰动时仍不间断地向用户提供电力,或发生系统崩溃时能够尽快判断故障类型、确定故障位置并恢复供电,需要研究以电力巡检、故障诊断、寿命评估为主要方向的电力系统安全维护技术。

4.1 电力巡检

人工智能在电力巡检中的应用主要集中在输电线路,输电线路在正常运行过程中,很容易受到自然因素和人为因素的影响而致破坏,对整个电力系统的稳定运行造成影响。在很多情况下,输电线路会分布在荒郊野外,恶劣的环境使传统人工巡检、GPS 巡检技术捉襟见肘,而无人机技术、智能机器人技术与深度学习图像识别技术的发展使无人巡检成为可能。

将音视频监测系统、定点采集系统、上位机系统集成到机器人上,机器人可以采集相应位置的音频、视频传到控制终端,相关工作人员可以通过远程操作机器人进行巡检^[50-52]。以无人机的航拍图像为基础数据进行识别是近两年电力巡检的主要发展方向,借助卷积神经网络的特征提取与分类功能可有效区分绝缘子、变压器、断路器、输电线路电杆和输电线铁塔等电力设备,还可以实现电力杆塔倾斜的自动识别^[53-54]。

4.2 故障诊断

电力系统故障诊断按诊断对象可以分为输电线路故障和电力设备故障,按诊断目的可以分为判断事故类型和定位故障位置。在输电线路故障中,架空线路接地、短路方面的问题与开关跳闸问题是比较常见的电气故障,此外,输电线路导线电缆物理损伤也会造成一系列的故障发生。基于人工智能技术的输电线路故障诊断主要包括故障分类、故障定位和故障预测几个方面,常用的方法包括 SVM、LSTM、模糊推理系统、极限学习机等。文献[55]利用 SVM 对电力线路故障类型进行准确识别;文献[56]在 SVM 基础上加入深度学习的 LSTM,对线路跳闸故障实现了分类和预测。人工智能在线路故障定位上的应用较故障诊断更加广泛,张庆超等基于人工神经网络提出非直接接地中性点系统单相接地故障的输电线路故障定位方法^[57];李小叶等提出了一种基于混合智能算法的直流输电线路故障定位方法,利用神经网络建模并利用遗传算法对模型进行修正,解决了传统测

距结果受制于故障行波波头检测准确性的问题^[58];徐舜等基于本征模函数(intrinsic mode function, IMF)特征能量矩的故障信息提取方法,并利用 SVM 进行故障定位,仅需测量故障电流就可以准确、有效地识别故障区段^[59]。近年来,对输电线路故障的研究越来越趋向判断事故类型和定位故障位置同时进行的方向发展,文献[60]和文献[61]分别借助自适应神经模糊推理系统和小波极限学习机这种新型机器学习算法对输电线路故障同时进行分类与定位。

电力设备故障常见于汽轮机、锅炉、旋转电机等发电设备与变压器、断路器、互感器等输变电设备中,其中人工智能方法在变压器故障中的应用发展较快,很多深度学习算法已经成功应用于故障识别中,应用方式如图4所示。文献[62]对比了不同机器学习算法及融合算法在基于溶解气体分析的变压器故障诊断中的应用效果。文献[63]借助深度置信网络,将诊断范围由单一故障扩展为单一故障与多重故障相结合,振动信号同样可以用于诊断变压器故障。文献[64]利用射频识别(radio frequency identification, RFID)传感器在器身内部采集绕组振动信号并利用深度学习的堆叠去噪自动编码器提取信号特征用于故障识别。除此之外,互感器故障智能诊断方法也有一些研究^[65]。

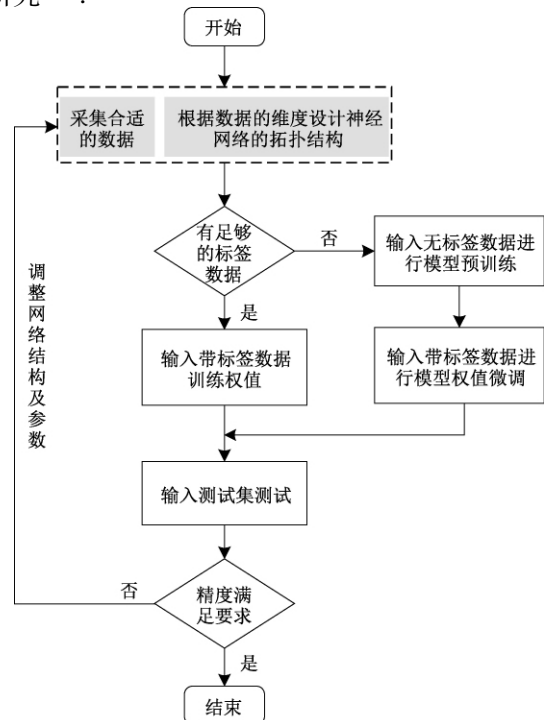


图4 电力故障智能诊断系统

Fig.4 Intelligent power fault diagnosis system

4.3 寿命评估

电力系统的寿命主要取决于电力设备的使用寿命,为有效延长电力设备的使用寿命,让电力系统的投资和回报有一个最佳平衡,必须进行寿命评估^[66].变压器的寿命由于其影响因素的多维性而较难计算,文献[67]介绍了变压器绝缘老化在线检测分析的模型,叙述了人工神经网络在变压器绝缘老化程度诊断和寿命评估方面应用的可行性和有效性;为了给决策者提供更为详细和多元化的检修信息,文献[68-70]利用模糊理论建立变压器寿命评估模型.文献[71]利用神经网络模型的预测功能,将电机振动信号作为输入,也可实现电机寿命评估功能.随着锂离子电池的广泛应用,其健康状态(state-of-health, SOH)估计逐渐成为电力领域的热点问题.人工智能在电池 SOH 中的应用思路为基于电池模型,采用人工智能算法对电池等效模型的电容、电阻等参数进行识别,进而描述电池 SOH,文献[72]沿此思路,针对在线应用问题,采用神经网络电池模型估计电池的荷电状态(state-of-charge, SOC),然后利用开路电压与 SOC 之间的关系,采用模糊逻辑和最小二乘法实现 SOH 的在线评估^[73].

5 人工智能在电力系统中应用的不足与改进措施

人工智能领域的知名科学家,原 IBM Woston Group 的首席科学家周伯文博士在演讲中指出:“如今我们仅处于人工智能发展的最初级阶段,人工智能依然依赖于专家设置的体系结构,学习性也依赖于人工设计的算法.”《中国制造 2025》中则明确指出:“我国人工智能缺少重大原创成果,在基础理论、核心算法以及关键设备等方面差距较大.”不论是放眼于世界还是着眼于中国,人工智能技术发展面临的最主要问题是数据结构未成体系、算法自主学习能力较弱以及计算能力有限,这些问题也相应地制约了人工智能技术在电力系统中的应用.

由上文综述不难发现,人工智能在电力系统感知预测和安全维护领域的应用进展十分迅速,很多新颖的深度学习算法已经成功运用到负荷预测、新能源发电预测、故障诊断等方向中,这些尝试都取得了很大的突破也显露出一定的缺陷.随着智能传感技术逐渐完善,电力系统感知预测的历史数据容易获取,在坚实的数据基础下,配备大量高性能硬件、组成高计算能力设备成为人工智能应用于电力

系统感知预测领域的关键.亟需研究面向电力系统感知预测的高精尖软、硬件模块,研制软硬件结合的集成人工智能芯片;亟需通过处理器等技术的研究提升计算处理能力,提高响应速度.数据是人工智能的基础,没有足够故障特征明显的数据的故障诊断无异于空中楼阁,智能电力故障诊断亟待研究能够精准捕捉故障数据的专用智能传感技术,亟待提出故障数据准确快速贴标签的方法,亟待解决故障数据库不完全问题.算法是人工智能的前提,相比于感知预测和安全维护,人工智能在电力管理控制领域的应用仍存在算法适应性较差的问题,如何改进基础算法,提出贴合领域特色的电力系统专用智能算法是研究的重点.

我国人工智能技术在电力系统各领域中的应用程度参差不齐,在积极应对人工智能技术主要问题的同时,要根据自身电力系统特点做出改进,后续研究可从以下方面扩展:

(1) 构建分布式人工智能算法:纵观人工智能技术的发展历程,早期的专家系统、模糊逻辑、人工神经网络对事件的演化机理依赖较多,属于理论驱动方法;而近期的深度学习算法依赖于大量多源异构数据集,属于数据驱动方法.电力系统智能化使得电力数据量呈指数增长、数据结构复杂度大大增加,也对人工智能算法的计算能力提出了更高的要求.分布式人工智能(distributed artificial intelligence, DAI)是电力系统人工智能的发展方向之一,通过并行分布式计算提高计算能力.

(2) 搭建电力系统智能化平台:谷歌、百度以及各人工智能相关企业都拥有自己的智能化平台,然而,现有的人工智能平台主要针对数据科学家与实验员设计,真正应用于实际的专业性工具仍然很少.未来电力系统中的人工智能将向混合智能方向发展,综合多种智能技术,取长补短,目的是搭建集成发电、输电、变电、配电、用电各环节与感知预测、管理控制、安全维护功能于一体的电力智能化平台,消除数据壁垒,真正提供人工智能学习运用的数据基础.

(3) 完善电力系统数物结合思想:以深度学习为代表的人工智能新算法虽然更适合现代电力系统的分析与处理,但其结果的可信度仍然制约于算法的可解释性,这样的系统较容易受到虚假数据干扰.且在电力故障检测时,由于程序中断造成的故障输出难以与实际故障区分,大大降低了电力基础设施故障的诊断效率与精度.未来对电力系统进行智能分析与判断时要依靠数据而不是完全依赖数

据,出发点仍要放在电力系统基础理论上,找出物理模型与数据结构之间千丝万缕的联系,完善电力系统数物结合思想,并将数据结构与机理模型之间的联系高效地应用于电力系统分布式人工智能算法与智能化平台中,真正实现数物有机结合。

6 结论

人工智能技术是引领未来的创新性技术,在

电力系统应用领域仍有很大潜力,世界各国对前沿技术的研究也从未停歇。笔者以第三次人工智能热潮为契机,从世界各国对待人工智能的态度与出台的相关政策出发,对人工智能算法在电力系统中的应用方向进行了综述,深入挖掘了人工智能在电力系统领域的短板并对未来发展方向进行了展望,主要内容如表 1 所示,旨在推动人工智能技术在电力系统应用领域的发展。

表 1 人工智能在电力系统中的应用综述
Tab. 1 Review on the Application of Artificial Intelligence in Power Systems

应用方向	应用领域	研究进展	技术优势/瓶颈	下一步研究方向	长期愿景
感知预测	负荷预测	短期预测: ANN	数据容易获取/ 计算能力不足	研究高精尖软、硬件模块,研 制软、硬件结合的集成人工智 能芯片;研究处理器技术	构建分 布式人 工智能 算法 搭建电 力系统 智能化 平台 完善电 力系统 数物结 合思想
		中长期预测: SVM			
	再生能源 发电预测	大数据高精度预测: LSTM 初步分级预测: ANN/SVM 大数据高精度预测: LSTM/DBN/CNN/SAE			
管理控制	能源消纳 与能量管理	能源规划: MAS 能量管理: MAS/GT	数据需求量较 小/算法适应 性弱	改进基础算法;提出贴合领域 特色的电力系统专用智能 算法	
	电压控制	ESs/ANN/GA/FL/MAS			
安全维护	电力巡检	图像采集: 机器人/无人机 特征提取: CNN	算法适应性强/ 故障数据不足	研究专用智能传感技术;研究 故障数据准确快速贴标签方 法;完善故障数据库	
	故障诊断	电力线路故障: SVM/LSTM 电力设备故障: DBN/SAE			
	寿命评估	电力设备寿命: ANN/FL 电池寿命: ANN/FL			

参考文献:

[1] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural computation, 2006, 18(7) : 1527-1554.

[2] 贾开,郭雨晖,雷鸿竹.人工智能公共政策的国际比较研究: 历史、特征与启示 [J].电子政务, 2018,189 (9) : 78-86.

[3] CALO R. Artificial intelligence policy: a primer and roadmap [J]. Social Science Electronic Publishing, 2017.

[4] 中华人民共和国国务院. 中国制造 2025 [R]. 2015,6.

[5] 中华人民共和国国务院.《国务院关于印发新一代人工智能发展规划的通知》[R].2017.

[6] 朱永利,尹金良.人工智能在电力系统中的应用研究与实践综述 [J].发电技术, 2018, 39(2) : 106-111.

[7] MOKHTARI S, SING J, WOLLENBERG B. A unit commitment expert system (power system control) [J]. IEEE Transactions on Power Systems, 1988, 3 (1) : 272-277.

[8] DILLON T S. Artificial neural network applications to power systems and their relationship to symbolic methods [J]. International Journal of Electrical Power & Energy Systems, 1991, 13(10) : 66-72.

[9] LU C N, WU H T, VEMURI S. Neural network based short term load forecasting [J]. IEEE Transactions on Power Systems, 1993, 8(1) : 336-342.

[10] HIGHLEY D D, HILMES T J. Load forecasting by ANN [J]. IEEE Computer Applications in Power, 1993, 6(3) : 10-15.

[11] ASAR A U, MCDONALD J R. A specification of neural network applications in the load forecasting problem [J]. IEEE Transactions on Control Systems Technology, 1994,2(2) : 135-141.

[12] HO K L, HSU Y, YANG C. Short term load forecasting using a multilayer neural network with an adaptive learning algorithm [J]. IEEE Transactions on Power Systems, 1992, 7(1) : 141-149.

[13] KHOTANZAD A, HWANG R C, ABAYE A, et al. An adaptive modular artificial neural network hourly load forecaster and its implementation at electric

- utilities [J]. IEEE Transactions on Power Systems, 1995, 10(3): 1716-1722.
- [14] KIM K H, PARK J K, HWANG K J, et al. Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems [J]. IEEE Transactions on Power Systems, 1995, 10(3): 1534-1539.
- [15] KASSAEI H R, KEYHANI A, WOUNG T, et al. A hybrid fuzzy, neural network bus load modeling and predication [J]. IEEE Transactions on Power Systems, 1999, 14(2): 718-724.
- [16] 周中明, 李建平, 张鑫, 等. ANN 在电力系统中期负荷预测中的应用 [J]. 电力系统及其自动化学报, 2003(2): 36-39.
- [17] CHEN B J, CHANG M W, LIN C J. Load forecasting using support vector Machines: a study on EUNITE competition 2001 [J]. IEEE Transactions on Power Systems, 2004, 19(4): 1821-1830.
- [18] ELATTAR E E, GOULERMAS J, WU Q H. Electric Load Forecasting Based on Locally Weighted Support Vector Regression [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 2010, 40(4): 438-447.
- [19] CEPERIC E, CEPERIC V, BARIC A. A Strategy for Short-Term Load Forecasting by Support Vector Regression Machines [J]. IEEE Transactions on Power Systems, 2013, 28(4): 4356-4364.
- [20] LIU Q, SHEN Y, WU L, et al. A hybrid FCW-EMD and KF-BA-SVM based model for short-term load forecasting [J]. CSEE Journal of Power and Energy Systems, 2018, 4(2): 226-237.
- [21] JIAO R, ZHANG T, JIANG Y, et al. Short-Term Non-Residential Load Forecasting Based on Multiple Sequences LSTM Recurrent Neural Network [J]. IEEE Access, 2018, 6: 59438-59448.
- [22] BEDI J, TOSHNIWAL D. Empirical Mode Decomposition Based Deep Learning for Electricity Demand Forecasting [J]. IEEE Access, 2018, 6: 49144-49156.
- [23] 戴彦, 王刘旺, 李媛, 等. 新一代人工智能在智能电网中的应用研究综述 [J]. 电力建设, 2018, 39(10): 1-11.
- [24] SIDERATOS G, HATZIARGYRIOU N D. An Advanced Statistical Method for Wind Power Forecasting [J]. IEEE Transactions on Power Systems, 2007, 22(1): 258-265.
- [25] LIU Y Q, SHI J, YANG Y P, et al. Short-term wind-power prediction based on wavelet transform-support vector machine and statistic-characteristics analysis [J]. IEEE Transactions on Industry Applications, 2012, 48(4): 1136-1141.
- [26] BUHAN S, CADIRCI I. Multistage wind-electric power forecast by using a combination of advanced statistical methods [J]. IEEE Transactions on Industrial Informatics, 2015, 11(5): 1231-1242.
- [27] YANG M, LIN Y, HAN X S. Probabilistic wind generation forecast based on sparse bayesian classification and dempster-shafer theory [J]. IEEE Transactions on Industry Applications, 2016, 52(3): 1998-2005.
- [28] SHI J, LEE W J, LIU Y Q, et al. Forecasting power output of photovoltaic systems based on weather classification and support vector machines [J]. IEEE Transactions on Industry Applications, 2012, 48(3): 1064-1069.
- [29] WANG H Z, WANG G B, LI G Q, et al. Deep belief network based deterministic and probabilistic wind speed forecasting approach [J]. Applied Energy, 2016, 182: 80-93.
- [30] 史佳琪, 张建华. 基于深度学习的超短期光伏精细化预测模型研究 [J]. 电力建设, 2017, 38(6): 28-35.
- [31] QURESHI A S, KHAN A, ZAMEER A, et al. Wind power prediction using deep neural network based meta regression and transfer learning [J]. Applied Soft Computing, 2017, 58: 742-755.
- [32] ZANG H. Hybrid method for short-term photovoltaic power forecasting based on deep convolutional neural network [J]. IET Generation, Transmission & Distribution, 2018, 12(20): 4557-4567.
- [33] KHODAYAR M, KAYNAK O, KHODAYAR M. Rough deep neural architecture for short-term wind speed forecasting [J]. IEEE Transactions on Industrial Informatics, 2017, 13(6): 2770-2779.
- [34] 肖俊明, 周谦, 瞿博阳, 等. 多目标进化算法及其在电力环境经济调度中的应用综述 [J]. 郑州大学学报(工学版), 2016, 37(2): 1-9.
- [35] 雷霞, 唐文左, 李逐云, 何锦宇, 刘群英. 考虑区域综合能源系统优化运行的配电网扩展规划 [J]. 电网技术, 2018, 42(11): 3459-3470.
- [36] 吴红斌, 孙天赐松, 蔡高原. 多微网互联系统的动态经济调度研究 [J]. 太阳能学报, 2018, 39(5): 1426-1433.
- [37] KUMAR NUNNA H S V S, DOOLLA S. Multiagent-based distributed-energy-resource management for intelligent microgrids [J]. IEEE Transactions on Industrial Electronics, 2013, 60(4): 1678-1687.
- [38] SAAD W, HAN Z, POOR H V. Coalitional game theory for cooperative micro-grid distribution networks [C]//IEEE International Conference on Communications Workshops, 2011: 1-5.

- [39] FADLULLAH Z M, KATO N. Game-theoretic coalition formulation strategy for reducing power loss in micro grids [J]. IEEE Transactions on Parallel & Distributed Systems, 2014, 25(9): 2307-2317.
- [40] 陈其森,汪湘晋,池伟,等.多微电网互联系统能量管理方法研究[J].电力系统保护与控制, 2018, 46(11): 83-91.
- [41] 姜潇娜,张栋.基于人工智能的电力系统自动化控制[J].通信电源技术, 2018, 35(3): 140-141.
- [42] LE T L, NEGNEVITSKY M. Network equivalents and expert system application for voltage and VAR control in large-scale power system [J]. IEEE Transactions on Power Systems, 1997, 12(4): 1440-1445.
- [43] LIU C C, TOMSOVIC K. An expert system assisting decision-making of reactive power/voltage control [J]. IEEE Transactions on Power Systems, 1986, 1(3): 195-201.
- [44] HSU Y Y, YANG C C. A hybrid artificial neural network-dynamic programming approach for feeder capacitor schedule [J]. IEEE Transactions on Power Systems, 1994, 9(2): 1069-1075.
- [45] 娄信明,盛戈峰,等.改进遗传算法在水电站自动电压控制中的应用[J].电力系统自动化, 2000, 24(24): 41-44.
- [46] SU C T, LIN C T. A new fuzzy control approach to voltage profile enhancement for power systems [J]. IEEE Transactions on Power Systems, 1996, 11(3): 1654-1659.
- [47] 杨胡萍,李威仁,左士伟,等.基于改进遗传算法的电力系统无功优化[J].郑州大学学报(工学版), 2015, 36(6): 66-69+75.
- [48] 潘哲龙,张伯明,孙宏斌,等.分布计算的遗传算法在无功优化中的应用[J].电力系统自动化, 2001, 25(12): 37-41.
- [49] YORINO N, ZOKA Y, WATANABE M, et al. An optimal autonomous decentralized control method for voltage control devices by using a multi-agent system [J]. IEEE Transactions on Power Systems, 2015, 30(5): 2225-2233.
- [50] 王翔.电力系统机器人的研究现状与展望[J].中国设备工程, 2018(13): 171-172.
- [51] 牛志华,石炎.巡检机器人在超特高压变电站的应用[J].山东电力技术, 2018, 45(6): 74-77.
- [52] 朱海,李小娇.浅谈变电站智能机器人巡检系统的应用[J].低碳世界, 2017(33): 147-148.
- [53] 李军锋,王钦若,李敏.结合深度学习和随机森林的电力设备图像识别[J].高电压技术, 2017, 43(11): 3705-3711.
- [54] 王榆夫,韩军,赵庆喜,等.基于无人机图像的电力杆塔倾斜检测[J].计算机仿真, 2017, 34(7): 426-431.
- [55] 祝志慧,孙云莲.基于 EMD 近似熵和 SVM 的电力线路故障类型识别[J].电力自动化设备, 2008, 7: 81-84.
- [56] ZHANG S, WANG Y, LIU M, et al. Data-based line trip fault prediction in power systems using LSTM networks and SVM [J]. IEEE Access, 2018, 6: 7675-7686.
- [57] ZHANG Q C, ZHANG Y, SONG W, et al. Transmission line fault location for single-phase-to-earth fault on non-direct-ground neutral system [J]. IEEE Transactions on Power Delivery, 1998, 13(4): 1086-1092.
- [58] 李小叶,李永丽,张烁.基于混合智能算法的直流输电线路故障测距方法[J].电力系统保护与控制, 2014, 42(10): 108-113.
- [59] 徐舜,杨毅,王奕,等.基于 IMF 能量矩和 SVM 的电力线路故障定位[J].电测与仪表, 2015, 52(11): 117-123.
- [60] REDDY M J, MOHANTA D K. Adaptive-neuro-fuzzy inference system approach for transmission line fault classification and location incorporating effects of power swings [J]. IET Generation, Transmission & Distribution, 2008, 2(2): 235-244.
- [61] CHEN Y Q, FINK O, SANSAVINI G. Combined fault location and classification for power transmission lines fault diagnosis with integrated feature extraction [J]. IEEE Transactions on Industrial Electronics, 2018, 65(1): 561-569.
- [62] SENOUSAOUI M E A, BRAHAMI M, Fofana I. Combining and comparing various machine-learning algorithms to improve dissolved gas analysis interpretation [J]. IET Generation, Transmission & Distribution, 2018, 12(15): 3673-3679.
- [63] DAI J J, SONG H, SHENG G, et al. Dissolved gas analysis of insulating oil for power transformer fault diagnosis with deep belief network [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2017, 24(5): 2828-2835.
- [64] WANG T, HE Y, LI B, et al. Transformer Fault Diagnosis Using Self-Powered RFID Sensor and Deep Learning Approach [J]. IEEE Sensors Journal, 2018, 18(15): 6399-6411.
- [65] HONG Y, CHANG C P. Detection and correction of distorted current transformer current using wavelet transform and artificial intelligence [J]. IET Generation, Transmission & Distribution, 2008, 2(4): 566-575.

- [66] 范永哲,倪晓蕊,范旭日.超期服役机组寿命评估技术及研究进展[J].河北电力技术, 2003, 22(4): 7-8.
- [67] 杨启平,薛五德,蓝之达.变压器绝缘老化的诊断与寿命评估[J].变压器, 2004(2): 13-17.
- [68] 栗然,韩彪,卢云,等.基于随机模糊理论的变压器经济寿命评估[J].电力系统保护与控制, 2014, 42(1): 9-16.
- [69] 杨丽徙,蔡红飞,任家印,等.模糊层次分析法的改进及其在变压器寿命评估中的应用[J].郑州大学学报(工学版), 2013, 34(3): 10-13.
- [70] 石光,吴春红,韩伟,等.基于随机模糊理论的电力变压器剩余寿命评估[J].电气应用, 2014, 33(21): 59-64.
- [71] GEBRAEEL N, LAWLRY M, LIU R, et al. Residual life predictions from vibration-based degradation signals: a neural network approach [J]. IEEE Transactions on Industrial Electronics, 2004, 51(3): 694-700.
- [72] SHAHRIARI M, FARROKHI M. On-line State of health estimation of VRLA batteries using state of charge [J]. IEEE Transactions on Industrial Electronics, 2012, 60(1): 191-202.
- [73] 刘大同,周建宝,郭力萌,等.锂离子电池健康评估和寿命预测综述[J].仪器仪表学报, 2015, 36(1): 1-16.

Review on the Application of Artificial Intelligence in Power Systems

MA Min¹, QIN Jia², YANG Dongsheng², ZHOU Bowen², PANG Yongheng², HAN Huanying²

(1.State Grid Liaoning Fuxin Power Supply Co. Ltd., Fuxin 123000, China; 2.School of Information Science and Engineering, Northeastern University, Shenyang 110000, China)

Abstract: The development of electric power system was an important evaluation index of national economic level. With the continuous access of distributed renewable energy and the continuous expansion of power grid scale, the power system was gradually become more and more complicated. The power data with the characteristics of multi-source, heterogeneous, large amounts of typical big data, which puts forward higher requirements for the analysis and processing methods of power problems. Artificial intelligence was the key to the future science and technology progress. China has to promote the development of Artificial Intelligence to national strategy. The emergence and development of artificial intelligence could provide powerful tools for power system planning and design, simulation, coordination and control, prediction and estimation, diagnosis, and recognition. Power system was one of the main application fields of artificial intelligence in our country. This review began with the policy requirements of artificial intelligence in the world in recent years; and mainly discussed the main application direction of artificial intelligence in power system, which focused on perception prediction, management control and security maintenance. Then, based on the shortcoming of the application of artificial intelligence itself, the shortcomings of artificial intelligence technology in the field of electric power application was analyzed. In addition, based on the characteristics of various directions, the problems of artificial intelligence in different directions of electric power application was deeply explored. Finally, suggestions and prospects for the development of intelligent power was put forward in view of the overall development trend of artificial intelligence.

Key words: artificial Intelligence; power system; perception prediction; management control; security maintenance

文章编号: 1671-6833(2019)05-0031-07

蓄电池储能运行控制对有源配电网影响研究

李雪, 宋彦龙

(上海大学 机电工程与自动化学院, 上海 200072)

摘要: 针对分布式发电及大量接入电动汽车对有源配电网功率和电压质量影响日益严峻的问题, 首先从储能容量及功率、日负荷曲线特性和单位时间角度分析了影响区间控制的因素, 提出了一种改进区间控制的储能出力模型来解决蓄电池储能电站一个周期内多次充放电问题; 进一步, 基于随机变量相关性的点估计概率潮流算法以分析分布式发电、电动汽车及储能电站接入配电网对电压水平的影响; 最后, 针对含蓄电池储能电站的改进 IEEE-33 节点有源配电网系统进行仿真分析, 实验结果验证了接入储能电站可以有效地降低系统功率及电压波动。

关键词: 蓄电池储能电站; 区间控制; 相关性; 概率潮流; 点估计

中图分类号: TM74

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.015

0 引言

传统配电网开环运行导致线路末端电压普遍较低, 而且负荷在峰谷时段差异大导致通过母线的功率也具有较大的峰谷差。随着风电、光伏等分布式发电单元接入配电网, 使得配电网母线功率的峰谷差问题更加严重, 快速普及的电动汽车 (electric vehicle, EV) 也逐渐渗透到配电网, 这加剧了配电网的电压不稳定和波动。蓄电池储能电站 (battery energy storage station, BESS) 由于具有能量存储和快速响应的特性, 可以在负荷侧对电网的峰谷负荷及分布式发电的出力进行调节, 不但能够削峰填谷, 而且还可有效调节节点电压以降低电压波动、提高电压质量。

配电网各节点的负荷及分布式发电的出力均存在较大的波动性和不确定性, 若仅根据典型日负荷曲线和风速曲线固定储能的充放电时段和功率, 将导致储能容量不能够充分利用, 无法达到预期的削峰填谷效果。为充分发挥储能对负荷的调节作用, 亟需制定合适的储能出力控制策略。文献 [1] 提出了一种基于负荷预测的分时段匹配区间控制策略以平抑母线的功率波动, 并对负荷预测与实际负荷的偏差进行处理。为了应对风电出力波动, 文献 [2] 提出了一种可变的分时段蓄电池

储能充放电控制策略, 以提高调控精度并延长储能寿命。文献 [3] 提出了一种改进的风储系统定容及控制策略以平抑风电出力。文献 [4] 提出了分布式储能与电压动态补偿器联合补偿的控制模型, 对电压暂降进行补偿。储能控制策略确定后, 可以根据实际负荷数据得出各时段的充放电功率, 然后利用概率潮流进一步分析储能电站的接入对配电网的影响。

概率潮流^[5-6] (probabilistic load flow, PLF) 通常可采用蒙特卡罗模拟法 (monte carlo simulation, MCS) 和点估计法 (point estimate method, PEM)。MCS 算法精度高但计算量大, 常被用作评价其他算法的标准; PEM 计算量小但要求输入的随机变量间相互独立。文献 [7] 针对输入变量概率密度函数未知的情况, 提出了一种基于 PEM 和 Gram-Charlie 展开的 PLF 实用算法。文献 [8] 考虑风速与负荷的相关性, 采用 PEM 方法进行计算, 并对线路容量的越限风险进行评估。文献 [9] 基于随机变量向量空间变换的点估计概率潮流计算方法, 分析了 3 种电动汽车充放电策略对有源配电网电压的影响。上述研究均未考虑储能的接入及储能与其他变量的相关性对配电网的影响。

笔者针对分布式发电及电动汽车接入配电网影响母线功率及电压质量的问题, 首先针对一个

收稿日期: 2018-11-17; 修订日期: 2019-01-21

基金项目: 国家自然科学基金资助项目 (61773253)

作者简介: 李雪 (1979—), 女, 河南平顶山人, 上海大学副教授, 博士, 主要从事电力系统优化与控制以及智能电网应用研究, E-mail: lixue@shu.edu.cn.

储能运行周期(一般设为一天)内会存在多个充放电时段的情况,提出一种改进的区间控制储能出力模型,然后考虑风速、负荷及储能出力的相关性,运用 Nataf 变换,结合初等变换,将随机变量从相关非正态空间转换到独立正态空间,进而建立了概率潮流模型并采用 $2m+1$ 点估计法求解,最后分析了接入储能电站能够有效降低系统功率及电压的波动。

1 储能出力模型

针对储能出力的随机性,首先描述储能的区间控制策略,分析影响区间控制的因素,然后针对多峰谷的日负荷曲线提出改进区间控制模型及计算方法,进而建立各时段储能出力的概率模型。

1.1 储能控制方法

1.1.1 储能的区间控制策略

区间控制策略^[1]是根据预设的负荷区间来确定蓄电池储能电站不同时刻的工作状态:当负荷值处于区间内时,储能电站不工作;当负荷值高于区间上限时,储能电站向外放电,近似等效为分布式电源;当负荷值低于区间下限时,储能电站充电,可近似为负荷。该控制策略可以根据不同的日负荷曲线、储能容量及最大充放电功率得到不同的控制区间,进而得到各时段储能的充放电功率,最大限度地利用储能容量使负荷的峰谷差最小,这样既能保证储能电站起到削峰填谷的作用,又能避免频繁切换储能运行状态影响蓄电池寿命。文献[1]的区间控制策略仅考虑一个周期内存在单个充放电时间段(当储能电站连续多时刻处于充电状态或不工作状态时定义为一个充电时间段,放电时间段定义类似)的情况,由于区间上下限与储能容量和负荷曲线特性相关,当储能容量充足且负荷曲线在周期内的峰谷波动较为频繁时,必然出现一个周期内多次充放电的情况。

以《青海电网负荷分析与预测》中青海电网春季典型日负荷特性曲线为例,首先分析多个充放电时段对区间控制的影响,如图1所示,其中虚线为区间的上下限。根据预设区间及区间控制规则,BESS 于 1:00~5:00、16:00 及 24:00 处于充电状态,7:00、18:00~22:00 处于放电状态,其余时段不工作。在一个周期内存在 3 个充电时段和 2 个放电时段,若采用只考虑单个充放电时段的区间控制方法,会降低预设区间的可靠性,使充放电量比例失衡,从而影响储能电

站削峰填谷效果,因此,接下来分析影响区间控制的因素。




图1 区间控制示意图

Fig.1 Diagram of interval controlling

1.1.2 影响区间控制的因素分析

区间控制下各时刻储能电站的工作模式、充放电功率均由区间上限 P_{d1} 和下限 P_{d2} 与原负荷的大小关系决定,而区间上下限值的确定则与储能电站容量、最大充放电功率、日负荷曲线特性以及单位时间长短相关。

(1) 储能容量及功率. BESS 的运行需满足容量及功率约束,任一时刻的 BESS 电量要处于防过充/过放区间内,且单位时间充放电功率也要小于 BESS 最大充放电功率,即

$$\begin{cases} \mu S_{\max} \leq S_i \leq \lambda S_{\max} \\ |P_i| \leq P_{\max} \end{cases}, \quad (1)$$

式中: λ 和 μ 分别为 BESS 防过充和过放的可靠系数; S_{\max} 和 P_{\max} 分别为 BESS 的最大容量和最大充放电功率。

当 BESS 的 S_{\max} 和 P_{\max} 增大时,单位时间内可充电或放电的功率增大,在负荷谷(峰)期可连续多时刻进行充(放)电工作,使得区间上下限的差值随之减小。当 S_{\max} 和 P_{\max} 足够大时,区间上下限差值接近零,即变为定边际负荷控制^[1]。

(2) 日负荷曲线特性. 在 BESS 参数相同的情况下,不同的日负荷曲线会得到不同的控制区间。日负荷曲线的峰谷差、峰谷出现时段等因素均会影响控制区间的确定。此外, BESS 的运行不仅要考虑容量和功率最大值的约束,还要考虑周期内充放电平衡问题以及充放电行为在时间上的约束(放电量需来自先前时刻的充电行为),因此日负荷曲线的峰谷期在周期内交替出现的次数同样会影响控制区间的确定,这也是笔者要着重解决的问题。

(3) 单位时间 Δt . 若 BESS 的工作周期为 24

h, 将其均分为 n 个时段, BESS 工作的单位时间为 Δt , 则各充放电时段的充放电量可表示为:

$$\begin{cases} S_{C_i} = \sum_{t_{si}}^{t_{ei}} |P_{d2} - P_C| \cdot \Delta t, \\ S_{D_j} = \sum_{t_{sj}}^{t_{ej}} |P_D - P_{d1}| \cdot \Delta t, \end{cases} \quad (2)$$

其中, P_C 和 P_D 分别为日负荷曲线中低于区间下限和高于区间上限的负荷值; t_{si} 和 t_{ei} 分别为各充放电时段开始和结束时刻。

当日负荷曲线各时刻的自相关性较强时(临近时刻的负荷值波动较小), Δt 的取值对区间值的影响较小。

1.2 改进区间控制模型及求取方法

1.2.1 改进的区间控制模型

针对日负荷曲线在单个周期存在多个充放电时段的问题, 不仅要考虑每个时段的储能容量约束, 还要考虑每个充放电循环后的充放电平衡约束, 为此提出以下改进的区间控制模型:

$$\begin{cases} S_{C_i} + S_{R_{i-1}} \leq \lambda S_{\max}, & 1 \leq i \leq N, \\ S_{D_i} \leq (1 - \mu) \eta S_{\max}, & 1 \leq i \leq M, \end{cases} \quad (3)$$

$$\begin{cases} S_{R_{i-1}} \geq 0, & 1 < i \leq M \\ \eta \sum_{i=1}^M S_{C_i} = \sum_{i=1}^M S_{D_i} \end{cases}, \quad (4)$$

$$S_{R_{i-1}} = \sum_{i=1}^{i-1} S_{C_{i-1}} - \sum_{i=1}^{i-1} S_{D_{i-1}} / \eta, \quad (5)$$

式中: S_{C_i} 为第 i 个充电时段的总充电量; S_{D_i} 为第 i 个放电时段的总放电量; $S_{R_{i-1}}$ 表示先前时段总充电量与总放电量的差值, 即当前时刻的剩余电量; η 为能量转换效率; N 和 M 分别为充、放电时段的个数。根据上述定义及日负荷曲线的特性分析可知, 充电时段会优先出现且充放电时段交替出现, 故充电时段个数 N 和放电时段个数 M 的关系为 $N = M$ 或 $N = M + 1$ 。

式(3)和(4)分别为容量和充放电平衡约束。式(3)中第一式表示任一时段的总充电量与剩余电量之和需满足储能电站的防过充约束; 第二式表示任一时段的总放电量需满足储能电站的防过放约束。式(4)中第一式表示各时段的充电量与剩余电量之和需满足下一时段的放电需求; 第二式表示周期内的总充电量和放电量需保持均衡, 即经过一个运行周期后的储能电量需保持在工作前的初始电量, 保证储能电站在下一个周期正常工作。

1.2.2 区间求取方法

储能电站充放电的时段及不同时段

量均由预设区间决定, 区间上限 P_{d1} 和下限 P_{d2} 可由以下迭代方法求取, 具体迭代过程为: 根据日负荷曲线求得日平均负荷值 P_d , 以 P_d 为中心, 令 $P_{d1} = P_d + \Delta P$ 、 $P_{d2} = P_d - \Delta P$ 作为区间的上下限初值。

迭代过程可分为两部分。①满足储能容量约束。首先判断每一个充电时段的容量与剩余电量之和是否满足约束(式(3)中第一式), 若不满足, 则说明充电容量过大, 令区间下限 P_{d2} 下移 ΔP 重新进行迭代校验, 然后判断各放电时段的容量是否满足限值(式(3)中第二式), 若不满足, 则说明放电容量过大, 令区间上限 P_{d1} 上移 ΔP 重新进行迭代校验, 当式(3)的两个条件均满足时, 取该时刻的区间上下限值进行下一轮的迭代。②满足充放电平衡约束。首先定义一个周期内总充电量和总放电量的差值为 k , 判断 k 的绝对值是否小于预设值 ε , 若不满足, 则进一步判断 k 的正负, $k > 0$ 说明充电量大于放电量, 由于上一步迭代令区间满足了容量约束, 因此选择减少充电量, 即 $P_{d2} = P_d - \Delta P$; 若 $k < 0$ 说明放电量大于充电量, 为满足容量约束选择减少放电量, 即 $P_{d1} = P_d + \Delta P$, 用修正的上下区间进行下一次迭代。除此之外, 还需判断每个充电时段的充电量及上个时段的剩余电量之和是否满足下一放电时段的放电量(式(4)第一式), 若不满足, 则需要减少放电量, 即 $P_{d1} = P_d + \Delta P$, 当上述两个条件均满足时, 迭代完成, 此时的 P_{d1} 、 P_{d2} 即为区间的上、下限值。

1.2.3 改进区间控制策略的性能分析

经过上述迭代得到区间控制的上下限值后, 根据初始负荷与区间上下限值的




图2 区间控制优化效果

Fig.2 Results of interval controlling

从图2中可以看出, 采用区间控制方式可以

根据储能电站的实际容量及日负荷曲线灵活地制定充放电工作模式,通过在负荷低谷期充电、高峰期放电将日负荷曲线控制在一个预设的区间内,从而实现削峰填谷.从图 2 对比文献[1]区间控制和本文改进区间控制的优化效果可知,文献[1]由于仅考虑单个充放电时段,采用一个周期内充/放电电量之和作为第一次迭代的约束条件,而实际情况下充放电工作模式交替出现,使得储能电站每次充电时段后的电量不断被消耗,各时刻的实际容量并没有越过容量上限,笔者改进后区间控制的预设区间更小,这是因为充分利用了储能电站的容量.同时,任意时刻的放电电量需在先前时段进行充电,而文献[1]默认一个周期内仅存在一个充放电循环,未考虑多个充放电时段的先后关系,导致 21:00~22:00 的剩余电量不足,储能电站无法放电,影响了实际的削峰填谷效果.

从图 2 中可以看出,在求得储能的控制区间后,BESS 各时段的工作模式及出力大小可由区间上下限值与原负荷的大小关系求得,假设各时段的储能出力均服从正态分布,即可得出各时段储能出力的概率分布.

为了更好地利用风能,平抑风电引起的负荷波动,需要加设消纳风电出力的储能电站.然而,与配电网的负荷相比,风速的波动性和不可预测性更大,因此不能采用基于预测数据的区间控制方法.可以通过比较日平均负荷曲线与风力发电的日平均出力曲线得出风储设备的充放电时段及功率.

2 EV、风速及负荷的概率模型

根据文献[10],电动汽车开始充电时刻服从正态分布,而日行驶里程服从对数正态分布.假设车主最后一次出行结束后便开始为电动汽车充电,且充电功率恒定.

考虑分布式发电和负荷的随机性,风速的概率分布采用两参数 Weibull 分布进行拟合^[11],且风机出力与风速满足三段式的线性关系^[12],即

$$P_W(v) = \begin{cases} 0, & v < v_{in}, v > v_{out} \\ \frac{v - v_{in}}{v_N - v_{in}} P_{W_N}, & v_{in} \leq v \leq v_N \\ P_N, & v_N \leq v \leq v_{out} \end{cases}, \quad (6)$$

其中, v_N 为额定风速; P_{W_N} 为风机额定功率; v_{in} 为

切入风速; v_{out} 为切出风速.

根据统计配电网节点负荷通常服从正态分布^[13].确定 EV、风速、负荷及储能出力的概率模型后,可通过概率潮流进一步分析接入储能对配电网系统的影响.运用 $2m+1$ 点估计法计算时,要求输入的随机变量间相互独立,有源配电网中不同风机的风速、系统各节点负荷间均存在一定的相关性.储能电站各时段的工作方式及出力大小由原负荷与区间上下限的大小关系决定,而区间则由储能电站的容量和日负荷曲线等因素决定,因此,储能的出力与配电网的负荷功率也具有一定的相关性.为满足点估计概率潮流对输入变量的要求,需要对各随机变量间的相关性进行处理.

3 概率潮流

针对各变量间存在的相关性,首先通过向量空间变换对随机变量的相关性进行处理,然后利用 $2m+1$ 点估计法进行概率潮流计算.

3.1 相关性处理

对于具有相关性的非正态随机变量,首先可利用 Nataf 变换^[14]将其从原空间转换为含相关性的标准正态空间,接着通过初等变换^[9]将其从相关正态空间转换为独立正态空间,然后在独立空间内采集所需的估计点,再通过初等变换和 Nataf 变换的逆变换将采集的估计点转换回原空间,最后进行 $2m+1$ 点估计概率潮流计算.

(1) Nataf 变换. $\mathbf{X}_w = (X_{w1}, X_{w2}, \dots, X_{wn})^T$ 是一组随机向量,随机变量的边际概率密度函数(probability density function, PDF) 为 $f(x_{wi})$ ($i = 1, 2, \dots, n$), 其累积分布函数(cumulative distribution function, CDF) 为 $F(x_i)$ ($i = 1, 2, \dots, n$). $\mathbf{Y} = (y_1, y_2, \dots, y_n)^T$ 为标准正态分布后的随机向量,其随机变量的 CDF 为 $\Phi(x_{wi})$ ($i = 1, 2, \dots, n$). 根据等效边际概率变换原理可以得出:

$$\begin{cases} \Phi(y_{wi}) = F(x_{wi}) \\ y_{wi} = \Phi^{-1}(F(x_{wi})) \end{cases} \quad i = 1, 2, \dots, n. \quad (7)$$

(2) 初等变换.通过 Nataf 变换到正态分布空间后,初等变换可以消除任意两个随机变量之间的相关性.根据三个引理^[9],可由式(8)将随机向量由相关正态空间转换到独立正态空间,即:

$$\mathbf{Z} = \mathbf{Y} \cdot \text{diag}(\sigma_{y_1}^{-1}, \sigma_{y_2}^{-1}, \dots, \sigma_{y_n}^{-1}) \mathbf{Q}, \quad (8)$$

其中, $\sigma_{Y_i}^{-1} (i=1,2,\cdots,n)$ 是随机变量 Y_i 的标准差倒数; $\text{diag}()$ 是对角矩阵; \mathbf{Q} 是随机向量 \mathbf{Y} 的特征向量矩阵。

3.2 点估计理论

通过变量相关变换得到 $2m+1$ 点估计法所需的随机输入变量后,采用 $2m+1$ 点估计法进行 PLF 计算。PLF 问题可以由输出随机变量与输入随机变量之间的关系来表述,即

$$\mathbf{Z} = \mathbf{F}(\mathbf{X}), \quad (9)$$

式中: \mathbf{Z} 是与电压相关的输出变量; $\mathbf{X} = (X_1, X_2, \cdots, X_n)^T$ 为输入变量。

$2m+1$ 点估计法通过采集 3 个估计点来估计随机变量,输出变量 \mathbf{Z} 的 j 阶矩为:

$$E(V^j) \cong \omega_0 [F(\mu_1, \mu_2, \cdots, \mu_n)]^j + \sum_{i=1}^n \sum_{k=1}^2 \omega_{i,k} [F(\mu_1, \mu_2, \cdots, X_{i,k}, \cdots, \mu_n)]^j, \quad (10)$$

$$\sigma_V = \sqrt{E(V^2) - E(V)^2}, \quad (11)$$

式中: $X_{i,k}$ 为估计点; μ_i 为输入变量 X_i 的均值; ω 为权重。

3.3 算法流程

风速 X_W 、EV 充电功率 X_{EV} 、系统负荷 X_L 以及储能出力 X_{BESS} 组成概率潮流的输入向量 $\mathbf{X} = (X_W, X_{EV}, X_L, X_{BESS})$, 首先应用 Nataf 变换将 X_W 由非正态相关空间转换到正态相关空间,再通过初等变换将正态变量由正态相关空间转换到正态独立空间,然后采集估计点 \mathbf{Z}_i 并通过逆变换将估计点变换回各自原空间,最后运用 $2m+1$ 点估计法进行概率潮流计算,算法流程如图 3 所示。

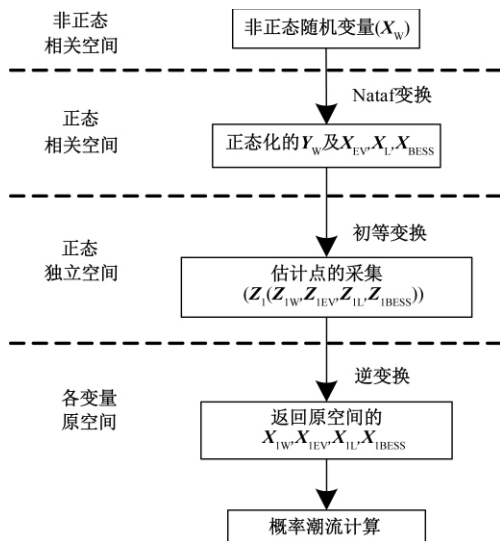


图3 向量空间变换流程图

Fig.3 Flow chart of vector space transformation

4 算例分析

笔者在改进的 IEEE-33 节点系统上进行实验,系统容量为 $3715+j2\ 300$ kVA,基准容量为 10 MVA,基准电压为 12.66 kV,松弛节点的电压值为 1(p.u.),负荷、电动汽车、风电和蓄电池储能电站作如下处理。

①设负荷服从正态分布,典型日负荷值作为期望,按 5% 的期望设定标准差,各节点负荷的相关系数为 0.9。

②3 个风电场分别连接到节点 15、25 和 30。每个风电场由两个额定功率为 100 kW 的双馈感应风力发电机组成。3 个风电场的相关系数矩阵^[15]如下:

$$\rho = \begin{bmatrix} 1 & 0.88 & 0.87 \\ 0.88 & 1 & 0.85 \\ 0.87 & 0.85 & 1 \end{bmatrix}. \quad (11)$$

③所有 EV 接到节点 7,充电功率服从正态分布,电动汽车的数量为 150 辆。

④共设 4 个蓄电池储能电站:其中 3 个采用改进的区间控制策略针对负荷进行削峰填谷,一个针对风电消纳风机出力。针对负荷的 BESS 中两个接入节点 18,另一个接入节点 33;用于消纳风能的 BESS 接到节点 32,根据典型日负荷曲线和风机的日平均出力曲线,规定其在每日的 2:00~6:00 时充电,在 11:00~12:00 及 16:00~18:00 两个高峰时段放电。BESS 的容量均为 $500\text{ kW}\cdot\text{h}$,最大功率为 300 kW,防过充和过放的可靠系数 λ 、 μ 分别为 0.9、0.1^[16],能量转换效率 η 为 0.9。设不同时间段的储能出力均服从正态分布,表 1 为蓄电池储能电站的充放电功率与系统其他变量在不同时刻的相关系数(表 1 中的相关系数通过储能出力曲线与负荷曲线获得)。

表 1 储能出力与其他变量的相关系数

Tab.1 Correlation coefficients between BESS outputs and other variables

时刻	5:00	11:00	17:00	23:00
负荷	0.87	0.87	0.80	0.34
风速	0.30	0.76	0.71	—

4.1 储能接入对功率及电压的影响分析

为了分析分布式发电接入和蓄电池储能电站接入对系统电压和功率的影响,考虑如下 3 种场景:①仅考虑原始负荷;②考虑分布式发电及电动汽车的接入;③考虑分布式发电、电动汽车和储能

的接入.

(1) 储能接入对系统功率的影响

3 种场景下通过系统母线变压器的功率期望曲线如图 4 所示.从图 4 中可以看出峰谷差的期望分别为 42.35%、59.92%、32.67%.接入分布式发电整体上降低了通过配电网母线的功率,减少了发电机的备用容量,但由于风速时间分布不均导致风机在不同时刻的出力差异较大,加剧了系统的峰谷差.通过引入蓄电池储能电站有效地降低了系统的功率波动,可以看出应用改进的区间控制策略达到了明显的削峰填谷效果.




图 4 系统母线功率期望

Fig.4 Power expectation of the system bus

(2) 储能接入对系统电压的影响

基于以上数据,通过概率潮流分析各场景下的系统节点电压.图 5 为系统节点在日负荷高峰时段的电压期望值,由图 4 可知储能电站于负荷高峰期进行放电,等效于分布式发电,图 5 中高峰时期的系统各节点电压在并入分布式发电的基础上进一步提升,其中并入储能的末端节点电压提升效果最为明显.




图 5 15 时节点电压期望

Fig.5 Expectation of node voltage in hour 15

图 6 为节点 18 的电压 PDF.从图 6 中可以

看出,接入分布式发电使电压的 PDF 整体右移,总体上对系统电压起到抬升作用,但也使 PDF 在横坐标上的跨度增大,增大了电压的波动性和不确定性.由于蓄电池储能电站在负荷高峰时段放电,等效于分布式发电,从而进一步提高了节点电压,降低了末端节点在负荷高峰期电压下限的风险,提高了系统的安全性.同时在负荷低谷时段作为负荷进行充电,降低了系统电压在时间上的波动,提高了系统的稳定性.




图 6 节点 18 的电压幅值 PDF

Fig.6 Voltage amplitude PDF of node 18

4.2 PEM 精度分析

通过将 PEM 结果与 MCS 对比进一步来验证采用改进区间控制后考虑 BESS 相关性的 PEM 精度,表 2 列出了这两种方法在不同时刻部分节点的电压计算结果.从表 2 中可以看出,与 MCS 相比,PEM 的均值误差小于 0.5%,标准差误差小于 8%,可见采用 $2m+1$ 点估计法进行概率潮流计算的结果可靠,相对 MCS 法节省了大量的计算时间.

5 结论

笔者提出了一种改进的储能区间控制方法以解决 BESS 一个周期内多次充放电问题,运用 Nataf 变换和 ET 变换处理变量相关性并采用 $2m+1$ 点估计概率潮流进一步分析 BESS 接入对电压水平的影响.在改进的 IEEE-33 系统上进行实验验证,结果表明,运用改进区间控制方法的 BESS 接入不仅可以减小通过母线功率的峰谷差,还可以减小电压波动性,提高有源配电网运行的稳定性和可靠性.同时,考虑变量相关性的 $2m+1$ PEM 与 MCS 相比结果更精确有效.

表2 不同时段部分节点的电压均值及标准差

Tab.2 Voltage mean value and standard deviation of some nodes at different times

节点	参数	时段 5		时段 11		时段 17		时段 23	
		PEM	MCS	PEM	MCS	PEM	MCS	PEM	MCS
2	μ	0.998 2	0.998 2	0.997 4	0.997 4	0.997 5	0.997 5	0.997 7	0.997 7
	σ	0.000 1	0.000 1	0.000 1	0.000 1	0.000 1	0.000 1	0.000 1	0.000 1
12	μ	0.954 3	0.954 2	0.939 5	0.939 4	0.938 1	0.938 2	0.943 2	0.943 2
	σ	0.003 9	0.003 9	0.003 0	0.003 0	0.003 9	0.003 8	0.003 9	0.003 8
22	μ	0.994 7	0.994 7	0.992 0	0.992 0	0.992 3	0.992 3	0.993 0	0.993 0
	σ	0.000 2	0.000 2	0.000 2	0.000 2	0.000 3	0.000 3	0.000 3	0.000 3
32	μ	0.945 5	0.954 2	0.931 7	0.939 4	0.930 0	0.938 2	0.934 4	0.943 2
	σ	0.003 5	0.003 4	0.002 5	0.002 4	0.004 6	0.004 5	0.003 9	0.003 8

储能的接入不仅可以提高系统母线功率及电压稳定性,还会对系统运行的经济性产生影响,因此考虑系统运行稳定性及经济性,利用概率潮流进行储能电站的选址定容是今后非常有价值的研究方向。

参考文献:

- [1] 尚璿, 邹能灵, 刘琦, 等. 采用区间控制的蓄电池储能电站调峰运行控制策略 [J]. 电工技术学报, 2015, 30(16): 221-229.
- [2] CHAI W, LI Z, CAI X. Variable charge/discharge time-interval control strategy of BESS for wind power dispatch [J]. Turkish Journal of Electrical Engineering and Computer Sciences, 2015, 23(6): 1645-1659.
- [3] ZHANG F, WANG G B, MENG K, et al. Improved cycle control and sizing scheme for wind energy storage system based on multiobjective optimization [J]. IEEE Transactions on Sustainable Energy, 2017, 8(3): 966-977.
- [4] 马兴, 李俊杰, 黎博, 等. 分布式储能参与电压暂降补偿的优化配置与控制策略 [J]. 郑州大学学报 (工学版), 2018, DOI: 10.13705/j.issn.1671-6833.2019.02.023.
- [5] PRUSTY B R, JENA D. A critical review on probabilistic load flow studies in uncertainty constrained power systems with photovoltaic generation and a new approach [J]. Renewable & Sustainable Energy Reviews, 2017, 69: 1286-1302.
- [6] JORDEHI A R. How to deal with uncertainties in electric power systems? A review [J]. Renewable & Sustainable Energy Reviews, 2018, 96: 145-155.
- [7] 艾小猛, 文劲宇, 吴桐, 等. 基于点估计和 Gram-Charlier 展开的含风电电力系统概率潮流实用算法 [J]. 中国电机工程学报, 2013, 33(16): 16-22.
- [8] LI X, ZHANG X, WU L, et al. Transmission line overload risk assessment for power systems with wind and load-power generation correlation [J]. IEEE Transactions on Smart Grid, 2015, 6(3): 1233-1242.
- [9] 李雪, 陈豪杰, 杜大军. 多时段及变量相关情形下电动汽车充/放电对有功配电网电压水平影响研究 [J]. 中国电机工程学报, 2018, 38(2): 526-536.
- [10] QIAN K J, ZHOU C K, ALLAN M. Modelling of load demand due to EV battery charging in distribution systems [J]. IEEE Transactions on Power Systems, 2011, 26(2): 802-810.
- [11] CAO Y J, ZHANG Y, ZHANG H X, et al. Probabilistic optimal PV capacity planning for wind farm expansion based on NASA data [J]. IEEE Transactions Sustainable Energy, 2017, 8(3): 1291-1300.
- [12] 李雪, 单伟璐, 杜大军, 等. 考虑需求侧管理和 DG 渗透率的主动配电网网架双层规划研究 [J]. 中国科学(信息科学), 48(10): 1333-1347.
- [13] RAN X H, MIAO S H. Three-phase probabilistic load flow for power system with correlated wind, photovoltaic and load [J]. IET Generation Transmission & Distribution, 2016, 10(12): 3093-3101.
- [14] CHEN Y, WEN J Y, CHENG S J, et al. Probabilistic load flow method based on Nataf transformation and latin hypercube sampling [J]. IEEE Trans on Sustainable Energy, 2013, 4(2): 294-301.
- [15] AKBARI M A, AGHAEI J, BARANI M. New metrics for evaluating technical benefits and risks of DGs increasing penetration [J]. IEEE Trans. Smart Grid, 2017, 8(6): 2890-2902.
- [16] 罗煜, 黄梅, 鲍彦, 等. 基于储能 SOC 优化控制的风储电站实时跟踪发电计划控制策略 [J]. 电工技术学报, 2016, 31(21): 214-220.

(下转第 50 页)

文章编号: 1671-6833(2019)05-0038-06

基于 GRU 网络的配电网故障数量等级预测方法

高金峰¹, 庞昊¹, 杜耀恒²

(1. 郑州大学 产业技术研究院, 河南 郑州 450001; 2. 国家电网烟台供电公司, 山东 烟台 264000)

摘要: 配电网故障数量的多少直接影响配电网的运行维护与用户的用电体验, 目前业界关于配电网故障数量等级预测的研究较少. 给出了一种基于 GRU 网络的配电网故障数据分析与故障数量等级预测方法. 通过条件熵来衡量配电网故障数量等级的历史依赖性, 采用距离相关系数对诸多气象特征因素进行相关性强弱考察, 筛选出最优特征子集, 最后通过训练 GRU 网络实现了配电网故障数量等级的预测. 算例结果证明了预测方法的有效性.

关键词: 配电网故障数量等级; 循环神经网络; GRU 网络; 历史依赖性; 相关性

中图分类号: TM755

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.007

0 引言

据统计, 80% 以上的用户停电事故是配电网故障导致的^[1]. 我国配电网运维检修普遍存在检修工作量大、检修时间紧等问题^[2]. 作为一种辅助最优决策与调度的手段, 配电网故障数量等级评估与预测对提升检修效率、科学调配人力资源具有现实意义.

导致配电网故障的因素分为内部因素和外部因素. 内部因素包括设备及线路老化程度、性能参数^[3], 部分指标难以量化, 并且由于各地配电网智能化、信息化程度不一, 造成了数据积累匮乏, 使得数据难以被全部、准确地采集并使用; 外部因素包括社会、季节及各种气象因素, 在恶劣气象条件下, 更易发生配电网故障^[3-4]. 我国早已建立了完整的气象观测体系, 气象及季节因素相对容易量化, 获取数据的途径更具普适性和便捷性.

国内外关于此类问题的研究, 大致可以分为基于统计和基于数据两大类, 研究外部因素的影响居多. 文献[5]针对电压、电流等内部因素, 提出了基于长短期记忆网络(long short-term memory, LSTM)与支持向量机(support vector machine, SVM)的预测方法; 文献[6]则针对气象等外部因素, 提出了一种基于 SVM 的预测方法; 文献[7]主要研究了风暴气象下配电网故障的预测方法; 文献[8-9]基于

统计的方法提出了一种在恶劣气象条件下配电网故障的预测方法; 文献[10-13]分别基于多元线性回归、时间序列、随机森林等算法建立了计及气象因素的预测模型. 上述研究中, 基于统计的方法建模环节繁琐, 在实际的社会、自然及电力系统环境中, 模型的鲁棒性较差; 其他诸如机器学习等基于数据的方法, 虽然在处理非线性问题的鲁棒性方面优于传统方法, 但其在处理大数据、挖掘深层关系上捉襟见肘.

在电力系统其他领域的研究中, 文献[14]采用 LSTM 神经网络算法, 实现了对电力变压器的运行状态预测. 文献[15]提出了一种基于门控循环单元网络与卷积神经网络(convolution neural network, CNN)的风电功率预测方法. 以上研究采用了基于循环神经网络(recurrent neural network, RNN)的 LSTM、门控循环单元网络(gated recurrent Unit, GRU)等算法. 循环神经网络以其在处理时间序列方面的出色表现^[16], 已经被用于研究电力系统的部分问题, 但尚未被用于配电网故障数量等级预测等相关问题.

针对预测精确度有待提高、内部因素原始数据获取困难等问题, 结合深度学习、数据挖掘技术现状, 笔者提出了一种基于 GRU 网络的配电网故障数据分析与故障数量等级预测方法. 该方法以气象、季节因素为研究对象, 通过数据分析、特征

收稿日期: 2018-12-17; 修订日期: 2019-03-11

作者简介: 高金峰(1963—), 男, 河南项城人, 郑州大学教授, 博士, 主要研究方向为电工理论与新技术, E-mail: jfgao@zzu.edu.cn.

筛选、训练GRU网络等步骤实现预测,算例结果证明了方法的有效性。

1 数据分析与特征筛选

1.1 数据预处理

(1) 数据聚类.为了便于和文献[6]作对比,根据配电网故障数据实际分布情况,笔者将离散的原始配电网故障数量聚类为0~5、6~10及10次以上3个等级,分别对应等级1、等级2和等级3。

(2) 归一化.气温数据存在正值和负值,降水量数据也较为离散,采用公式(1)对上述两类数据进行归一化。

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (1)$$

式中: x 为归一化前的数据; x_{\max} 和 x_{\min} 为原始数据中同类数据的最大值和最小值。

(3) 特征映射.季节因素常用文字描述,需要量化为数字形式,转换规则如表1。

表1 季节因素的转换规则

Tab.1 Transformation rules of seasonal factors

季节	转换规则	转换形式
春季	连续7日日平均气温在10℃以上	1
夏季	连续7日日平均气温在23℃以上	2
秋季	连续7日日平均气温在22℃以下	3
冬季	连续7日日平均气温在9℃以下	4

1.2 历史依赖性分析

电力系统在大多数情况下都保持运行状态,为了判断当前配电网故障数量等级与历史故障数量等级间的联系,笔者采用条件熵来衡量历史依赖性的强弱.定义配电网故障数量等级的条件熵为:

$$H(S|N) = - \sum_{q=1}^n \sum_{j=1}^k (p(n_q, s_j) \lg(p(s_j|n_q))), \quad (2)$$

式中: S 为配电网故障数量等级,分为等级1、等级2和等级3,即 $S = \{s_1, s_2, s_3\}$; N 为聚类后的故障数量等级时间序列, $N = \{n_1, n_2, \dots, n_n\}$ 代表 n 天前的故障数量等级数列; $p(n_q, s_j)$ 为 n_q, s_j 的联合分布概率; $p(s_j|n_q)$ 为 s_j, n_q 的条件概率. $H(S|N)$ 越小,说明在此条件下,配电网故障数量等级的不确定性越低,越容易预测,反之说明不确定性越高。

1.3 相关性分析

采用距离相关系数来衡量特征因素与配电网故障数量等级间的相关性强弱,以此来剔除冗余的特征因素,确定最优特征子集.因笔者无法收集

到足够充足有效的内部因素数据,此处特征因素仅指气象因素,此法对于内部因素数据同样适用。

距离相关系数是皮尔斯相关系数的改进,克服了原方法只对线性相关性敏感的短板,且不需要任何假设的前提条件,使得其无论在线性或者非线性相关性分析中均有广泛的应用。

定义两个变量 M 和 V , 其间的距离相关系数定义为 $dCor(M, V)$. $dCor(M, V)$ 为0,说明 M 和 V 相互独立; $dCor(M, V)$ 越大,说明 M 和 V 的相关性越强. $dCor(M, V)$ 的计算公式如下:

$$dCor(M, V) = \left(\frac{dCov(M, V)}{\sqrt{dCov(M, M) dCov(V, V)}} \right)^{1/2}. \quad (3)$$

当上式分母中一项或者全部为0时,经验距离协方差 $dCov(M, V)$ 计算公式如下:

$$dCov(M, V) = \frac{1}{n^2} \sum_{k,l=1}^n M_{kl} \cdot V_{kl}; \quad (4)$$

$$M_{kl} = m_{kl} - \hat{m}_k - \bar{m}_l + \bar{m}; \quad (5)$$

$$\bar{m}_k = \frac{1}{n} \sum_{l=1}^n m_{kl}; \quad (6)$$

$$\bar{m}_l = \frac{1}{n} \sum_{k=1}^n m_{kl}; \quad (7)$$

$$\bar{m} = \frac{1}{n^2} \sum_{k,l=1}^n m_{kl}; \quad (8)$$

$$m_{kl} = |M_k - M_l|_p, \quad (9)$$

其中, $M \in R^p$, 对于 $V \in R^q$ 计算公式类似。

2 GRU网络及其训练

2.1 网络结构

GRU网络是RNN的一种变体,实际中单纯的RNN网络结构很容易出现梯度消失或梯度爆炸问题。

GRU网络可以解决RNN的前述问题. GRU网络的隐藏层单元结构如图1. 包含重置门 r_t 和更新门 z_t 两个状态门, 通过控制状态门的权重在0~1变化, 实现对“历史记忆”的加强与遗忘. 具体的公式表示如下:

$$r_t = \sigma(U_r \cdot x_t + W_r \cdot h_{t-1}); \quad (10)$$

$$z_t = \sigma(U_z \cdot x_t + W_z \cdot h_{t-1}); \quad (11)$$

$$H_t = \tanh[U_h \cdot (r_t \cdot h_{t-1}) + W_h \cdot x_t]; \quad (12)$$

$$h_t = (1 - z_t) \cdot H_t + z_t \cdot h_{t-1}; \quad (13)$$

式中: h_t 为候选隐藏层状态; \tanh 为隐藏层激活函数, 其他符号含义与前述相同。

笔者构建的3层神经网络架构如图2, 将外部因素序列作为数据输入, 通过3层GRU神经网络




图1 GRU的隐藏层单元结构

Fig.1 Hidden layer unit structure of GRU

络进行前向计算,挖掘数据纵向时序联系以及横向非线性关系,最终通过 Softmax 分类器根据最大概率准则得出配电网故障数量等级预测结果。

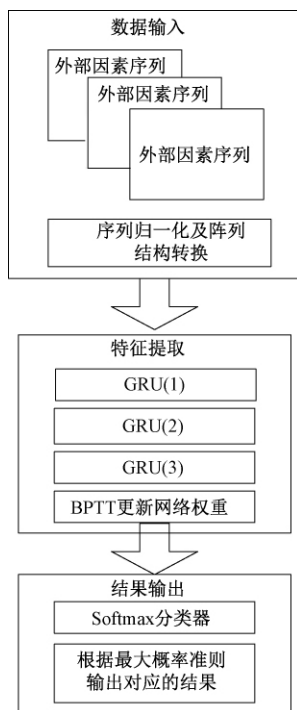


图2 网络构架

Fig.2 Network architecture

2.2 训练网络

将筛选后的特征变量与每日配电网故障数据整合至同一数据库中,便于统一输入网络,数据格式统一采用科学计数法.再将集成后的数据集随机拆分为训练集和测试集,为了避免训练集数目不同造成不同故障等级学习及预测效果的差异,根据前述第2部分中配电网故障数量的3个等级,每个故障数量等级各对应相同组数据作为训练集,对网络采用有监督学习的方式进行训练,并采用沿时间反向传播算法(back propagation trough time, BPTT)更新网络权重以及(root mean square prop, RMSprop)优化算法进行梯度优化。

网络的超参数主要包括网络层数、隐藏层神经元个数、输出层神经元个数和学习率.鉴于笔者采集的原始数据量有限,为避免梯度消失过早,采用了较小的学习率进行训练.经过对不同的结构搭配及超参数调试,最终的网络由3层隐藏层和1层 Softmax 全连接输出层堆叠而成.其中,隐藏层的激活函数采用 tanh, units 值分别为 64、32 和 16, dropout 为 0.4, Softmax 输出层 units 为 3, learning rate 为 0.005, 学习轮数为 1 000。

2.3 评估网络

笔者采用精确度 A (accuracy)、查准率 P (precision) 和查全率 R (recall) 来评估网络的分类预测能力,定义 N_{TP} 、 N_{FP} 、 N_{TN} 和 N_{FN} 分别为每个故障数量等级预测结果中真正例、假正例、真反例和假反例的数量.计算公式如下:

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FN} + N_{FR} + N_{TN}}; \quad (14)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}; \quad (15)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}. \quad (16)$$

3 算例及结果分析

3.1 原始数据分析及历史依赖性分析

数据来源于国家电网华东某地级市供电公司 10 kV 配电网故障抢修日志,2005 年 1 月至 2010 年 12 月期间,该地级市 10 kV 配电网故障次数共 4 115 次,每月故障数量统计如图 3.这些故障可以分为状态故障、设备故障和客户内部故障 3 大类,具体比例如图 4.客户内部故障虽然主要由客户自身原因导致,但考虑到会对局部配电网造成一定的影响,故在统计时保留此部分故障。




图3 每月故障数量统计趋势

Fig.3 Monthly failure statistics trend

由图3、图4可得,该地级市配电网的故障数量根据月份、季节不同呈现一定的规律,而时间、季节与气象因素有较为直接的因果关系.其中六、




图 4 故障类型

Fig.4 Fault type

七、八三月份及一月、十二月份的故障数量达到半年内局部最大值,三、四及十月为半年内局部最小值.这与该地级市根据季节、温度变化的生产生活规律相符.

配电网故障数量等级的条件熵如图 5 所示.由图 5 可知,条件熵随着 n 的增大呈下降趋势,即配电网故障数量等级对历史数据有较大的依赖,随着历史数据的增加,配电网故障数量等级可预测性逐渐增强,挖掘时间序列的前后关系正是 RNN 及 GRU 网络的优势.由此进一步印证

了笔者所研究的问题与算法之间的匹配性与适用性.




图 5 不同天数情况下的条件熵

Fig.5 Conditional entropy under different days

3.2 气象因素的距离相关系数

气象因素主要包括气温、气压、风速、风向、降水量、相对湿度和光照小时数 7 种.笔者根据国家气象信息中心网站获取的历史气象数据,7 种气象因素的距离相关系数计算数值从大到小排列如表 2,根据统计学经验及惯例,可以认为距离相关系数计算值小于同批次最大值 25% 的因素与配电网故障数量具有弱相关性,故将气压、风向、日照小时数剔除,由此确定出气象因素的最优特征子集为气温、风速、降水量、相对湿度.值得说明的是,由于配电网所处的地区不同、数据特征不同,各气象因素的相关性强弱也可能与本研究不尽相同.

表 2 各气象因素的距离相关系数

Tab.2 The distance correlation of meteorological factors

气象因素	气温	降水	风速	相对湿度	气压	风向	日照小时	参考阈值
dCor	0.786	0.613	0.549	0.396	0.136	0.106	0.090	0.197

根据前述分析,故障数量的分布也与季节有关,在气象因素最优特征子集的基础上,引入季节组成下一步输入网络的特征集合.同时考虑到有相当一部分配电网故障是在夜间发生的,将气温、风速、降水量按照日间和夜间分别统计,即季节、日间最高气温、夜间最低气温、日间(夜间)最大风速、日间(夜间)最小风速、日间(夜间)降水量、日间(夜间)相对湿度,共 11 种.

3.3 预测结果及评估

经过数据集成,利用 24 090 个经前述方法处理分析的数据训练、测试网络,经过 1 000 轮迭代后,网络在测试集上的精确度达到 80.41%.本节将针对网络的各项指标进行分析评估.

将前述网络与反向传播神经网络(back propagation neural network, BPNN) 及文献 [6] 所述支持向量机的对比.为保证与前述 GRU 网络构架参数相同, BPNN 也采用 3 层隐藏层和 1 层 Softmax

全连接输出层,隐藏层的激活函数采用 tanh, units 值分别为 64、32 和 16, dropout 为 0.4, Softmax 输出层 units 为 3, learning rate 为 0.005, 同样训练 1 000 轮, GRU 网络与 BPNN 的查准率与查全率对比如表 3, 精确度如图 6. 从表 3 可以看出, GRU 网络在 3 个故障数量级的评价指标上均优于 BPNN, 说明 GRU 网络对不同类别的样本均有较好的适应性. 由图 6 可以看出在相同数据集的情况下, BPNN 的预测精确度停留在较低的水平. 这是由于 BPNN 是将动态的时间序列转换至静态空间建模, 与 RNN 及 GRU 有本质区别, 难以充分挖掘时间序列内部历史关系. 也从侧面印证了前述对于配电网故障数量等级历史相关性分析的正确性.

图 7 为 GRU 与文献 [6] SVM 算法的精确度对比. SVM 算法基于 Scikit-learn 机器学习框架实现, 根据文献 [6] 所述, 采用高斯径向基核函数,

表 3 查准率与查全率的对比

Tab.3 Comparison between precision rate and recall rate /%

类别	GRU			BPNN		
	1	2	3	1	2	3
查准率	79.28	81.92	77.66	57.13	48.57	60.03
查全率	64.89	72.12	76.20	52.59	56.82	50.26




图 6 GRU 与 BPNN 的对比

Fig.6 Comparison of GRU and BPNN

gamma 为 0.34, C 为 30.可以看出在相同的分类条件下,GRU 网络相较于 SVM 算法,在精确度上有一定的提高,尤其是在 3 分类的精确度上,提升了约 10 个百分点,但由于笔者仅以外部因素为研究对象及输入特征,以及特征维度及数据集大小的原因,预测精确度的提升也是有限的.




图 7 GRU 与 SVM 的对比图

Fig.7 Comparison of GRU and SVM

(1) 预测结果与网络深度的关系.笔者尝试增加网络的深度以期提升网络的预测精确度,经测试发现,在网络深度为 4 层时,精确度与 3 层网络几乎相同,但当网络深度为 5 层时,测试集精确度反而大幅下降,产生严重的过拟合问题.这是由于随着网络深度的增加,需要学习的网络参数陡增,而训练集大小及特征维度不能与之相匹配.

(2) 预测结果与特征选择的关系.根据表 1,现选取三组气象因素:第一组选取表 1 中全部气象因素,共 7 种;第二组选取相对湿度、气压、风向、日照小时数,共 4 种;第三组为前述根据距离相关系数法选取的 4 种气象因素,即气温、降水、风速、相对湿度.3 组特征除气象因素外,季节因素均相同,分别训练前述 GRU 网络,网络结构、参数及训练次数均与前述相同,测试集精确度如表 4.对比第一组

与第三组可得,在不剔除冗余特征的情况下,将增加网络训练工作量并降低预测精确度;对比第二组与第三组可得,选择具有强相关性的特征变量将显著提升网络的预测精确度,由此也印证了前述距离相关系数法的实际意义.

表 4 精确度对比

Tab.4 Comparison of accuracy rates %

组别	第一组	第二组	第三组
精确度	74.87	53.19	80.41

4 结论

(1) 所提方法在有效筛选故障特征的基础上,使用 GRU 网络能更加充分地利用多变量信息、挖掘时间序列历史关系,较 BPNN、SVM 等算法,提高预测精度.

(2) 如果采用数值天气预报等高精度、分时段、分区域的外部特征数据,在笔者所述方法的基础上,可以提高预测时效及精确度.

(3) 随着电网智能化、信息化程度的不断提升,将产生和积累海量的数据,笔者所提方法在处理大数据方面的优势将不断凸显;在外部因素的基础上,结合更多的配电网内部因素,可以增加 GRU 网络的深度,在预测配电网故障数量等级的基础上,为预测配电网故障风险等级提供有效途径.

参考文献:

- [1] BILLINTON R, WANG P. Reliability-network-equivalent approach to distribution-system-reliability evaluation [J]. Generation, Transmission and Distribution, 145(2): 149-153.
- [2] 张稳,盛万兴,刘科研,等.计及气象因素相关性的配电网故障风险等级预测方法[J].电网技术, 2018, 42(8): 2391-2398.
- [3] 刘科研,吴心忠,石琛,等.基于数据挖掘的配电网故障风险预警[J].电力自动化设备, 2018, 38(5): 148-153.
- [4] 马瑞,周谢,彭舟,等.考虑气温因素的负荷特性统计指标关联特征数据挖掘[J].中国电机工程学报, 2015, 35(1): 43-51.
- [5] ZHANG S L, WANG Y X, LIU Z J, et al. Data-based line trip fault prediction in power systems using LSTM networks and SVM [J]. IEEE Access, 2018 (3): 7675-7686.
- [6] BAI Y L, LI Y H, LIU Y G, et al. Short-term prediction of distribution network faults based on support vector

- machine [C]//Proceeding of the 2017 12th IEEE Conference on Industrial Electronics and Application, 2018: 1421-1426.
- [7] ZHU D, CHENG D L. Storm modeling for prediction of power distribution system outages [J]. Electric Power Systems Research, 2007, 77(8) : 973-979.
- [8] LIU H B, DAVIDSON R A, ROSOWSKY D V, et al. Negative binomial regression of electric power outages in hurricanes [J]. Journal of Infrastructure Systems, 2005, 11(4) : 258-267.
- [9] LIU H B, DAVIDSON R A, APANASOVICH T V. Spatial generalized linear mixed models of electric power outages due to hurricanes and ice storms [J]. Reliability Engineering and System Safety, 2008, 93(6) : 875-890.
- [10] 张鹏飞,瞿海妮,肖其师,等.基于气象因素和时间序列分析的配电网故障数量预测[J].陕西电力, 2016, 44(1) : 68-72.
- [11] 蔡冬阳,彭涛.基于多元线性回归的故障报修受理数量预测研究[J].江苏科技信息, 2016(20) : 61-65.
- [12] 程森海,楼俏,王琼,等.基于随机森林算法的配网抢修故障量预测方法[J].计算机系统应用, 2016, 25(9) : 137-143.
- [13] 王继业,魏晓菁,郝悍勇,等.基于灰色投影随机森林算法的配网故障量预测模型[J].自动化技术与应用, 2018, 37(4) : 75-78.
- [14] 代杰杰,宋辉,盛戈皞,等.采用LSTM网络的电力变压器运行状态预测方法研究[J].高电压技术, 2018, 44(4) : 1099-1106.
- [15] 牛哲文,余泽远,李波,等.基于深度门控循环单元神经网络的短期风功率预测模型[J].电力自动化设备, 2018, 38(5) : 36-42.
- [16] 赵淑芳,董小雨.基于改进的LSTM深度神经网络语音识别研究[J].郑州大学学报(工学版), 2018, 39(5) : 63-67.

A Method for Predicting the Number of Faults in Distribution Network Based on GRU Neural Network

GAO Jinfeng¹, PANG Hao¹, DU Yaoheng²

(1.Industrial Technology Research Institute, Zhengzhou University, Zhengzhou 450001, China; 2.State Grid Yantai Power Supply Company, Yantai 264000, China)

Abstract: The number of faults in distribution network was a direct impact on the operation and maintenance of distribution network and the user's power consumption experience. At present, there were few studies on the prediction of the number of faults in distribution network. To measure the historical dependence of distribution network fault magnitude, the optimal feature subset was selected by using the distance correlation coefficient to investigate the correlation of many meteorological features. Finally, the GRU neural network was trained to predict the fault magnitude of distribution network accurately. The results proved the feasibility of this method.

Key words: number of faults in distribution network; RNN; GRU neural network; historical dependence; relevance

文章编号: 1671-6833(2019)05-0044-07

基于 Bi-RNN 的风电机组主轴承温度预警方法研究

尹诗^{1,2}, 侯国莲¹, 于晓东¹, 李 宁¹, 王其乐², 弓林娟¹

(1. 华北电力大学 控制与计算机工程学院, 北京 102206; 2. 中能电力科技开发有限公司, 北京 100034)

摘 要: 主轴承是风电机组能量传递的关键设备, 本文以双馈风力发电机组主轴承为研究对象, 首先采用高斯混合模型 (gaussian mixture model, GMM) 对机组工况进行辨识; 其次在各个子工况空间内建立基于双向循环神经网络 (bi-directional recurrent neural network, Bi-RNN) 的风电机组主轴承温度模型; 然后, 采用随机森林算法对主轴承温度模型残差进行建模与预测, 从而实现机组主轴承故障预警; 最后以某大型风电场机组为对象建模并开展仿真研究. 结果表明, 基于工况辨识的 Bi-RNN 神经网络算法结合随机森林算法对主轴承故障预警具有较强的实用性和较高的准确率.

关键词: 风电机组; 主轴承; 工况辨识; Bi-RNN; 随机森林

中图分类号: TK83

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.008

0 引言

近年来, 风能在世界能源结构中的地位越来越突出, 风电将逐步成为火电、水电之后的第三大常规能源^[1]. 由于风电机组运行环境恶劣, 受气象、设备老化等多种不确定因素的影响, 容易出现性能劣化与运行状态恶化问题, 导致运维费用居高不下. 统计资料表明, 陆上和海上风电机组的运维费用分别占各自风电场收入的 10%~15% 和 20%~35%^[2]. 在风电机组故障统计中, 风电机组中发生电气和控制系统故障较为频繁, 但是平均故障修复时间 (mean time to repair, MTTR) 较短, 传动系统中的主轴承、齿轮箱、发电机等设备 MTTR 较长^[3-4]. 因此, 笔者通过风电机组主轴承温度预警来了解设备健康情况, 这对合理安排检修具有重要的实践意义.

文献 [5-8] 分别采用频域分析法和时域分析法对轴承或齿轮箱进行故障诊断分析, 但没有考虑故障劣化的渐变过程. 文献 [9] 基于主成分分析法建立了正常运行状态下轴承的温度预测模型, 并通过滑动窗口残差统计方法对故障进行有效预测, 该方法中阈值的设定增加了人为参与度. 文献 [10] 利用改进的集合经验模态分解方法构建轴承健康劣化度模型, 但模型未考虑时序数据故障

劣化渐变过程对故障预警模型的影响. 文献 [11] 利用非线性状态估计 (nonlinear state estimate technology, NSET) 方法建立齿轮箱正常工作状态下的温度模型并用其进行温度预测, 采用滑动窗口方法计算残差的统计分布特性, 当残差的均值或标准差的置信区间超出预先设定的阈值时, 认为齿轮箱工作状态异常, 该方法同样需要人为设定阈值判断故障情况. 文献 [12] 通过采集风电机组主轴转动频率、滚动体频率和保持架频率等参数, 利用深度置信网络模型对风电机组进行主轴承故障诊断, 输入训练样本, 逐层无监督训练达到局部参数最优, 反向微调使整体性能最优, 并用测试集数据进行验证, 该方法未考虑风电机组运行过程中数据会随季节发生长周期变化, 造成模型精度不高.

以上这些研究方法虽然对风电机组主轴承故障预警研究起到了促进作用, 但仍存在研究盲点:

第一, 算法模型多基于某段时间的采集与监视控制系统 (supervisory control and data acquisition, SCADA) 数据, 但风电机组运行过程中数据通常会随季节发生长周期变化, 这些变化有可能将故障早期形成过程中产生的数据变化淹没, 无法在真正意义上实现故障预警.

第二, 在建立时序数据模型过程中, 通常只考

收稿日期: 2018-12-27; 修订日期: 2019-02-21

基金项目: 中央高校基本科研业务费专项资金资助项目 (2019JG004); 国家自然科学基金资助项目 (61603136)

作者简介: 尹诗 (1988—), 男, 山东菏泽人, 华北电力大学博士生, 主要从事风电数据挖掘, E-mail: yinshi502@163.com.

考虑模型输入输出的非线性关系,很少考虑时序数据故障劣化的渐变过程对故障预警模型的影响。

第三,算法多采用人为设定阈值来评价风电机组故障状态,阈值设定不合理会导致模型预测精度不高、泛化性差的问题。

因此,笔者将 GMM、Bi-RNN 神经网络算法、随机森林算法相结合,提出一种风电机组主轴温度预警方法,使用 SCADA 数据和设备更换台账就能准确预警主轴故障。

1 预警方法设计

笔者以风电机组主轴为研究对象,将 GMM、Bi-RNN 神经网络算法、随机森林算法有机结合,开展主轴温度预警研究。

考虑到风电机组运行的工况不同,利用 GMM 对机组工况进行辨识,克服了气候周期性变化及气象条件瞬时变化对预警结果的影响,扩大了算法的时间尺度和适用范围。

考虑到机组设备故障劣化的渐变过程对模型精度的影响,利用 Bi-RNN 神经网络算法建立主轴温度模型,使之能够更加精准地预测以长时间序列数据为特征的故障劣化问题。

采用随机森林算法建立主轴故障预警决策模型,降低人为设定阈值引起的复杂性和不确定性,使得该预警方法更加有利于工程实际应用,具体方法框图如图 1 所示。

首先,将多台风电机组 SCADA 数据预处理,从中选取有效数据,确定 Bi-RNN 神经网络算法的输入数据和输出数据;再采用 GMM 对机组运行工况进行辨识,根据机组运行建立 3 个子工况空间;然后在每个子工况空间内建立基于 Bi-RNN 神经网络的主轴温度模型,并计算模型输出与 SCADA 数据之间的残差;最后将计算的残差按天提取残差特征向量,根据残差分布建立基于随机森林的主轴故障预警决策模型。将测试机组数据同样按照以上步骤进行计算,根据随机森林算法输出结果判断风电机组主轴异常情况。

2 算法原理及实现

2.1 基于 GMM 的风电机组工况辨识

GMM 是一种聚类算法,该算法利用高斯概率密度函数(正态分布曲线)精确量化的事物,是将一个事物分解为若干基于高斯概率密度的函数模型。某一高斯模型的概率密度函数为:

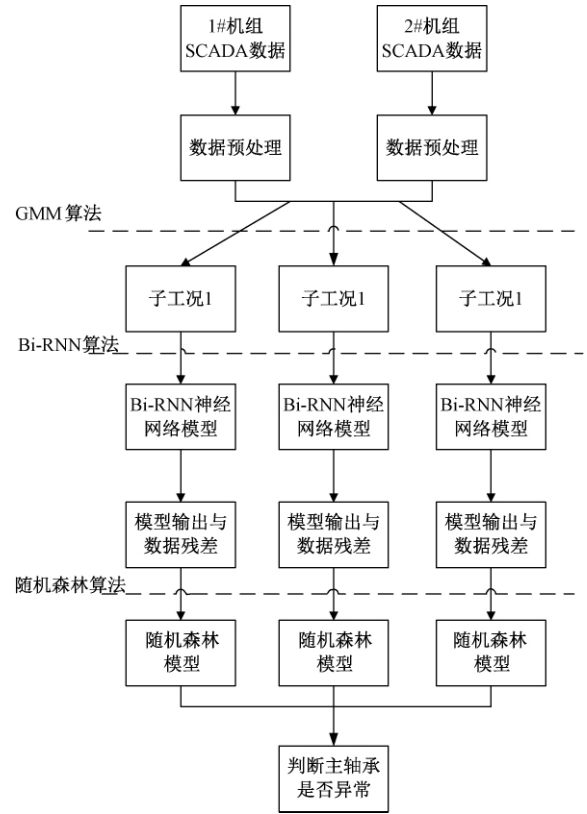


图 1 风电机组主轴温度预警建模方法结构图
(2 台风电机组示例)

Fig.1 Structure diagram of temperature prediction model for main bearing of wind turbine
(Examples of 2 wind turbines)

$$N(\mathbf{x} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{D/2} |\boldsymbol{\Sigma}|^{1/2}} \exp \left[-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right], \quad (1)$$

其中, \mathbf{x} 为 D 维向量; $\boldsymbol{\mu}$ 为 D 维均值; $\boldsymbol{\Sigma}$ 为 $D \times D$ 维协方差矩阵。

GMM 的概率密度函数为:

$$p(\mathbf{x}) = \sum_{k=1}^K \pi_k N(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k). \quad (2)$$

式中: K 为高斯混合模型中高斯模型数量; $\sum_{k=1}^K \pi_k = 1$ 且 $0 \leq \pi_k \leq 1$ 。

应用 GMM 对风电机组运行工况进行辨识,建立 3 个子工况空间,将生成的每个高斯模型中的数据期望值作为多维特征点,代表隶属于本高斯模型全部有效数据点的数据特征。

2.2 基于 Bi-RNN 神经网络的风电机组主轴温度模型

深度学习模型是一种拥有多个非线性映射层级的深度神经网络模型,能够对输入信号逐层抽象并提取特征,挖掘出更深层次的潜在规律^[13]。在众

多深度学习模型中,循环神经网络(recurrent neural network, RNN)将历史数据的时序特征引入到网络结构设计中,具有较强的适应性,如图2所示。

令第 t 时刻的输入为 $x_t \in R_{x\dim}$, 隐层节点的输出为 $h_t \in R_{h\dim}$, 输出层 $o_t \in R_{o\dim}$, 输入到隐层的权重矩阵 $U \in R_{x\dim \times h\dim}$, 隐层自循环的权重矩阵 $W \in R_{h\dim \times h\dim}$, 隐层到输出层的权重 $V \in R_{h\dim \times o\dim}$, 对应偏执向量分别为 $b_h \in R_{h\dim}$, $b_o \in R_{o\dim}$, 那么正向计算:

$$h_t = f(\text{net}_{ht}), \quad (3)$$

$$\text{net}_{ht} = x_t U + h_{t-1} W + b_h, \quad (4)$$

$$o_{th} = g(\text{net}_{ot}), \quad (5)$$

$$\text{net}_{ot} = h_t V + b_o, \quad (6)$$

其中, $\text{net}_{st}, \text{net}_{ot}$ 分别表示激活前对应的加权和; $f(\cdot), g(\cdot)$ 表示激活函数。




图2 RNN神经网络前向传播展开图

Fig.2 Expansion diagram of RNN neural network forward propagation

Bi-RNN神经网络如图3所示。输出由两个RNN的状态共同决定,算法既考虑时序数据的过去也考虑时序数据的将来,因此具有较强的时间特征。Bi-RNN神经网络在语言建模、视频行为分析、医学分析、图像识别等方面具有良好的应用^[14-18],在设备可靠性领域,劣化渐变过程对建立故障预警模型更为重要,因此,笔者将Bi-RNN神经网络算法引入到主轴温度预警建模过程中。




图3 Bi-RNN神经网络前向传播图

Fig.3 Diagram of Bi-RNN neural network forward propagation

Bi-RNN可以看作两个RNN的连接:一个是前向传播RNN,另一个是反向传播RNN。反向传

播RNN的计算公式为(7)~(10)。Bi-RNN输出由两个RNN的状态求和共同决定。

$$q_t = f(\text{net}_{qt}), \quad (7)$$

$$\text{net}_{qt} = x_t U + q_{t+1} W + b_h, \quad (8)$$

$$o_{tq} = g(\text{net}_{ot}), \quad (9)$$

$$\text{net}_{ot} = q_t V + b_o. \quad (10)$$

根据公式(5)得出Bi-RNN的前向输出为两个RNN的状态和:

$$o_t = o_{tq} + o_{th}. \quad (11)$$

Bi-RNN神经网络输入参变量选择与主轴承温度密切相关的7个参数。

①风速:传动系统的转速与风速正相关,相应的主轴承温度会发生变化。

②发电机转速:与主轴承转速正相关。

③有功功率:与主轴承温度正相关。

④风向角:风向角影响风电机组机舱对风的准确性,影响机组有功功率。

⑤环境温度:由于风电机组所处的环境温度差异,即使机组功率和风速相同时,环境温度的不同也会导致主轴温度有很大差异。

⑥发电机绕组温度:主轴承转速越高,发电机转速越高,发电机绕组温度相对较高。

⑦齿轮箱油温:主轴承转速越高,齿轮箱传动系统转速越高,齿轮箱油温和主轴承温度相对越高。

输入和输出数据将做归一化处理,归一化计算公式为:

$$x_t = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}}. \quad (12)$$

模型输入的参变量为数据的10分钟最大值、最小值、均值,输出数据选取10分钟均值。

模型参数选取时,设定输入层21个神经元,隐层设置4层记忆细胞,其中第一层100个神经元、第二层60个神经元、第三层35个神经元、第四层15个神经元,每一层的激活函数选择为线性整流函数(rectified linear unit, ReLU),输出层共1个神经元,激活函数为线性激活函数。

2.3 基于随机森林的主轴承故障预警决策

随机森林是一个包含多个决策树的分类器,并且输出的类别是由决策树的投票决定。随机森林算法框图如图4所示。将要分类的样本输入多个决策树,以少数服从多数的原则表决出这个样本的最终分类类型。

将风电机组主轴承温度模型输出与SCADA数据残差按天计算,得到残差向量的6个特征,分别是:模型残差向量最小值、模型残差向量最大

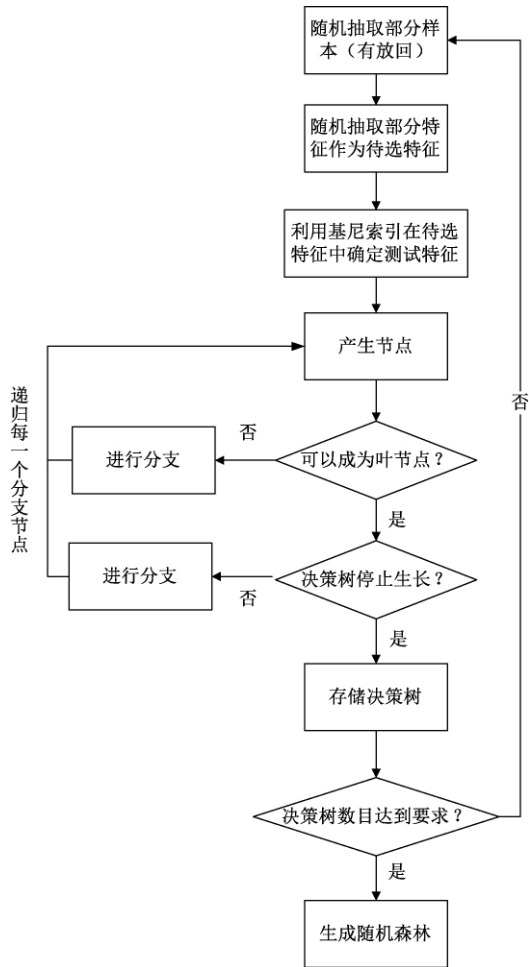


图 4 随机森林算法框图

Fig.4 Block diagram of random forest

值、模型残差向量平均值、模型残差向量中位数、模型残差向量标准差、模型残差向量欧氏距离.将该特征向量作为随机森林算法的输入,以是否为异常时间段标记值为随机森林算法的输出(1 代表正常,0 代表异常),样本设置为等权重,训练主轴轴承故障预警决策模型.

主轴轴承故障预警决策判定标准为: 将故障警戒线设置为 0.6,如果在一个月內随机森林算法输出有大量的数据点位于故障警戒线下且呈现出无反弹的特征,可以认为主轴轴承已发生磨损或已发生和主轴轴承温度相关的其他一些类似异常,反之判断主轴轴承正常.

3 实例分析及验证

笔者选用内蒙古某风电场 33 台 1.5 MW 双馈风力发电机组,切入风速为 3.5 m/s,切出风速为 25 m/s,在风速为 13 m/s 时进入恒功率阶段.选取 25 台主轴轴承正常运行的机组数据作为模型训练数据,每 1 台机组选取 1 个月数据,覆盖时间为全年,机组工况覆盖为切入风速到切

出风速的全工况.

为保证算法模型精度,将参与训练和测试的风电机组 SCADA 数据预处理,包括:剔除错位数据、噪声数据、停机数据,保留正常工况下的有效数据点,选取训练数据 30 103 条.

选取数据过程中,将风电机组升功率阶段中发电机恒转速阶段的 SCADA 数据去除,保留变速最大功率追踪阶段数据,其优点在于:①最大程度保留了风电机组动态参数丰富阶段的有效数据;②能避免因风力资源时间分布不均衡,尤其在风电机组长周期运行时,恒转速阶段风速差别较大的问题.

测试数据共选取 8 台风电机组数据,其中 4 台风电机组主轴异常,4 台风电机组主轴正常.A002 号机组和 A005 号机组由于主轴磨损严重分别在 2017 年 12 月 3 号和 12 月 15 号更换;A007 号机组由于主轴开裂于 2017 年 1 月 13 号更换主轴;A018 号机组由于主轴滚子表面剥落于 2017 年 5 月 1 日更换,选取每台机组更换主轴前 1 个月的运行数据为测试数据.

应用 GMM 对风电机组运行工况划分为 3 个子工况:工况 1 是风速较低、有功功率相对较低的工况;工况 3 是风速较大、有功功率相对较高的工况;工况 2 介于两种工况之间. GMM 建模结果如图 5 所示,每个工况的多维特征点如表 1 所示.




图 5 GMM 建模结果

Fig.5 GMM modeling results

表 1 某 GMM 生成的多维特征点

Tab.1 Multidimensional feature points generated by a GMM

多维特征点/工况	风速 / ($\text{m}\cdot\text{s}^{-1}$)	发电机转速 / ($\text{r}\cdot\text{min}^{-1}$)	有功功率 / (kW)
工况 1	4.53	1 060.4	134.9
工况 2	6.95	1 443.0	458.3
工况 3	9.74	1 723.0	1 135.7

在 3 个子工况下,分别使用 RNN 和 Bi-RNN 神经网络建立风电机组主轴承温度模型. RNN 与 Bi-RNN 训练误差对比见表 2,误差计算采用均方误差(mean-square error, MSE).

在模型训练过程中,尽管 RNN 神经网络在前几次训练中误差和收敛速率高于 Bi-RNN,但是很快 Bi-RNN 神经网络的收敛速率和训练误差均好于 RNN,这表明在同等条件下,Bi-RNN 神经网络算法训练精度优于 RNN 模型.

表 2 3 种工况下 RNN 和 Bi-RNN 训练误差

Tab.2 Training errors of RNN and Bi-RNN of three conditions

工况训练误差	RNN 迭代次数 (100 次)	Bi-RNN 迭代次数 (100 次)	RNN 迭代次数 (200 次)	Bi-RNN 迭代次数 (200 次)	RNN 迭代次数 (500 次)	Bi-RNN 迭代次数 (500 次)	RNN 迭代次数 (1 000 次)	Bi-RNN 迭代次数 (1 000 次)
工况 1	0.339 9	0.378 7	0.034 6	0.021 5	0.026 0	0.016 0	0.021 7	0.013 1
工况 2	0.277 7	0.357 5	0.041 8	0.023 8	0.027 2	0.017 6	0.021 8	0.013 0
工况 3	0.217 1	0.291 1	0.041 7	0.023 7	0.025 5	0.015 9	0.021 7	0.012 9

模型训练和测试结果如图 6 所示.图中红色虚线为机组主轴承温度模型输出,蓝色实线为训练数据的输出.绿色曲线为机组主轴承正常测试样本数据与模型输出之间的残差,蓝色曲线为机组主轴承异常测试样本数据与模型输出之间的残差.从图 6 中可以看出,当主轴异常时,以主轴温度为表征的模型输出和数据之间的残差增大,尤其是在工况 3 的时间序列后期这种残差更大.

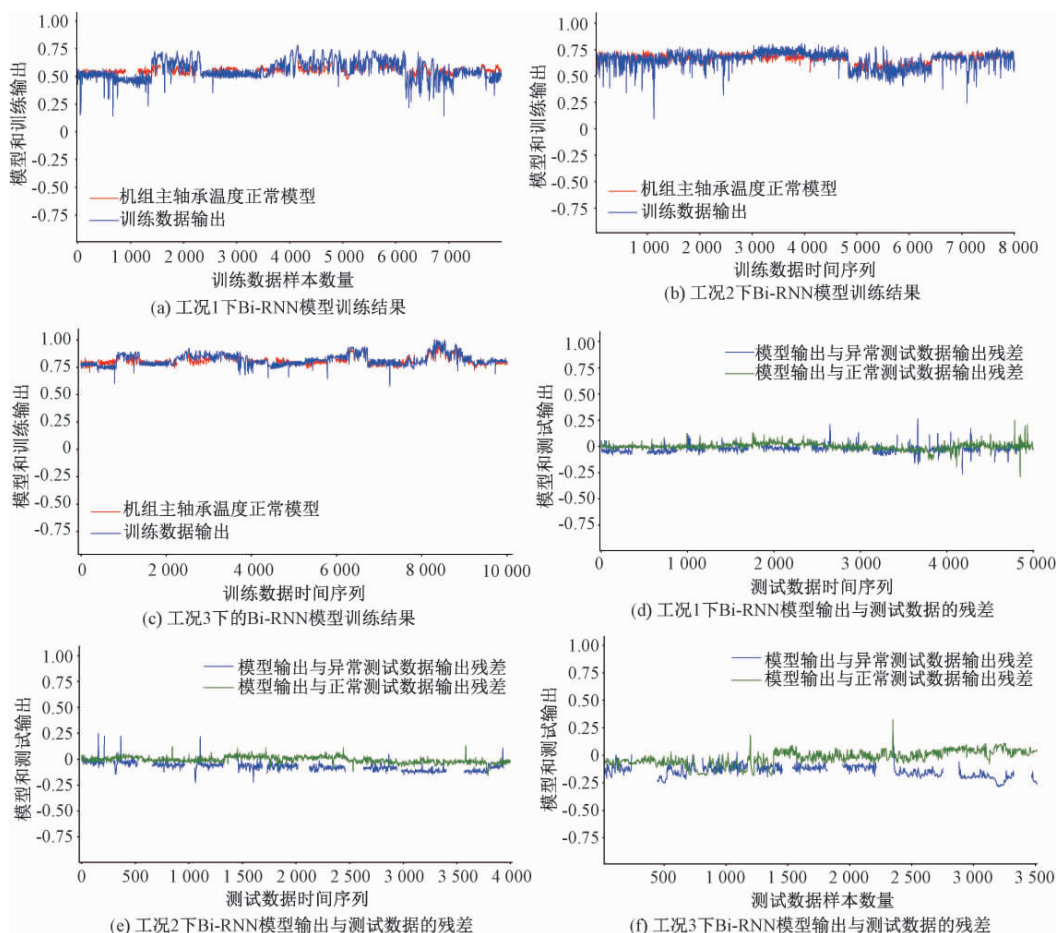


图 6 基于 Bi-RNN 神经网络的风电机组主轴承温度模型训练和测试

Fig.6 Temperature model training and testing of wind turbine main bearing based on Bi-RNN

将测试机组 SCADA 数据输入风电机组主轴承温度模型并计算与 SCADA 数据之间的残差.按照 2.3 中提出的特征向量提取方法,将特征向量输入主轴承故障预警决策模型获取随机森林算法

的输出结果.测试的 8 台机组的故障预警情况如图 7 所示.

从图 7(a) 中可以看出,30#机组、32#机组、33#机组一个月每天的正常率都在警戒线以上,按

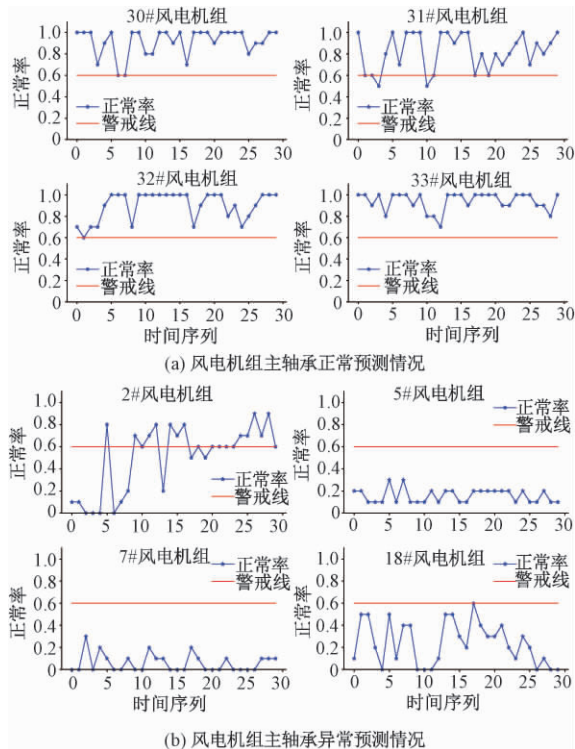


图7 风电机组主轴承运行状态预测情况

Fig.7 Prediction of main bearing operation state of wind turbine

照主轴承故障预警决策判定标准,这3台机组判定为主轴承正常。31#机组有两个时刻机组主轴承的正常率在警戒线以下,但又快速反弹至警戒线以上,按照决策标准同样可判断该机组主轴承正常,后续可重点关注该台机组主轴承状态。4台主轴承正常的机组预测全部正确。

从图7(b)中可以看出,5#机组、7#机组、18#机组一个月每天的正常率都在警戒线以下并且无反弹的趋势,根据主轴承故障预警决策判定标准,这3台机组判定为主轴承异常。2#机组在时间序列前期正常率在警戒线震荡,在后期正常率又上升至警戒线以上,后续应持续关注。4台主轴承异常的机组中有3台机组预测正确。

4 结论

提出了一种风电机组主轴承温度预警方法,将GMM、Bi-RNN神经网络算法、随机森林算法有机结合预警潜在的故障。

相比于传统的故障预警方法,所用的算法对原始数据无特定要求,基本参数调校快。在方法设计中利用GMM对机组工况进行辨识,克服了气候周期性变化及气象条件瞬时变化对后续建模的影响,扩大了算法的时间尺度适用范围;同时,基于Bi-RNN神经网络的风电机组主轴承

温度模型,增加了故障劣化渐变过程的时序特征,使得故障预警模型更接近于实际状态;此外,基于随机森林的主轴承故障预警决策减低了人为设定阈值的复杂性和不确定性,提升了故障预测精度。文章最后通过实例验证了该方法的有效性与实用性。

参考文献:

- [1] 刘振亚.中国电力与能源[M].北京:中国电力出版社,2012.
- [2] TAVNER P. Offshore wind turbines: reliability, availability and maintenance [M]. London: The Institution of Engineering and Technology, 2012.
- [3] RIBRANT J, BERTLING L M. Survey of failures in wind power systems with focus on Swedish wind power plants during 1997 - 2005 [C]. IEEE Transactions Energy Conversion, 2007, 22(1): 167-173.
- [4] 金晓航,孙毅,单继宏,等.风力发电机组故障诊断与预测技术研究综述[J].仪器仪表学报,2017,38(5): 1041-1053.
- [5] 李浪. 基于振动信号的风电机组轴承故障诊断研究[D].北京:华北电力大学电气与电子工程学院,2017.
- [6] 罗毅,甄立敬.基于小波包与倒频谱分析的风电机组齿轮箱齿轮裂纹诊断方法[J].振动与冲击,2015,34(3): 210-214.
- [7] 龙泉,刘永前,杨勇平.基于粒子群优化BP神经网络的风电机组齿轮箱故障诊断方法[J].太阳能学报,2012,33(1): 120-125.
- [8] 黄元维.基于支持向量机的风电机组主轴承故障诊断[J].仪器仪表用户,2016,23(11): 88-92.
- [9] 丁佳煜,许昌,葛立超,等.基于轴承温度模型的风电机组故障预测研究[J].可再生能源,2018,36(2): 276-282.
- [10] 董兴辉,张光,程友星,等.一种风电机组轴承健康劣化趋势预测方法[J].动力工程学报,2018,38(5): 374-379.
- [11] 刘长良,闫萧.基于工况辨识的风电机组齿轮箱状态监测[J].热能动力工程,2016,31(7): 41-46.
- [12] 王春梅.基于深度置信网络的风电机组主轴承故障诊断方法研究[J].自动化仪表,2018,39(5): 33-37.
- [13] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015(521): 436-444.
- [14] 喻晓东. 基于BRNN和注意力机制的视频行人再识别方法研究[D].济南:山东大学控制科学与工程学院,2018.
- [15] 张克君,李伟男,钱榕,等.基于深度学习的文本自动摘要方案[J].计算机应用,2019,39(2): 311-315.

- [16] 胡婕,张俊驰.双向循环网络中文分词模型[J].小型微型计算机系统,2017,38(3):522-526.
- [17] 杨文柱,刘晴,王思乐,等.基于深度卷积神经网络的羽绒图像识别[J].郑州大学学报(工学版),2018,39(2):11-17.
- [18] 毛晓波,张群,梁静,等.基于 PSO-RBF 神经网络的雾霾车牌识别算法研究[J].郑州大学学报(工学版),2017,38(4):46-50.

Research on Temperature Prediction Method for Main Bearing of Wind Turbine Based on Bi-RNN

YIN Shi^{1,2}, HOU Guolian¹, YU Xiaodong¹, LI Ning¹, WANG Qile², GONG Linjuan¹

(1.School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China; 2.ZhongNeng Power-Tech Development Co.,LTD, Beijing 100034, China)

Abstract: The main bearing was the key equipment for energy transmission of wind turbines. In this paper, the main bearing of doubly fed wind turbines were examined. Firstly, the working conditions of wind turbines were identified by using Gauss mixture method. Secondly, the temperature model of main bearing of wind turbines based on Bi-directional Recurrent Neural Network (Bi-RNN) was established in each sub-working condition space. Thirdly, random forest was used to establish and predict residual temperature model of main bearing, so as to realize the fault warning of main bearing of wind turbines. Finally, algorithm model were used to carry out and simulate in a large wind farm. The results showed that the Bi-RNN neural network based on conditions identification which combined with random forest algorithm had strong practicability and high accuracy for main bearing early warning.

Key words: wind turbine; main bearing; condition identification; Bi-RNN; random forest

(上接第 37 页)

Study on the Influence of Battery Energy Storage Operation Control on Active Distribution Network

LI Xue, SONG Yanlong

(School of Mechatronic Engineering and Automation, Shanghai University, Shanghai 200072, China)

Abstract: With the massive integration of distributed generation and electric vehicles, the problems of power and voltage quality in active distribution network were increasingly shown. Aiming at this issue, the factors affecting the interval control were analyzed in terms of energy storage capacity and power, daily load curve characteristics and unit time firstly. An improved interval control method for energy storage output model was then proposed to solve the problem of multiple charging/discharging operation in one cycle. Considering the correlation of random variables, probabilistic load flow using point estimate method was analyzed to state the influence of distributed generation, electric vehicles and energy storage station on voltage level. Finally, simulation analysis was operated on the improved IEEE-33 node active distribution network system with battery energy storage station. The results showed that the integration of energy storage station could effectively reduce the fluctuation of system power and voltage.

Key words: battery energy storage station; interval control; correlation; probabilistic load flow; point estimation method

文章编号: 1671-6833(2019)05-0051-06

基于灰狼优化算法的多源互联电力系统负荷频率控制

侯国莲, 郭雅迪, 弓林娟

(华北电力大学 控制与计算机工程学院, 北京 102206)

摘 要: 随着互联电力系统的快速发展和可再生能源的大规模介入, 电力系统呈现出互联和多源的特点. 基于这一情况, 从多源互联电力系统的实际需求出发, 首先建立含有火、水、气以及可再生能源参与的四区域多源互联电力系统, 然后针对可再生能源发电过程的随机性和波动性, 采用基于灰狼优化算法的 PID 控制器进行负荷频率控制, 以快速抑制频率波动. 仿真结果表明, 在不同的扰动情况下, 无论是对于互联系统的频率偏差还是联络线的交换功率偏差, 本文所采取的控制策略均能取得良好的控制效果和鲁棒性.

关键词: 可再生能源; 多源互联电力系统; 灰狼优化算法; 负荷频率控制; 优化控制

中图分类号: TP13

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.013

0 引言

含有多种发电类型的独立电力区域经由联络线连接构成的互联系统称为多源互联电力系统. 由于各区域之间的互联关系, 任一区域出现的频率波动都将导致系统联络线功率偏差和其他区域频率的波动, 因此, 为保证电能质量, 需考虑负荷频率控制(load frequency control, LFC)问题. 负荷频率控制可以通过平衡发电量和负载消耗量将系统频率和联络线功率稳定在理想值, 是实现电力系统频率稳定的一个重要环节^[1]. 然而随着风能、光能等可再生能源大规模并入电网, 其随机性和波动性将对互联电力系统造成较大的冲击, 给频率控制造成困难. 以往针对常规互联电力系统设计的频率控制器已不能满足控制需求. 需要对含有可再生能源的多源互联电力系统进行负荷频率控制策略研究.

在过去的几十年中, 关于互联电力系统负荷频率控制方法得到了较为广泛的应用. 文献[2]对 I、PI、PD、PID 等几种经典控制器在负荷频率控制中的性能进行了对比, 但其应用仅局限于两区域系统. 针对文献[2]中的不足, 文献[3]对两区域、三区域和五区域等多区域系统进行了研究, 然而只考虑了火力发电, 忽略了多种能源并存的情况.

文献[4]的研究建立在一个包含火电、水电、燃机在内的两区域互联电力系统, 且每个区域都包含以上三种发电类型. 上述研究^[1-3]主要关注了常规能源发电类型, 却未能充分考虑包含可再生能源的多源互联电力系统的 LFC 问题. 随着发电产业的兴起, 常规能源储量迅速减少, 碳排放问题日益严重, 因此, 寻找替代能源以满足未来的能源需求逐渐成为社会各界关注的焦点. 基于此情况, 太阳能和风能因其覆盖广泛, 容易获得, 以及可再生的显著优势成为首选. 文献[5]提出了一个由盘式斯特林太阳能热系统和风力机系统组成的两区域混合热力系统, 并采用仿生优化技术同时优化控制器参数. 文献[6]考虑了包含太阳能热电厂在内的三区域互联电力系统, 并采用灰狼优化算法优化二级控制器的增益. 文献[7]则基于风电参与下的两区域互联电力系统, 采用滑模控制来稳定系统频率. 上述文献虽然考虑了可再生能源参与的情况, 但互联电力系统的大部分区域都只有一种发电形式, 与当前电力系统实际情况差异较大, 因此, 笔者的研究将基于多种发电方式并存的多源互联电力系统展开.

由于大规模光伏和风能等可再生能源的接入, 多源电力系统具有较大波动性和较强随机性, PID 等经典控制器很难满足多源电力系统 LFC 的

收稿日期: 2019-01-11; 修订日期: 2019-03-17

基金项目: 国家自然科学基金资助项目(61603136); 中央高校基本科研业务费专项资金资助(2019JG004)

作者简介: 侯国莲(1966—), 女, 湖北人, 华北电力大学教授, 主要从事过程控制、复杂系统优化控制、新能源技术及控制策略等方面的研究, E-mail: hgl@ncepu.edu.cn.

控制需求.近年,又涌现了大批将先进控制和优化技术与经典控制器结合以获得控制性能的研究成果.文献[8]和文献[9]分别采用模糊逻辑和神经网络对自动发电控制系统展开了研究,然而采用模糊逻辑需要更多的计算时间来检查规则库,使用神经网络控制器需要更多的训练时间.为了获得理想的控制器参数最优值,文献[10]将遗传算法同时用于控制器增益和其他参数的优化,遗传算法搜索速度较慢且容易陷入局部最优.文献[11]采用粒子群算法优化模糊 PI 控制器的参数,与遗传算法一样,粒子群算法也存在易陷入早熟收敛的问题.相比之下,菌群算法则有效克服了上述缺陷,文献[12]证明了该算法的优化性能明显优于粒子群算法.文献[13]通过混合灰狼优化算法来解决人工蜂群算法收敛速度慢的问题.此外,萤火虫算法在文献[14]中被成功应用于负荷频率控制并表现出良好的搜索精度,但收敛速度有待提高.文献[15]使用了一种名为布谷鸟搜索的元启发式算法进行负荷频率控制,该算法在全局寻优时存在收敛速度慢、搜索精度低等问题.在此基础上,Mirjalili 等受到野生狼群的狩猎机制和民主行为的启发,提出了一种称为灰狼优化算法(GWO)的元启发式算法^[17].相较于差分进化算法、粒子群算法和人工蜂群算法,灰狼优化算法在全局搜索、避免局部最优和收敛速度等方面都表现出较强优势,因此,笔者将基于灰狼优化算法,展开多源电力互联系统负荷频率控制研究.

基于以上分析,笔者首先建立了一个风、光参与下的四区域多源互联电力系统模型.该系统模型结合互联电力系统的实际运行状况,各个区域中均包含两种发电类型.其次,采用灰狼优化算法优化 PID 控制器参数,将优化的 PID 控制器用于负荷频率控制.最后,在不同的负载情况下对所研究的系统进行仿真实验,进一步验证笔者所用控制器的优良控制性能.

1 四区域多源互联电力系统的负荷频率控制模型

LFC 主要根据区域控制偏差(area control error, ACE)来实现对机组输出功率的控制调节,通过对机组有功功率进行连续快速稳定调节使 ACE 快速趋于零,从而保证全系统的发电出力 and 负荷功率相匹配.

笔者建立了一个四区域多源互联电力系统模型,图 1 为系统的互联结构示意图.四区域之间通

过联络线实现两两互联, ΔP_{tie}^{ij} 为区域之间的联络线功率偏差量.该模型基于互联电力系统的实际情况,每个区域中均引入多种发电类型.由于目前火力发电依然占据发电行业的主导地位,因此每个区域都包含火电.该四区域模型的具体组成为:区域 1 包含火电和风电,区域 2 包含火电和水电,区域 3 包含火电和燃气机组,区域 4 包含火电和光伏发电.图 2 为该四区域多源互联电力系统的传递函数模型.

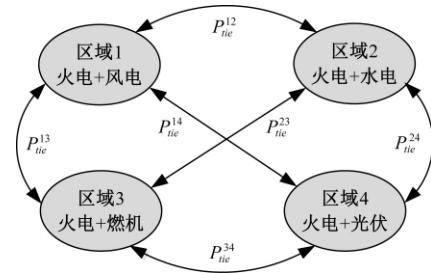


图 1 四区域多源互联电力系统结构示意图

Fig.1 The block of four-area interconnected power system

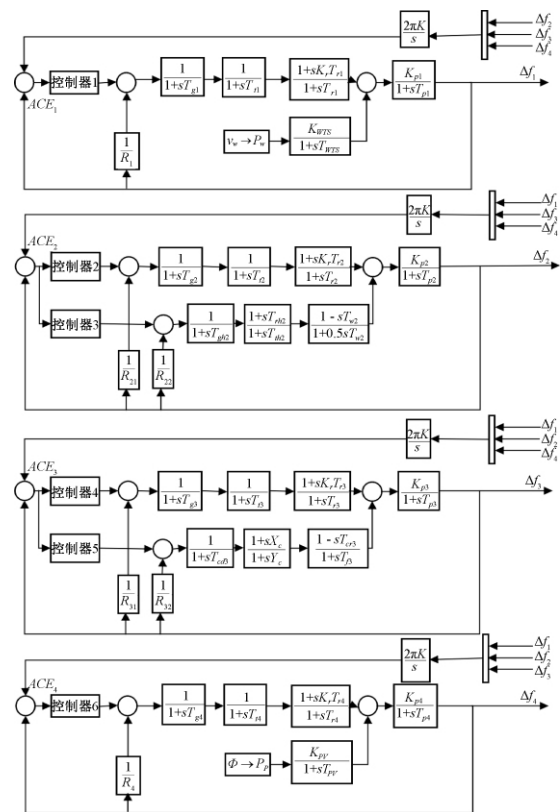


图 2 四区域多源互联电力系统的传递函数模型

Fig.2 Transfer function model of four-area multi-source interconnected power system

图 2 中, R_i 为调速器的调差参数; T_{gi} 为火电机组调速器时间常数; T_{ti} 为汽轮机时间常数; K_r 为汽轮机再热常数; T_{ri} 为汽轮机再热时间常数;

T_w 为水锤的时间常数; T_{rh} 为水轮机调速器复位时间常数; T_{th} 为水轮机调速器瞬时下垂时间常数; T_{gh} 为水轮机调速器时间常数; X_c 为燃气轮机调速器提前时间常数; Y_c 为燃气轮机调速器的滞后时间常数; T_f 为燃气轮机燃料时间常数; T_{cr} 为燃气轮机燃烧反应延迟时间; T_{cd} 为燃气轮机压缩机流量时间常数; K_{pi} 为电力系统增益; T_{pi} 为电力系统时间常数. 相关参数值见附录.

风电机组的输出机械功率由式(1)计算得到^[19],

$$P_w = \frac{1}{2} \rho C_p A_r v_w^3, \quad (1)$$

式中: ρ 为空气密度; C_p 为效率系数; A_r 为扫风面积; v_w 为实际风速.

光伏发电机组的输出功率如公式(2)^[20],

$$P_p = \eta S \Phi [1 - 0.005 (T_a + 25)], \quad (2)$$

式中: η 为转换效率; S 为有效光照面积; Φ 为太阳光照强度; T_a 为环境温度.

2 灰狼优化控制策略及应用研究

与常规能源不同,风能具有较强的随机性和波动性,这就导致风力发电机组不像传统机组那样具有良好的可控性.当在互联电力系统中引入风电后,系统的频率也会受到风能波动的影响而产生偏差.针对以上问题,笔者将灰狼优化与PID控制器相结合,采用灰狼优化算法优化PID参数,并将优化的PID控制器用于负荷频率控制,以快速稳定频率波动.

2.1 灰狼优化算法原理介绍

灰狼优化算法是 Mirjalili 等于 2014 年提出的^[18],反映了自然界中灰狼家族的社会制度和群体狩猎行为.灰狼群体有着非常严格的社会等级制度,狼群通常分为 α , β , δ 和 ω 4 个等级,其中, α 狼为第一级,主要负责统筹决策; β 狼是第二级,辅助 α 狼做出决策; δ 狼是第三级, δ 需要服从 α 和 β 的决策; 整个狼群中等级最低的是 ω 狼,必须服从高等级的狼.在笔者的PID控制器参数优化过程中,将每一个参数视为灰狼种群中的个体,结合狼群捕猎过程中的跟踪、包围和攻击猎物 3 个阶段,可根据狼群的社会等级制度与捕猎过程来定义数学模型并寻找最优解.

依据上述分析,将最优解定义为 α ,将第二、第三最优解分别定义为 β 和 δ ,其余候选解定义为 ω .将狼群中个体与猎物之间的距离定义为 D ,

$$D = |CX_p(t) - X|, \quad (3)$$

$$C = 2r_1, \quad (4)$$

式中: t 为当前代数; X_p 为猎物的位置; X 为一条灰狼所在的位置; C 为系数向量; r_1 是 $[0,1]$ 内的随机向量.

为缩短自身与猎物之间的距离,狼群中的个体会根据如下公式不断进行位置更新,

$$X(t+1) = X_p(t) - A \cdot D, \quad (5)$$

$$A = 2ar_2 - a, \quad (6)$$

其中, A 为收敛影响因子; 收敛因子 a 的值随着迭代次数的增加从 2 到 0 线性减少; r_2 是 $[0,1]$ 内的随机向量.

由于 α , β 和 ω 在狼群中具有较高等级,故认为它们能够携带更多猎物位置信息,可以带领狼群逐渐靠近猎物.将目前为止已得到的 3 个最优解保存并忽略其他解,并根据 3 个最优解来更新狼群的位置信息,逐步寻得全局最优解.更新的过程定义如下:

$$D_\alpha = |C_1 X_\alpha(t) - X|; \quad (7)$$

$$D_\beta = |C_2 X_\beta(t) - X|; \quad (8)$$

$$D_\delta = |C_3 X_\delta(t) - X|. \quad (9)$$

基于计算所得距离, α , β 和 ω 通过下式进行自身位置的修正:

$$X_1 = X_\alpha - A_1 \cdot D_\alpha; \quad (10)$$

$$X_2 = X_\beta - A_2 \cdot D_\beta; \quad (11)$$

$$X_3 = X_\delta - A_3 \cdot D_\delta. \quad (12)$$

接下来狼群中余下个体将根据 α , β 和 ω 的共同决策得到式(13)所示的下一步移动位置,

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3}. \quad (13)$$

综上所述,灰狼优化算法在寻优过程中,首先随机地选出狼群(候选解),在迭代过程中, α , β , δ 狼估计可能的猎物位置.然后每一个候选解不断更新它们离猎物位置,同时,参数 a 从 2 到 0 逐渐减少,最终寻得最优解即PID控制器参数的最优值.

2.2 灰狼优化控制策略在负荷频率控制中的应用

为了在得到较小超调量的同时尽量缩短调节时间,笔者选取灵敏度较好的ITAE作为性能指标,ITAE的定义如下:

$$J_{ITAE} = \int_0^T t |e(t)| dt. \quad (14)$$

针对所研究的互联电力系统,系统误差由区域控制偏差(ACE)构成.ACE本质上是由区域频率偏差和联络线功率偏差组成,其计算公式如下:

$$ACE = \Delta P_{tie}^{ij} + k \Delta f_i, \quad (15)$$

式中: k 为控制区域的频率偏差系数; Δf_i 为区域 i 的频率偏差量; ΔP_{tie}^{ij} 为控制区域之间的联络线功率偏差量。

基于此,笔者确定的适应度函数如式(16)所示,

$$J = \int_0^T (|\Delta f_i| + |\Delta P_{tie}^{ij}|) dt, \quad (16)$$

式中: Δf_i 为区域 i 的频率偏差量; ΔP_{tie}^{ij} 为区域 i 与区域 j 之间的联络线功率偏差。

3 仿真实验及结果分析

3.1 动态时域响应实验

在区域2中加入1%的负荷阶跃扰动,分别采用灰狼优化算法与经典的粒子群算法(PSO)、遗传算法(GA)以及改进的综合学习粒子群算法(cIPSO)、自适应差分进化算法(SaDE)对控制器参数进行优化。各区域的频率偏差及区域间的联络线功率偏差如图3和图4所示。

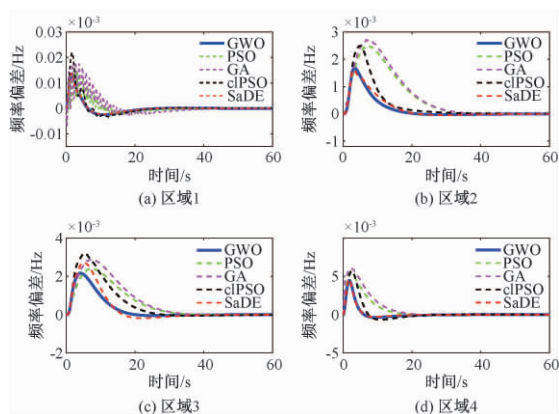


图3 区域2中加入1%的负荷阶跃扰动时4个区域的频率偏差比较

Fig.3 Frequency deviation of four areas for 1% step increase load in area2

从图3、图4所示实验结果可以看出:经灰狼优化算法优化的控制器能够有效减小超调量,缩短响应时间,在所比较的几种优化算法中也表现出较优的控制效果。图5给出了各算法优化下区域2的ACE动态响应曲线。表1给出了使用各优化算法进行10次实验所得到的ACE动态响应曲线的平均峰值和平均响应时间。由以上结果也可

表1 采用不同优化算法时区域2中ACE响应时间和峰值的比较

Tab.1 Comparison of ACE in area-2 with different algorithms

响应时间/s					峰值/ 10^{-2}				
GWO	PSO	GA	cIPSO	SaDE	GWO	PSO	GA	cIPSO	SaDE
36.65	74.1	90.57	63.59	41.36	0.032	0.045 3	0.067 3	0.081 4	0.045 2




图4 区域2中加入1%的负荷阶跃扰动时各区域间联络线功率偏差比较

Fig.4 Tie-line power deviation between four areas for 1% step increase load in area2




图5 区域2的ACE动态响应区域对比

Fig.5 Comparison of ACE of area-2

以看出,采用灰狼优化算法的控制器可以获得更小的峰值和更短的响应时间。

为进一步验证笔者所用控制器的性能,在区域2中加入如图6所示不同类型的负荷扰动,得到图7和图8所示4个区域的频率偏差和各区域间的联络线功率偏差。




图6 负荷扰动变化曲线

Fig.6 Random load disturbance




图7 区域2中加入随机负荷阶跃扰动时4个区域的频率偏差响应曲线

Fig.7 Frequency error of four areas for random load disturbance in area 2

由图7和图8可以看出,对于不同类型的随机负荷扰动,基于灰狼优化算法的控制器都可以较快地稳定各区域的频率偏差和各区域间的联络线功率偏差,具有较快的响应时间和较小的超调量,控制效果较好.以上实验中控制器参数的优化

结果见表2.

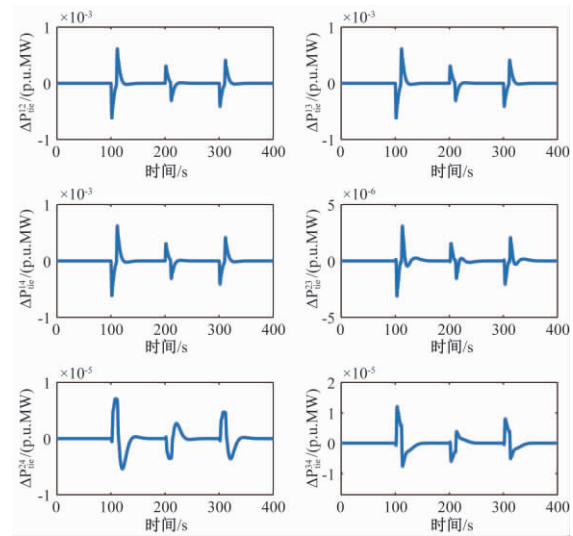


图8 区域2中加入随机负荷阶跃扰动时各区域间联络线功率偏差响应曲线

Fig.8 Tie-line power error between four areas for random load disturbance in area 2

表2 动态时域响应实验中控制器增益的优化结果

Tab.2 Optimized PID controller parameters

控制器增益	在区域2中加入单一负荷扰动时						在区域2中加入连续负荷扰动时					
	控制器1	控制器2	控制器3	控制器4	控制器5	控制器6	控制器1	控制器2	控制器3	控制器4	控制器5	控制器6
K_P	0.985	0.247	1.000	0.104	0.576	0.934	0.993	0.478	0.845	0.829	0.696	1.000
K_I	1.000	0.029	1.000	0.423	1.000	0.983	1.000	0.734	0.641	0.003	0.001	0.999
K_D	0.099	0.167	0.173	0.026	0.430	0.157	0.110	0.415	0.116	0.005	0.268	0.168

3.2 鲁棒性分析

鲁棒性是指当系统的变量在一定可容忍范围内改变时,系统仍能有效地执行任务.将系统参数 T_g 从其标称值变为标称值的+25%和-25%,对所设计控制器的鲁棒性进行了检验.图9给出了在

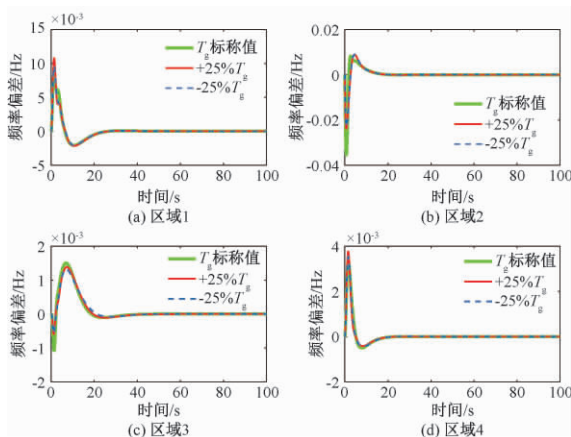


图9 当 T_g 分别为标称值、25%标称值和-25%标称值时4个区域的频率偏差

Fig.9 Frequency deviation of four areas with variation of T_g

这3种情况下各区域的频率偏差变化情况.

由图8观察得到,系统时间常数 T_g 对系统性能的影响可以忽略不计,因此,在系统参数变化较大的情况下,所提出的控制器依然能够保持良好的控制效果表现出一定的鲁棒性.

4 结论

针对所建立的含有火、水、气以及可再生能源的四区域多源互联电力系统的负荷频率控制设计了一种采用灰狼优化算法优化的PID控制器.首先考虑单一区域中的负荷扰动,比较了在所采用的灰狼优化算法优化下与常用粒子群算法和遗传算法优化下控制器控制效果,仿真结果表明所设计的控制器的具有更好的动态性能.随后对指定区域施加了不同类型的随机负荷扰动,该控制器依然保持较好的控制性能,能快速有效地消除随机负荷扰动的影响.最后通过将系统参数分别变为标称值的+25%和-25%对控制器进行了灵敏度分析,验证了控制器的鲁棒性.结果表明,笔者

所设计的控制器具有较好的鲁棒性和稳定性,即使在系统参数变化较大的情况下,也依然保持良好的控制性能。

附录

算法参数选取如下:

$R_i = 2.4 \text{ Hz/(p.u.)}$, $T_{gi} = 0.08 \text{ s}$, $T_{ii} = 0.3 \text{ s}$,
 $K_r = 0.5$, $T_{ri} = 10 \text{ s}$, $T_w = 1 \text{ s}$, $T_{rh} = 0.6 \text{ s}$, $T_{ih} = 10 \text{ s}$,
 $T_{gh} = 48.7 \text{ s}$, $X_c = 0.6 \text{ s}$, $Y_c = 1 \text{ s}$, $T_f = 0.23 \text{ s}$, $T_{cr} =$
 0.01 s , $T_{cd} = 0.05 \text{ s}$, $K_{pi} = 120 \text{ Hz/(p.u.)}$, $T_{pi} = 20 \text{ s}$

参考文献:

- [1] 胡泽春, 罗浩成. 大规模可再生能源接入背景下自动发电控制研究现状与展望[J]. 电力系统自动化, 2018, 42(8): 2-15.
- [2] SAHU R K, PANDA S, ROUT U K. DE optimized parallel 2-DOF PID controller for load frequency control of power system with governor dead-band non-linearity[J]. International Journal of Electrical Power & Energy Systems, 2013(49): 19-33.
- [3] SAIKIA L C, NANDA J, MISHRA S. Performance comparison of several classical controllers in AGC for multi-area interconnected thermal system[J]. International Journal of Electrical Power & Energy Systems, 2011, 33(3): 394-401.
- [4] PRADHAN P C, SAHU R K, PANDA S. Firefly algorithm optimized fuzzy PID controller for AGC of multi-area multi-source power systems with UPFC and SMES[J]. Engineering Science & Technology An International Journal, 2016, 19(1): 338-354.
- [5] RAHMAN A, SAIKIA L C, SINHA N. Automatic generation control of an interconnected two-area hybrid thermal system considering dish-stirling solar thermal and wind turbine system[J]. Renewable Energy, 2017, 105: 41-54.
- [6] SHARMA Y, SAIKIA L C. Automatic generation control of a multi-area ST-Thermal power system using Grey Wolf Optimizer algorithm based classical controllers[J]. International Journal of Electrical Power & Energy Systems, 2015(73): 853-862.
- [7] 周晖, 付娅, 韩盟, 等. 基于粒子群算法的含大规模风电互联系统的负荷频率控制[J]. 电力系统保护与控制, 2014, 4(10): 1-7.
- [8] 丁冬, 刘宗歧, 杨水丽, 等. 基于模糊控制的电池储能系统辅助 AGC 调频方法[J]. 电力系统保护与控制, 2015, 43(8): 81-87.
- [9] SHREE S B, KAMARAJ N. Hybrid neuro fuzzy approach for automatic generation control in restructured power system[J]. International Journal of Electrical Power & Energy Systems, 2016(74): 274-285.
- [10] GOLPRA H, BEVRANI H. Application of GA optimization for automatic generation control design in an interconnected power system[J]. Energy Conversion & Management, 2011, 52(5): 2247-2255.
- [11] JEYALAKSHMI V, SUBBURAJ P. PSO-scaled fuzzy logic to load frequency control in hydro thermal power system[J]. Soft Computing, 2016, 20(7): 2577-2594.
- [12] 谢平平, 李银红, 刘晓娟, 等. 基于社会学习自适应细菌觅食算法的互联电网 AGC 最优 PI/PID 控制器设计[J]. 中国电机工程学报, 2016, 36(20): 5440-5448.
- [13] SOUED S, EBRAHIM M A, RAMADAN H S, et al. Optimal blade pitch control for enhancing the dynamic performance of wind power plants via metaheuristic optimisers[J]. IET Electric Power Applications, 2017, 11(8): 1432-1440.
- [14] SAIKIA L C, SAHU S K. Automatic generation control of a combined cycle gas turbine plant with classical controllers using Firefly Algorithm[J]. International Journal of Electrical Power & Energy Systems, 2013(53): 27-33.
- [15] DASH P, SAIKIA L C, SINHA N. Comparison of performances of several Cuckoo search algorithm based 2DOF controllers in AGC of multi-area thermal system[J]. International Journal of Electrical Power & Energy Systems, 2014(55): 429-436.
- [16] SAHU B K, PATI S, MOHANTY P K. Teaching-learning based optimization algorithm based fuzzy-PID controller for automatic generation control of multi-area power system[J]. Applied Soft Computing Journal, 2015(27): 240-249.
- [17] 常玉林, 汪小淳, 张鹏. 改进蚁群算法在交通分配模型中的应用[J]. 郑州大学学报(工学版), 2017, 38(2): 41-45.
- [18] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69(3): 46-61.
- [19] LEE D J, WANG L. Small-signal stability analysis of an autonomous hybrid renewable energy power generation/energy storage system part i: time-domain simulations[J]. IEEE Transactions on Energy Conversion, 2008, 23(1): 311-320.
- [20] DAS D C, SINHA N, ROY A K. Small signal stability analysis of dish-stirling solar thermal based autonomous hybrid energy system[J]. International Journal of Electrical Power & Energy Systems, 2014, 63(1): 485-498.

Load Frequency Control of Multi-source Power System Based on Grey Wolf Optimization

HOU Guolian, GUO Yadi, GONG Linjuan

(School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: With the rapid development of interconnected power systems and the large-scale intervention of renewable energy, power systems were characterized by interconnectedness and multiple sources. In this circumstance, the study in this paper began with the actual needs of multi-source interconnected power system. Firstly, a four-area multi-source interconnected power system with the participation of fire, water, gas and renewable energy was established and each area contained more than one form of power generation. Then, aiming at the randomness and fluctuation of renewable energy generation process, the load frequency was controlled by the grey wolf optimization (GWO) algorithm based PID controller to stabilize the frequency fluctuation quickly. Finally, the simulation results showed that the proposed controller could achieve good control effect and show strong robustness under different disturbances, regardless of the frequency deviation of the interconnected system or the switching power of the tie-line.

Key words: renewable energy; multi-source power; grey wolf optimization(GWO) ; load frequency control; optimal control

文章编号: 1671-6833(2019)05-0058-06

基于 IGA 的配电系统运行损耗与可靠性优化

樊一娜¹, 梁伟², 黄渝清¹, 赵东初¹, 陈圣博¹, 李明³

(1. 北京师范大学珠海分校 工程技术学院, 广东 珠海 519087; 2. 山东省聊城市水利勘测设计院, 山东 聊城 252061; 3. 复旦大学 信息科学与工程学院, 上海 200433)

摘要: 提出了一种兼顾径向功率分配系统(RDS)的可靠性和效率的优化方案, 目的是在网络重构(DNR)的过程中使有功功率的损耗降低到最小. 本文实质上是基于改进后遗传算法的网络分支故障分析, 即在暂态过程中重点分析保护系统对故障和恢复系统的响应. 具体方法是首先采用基于分支可靠性的非连续蒙特卡罗仿真方法对网络结构的可靠性进行预测, 然后利用遗传算法, 进行可实现的结构重构和高效搜索. 此外, 本文在无投资的情况下分析了 RDS, 将这种算法应用在一个 69 条线路的网络上, 实验结果证明了改进遗传算法的优越性.

关键词: 遗传算法; 损失最小化; 网络重构; 可靠性; 电力服务

中图分类号: TM711

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.009

0 引言

主动配电网重构不仅是优化辐射式供电的重要方式, 也是自动化运行的研究关键. 在正常运行中, 配电网重构可以有效降低功率损耗, 平衡负载和稳定电压. 但是由于电力需求及负载用户不断增加, 故障的影响比以前更加广泛, 因此, 对 RDS 和 DNR 改进的需要逐步加强. 国外, 文献[1-2]中的分析和文献[3-5]的“蒙特卡罗模拟(MCS)方法”已经应用于对 RDS 可靠性的评估.

网络重构(DNR)近年来得到了广泛应用. 迄今为止提出的大多数 RDS 优化技术都是使用启发式算法、数字规划或近似技术, 这样的计算结果相当接近或者直接得到了局部最优解. DNR 使用的模拟热处理法^[1]、粒子群优化法(PSO)^[9]和遗传算法(IGA)^[5,7-10]也在普遍应用.

笔者研究的主要内容是在正常运行的条件下提出一种改进的遗传算法, 将可靠性优化与有效能量损失最小相结合. 该算法用于 DNR 优化 RDS, 使其具有搜索全局或近似全局最优解的能力.

由于线路故障, 按照传统遗传算法不容易收敛得到最优解, 因此笔者提出了一种改进的非连续 MCS 方法, 模拟实际系统分支中的故障, 并估计其可靠性指标. 为了提高模型的可靠性, 考虑了故障后 RDS 保护系统的响应和故障的恢复过程.

1 改进的遗传算法(IGA)

在 DNR 里使用遗传算法的关键是使遗传进化的每一个阶段都具有辐射性, 并且尽量满足径向约束条件. 在这种情况下 IGA 使用了特殊编码和解码技术使染色体长度很小, 并且在优化过程中不会产生无用的解. 可以得出, 在辐射网络中开环支路的数目总是等于联络开关(N_{ts})的数目. 如式(1)所示,

$$N_{ts} = N_b + (N_n - N_{ss}), \quad (1)$$

式中: N_b 表示分支的数目; N_n 表示节点数目; N_{ss} 表示 RDS 中的变电站数目.

1.1 基因操作

为了确保在优化过程开始时具有更高的遗传多样性, 初始种群需要随机生成. 基因操作考虑个体的数量(N_{ind})时比特为“0”或“1”.

收稿日期: 2019-01-14; 修订日期: 2019-04-22

基金项目: 国家自然科学基金资助项目(61375122)

作者简介: 樊一娜(1979—), 女, 江西南昌人, 北京师范大学珠海分校讲师, 硕士, 主要从事智能电网研究, E-mail: fanyina@bnuz.edu.cn.

通信作者: 李明(1964—), 男, 山东青岛人, 复旦大学教授, 博士, 主要从事电力系统自动化研究, E-mail: blang09@fudan.edu.cn.

该染色体由 N 个二进制“0”和“1”子字符串(st)组成,每个子字符串表示RDS的一个连接开关,在对每个字符串进行解码时,将二进制数转换为等效的十进制数,表示开环辐射网络的约束条件.在遗传算法中交叉概率(p_c)和变异概率(p_m)是重要参数.为了达到IGA的最佳性能,采用了具有明确切割点的均匀交叉技术如图1所示,这将提高遗传的多样性.




图1 均匀交叉技术实例

Fig.1 Example of the uniform crossover technique

在本文中,突变算子应用于染色体的每一个比特,具有一定的发生概率(p_m),突变将会在所选位从0改为1,或者从1改为0.遗传操作过程如图2所述.

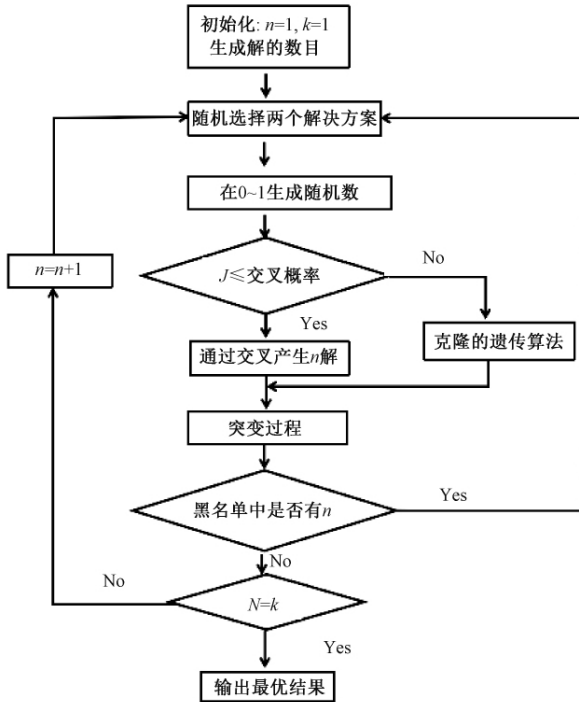


图2 遗传方法(IGA)操作流程

Fig.2 Flowchart of the genetic manipulation approach

1.2 可靠性分析

如果网络分支短路或开路,会直接导致辐射式供电系统瘫痪.在一个分支故障之后,保护系统对短路的响应时间和恢复故障的过程进行切换操作,直接影响网络功率损耗.这些都是通过闭合保

护装置的开关来实现的.

笔者的模型假设所有分支的故障是永久性故障,所有安装的开关为远程控制开关.故障后如果保护系统动作正确,距离故障点最近的保护装置将自动运行.

在保护动作之后,开关将自动切除故障,恢复该支路的初始值和终值.永久性故障点(I_f)仍然隔离,初始值恢复过程如图3所示.

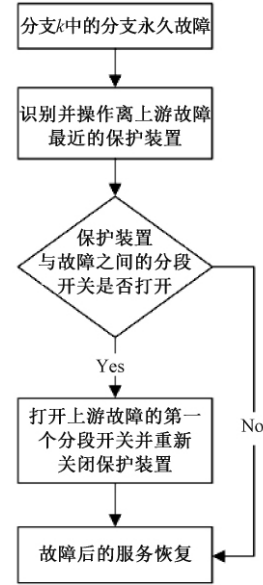


图3 初始值恢复程序流程图

Fig.3 Flowchart of the upstream restoration procedure

在优化过程中,IGA 减少了计算时间,提高了收敛速度,仿真效率更高.

假设一个网络分支出现永久性故障点(k),负载点(i)的故障时间 β_{ik} 取决于辐射式网络供电恢复的速度,如式(2)所示,

$$\beta_k = \begin{cases} rt_k, & I = I_p \\ sw_t, & I = I_t \end{cases} \quad (2)$$

其中, rt_k 是分支的故障修复时间; sw_t 是切换时间($sw_t < rt_k$).

在辐射式供电网络可靠性指标中,系统的故障频率和故障时间为重要参数.电量不足指标ENS中的母线节点平均负荷(L_a)如式(3)所示:

$$L_a = L_p l_f, \quad (3)$$

式中: L_p 是峰值负载需求; l_f 为负载.ENS如式(4)计算可得

$$ENS = \sum_{i=1} L_{a(i)} U_i, \quad (4)$$

其中, L_a 是连接到负载点*i*的平均负载; U_i 是供电中断的年持续时间.

随机的MCS方法可以用来分析ENS的指数和径向功率分配在故障状态下的可靠性.在MCS

计算之前,必须提供 RDS 的每个网络分支的可靠性参数,笔者假设了网络分支的 4 个可靠性级别,如表 1 所示.

表 1 可靠性水平等级
Tab.1 Branch reliability levels.

等级	分支机构的可靠性水平
1	非常不可靠
2	不可靠
3	可靠
4	非常可靠

正常运行状态下的正态密度曲线可以得到一个概率密度函数 f , 其特征是平均修复时间为一个随机变量. MCS 中不同的概率分布来源于网络的历史数据, 在实验中模拟了网络分支的故障和修复历史. 根据历史数据, MCS 预测 RDS 的每个分支故障频率 λ_k (每年发生的次数) 和修复所需的时间 rt_k . ENS 指数由式 (5) 决定,

$$ENS = \sum_{k=1}^n \sum_{i=1}^m \lambda_k L_{a(i)} \beta_{ik}, \quad (5)$$

其中, λ_k 是每年发生分支故障频率; β_{ik} 是供电中断的持续时间.

1.3 年度有功功率损失

通过计算每个支路上的功率损耗, 可以得出在 RDS 中的总有功功率损耗, 如式 (6),

$$P_{\text{损}} = \sum_{i=1}^{B_i} \frac{P_i^2 + Q_i^2}{|V_i|^2} r_i, \quad (6)$$

式中: B_i 为支路数; r_i 为支路上的阻值为 P_i 支路上的有功功率; Q_i 为支路路上的无功功率; V_i 为支路电压.

为了方便计算, 现把一年分成三个季节: 夏季 (7 月、8 月、9 月)、冬季 (12 月、1 月、2 月) 和半季 (剩余月份). 要估算年度的有功功率损失

(W_{Loss}), 需要在 MV 网络中把每天的能量损失都叠加起来, 计入到季节 i 中. W_{Loss} 可通过公式 (7) 进行计算.

$$W_{\text{Loss}} = 92 \times W_W + 90 \times W_S + 183 \times W_{\text{HS}}, \quad (7)$$

通过计算, 可得出在季节 i 的每日 j 的有功功率损失 W_i .

假设 RDS 是三相对称网络, 直接采用单相功率计算方法即可. 利用 IGA 算法在峰值时间分析冬季的功率流量, 在功率损耗曲线上可以查出 $Loss_{i,j}$ 的值.

1.4 适应度函数

相比于单一复合函数优化方法, 经典加权和多目标的优化方法更为有效. 利用该方法, IGA 会同时处理两个目标, 并且根据这两个目标的附加权重做出不同的优化方案, 利用适应度函数求 W_{Loss} 和 ENS 的最小值,

$$\text{最小适应度} = (\alpha_1 W_{\text{Loss}} + \alpha_2 ENS) \times 100. \quad (8)$$

为了正确计算 W_{Loss} 和 ENS, 设置参数 α_1 和 α_2 :

$$\alpha_1 = \frac{w_1}{W_{\text{Lossb}}}; \quad \alpha_2 = \frac{w_2}{ENS_b}. \quad (9)$$

式中: w_1 是功率损失的权重; w_2 是不考虑基础网络配置的权重; W_{Lossb} 是年度有功功率损失; ENS_b 是能量总和.

2 案例分析

笔者通过两种方法对 DNR 进行分析. 第一, 只考虑可靠性, 不考虑经济性; 第二, 既考虑可靠性又考虑经济性. 在网络配置中, 由实验决定保护开关的个数和保护开关的安装地点. 案例是以 12.66 kV 的三相对称 RDS 网络^[12]作为参考, 如图 4 所示.

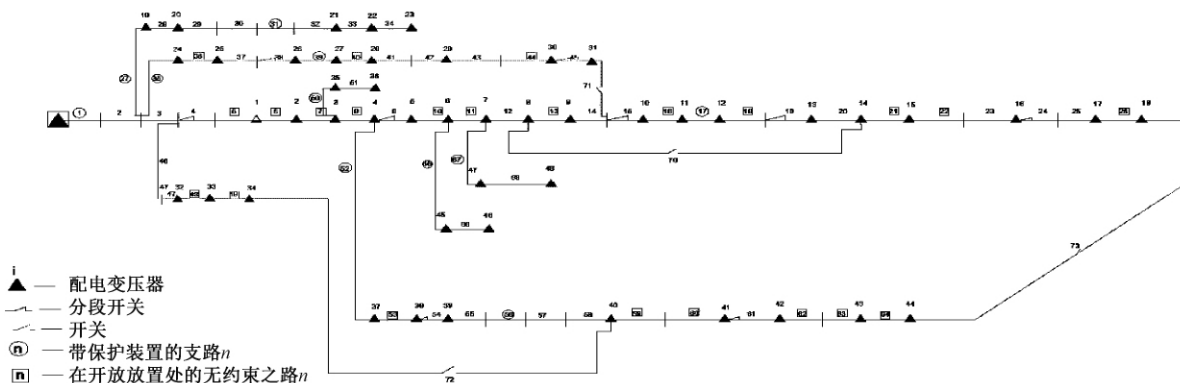


图 4 64 总线的 RDS 测试

Fig.4 Tested 69 bus RDS

该网络以 8 MVA 的容量、73 个支路、9 个自动分段的开关、5 个自动连接保护开关、总负

荷为 3.8 MV 和 2.69 MVar(峰值) 的 69 个节点(其中 48 个是配电变压器的负载点),构成一个变电站.此网络的功率因数为 0.8.在案例分析中,所有节点电压在 0.8~1 p.u.并利用 IGA 中的 GA 和粒子群算法的控制系数得出实验结果.

其中非连续 MCS 分析了 3 000 次实验,在假设的地点每一次实验就会随机发生 15 次年度支路故障.表 2 中列出了反应支路故障程度的参数,同时根据每条支路不同的故障程度归算到不同的概率上,如表 3 所示.开关时间设置为 5 min,每条支路的可靠性等级如图 5 所示.




图 5 69 总线 RDS 的支路可靠性等级

Fig.5 Branch reliability levels of the 69 bus RDS

3 仿真结果

在分析了基础网络配置后,计算得 W_{Loss} 的值为 5 157, ENS 的值为 4.72 MWh.

改进后的模型不但提高了搜索故障点的能力,而且也提高了开关动作精度,从而获得了不同的 ENS 值.由于 W_{Loss} 和 ENS 之间的差异,实验过程中权重的取值可用标准化的方法确定.表 4 的结果显示了优化的第一个方法: W_{Loss} 和 ENS 等值时, $w_1 = 0.5$ 倍 α_1 (1.5835×10^{-4}), $w_1 = \alpha_2$ (0.1059).

表 4 基于不同方法的投资优化

Tab.4 Optimization without investment based on different methods.

解决方案	开放支路路线	$W_{Loss}/(\text{MWh})$	$ENS/(\text{MWh})$	适应值
2 ($w_1=0.5$; $w_2=0.5$)	13-54-61-69-70	2 547.31	4.12	83.98
3 ($w_1=0.3$; $w_2=0.7$)	4-10-45-61-70	3 039.65	3.98	87.90
4 ($w_1=1$; $w_2=0$)	9-13-19-61-72	2 498.38	4.48	79.12
5 ($w_1=0$; $w_2=1$)	4-11-61-69-70	3 216.90	3.90	82.63

与传统 GA 方法相比,IGA 可以使用一个统一的交叉技术来解决这个值的动态变化.从而解决传统 GA 算法在优化过程中容易直接得到部分最优解的问题.表 5 中指出了在第 13 个支路中增加一个保护开关使开关动作具有速断性.GA 的方案 S2 中,功率损耗减少 19.3%, ENS 减少了

表 2 支路故障程度

Tab.2 Degrees of failure severity

可靠性等级	所在支路百分比/%	故障程度等级		
		1	2	3
1	42.5	60	40	0
2	16.4	40	50	10
3	38.4	20	40	40
4	2.7	0	20	80

表 3 不同故障等级发生的概率

Tab.3 Probability of occurrence of each degree of failure severity %

故障程度等级	平均恢复时间 rt_{av}/min	误差
1	60	9
2	40	6
3	15	3

在第二个方法中, RDS 线路中增加了一个新的保护开关.在这种情况下权重的分配有几种不同的方案,如表 4 所示.例如在方案 3 中,系数 α_1 和 α_2 分别调整到了 0.9501×10^{-4} 和 0.1483.将表 4 中得到的不同优化解决方案和算法性能指标进行对比,得出最好的解决方法是方案 S1 中所提出的 IGA.该方案优化结果是使有功功率损耗减少了 16.3%, ENS 减少了 9.3%.虽然 IGA 与 PSO^[9] 结果相似,但是 IGA 在收敛的过程中速度更快.

12.7%.在方案 S3 中,放弃部分速断性而增加了可靠性,所以功率损耗减少了 3.7%且 ENS 减少了 15.7%.方案 S4 和 S5 证明了结合两个目标获得折中解决方案的优点.假设 S4 只有有功功率损耗的减少量, S5 只有 ENS 的减少量,在设置了一个目标参数 i.e 后利用第一种方法有功功率损耗

表 5 安装新的连接开关后利用 IGA 进行投资优化各值
Tab.5 Optimization with investment using IGA(one new tie-switch)

项目	文献 [14] 算法	GA	PSO	IGA
开放支路路线	69-70-71-72-73	9-45-61-70-72	9-61-70-71-72	
W_{Loss} (MWh)	3 157.53	2 669.35	2 643.67	
ENS (MWh)	4.29	4.72	4.25	4.28
适应值	100	87.28	87.20	
基因代数	—	6	14	5

量减少了 20.8%, ENS 只减少了 5.1%; 但是在第二种方法下只有 ENS 减少了 17.4%.

方案 S1 中利用 IGA、PSO 和 GA 算法得出适应度随基因代数的繁衍, 如图 6 所示. 结果证明了 IGA 快速收敛的能力, 这样就节省了最佳解决方案的时间. 而且从图中可以看出利用 IGA 算法适应度函数在第 5 代得出了一个不再变化的最小值, 而 GA 和 PSO 算法分别在第 6 代和第 14 代确立了最小值. 在计算速度方面, IGA、PSO 和 GA 算法模拟得到的平均计算时间分别是 220、309 和 294 s. 笔者提出的方法在正常运行状态下会在一年内得到优化的 RDS 网络配置.




图 6 使用 IGA 和其他方法得出解决方案 S1 的收敛性能
Fig.6 Convergence preformance using IGA and other methods for solution S1

4 结论

笔者提出将 IGA 应用于 RDS 的优化, 通过一个 DNR 过程将该算法的可靠性和效率同时结合起来. 此外还提出了一种改进的算法模型, 是在一个随机的 MCS 网络中进行网络配置, 既考虑了保护的速断性, 又考虑了保护的时效性. 该算法在处理 DNR 问题时, 使用了单一的复合函数, 性能良好. 这不但解决了快速收敛的关键问题, 还增加了系统的稳定性, 降低了故障概率.

将该方法应用于一个 69 节点的 RDS 中, 所有实验节点都可以做到在稳定性提高的同时快速收敛, 这个结果证明了可靠性与效率相结合的重要性. 但是在实践中很难精确地选择目标的权重, 如果改变目标的权重将会对结果造成很大的影响

(即会得到不同的优化解). 为了解决这个问题, 下一步应该采用一个多目标优化方案得到整个系统的最优解集.

参考文献:

- [1] 孙磊, 杨贺钧, 丁明. 配电系统开关优化配置的混合整数线性规划模型 [J]. 电力系统自动化, 2018, 40(16): 87-95.
- [2] 吴博. 基于蚁群算法的配电网保护最优协调整定 [J]. 电气技术与经济报刊, 2018(3): 3-8.
- [3] 侯雨伸, 王秀丽, 张玥, 等. 考虑维度重要性的电力系统可靠性评估拟蒙特卡洛方法 [J]. 电力系统自动化, 2016, 40(16): 31-37.
- [4] CEBRIAN J C, KAGANN, Reconfiguration of distribution networks to minimize loss and disruption costs using genetic algorithms [J]. Electric power systems research, 2010, 80(1): 53-62.
- [5] MIRJALILI HR, SEDIGHIANARAKIAR, HAGHIFAM MR. A new method for loss reduction based on simultaneous DG placement and network reconfiguration [C] // 19th Iranian conference on electrical engineering, Iran, 2011: 1-6.
- [6] 季杭为. 含分布式能源的交直流混合配电系统运行优化研究 [D]. 东南大学吴健雄学院, 2017: 57-61.
- [7] VITORINO R M, JORGE H M, NEVES L P. Network reconfiguration using a genetic approach for loss and reliability optimization in distribution systems [C] // 2nd international conference on power engineering energy and electrical drives, USA. University of California Berkeley Campus, 2009: 84-89.
- [8] RAVIBABUP, RAMYA M S, SANDEEP R, et al. Implementation of improved genetic algorithm in distribution system with feeder reconfiguration to minimize real power losses [C] // 2nd international conference on computer engineering and technology, China, Sanya, 2010, 4: 4320-4323.
- [9] 马少飞, 胡俊, 刘强, 等. 基于粒子群算法的配电网故障定位研究 [J]. 智慧电力期刊, 2018, 46(9): 83-87.
- [10] ZHANG BC, GUO QW, LI X, et al. Reconfiguration in distribution systems based on refined genetic algorithm

- for improving voltagequality [C]//Asia-pacific power and energyengineeringconference, China, Wuhan, 2011: 1-4.
- [11] 魏超峰,李琼林,蒋建东,等.谐波因素的配电网损耗量化计算与建模仿真 [J].郑州大学学报(工学版), 2018,39(1): 53-57.
- [12] 肖炎,郭永基,席勇健,等.一种评估大规模电力系统可靠性的新算法 [J].清华大学学报(自然科学版),1999,55(1): 13-16.
- [13] 张振,刘艳红. 基于特征值的单机无穷大电力系统随机稳定性分析 [J] 郑州大学学报(工学版),2018, 39(4): 58-63.

Loss and Reliability Optimization for Power Distribution System Operation on Improved Genetic Algorithms

FAN Yina¹, LIANG Wei², HUANG Yuqing¹, ZHAO Dongchu¹, CHEN Shengbo¹, LI Ming³

(1. Beijing Normal University, Zhuhai 519087, China; 2. City Water Conservancy Survey and Design Institute, Liaocheng 252061, China; 3. Fudan University, Shanghai 200433, China)

Abstract: This study focused on an optimization method that combined simultaneously the reliability and the efficiency of radial power distribution systems (RDS), minimized active energy losses, through a process of network reconfiguration. The study based on the failure analysis on network branches, with a special concern on the protection system response to faults and the service restoration procedures, in the emergency state. A non-sequential Monte Carlo simulation based on the branch reliability was used to evaluate reliability of the network configurations. Due to a large number of possible configurations and the need of an efficient search, the optimization was made through an improved genetic algorithm (IGA). In a first step, the method analyzed the RDS considering the absence of investment, and in a second step, the possibility of placing a limited number of new tie-switches in certain branches, according to the definitions made by a decision maker. The effectiveness of the proposed methodology was demonstrated through the analysis of a 69 bus RDS and by comparison against other reported methodologies.

Key words: genetic algorithm; loss minimization; network reconfiguration; reliability; service restoration

文章编号: 1671-6833(2019)05-0064-08

分布式储能参与电压暂降补偿的优化配置与控制策略

马兴¹, 李俊杰¹, 黎博², 谢巍², 高盟凯², 陈民铀²

(1. 国网重庆市电力公司电力科学研究院, 重庆 401120; 2. 重庆大学 电气工程学院, 重庆 400044)

摘要: 针对分布式储能参与电网电压暂降补偿的补偿服务, 提出了分布式储能优化配置模型、分布式储能与动态电压补偿器联合补偿的控制策略。首先, 以最小化分布式储能安装成本与敏感负荷的电压越限成本为目标, 建立了分布式储能双层优化配置模型。然后, 以分布式储能、动态电压补偿器的补偿成本和敏感负荷的电压满意度为目标, 建立了分布式储能与电压动态补偿器联合补偿的控制模型。采用随机变异的粒子群算法求解分布式储能优化配置模型与联合补偿的控制模型。最后以 IEEE 33 节点系统进行算例仿真。仿真结果表明, 所提方法能减少储能容量的配置, 同时联合补偿策略能提高补偿效果和减少补偿设备的投资。

关键词: 分布式储能; 电压暂降; 补偿策略; 动态电压补偿器; 成本

中图分类号: TM7

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.004

0 引言

近年来, 随着工业和信息行业的发展, 基于计算机、微处理器控制的负荷敏感设备大量应用, 电网对电能质量的要求也越来越高。同时, 在配电网中, 大量非线性、冲击性负荷以及分布式电源的接入带来了各种电能质量问题, 其中电压暂降是影响电力设备安全稳定运行的最主要的电能质量问题^[1]。

电压暂降的治理方法可归纳为基于能量储存技术^[2]、恒压变压器、固态开关^[3]、逆变器^[4]以及联合补偿等方案。对于敏感负载而言, 使用动态电压恢复器(dynamic voltage restorer, DVR)是解决电压暂降问题的有效手段。关于如何提升 DVR 补偿效率^[5]和补偿性能^[6]都有相关研究。但是, DVR 的补偿能力主要取决于其内部电池容量的大小, 对于较为严重的电压暂降, 它能补偿的跌落深度和持续时间都有限。随着电池技术发展和成本下降, 分布式储能得到了快速发展, 储能凭借其快速功率调节能力, 在平滑分布式电源出力波动、改善电压质量方面有显著作用^[7], 但分布式储能的配置与运行需要大量投资, 因此, 如何优化分布式储能的配置与运行策略是分布式储能参与电压暂降

治理亟需解决的问题。

目前, 针对储能的优化配置与控制已有大量的研究成果, 文献[8]以最小化储能投资运行成本和电压偏差为目标, 建立双层储能多目标优化配置模型, 采用粒子群算法求解该模型。文献[9]构建年支出费用函数, 对系统电压薄弱点进行有限排序, 选取安装地点, 然后优化求解费用最小所对应的 STATCOM 最优容量。文献[10]提出时序灵敏度计算方法, 从改善电压的角度深入研究储能系统最佳选址及配置。在储能参与电压暂降治理方面, 文献[11]利用微电网中混合储能能量互补特点, 控制储能充放电抑制负载突变对直流母线造成的电压波动问题。文献[12]提出电能质量控制器并联侧和串联侧储能联合的联合控制策略, 从而实现维持微电网母线电压稳定、降低网络损耗的多目标优化。

笔者针对分布式储能参与电压暂降治理的配置与运行策略问题, 首先, 以储能投资成本、电压暂降检测设备安装成本和敏感负荷的电压成本为目标, 建立了分布式储能参与电压暂降补偿的优化配置模型。然后, 在优化配置的基础上, 以分布式储能、DVR 补偿成本和电压满意度为目标, 建立 DVR 与分布式储能联合补偿控制策略, 并采用

收稿日期: 2018-11-27; 修订日期: 2019-02-16

基金项目: 国家电网公司科技资助项目(5220001600V6); 国网重庆市电力公司科技资助项目(52202316000X)

通信作者: 黎博(1992—), 男, 广西桂林人, 重庆大学博士生, 主要从事电网分布式优化研究, E-mail: boli9301@163.com.

粒子群算法求解该模型.最后,采用 IEEE 33 节点系统对优化配置模型和联合补偿的控制方法进行仿真验证.

1 分布式储能参与电压暂降补偿分析

分布式储能参与电压暂降的治理方式如图 1 所示.分布式储能由两条母线引出:一条通过逆变器与 PCC 点连接;另外一条与 DVR 储能设备连接,对 DVR 直流母线进行供电.

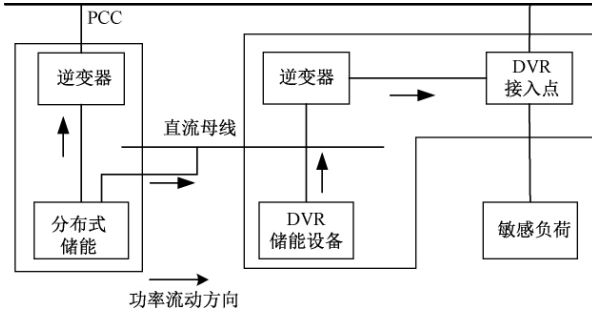


图 1 分布式储能参与电压暂降补偿的形式

Fig.1 The voltage compensation method using DESS

图 2 为电网发生电压暂降时电压电流向量关系图。 U_{s-sag} 为发生暂降后的电网电压; U_{dvr} 为 DVR 的输出电压,以补偿电网电压的变化值; φ 为 U_{dvr} 与 U_{s-sag} 的电压夹角; U_{L-sag} 为通过 DVR 补偿后的负载恢复电压,当 DVR 可以实现全相补偿时, $U_{L-sag} = U_s$.




图 2 发生电压暂降时各电流电压向量关系图

Fig.2 The relationship between current and voltage vector when voltage sag occurs

假设暂降发生前后负载 Z_L 不发生变化,则此时为

$$I_{L-sag} = U_{L-sag} / Z_L. \quad (1)$$

将配电网中的分布式储能当作一个整体,从功率角度对电压暂降时的暂降区域进行分析。 P_s 为外界注入暂降区域的功率; $\sum P_i$ 为分布式电源通过逆变器注入配电网的等效总功率; P_L 为负荷消耗总功率,则

$$P_s + \sum P_i + P_{dvr} = P_L, \quad (2)$$

$$P_s = U_s I_s. \quad (3)$$

设 γ 为 U_{L-sag} 与分布式电源等效总电流 $\sum I_i$ 的夹角,则

$$\sum P_i = |U_{s-sag} + U_{dvr}| \cos \gamma \sum P_i, \quad (4)$$

$$P_{dvr} = U_{dvr} I_{s-sag} \cos \varphi, \quad (5)$$

$$P_L = U_{L-sag} I_{L-sag} \cos \theta. \quad (6)$$

为了使负荷不受电压暂降的影响, U_{L-sag} 要保持和暂降前的系统电压一致,即 $U_{L-sag} = U_s$, 那么 DVR 的输出补偿电压为

$$U_{dvr} = P_{dvr} / [I_{L-sag} - \sum P_i \cos \varphi]. \quad (7)$$

因此,当发生电压暂降时,储能的输出功率能减小 DVR 的补偿出力,储能的输出电流能减小 DVR 的输出补偿电压,从而达到提高补偿效果的目的.

2 考虑电压暂降的分布式储能配置

2.1 储能系统模型

储能单元中的功率变换系统 (power conversion system, PCS) 可快速、独立地调节储能的有功和无功出力,用电池荷电状态 (state of charge, SOC) 表示储能的能量水平,储能系统经 Δt 时间后的能量变化可以表示为^[14-15]:

$$SoC_i(t + \Delta t) = SoC_i(t) - \Delta SoC(\Delta t), \quad (8)$$

$$VSoC(\Delta t) = \begin{cases} \frac{\Delta t}{W_{rated}} \eta_{in} P_i(t), & I(t) = 0 \\ \frac{V_t}{W_{rated}} \frac{1}{\eta_{out}} P_i(t), & I(t) = 1 \end{cases}. \quad (9)$$

式中: SoC_i 为第 i 个储能的 SOC 值; W_{rated} 为储能的额定容量; $\Delta SoC(\Delta t)$ 为 t 时刻与 $t+1$ 时刻储能的 SOC 变化量; η_{in} 、 η_{out} 分别为储能系统充电和放电效率.

2.2 分布式储能的选址安装

由于分布式储能设备安装昂贵,在考虑电压暂降补偿效果时须考虑补偿成本.考虑经济性与电压质量目标,建立最小化电压暂降补偿成本为目标的储能优化配置模型,优化目标包括经济目标与电压质量目标,经济目标兼顾储能安装成本 f^a 、电压暂降检测装置安装成本 f^b 、敏感设备的电压质量成本 f^c .

(1) 分布式储能系统的容量成本

对于整个储能系统,在编号为 j 的电压暂降事件中,所需的容量与所消耗的能量为

$$\begin{cases} S_j = \sum_{i=1}^n S_{ij} = \sum_{i=1}^n \sqrt{P_{C,ij}^2 + Q_{C,ij}^2} \\ E_j = \sum_{i=1}^n E_{ij} = \sum_{i=1}^n t_j \sqrt{P_{C,ij}^2 + Q_{C,ij}^2} \end{cases}, \quad (10)$$

式中: S_{ij} 、 E_{ij} 分别为分布式储能 i 在电压暂降事件 j 中所需的容量和所消耗的能量; $P_{C,ij}$ 、 $Q_{C,ij}$ 分别为分布式储能 i 在电压暂降事件 j 中输出的有功功率和无功功率; n 为分布式储能的总个数; j 为电压暂降事件的编号; t_j 为电压暂降事件 j 持续的时间。

在电压暂降事件 j 的补偿中, 储能投资成本^[13]为

$$f_j^a = C_{IE} \cdot S_j + C_{IS} \cdot E_j + C_{RE} \cdot S_j + C_{RS} \cdot E_j + C_1, \quad (11)$$

式中: C_{IE} 、 C_{IS} 分别为储能单位容量和能量投资成本; C_{RE} 、 C_{RS} 分别为储能单位容量和能量运行成本; C_1 为储能固定投资成本。

考虑到储能的配置成本一般与其容量和能量呈线性相关, 将式(10) 线性函数中的常数项合并后得

$$f_j^a = k_E E_j + k_S S_j + C_1. \quad (12)$$

在 m 次电压暂降事件下, 假设储能系统能满足所有电压暂降事件的补偿要求, 那么每个储能设备的备用容量要达到多次事件中的最大容量, 所需储能系统总备用容量和能量为

$$\begin{cases} S = \max(S_0, S_1, \dots, S_m) \\ E = \max(E_0, E_1, \dots, E_m) \end{cases}. \quad (13)$$

那么在多次电压暂降事件中, 储能系统成本为

$$f^a = k_E E + k_S S + C_1. \quad (14)$$

(2) 电压暂降检测设备安装成本

由于电压暂降的随机性, 补偿设备为快速响应电压暂降的补偿需求, 需要对储能设备安装电压暂降检测设备, 其安装成本可表示为

$$\begin{cases} f^b = \sum_{i=1}^n f_i^b \\ f_i^b = C_2 \end{cases}, \quad (15)$$

式中: f_i^b 为储能 i 检测设备的安装成本; C_2 为储能安装处的电压暂降检测成本。

(3) 敏感负荷上电压指标折算成本

$$\begin{cases} f^c = \sum_{g=1}^h f_g^c \\ f_g^c = \begin{cases} 0, & U_i \geq U_{\text{req}} \\ k(U_{\text{req}} - U_i), & U_i < U_{\text{req}} \end{cases} \end{cases}, \quad (16)$$

式中: U_i 为敏感负荷 i 处节点 i 电压; U_{req} 为电压

下限值; f_g^c 为敏感负荷 g 的电压成本; k 为电压成本系数。

笔者以最小化电压暂降补偿成本 f_1 为目标函数, 储能的安装位置、额定容量为决策变量. 约束条件包括: 暂态电压稳定运行约束、系统的有功和无功平衡约束、传输线路功率约束, 该优化模型表示为

$$\begin{cases} \min_{X_1} f_1 = f^a + f^b + f^c \\ \text{s.t. } g(X_1) \leq 0 \end{cases}, \quad (17)$$

式中: $X_1 = [x_1, x_2, \dots, x_n, y_1, y_2, \dots, y_n, z_1, z_2, \dots, z_n]$, x_1, x_2, \dots, x_n 为节点编号; y_i, z_i 分别为对应节点 x_i 处安装储能的功率和容量; $g(X_1)$ 为约束条件, 为保障电网安全稳定运行, 需要满足一系列等式、不等式约束条件。

等式约束: 系统的潮流约束, 可表示为

$$\begin{cases} P_i + P_{MG,i} - P_{Li} - U_i \sum_{j=1}^{N_{\text{bus}}} U_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) = 0 \\ Q_i + Q_{MG,i} - Q_{Li} - U_i \sum_{j=1}^{N_{\text{bus}}} U_j (G_{ij} \sin \theta_{ij} + B_{ij} \cos \theta_{ij}) = 0 \end{cases}, \quad (18)$$

式中: P_i 、 $P_{MG,i}$ 和 P_{Li} 分别为节点 i 的储能有功出力、平衡节点有功出力、负荷有功需求; Q_i 、 $Q_{MG,i}$ 和 Q_{Li} 分别为节点 i 的储能无功出力、平衡节点无功出力、负荷无功需求; U_i 为节点 i 的电压; G_{ij} 和 B_{ij} 分别代表节点 i 和 j 之间电导和电纳; θ_{ij} 为节点 i 和 j 的相位差。

储能额定功率和容量约束:

$$\begin{cases} P_{\min} \leq P_i \leq P_{\max} \\ Q_{\min} \leq Q_i \leq Q_{\max} \end{cases}, \quad (19)$$

$$\sqrt{P_i^2 + Q_i^2} \leq S^{\max}, \quad (20)$$

式中: P_{\min} 、 P_{\max} 和 Q_{\min} 、 Q_{\max} 分别为各储能单元输出有功功率和无功功率的下限和上限值; S^{\max} 为储能的额定容量。

不等式约束包括

(1) 储能系统的荷电状态约束:

$$SoC_i^{\min} < SoC_i(t) < SoC_i^{\max}, \quad (21)$$

(2) 节点电压约束:

$$U_{\text{req}} \leq U_i \leq 1.07 U_0, \quad (22)$$

$$U_k \geq U_{\text{req}}, \quad (23)$$

(3) 传输线路功率约束:

$$P_k \leq P_{k\max}. \quad (24)$$

式中: U_k 为敏感负荷处的电压; U_0 为电压标幺

值,取值为1; P_k 为第 k 条线路传输的有功功率。

3 分布式储能与 DVR 联合补偿策略

3.1 优化控制模型

联合分布式储能与 DVR 对电压暂降进行补偿,建立的联合补偿模型以分布式储能补偿成本 F^{ES} 、DVR 的补偿成本 F^{DVR} 最小和敏感负荷的电压满意度 F^{VOL} 最大为目标函数,考虑节点电压暂降情况、分布式储能和 DVR 输出约束、潮流收敛等约束,其目标函数可表示为

$$\min f_2 = m_b \sum F_i^{\text{ES}} + m_c \sum F_i^{\text{DVR}} - m_a \sum F_i^{\text{VOL}}, \quad (25)$$

式中: m_a 、 m_b 和 m_c 分别为敏感负荷电压满意度、分布式储能补偿成本和 DVR 补偿成本系数。

(1) 分布式储能的补偿成本

$$F_i^{\text{ES}} = \eta_i^{\text{ES}} \sqrt{P_{\text{ESS},i}^2 + Q_{\text{ESS},i}^2}, \quad (26)$$

式中: $P_{\text{ESS},i}$ 、 $Q_{\text{ESS},i}$ 为第 i 个储能的有功、无功输出; η_i^{ES} 为分布式储能单位容量的补偿成本。

(2) DVR 补偿成本

当某节点发生电压暂降时, DVR 参与补偿的成本为

$$F_i^{\text{DVR}} = \eta_i^{\text{DVR}} P_{\text{dvr},i}, \quad (28)$$

$$P_{\text{dvr},i} \leq P_{\text{max}}^{\text{DVR}}, \quad (29)$$

式中: η_i^{ES} 为 DVR 单位容量的补偿成本; $P_{\text{max}}^{\text{DVR}}$ 为 DVR 功率输出上限。

(3) 敏感负荷的电压满意度

敏感负荷的电压满意度以敏感负荷的耐受电压与正常电压为界,划分为3个区间。

$$F_i^{\text{VOL}} = \begin{cases} 1 & U_i \geq U_{\text{req}} \\ \frac{U_i - U_{\text{res}}}{U_{\text{req}} - U_{\text{res}}} & U_{\text{res}} \leq U_i < U_{\text{req}} \\ 0 & U_i < U_{\text{res}} \end{cases}, \quad (29)$$

式中: U_i 为节点 i 上敏感负荷的电压; U_{req} 为补偿的目标电压; U_{res} 为敏感负荷的耐受电压。

以 f_2 作为目标函数,式(26)~(28)构成了联合补偿策略的优化方法,可表示为

$$\begin{cases} \min_{X_2} f_1(x) \\ \text{s.t. } h(X_2) = 0 \\ g(X_2) \leq 0 \end{cases}, \quad (30)$$

式中: $X_2 = [P_{\text{ESS},1}, P_{\text{ESS},2}, \dots, P_{\text{ESS},n}, Q_{\text{ESS},1}, Q_{\text{ESS},2}, \dots, Q_{\text{ESS},n}, P_{\text{dvr},1}, P_{\text{dvr},2}, \dots, P_{\text{dvr},n}]$ 为分布式储能系统和 DVR 的充放电功率; $h(X_2) = 0$ 为等式约束,对应式(18); $g(X_2)$ 为不等式约束,对应式

(19)~(24)和(29)。

3.2 基于随机变异的粒子群优化算法

粒子群算法 (particle swarm optimization, PSO) [16] 是一种智能算法,通过模拟鸟群捕食行为,经过粒子之间的信息传递和搜寻来寻找目标函数中的最优解。PSO 算法的速度和位置更新模型可表示为

$$V_i(t+1) = \omega V_i(t) + c_1 r_1 \times [P_{\text{best}_i} - X_i(t)] + c_2 r_2 \times [G_{\text{best}} - X_i(t)], \quad (31)$$

$$X_i(t+1) = X_i(t) + V_i(t+1), \quad (32)$$

式中: V_i 和 X_i 分别为第 i 个粒子的速度和位置; ω 为惯性系数; c_1 和 c_2 为加速系数,分别代表自身经验、社会经验系数; r_1 和 r_2 为 0~1 的随机常数。 P_{best_i} 和 G_{best} 分别为粒子 i 的历史最佳位置和种群历史最佳位置。

PSO 算法在求解优化模型中容易陷入局部最优,因此对随机选择的粒子进行变异 [17],该算法的稳定性与收敛性已在文献 [17] 中有详细说明,当粒子速度小于阈值时,粒子变异方式为

$$X_{id} = X_{id} + \alpha v_{\text{max},d} \text{sign}(2r_3 - 1), \quad (33)$$

式中: x_{id} 为粒子 i 的第 d 维; $\alpha \in [0,1]$ 为粒子变异程度; $v_{\text{max},d}$ 为粒子第 d 维的最大飞行速度; $r_3 \in [0,1]$ 为随机数。

3.3 储能与 DVR 联合补偿控制策略

分布式储能与 DVR 联合补偿流程如图 3 所示。

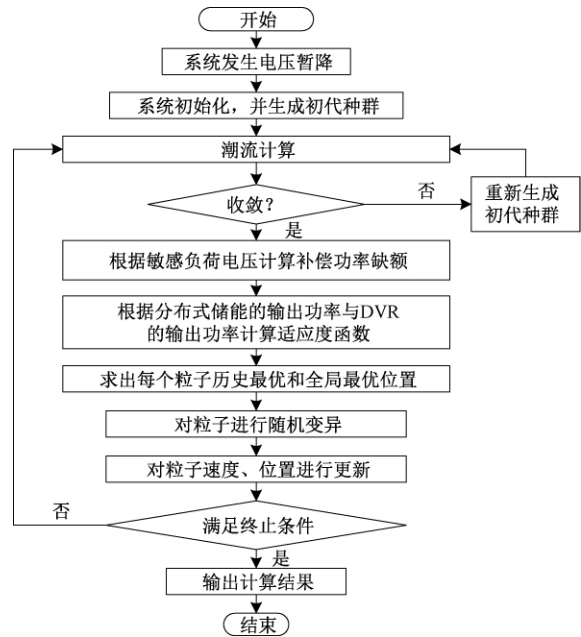


图3 联合补偿策略流程图

Fig.3 The joint compensation strategy for voltage sag

4 仿真及算例分析

4.1 算例介绍

为了验证笔者提出的算法,采用 IEEE 33 系统作为配电网测试系统进行仿真实验.以节点 7、25、26、33 为敏感负荷接入位置.其中节点 7 接入直流调速器带直流电机,节点 25、33 接入变频器,节点 26 接入交流接触器.电压暂降的测试波形采用蒙特卡罗法生成,然后根据配电网参数计算相位跳变信息.




图 4 IEEE 33 节点系统

Fig.4 IEEE 33 bus system

表 1 相关参数和控制变量范围

Tab.1 Parameters and control variable information

参数/变量	取值范围
荷电状态 SOC	[0.2, 0.8]
储能投资费用参数	2 500 元/kWh 1 000 元/kW
配电网节点电压	[0.95, 1.05] p.u.
储能充放电效率	0.95
储能有功输出功率限制/MW	[0, 5]
储能无功输出功率限制/MW	[0, 5]
储能充放电效率	0.95
敏感负荷补偿目标/p.u.	[0.93, 1]
PSO 种群大小	100
PSO 最大迭代数	500
变异概率	1/d (d 为决策变量数)

4.2 分布式储能优化配置

4.2.1 分布式储能位置与容量优化配置

笔者将优化配置模型分为两层,外层优化分布式储能的接入位置,内层优化分布式储能的容量配比,求解流程为:

(1) 外层优化采用整体排序的方式对储能安装位置进行初步筛选.假设所有节点接入分布式储能,通过内层对其输出进行优化,将输出为零或者接近零的节点排除,得到分布式储能的最优接入位置.具体如下:

①电压幅值设置为 60% 额定电压,假设所有节点接入了分布式储能,并设置分布式储能的有功输出为 1 MW,计算敏感负荷接入点的电压恢复量.

②在同等电压暂降下,设置分布式储能的无功输出为 1 MVar,计算敏感负荷接入点的电压恢复量.

③分别以各敏感负荷的电压恢复量和总电压恢复量进行排序,得到对单个敏感负荷补偿效果最佳接入点和综合最佳接入点.分别选取对单一敏感负荷点影响最大的接入位置和综合影响最大的接入位置作为有效接入位置,筛选节点为: 32、31、33、30、26、25、12、2.

(2) 内层优化模型采用变异的 PSO 优化,控制变量为储能容量, f_1 作为目标函数,得到输出结果.

(3) 将步骤 (2) 中储能的最优容量配置返回给外层,用来计算储能的最优接入位置.

(4) 输出分布式储能的最优配置方案,如表 2 所示.

表 2 分布式储能配置结果

Tab.2 Allocation results for location and capacity of DESS

接入位置	有功功率/MW	无功功率/Mvar	容量/(MW·h)
26	5	4.417	6.670
25	5	5	7.071
12	1.256	0.930	2.443

在该优化配置下,敏感负荷所在的节点的电压均满足了补偿要求.而且,由于储能与 DVR 补偿原理不同,采用储能补偿时可以抬升接入点所在支路电压水平.在本算例中,虽然仅将 4 个敏感负荷的电压指标计入了目标函数,但是经过优化之后,所有节点的电压均有抬升,其中三分之二的节点电压达到了额定电压 90% 以上.

4.2.2 优化结果验证

从初步筛选的 8 个分布式储能接入位置中随机抽取 3 个位置组合,仅对容量进行优化,其结果对比如表 3 所示.

在表 3 中,第 3、5 组虽然满足了补偿的要求,但是所需要的容量比第 1 组更大;第 2、4 组不满足敏感负荷电压要求.结果表明笔者提出的优化配置方案能满足经济性与技术性的要求.

4.3 储能与 DVR 联合补偿控制策略仿真分析

为了验证笔者提出联合补偿控制策略,采用 IEEE 33 系统进行仿真实验.敏感负荷的位置为节点 7、25、26 和 33,分布式储能的配置如表 2 所示.

4.3.1 只采用分布式储能进行补偿

电压暂降幅值取 70% 额定电压,将储能接

表 3 随机接入位置的部分优化结果

Tab.3 Partial results for random access locations of DESS

方案 编号	节点号/有功输出/MW/ 无功输出/Mvar/容量/ MWh	总容量	完成 补偿 目标	电压越 限节点 数/个
1	12/1.076/0.797/1.339	12.054	4/4	0
	25/4.38/1.584/4.658			
	26/5.00/5.00/6.057			
2	25/5.000/5.000/7.071	16.584	3/4	5
	30/5.000/4.763/6.906			
	31/2.608/0.000/2.608			
3	25/4.525/1.403/4.738	12.545	4/4	0
	26/4.508/3.630/5.788			
	30/1.705/1.081/2.019			
4	12/4.348/2.273/4.906	19.056	2/4	5
	25/3.837/2.459/4.557			
	31/2.567/1.900/3.193			
5	25/3.783/2.373/4.466	12.464	4/4	0
	26/4.921/4.209/6.475			
	32/1.056/1.097/1.522			

入位置带入优化模型进行计算,分别取补偿目标为 0.93(p.u.) 和 1.00(p.u.) ,结果如表 4 和图 5 所示.

表 4 分布式储能输出功率的优化结果

Tab.4 Solutions for the output of DESS output

补偿目标/ (p.u.)	接入位置	有功功率/ MW	无功功率/ Mvar
0.93	12	4.494	4.417
	25	3.088	2.959
	26	2.711	1.232
1.00	12	5.000	5.000
	25	4.982	5.000
	26	3.549	1.162

在补偿效果方面,单独使用分布式储能进行电压暂降补偿时,可以完成较低补偿目标的补偿任务.当补偿目标为 1.00(p.u.) 时,位于节点 12、25 处的分布式储能均达到了输出功率上限,但是节点 10~18 均发生了电压越限,影响电网的安全运行.

在补偿效率方面,仅采用分布式储能进行补偿时,所需要的储能容量很大,且由于补偿不精准,会导致部分节点过电压.

4.3.2 只采用 DVR 进行补偿

在同样的电压暂降条件下,若只采用 DVR 进行补偿,则 DVR 需要补偿全部暂降功率缺额,其结果如表 5 和图 6 所示.




图 5 只采用分布式储能进行补偿的电压分布

Fig.5 The voltage profile when only using DESS

表 5 DVR 补偿结果

Tab.5 Solutions for output of DVR

节点 编号	补偿电压 缺额/(p.u.)	最大电流/ (p.u.)	最大容量 比例/%
7	0.413	0.340+j0.170	70.190
25	0.370	0.667+j0.318	58.730
26	0.405	0.1008+j0.050	68.067
33	0.428	0.105+j0.070	74.830




图 6 只采用 DVR 进行补偿的电压分布

Fig.6 The voltage profile when only using DVR

仅采用 DVR 进行补偿时,虽然敏感负荷上的电压达到了补偿要求,但是整个配电网中的电压分布较差.同时,在发生深度电压暂降时,需要 DVR 的容量较大,由于 DVR 设备功能的单一性,提高 DVR 的配置容量所需的成本会较高.在此算例中需要敏感负荷容量的 35% 才能满足补偿需求,对比储能与 DVR 联合补偿的 DVR 容量需求提高了 10%.

4.3.3 采用储能与 DVR 联合补偿

在所有敏感负荷上加装 DVR 设备,总补偿目标设为 1.00(p.u.) ,储能的补偿目标设为 0.8

(p.u.), 缺额由 DVR 设备补齐, 分布式储能和 DVR 输出结果、电压分布曲线如表 6、7 和图 7 所示。

表 6 DVR 补偿结果

Tab.6 Results for the output of DVR

节点编号	补偿电压缺额/(p.u.)	最大电流/(p.u.)	最大容量比例/%
7	0.196	0.249+j0.124	24.38
25	0.199	0.524+j0.250	24.84
26	0.183	0.073+j0.037	22.40
33	0.199	0.075+j0.050	24.84

表 7 分布式储能输出功率的优化结果

Tab.7 Results for the output of DESS

接入位置	有功功率/MW	无功功率/Mvar
12	3.477	1.893
25	1.783	1.509
26	0.590	0.295




图 7 分布式储能与 DVR 联合补偿的电压分布

Fig.7 The voltage profile when combining DESS and DVR for voltage sag compensation

采用分布式储能与 DVR 联合补偿时:一方面,不仅保证了敏感负荷上的补偿效果,也抬升了整体线路电压。同时,其分布式储能的输出功率较低,在抬升整体电压的同时不会造成节点电压超限。另一方面,DVR 的配置容量也较低,本算例中只需要敏感负荷容量的 25%即可满足补偿需求。

5 结论

(1) 在分布式储能优化配置方面,建立以经济性与电压安全性为目标的双层优化模型,外层优化分布式储能接入位置,内存优化储能容量。结果表明,在计算分布式储能安装位置时,根据电压灵敏度排序确定了初始安装位置范围,减少了计算复杂度,提高了优化速度。其次,该结果与随机

生成的对照组对比发现,其配置结果所需的总容量更小。

(2) 在分布式储能与 DVR 联合补偿电压暂降方面,以补偿成本和敏感负荷的电压满意度为目标,建立了分布式储能与电压动态补偿器联合补偿的控制模型。在仿真中对比了 3 种补偿方式,发现采用分布式储能与 DVR 联合补偿时,其补偿效果优于只采用分布式储能,其补偿耐久能力高于只采用 DVR 进行补偿。并且,采用分布式储能与 DVR 进行联合补偿,可减少补偿设备数量,降低补偿设备投资。

参考文献:

- [1] 姜鹏. 统一电能质量控制器的仿真及实验研究[D]. 北京: 北京交通大学电气工程学院, 2014.
- [2] 钟云, 张建成. 基于超级电容器储能的电压暂降补偿分析[J]. 电力自动化设备, 2005, 25(6): 43-45.
- [3] 卜凡鹏. 固态切换开关(SSTS)的研究[D]. 北京: 北京交通大学电气工程学院, 2011.
- [4] 王同勋, 薛禹胜, CHOI S S. 动态电压恢复器研究综述[J]. 电力系统自动化, 2007, 31(9): 101-107.
- [5] CHOI S S, LI J D, VILATHGAMUWA D M. A generalized voltage compensation strategy for mitigating the impacts of voltage sags/swells[J]. IEEE Transactions on Power Delivery, 2005, 20(3): 2289-2297.
- [6] 尹婷, 陈轩恕, 刘飞, 等. 基于混合储能系统的动态电压恢复器[J]. 高电压技术, 2009, 35(1): 181-185.
- [7] WEN S, LAN H, FU Q, et al. Economic allocation for energy storage system considering wind power distribution[J]. IEEE Transactions on Power Systems, 2015, 30(2): 644-652.
- [8] 程庭莉, 陈民铀, 罗欢. 含可再生能源发电的配网储能多目标优化配置方法[J]. 电网技术, 2017, 41(9): 2808-2815.
- [9] 黄小庆, 曹阳, 吴卫良, 等. 考虑电压暂降指标的电压协调控制方法研究[J]. 电力系统保护与控制, 2015, 43(22): 147-154.
- [10] 李振坤, 陈思宇, 符杨, 等. 基于时序电压灵敏度的有源配电网储能优化配置[J]. 中国电机工程学报, 2017, 37(16): 4630-4640.
- [11] 程志江, 李永东, 谢永流, 等. 带超级电容的光伏发电微网系统混合储能控制策略[J]. 电网技术, 2015, 39(10): 2739-2745.
- [12] 张任. 基于储能的微电网电能质量快速治理研究[D]. 杭州: 浙江工业大学机械工程学院, 2017.
- [13] 向育鹏, 卫志农, 孙国强, 等. 基于全寿命周期成本的配电网蓄电池储能系统的优化配置[J]. 电网技术, 2015, 39(1): 264-270.

- [14] GABASH A, LI P. Flexible optimal operation of battery storage systems for energy supply networks [J]. IEEE Transactions on Power Systems, 2013, 28(3) : 2788–2797.
- [15] 梁静,刘睿,瞿博阳,等. 进化算法在大规模优化问题中的应用综述 [J]. 郑州大学学报(工学版), 2018,39(3) : 15–21.
- [16] KUNDU R, DAS S, MUKHERJEE R, et al. An improved particle swarm optimizer with difference mean based perturbation [J]. Neurocomputing, 2014, 129 (129) : 315–333.
- [17] 程衫,陈民铀,黄慧宸.含分布式发电的配电网多目标无功优化策略研究 [J]. 电力系统保护与控制, 2013,41(10) : 45–50.

Optimal Allocation and Control Strategy of Distributed Energy Storage System for Compensating Voltage Sag

MA Xing¹, LI Junjie¹, LI Bo², XIE Wei², GAO Mengkai², CHEN Minyou²

(1.Electrical Power Research Institute of State Grid Chongqing Electric Power Company, Chongqing 401120, China; 2.School of Electrical Engineering, Chongqing University, Chongqing 400044, China)

Abstract: In order to provide voltage sag compensation in distribution network, a model to optimize the allocation of distributed energy storage system (DESS) and a control strategy incorporating DESS and dynamic voltage restorer (DVR) was formulated and solved have been formulated and solved. In this paper, a double-layer DESS allocation model based on minimize the installation cost of DESS, voltage sag detection equipment and voltage sag of sensitive load was formulated to find optimal configuration of DESS. Then, the minimization cost of DVR, DESS and maximization of voltage for sensitive loads were achieved by joint compensation control model combining DESS and DVR. Moreover, the particle swarm optimization algorithm with random mutation was employed to seek optimal solution of the proposed model. This approach was tested on the IEEE 33 bus system integrated with DESS and sensitive load. The results revealed that the optimal allocation model could reduce storage capacity, and dispatch model could successfully meet the demands when considering voltage sag and further reduce the investment of the compensation equipment.

Key words: distributed energy storage system; voltage sag; compensation strategy; voltage dynamic restorer; cost

文章编号: 1671-6833(2019)05-0072-07

基于风电可调节不确定代价的风光柴储联合优化调度

薛金花¹, 王德顺¹, 郁正纲², 李红², 朱信舜³, 窦春霞⁴

(1. 中国电力科学研究院有限公司, 江苏 南京 210009; 2. 国网江苏省电力有限公司连云港供电分公司, 江苏 连云港 222000; 3. 南京南瑞继保工程技术有限公司, 江苏 南京 210009; 4. 南京邮电大学先进技术研究院, 江苏 南京 210023)

摘要: 针对孤岛微电网中间歇式能源出力的不确定性问题, 基于可调节风电的不确定代价, 考虑蓄电池储能系统和柴油发电机组的控制特性. 在系统稳定供电的前提下, 以系统运维成本、污染物排放量为目标, 引入可调负荷充放电等相关约束, 建立孤岛微电网能量优化调度模型, 优化储能充放电与柴油机组出力. 并在此基础上, 利用改进粒子群算法对模型进行求解, 根据所建模型三种情景对比, 进一步分析9个不同调度区间系数对调度结果的影响机理, 算例仿真验证了可调节风电不确定代价优化模型和优化方法的有效性和可行性.

关键词: 孤岛微电网; 不确定代价; 蓄电池储能系统; 优化调度; 粒子群算法

中图分类号: TM615

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.006

0 引言

随着间歇性能源的快速发展, 孤岛微电网供电侧与用电侧因风光能源出力不确定以及负荷需求波动而无法达到完全适配^[1], 所以必须配备可控分布式能源(如柴油发电机组、蓄电池储能系统)对微电网进行整体调控. 柴油发电机组主控是传统的微电网维稳方法, 能够平衡变化幅度较大的系统净负荷波动, 实现系统频率的无差控制, 但反应时间较长. 蓄电池主控是近期主流的微电网维稳方案, 可在短时间内对小幅随机净负荷波动做出应对, 提高独立微电网系统的瞬态频率响应特性和频率质量, 但稳定性较差^[2-3]. 故将柴油发电机组和蓄电池储能系统结合组成混合控制系统, 优势互补, 更好地给微电网提供所需电能.

当前, 世界各国专家对单一分布式能源主控策略做了一定的研究, 但对于混合控制系统的研究还比较少. 文献[4]给出了一个小功率离

网型风光柴储混合发电系统模型, 根据气象条件、蓄电池荷电状态的变化, 合理调节能量流动、分配各功率模块的功率输出. 文献[5]提出了以蓄电池储能水平为纽带的多时间尺度能量优化调度方案. 文献[6]采用基于 well-being 模型的蒙特卡罗模拟法评估风光柴储小型孤立发电系统的可靠性, 通过满足“等效净负荷”的需求达到可再生能源出力利用率最高的目标. 文献[7]根据储能系统在不同运行模式下的功能定位, 提出了一种基于 SOC 状态的微电网能量优化调度策略, 以保证日前调度的时效性.

笔者以柴油发电机组和蓄电池组混合控制系统作为风光互补微电网的主控系统和能量调节装置. 在综合考虑可再生能源出力不确定的基础上, 结合系统运维成本及燃料成本, 提出了基于可调节风电不确定代价的孤岛微电网调度策略. 并据此建立仿真模型, 通过多个仿真实验结果对比, 证明该策略可有效提高系统的可靠性与经济性.

收稿日期: 2019-01-11; 修订日期: 2019-04-07

基金项目: 国家自然科学基金重点资助项目(61533010); 国家自然科学基金青年基金(61503199, 61503193); 国网江苏省电力有限公司科技项目; 江苏省自然科学基金青年基金(BK20150853); 电力电子变压器研制及其在配电网的示范应用(J2017140)

作者简介: 薛金花(1984—), 女, 江苏人, 中国电力科学研究院高级工程师, 主要从事储能的技术和经济性分析研究, E-mail: xuejinhua@epri.sgcc.com.cn.

通信作者: 窦春霞(1967—), 女, 南京邮电大学教授, 博导, 研究方向为新能源控制技术、微电网控制、神经网络、自适应控制等, E-mail: cxdou@ysu.edu.cn.

1 风光互补微电网模型

风光互补微电网模型利用风能、光伏发电互补与储能单元结合来提高微电网供电的可靠性和安全性^[8].风光互补微电网结构如图1所示.




图1 风光柴储微电网结构图

Fig.1 Scenery diesel storage micro grid structure

1.1 光伏发电单元建模

光伏系统的输出功率跟辐照强度和空气温度等有紧密关系^[9],光伏出力公式为:

$$P_{pv} = \alpha_{pv} R_{pv} \frac{L_n}{L_s} [1 + \lambda (T_1 - T_s)], \quad (1)$$

式中: P_{pv} 为光伏出力; α_{pv} 为光伏阵列的功率因素; R_{pv} 为光伏阵列总电阻; L_n 和 L_s 分别代表此刻和标准状态下的光照强度; λ 为温度系数; T_1 和 T_s 分别为当前时刻、标准状态下光伏阵列表面温度.

1.2 风力发电单元建模

风机捕获的风能及风机轴上输出的机械功率分别为^[10]:

$$P_w = \frac{1}{2} C_p \rho \pi r^2 v^3, \quad (2)$$

$$P_{mech_opt} = 0.5 C_{pmax} \rho \pi r^2 \left(\frac{\omega_{wt} r}{\lambda_{opt}} \right)^3, \quad (3)$$

式中: P_w 为风机捕获的风能; C_p 为风能利用效率; ρ 为空气密度; r 为风机叶片半径; v 为风机捕获风速; P_{mech_opt} 为风机轴上产生的机械功率; C_{pmax} 为最大风能利用率系数; ω_{wt} 为风机转速; λ_{opt} 为最佳叶尖速比.

1.3 柴油机组建模

(1) 油耗关系.柴油发电机组耗油量 F 与其输出功率 P_d 之间函数关系为^[11]:

$$F = F_s Y_d + k P_d, \quad (4)$$

式中: F_s 为柴油机组单位功耗; Y_d 为柴油机组额定功率; k 为柴油机组燃料取消斜率.

(2) 成本函数.柴油发电机的耗能特性函

数为:

$$f(P_d) = \alpha_d P_d^2 + \beta_d P_d + \xi_d, \quad (5)$$

式中: $f(P_d)$ 为柴油机组小时燃料费; α_d 、 β_d 和 ξ_d 均为柴油机组的费用系数.

1.4 蓄电池储能系统建模

蓄电池储能系统运营成本模型如下:

$$F_{bat} = \sum_{m=1}^N \left(\frac{E_{bat}}{\eta} \times c_e \times \omega_m \right), \quad (6)$$

式中: F_{bat} 为储能运维成本; N 为储能寿命年限; m 为储能使用年份; E_{bat} 为储能额定容量; η 为储能转换效率,且 $0 \leq \eta \leq 1$; c_e 为储能单位容量投资成本; ω_m 为储能年运维成本占投资成本的比例.

1.5 负荷模型

微电网中负荷可分为固定负荷和可调负荷,间歇性能源无法满足负荷需求时微电网优先给固定负荷供能,同时削减可调负荷.

本文涉及的可调负荷以合约形式允许供电公司有偿地削减可调负荷的负荷需求,可调负荷补偿成本模型如下:

$$\begin{cases} C_{adj} = \gamma_{adj} P_{adj}(t) \Delta t \\ P_{adj}(t) = \eta P_{load}(t) \end{cases}, \quad (7)$$

式中: C_{adj} 为孤岛微电网运行时可调负荷的补偿成本; γ_{adj} 为供电公司对可调负荷单位功率的补偿电价,同时补偿电价为一定值且低于微电网向用户售电的电价; $P_{adj}(t)$ 为 t 时刻的可调负荷功率; η 为可调负荷与总负荷量的占比.

2 孤岛微电网的能量调度建模

2.1 柴油机组配置

传统孤岛微电网系统的净负荷通过柴油机供能解决.然而,柴油机组的选择十分复杂,单台容量太小会频繁启动,增加运维成本;单台容量太大会因机组长期处于低功率输出而导致机组单位油耗比增大,降低柴油机组使用年限,因此,柴油机组的容量配置要进行适当优化^[12].

单台柴油机最佳负荷率一般在 75%,此时既留有一定的功率裕度,经济性也相对较高;而最低负荷率通常在 25%~30%,若低于此下限,柴油机组单位油耗比增大,同时运行寿命降低^[13].

新能源发电系统一般在白天有较大的输出功率,且长时间内输出波动较小.考虑按额定功率将机组分为两组,大功率柴油机组的总功率最大值应略大于负荷上限,使得小功率柴油机额定功率的 75%和大功率柴油机组额定功率 30%保持一

致.不仅优化了机组组合,减少燃料消耗和维护成本,微电网也有更大的调节裕度.

2.2 蓄电池下垂控制

蓄电池控制分为有功-频率控制(Pf 控制)和无功-电压控制($Q-U$ 控制),通常利用蓄电池的逆变器来实现;蓄电池逆变器通过控制 d 轴电流分量快速响应外环的频率差(Δf)信号,对蓄电池组的输出功率参考值(P_{ref})进行调控^[14].为了避免蓄电池频繁充放电,通常设定频率稳定区、输出上下值及锁定区.如图2所示,区域A为Droop控制的调节锁定区,系统频率在该区域内属于正常波动,蓄电池组不参加频率调节.结合上一章的研究,在更大频率差情况下,将频率调节交于柴油发电机组,蓄电池退出频率控制. BH 和 BL 是蓄电池组频率调节区域. DH 和 DL 是柴油机组频率调节区域.




图2 微电源下垂控制特性图

Fig.2 Micro-power droop control characteristics

由此可知,基于蓄电池组 Pf 控制特性的改进函数如下式(8),式(10)为其Droop控制系数.

$$P_{ref} = \varphi_p \times (f_0 - f_m) + P_0, \quad (8)$$

$$f_m \in [f_3, f_1] \text{ or } [f_2, f_4], \quad (9)$$

$$\varphi_p = \frac{P_{max} - P_0}{f_0 - f_{min}}, \quad (10)$$

式中: P_{ref} 为蓄电池组出力的参考值; φ_p 是下垂控制系数; f_0 为额定频率; f_m 为实测频率; P_0 为有功功率初始值; P_{max} 、 P_{min} 分别是蓄电池有功功率输出上、下限值.

2.3 系统能量调度策略

由于分布式能源的随机性、不可调度性等,柴油机组、电池储能系统可以充当系统备用能源,通过充放电对整个系统起到能量缓冲的作用.

$$\Delta P(t) = P_{load}(t) - \sum_{j=1}^{N_w} P_{wj}(t) - P_{pv}(t) - P_{adj}(t), \quad (11)$$

式中: $\Delta P(t)$ 为系统净负荷; P_{load} 为负荷总需求量.

① $\Delta P(t) \leq 0$,新能源分布式电源发电功率过

剩,如果充电功率和剩余电量在蓄电池约束范围内,蓄电池组充电.当供电功率或剩余电量超出阈值时,蓄电池以最大限定功率 $P_{cmax}(t)$ 充能剩余能量通过卸荷元件消耗.

②新能源分布式电源发电功率不足,则有3种运行策略:一是当 $\Delta P(t) < P_{cmax}(t)$ 时,柴油机不启动,蓄电池组放电来补充不足;二是 $\Delta P(t) > P_{cmax}(t)$ 且与小功率柴油机组最佳负荷较为接近,启动小功率柴油机组且以最佳负荷工作,蓄电池组补充调节;三是 $P(t) > P_{cmax}(t)$ 且与大功率柴油机组最佳负荷较为接近,启动大功率柴油机组且以最佳负荷工作,蓄电池组补充调节^[14].当柴油机储能运行成本较高且负荷可调时,系统选择削减部分负荷来满足负荷平衡,此时可调负荷补偿成本要小于柴油机、储能运行工作成本.

2.4 目标函数

笔者以风光柴储的运维成本最小、柴油机燃料成本最小以及可调负荷的补偿成本最小为目标进行优化,转化公式如下:

$$\min C = \sum_{i=1}^N C_x \times \rho_{i,x}(P_{i,t}), \quad (12)$$

$$C_G = \sum_{i=1}^N CE_i(P_{i,t}), \quad (13)$$

$$C_{OM} = \sum_{i=1}^N P_{i,t} \times CO_i, \quad (14)$$

$$C_{DP} = \sum_{i=1}^N \frac{ADCC_i}{8760 \times cf_1 \times P_{g,i}}, \quad (15)$$

式中: C_x 为各种成本; $\rho_{i,x}$ 为各成本比重; $P_{i,t}$ 为柴油机组的运维成本,元/h; C_G 为柴油机组燃料消耗成本,元/h; CE_i 为第 i 个柴油机组燃料消耗成本,元/h; C_{OM} 为运维成本,元/h; CO_i 为运维系数,元/(kW·h); C_{DP} 为耗损成本; $ADCC_i$ 为柴油机组输出功率上限制,具体公式如式(15)和式(16)所示; cf_1 为容量因素; $P_{g,i}$ 为最大输出功率.

$$ADCC = IC_o \times cfr, \quad (16)$$

$$cfr = r - \frac{r}{(1+r)^m - 1}, \quad (17)$$

式中: IC_o 为风电、光伏和蓄电池组的安装成本,元/kW; cfr 为成本回收系数; r 为收益率; m 为发电单元使用年限.

微网环保性的最终目标是微网处理发电设备污染物费用 C_2 最少,转化公式如下:

$$\min C_2 = \sum_{i=1}^N C_x \times \rho_{i,x}(P_{i,t}). \quad (18)$$

式中: x 为污染物处理种类; C_x 为处理该类污染物的成本,元/kg; $\rho_{i,x}$ 为输出单位电能时柴油机组排放的污染物,g/(kW·h).

微网中可调负荷补偿成本,转化公式如下:

$$\min C_{\text{adj}} = \gamma_{\text{adj}} P_{\text{adj}}(t) \Delta t. \quad (19)$$

2.5 约束条件

功率平衡约束

$$\sum_{i=1}^N P_{i,t} = P_{L,t} - P_{\text{Bat},t} - \sum_{j=1}^{N_w} P_{w,j,t} - P_{\text{pv},t}, \quad (20)$$

式中: $P_{i,t}$ 为 t 时刻的柴油机组出力; $P_{L,t}$ 为 t 时刻的负荷需求; $P_{\text{Bat},t}$ 为 t 时刻的蓄电池出力; $P_{w,j,t}$ 为 t 时刻的风电机出力; $P_{\text{pv},t}$ 为 t 时刻的光伏出力。

微电源输出功率约束

$$\begin{cases} P_i^{\min} \leq P_{i,t} \leq P_i^{\max} \\ \bar{P}_{w,j}(t) + \gamma_{w,j}(t) \tilde{P}_{w,j}^{\min}(t) \leq P_{w,j,t} \leq \bar{P}_{w,j}(t) + \gamma_{w,j}(t) \tilde{P}_{w,j}^{\max}(t) \end{cases}, \quad (21)$$

式中: P_i^{\min} 、 P_i^{\max} 分别为各发电单元的最小、最大输出功率。

蓄电池荷电状态约束

$$\begin{cases} SOC_{\min} \leq SOC_t \leq SOC_{\max} \\ E_{t+1} = E_t + (P_{\text{pv},t} + P_{w,t} + P_{d,t} - P_{\text{load},t}) * \eta_c, \\ E_{t+1} = E_t - (P_{\text{pv},t} + P_{w,t} + P_{d,t} - P_{\text{load},t}) * \eta_d. \end{cases} \quad (22)$$

式中: SOC_{\min} 、 SOC_{\max} 分别为蓄电池最低、最高的荷电状态; E_t 为 t 时刻蓄电池的容量; η_c 、 η_d 分别为充放电效率。笔者将 SOC 范围限定在 $[20\%, 80\%]$, 即 $SOC_{\min} = 20\%$, $SOC_{\max} = 80\%$ 。

爬坡率约束

$$\begin{cases} P_t - P_{t-1} \leq UR \\ P_{t-1} - P_t \leq DR \end{cases}, \quad (23)$$

其中, P_t 为 t 时刻可控发电装置输出功率, UR 、 DR 分别是可控发电装置上升、下降出力限制。

可调负荷功率约束

为保证微网内用户体验、安全稳定运行,可调负荷功率不得超过总负荷量的 25%。

$$\begin{cases} \underline{\eta} \leq \eta \leq \bar{\eta} \\ \underline{\eta} P_{\text{load}}(t) \leq P_{\text{adj}}(t) \leq \bar{\eta} P_{\text{load}}(t) \end{cases}, \quad (24)$$

其中, $\underline{\eta}$ 、 $\bar{\eta}$ 为可调负荷占总负荷量可调比重的上下限。

3 模型求解

笔者采用粒子群算法求解优化策略,算法从随机解出发,通过迭代不断追随当前搜索到的最优解来寻找全局最优值^[15],如图3所示。

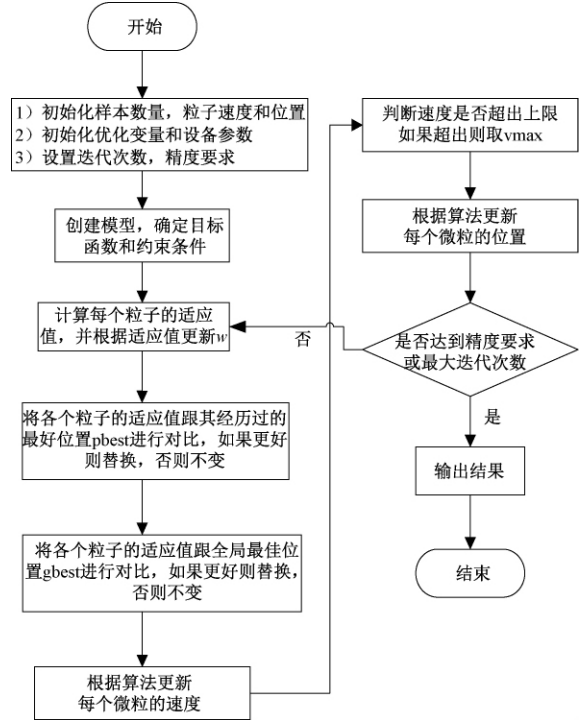


图3 基于粒子群算法的微电网控制策略流程图

Fig.3 Particle swarm optimization based microgrid control strategy flow

为了提升算法寻优速度,笔者对惯性权重进行动态更新^[16],更新公式可表示为:

$$w = w_{\max} - (w_{\max} - w_{\min}) \times k / \text{iter}_{\max}, \quad (25)$$

式中: w_{\max} 、 w_{\min} 分别为惯性权重上限、下限; iter_{\max} 为迭代次数的上限。

4 算例分析

以某孤岛微电网为研究对象,主要包括 8 组 50 kW 光伏阵列,2 台 60 kW 风力发电机,容量为 400 kW·h 的蓄电池储能系统,一组总功率为 400 kW 的柴油机^[17],一组总功率为 160 kW 的柴油机,并选取一天二十四小时作为一个调度周期。表 1 是各分布式电源的维护和燃料成本系数。

表 1 各分布式电源的维护和燃料成本系数

Tab.1 Maintenance and fuel cost factors for each distributed power supply

装置	维护费用/ (元·kW ⁻¹ ·h ⁻¹)	燃料成本/ (元·kW ⁻¹ ·h ⁻¹)
风力发电机	2.2	0
光伏阵列	2.2	0
柴油发电机	1.5	2

为充分利用可再生能源,笔者选取风速较低,日照强度充足的白天,仿真算例的光伏阵列以及风力发电机组按最大功率进行发电,分别在柴油

发电机组做主电源的无优化孤岛微电网、蓄电池做主电源的无优化孤岛微电网和基于笔者提出的能量调度孤岛微电网3种环境下进行对比仿真^[18-19],结果如图4所示。

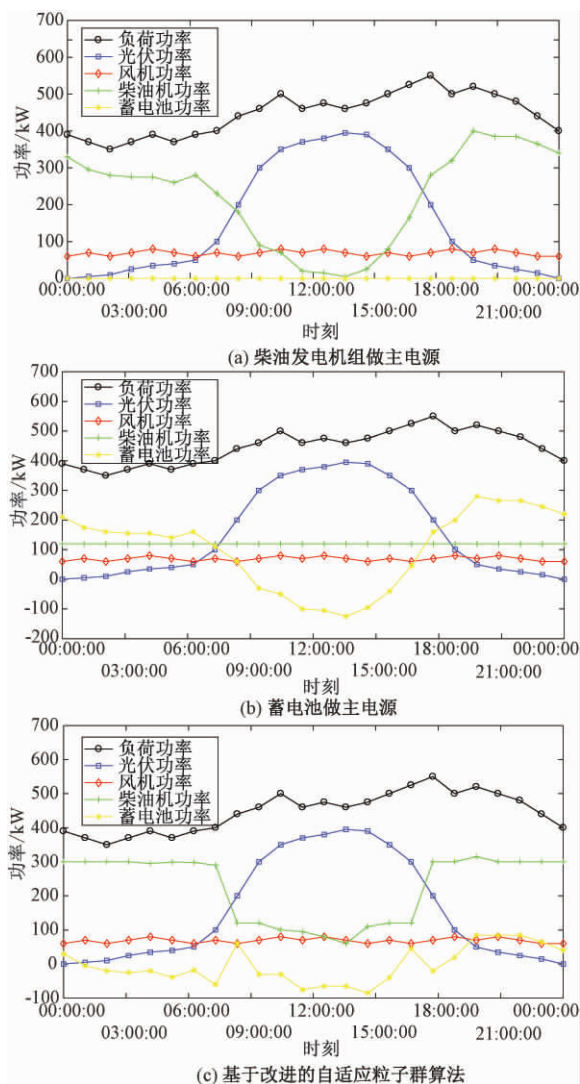


图4 孤岛微电网能量管理模型仿真结果图

Fig.4 Simulation results of an island microgrid energy management model

图4(a)中,当 $P_{DEpayload} = P_{Load} - P_{pv} - P_{SB} - P_{wt} > 0$ 时,切除蓄电池系统,启动柴油机组应对系统净负荷平衡波动.当新能源发电系统总功率超出负荷需求时,柴油机组转入最低启停功率保证系统的频率电压稳定。

图5中,当 $P_{SB} = P_{Load} - P_{pv} - P_{DEpayload} - P_{wt} \neq 0$ 时,利用蓄电池的放电来平衡系统的净负荷波动,蓄电池的出力功率随系统净负荷的波动而波动,此时柴油机组以最低负荷功率运行。

从图4可以看出,系统以柴油发电机组主控时,充分利用可再生能源蓄电池的“吞吐”特性来维持系统的稳定.从仿真来看,当新能源发电系统




图5 不同主控电源时可调负荷削减功率

Fig.5 Adjustable load reduction power for different main control power supplies

输出功率不足时,柴油发电机组输出功率保持在300 kW;当新能源发电系统输出功率充足时,柴油发电机组输出功率保持在100 kW,波动起伏非常小.蓄电池的输入输出功率范围在0~100 kW^[19],两组可控调节供电系统输出功率均比较稳定。

基于不同的不确定性预算要求,通过调整调度间隔系数获得不同间隔.通过求解鲁棒模型,在表2中列出了9种不确定性等级下包括燃料成本,不确定性预算和总输出违规功率的数据,几乎所有数据都按升序排列.当风电出力较大时,柴油机组输出减少,此时所耗费的燃料成本也随之降低;否则,燃料成本增加.总输出违规设置为1.0 MW,当不同级别的违规不超过1.0 MW时,可以认为利用鲁棒优化方法处理约束条件的方法是可行的.在孤岛微网中,通过考虑间歇性能源的不确定性等级与经济性之间的比例关系,对实际运营有着重要的指导作用。

表2 9个调度区间系数与调度结果

Tab.2 Scheduling results with nine dispatch interval coefficients

不确定等级	燃料成本/元	Δt	违规功率/kW
1	251 735	0.0	0.977 6
2	251 305	0.5	0.971 0
3	251 089	1.0	0.963 5
4	249 120	1.0	0.961 4
5	247 983	2.0	0.957 8
6	247 056	2.0	0.952 3
7	246 833	3.0	0.946 5
8	246 354	3.0	0.941 1
9	245 583	4.0	0.936 9

如图5所示,两条曲线分别为柴油机和蓄电池主控时系统可调负荷的调节功率.分析可知,光伏夜间无法供电,且柴油机发电成本高于负荷补偿成本,此时选择削减可调负荷;白天光照

充足,可再生能源发电满足负荷需求且为获得更大收益,充分利用负荷消纳而蓄电池调度成本低于柴油发电机,故可调负荷曲线较柴油机主控时更低,此时微网内可再生能源消纳能力更高,弃光率更少,系统供电可靠性及稳定性更高。

在图6中,柴油发电机做主电源的无优化孤岛微电网的总成本为 4.57×10^4 元,柴油发电机组的燃料消耗较大,且长时间低功率运行会大大提高柴油发电机耗损,增加设备的损失.在蓄电池做主电源的无优化孤岛微电网中的总成本为 4.12×10^4 元,当新能源发电功率出现波动时,蓄电池充放电(深充深放)次数明显加剧.在实际工程中,蓄电池充放电深度与损耗成本呈指数关系,充放电深度越大,使用寿命越小,损耗成本越高,系统经济成本就越低.笔者提出的不确定成本代价的孤岛微电网能量调度策略中,柴油发电机组根据新能源发电功率及蓄电池充放阈值调整输出功率,并据此启停柴油机,避免了柴油机的频繁启停,使其保持在最佳负荷区间工作,单位油耗比、运维成本都得到大幅降低.同时蓄电池浅充浅放,其损耗成本也得到改善,此时系统总成本为 3.91×10^4 元。




图6 3种模式下微电网的分布式电源发电成本对比图

Fig.6 Comparison of distributed power generation costs of microgrid in three different modes

图7是利用普通 PSO 算法进行优化求解,寻找到的全局最优值 fitness 为 4.58×10^4 元,此时迭代次数为 185.图8为利用改进 PSO 算法求解得到整体最优解的曲线图,此时最优值 fitness 为 3.91×10^4 ,迭代次数为 158.对比两者的全局最优值和迭代次数可知,利用改进后的 PSO 算法进行优化,全局搜索能力和收敛速度方面有明显改善。

从仿真得到的结果来看,利用改进 PSO 算法优化本文中的孤岛微电网多目标成本问题,比未优化 PSO 算法得到的成本数值更低。




图7 普通粒子群算法的整体最佳解

Fig.7 The best solution of general particle swarm optimization




图8 改进粒子群算法的整体最佳解

Fig.8 The global optimal solution of the improved particle swarm optimization algorithm

5 结论

提出了基于可调节风电不确定代价的孤岛微电网调度策略,由于光伏、风电的不确定性带来不确定性成本问题,考虑蓄电池组快速调节特性以及柴油机发电缓慢的调节特性,建立了基于不同补偿功率的孤岛微电网频率分层控制,根据净负荷功率大小,利用蓄电池组处理变化幅度较小和变化周期较短的随机净负荷波动,使其保持在较小范围内,提高孤岛微电网系统的瞬态频率响应特性;利用柴油发电机应对变化幅度较大和变化周期较长的系统净负荷波动,以此控制频率的无差调节,保证系统充放电频率稳定.在3种不同情景下对微网系统优化模型进行对比,进一步分析9个不同调度区间系数对调度结果的影响机理,仿真结果验证了所提方法能够有效提高孤岛微电网供电的可靠性,同时保证系统运营的经济性。

参考文献:

- [1] 葛晓琳. 风光储混合发电系统优化设计与分析[J]. 上海电力学院学报, 2014, 30(4): 297-302.
- [2] 马艺玮, 杨苹, 陈思哲, 等. 含柴油发电机和蓄电池储能的独立微电网频率分层控制[J]. 控制理论与

- 应用, 2015, 32(8): 1098-1105.
- [3] 马艺玮, 杨苹, 吴捷. 含多分布式电源独立微电网的混合控制策略[J]. 电力系统自动化, 2015, 39(11): 103-109.
- [4] 陈斌, 殷慧兰, 胡洛瑄, 等. 基于 Matlab/Simulink 的风光柴储发电系统仿真[J]. 电气电子教学学报, 2013, 35(4): 84-88.
- [5] 李保恩, 李献伟, 毋炳鑫. 基于储能 SOC 状态的微电网能量优化调度策略研究[J]. 电力系统保护与控制, 2017, 45(11): 108-114.
- [6] 陈柔伊, 董旭柱, 黄邵远, 等. 孤岛微网系统柴发配置分析[J]. 电工电能新技术, 2014, 33(10): 58-63.
- [7] 丁明, 杨向真, 苏建徽. 基于虚拟同步发电机思想的微电网逆变电源控制策略[J]. 电力系统自动化, 2009, 33(8): 89-93.
- [8] 时珊珊, 鲁宗相, 闵勇, 等. 微电源特性分析及其对微电网负荷电压的影响[J]. 电力系统自动化, 2010, 34(17): 68-71.
- [9] 赵波. 微电网优化配置关键技术及应用[M]. 北京: 科学出版社, 2015.
- [10] 李佳华, 马连博, 王兴伟, 等. 基于多目标蜂群进化优化的微电网能量调度方法[J]. 郑州大学学报(工学版), 2018, 39(6): 50-58.
- [11] BINDNER H, CRONIN T, LUNDSAGER P, et al. Lifetime modelling of lead acid batteries [J]. Journal of Power Sources, 2005, 53(1): 111-117.
- [12] 杨瑞峰, 崔志琴. 大功率柴油机组结合建模技术研究[J]. 内燃机工程, 2003, 24(3): 20-22.
- [13] 韩晓娟, 程成, 籍天明, 等. 计及电池使用寿命的混合储能系统容量优化模型[J]. 中国电机工程学报, 2013, 33(34): 91-97.
- [14] 张宏春. 柴油机超负荷运转的危害及产生机理[J]. 中国设备工程, 2017(19): 56-58.
- [15] ZHANG L Y, ZHANG J B. Optimization research on the hybrid energy storage capacity of stand-alone wind/PV micro-grid based on improved PSO [J]. Power & Energy, 2016, 37(4): 471-475.
- [16] 陆亚南, 施泉生. 基于改进粒子群算法的含分布式发电配网孤岛划分[J]. 电工电能新技术, 2016, 35(7): 17-23.
- [17] BASU M. Particle swarm optimization based goal-attainment method for dynamic economic emission dispatch [J]. Electric Power Components and Systems, 2006, 34(9): 1015-1025.
- [18] 阎新芳, 严晶晶, 冯岩. WSN 中基于梯度和粒子群优化算法的分级簇算法[J]. 郑州大学学报(工学版), 2016, 37(2): 33-36.
- [19] 李军徽, 冯爽, 崔新振, 等. 风储联合发电系统中锂电池寿命评估[J]. 电工电能新技术, 2015, 34(10): 34-38.

A Dispatching Strategy for Isolated Island Micro-grid Based on Adjustable Wind Power Uncertain Cost

XUE Jinhua¹, WANG Deshun¹, YU Zhenggang², LI Hong², ZHU Xinshun³, DOU Chunxia⁴

(1. China Electric Power Research Institute, Nanjing, Jiangsu 210009, China; 2. State Grid Jiangsu Power Co., Ltd. Lianyungang Power Supply Branch, Lianyungang City, Jiangsu 222000, China; 3. Nanjing Nanrui Jibao Engineering Technology Co., Ltd, Nanjing, Jiangsu 210009, China; 4. Institute of advanced technology, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: To deal with the uncertainty of intermittent energy in the island microgrid model, based on the uncertain cost of adjustable wind power, this paper examined the different control characteristics of battery energy storage system and diesel generator set, on the premise of ensuring stable power supply of the system, the optimized charge and discharge of energy storage and diesel unit output. And it introduced the adjustable load and other related constraints with the system cost and pollutant emission as the goal, and established the energy optimization scheduling model of the island microgrid. The related constraints such as adjustable load were introduced to establish an energy optimization scheduling model for the island microgrid. On this basis, the improved particle swarm optimization algorithm was used to solve the model. According to the comparative analysis of the micro-grid system optimization models under three different scenarios, the influence mechanism of nine different scheduling interval coefficients on the scheduling results was further analyzed. The effectiveness and feasibility of the wind turbine uncertain cost optimization model and optimization method were verified by case study.

Key words: island microgrid; uncertain cost; battery energy storage system; optimal scheduling; particle swarm optimization

文章编号: 1671-6833(2019)05-0079-05

基于多分辨率卷积神经网络的火焰检测

黄文锋¹, 徐珊珊², 孙 燚², 周 兵²

(1. 河南省科学技术信息研究院, 河南 郑州 450003; 2. 郑州大学 信息工程学院, 河南 郑州 450001)

摘 要: 采用一种基于多分辨率卷积神经网络的火焰检测算法对真实场景中的火焰目标进行检测. 该算法以 BN_Inception 网络为基础架构, 采用不同分辨率的神经网络互补学习复杂场景中火焰的多尺度视觉特征, 同时该算法重点关注检测目标场景的背景环境、局部目标和整体布局等特征. 使用该算法在构造的涵盖大多数真实场景的火焰数据集上进行测试, 实验结果表明, 提出的算法能够取得更好的检测效果, 并在实际场景中得到了有效验证.

关键词: 多分辨率卷积神经网络; 火焰检测; 深度学习; 弱监督定位

中图分类号: TP183

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.05.022

0 引言

由于火灾的不确定性和高危性, 给人们的生命健康和财产安全带来了极大的潜在威胁, 提前预防、及时检测和预警各类火灾事故变得越来越重要. 由于传统火灾探测器的局限性及监控设备的普及和图像视频处理技术的快速发展, 基于图像或视频的火焰检测技术得到了迅猛发展. 该类技术将图像视频信号输入处理单元, 利用图像处理、机器学习、模式识别等相关算法来判断有无火灾发生^[1].

早期的火焰检测研究一般是基于火焰的各类属性特征, 包括颜色、形状和动态特征^[2-7]. 近些年, 随着机器学习技术的快速发展, 尤其是深度学习技术的涌现, 一些研究者开始尝试使用深度神经网络研究传统特征难以刻画特性^[8], 并取得了不错的进展. 自从 AlexNet^[9] 取得进展以来, 人们一直致力于利用各种深度学习技术进行图像识别, 例如卷积神经网络^[9]、VGG 网络和 Inception 网络^[10]等. 2012 年, Krizhevsky 等提出基于深度学习理论的深度神经网络(DCNN) 图像分类算法, 使图像分类的准确率大大提升, 同时也带动了目标检测准确率的提升. 2015 年, Google 网络的 V1, V2, V3 和 V4 系列相继问世, 这一系列的 Inception 网络无论是训练速度还是准确率都使目标检测和分类任务有了极大

的提高. 但是, 由于目标检测任务场景的复杂性, 使得这些网络在训练过程中遇到了挑战. 因此, 多尺度或者多分辨率框架的想法被越来越多的研究者用到目标检测任务中. VGGNet^[11] 首次采用多尺度裁剪进行网络训练, 然后被 ResNet^[12] 和 Inception V3^[13] 沿用. 多尺度表示也被广泛应用于各项目目标检测任务中, 例如细粒度识别^[14]、场景识别^[15]等. 然而, 这类方法目前存在数据不充分、精度不高和场景适应性差等缺点.

针对上述问题, 笔者使用深度卷积网络——Inception Networks 对火焰目标进行检测. 为实现对各类不同场景的有效覆盖, 笔者采用多分辨率卷积网络作为基础框架, 在充分获取火焰多层次特征的基础上, 使用类激活映射方法对火焰目标进行准确定位. 笔者在包含各种场景的数据集上进行了实验, 均取得了很好的效果. 同时, 笔者也实现了一种基于 BP 神经网络的火焰识别算法, 对比结果表明, 笔者所提出的基于多分辨率卷积神经网络算法取得了更好的检测结果.

1 基于多分辨率卷积神经网络的火焰检测

笔者提出了一种基于多分辨率卷积神经网络的火焰检测算法, 如图 1 所示. 笔者在本节先描述复杂场景下火焰检测使用的基本网络架构, 然后阐述具体的多分辨率卷积神经网络架构.

收稿日期: 2018-10-17; 修订日期: 2019-02-19

基金项目: 国家自然科学基金资助项目(61872324); 河南省科技攻关资助项目(182102210072)

通信作者: 孙燚(1986—), 男, 辽宁营口人, 郑州大学信息工程学院助教, 主要从事人工智能和无线传感器网络研究,
Email: ieysun@zzu.edu.cn.

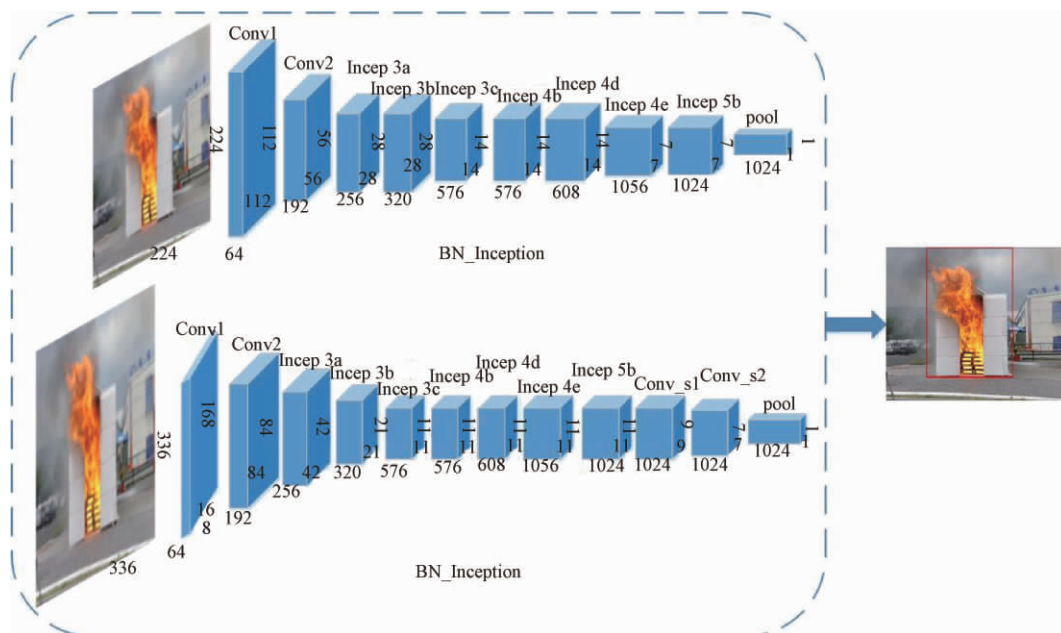


图1 多分辨率卷积神经网络框架

Fig.1 The framework of multi-resolution convolutional neural network

1.1 基础卷积神经网络架构

随着深度学习技术的快速发展,目前卷积神经网络已在图像分类和目标检测上取得了巨大的成功,有代表性的典型网络包括 AlexNet、VGGNet 和 ResNet 等^[12].综合考虑神经网络的识别性能和计算代价后,笔者选择使用 BN_Inception 作为基础框架实现所提出的火焰检测方法.

BN_Inception 架构中 inception 模块融合不同尺度特征^[17],采用不同大小的卷积核(比如 1、3、5)对感受野提取特征,设定卷积步长 stride=1,只需分别设定 padding=0、1、2,就可以得到相同维度的特征直接拼接在一起,使之更适合复杂场景识别任务.Inception 模块还采用 1×1 卷积核进行降维,参数数量大大减少.将稀疏矩阵聚类为密集的子矩阵,既保持了网络结构的稀疏性,又能利用密集矩阵的高计算性能^[16].

在 BN_Inception 架构中,批量归一化 BN 层可以加速网络收敛,提高网络性能.在卷积神经网络的训练过程中,BN 层保证每次迭代时,网络每层的输入数据都满足正态分布,它通过学到的重构参数 γ 、 β 对数据缩放平移,恢复出原始的每层学到的特征.BN 层使激活输入值落在对 Sigmoid 敏感的区域,避免梯度消失问题,参数调整率变大,收敛加快.

1.2 多分辨率卷积神经网络架构

对于复杂场景下的火焰检测,考虑到场景特征的多尺度特性,笔者提出多分辨率的卷积神经

网络架构,同时关注场景的背景环境、局部目标、整体布局等特征^[17].

多分辨率的卷积神经网络由粗分辨率和细分辨率卷积神经网络两部分构成.两种不同分辨率的卷积神经网络使用不同分辨率的训练数据作为输入,使用基础架构 BN_Inception 训练网络模型,然后进行复杂场景下的火焰检测.

1.2.1 粗分辨率卷积神经网络

粗分辨率的卷积神经网络处理图像大小是 224×224,共 13 层.它以粗略的视角观察图像关注场景的整体布局信息,容易遗漏局部细节,而一些小目标往往是场景分类的重要线索.一个强大的场景分类神经网络需要学习场景多层次的视觉概念,因此笔者还要令神经网络更精细地学习场景的视觉信息.

1.2.2 细分辨率卷积神经网络

细分辨率的卷积神经网络处理图像大小是 336×336,鉴于输入图像更大,综合考虑模型的速度和容量后,相比于粗分辨率的卷积神经网络,笔者新增加了 3 个卷积层.在细分辨率下,卷积神经网络可以更精细地学习场景,能精准地捕捉到场景中有意义的局部细节信息.

由于输入图像的分辨率不同,卷积神经网络在每层对原始图像都有大小不同的感受野,这种设计使得网络能够学习复杂场景的多尺度信息.两个不同分辨率的卷积神经网络彼此互补,对分类的概率取算术平均值作为场景的最终判断结果.

1.3 多分辨率的神经网络训练

1.3.1 数据处理

笔者通过现场拍照或是互联网共收集了 1 173 张各种复杂场景下的火焰图片.将收集的火焰图片按 2:1:1 的比例,分为训练数据集、验证数据集和测试数据集^[18].模型训练使用 caffe 深度学习框架,将图片处理为分辨率为 224×224 , 336×336 的 lmd6 格式数据供训练使用.

1.3.2 训练网络

笔者对两种不同分辨率的卷积神经网络进行并行独立训练,并使用随机批量梯度下降算法优化神经网络权重.为了实现数据增广,笔者将 $N \times N$ 的输入图像按 $[N, 0.875N, 0.75N, 0.625N, 0.5N]$ 的比例随机裁剪后输入神经网络.训练阶段,在计算好总的数量后,设定总迭代次数为 20 万次,用训练 2 000 次就测试 1 次的策略,将学习率初始化为 0.001,每训练 5 万次学习率衰减 10 倍.测试精度与迭代次数曲线如图 2 所示,其中,横轴表示迭代次数,纵轴表示测试精度.找出最优模型作为复杂场景下火焰检测的预测模型,取精度最高的模型用于复杂场景下的火焰检测.




图2 测试精度曲线图

Fig.2 Test accuracy graph

1.4 类激活映射方法

卷积神经网络通过多个卷积层提取图像的特征,从低层的位置信息逐渐到学习高层的语义信息,高层特征做加权操作后送给输出层(softmax层),得出最终分类的预测结果^[18].笔者根据卷积神经网络的这种连接结构使用类激活映射方法推导出卷积层到输出层的特征图权重,证明图像判别力强的局部区域对于最终分类结果具有重要意义.

在网络结构中,笔者使用全局平均池化层替换全连接层,保持了卷积对于场景激活区域的定位能力.对任意输入图像,使用训练好的模型检测完成后,提取输出层权重作为神经元最终做决定的依

据.把这些权重作为最后一个卷积层特征图的权重,计算出特征图的加权和,高亮显示出火焰场景中最具判别力的区域,图3为图1中火焰图像的灰度图,图中高亮区域(黄色部分)代表响应度最高的地方,即火焰目标,绿色区域表示响应度次之,蓝色区域响应度最低.将灰度图处理后与原图叠加生成热力图,图4为火焰图像的热力图,图中的高亮部分(红色区域)代表响应最高的火焰目标,绿色区域响应度次之,蓝色区域响应度最低.在热力图上使用阈值分割技术生成包围框定位出火焰在场景中的位置.在实现了火焰场景判别的情况下,笔者利用类激活映射方法,在只有图像标签的弱监督数据集上定位火焰在场景中的位置.




图3 火焰图像灰度图

Fig.3 Grayscale map of fire image




图4 火焰图像热力图

Fig.4 Heatmap of fire image

1.5 自学习的目标检测

笔者利用类激活映射方法,进一步在海量的场景数据上自动生成包围框,作为火焰检测的训练数据,指导神经网络完成目标检测任务.不仅省去了昂贵的人工标注成本,而且使火焰检测的定位精度也得到进一步提升.

2 实验对比

2.1 基于BP神经网络的火焰检测

BP神经网络是反向传输的一种神经网络,作为对比试验,笔者实现了使用BP神经网络对火焰进行检测.以火焰的圆形度、尖角数和面积变化率作为BP神经网络的输入信号,对火焰信息进行全方面的描述^[19-20].经过训练的BP神经网络输出该图片含有火焰目标的概率值.

2.2 基于多分辨率卷积神经网络的火焰检测

基于 BP 神经网络的火焰检测算法基于多特征融合思想^[21]利用火焰目标提取一些物理特征(颜色、圆弧度、尖角数和面积变化率)经过量化后作为神经网络的输入,BP 神经网络的输出层将输出该图像是火焰图像的概率,并将满足火焰特征的像素在图像中对火焰目标进行定位.笔者提出的火焰检测算法采用多分辨率卷积网络作为基础框架,在充分获取火焰多层次特征的基础上,使用类激活映射方法对火焰目标进行准确定位.这两种算法在笔者构造的涵盖各种复杂场景的火焰数据集上进行测试,并从检测正确率、定位覆盖率和处理速度等方面进行分析对比,结果如表 1 所示.

表 1 两种算法检测结果对比

Tab.1 Comparison of detection results of two algorithms

算法	检测正确率/ %	定位覆盖率/ %	处理速度/ fps
BP 网络	67.5	52.7	5
笔者算法	95.8	86.3	8

表 1 中的正确率是指在涵盖各种复杂场景的 1 173 张火焰图像数据集上实验,能够正确识别火焰在整个数据集中所占的百分比.笔者定义目标的定位框与真值的 IOU^[4]值大于 50%的图像在整个数据集所占的百分比.定位覆盖率是能够正确识别火焰目标并且准确定位出火焰目标范围在整个数据集中所占的百分比.

由表 1 可知,由于 BP 神经网络的训练数据过多地依赖于传统的火焰图像特征,因此,会发生错检和漏检的情况.而笔者所提方法将火焰检测的正确率提高了 28.3%,其中所采用的弱监督定位方法,可以极大地提高对火焰目标的定位和框选覆盖准确率.另外,笔者提出的网络框架采用批量归一化的处理方法,极大地提高了对图像的处理速度,部分结果如图 5 所示.

其中,图(a)为基于 BP 神经网络的火焰检测算法对“晚霞”的检测结果,结果显示将晚霞误识别为火焰,但是笔者所提出的算法不会发生类似的错检情况(如图(b)).图(c)为基于 BP 神经网络火焰检测算法对含有火焰目标的图像发生了漏检的情况,笔者所提出的基于多分辨率的火焰检测算法检测结果如图(d)所示:检测出火焰目标,并用红色包围框对火焰目标进行定位,“fire”代表检测结果为火焰,检出概率为“0.99”;笔者使用类激活映射的方法可以在很大的程度上提高火

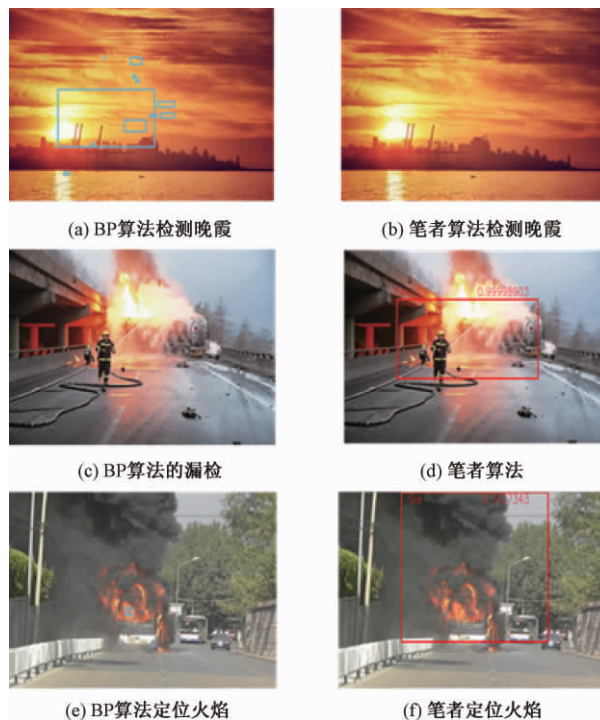


图 5 对比试验的部分实验结果展示

Fig.5 Demonstration of some experimental results of comparative experiments

焰目标的定位覆盖率,如图(e)、图(f)所示,图(e)为基于 BP 神经网络的火焰检测算法检测结果,该算法存在对火焰目标定位覆盖率不完全的问题.图(f)为笔者所提出算法的检测结果,可正确检测出“fire”目标,概率为 0.74,与图(e)相比,定位覆盖率更为完整.

3 结论

笔者通过使用基于多分辨率卷积神经网络的火焰检测算法,实现了在复杂场景下的火焰检测,并在实际场景中得到了有效的应用.在复杂场景中,相比于传统的 BP 神经网络,笔者提出的算法互补学习了火焰的多尺度视觉特征,同时关注场景的背景环境、局部目标、整体布局等特征.实验结果表明笔者提出的算法在检测精度和检测速率上都得到了显著提升,对于场景分类和未来的场景理解都具有重要实际意义.

参考文献:

- [1] 杜静,严云洋,高尚兵,等.时空视觉选择性注意机制的视频火焰检测[J].计算机辅助设计与图形学学报,2014,26(3):479-485.
- [2] ZHANG K, SONG H, ZHANG L. Active contours driven by local image fitting energy[J]. Pattern Recognition, 2010, 43(4): 1199-1206.

- [3] JIANG B, LU Y, LI X, et al. Towards a solid solution of real-time fire and flame detection [J]. *Multimedia Tools & Applications*, 2015, 74(3): 689–705.
- [4] 靳琪琳, 段锁林. 基于神经网络与加权融合的火灾火焰识别研究 [J]. *计算机工程与应用*, 2013, 49(13): 156–159.
- [5] 邵婧, 王冠香, 郭蔚. 基于视频动态纹理的火灾检测 [J]. *中国图象图形学报*, 2013, 18(6): 38–44.
- [6] 邵良杉, 郭雅婵. 基于 Codebook 的视频火焰识别算法 [J]. *计算机应用*, 2015, 35(5): 1483–1487.
- [7] 严云洋, 杜静, 高尚兵, 等. 融合多特征的視頻火焰检测 [J]. *计算机辅助设计与图形学学报*, 2015, 27(3): 433–440.
- [8] 杨文柱, 刘晴, 王思乐, 等. 基于深度卷积神经网络的羽绒图像识别 [J]. *郑州大学学报(工学版)*, 2018, 39(2): 11–17.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C] // *International Conference on Neural Information Processing Systems*. Curran Associates Inc. 2012: 1097–1105.
- [10] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C] // *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2015: 1–9.
- [11] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. *Pattern Recognition*, 2014, 47(5): 1409–1421.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016: 770–778.
- [13] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C] // *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016: 2818–2826.
- [14] ZHANG Y, WEI X S, WU J, et al. Weakly supervised fine-grained categorization with part-based image representation [J]. *IEEE Transactions on Image Processing*, 2016, 25(4): 1713–1725.
- [15] WANG Z, WANG L, WANG Y, et al. Weakly supervised patchNets: describing and aggregating local patches for scene recognition. [J]. *IEEE Transactions on Image Processing*, 2017, 26(4): 2028–2041.
- [16] ZHOU B, KHOSLA A, LAPEDRIZA A, et al. Learning deep features for discriminative localization [C] // *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016: 2921–2929.
- [17] ZHOU B, LAPEDRIZA A, KHOSLA A, et al. Places: a 10 million image database for scene recognition. [J]. *IEEE Trans Pattern Anal Mach Intell*, 2018, (99): 1–12.
- [18] MAHENDRAN A, VEDALDI A. Understanding deep image representations by inverting them [C] // *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2015: 5188–5196.
- [19] 刘芳. 面向视频的火焰检测与跟踪算法研究 [D]. 南昌: 南昌航空大学信息工程学院, 2018.
- [20] 梅建军, 张为. 基于 ViBe 与机器学习的早期火灾检测算法 [J]. *光学学报*, 2018, 38(7): 60–67.
- [21] 张震, 刘博, 李龙. 一种多特征提取及融合的虹膜识别方法 [J]. *郑州大学学报(工学版)*, 2017, 38(1): 63–67.

Fire Detection Based on Multi-resolution Convolution Neural Network

HUANG Wenfeng¹, XU Shanshan², SUN Yi², ZHOU Bing²

(1. Henan Provincial Institute of Scientific & Technical Information, Zhengzhou 450003, China; 2. School of Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: A fire detection algorithm based on multi-resolution convolutional neural network was proposed to achieve the objective of fire detection in real scenes. This algorithm leveraged the BN_Inception network as the basic network structure. Different coarse and fine resolution neural networks were used to learn the multi-scale visual features of the fire in complex scenes complementarily, while paying attention to the background environment, local targets and overall layout of the scene. The method was evaluated in fire dataset covers most real scenes. The experiment showed that the proposed method could achieve better detection results than other methods, which could be effectively applied in the real world.

Key words: multi-resolution convolutional neural network; fire detection; deep learning; weak supervised learning

文章编号: 1671-6833(2019)05-0084-07

基于 BP-RBF 神经网络的组合模型预测港口物流需求研究

蔡婉贞¹, 黄 翰²

(1. 汕头职业技术学院 经济管理系, 广东 汕头 515078; 2. 华南理工大学 软件学院, 广东 广州 510006)

摘 要: 为了准确、高效地预测港口物流需求量, 提出一种基于 BP-RBF 神经网络的组合预测模型。考虑到物流需求的非线性变化特点, 在建模过程中首先采用 BP 与 RBF 两种神经网络方法分别建立单项预测子模型, 然后依据各子模型预测结果赋予不同权重进一步构建加权组合预测模型。再以汕头港为例, 通过 MATLAB 软件对港口物流需求量进行仿真预测。结果表明, 组合预测模型较单一预测模型具有更高的预测精度, 能有效减少出现较大误差的概率, 使预测结果更接近于实际情况, 可为港口今后物流发展规划提供参考。

关键词: BP 神经网络; RBF 神经网络; 组合模型; 预测; 港口物流需求

中图分类号: TP183; F552.7

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.02.025

0 引言

随着粤东沿海产业带建设的快速推进, 汕头港口物流将迎来更大的发展机遇和挑战。对港口的物流需求进行精准的预测, 将为港口物流产业发展以及物流基础设施规划设计提供可靠的数据支持。目前用于物流需求预测的理论方法可分为定性和定量两大类^[1]。定性预测方法主要包括德尔菲法、专家调查法、主观概率法等。定性预测法较灵活, 预测简单迅速, 但易受主观因素的影响, 难以对物流需求作数量上的精确描述。定量预测法则是利用历史数据或因素变量来预测未来物流需求的数学模型。传统港口物流需求定量预测方法主要有回归分析法^[2]、移动平均法^[3]、指数平滑法^[4]等。然而, 物流系统是一个非常复杂的非线性系统, 物流需求受多种因素共同影响, 既存在一定的规律性, 又具有很强的随机性, 这使得传统的预测模型很难准确反映出各因素之间的复杂映射关系, 从而影响预测结果的准确性。基于黑箱理论的人工神经网络是模仿大脑神经网络的结构和功能而建立的一种数学模型, 凭借其非线性处理、自适应学习、高容错能力等特性, 可以较轻松地实现非线性映射过程, 广泛应用于非线性系统以及模型未知系统的预测控制^[5-6]。BP 神经网络和 RBF

神经网络是两种常用的人工神经网络中, 两者均属于前向型神经网络, 其中 BP 神经网络是一种按照误差反向传播算法训练的多层神经网络, 属于典型的全局逼近网络, 该神经网络模型无论在网络理论还是在性能方面均比较成熟, 具有较强的非线性映射能力和柔性网络结构^[7-9]。BP 神经网络也存在收敛速度慢、容易陷入局部极小值的缺点, 难以保证学习结果达到均方误差的全局最小。与 BP 神经网络不同, RBF 神经网络是一种局部逼近网络, 只要有足够多的隐层神经元, RBF 神经网络就能够以任意精度逼近任何连续非线性函数, 具有训练速度快, 不易陷入局部极小值等优点^[10-11]。当算例中样本数据较多时, 应用单一神经网络模型进行训练易出现过拟合问题, 影响网络预测效果。鉴于港口物流需求量具有明显的不确定性和非线性特征, 笔者拟将人工神经网络方法引入到港口物流需求预测中, 分别构建 BP 神经网络和 RBF 神经网络预测模型。考虑到单一预测方法在实际预测中预测效果并不稳定, 得出的预测结果与实际值可能存在较大偏差, 为综合利用各神经网络模型的优点提高预测精度, 笔者拟将上述单项模型预测结果按照误差平方和最小的原则计算各自的权系数, 加权构建组合预测模型, 并以汕头港为例进行实证分析。

收稿日期: 2018-09-11; 修订日期: 2018-11-12

基金项目: 国家自然科学基金资助项目(61370102)

作者简介: 蔡婉贞(1982—), 女, 广东汕头人, 汕头职业技术学院讲师, 硕士, 主要从事物流管理研究, E-mail: 47653812@qq.com.

1 预测方法

1.1 BP 神经网络

BP 神经网络包括输入层、中间层和输出层。在整个网络中,为实现纵向全连接,横向每层的神经元间无连接,是一种按误差逆传播算法训练的前馈网络。它利用网络的实际输出和期望输出之间的误差最小对网络的多层连接权值和阈值由后向前逐层进行修正,随着这种误差逆向传播修正不断进行,神经网络对输入模式响应的正确率也不断提高。构建 BP 神经网络模型时,首先给每个连接权值和阈值赋予 $(-1, 1)$ 内的随机值;然后从训练样本中随机选取一组样本输入向量 $\mathbf{P}_k = (p_1, p_2, \dots, p_n)$ 和期望输出向量 $\mathbf{Q}_k = (q_1, q_2, \dots, q_l)$ 提供给网络。接着用输入向量 \mathbf{P}_k 、连接权 v_{ij} 和阈值 θ_j 计算隐层各单元的输入,然后利用该输入通过传递函数 f 计算隐层各单元的输出,

$$O_j = f\left(\sum_{i=1}^n v_{ij} p_i - \theta_j\right), \quad (1)$$

式中: i 为输入层的维数 ($i=1, 2, \dots, n$)。然后用隐层的输出 O_j 、连接权 w_{ji} 和 ψ_i 阈值计算输出层各单元的输入,然后利用该输入通过传递函数 f 计算输出层的响应,即网络的实际输出,

$$Y_i = f\left(\sum_{j=1}^p w_{ji} O_j - \psi_i\right), \quad (2)$$

式中: j 为隐层的维数, $j=1, 2, \dots, p$ 。

式(1)、式(2)中,传递函数 f 通常选用 sigmoid 型函数,

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (3)$$

再利用网络期望输出向量 \mathbf{Q}_k 和网络实际输出向量 \mathbf{Y}_i 计算出输出层的校正误差,

$$d_i^k = (q_i^k - Y_i) f'\left(\sum_{j=1}^p w_{ji} O_j - \psi_i\right), \quad (4)$$

式中: f' 为输出层函数的导数。接着利用该误差、连接权 w_{ji} 和隐层各单元的输出计算出隐层的校正误差,

$$e_j^k = \left(\sum_{i=1}^q w_{ji} d_i^k\right) f'\left(\sum_{i=1}^n v_{ij} p_i - \theta_j\right). \quad (5)$$

求得上述校正误差后,再利用该误差沿逆方向逐层修正输出层至隐层、隐层至输入层的连接权值和阈值。其校正量分别为:

$$\Delta w_{ji} = \alpha d_i^k O_j, \quad (6)$$

$$\Delta \psi_i = \alpha d_i^k, \quad (7)$$

式中: $0 < \alpha < 1$ 。

$$\Delta v_{ij} = \beta e_j^k p_i^k, \quad (8)$$

$$\Delta \theta_j = \beta e_j^k, \quad (9)$$

式中: $0 < \beta < 1$ 。

对所有学习样本均按照上述计算方法对网络进行训练,通过重复执行以上过程,使实际输出不断逼近期望输出,直到网络全局误差函数 E 小于预先设定的极小值或学习次数大于预先设定的数值时,则完成网络的训练和收敛过程。

1.2 RBF 神经网络

RBF 神经网络属于单隐层的三层前馈网络,该网络输入层仅起到传输信号的作用,神经元的数目为样本中输入向量的维数;隐层是由一组传递函数为径向基函数的神经元构成的非线性映像层,能将低维输入数据映射到高维空间内,使其变得线性可分;输出层则对隐层的输出进行线性加权求和得到网络的最终输出。RBF 神经网络最常用的径向基函数是高斯函数,表达式为:

$$g_i(x) = \exp \frac{-\|\mathbf{x} - \mathbf{c}_i\|^2}{2\sigma_i^2}, \quad (10)$$

式中: $g_i(x)$ 为隐层中第 i 个神经元的输出; \mathbf{x} 为 n 维输入向量; \mathbf{c}_i 为高斯函数的中心; σ_i 为高斯函数的方差; $\|\mathbf{x} - \mathbf{c}_i\|$ 为欧式范数。网络的输出为隐层神经元输出的线性加权求和,表达式为:

$$y_i = \sum_{i=1}^k w_{ij} g_i(x). \quad (11)$$

RBF 神经网络训练分为无教师式学习与有教师式学习两个阶段。第一阶段为无教师式学习,可用基于 K-means 聚类方法求取径向基函数的中心 \mathbf{c}_i ,然后计算出方差 σ_i ,

$$\sigma_i = \frac{c_{\max}}{\sqrt{2k}}, \quad (12)$$

式中: c_{\max} 为所选取中心之间的最大距离, $i=1, 2, \dots, k$ 。通过上述学习求解径向基函数的中心和方差后,便进入第二阶段有教师式学习,即求解隐层和输出层之间神经元的连接权 w_{ij} ,可用最小二乘法计算得到,

$$w_{ij} = \exp\left(\frac{k}{c_{\max}^2} \|\mathbf{x} - \mathbf{c}_i\|\right). \quad (13)$$

此处的权为网络可调参数, RBF 神经网络通过检查输出误差来调整径向基函数的中心 \mathbf{c}_i 和连接权值 w_{ij} ,据此调整网络内部系数,然后再重新检查网络误差,重复此过程直到网络达到误差要求或者最大隐层神经元数时则完成网络训练。

1.3 组合模型

港口物流需求预测是一个十分复杂的非线性

问题,仅使用单一的预测方法进行预测往往具有片面性,如 BP 神经网络虽然具有良好的曲线拟合能力、抗干扰和学习能力,但该网络采用的是基于梯度下降的训练算法,容易陷入局部最优,应用该网络进行长期预测时,受传递函数的影响,预测精度会随着时间推移而降低.RBF 神经网络可对非线性连续函数一致逼近且不存在局部极小问题,可并行高速地处理数据.RBF 网络基函数中心是在输入样本集中选取的,有时难以反映系统真正的输入输出关系,且优选过程中有可能出现数据病态问题.如果可以综合利用上述网络模型的输出信息,赋予精度高的输出数据较高权重,精度低的输出数据占较低权重,最后将各网络模型的输出结果进行融合,不仅能够提高港口长期物流需求预测的精度,又能保障预测结果的稳定性.为将上述单项模型预测结果进行最优组合以提高预测效果,本研究采用的是一种“误差平方和最小”的加权组合预测模型,即通过求误差平方和最小值来确定最优权重系数,该方法综合了多种预测方法的优点,只要选择合适的组合权值就能有效提高预测精度.权重系数的大小与各单项预测方法的预测误差有关,误差大的预测方法相应权重小;反之,误差越小的预测方法对应的权重越大.应用 n 种不同的预测模型对同一个预测对象进行预测时,其加权组合模型预测值可表示为,

$$Y_t = \sum_{i=1}^n w_i Y_{it}. \quad (14)$$

式中: Y_t 为 t 时刻组合预测模型的预测值; Y_{it} 为第 i 个预测模型的预测值 ($i = 1, 2, \dots, n$); w_i 为第 i 个预测模型的加权系数 ($i = 1, 2, \dots, n$); 设某一时段的实际值为 C_t ; 欲使组合模型误差平方和达到最小,可构建以下方程组,

$$\begin{cases} \text{Min} \sum_{t=1}^n (C_t - \sum_{i=1}^n w_i Y_{it})^2 = 1 \\ \sum_{i=1}^n w_i = 1 \end{cases}. \quad (15)$$

通过计算组合模型误差平方和的最小值,求各个预测模型加权系数 w_i 的值.在建模过程中,先通过分别构建 BP 神经网络和 RBF 神经网络预测模型,采用训练效果最佳时的预测结果作为单项模型的最终预测值,将其与实测值一起代入式(15)计算得到各单项模型的加权系数,再将各预测模型的权值代入式(15)中进一步计算得到加权组

合模型的最终预测值,组合模型具体构建流程如图 1 所示.

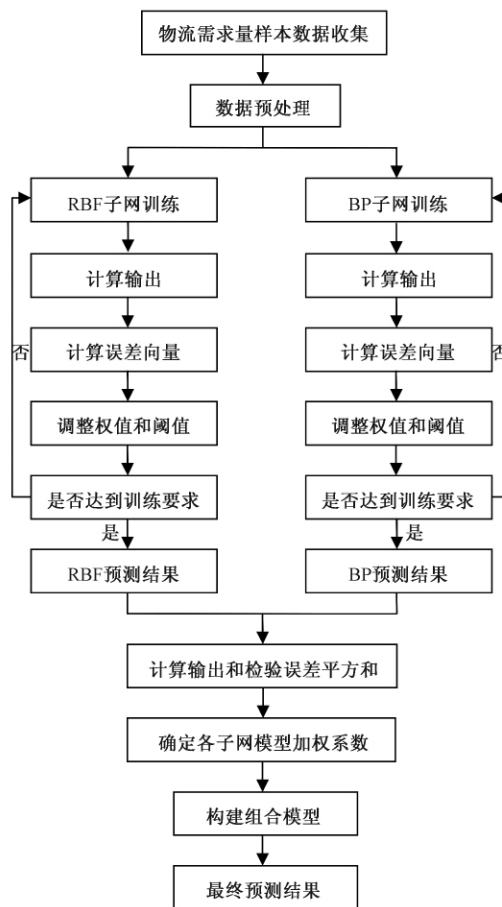


图 1 算法流程图

Fig.1 Algorithm flowchart

2 实证分析

为了测试上述模型对港口物流需求的预测效果,笔者以汕头港为例进行实证分析,样本数据如表 1 所示.实证数据以 2000~2017 年汕头港直接经济腹地三次产业产值、进出口总额、社会消费品零售总额、固定资产投资额作为物流需求的影响因素,港口货物吞吐量作为物流需求指标.2000~2016 年数据来源于广东省统计年鉴,2017 年数据来自汕头港直接经济腹地各市的国民经济和社会发展统计公报.表 1 中,符号 x_1 为第一产业产值,亿元; x_2 为第二产业产值,亿元; x_3 为第三产业产值,亿元; x_4 为进出口总额,亿美元; x_5 为社会消费品零售总额,亿元; x_6 为固定资产投资额,亿元; y 为港口货物吞吐量,万吨.将表 1 中的数据分成训练集和测试集两部分,训练集为 2000~2012 年各项数据,测试集为 2013~2017 年各项数据,训练集用来数据建模,测试集用来对建立的模型

表 1 样本数据
Tab.1 Sample data

年份	x_1	x_2	x_3	x_4	x_5	x_6	y
2000	195.22	509.00	415.39	61.65	429.22	256.06	1 284.00
2001	195.39	514.48	438.03	40.87	456.88	261.04	1 309.00
2002	200.02	544.68	462.01	46.31	497.34	289.30	1 380.00
2003	205.36	611.02	500.86	57.36	540.22	330.10	1 470.00
2004	223.73	707.29	575.83	73.04	625.33	388.29	1 576.00
2005	220.85	812.99	626.03	86.06	722.86	464.55	1 736.00
2006	214.13	964.90	693.20	98.62	841.51	543.18	2 014.60
2007	240.56	1 140.01	819.32	109.00	1 007.69	655.71	2 301.04
2008	285.61	1 362.07	946.04	117.53	1 233.11	796.00	2 806.47
2009	298.09	1 469.07	1 071.70	125.87	1 479.20	1 011.35	3 101.80
2010	339.93	1 732.62	1 233.18	159.87	1 841.55	1 304.04	3 509.30
2011	392.45	2 005.35	1 449.31	185.59	2 206.18	1 492.82	4 005.00
2012	427.22	2 247.46	1 607.57	188.11	2 271.41	1 729.73	4 562.79
2013	455.61	2 543.16	1 770.54	196.06	2 519.36	2 144.42	5 037.90
2014	484.51	2 798.22	1 950.29	206.18	2 840.89	2 817.05	5 160.91
2015	516.36	2 923.35	2 183.54	219.24	3 225.41	3 596.43	5 180.90
2016	578.04	3 043.47	2 488.75	209.53	3 608.99	4 170.05	4 985.05
2017	582.69	3 306.96	2 812.43	206.17	3 985.80	4 981.53	4 889.70

进行检验.

2.1 BP 神经网络模型构建及仿真分析

由于数据存在不同的量纲,必须先对数据进行标准化处理,归一化公式

$$X_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \tag{16}$$

对样本输入进行归一化处理,使数据归一到 [0, 1].其中, X_i 和 x_i 分别为转换前、后的值, x_{\max} 和 x_{\min} 分别为样本的最大值和最小值.数据归一化处理后,构建三层 BP 网络,包括一个输入层(6 个神经元),一个隐含层和一个输出层(1 个神经元).网络隐含层神经元传递函数为 tansig,输出层神经元传递函数为 logsig,训练函数采用 trainlm.训练周期为 1 000 次,训练精度为 0.000 001.根据 Kolmogorov 定理,当输入层的神经元为 6 个时,网络中间层的神经元可初步确定为 13 个,考虑本例的实际情况,解决该问题的网络隐含层神经元应当在 13~20 个,将它们的训练结果进行比较,如表 2 所示.当网络隐层的神经元为 14 个时,网络的训练效果最佳,此时网络模型的平均绝对百

分误差(*MAPE*) 最小,*MAPE* 表达式如下:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right| \times 100\%. \tag{17}$$

使用该网络模型对 2013~2017 年的港口物流需求量进行预测,以检验网络的预测性能,即应用归一化后的测试集样本对上述训练好的网络进行仿真.经过多次反复训练(训练结果见图 2),得到 BP 神经网络的最终预测值,再进行反归一化后便可得到 2013~2017 年的物流需求预测结果.

表 3 为预测结果.如表 3 所示,BP 神经网络模型的预测值与真实值较为一致,除 2017 年预测结果的相对误差偏大,其余 4 年的预测值与真实值的相对误差均低于 5%.BP 神经网络模型由于初始连接权值和阈值的随机性,即使是在同一个训练集下训练,每次训练的结果也很难保证完全一致,这意味该网络训练得到的预测结果存在较大的波动^[12],因此,需经过多次反复训练才能得到精度比较理想的预测结果.

表 2 BP 神经网络训练误差
Tab.2 Training errors of BP neural network

神经元个数	13	14	15	16	17	18	19	20
网络平均绝对百分误差/%	3.11	2.85	4.94	3.66	3.09	3.55	3.08	3.14




图2 误差性能曲线

Fig.2 Error performance curve

2.2 RBF神经网络模型构建及仿真分析

RBF神经网络模型输入层、输出层的确定同BP神经网络.利用newrbe函数创建一个精确的神经网络,该函数在创建网络时,将自动选择隐含层的数目,使得误差为0. MATLAB调用程序为: net = newrbe (X _ train, Y _ train, SPREAD), SPREAD 为径向基函数的分布密度.本研究应用归一化后的训练集样本进行多次反复训练,预测曲线如图3所示.当 SPREAD=0.55 时,网络预测性能最佳.




图3 不同 SPREAD 的预测曲线

Fig.3 Prediction curves with different SPREAD values

应用训练好的 RBF 神经网络模型对 2013~2017 年的物流需求进行预测,与 BP 神经网络模型预测结果相仿,RBF 神经网络模型的预测值与实际值均较为接近,其相对误差均低于 5%.由于该网络基函数中心是在输入样本集中选取的,样本数量较多时需要比 BP 神经网络更多的隐层神经元才能达到预期的训练目标,易出现过拟合现象^[13-14].因此,RBF 神经网络部分预测结果仍存在较大波动,如 2014 年预测值与实际值之间的相对误差仍高达 4.42%.

2.3 组合模型构建及仿真分析

根据上述两种神经网络模型预测结果,按照公式(15)建立方程组,求解方程组可得到 BP 神经网络模型加权系数为 0.377 1,RBF 神经网络模型加权系数为 0.622 9,按照此加权系数进行组合预测,可得到 2013~2017 年汕头港货物吞吐量的预测结果.如表3所示.与单项模型不同,组合模型的预测值能更好地贴合实际货物吞吐量,预测值与实际值的相对误差均低于 3%.从 2013~2017 年 5 组测试集的预测结果来看,BP 和 RBF 神经网络均存在部分年份的预测结果波动较大的问题,且 BP 神经网络预测结果波动有随时间推移逐渐增大的趋势,组合模型通过最优加权组合法将上述两种预测模型的结果进行融合,既结合 BP 与 RBF 神经网络的预测优点,又充分利用各个单项子模型的有效预测信息,经过加权处理有效降低单项模型对组合预测模型预测效果的影响,使预测结果更为稳定和可靠.

2.4 模型精度评价

笔者采用 MAPE 和误差均方根(RMSE)作为 3 种预测模型精度评价指标

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}. \quad (18)$$

表3 组合模型预测结果

Tab.1 Simulation results

年份	真实值/万吨	BP 神经网络模型		RBF 神经网络模型		组合模型	
		预测值/万吨	相对误差/%	预测值/万吨	相对误差/%	预测值/万吨	相对误差/%
2013	5 037.90	5 065.98	-0.91	5 089.64	1.03	5 080.72	0.85
2014	5 160.91	5 148.09	-0.01	5 388.87	4.42	5 298.08	2.66
2015	5 180.90	5 177.37	-0.13	5 299.81	2.30	5 253.64	1.40
2016	4 985.05	5 180.15	3.79	5 074.40	1.79	5 114.27	2.59
2017	4 889.70	5 180.22	5.73	4 853.67	-0.74	4 976.80	1.78

预测精度比较如表4.由表4可以看出,BP、RBF 神经网络模型及其组合模型预测结果精度较高.在 3 种预测模型中,组合模型的 MAPE 和

RMSE 均低于单项模型,说明使用 BP-RBF 神经网络组合模型进行预测可以有效地提高预测精度.

表 4 预测精度比较
Tab.4 Comparison of prediction accuracy

模型	平均绝对百分误差 (MAPE) /%	误差均方根 (RMSE)
BP 神经网络	2. 11	157. 12
RBF 神经网络	2. 05	124. 95
组合模型	1. 86	100. 23

2.5 汕头港未来五年的物流需求预测

使用构建好的组合模型对未来五年(2018~2022 年) 汕头港货物吞吐量进行预测,首先要推测未来五年汕头港直接经济腹地三次产业产值、进出口总额、社会消费品零售总额、固定资产投资额的值作为模型的输入变量,笔者采用年均增长率对其进行大致预估.为了测试上述自变量的预估值对组合预测的仿真效果,先将表 1 中 2000~2012 年各项数据作为训练集,2013~2017 年 6 个自变量的预估值作为测试集的输入变量,接着按照此前建立组合模型的方法对数据进行预测,测试结果见表 5.组合模型的 MAPE 和

RMSE 分别为 1. 62%和 103. 06.

表 5 测试结果
Tab. 5 Test result

年份	真实值/万吨	组合模型	
		预测值/万吨	相对误差/%
2013	5 037. 90	5 080. 72	0. 30
2014	5 160. 91	5 298. 08	2. 77
2015	5 180. 90	5 253. 64	0. 16
2016	4 985. 05	5 114. 27	-1. 50
2017	4 889. 70	4 976. 80	-3. 35

由此可见,应用年均增长率求得的预估值作为输入变量进行组合预测同样具有较高的预测精度,可以用来对未来五年的港口物流需求进行组合预测.

因此,采用 2000~2017 年上述自变量各值(x_1-x_6) 的年均增长率来推测 2018~2022 年各项相应数据的值,然后将预测出来的各自变量的值作为输入变量输入到此前已构建好的组合模型进行预测,便可得到汕头港货物吞吐量(y) 2018~2022 年预测值(见表 6) .

表 6 预测结果
Tab.6 Forecasting results

年份	x_1	x_2	x_3	x_4	x_5	x_6	y 预测值
年均增长率/%	6. 64	11. 64	11. 91	7. 36	14. 01	19. 08	—
2018	621. 40	3 691. 78	3 147. 33	221. 34	4 544. 09	5 931. 81	5 502. 16
2019	662. 69	4 121. 37	3 522. 11	237. 63	5 180. 58	7 063. 38	6 401. 19
2020	706. 72	4 600. 96	3 941. 51	255. 12	5 906. 23	8 410. 79	6 961. 21
2021	753. 67	5 136. 36	4 410. 86	273. 90	6 733. 51	10 015. 25	7 138. 03
2022	803. 74	5 734. 05	4 936. 09	294. 06	7 676. 67	11 925. 77	7 208. 32

由表 6 可以看出,在保持经济增速相对稳定的前提下,汕头港未来五年的物流需求仍会持续增长,尤其是 2018 年至 2020 年这段时间,其物流需求量会有较大增幅.因此,汕头未来的港口物流业将有较好的发展前景,需要加大港口基础设施建设力度,进一步优化与整合现有港口资源,提高港口服务质量和效率以应对未来物流需求的迅猛增长.

3 结论

本研究分别建立了基于 BP 神经网络和 RBF 神经网络的港口物流需求预测模型以及基于上述两种模型的组合预测模型.结果表明,BP 神经网络和 RBF 神经网络均可用来预测港口的物流需求量,其预测结果与实际数据较为接近,但仍有部分预测结果存在较大误差.将上述两种模型的预

测结果进行组合后,可以有效减少较大误差的出现,从而提高预测精度,说明应用该组合模型对港口物流需求进行预测是切实可行的,其预测结果更加稳定可靠,因此更适合于实际预测.

参考文献:

[1] 张璐,木仁. 物流需求预测方法概述 [J]. 物流科技, 2015, 38 (7) : 104-106.

[2] 徐志刚. 基于自回归模型的上海港港口吞吐量的预测 [J]. 武汉交通职业学院学报, 2011, 13 (1) : 71-74.

[3] 李琦. 物流需求预测中移动平均法应用分析 [J]. 中国商贸, 2011 (2) : 139-140.

[4] 关克平,齐梦雅.基于指数平滑法的宁波-舟山港港口吞吐量预测研究 [J]. 中国水运(下半月), 2013, 13 (12) : 28-29.

[5] RUBEN G B, ZHANG K, BAO H, et al. Application

- and sensitivity analysis of artificial neural network for prediction of chemical oxygen demand [J]. *Water Resources Management*, 2018, 32(1): 1-11.
- [6] MAGHREB M, SAMMUT C, WALLER T S. Predicting the duration of concrete operations via artificial neural network and by focusing on supply chain parameters [J]. *Building Research Journal*, 2014, 61(1): 1-14.
- [7] RAVA E, CHIRWA E M. Prediction of performance of the moving-bed biofilm pilot reactor using backpropagation artificial neural network (BP-ANN) [J]. *Chemical Engineering Transactions*, 2017, 61: 189-1194.
- [8] ZHANG J, YANG G. Analysis on Shanghai's logistics demand based on BP neural network [C]//*IEEE International Conference on Networking*, 2013, 16(2): 556-561.
- [9] 曾庆山, 全书鹏, 靳志强. 融合 BP 神经网络与 ARIMA 的短时交通流预测 [J]. *郑州大学学报(工学版)*, 2011, 32(4): 60-63.
- [10] HU Z, ZHANG Y, YAO L. Radial basis function neural network with particle swarm optimization algorithms for regional logistics demand prediction [J]. *Discrete Dynamics in Nature & Society*, 2014(2): 189-192.
- [11] 毛晓波, 张群, 梁静, 等. 基于 PSO-RBF 神经网络的雾霾车牌识别算法研究 [J]. *郑州大学学报(工学版)*, 2017, 38(4): 46-50.
- [12] 陈志礼, 宁正福, 杜华明, 等. 基于改进 BP 神经网络的页岩吸附量预测模型 [J]. *断块油气田*, 2018, 25(2): 208-212.
- [13] 贺文阳, 王俊年. RBF 神经网络的混合微粒群学习算法 [J]. *计算机与现代化*, 2009(4): 35-38.
- [14] 杨杰, 李爱群, 曾捷. 改进 RBF 网络及其在悬索桥吊索损伤定位中的应用 [J]. *南京航空航天大学学报*, 2011, 43(1): 110-114.

A Model Based on the Combination of BP and RBF Neural Network for Port Logistic Demand Forecasting

CAI Wanzhen¹, HUANG Han²

(1. Department of Economic Management, Shantou Polytechnic, Shantou 515078 China; 2. School of Software Engineering, South China University of Technology, Guangzhou 510006 China)

Abstract: In order to get the excellent accuracy for port logistic demand forecasting, a combination model based on the BP and RBF neural network was utilized to forecast the logistic demand of Shantou port in this paper. According to the nonlinear change of logistic demand, the BP neural network and RBF neural network were used to establish the single forecasting sub-model separately. And then, the sub-models were combined through the magnitude of the forecasting error to forecast the logistic demand. The simulation was performed by using MATLAB software. Experiment results showed that the combination model could achieve considerably better predictive performances than the single model of BP or RBF neural network. It could reduce the mean absolute percentage error and root mean square error in the logistic demand of Shantou port. These results indicated that forecast combination could improve the precision of the single neural network model for port logistic demand forecasting, and could help the decision maker in relevant port sector make proper decisions.

Key words: BP neural network; RBF neural network; combined model; forecast; port logistic demand

一种前景提取的行人模式识别检测算法

杨忠明¹, 李子龙², 胡音文², 黄 翰², 蔡昭权³

(1. 广东科学技术职业学院 计算机工程技术学院, 广东 珠海 519090; 2. 华南理工大学 软件学院, 广东 广州 510006; 3. 惠州学院, 广东 惠州 516007)

摘 要: 通过深入研究高斯混合模型、HOG+SVM 分类器和 Haar+AdaBoost 分类器的算法原理, 提出了一种基于前景提取和模式识别的行人检测算法, 首先使用高斯混合模型进行背景建模, 通过前景提取的方法提取出运动物体, 对运动物体进行行人检测, 最后对判断为行人的对象进行人脸检测, 分类区分出蒙面的可疑行人, 解决基于背景建模方法的误判问题和基于统计学习方法的效率问题, 实验结果表明, 相对于单独使用模式识别算法, 新算法显著降低了漏检率, 且在运行速度和检测率方面表现良好。

关键词: 背景建模; 行人检测; 人脸检测; AdaBoost; 模式识别

中图分类号: TP317.4

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.02.017

0 引言

目前平安城市的视频监控遍布城市核心区域, 利用监控视频完成行人检测有利于人流统计、安全防范等, 检测蒙面的可疑行人是视频监控的核心问题。目前常用的行人检测方法可分为两类: 基于背景建模的方法和基于统计学习的方法^[1]。前者易受干扰, 误判率较高^[2]; 后者受训练样本影响较大, 且只能对目标进行多尺度反复扫描, 处理速度较慢^[3]。另有学者提出基于 ELM 与 Mean Shift 的算法解决行人遮挡带来的检测异常问题^[4]。目前的行人检测方法因判别因素单一, 且缺乏多因素之间的关联性研究, 故难以取得令人满意的检测效果, 亟需一种高效的复合型算法提高行人检测的速度和准确率^[5]。

针对上述行人检测方法的缺点与不足, 笔者提出一种基于前景提取和模式识别的行人检测算法, 以解决基于背景建模方法的误判问题和基于统计学习方法的效率问题。

1 关键算法原理

1.1 混合高斯模型

混合高斯模型的基本思想是使用 K 个高斯分布对视频中图像的每一像素进行建模, 不只是

选择一个特定的分布^[6]。GMM 将当前像素点判定为背景模型的概率定义为:

$$p(X_t) = \sum_{k=1}^K \omega_{k,t} \times \eta(X_t, \mu_{k,t}, \sigma_{k,t}^2), \quad (1)$$

式中: K 为高斯模型的数量, K 取值越大, 背景模型抗干扰能力越强, 对应的计算量也会越大, 取值一般为 $3 \sim 5$ ^[7]; $\omega_{k,t}$ 是 t 时刻第 k 个高斯分布的权值; $\mu_{k,t}$ 为与之相对应的均值; $\sigma_{k,t}^2$ 为与之相对应的方差; $\eta(X_t, \mu_{k,t}, \sigma_{k,t}^2)$ 为 t 时刻第 k 个高斯分布的概率密度函数, 可表示为:

$$\eta(X_t, \mu_{k,t}, \sigma_{k,t}^2) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} e^{-\frac{1}{2}(X_t - \mu_{k,t})^T \Sigma_k^{-1} (X_t - \mu_{k,t})}. \quad (2)$$

每读取一个新的视频帧, 都需要更新模型参数, 新一帧的每一像素都需要匹配所有的 K 个高斯分布, 并决定是否更新。更新公式为:

$$\omega_{k,t} = (1 - \alpha) \omega_{k,t-1} + \alpha(M_{k,t}), \quad (3)$$

$$\mu_{k,t} = (1 - \rho) \mu_{k,t-1} + \rho X_t, \quad (4)$$

$$\sigma_{k,t}^2 = (1 - \rho) \sigma_{k,t-1}^2 + \rho(X_t - \mu_{k,t})^T (X_t - \mu_{k,t}), \quad (5)$$

$$\rho = \alpha \eta(X_t, \mu_{k,t}, \sum_{k=1}^K \cdot), \quad (6)$$

其中, α 为权值更新率; ρ 为参数更新率。

若新的像素点与某个分布匹配, 则 $M_{k,t}$ 取 1; 反之, $M_{k,t}$ 取 0, 若新的像素点不与任何分布匹配, 则用新的像素点建立新的高斯分布, 替换掉拥有

收稿日期: 2018-11-19; 修订日期: 2018-12-21

基金项目: 国家自然科学基金资助项目(61772225); 广州市科技计划资助项目(201804010276、2018070100047)

作者简介: 杨忠明(1980—), 男, 广东科学技术职业学院副教授, 主要研究方向为智能优化算法及应用, E-mail: yzm8008@126.com.

最低优先级的高斯分布^[8].更新高斯模型参数后,以 $\omega_{k,t}/\sigma_{k,t}$ 作为评测标准,将 K 个高斯分布从高到低的顺序进行排列.序列顶部的高斯分布最可能描述背景,故可取前 B 个高斯分布来构成初始的背景模型,为之后的前景提取做准备,

$$B = \arg \min_k \left(\sum_{k=1}^K \omega_{k,t} \right) > T, \quad (7)$$

式中: T 为背景阈值.

将每帧的每个像素与背景模型匹配,如果与其中一个高斯分布相匹配,则将此像素点归为背景点,如果不与任何一个高斯分布相匹配,则将此像素点归为前景点.

1.2 基于 HOG 特征的 SVM 分类器

HOG 算子是一种用于目标检测的特征描述符,通过计算图像梯度或边缘方向直方图来构成特征^[9].图像中像素点 (x, y) 的梯度为:

$$G_x(x, y) = H(x+1, y) - H(x-1, y), \quad (8)$$

$$G_y(x, y) = H(x, y+1) - H(x, y-1), \quad (9)$$

其中, $G_x(x, y)$ 为 (x, y) 处的水平方向梯度; $G_y(x, y)$ 为 (x, y) 处的垂直方向梯度幅值; $H(x, y)$ 为 (x, y) 处的像素值.像素点和梯度方向分别为:

$$G(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2}, \quad (10)$$

$$\alpha(x, y) = \tan^{-1}(G_y(x, y)/G_x(x, y)). \quad (11)$$

计算 Hog 特征的步骤为: 首先将图像划分成多个小区域,记为细胞单元,把梯度方向平均分成 9 个区间(bin).计算单元中各个像素点的梯度或边缘的方向直方图,求取一个 9 维的特征向量.将相邻的 4 个单元组成一个块(block),把块内的特征向量联合起来得到 36 维的特征向量.用块对目标图像进行扫描,取一个细胞单元作为步长,最后将所有块的特征串连起来得到人体的特征^[10].

支持向量机 SVM^[11] 解决了在线性可分情况下的最优分类面问题,最优分类不仅正确分开两类且使分类间隔达到最大,在高维情况下,最优分类则是要求出分类面.我们可以用一个非线性映射,求出用于数据分类的超平面,如图 1 所示.

1.3 AdaBoost 分类器

AdaBoost 算法^[18] 将多个弱分类器迭代成一个强分类器,然后将多个强分类器进行级联,构成一个最优的分类器,用来对图像进行检测^[12].常用的特征向量为 Viola^[17] 提出的类 Haar 特征^[13].类 Haar 特征是一种“矩形”对特征,描述图像模式相邻区域的特征差异,如图 2 所示.




图 1 超平面

Fig.1 Hyperplane




图 2 常用的 Haar 特征

Fig.2 Commonly used Haar features

取图像中与 Haar 特征大小相同的子区域,将 Haar 特征中白色区域对应的图像像素强度值之和减去黑色区域对应的图像像素强度值之和,便能求得特征值. AdaBoost 算法的训练过程则是挑选最优弱分类器,并赋予权重的过程.

步骤 1. 首先计算出样本 Haar 特征位置参数.

步骤 2. 根据 Haar 特征的位置参数求出各弱分类器.

步骤 3. 按 AdaBoost 算法的训练流程迭代并挑选出最优弱分类器.

步骤 4. 记录当前最优弱分类器及其迭代权重.

步骤 5. 提高上一轮误判的样本权重.

步骤 6. 将新样本与上一轮误判的样本进行新一轮训练.

步骤 7. 重复步骤 4 至步骤 6, 循环 N 次获得 N 个最优弱分类器.

步骤 8. 联合 N 个最优弱分类器获得强分类器^[14].

2 算法设计及实现

首先使用混合高斯模型进行背景建模,提取出运动物体,而后对前景图像进行行人检测,判断前景图像中是否含有行人以及行人的位置,再对判断出的行人进行人脸检测,算法整体结构如图 3 所示.

2.1 基于混合高斯模型的前景目标发现算法

首先利用混合高斯模型建立视频背景模型,从而实现视频前景目标的发现.算法 2-1 给出了基于混合高斯模型的前景目标发现算法的伪代码.

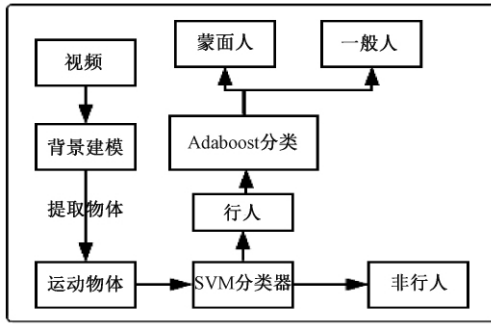


图3 算法结构

Fig.3 The algorithm structure

基于混合高斯模型的前景目标发现算法代码如下:

输入: 高斯模型的数量 K .

输出: 前景目标外接矩形集合 S_{final}

- 1: **while** 视频未读取完 **do**
- 2: 从视频中读取一帧图像
- 3: $I \leftarrow$ 图像标准化
- 4: **if** 为第一帧图像 **then**
- 5: $GMM \leftarrow$ 初始化 K 个高斯模型
- 6: $I_b \leftarrow$ 初始化背景
- 7: **else**
- 8: $GMM \leftarrow$ 更新高斯模型
- 9: $I_b \leftarrow$ 更新背景
- 10: $J \leftarrow I - I_b$
- 11: $BW_s \leftarrow$ 对 J 进行二值化
- 12: $BW \leftarrow$ 缩放 BW_s 至视频大小
- 13: $I'_f \leftarrow$ 对 BW 进行形态学处理
- 14: $I''_f \leftarrow$ 计算 I'_f 的轮廓
- 15: $S_{rect} \leftarrow$ 计算 I''_f 中各个目标的外界矩形
- 16: $S_{final} \leftarrow$ 精简轮廓
- 17: **end if**
- 18: **end while**

其中,算法第3行的图像标准化需要将首帧灰度化,并将其长宽放缩到原图的1/3.灰度化和放缩的目的是为了降低时间消耗.算法第12行将高斯模型提取到的前景图像的长宽恢复到原始大小.这里恢复的原因是,若输入的图像过小,会大大提高后面行人检测和人脸检测的漏检率.

算法第13行形态学处理的输入为前景图像 BW ,输出为已填补好缝隙的前景图 I'_f . 包括两个步骤:①对提取出的前景图像进行开运算,以消除前景图像的噪声,即那些离散、独立的点;②填补前景缝隙,对提取出的前景图像进行闭运算,对图像分开的、离散的区域进行连接,填补图像中狭小

的缝隙.

算法第15行生成前景轮廓,输入为前景图像 I''_f ,输出为提取到的矩形框集合 S_{rect} . 因为前景提取的效果并不理想,即使经过形态学处理,提取出来的图像依然过于零碎,无法构成一幅较圆满的运动物体前景图.为了更准确地找出前景图像即运动物体的矩形框,首先找出所有前景点的轮廓,然后找出这些轮廓的凸包及其外接矩形;为防止边缘丢失,其长宽分别增加 O_w 像素和 O_h 像素,并将其加入到集合 S_{rect} .

算法第15行对应的精简前景目标输入为前景矩形框集合 S_{rect} ,输出为已被精简的集合 S_{final} . 遍历 S_{rect} ,每次取出单一 $rect_1$ 并与 S_{rect} 中剩余的 $rect_2$ 进行比对,若 $|rect_1 \cdot x - rect_2 \cdot x| < t$,则求 $rect_1$ 与 $rect_2$ 的外接矩形,并将其添加到 S_{rect} ,删除 $rect_1$ 、 $rect_2$. 否则,将 $rect_2$ 加入 S_{final} .

2.2 基于方向梯度直方图与支持向量机的行人检测

步骤1.初始化行人检测分类器.创建 SVM 分类器,分类器类型为 ϵ -支持向量回归机,使用核函数为线性核函数.

步骤2.将2.1节中得到的 S_{rect} 设置为当前帧 I_{curr} 的感兴趣区域,并裁出,得到 I_{dest} .

步骤3.将感兴趣区域提取出来保存至新的图像中,并放缩至固定大小 64×128 .这里将图像放缩至固定大小不仅是为了缩小输入图像以提高算法运行速度,而且也防止输入图像过小以至小于检测窗口的最小限制.

步骤4.使用直方图均衡化增强 I_{dest} 的亮度与对比度,并对 I_{dest} 进行多维度检测.将结果保存至集合 S_{person_result} 中.

步骤5.遍历集合 S_{person_result} ,处理得到的行人矩形框,将不嵌套的矩形框加入新集合 S_{person_final} 中,而嵌套的矩形框则取大的矩形框加入 S_{person_final} .

步骤6.求出矩形框在原图像 I_{curr} 中的坐标,绘制行人检测结果.

步骤7.重置 I_{curr} 的感兴趣区域,重复步骤2~7,直到 S_{rect} 遍历完毕.

2.3 基于 Haar 特征与 AdaBoost 的人脸检测

步骤1.初始化人脸检测分类器.

步骤2.将2.2节中得到的 S_{person_final} 设置为当前帧 I_{curr} 的感兴趣区域,并裁出.

步骤3.使用直方图均衡化增强图片亮度与对比度.

步骤 4. 进行人脸检测, 得到结果序列.

步骤 5. 遍历结果序列, 求出检测出的矩形框在当前帧 I_{curr} 中的位置.

步骤 6. 在 I_{curr} 中绘出结果矩形框.

3 实验结果分析

3.1 实验设置

针对行人检测任务, 本文使用的数据集为 Duke 大学的 MTMC 数据集^[19], 该数据集包含 8 个摄像头拍摄的超过 160 GB 数据, 时长约 85 min. 本实验所采用的计算环境为 Ubuntu16.04 + E5 2630v4(10 核, 20 线程, 2.2 GHz). 实验通过检测耗时、检测框数、错检数、漏检率 4 个性能指标定量描述算法的性能. 实验中提出方法所涉及的参数设置如下: 混合高斯模型中高斯模型的数量一般取 3~5, K 取值越大, 背景模型抗干扰能力越强, 但对应的计算量也会越大^[7]. 为了取得背景模型的精度与速度之间的平衡, 笔者取 K 值为 3. 背景阈值 $T=26$, 最小轮廓面积为 5 000 像素, 长宽扩增分别为 $O_w=60$ 像素和 $O_h=200$ 像素. 在人脸检测应用实验中考虑到 Adaboost 检出率及计算代价随着弱分类器数量增加而增加, 弱分类器数量达到一定数量时(大于 500 个弱分类器), 其检出率提升不明显^[20], 本实验中弱分类器数量取 500.

3.2 实验结果

实验结果如表 1 所示. 笔者算法在运行速度和检测效率方面表现良好, 可在实际程序中应用. 通过实验可以看出, 相对于单独使用模式识别算法大大地降低了漏检率, 先提取出运动物体再检测, 也会大大地降低错检数. 这里的总框数是指该模式识别算法所检测到的所有矩形框的数量. 下面针对表 1 的实验结果从准确率和计算耗时进行分析.

表 1 实验结果

Tab.1 Experimental results

	HOG+ SVM	Haar+ AdaBoost	笔者 算法
行人检测时间/(ms·帧 ⁻¹)	853.54	—	77.66
行人检测结果框数/(个·帧 ⁻¹)	2.34	—	0.47
人脸检测时间/(ms·帧 ⁻¹)	—	2 121.86	129.99
人脸检测结果总框数	—	1.36	0.08
错检数/(个·帧 ⁻¹)	4.90	—	0.93
漏检率/%	80.06	—	77.49

3.3 准确率及分析

经过背景建模、前景提取之后得到的前景矩

形框会出现过小, 产生一定的误差. 但由于本算法适当扩大了前景矩形框, 实际检测效果并未受到较大影响. 通过背景建模与前景提取, 可以有效减小行人的搜索范围, 缩减行人检测器的滑窗数量, 从而降低行人检测的误检数和漏检率.

由于人脸是跟随行人一同运动的实体. 与行人检测相似, 由于降低了搜索范围, 人脸检测的滑窗数量大大降低, 同样降低了人脸检测的误检数和漏检率.

3.4 计算耗时及分析

对码率为 26 295 Kbps, 分辨率为 1 920 × 1 080 的 MTS 格式视频文件进行处理, 其中背景建模部分每一帧平均耗时约为 115.47 ms, 行人检测部分每一帧平均耗时约为 77.66 ms, 而人脸检测部分每一帧平均耗时约为 129.99 ms.

根据过去图像处理领域研究经验可知, 若将平常的彩色图像转换为灰度图进行处理, 将能极大地提高背景建模的速度; 将输入的图像缩小, 则其运行时间也会按比例减少. 本实验将输入图像转换成灰度图并且缩小到原来的 1/3 来进行背景建模, 取得了不错的效果.

同时输入的图像对函数的运行速度影响很大, 所以本实验在行人检测之前使用背景建模再进行前景提取的方法提取出运动物体, 力求将检测区域缩到最小, 提高运行速度, 类似的方法可见文献[16].

另外一个影响较大的参数为 padding, 是用于对要检测的图像进行边界的扩充, 如果设置为 (0,0), 那么检测窗口的中心就不是从图像的 (0,0) 坐标开始扫描的. 这样虽然能提高运行速度, 却会降低检测正确率, 所以这是一个需要权衡的参数, 经对比, 本实验使用参数 (32,32), 这样较好地平衡运行速度和检测正确率.

对于人脸检测部分的运行速度, 受到输入图像的质量和大小影响, 经过背景建模和前景提取之后, 将识别区域限制在一个较小的范围, 依然耗时大约在 130 ms. 所以只能在行人检测检测到结果的前提下才启动人脸检测, 该方法人脸检测的漏检率会提高, 不过能有效地提升总体的运行速度.

4 结论

研究了一种基于前景提取和模式识别的行人检测算法, 通过对混合高斯模型、HOG+SVM 分类器、Harr+AdaBoost 等基础算法的综合应用, 解决

前景提取的误检率问题和模式识别的速度问题,并且该思路还可以完成蒙面人这一类特殊对象的初步甄别,并通过实验验证了新型混合算法的可行性。

在部分特殊场景下,会存在混合高斯模型提取出的矩形框比行人对象要小的情况,下一步的工作将针对混合高斯模型提取出的矩形框不准确的问题,在矩形框附近进行多次采样的方法进行研究。

参考文献:

- [1] 杨涛,李静,潘泉,等.基于场景模型与统计学习的鲁棒行人检测算法[J].自动化学报,2010,36(4):499-508.
- [2] 张江钰.依据移动终端和机器视觉的机器人路径跟随控制方法研究[D].武汉:湖北工业大学电气与电子工程学院,2016.
- [3] 李蹊.深度学习在行人检测中的研究与应用[D].北京:北京邮电大学信息与通信工程学院,2017.
- [4] 郝向东,毛晓波,梁静.ELM与Mean Shift相结合的抗遮挡目标跟踪算法[J].郑州大学学报(工学版),2016,37(1):1-5.
- [5] SHIPOVA K G, SAVCHENKO A V. Video-Based pedestrian detection on mobile phones with the cascade classifiers[C]//International Conference on Network Analysis. Springer, Cham, 2014: 209-216.
- [6] RUMAKSARI A N, SUMPENO S, WIBAWA A D. Background subtraction using spatial mixture of Gaussian model with dynamic shadow filtering[C]//International Seminar on Intelligent Technology and ITS Applications. IEEE, 2017: 296-301.
- [7] 范文超,李晓宇,魏凯,等.基于改进的高斯混合模型的运动目标检测[J].计算机科学,2015,42(5):286-288+319.
- [8] SHAHBAZ A, KURNIANGGORO L, JO K H. A comparative study of foreground detection using Gaussian mixture models-novice to novel[C]//International Conference on Control, Automation and Systems. IEEE, 2017: 1333-1336.
- [9] 符林清.采用HOG算子的行人检测实时处理器的性能优化[D].深圳:深圳大学信息工程学院,2016.
- [10] 徐琳,张明.基于特征融合的行人检测技术[J].计算机系统应用,2015,24(10):238-242.
- [11] ANSARI M A, DIXIT M, Kurchaniya D, et al. An effective approach to an image retrieval using SVM classifier[J]. International journal of computerences & Engineering, 2018, 5(6): 1410-1417.
- [12] WANG J, GAO L, ZHANG H, et al. Adaboost with SVM-Based classifier for the classification of brain motor imagery tasks[M]//Universal Access in Human-Computer Interaction. Users Diversity. Springer Berlin Heidelberg, 2011: 629-634.
- [13] OUALLA M, Sadiq A, Mbarki S. A survey of Haar-Like feature representation[C]//International Conference on Multimedia Computing and Systems. IEEE, 2014: 1101-1106.
- [14] 李文娜.基于Haar特征级联强分类器和肤色模型的人脸检测[J].辽宁石油化工大学学报,2010,30(3):61-64.
- [15] KHAMMARI A, NASHASHIBI F, ABRAMSON Y, et al. Vehicle detection combining gradient analysis and AdaBoost classification[C]. Intelligent Transportation Systems. IEEE, 2015: 66-71.
- [16] 田仙仙,鲍泓,徐成.一种改进HOG特征的行人检测算法[J].计算机科学,2014,41(9):320-324.
- [17] VIOLA P, JONES M. Rapid Object Detection using a Boosted Cascade of Simple Features[C]//IEEE Computer Society Conference on Computer Vision & Pattern Recognition. 2003,41(1):112-117.
- [18] FREUND Y, SCHAPIRE R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences, 1997, 55(1): 119-139.
- [19] RISTANI E, SOLERA F, ZOU R S, et al. Performance Measures and a Data Set for Multi-Target, Multi-Camera Tracking[J]. Discrete Dynamics in Nature, 2016(2): 710-719.
- [20] HTIKE K K. Efficient determination of the number of weak learners in AdaBoost[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2017, 29(5): 967-982.

A Pedestrian Model Recognition Detection Algorithm Based on Foreground Extraction

YANG Zhongming¹, LI Zilong², HU Yinwen², HUANG Han², CAI Zhaoquan³

(1.Guangdong Polytechnic of Science and Technology, Zhuhai 519090, China; 2.South China University of Technology, Guangzhou 510006, China; 3.Huizhou University, Huizhou 516007, China)

Abstract: In this paper, the algorithm principles of Gaussian mixture model, HOG+SVM classifier and Haar+Adaboost classifier were explored. A pedestrian detection algorithm based on foreground extraction and pattern recognition was proposed. The background modelling was executed by using Gaussian mixture model and then the moving object was entracted by using foreground modeling methods. The pedestrian detection hased on the moving objects and face recognition on the objects were execnted. By this, the misjudgment problems was solved based on background modeling methods and efficiency problems based on statistical learning methods. The experimental results showed that the new algorithm could greatly reduce the missed detection rate compared to using the pattern recognition algorithm alone, and it performed well in terms of running speed and detection rate.

Key words: background modeling; pedestrian detection; face detection; AdaBoost; model recognition

本刊被下列数据库及文摘收录:

- 美国《化学文摘》(CA)
- 俄罗斯《文摘杂志》(AJ)
- 英国《科学文摘》(SA)
- 美国《数学评论》(MR)
- 美国《剑桥科学文摘》(CSA)
- 波兰《哥白尼索引》(IC)
- 《中国学术期刊(光盘版)》
- 《中国科技论文统计源》
- 《中文科技期刊数据库》
- 《中国期刊网》
- 《中国学术期刊综合评价数据库》

- 《万方数据系统》
- 《中国机械工程文摘》
- 《中国数学文摘》
- 《中国化学化工文摘》
- 《中国无机分析化学文摘》
- 《中国力学文摘》
- 《中国物理文摘》
- 《工程机械文摘》
- 《中国学术期刊文摘》
- 《电子科技文摘》

郑州大学学报(工学版)
Zhengzhou Daxue Xuebao (Gongxueban)

双月刊 (1980年创刊)

第40卷 第5期 总第167期 2019年9月10日

Journal of Zhengzhou University
(Engineering Science)

Bimonthly (Started in 1980)

Vol.40 No.5 Sum No.167 Sep. 10, 2019

主管单位 河南省教育厅
主办单位 郑州大学
出版单位 《郑州大学学报》编辑部
电子信箱 gxb@zzu.edu.cn
地 址 河南省郑州市科学大道100号(450001)
电 话 (0371)67781276 67781277
主 编 李燕燕
副 主 编 梁 静
印刷单位 山西同方知网印刷有限公司
发行范围 国内外公开发行
征 订 处 全国各地邮政局
发行单位 河南省邮政发行局

Administrated by The Education Department
of Henan Province
Sponsored by Zhengzhou University
Edited & Published by Editorial Board of Journal of
Zhengzhou University
E-mail gxb@zzu.edu.cn
Address No.100 Science Avenue, Zhengzhou 450001, China
Telephone (0371)67781276 67781277
Chief Editor LI Yanyan
Executive Chief Editor LIANG Jing
Printed by Shanxi Tongfang Knowledge Network Printing Co., Ltd
Distributed by Publishing Trading Corporation,
P.O.B.782, Beijing 100011, China

中国标准刊号: ISSN 1671-6833
CN 41-1339/T

定价: 20.00元

邮发代号: 36-232