物联网环境下考虑多个利益主体的 区域配电系统能量管理

岳菁鹏^{1,2},胡志坚²,陈纬楠²

(1. 广东电网有限责任公司电力科学研究院,广东 广州 510080;2. 武汉大学 电气与自动化学院,湖北 武汉 430000)

摘要:随着物联网设备和分布式资源在配电网中的不断渗透,区域配电网的能量管理问题面临新的挑战,为 此提出云-雾分层能量管理架构,并利用智能算法实现含多个利益主体的配电系统的能量管理和优化决策。 所提方法在雾层计算中借助机器学习完成对智能电表、各种物联网设备产生的数据进行计算和处理,在云端 计算中通过云-雾间的数据交互及外部信息的收集,利用智能优化算法对配电网制定的决策目标进行整体优 化计算,以达到智能决策的目的。通过建立配电网内普通用户、微电网、配电网运营商3个利益主体的效用 和收益模型,在雾层捕捉用户用电行为和对新能源出力数据进行回归预测,根据用户用电负荷对电价的反 应,在云端以社会福利最大为目标,对配电网的总购电负荷及零售电价进行优化决策,实现整个配电网的优 化管理。通过IEEE 33节点系统算例对所提方法进行仿真,结果验证了所提方法的有效性。

关键词:物联网;多利益主体;微电网;区域配电网;能量管理 中图分类号:TM 73;TK 01

文献标志码:A

DOI:10.16081/j.epae.202008002

0 引言

物联网 IoT(Internet of Things)是利用现代通信 和互联网技术,通过有线和无线的方式将不同的设 备、传感器等进行相连的技术^[1]。目前, IoT 设备之 间的连接越来越多,预计到2020年将有260亿个IoT 设备进行连接[2]。随着能源互联网技术在电网领域 的深度应用,以及设备在电网各个环节特别是用电 环节的不断增多,各成员的信息和数据交换将变得 更加频繁,越来越多的可控单元将参与到配电网的 能量运行和管理过程中。例如,文献[3]通过对IoT 设备的控制实现了电能自动需求响应,从而优化家 庭用电行为;文献[4]通过对微电网中IoT设备的能 量管理实现运行成本最小化。同时,在配电系统中, 随着 loT 设备和智能电表的应用,系统中将产生大量 数据,这些数据的来源不同,格式多样化,单靠云集 中庞大的数据进行处理会引起云端的负荷过重,利 用雾计算分层处理是一种很好的途径[5-6]。文献[7] 提出了基于IoT和雾计算的3层能量管理架构,第一 层为用户通过IoT网关和智能电表实现与系统之间 的通信和互联,第二层实现用户和零售市场之间的 互联,第三层进行系统稳定性计算和数据存储。

在电力IoT环境下,智能算法的不断发展和应用 有利于对电网运行中产生的大数据进行检测、识别 和挖掘。如模糊逻辑、支持向量机、人工神经网络 ANN(Artificial Neural Network)等可实现对电力系

收稿日期:2020-03-26;修回日期:2020-06-07

基金项目:国家自然科学基金资助项目(51977156) Project supported by the National Natural Science Foundation of China(51977156)

统中的负荷进行预测,其中支持向量机和神经网络 应用最为广泛,同时随着信息化水平的提高以及海 量配用电数据的获取,基于人工智能的神经网络由 浅层神经网络逐步过渡到深层网络[8-10]。文献[11] 利用地基云图结合径向基函数人工神经网络,通过 有监督和无监督学习混合训练的方法,对短期光伏 功率进行预测。文献[12]将深度信念学习方法与传 统BP神经网络、支持向量机进行比较,研究结果表 明深度信念学习方法能在复杂因素影响的情况下提 高预测精度。

随着售电侧市场改革的不断深入,特别是中央 "9号文"提出了放开零售市场,多途径培育市场主 体,并引导具有分布资源的用户和微电网参与电力 交易,未来在配电网中将出现越来越多的新利益主 体,在此背景下的配电网能量管理和优化调度亟待 进行研究[13-15]。本文选择将配电系统中的普通用 户、微电网及配电网运营商 DSO (Distribution System Operator)3个利益主体作为研究对象,首先建立 了三者的效用及收益模型,然后提出了IoT环境下配 电网的云-雾分层能量管理架构,利用智能算法在雾 端对用户的用电行为进行回归预测,分析用户的用 电行为与新能源出力,在云端对给定目标进行优化 计算,最后通过仿真算例验证所提能量管理方法和 模型的有效性。

1 系统模型

图1给出了配电网的云-雾分层能量管理架构 示意图,其主要包含3层结构:底层为配电网内的各 成员,包括用户、分布式能源及微电网等;中间层为 物理电网中部署的雾计算节点,该节点可利用机器 学习对底层数据进行挖掘,实现聚类、回归预测等目 的;上层为针对整个电网计算的云节点,可以利用人 工智能优化工具(如启发式学习)实现配电网的整体 优化管理。图中,*K*为微电网的数量;*N*为普通用户 的数量。



图1 含微电网的配电网分层能量管理架构示意图

Fig.1 Schematic diagram of hierarchical energy management architecture for distribution network with microgrids

1.1 底层结构

在普通用户和微电网的各种用电设备、太阳能、 小型风力发电机、储能系统等分布式资源中均可部 署 IoT设备。IoT设备的连接及通信示意图如图 2 所 示。数据库系统可对智能电表数据和 IoT设备产生 的数据进行存储,同时雾层服务器与数据库系统相 连。局域 IoT 网关(gateway)及设备之间的通信有有 线和无线 2 种形式,如 IEEE 802.11(WLAN)、IEEE 802.15(WPAN)、IEEE 802.15.4(Zigbee)等。网关可 以采集 IoT设备的用电信息以及外部相关信息(如 电价),通过 OpenADR 协议与配电网进行通信,并通 过各自的能量管理系统实现负荷管理、需求响应 等功能^[16-18]。



图2 IoT设备的连接及通信示意图

Fig.2 Schematic diagram of connection and communication among IoT devices

1.2 雾层级功能

在配电网的某些节点中部署服务器(CPU)和数据库实现对底层的一部分用户信息的数据存储和管理,以及处理用户和DSO的请求,从而减轻云端数

据的处理压力,降低延时。如图2所示,雾节点与底 层用户的 IoT 网关和智能电表进行通信。本文提出 在雾层级部署人工神经网络,通过对样本数据的学 习和网络训练,实现对用户用电行为的回归预测^[19]。 基于机器学习的负荷预测示意图如附录中图 A1 所 示。输入数据为影响用户用电行为的各种因素,如 时间属性、电价属性、天气数据等,输出为实时预测 负荷,可捕捉用户在不同条件下的用电行为,同时为 DSO和用户的负荷管理提供充足的信息来源。神经 网络训练过程中需要确定输入层神经元、隐含层节 点个数、输入层与隐含层之间的权值、隐含层与输出 层之间的权值以及输入层和输出层的阈值等。同 理,在雾节点可实现对微电网和分布式资源的出力 预测,如根据所采集的地理信息、天气数据(风速、光 照强度等)、分布式电源类型等,基于神经网络学习 进行风 / 光发电功率预测。

1.3 云端功能

云端负责整个配电网的能量管理,可进行优化 调度和稳定计算,并与外部市场连接参与竞价交易。 其通过广域网络(如互联网)与雾层进行通信,并对 数据进行存储和处理,根据整个系统的运行状态和 外部信息发出指令,根据所建立的优化模型,利用部 署在云端的智能优化算法做出决策。

本文利用智能优化算法中的自适应差分进化 DE(Differential Evolution)算法^[20]求解云端建立的 全局最优化问题。DE算法为基于群体的启发式搜 索算法,基本思想来源于遗传算法,其进化流程与遗 传算法非常类似,可以求解大规模离散、非线性问 题,具有很好的鲁棒性。在本文中,首先输入雾端数 据,以用户、微电网、DSO的目标函数及相应约束建 立优化模型,并编码生成初始种群;然后通过交叉、 变异、选择操作,生成下一代种群并计算种群的适应 度,若此时满足指标阈值或达到最大迭代次数,则转 码输出结果,否则重复迭代步骤。

2 配电网内各主体模型

2.1 用户收益模型

不同用户的用电习惯和用电喜好一般是相互独 立的,IoT、智能电表以及大数据技术的发展使得对 每个用户的用电习惯进行捕捉成为可能。例如通过 收集温度、电价、用电时间、功率等数据信息,对不同 居民、工业用户的用电习惯和行为进行分析。本文 利用微观经济学的函数概念建立用户效用模型。通 过选择不同的效用函数U(x,ω)对用户的用电行为 建模,其中x为用户的能源消费水平,参数ω随时间 和用户的不同而变化,表示用户的电能消费行为习 惯。对每个用户而言,效用函数代表用户的满意度, 本文参考文献[21],将效用函数定义为二次边际效 用递减函数,如式(1)所示。

$$U(x,\omega) = \begin{cases} \omega x - \alpha x^2/2 & 0 \le x \le \omega/\alpha \\ \omega^2/(2\alpha) & x > \omega/\alpha \end{cases}$$
(1)

其中, α为提前设置的参数, 表示电能消费的外部 条件。

图3给出了当α=0.3时不同用户电能消费行为 习惯下的效用以及当ω=0.5时的边际效用(图中效 用为标幺值)。由图3可知,在任何的用户电能消费 行为习惯下,其边际效用均递减,但递减速度不一。



图 3 $\alpha = 0.3$ 时用户用电效用函数 Fig.3 Utility function of consumer consumption

when $\alpha = 0.3$

综上,用户消费电力所获得的效用与购买电力 的成本构成了用户的总收益,如式(2)所示。

$$R_{\text{cumstomer},i} = \sum_{t=1}^{T} \left(U(x_i^t, \boldsymbol{\omega}_i) - P_{\text{retailer}}^t x_i^t \right)$$
(2)

其中, $R_{\text{cumstomer},i}$ 为用户i的总收益;T为时间周期; P_{retailer}^{i} 为t时刻用户购电的实时零售电价; x_{i}^{i} 为用户i在t时刻的能源消费,本文中由用电功率计算; ω_{i} 为用户i的电能消费行为习惯。

2.2 微电网模型

本文考虑的微电网均为并网型,且允许微电网 的能量双向流动,即微电网可通过自身的能量管理 系统,基于内部条件和外部信号(如价格、需求响应 等)优化能量流动,一般上网电价相对固定,按照当 地新能源的上网价格进行交易,微电网的购电价格 则按照整个配电网的零售电价,如实时电价、分时电 价等。

现从微电网内新能源和储能系统成本、购电成 本及售电收益的角度建立微电网收益模型。

(1)储能系统的成本模型。

储能的运行策略由自身的能量管理系统确定, 其运行成本基于全寿命周期的概念,取决于电池充 放电的速度和功率,可建立关于充放电功率的二次 凸函数^[22],如式(3)所示。

$$S_{j} = \sum_{i=1}^{r} \alpha_{1} (S_{j}^{i})^{2} + \beta_{1}$$
(3)

其中, S_j 为微电网j内储能系统的总成本; S'_j 为微电网j内储能系统在t时刻的充放电量; α_1 、 β_1 为常数,

 $\exists \alpha_1 \neq 0_\circ$

(2)新能源的成本模型。

新能源包括光伏和风电,其成本模型根据新能源的上网电量建立。对于新能源而言,其成本包含两部分:第一部分为新能源从全寿命角度考虑的损耗成本,第二部分为新能源的运行维护成本。因此,新能源的成本模型为:

$$r_{j} = \sum_{i=1}^{T} \alpha_{2} (r_{j}^{i})^{2} + \beta_{2} r_{j}^{i}$$
(4)

其中, r_j 为微电网j内新能源的总成本; r_j 为微电网j内新能源在t时刻的发电量; α_2 为常数; β_2 为新能源 的平均运维成本。

(3)微电网内用户的收益模型。

与配电网内的其他用户一样,微电网内用户的 收益模型均采用效用函数减购电成本表示,见式(5)。

$$L_j = U(x_j^t, \omega_j) - P_{\text{retailer}}^t x_j^t$$
(5)

其中, L_j 为微电网 j 内用户的总收益; $U(x'_j, \omega_j)$ 为微 电网j内用户的效用函数; x'_j 为微电网j内用户在t时 刻的能源消费量。

(4)新能源售电收入。

微电网内自身的发电资源以当地新能源上网电 价卖给电网,则新能源售电收入可表示为:

$$\begin{cases} H_{\text{renewable},j} = p_{\text{renewable},\text{sell}} E_{\text{renewable},j}^{t} \\ \text{s.t.} \quad 0 \le E_{\text{renewable},j}^{t} \le B_{\text{initial}} + r_{j}^{t} + \sum_{t=1}^{T} (r_{j}^{t-1} - E_{\text{renewable},j}^{t-1})^{(6)} \end{cases}$$

其中, $H_{\text{renewable},j}$ 为微电网j内新能源的售电总收入; $p_{\text{renewable},\text{sell}}$ 为新能源上网电价,本文中取固定值; B_{initial} 为初始时刻微电网内储能系统的电量; r_j^{t-1} 为微电网j内新能源在t-1时刻的发电量; $E_{\text{renewable},j}^{t-1}$ 分微电网j内新能源在t-1、t时刻的上网电量。 该式中的约束条件是指新能源交易电量的上限为t-1时刻新能源的剩余电量与t时刻新能源发电量之和。

综上所述,单个微电网*j*在一定时段内的总收 益*R*_{mg,j}为:

$$R_{\text{mg},j} = H_{\text{renewable},j} + L_j - S_j - r_j \tag{7}$$

2.3 DSO 模型

(1)购电成本。

DSO负责从电力批发市场和微电网购买电力供给用户,从批发市场购电的成本 $C_{\text{wholesale}}$ 和购买新能源电量的成本 $C_{\text{renewable}}$ 分别如式(8)和式(9)所示。

$$C_{\rm wholesale} = p_{\rm wholesale} E_{\rm wholesale} \tag{8}$$

$$C_{\text{renewable}} = p_{\text{renewable, sell}} \sum_{t=1}^{T} E_{\text{renewable}}^{t}$$
(9)

其中, $E_{wholesale}$ 为DSO从电力批发市场购买的电量; $p_{wholesale}$ 为电力批发价格参数,反映了价格与批发电量和时间的关系; $E'_{renewable}$ 为t时刻新能源的上网电 量,且有 $\sum_{t=1}^{T} E_{\text{renewable}}^{t} \leq \sum_{t=1}^{T} \sum_{j=1}^{K} E_{\text{renewable},j}^{t}$,表示t时刻DSO

从微电网购买的新能源电量不能超过所有微电网在 *t*时刻提供的电量。

(2)碳排放收益。

京都议定书(Kyoto protocol)规定温室气体减排 量成为可交易的无形商品,在一定的时段内碳排放 收益*H*。与可再生能源发电量间的关系可表示为:

$$H_{\rm c} = a \sum_{t=1}^{T} \left(E_{\rm renewable}^{t} \right)^2 + b \sum_{t=1}^{T} E_{\rm renewable}^{t}$$
(10)

其中,a和b为常系数。

(3) 售电收入。

配电网以零售价格将电量出售给配电网内的用户,售电收入*R*_{retai}可表示为:

$$R_{\text{retail}} = \sum_{i=1}^{N} \sum_{j=1}^{K} \sum_{t=1}^{T} P_{\text{retail}}^{t} \left(x_{i}^{t} + x_{j}^{t} \right)$$
(11)

综上所述,配电网总收益*R*_{dis}可通过购电成本、 碳排放收益、售电收入的代数和计算得到,可表示为:

$$R_{\rm dis} = H_{\rm c} - C_{\rm renewable} + R_{\rm retail} - C_{\rm wholesale}$$
(12)

2.4 云端优化目标

整个配电网的总体社会福利最大,即用户、微电 网、DSO 三方的收益最大化,假设某配电网包含 N个 用户、K个独立微电网、1个 DSO,根据式(2)所示用 户收益、式(7)所示微电网的总收益和式(12)所示配 电网的总收益,建立本文寻优的目标函数为:

$$\begin{cases} \max \sum_{i=1}^{N} R_{\text{customer}, i} + \sum_{j=1}^{K} R_{\text{mg}, j} + R_{\text{dis}} \\ \text{s.t.} \quad E_{\text{wholesale}}^{\min} \leq E_{\text{wholesale}}^{t} \leq E_{\text{wholesale}}^{\max} \end{cases}$$
(13)
$$E_{\text{wholesale}}^{\min} = \sum_{i=1}^{N} x_{i}^{t} - \sum_{j=1}^{K} E_{\text{renewable}, j}^{t} \end{cases}$$

其中, $E_{wholsale}^{max}$ 、 $E_{wholsale}^{min}$ 分别为DSO从电力批发市场购买电量的上、下限, $E_{wholsale}^{min}$ 应满足配电网内所有用户的电能需求。

3 算例分析

为了验证将人工智能应用于本文所提配电网能 量管理架构的可行性,以IEEE 33节点系统为例进 行算例分析。该配电网含有3个微电网,分别位于 节点12、24、30处,系统的结构图如附录中图A2所 示。微电网中含有光伏、风机等分布式发电资源。

该配电网基于第1节所提云-雾架构进行能量 管理,雾层对每个微电网中的分布式能源和负荷进 行计算,主要进行回归预测,其他普通用户也在相应 的雾层通过机器学习对其进行用电行为的回归预 测,得到所有用户的实时ω值,在云端利用智能DE 算法对配电网内24h的零售电价和配电网总购电量 进行寻优计算,具体实现过程如下。

3.1 雾层智能计算过程

该配电网包含718个不同的用户,在相应的雾 节点通过基于 Levenberg-Marquardt 算法的多层前馈 神经网络对所有用户的用电习惯进行监督学习,实 现回归预测,输入数据包括时间、时间类型、温度、湿 度、光照强度、风速等信息,输出数据为用户的用电 时间和负荷,训练集、验证集和测试集分别占数据的 70%、15%和15%。该神经网络包含2层,其隐含层 根据经验选择10个神经元,设置在网络泛化能力不 再提高时停止训练。学习泛化轨迹如图4所示。由 图可以看出,经过34次迭代均方根误差开始满足 要求(此时达到的最佳值为0.002268),40次迭代 之后停止学习,具体回归效果如附录中图A3所示, 其 $R \ge 0.92$,根据经验可知,当R > 0.9时,认为训练后 回归效果较好。



图4 学习泛化轨迹

Fig.4 Learning generalization trajectory

用户某天的用电效用特征(标幺值)见图5。与 负荷预测同理,在雾层对所收集的配电网内发电资 源数据进行学习,如将地理位置、气象条件、风机/ 光伏发电机类型等作为输入,可输出功率作为网络 输出,建立神经网络并进行训练。本文假设每个微 电网内部根据自身的能量管理算法操作其储能的运 行情况,在雾层可获得微电网在一定价格条件下的 分布式新能源交易量。不失一般性,分布式新能源 数据采用Open Energy Information(OpenEI)^[23]中典 型日的风电、光伏功率。



Fig.5 Customers' utility feature on a given day

3.2 云端智能计算

利用雾层收集的数据,基于DE算法实现式(13) 所示最大化社会福利的目标函数,对配电网的总购 电量和DSO的零售电价进行优化。

令 α =0.3,用户模型中初始参数 ω 为(0,1]范围 之内的随机数,在云端计算时根据图5,取实时的平 均值 $\bar{\omega}$ 。微电网模型中的储能成本参数为 α_1 =1、 β_1 =0,新能源成本参数为 α_2 =1、 β_2 =1, $p_{\text{renewable,sell}}$ =1.5 元/(kW·h)。不失一般性,配电网模型中DSO购电 价格参数取固定价格0.45元/(kW·h),配电网碳收 益模型参数为a=0.78、b=1。

云端通过智能DE算法对决策目标进行全局寻 优,通过计算精度和时间权衡后,选择种群规模为 50,最大遗传代数为40,变异率为0.06,交叉率为 0.7,日优化计算结果在进行24次迭代时达到收敛, 而基于相同的数据利用传统遗传算法进行求解时, 需迭代30次才开始收敛。所得DSO日购电量和零 售电价如图6所示。





根据优化计算结果和云-雾节点数据,可得各方 成本、收益结果如表1所示。可见,在IoT环境下,通 过云-雾能量管理和人工智能技术,可实现配电网的 实时优化决策,可对配电网内各成员的收益进行实 时计算和在线能量管理。

表	各方成本	、收益结果
	H / / ///	

Table 1	Cost	and	earning	results	of	all	parties
10010 1	0000			1000000	~ *	****	perrete

	e	-	
指标	结果	指标	结果
平均批发电价 / [元・(kW・h)⁻1]	0.3530	MG ₁ 收益 / 元	1948
平均零售电价 / [元・(kW・h) ⁻¹]	0.4236	MG_2 收益 / 元	2110
配电网内用户成本 / 元	1.1590×10 ⁵	MG ₃ 收益 / 元	1 3 2 2
DSO 收益 / 元	3.3671×10^{4}	碳排放收益 / 元	10491

4 结论

由于分布式可再生能源、IoT设备在配电网系统 中不断渗透,系统运行产生的数据量不断增大,同时 配电网内的利益主体逐渐多样化,针对该背景下区 域配电网的能量管理和优化决策问题,本文提出了 云-雾分层能量管理架构,在雾层利用神经网络对配 电网内用户的用电行为进行捕捉,同时对分布式发 电资源进行回归预测,在云端计算中利用智能算法 实现整个配电网的优化决策,所提方法能为DSO的 运行决策和在线能量管理提供参考。 与此同时,随着 IoT 设备在用户侧不断渗透以及 售电侧市场改革的深入,售电公司、具有分布式资源 的用户、虚拟电厂运营商等新的利益主体将出现,使 得未来配电网内各利益主体的优化决策模型更加丰 富,未来配电网的能量管理系统如何满足用户多样 化需求和信息的安全交互将是下一步的研究方向。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

- [1] 荆孟春,王继业,程志华,等. 电力物联网传感器信息模型研究 与应用[J]. 电网技术,2014,38(2):532-537.
 JING Mengchun, WANG Jiye, CHENG Zhihua, et al. Research and application of sensor information model in power internet of things[J]. Power System Technology,2014,38(2):532-537.
- [2] LEE I,LEE K. The Internet of Things(IoT):applications, investments, and challenges for enterprises[J]. Business Horizons, 2015,58(4):431-440.
- [3] CHEN C R, LAN M J, HUANG C C, et al. Demand response optimization for smart home scheduling using genetic algorithm[C]//2013 IEEE International Conference on on Advanced Video and Signal Based Surveillance. Krakow, Poland: IEEE, 2013:1461-1465.
- [4] YUE J P, HU Z J, LI C D, et al. Economic power schedule and transactive energy through an intelligent centralized energy management system for a DC residential distribution system[J]. Energies, 2017, 10(7):916.
- [5] CHIANG M, ZHANG T. Fog and IoT: an overview of research opportunities[J]. IEEE Internet of Things Journal, 2016, 3(6): 854-864.
- [6] NEGASH B,GIA T N,ANZANPOUR A, et al. Leveraging fog computing for healthcare IoT[J]. Springer International Publishing,2018,1:145-169.
- [7] YAGHMAEE MOGHADDAM M H, LEON-GARCIA A. A fogbased internet of energy architecture for transactive energy management systems[J]. IEEE Internet of Things Journal, 2018, 5(2):1055-1069.
- [8] 郝然,艾芊,肖斐. 基于多元大数据平台的用电行为分析构架研究[J]. 电力自动化设备,2017,37(8):20-27.
 HAO Ran,AI Qian,XIAO Fei. Architecture based on multivariate big data platform for analyzing electricity consumption behavior[J]. Electric Power Automation Equipment,2017,37(8): 20-27.
- [9] 赵文清,沈哲吉,李刚. 基于深度学习的用户异常用电模式检测[J]. 电力自动化设备,2018,38(9):34-38.
 ZHAO Wenqing,SHEN Zheji,LI Gang. Anomaly detection for power consumption pattern based on deep learning[J]. Electric Power Automation Equipment,2018,38(9):34-38.
- [10] 胡伟,郑乐,闵勇,等. 基于深度学习的电力系统故障后暂态稳 定评估研究[J]. 电网技术,2017,41(10):3140-3146.
 HU Wei,ZHENG Le,MIN Yong, et al. Research on power system transient stability assessment based on deep learning of big data technique[J]. Power System Technology,2017,41(10): 3140-3146.
- [11] 陈志宝,丁杰,周海,等. 地基云图结合径向基函数人工神经网 络的光伏功率超短期预测模型[J]. 中国电机工程学报,2015, 35(3):561-567.

CHEN Zhibao, DING Jie, ZHOU Hai, et al. A model of very short-term photovoltaic power forecasting based on groundbased cloud images and RBF neural network[J]. Proceedings of the CSEE, 2015, 35(3):561-567.

- [12] 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.
 KONG Xiangyu,ZHENG Feng, E Zhijun, et al. Short-term load forecasting based on deep belief network[J]. Automation of Electric Power Systems,2018,42(5):133-139.
- [13] 中共中央国务院.关于进一步深化电力体制改革的若干意见 (中发[2015]9号)[EB/OL].(2015-03-15)[2019-06-27]. http://tgs.ndrc.gov.cn/zywj/201601/t20160129_773852.html.
- [14] LI C D, DE BOSIO F, CHEN F, et al. Economic dispatch for operating cost minimization under real-time pricing in droopcontrolled DC microgrid[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2017, 5(1):587-595.
- [15] SHEN J S, JIANG C W, LIU Y Y, et al. A microgrid energy management system with demand response for providing grid peak shaving[J]. Electric Power Components and Systems, 2016,44(8):843-852.
- [16] KIM J,BYUN J,JEONG D, et al. An IoT-based home energy management system over dynamic home area networks[J]. International Journal of Distributed Sensor Networks, 2015, 2015;1-15.
- [17] JALALI F, VISHWANATH A, DE HOOG J, et al. Interconnecting fog computing and microgrids for greening IoT[C]//2016 IEEE Innovative Smart Grid Technologies-Asia (ISGT-Asia). Melbourne, Australia: IEEE, 2016:693-698.
- [18] SAMADI P, MOHSENIAN-RAD A H, SCHOBER R, et al. Optimal real-time pricing algorithm based on utility maximization for smart grid[C]//2010 First IEEE International Conference on Smart Grid Communications. Gaithersburg, MD, USA: IEEE, 2010:415-420.
- [19] 赵文清,严海,周震东,等.基于残差 BP 神经网络的变压器故 障诊断[J].电力自动化设备,2020,40(2):143-148.

ZHAO Wenqing, YAN Hai, ZHOU Zhendong, et al. Fault diagnosis of transformer based on residual BP neural network[J]. Electric Power Automation Equipment, 2020, 40(2):143-148.

- [20] 周艳平,蔡素. 一种自适应差分进化算法及应用[J]. 计算机 技术与发展,2019,29(7):119-123.
 ZHOU Yanping,CAI Su. An adaptive differential evolution algorithm and its application[J]. Computer Technology and Development,2019,29(7):119-123.
- [21] LI N, CHEN L J, LOW S H. Optimal demand response based on utility maximization in power networks[C] //2011 IEEE Power and Energy Society General Meeting. San Diego, CA, USA: IEEE, 2011:1-8.
- [22] CHIU T C,SHIH Y Y,PANG A C,et al. Optimized day-ahead pricing with renewable energy demand-side management for smart grids[J]. IEEE Internet of Things Journal, 2017, 4(2): 374-383.
- [23] OpenEI. Energy information and data(OpenEI.org)[EB / OL]. [2019-06-27]. https://openei.org / wiki / Main_Page.

作者简介:



岳菁鹏(1985—), 男, 湖北武汉人, 博 士研究生, 主要研究方向为分布式能源及微 电网(**E-mail**: jp_yue@whu.edu.cn);

胡志坚(1969—),男,湖北武汉人,教 授,博士,主要研究方向为电力系统分析、新 能源并网等(E-mail:zhijian_hu@163.com); 陈纬楠(1995—),男,江苏南通人,硕 士研究生,主要研究方向为负荷预测及微电

网能量管理(E-mail:2572921286@qq.com)。

山月加月

(编辑 陆丹)

Energy management of regional distribution system considering multiple stakeholders under IoT environment

YUE Jingpeng^{1,2}, HU Zhijian², CHEN Weinan²

(1. Electric Power Research Institute of Guangdong Power Grid Co., Ltd., Guangzhou 510080, China;

2. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430000, China)

Abstract: With the continuous penetration of IoT (Internet of Things) devices and distributed resources in the distribution network, the energy management of regional distribution network is facing new challenges. Therefore, a cloud-fog layered hierarchical energy management architecture is proposed, and the intelligent algorithm is used to realize the energy management and optimal decision-making of distribution system with multiple stakeholders. In the fog layer calculation, the data generated by smart meters and various IoT devices are calculated and processed with the help of machine learning. In the cloud layer calculation, the data interaction between cloud and fog and the collection of external information are used to carry out the overall optimization calculation of decision-making objective of distribution network by using intelligent optimization algorithm, so as to achieve the purpose of intelligent decision-making. The utility and income models of three stakeholders of common users, microgrid and distribution system operator are established. In the fog layer, the regression prediction of users' electricity consumption behavior and new energy output data is realized. According to the users' response to electricity price, the optimization decision of total purchasing load and retail price is made for distribution network in the cloud layer with the goal of maximizing social welfare, to realize the optimal management of the whole distribution network. The proposed method is simulated by the example of IEEE 33-bus system and the results verify the effectiveness of the proposed method.

Key words: IoT; multiple stakeholders; microgrid; regional distribution network; energy management

116

附 录



图 A1 用户负荷的机器学习示意图 Fig.A1 Schematic diagram of machine learning for users' load



图 A2 IEEE 33 节点配电系统结构图 Fig.A2 Structure of IEEE 33-bus distribution system



图 A3 训练集、验证集、测试集的回归效果 Fig.A3 Regression effect of training, validation and test sets