

# 考虑广义需求侧资源的深度置信网络短期负荷预测方法

胡 实, 唐 昊<sup>†</sup>, 吕 凯, 杨晨芳

(合肥工业大学 电气与自动化工程学院, 安徽 合肥 230009)

**摘要:** 随着智能电网信息化水平的不断提高以及可控负荷、分布式电源和储能等广义需求侧资源的大量接入, 将产生海量负荷数据集并改变负荷特性。为了提高负荷预测精度, 提出了一种考虑广义需求侧资源的深度置信网络(DBN)负荷预测方法。首先, 借助负荷聚合商确定了广义需求侧资源参与电力市场的机制, 构建了基于合同的广义需求侧资源调度模型, 并利用该模型求解广义需求侧资源参与电力市场的最优调度计划。其次, 引入DBN结构, 并将广义需求侧资源的最优调度计划作为其输入量, 建立了短期负荷预测模型。最后, 以实际数据进行仿真测试, 结果表明, 本文所提方法具有更高的预测精度。

**关键词:** 短期负荷预测; 广义需求侧资源; 深度置信网络; 负荷聚合商

**引用格式:** 胡实, 唐昊, 吕凯, 等. 考虑广义需求侧资源的深度置信网络短期负荷预测方法. 控制理论与应用, 2023, 40(3): 493–501

DOI: 10.7641/CTA.2021.10209

## Short-term load forecasting method of deep belief network by considering generalized demand-side resources

HU Shi, TANG Hao<sup>†</sup>, LÜ Kai, YANG Chen-fang

(School of Electrical Engineering and Automation, Hefei University of Technology, Hefei Anhui 230009, China)

**Abstract:** With the continuous improvement of the informatization level of smart grid and the massive access of generalized demand-side resources such as controllable load, distributed power sources and energy storage, massive load data sets will be generated and load characteristics will be changed. In order to improve the load forecasting accuracy, a deep belief network (DBN) load forecasting method considering generalized demand-side resources is proposed. Firstly, the mechanism of the participation of generalized demand-side resources in the power market is determined with the help of load aggregators, and a contract-based generalized demand-side resource scheduling model is constructed, which determines the optimal scheduling plan of generalized demand-side resources participating in power market. Then, a short-term load forecasting model is established by introducing the DBN structure and taking the optimal scheduling plan as its input. Finally, a simulation test is conducted with the actual data, and the results show that the proposed method has higher prediction accuracy.

**Key words:** short-term load forecasting; generalized demand side resources; deep belief network; load aggregator

**Citation:** HU Shi, TANG Hao, LÜ Kai, et al. Short-term load forecasting method of deep belief network by considering generalized demand-side resources. *Control Theory & Applications*, 2023, 40(3): 493–501

## 1 引言

短期负荷预测对于调度部门的机组最优组合、经济调度、最优潮流, 尤其是对现在与将来的电力市场有着重要的意义, 准确的负荷预测, 有利于合理安排发电机组的启停, 提高发电设备的利用率和调度的经济性, 保持电网运行的安全稳定性<sup>[1]</sup>。智能电网中可控负荷、分布式电源以及储能等广义需求侧资源以其

灵活多样的方式进行需求响应, 使负荷转移能力增强, 可转移时间范围更广<sup>[2–4]</sup>。在电力市场环境下, 用户针对不同的价格信号和激励机制以用电经济性为目标, 合理调整可控负荷、分布式电源及储能资源, 改变了负荷特性与变化规律<sup>[5–7]</sup>。为此, 在电力市场的短期负荷预测中, 需要考虑广义需求侧资源, 以提高预测精度。

收稿日期: 2021–03–13; 录用日期: 2021–10–14。

<sup>†</sup>通信作者。E-mail: htang@hfut.edu.cn; Tel.: +86 13856089699。

本文责任编辑: 张化光。

国家电网有限公司总部科技项目“弹性环境下基于深度学习的智能调度技术”(SGTYHT/19–JS–215)资助。

Supported by the State Grid Corporation of China Project “Intelligent Scheduling Technology Based on Deep Learning in Flexible Environment” (SGTYHT/19–JS–215).

国内外学者对考虑广义需求侧资源的负荷预测问题展开了一些研究。文献[8]分析以电价为引导的需求响应对用户负荷的影响,提出了支持向量分位数回归与核密度估计相结合的负荷预测模型。文献[9]将实际需求响应量化结果引入径向基函数神经网络,提高了负荷预测精度。文献[10]将用户主动响应计划作为负荷预测的外生输入量,测试得出将响应计划作为输入变量能够降低负荷预测的误差。

随着电网规模的不断扩大,信息化水平的不断提高,智能电网调度系统数据收集能力也不断提升,负荷及相关数据呈指数级增长,而上述文献中的负荷预测方法多为三层的浅层网络,难以很好地处理如今电网海量化的负荷数据集。深度置信网络(deep belief network, DBN)是一种高效的深度学习算法<sup>[11]</sup>,由若干个受限玻尔兹曼机(restricted boltzmann machine, RBM)<sup>[12]</sup>堆叠组成,可用于无监督学习,能够有效地处理电力负荷大数据。

近年来, DBN在图像分类<sup>[13]</sup>、汇率预测<sup>[14]</sup>和模式识别<sup>[15]</sup>等领域得到了广泛的应用,为复杂环境下的负荷预测问题提供了新的思路。文献[16]将DBN应用于时间序列预测问题,得到较好的预测效果。文献[17]建立了由两个RBM组成的DBN预测模型,结果表明DBN预测模型的预测精度明显优于传统神经网络。文献[18]基于DBN建立电、热、气多元负荷预测模型,结果验证了模型的有效性。

可控负荷、分布式电源和储能等广义需求侧资源大量接入并参与到电力市场中,其调度的灵活性必然会影响用电负荷的变化。故本文首先针对可削减负荷(load curtailment, LC)、可转移负荷(load shift, LS)和储能系统(energy storage, ES)3种可控资源,构建基于合同的广义需求侧资源最优调度模型。该模型以负荷聚合商(load aggregator, LA)收益最大为目标,并在合同的各项约束下,根据实时电价求解广义需求侧资源参与电力市场的最优调度策略。基于此,引入DBN负荷预测模型,将广义需求侧资源的最优调度计划作为输入量,提出了基于广义需求侧资源最优调度计划的综合负荷预测方法,并进行算例验证。

## 2 基于合同的广义需求侧资源调度模型

LA作为一个中介机构,可以整合用户需求响应资源并将它们引入市场交易。中小型电力用户在LA的帮助下和指导下,可以形成科学的用电方式,提高终端设备的用电效率<sup>[19]</sup>。LA的运行机制如图1所示。

为了引导用户更好地参与市场调节,本节站在LA的角度,提出了一种基于合同的广义需求侧资源调度模型。LA可以根据聚合的电力用户所在地区电价、用电特性等因素与用户签订不同的合同。其中,合同的差异主要体现在约定价格、响应量和响应时段等方面

的设置。根据电力市场实时电价和合同约定价格的差额,以最大化收益为目标,并在合同内容的规定下确定LC, LS和ES的最优调度计划,引导用户合理安排用电时间,达到削峰填谷的作用。

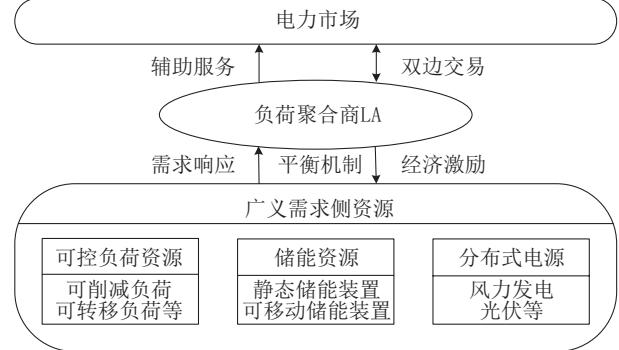


图1 LA的运行机制

Fig. 1 The operating mechanism of LA

### 2.1 可削减负荷合同模型

可削减负荷通常指可根据需要对用电量进行一定削减的负荷<sup>[2]</sup>。LA与中小型用户签订可执行的LC合同,并按照合同约定价格和电力市场实时电价的差额安排负荷削减的最佳时段,以获取最大利润并达到削峰的效果。LC合同模型的目标函数为

$$\max \sum_{t \in T} (\rho_t L_t^{\text{LC}} - C_t^{\text{LC}}), \quad (1)$$

式中:  $\rho_t$ 为电力市场实时电价,  $L_t^{\text{LC}}$ 为LC在t时刻总负荷削减量,  $C_t^{\text{LC}}$ 为LC合同在t时刻总成本,  $T$ 为1天中时间序列的个数。 $L_t^{\text{LC}}$ 和 $C_t^{\text{LC}}$ 的计算公式如下:

$$L_t^{\text{LC}} = \sum_{k \in N_{\text{LC}}} q_k^{\text{LC}} u_{kt}^{\text{LC}}, \quad (2)$$

$$C_t^{\text{LC}} = \sum_{k \in N_{\text{LC}}} (IC_k^{\text{LC}} y_{kt}^{\text{LC}} + c_k^{\text{LC}} q_k^{\text{LC}} u_{kt}^{\text{LC}}), \quad (3)$$

式中:  $q_k^{\text{LC}}$ ,  $IC_k^{\text{LC}}$ 和 $c_k^{\text{LC}}$ 分别为第k个LC合同规定的负荷削减量、启动成本和价格;  $u_{kt}^{\text{LC}}$ 为负荷削减状态指标,当第k个LC合同在t时刻执行时 $u_{kt}^{\text{LC}}=1$ ,否则 $u_{kt}^{\text{LC}}=0$ ;  $y_{kt}^{\text{LC}}$ 为LC合同启动指标,当第k个LC合同在t时刻启动时 $y_{kt}^{\text{LC}}=1$ ,否则 $y_{kt}^{\text{LC}}=0$ ;  $N_{\text{LC}}$ 为合同数量。合同的约束条件<sup>[20]</sup>为

$$\sum_{t'=t}^{t+D_k^{\min, \text{LC}}-1} u_{kt'}^{\text{LC}} \geq D_k^{\min, \text{LC}} y_{kt}^{\text{LC}}, \forall k, t, \quad (4)$$

$$\sum_{t'=t}^{t+D_k^{\max, \text{LC}}-1} z_{kt'}^{\text{LC}} \geq y_{kt}^{\text{LC}}, \forall k, t, \quad (5)$$

$$\sum_{t \in T} y_{kt}^{\text{LC}} \leq MN_k^{\text{LC}}, \forall k, \quad (6)$$

$$y_{kt}^{\text{LC}} - z_{kt}^{\text{LC}} = u_{kt}^{\text{LC}} - u_{k(t-1)}^{\text{LC}}, \forall k, t, \quad (7)$$

$$y_{kt}^{\text{LC}} + z_{kt}^{\text{LC}} \leq 1, \forall k, t, \quad (8)$$

其中:  $D_k^{\min, \text{LC}}$ 和 $D_k^{\max, \text{LC}}$ 分别为第k个LC合同的最短持续时间和最长持续时间;  $MN_k^{\text{LC}}$ 为第k个LC合同每

日最大执行次数;  $z_{kt}^{\text{LC}}$  为合同停止指标, 当第  $k$  个 LC 合同在  $t$  时刻停止时  $z_{kt}^{\text{LC}} = 1$ , 否则  $z_{kt}^{\text{LC}} = 0$ . 可见, 约束(4)–(6)分别为最短持续时间、最长持续时间和每日合同最大执行次数的限制, 约束(7)控制合同启停指标, 而约束(8)确保  $y_{kt}^{\text{LC}}$  和  $z_{kt}^{\text{LC}}$  不会同时为 1.

## 2.2 可转移负荷合同模型

可转移负荷通常指在一个调度周期内总用电量不变, 各时段用电量可灵活调节的负荷<sup>[2]</sup>. LA 通过引导用户将用电量从合同规定的负荷减少时段转移至负荷增加时段, 从而起到移峰填谷的作用. 可表示为

$$\max \sum_{t \in T} (\rho_t L_t^{\text{LS}} - C_t^{\text{LS}}), \quad (9)$$

$$L_t^{\text{LS}} = \sum_{k \in N_{\text{LS}}} q_k^{\text{LS}} u_{kt}^{\text{LS}}, \quad (10)$$

$$C_t^{\text{LS}} = \sum_{k \in N_{\text{LS}}} (IC_k^{\text{LS}} y_{kt}^{\text{LS}} + c_k^{\text{LS}} q_k^{\text{LS}} u_{kt}^{\text{LS}}), \quad (11)$$

$$\sum_{t \in T} q_{kt}^{\text{LS}} \alpha_{kt}^{\text{LS}} = 0, \forall k, \quad (12)$$

式(12)为可转移负荷调度前后变化约束, 式中,  $q_{kt}^{\text{LS}}$  表示第  $k$  个 LS 合同在  $t$  时刻规定的负荷转移量,  $\alpha_{kt}^{\text{LS}}$  表示  $t$  时刻负荷的转移方向,  $\alpha_{kt}^{\text{LS}} = -1$  表示负荷在该时刻转出,  $\alpha_{kt}^{\text{LS}} = 0$  表示该时刻无转移负荷,  $\alpha_{kt}^{\text{LS}} = 1$  表示负荷在该时刻转入. 合同的约束条件<sup>[20]</sup>为

$$\sum_{t'=t}^{t+DT_k^{\text{min,LS}}-1} u_{kt'}^{\text{LS}} \geq D_k^{\text{min,LS}} y_{kt}^{\text{LS}}, \forall k, t, \quad (13)$$

$$\sum_{t'=t}^{t+DT_k^{\text{max,LS}}-1} z_{kt'}^{\text{LS}} \geq y_{kt}^{\text{LS}}, \forall k, t, \quad (14)$$

$$\sum_{t \in T} y_{kt}^{\text{LS}} \leq MN_k^{\text{LS}}, \forall k, \quad (15)$$

$$y_{kt}^{\text{LS}} - z_{kt}^{\text{LS}} = u_{kt}^{\text{LS}} - u_{k(t-1)}^{\text{LS}}, \forall k, t, \quad (16)$$

$$y_{kt}^{\text{LS}} + z_{kt}^{\text{LS}} \leq 1, \forall k, t, \quad (17)$$

$$u_{kt}^{\text{LS}} = 0, \forall t \notin T_k^{\text{LS}}, \quad (18)$$

其中:  $T_k^{\text{LS}}$  为负荷转移时间段; 约束(18)限制 LS 合同在  $T_k^{\text{LS}}$  期间执行;  $L_t^{\text{LS}}$ ,  $C_t^{\text{LS}}$ ,  $q_k^{\text{LS}}$ ,  $IC_k^{\text{LS}}$  和  $c_k^{\text{LS}}$  等变量及约束与 LC 模型类似.

## 2.3 储能系统合同模型

储能装置可以方便地实现负荷在时空上的转移, 是 LA 理想的控制资源之一<sup>[4]</sup>. LA 根据电价差额安排储能充放电的最佳时段以最大化收益, 而储能的负荷转移特性也起到了削峰填谷的作用. ES 放电合同模型的目标函数为

$$\max \sum_{t \in T} (\rho_t DL_t^{\text{ES}} - C_t^{\text{ES}}), \quad (19)$$

其中:  $DL_t^{\text{ES}}$  为 ES 在  $t$  时刻总放电量,  $C_t^{\text{ES}}$  为 ES 在  $t$  时刻总成本.  $DL_t^{\text{ES}}$  和  $C_t^{\text{ES}}$  的计算公式如下:

$$DL_t^{\text{ES}} = \sum_{k \in N_{\text{ES}}} P_{kt}^{\text{ES}}, \quad (20)$$

$$C_t^{\text{ES}} = \sum_{k \in N_{\text{ES}}} c_k^{\text{ES}} P_{kt}^{\text{ES}}, \quad (21)$$

式中:  $P_{kt}^{\text{ES}}$  为第  $k$  个 ES 合同在  $t$  时刻的放电功率,  $c_k^{\text{ES}}$  为第  $k$  个 ES 合同的约定价格,  $N_{\text{ES}}$  为 ES 合同数量. 合同的约束条件<sup>[20]</sup>为

$$0 \leq P_{kt}^{\text{ES}} \leq u_{kt}^{\text{ES}} P_k^{\text{max}}, \forall k, t, \quad (22)$$

$$\sum_{t \in T} P_{kt}^{\text{ES}} \leq \eta_k E_k^{\text{max}}, \forall k, t, \quad (23)$$

$$\sum_{t'=t}^{t+DT_k^{\text{ES}}-1} z_{kt'}^{\text{ES}} \geq y_{kt}^{\text{ES}}, \forall k, t, \quad (24)$$

$$\sum_{t \in T} y_{kt}^{\text{ES}} \leq MN_k^{\text{ES}}, \forall k, \quad (25)$$

$$y_{kt}^{\text{ES}} - z_{kt}^{\text{ES}} = u_{kt}^{\text{ES}} - u_{k(t-1)}^{\text{ES}}, \forall k, t, \quad (26)$$

$$y_{kt}^{\text{ES}} + z_{kt}^{\text{ES}} \leq 1, \forall k, t, \quad (27)$$

其中:  $P_k^{\text{max}}$ ,  $\eta_k$  和  $DT_k^{\text{ES}}$  分别为第  $k$  个 ES 合同规定的储能装置额定功率、放电效率和连续放电时间;  $E_k^{\text{max}}$  为储能装置容量;  $MN_k^{\text{ES}}$  为每日合同最大执行次数;  $u_{kt}^{\text{ES}}$  为储能放电状态指标;  $y_{kt}^{\text{ES}}$ ,  $z_{kt}^{\text{ES}}$  分别为 ES 放电合同启动、停止指标. 约束(22)表示 ES 放电功率应该不大于额定功率; 约束(23)表示在调度时间内 ES 总放电量不大于能量容量; 约束(24)为 ES 连续放电时间的限制; 约束(25)限制每日 ES 合同的最大执行次数; 合同启停变量约束如式(26)–(27)所示.

储能充电时, LA 从电力市场购电出售给储能用户, 充电合同模型与放电合同模型类似, 不同处仅在于合同的约定价格, ES 充电合同模型的目标函数为

$$\max \sum_{t \in T} (Q_t^{\text{ES}} - \rho_t CL_t^{\text{ES}}), \quad (28)$$

其中:  $Q_t^{\text{ES}}$  为  $t$  时刻 LA 从储能用户处获得的总收益,  $CL_t^{\text{ES}}$  为 ES 在  $t$  时刻的总充电量, 储能充电合同约束与放电合同类似.

上述式(1)–(28)将需求响应资源调度模型公式化为混合整数线性规划(MILP)问题, 对该问题优化求解能确定需求响应资源的最佳参与时间, 得到每个时刻的负荷削减量  $L_t^{\text{LC}}$ 、负荷转移量  $L_t^{\text{LS}}$  和储能系统充放电功率  $ES_t$ .

## 3 基于深度置信网络的负荷预测模型

### 3.1 深度置信网络原理

本文采用的基于 DBN 的预测模型由多个堆叠的 RBM 和单层反向传播(back propagation, BP)网络组成, 如图 2 所示. 其中,  $w_n$  为第  $n$  层和第  $n+1$  层神经元之间的连接权重,  $a$  为输入层神经元的偏置向量,  $b_n$  为第  $n$  层隐藏层神经元的偏置向量.

DBN 网络的训练过程包括预训练与反向微调两部分, 目的是确定连接权重与神经元偏置.

RBM 作为 DBN 的基本组成单元, 每个 RBM 由一个可见层和隐藏层组成, 可见层输出作为隐藏层输入.

用 $v = (v_1 \ v_2 \ \cdots \ v_{n_v})^T$ 和 $h = (h_1 \ h_2 \ \cdots \ h_{n_h})^T$ 表示可见层和隐藏层状态向量, 神经元未激活、激活两种状态, 用0和1表示, 用 $a = (a_1 \ a_2 \ \cdots \ a_{n_v})^T$ 和 $b = (b_1 \ b_2 \ \cdots \ b_{n_h})^T$ 表示可见层和隐藏层的偏置向量;  $W = (w_{ij}) \in \mathbb{R}^{n_v \times n_h}$ 为可见层和隐藏层之间的权值矩阵, 其中 $w_{ij}$ 为可见层中第*i*个神经单元与隐藏层中第*j*个神经单元之间的连接权重值;  $n_v$ 和 $n_h$ 分别为可见层与隐藏层中的神经单元的数目. 并记 $\theta = (W, a, b)$ 为RBM的参数.

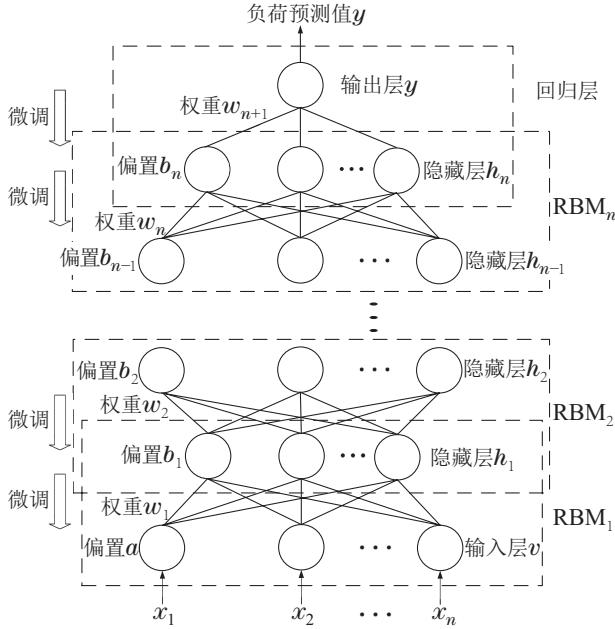


图2 DBN预测模型  
Fig. 2 DBN prediction model

RBM是一种基于能量的概率模型, 对于给定的状态 $(v, h)$ , 可定义如下的能量函数<sup>[21]</sup>:

$$E_\theta(v, h) = -\sum_{i=1}^{n_v} \sum_{j=1}^{n_h} v_i h_j w_{ij} - \sum_{i=1}^{n_v} a_i v_i - \sum_{j=1}^{n_h} b_j h_j. \quad (29)$$

利用上面的能量函数, 得出状态的联合概率分布

$$P_\theta(v, h) = \frac{1}{Z_\theta} e^{-E_\theta(v, h)}, \quad (30)$$

其中 $Z_\theta = \sum_{v, h} e^{-E_\theta(v, h)}$ 为归一化因子.

根据式(30)可以得出可见层和隐藏层的概率分布 $P_\theta(v)$ 与 $P_\theta(h)$

$$P_\theta(v) = \frac{1}{Z_\theta} \sum_h e^{-E_\theta(v, h)}, \quad (31)$$

$$P_\theta(h) = \frac{1}{Z_\theta} \sum_v e^{-E_\theta(v, h)}. \quad (32)$$

由于RBM的结构特点, 当给定可见层所有神经元的状态 $v$ 时, 隐藏层第*j*个单元状态为1的概率为

$$P(h_j = 1 | v) = \text{sigm}(b_j + \sum_{i=1}^{n_v} w_{ij} v_i), \quad (33)$$

式中 $\text{sigm}(x) = 1/(1 + e^{-x})$ 为激励函数.

同理, 当给定隐藏层所有神经元的状态 $h$ 时, 可见层第*i*个单元状态为1的概率为

$$P(v_i = 1 | h) = \text{sigm}(a_i + \sum_{j=1}^{n_h} w_{ij} h_j). \quad (34)$$

对RBM训练的目的是确定参数 $\theta = (W, a, b)$ 的值, 该参数可以通过求对应的极大对数似然函数获得.

假定训练的样本集合为:  $S = \{v^1, v^2, \dots, v^{n_s}\}$ , 其中 $n_s$ 为训练样本数目,  $v^m = (v_1^m, v_2^m, \dots, v_{n_v}^m)$ ,  $m = 1, 2, \dots, n_s$ , 则

$$\ln L(\theta) = \sum_{m=1}^{n_s} (\ln \sum_h e^{-E(v_m, h)} - \ln \sum_{v, h} e^{-E(v, h)}). \quad (35)$$

可得对数似然函数关于 $\theta$ 的梯度为

$$\begin{aligned} \frac{\partial \ln L(\theta)}{\partial \theta} = & \sum_{m=1}^{n_s} \left( \left\langle -\frac{\partial E(v_m, h)}{\partial \theta} \right\rangle_{P(h|v_m)} + \right. \\ & \left. \left\langle \frac{\partial E(v, h)}{\partial \theta} \right\rangle_{P(v, h)} \right), \end{aligned} \quad (36)$$

其中 $\langle \cdot \rangle_p$ 表示关于分布 $p$ 的期望值. 为了计算上述的偏导数, 通常运用采样方法近似计算.

Hinton提出的对比散度 (contrastive divergence, CD) 算法是RBM的一种快速学习算法<sup>[22]</sup>. CD算法首先根据训练样本确定可见层神经元的状态, 然后根据式(33)–(34)计算得到重构后可见层和隐藏层神经元的状态. 从而, 各参数变化量的计算公式为

$$\begin{cases} \Delta w_{ij} = \varepsilon (\langle v_i h_j \rangle_D - \langle v_i h_j \rangle_{\text{Recon}}), \\ \Delta a_i = \varepsilon (\langle v_i \rangle_D - \langle v_i \rangle_{\text{Recon}}), \\ \Delta b_j = \varepsilon (\langle h_j \rangle_D - \langle h_j \rangle_{\text{Recon}}), \end{cases} \quad (37)$$

式中:  $\varepsilon$ 为学习率,  $D$ 为原始数据定义的分布, Recon为重构后定义的分布.

以训练样本 $v_0$ 和经过一次Gibbs采样得到的 $v_1$ 的差异量error作为RBM训练的评估指标.

$$\text{error} = \|v_1 - v_0\|. \quad (38)$$

最后, 从网络顶层的BP神经网络<sup>[23]</sup>出发, 利用反向传播算法微调网络参数, 得到最优的训练结果.

### 3.2 考虑广义需求侧资源的负荷预测模型

在传统的负荷预测模型中, 负荷影响因素只包含温度、湿度、日类型、天气情况和历史负荷等. 由于电力负荷具有延续性和相似性, 以预测d日t时刻负荷为例, 本文中传统负荷预测模型输入量如表1所示. 表1中, 上标d和下标t分别表示日期和时刻点,  $L_{t-1}^{d-1}$ 即为预测日前一天前一时刻负荷值;  $T_{\max}^d$ ,  $T_{\text{ave}}^d$ 和 $T_{\min}^d$ 分别为d日的最高温度、平均温度和最低温度,  $T_t^d$ 和 $H_t^d$ 分别为d日t时刻的温度和湿度,  $g^d$ 为d日的天气状况;  $w^d$ 为d日的日类型.

在本文所提负荷预测模型中, 对于光伏和风机这

两种分布式电源, 其出力的主要影响因素分别为光照强度和风速。为提高负荷预测精度, 将电价和影响光伏、风机出力的光照强度、风速以及根据式(1)–(28)求解得到训练集和测试集中每天各时刻负荷削减量、负荷转移量和储能充放电功率的最优调度方案作为预测模型的新增输入量。其中,  $d$ 日 $t$ 时刻的负荷削减量、负荷转移量和储能充放电功率分别为 $L_t^{\text{LC},d}$ ,  $L_t^{\text{LS},d}$ 和 $\text{ES}_t^d$ ,  $d$ 日 $t$ 时刻的光照强度、风速和实时电价分别为 $I_t^d$ ,  $W_t^d$ 和 $P_t^d$ , 如表2所示。

表1 传统负荷预测模型输入量

Table 1 Input of traditional load forecasting model

历史负荷	天气和日类型
$L_{t-1}^{d-1}, L_t^{d-1}, L_{t+1}^{d-1}, L_{t-1}^{d-2}, L_t^{d-2}, L_{t+1}^{d-2}$	$T_{\max}^d, T_{\text{ave}}^d, T_{\min}^d$
$L_{t-1}^{d-7}, L_t^{d-7}, L_{t+1}^{d-7}$	$T_t^d, H_t^d, g^d, w^d$

表2 考虑广义需求侧资源的负荷预测模型输入量  
Table 2 Input of load forecasting model considering generalized demand-side resources

历史负荷	天气和日类型	广义需求侧资源
$L_{t-1}^{d-1}, L_t^{d-1}, L_{t+1}^{d-1}$	$T_{\max}^d, T_{\text{ave}}^d$	$I_t^d, W_t^d, P_t^d$
$L_{t-1}^{d-2}, L_t^{d-2}, L_{t+1}^{d-2}$	$T_{\min}^d, T_t^d$	$L_t^{\text{LC},d}, L_t^{\text{LS},d}$
$L_{t-1}^{d-7}, L_t^{d-7}, L_{t+1}^{d-7}$	$H_t^d, g^d, w^d$	$\text{ES}_t^d$

为证明广义需求侧资源对负荷预测精度的影响, 本文分别以表1和表2两种影响因素构成DBN负荷预测模型的输入量, 对考虑广义需求侧资源前后的预测模型进行对比。

#### 4 算例分析

本算例选取澳大利亚某地区2018年7月到8月的实际负荷数据、实时电价数据<sup>[24]</sup>和天气数据进行仿真分

析。其中, 天气数据源自气象网站, 包括温度、湿度、天气状况、光照强度和风速。由于本文旨在对用电负荷的总量进行预测, 故暂未考虑系统拓扑和负荷分布。

#### 4.1 基于合同的广义需求侧资源调度模型求解

根据该地区各季节典型日负荷曲线<sup>[24]</sup>, 如图3所示, 提出了3种广义需求侧资源的合同方案, 合同的具体内容如表3–5所示。其中, 由于不同季节负荷峰谷时段存在差异, 并考虑到合同的适应范围, 故设置了3种不同的负荷转移时段, 旨在将用电高峰时段的负荷转移至其它时段。在实际调度优化中, 具体的负荷转移时段取决于当天整体的负荷情况。根据表3–5中3种合同方案下每种合同的约定, 可削减负荷、可转移负荷和储能某一时段的最大调度量分别为300 MW, 200 MW, 300 MW, 3种资源合计约占平均总负荷的8.9%。

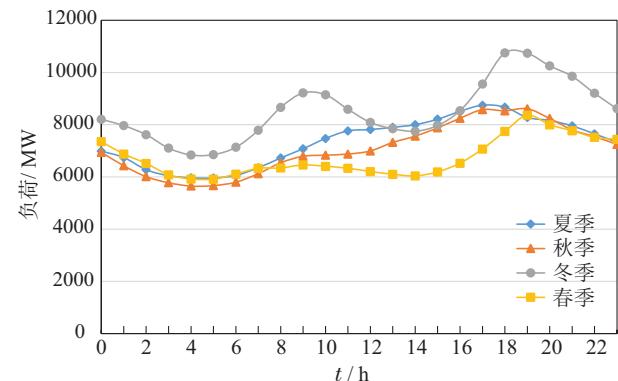


图3 各季节典型日负荷曲线

Fig. 3 Typical daily load curves of each season

对于第2节的MILP问题, 本文采用Yalmip优化工具箱求解, 若规定负荷减少为正, 负荷增加为负, 则该地区7月1日实时电价下基于合同的广义需求侧资源最优调度方案如图4–6所示。

表3 LC合同内容  
Table 3 LC contract contents

合同	削减量/MW	约定价格/(\$·(MW) <sup>-1</sup> )	启动费用/\$	最短持续时间/h	最长持续时间/h	每日合同最大执行次数
1	100	80	200	3	6	2
2	100	90	200	3	6	2
3	100	100	200	3	6	2

表4 LS合同内容  
Table 4 LS contract contents

合同	转移量/MW	约定价格/(\$·(MW) <sup>-1</sup> )	启动费用/\$	最短持续时间/h	最长持续时间/h	每日合同最大执行次数	负荷减少时间/h	负荷增加时间/h
1	100	80	200	3	6	2	10~16	4~10
2	100	90	200	3	6	2	14~20	8~14
3	100	100	200	3	6	2	16~22	10~16

表 5 ES合同内容

Table 5 ES contract contents

合同	额定功率/MW	放电约定价格/(\$·(MW) <sup>-1</sup> )	充电约定价格/(\$·(MW) <sup>-1</sup> )	储能容量/MWh	连续充放电时间/h	每日合同最大执行次数	充放电效率
1	100	80	50	600	6	2	0.9
2	100	90	55	600	6	2	0.9
3	100	100	60	600	6	2	0.9

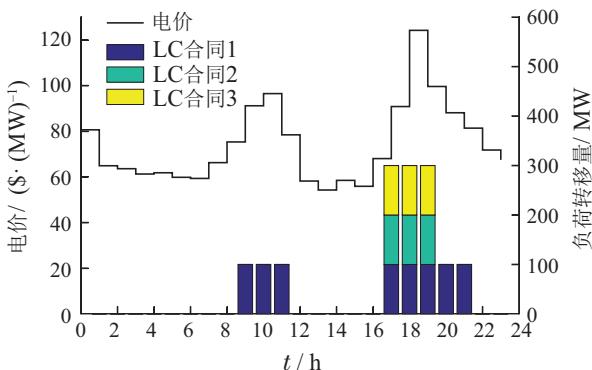


图 4 LC 最优调度方案

Fig. 4 LC optimal scheduling scheme

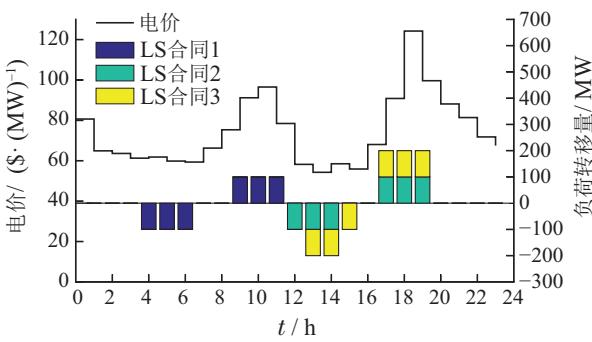


图 5 LS 最优调度方案

Fig. 5 LS optimal scheduling scheme

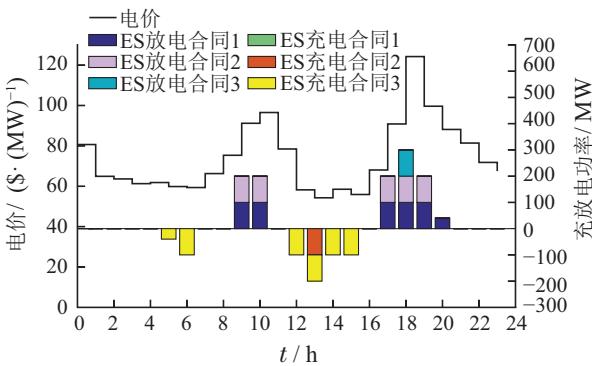


图 6 ES 最优调度方案

Fig. 6 ES optimal scheduling scheme

如图4所示,由于合同执行最小持续时间(3 h)的限制,第1个LC合同安排在9~11和17~21小时执行,第2和第3个LC合同安排在17~19小时执行.在图5中,由于负荷转移时段限制,第1个LS合同仅在9~11小时执

行且将减少的用电量转移到4~6小时;第2和第3个LS合同在17~19小时执行,减少的用电量分别转移到12~14和13~15小时.图6给出了储能系统的最优调度方案,由于充放电效率和储能容量的限制,一天内储能充放电总功率限制为540 MW.

#### 4.2 负荷预测算例

为验证本文所提负荷预测方法的有效性,需对负荷数据进行仿真模拟.第4.1节求得的负荷削减量、负荷转移量和储能充放电功率为需求响应计划量,而实际响应量随时间变化存在着内在不稳定性,响应力度受外部因素(如时间点、气象条件、电价等)变化的影响.某一时刻用户实际响应负荷DRL<sub>true</sub>(t)是由本时刻计划响应负荷的实际响应量DRL(t),叠加其他各时刻计划响应负荷受影响后分摊到本时刻的响应量,而不同时刻的各外部影响因素的大小以及对负荷影响机制是变化的<sup>[6]</sup>.因此,本文构建线性时变模型如下:

$$\begin{aligned} DRL_{true}(t) = & \\ & a_0(\omega(t))DRL(t) + \\ & a_1(\omega(t-1))DRL(t-1) + \cdots + \\ & a_p(\omega(t-p))DRL(t-p) + \cdots + \\ & a_{n-1}(\omega(t-n+1))DRL(t-n+1) + r(t), \quad (39) \end{aligned}$$

其中:  $r(t)$ 为零均值独立同分布随机误差部分负荷;  $a_p(\omega(t-p))DRL(t-p)$ 为  $t-p$  时刻计划响应负荷对  $t$  时刻实际响应负荷产生的影响;  $a_p(\omega(t-p))$  为该部分负荷占  $t-p$  时刻计划响应负荷的百分比,  $p=0, 1, \dots, n-1$ ,  $n$  为对  $t$  时刻实际响应负荷产生影响的连续时刻数,  $a_p(\omega(t-p))$  的计算公式如下:

$$\begin{aligned} a_p(\omega(t-p)) = & \\ & a_{p,0} + a_{p,1}\partial_1(\omega(t-p)) + a_{p,2}\partial_2(\omega(t-p)) + \\ & a_{p,q}\partial_q(\omega(t-p)) + \cdots + a_{p,m}\partial_m(\omega(t-p)), \quad (40) \end{aligned}$$

其中:  $\omega(t-p)$  为  $t-p$  时刻对用户响应产生影响的外部影响因素向量;  $\partial_q(\omega(t-p))$  表示  $t-p$  时刻各外部影响因素以第  $q$  种机制影响  $t-p$  时刻的实际响应负荷;  $a_{p,q}$  为  $t-p$  时刻第  $q$  种影响机制的权重,  $q=0, 1, \dots, m$ ;  $m$  为各外部影响因素对响应负荷的影响机制数量.

根据参考文献[6]中的数据,本文选取模型参数  $n = 3, m = 1, a_{0,0} = 0.6, a_{0,1} = 0.01, a_{1,0} = 0.2, a_{1,1} = 0.01, a_{2,0} = 0.05, a_{2,1} = 0.01$ , 外部因素的影响机制  $\partial_1(\omega(t))$  为

$$\partial_1(\omega(t)) = \begin{cases} 0.5t, & t \in [0, 11], \\ 0.5(t - 12), & t \in [12, 23]. \end{cases} \quad (41)$$

将该地区7月和8月的实际负荷数据作为无广义需求侧资源的原始实际总用电负荷,在此基础上,叠加可削减负荷、可转移负荷和储能3种广义需求侧资源的最优调度计划量,作为待预测的综合负荷,如图7所示。图中所示为连续7天的原始负荷和仿真的综合负荷曲线,可以看出进行需求响应后,综合负荷曲线峰谷差较小。

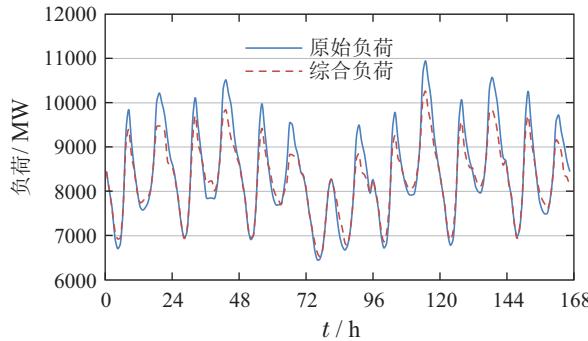


图7 仿真前后负荷曲线

Fig. 7 The curves of load before and after simulation

#### 4.2.1 模型参数设置

负荷预测的时间和精度与DBN预测模型的网络参数设定有很大的关系。参照文献[21, 25], DBN负荷预

测模型的一些参数设置如表6所示。

表6 DBN负荷预测模型参数

Table 6 Parameters of DBN load forecasting model

参数	数值	参数	数值
RBM学习率	0.1	微调BP学习率	0.01
预训练批次大小	24	微调最大迭代次数	5000
预训练最大迭代次数	100	微调误差限	0.0001

隐藏层层数和每层隐藏层神经元个数对DBN预测模型的预测结果影响较大。一般情况下,网络的层数越多,对数据的拟合精度也就越高,然而随着网络层数的增多,网络训练的耗时也会增大,还有可能出现累计误差,影响预测精度等问题。为获得最佳的预测模型,本文采用实验测试的方法,确定隐藏层层数和每层隐藏层神经元个数。

以表1的影响因素作为网络的输入量,隐藏层数量依次设置为1, 2, 3, 每层隐藏层神经元个数依次设置为5, 10, 15, 20, 25, 30, 则不同网络参数下DBN预测模型的预测精度和耗时如表7所示。从表中可以看出,当第1层隐藏层神经元个数为15时,预测误差最小,平均绝对百分比误差(mean absolute percentage, MAPE)和均方根误差(root mean squared error, RMSE)分别为2.4485%和248.39 MW,故第1层隐藏层神经元个数固定为15。此时,当第2层隐藏层神经元个数为10时,MAPE和RMSE取得最小值2.3830%和237.92 MW,均低于有3层隐藏层时的预测误差,并且模型的预测耗时也适中。因此,本文的DBN预测模型设定为4层,其中两层隐藏层的神经元个数分别为15和10。

表7 不同网络结构时DBN模型的预测性能

Table 7 Forecasting performance of DBN model under different network structures

隐藏层层数	神经元个数	MAPE/%	RMSE/MW	耗时/s	神经元个数	MAPE/%	RMSE/MW	耗时/s
1	5	2.4652	251.11	38.16	20	2.4896	254.56	52.73
	10	2.4580	250.08	43.15	25	2.5150	258.72	50.45
	15	2.4485	248.39	47.73	30	2.6183	274.57	54.25
2	5	2.4202	244.59	61.30	20	2.3848	238.84	69.03
	10	2.3830	237.92	63.15	25	2.4202	244.59	74.68
	15	2.3888	237.94	66.60	30	2.4552	247.49	77.53
3	5	2.6361	275.25	90.61	20	2.4621	249.75	102.14
	10	2.5056	251.94	93.76	25	2.5192	258.70	103.53
	15	2.4826	254.38	96.42	30	2.6756	276.12	110.40

#### 4.2.2 实验结果分析

为验证所提预测方法的有效性,分别用基于BP神经网络和基于DBN的预测模型对考虑广义需求侧资源前后的预测结果进行对比分析。以2018年7月1日至

7月31日数据作为训练数据集,分别应用4种预测模型对8月1日至8月7日数据进行预测,比较4种模型的预测性能,表8给出了每日4种预测模型的MAPE值RMSE值。对于DBN预测模型,当输入不考虑广义需求侧资

源时, 预测误差较大, MAPE和RMSE分别为2.4839%和247.30 MW, 而考虑广义需求侧资源影响因素后, 提高了预测精度, MAPE和RMSE分别降低了0.3745%和28.61 MW, 为2.1094%和218.69 MW. 对于BP预测模型, 在考虑广义需求侧资源后, 模型预测的MAPE和RMSE较未考虑广义需求侧资源的预测模型分别降低了0.4143%和47.26 MW.

图8为8月3日实际负荷和4种模型的负荷预测曲线对比图, 从图中可以看出, 考虑广义需求侧资源的DBN模型预测曲线整体上更接近于实际负荷曲线, 在曲线的峰谷处更为明显, 预测精度最为理想.

表 8 4种模型的预测误差  
Table 8 Forecasting errors of four models

日期	未考虑广义需求侧资源BP		考虑广义需求侧资源BP		未考虑广义需求侧资源DBN		考虑广义需求侧资源DBN	
	MAPE/%	RMSE/MW	MAPE/%	RMSE/MW	MAPE/%	RMSE/MW	MAPE/%	RMSE/MW
8月1日	4.7586	525.39	4.2442	396.57	2.2226	211.84	2.0224	195.47
8月2日	4.9007	450.58	4.4285	428.29	2.4174	239.63	2.0496	205.92
8月3日	4.7658	505.67	4.1710	438.03	2.3125	228.33	1.9206	178.00
8月4日	5.1764	504.13	4.9442	425.20	2.8252	246.74	2.3081	210.43
8月5日	5.4949	574.28	5.2205	573.19	2.8569	316.04	2.4022	295.72
8月6日	4.2506	409.24	3.7500	385.38	1.9822	203.48	1.5915	177.27
8月7日	4.4587	444.95	4.1472	436.77	2.7709	285.01	2.4709	268.03
平均值	4.8294	487.75	4.4151	440.49	2.4839	247.30	2.1094	218.69

## 5 结论

大量广义需求侧资源参与电力市场对短期负荷预测精度有了更高的要求, 同时, 智能电网调度系统产生的海量数据集, 为深度学习的使用提供了数据基础. 为此, 本文首先通过负荷聚合商将广义需求侧资源引入市场交易, 构建基于合同的广义需求侧资源调度模型以获取其最优调度方案. 基于此, 将广义需求侧资源的最优调度计划作为负荷预测模型的输入量, 构建了考虑广义需求侧资源的DBN短期负荷预测模型, 并与基于BP神经网络的预测模型和未考虑广义需求侧资源的DBN预测模型得到的结果进行对比. 实际算例结果表明, 以LA收益最大为目标, 建立的基于电价合同的需求响应资源调度模型可以有效的响应市场实时电价, 确定LC, LS和ES的最佳参与时间; 并且在预测模型中考虑广义需求侧资源最优调度计划的影响有利于提高模型的预测精度, 降低预测误差.

## 参考文献:

- [1] KANG Chongqing, XIA Qing, LIU Mei. *Power System Load Forecasting*. 2nd Edition. Beijing: China Electric Power Press, 2017.  
(康重庆, 夏清, 刘梅. 电力系统负荷预测. 第2版. 北京: 中国电力出版社, 2017.)
- [2] WANG Ke, YAO Jianguo, YAO Liangzhong, et al. Overview of research on flexible load scheduling of electric power. *Automation of*

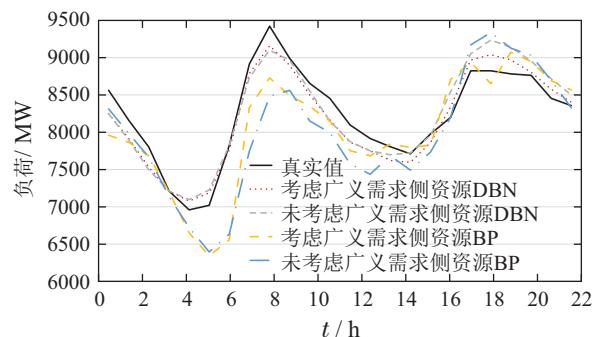


图 8 负荷预测曲线对比  
Fig. 8 The comparison of load forecasting curves

*Electric Power Systems*, 2014, 38(20): 127 – 135.  
(王珂, 姚建国, 姚良忠, 等. 电力柔性负荷调度研究综述. 电力系统自动化, 2014, 38(20): 127 – 135.)

- [3] ZENG Bo, YANG Yongqi, DUAN Jinhui, et al. Key issues of demand-side response in new energy power system and future research prospects. *Automation of Electric Power Systems*, 2015, 39(17): 10 – 18.  
(曾博, 杨雍琦, 段金辉, 等. 新能源电力系统中需求侧响应关键问题及未来研究展望. 电力系统自动化, 2015, 39(17): 10 – 18.)
- [4] CHENG Shijie. Application prospect analysis of large-scale energy storage technology in power system. *Automation of Electric Power Systems*, 2013, 37(1): 3 – 8.  
(程时杰. 大规模储能技术在电力系统中的应用前景分析. 电力系统自动化, 2013, 37(1): 3 – 8.)
- [5] XING Long, ZHANG Peichao, FANG Chen, et al. Optimal operation for microgrid using generalized demand side resources. *Automation of Electric Power Systems*, 2013, 37(12): 7 – 12, 133.  
(邢龙, 张沛超, 方陈, 等. 基于广义需求侧资源的微网运行优化. 电力系统自动化, 2013, 37(12): 7 – 12, 133.)
- [6] SU Xiaolin, LIU Xiaojie, YAN Xiaoxia, et al. Short-term load prediction of active distribution network taking demand response into account. *Automation of Electric Power Systems*, 2018, 42(10): 60 – 66, 134.  
(苏小林, 刘孝杰, 阎晓霞, 等. 计及需求响应的主动配电网短期负荷预测. 电力系统自动化, 2018, 42(10): 60 – 66, 134.)
- [7] TANG Qingfeng, LIU Nian, ZHANG Jianhua. Theory and key problems for automated demand response of user side considering generalized demand side resources. *Power System Protection and Control*, 2014, 42(24): 138 – 147.

- (汤庆峰, 刘念, 张建华. 计及广义需求侧资源的用户侧自动响应机理与关键问题. 电力系统保护与控制, 2014, 42(24): 138 – 147.)
- [8] HE Yaoyao, LIU Rui, QIAN Aoyang. A short-term power load probability density prediction method based on real-time electricity price and support vector quantile regression. *Chinese Journal of Electrical Engineering*, 2017, 37(3): 768 – 775.  
(何耀耀, 刘瑞, 撒奥洋. 基于实时电价与支持向量分位数回归的短期电力负荷概率密度预测方法. 中国电机工程学报, 2017, 37(3): 768 – 775.)
- [9] ZHANG Zhisheng, YU Daolin. RBF-NN short-term load forecasting model considering comprehensive influencing factors of demand response. *Chinese Journal of Electrical Engineering*, 2018, 38(6): 1631 – 1638, 1899.  
(张智晟, 于道林. 考虑需求响应综合影响因素的RBF-NN短期负荷预测模型. 中国电机工程学报, 2018, 38(6): 1631 – 1638, 1899.)
- [10] GARULLI A, PAOLETTI S, VICINO A. Models and techniques for electric load forecasting in the presence of demand response. *IEEE Transactions on Control Systems Technology*, 2015, 23(3): 1087 – 1097.
- [11] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets. *Neural Computation*, 2006, 18(7): 1527 – 1554.
- [12] FIDCHER A, IGEL C. An introduction to restricted boltzmann machines. *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*. Berlin Heidelberg: Springer, 2012.
- [13] LIU P, HAN S, MENG Z, et al. Facial expression recognition via a boosted deep belief network. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Columbus, OH: IEEE, 2014: 1805 – 1812.
- [14] CHAO J, SHEN F, ZHAO J. Forecasting exchange rate with deep belief networks. *The 2011 International Joint Conference on Neural Networks*. San Jose, CA: IEEE, 2011: 1259 – 1266.
- [15] ZHANG Xinbo, TANG Ju, PAN Cheng, et al. Deep confidence network method for partial discharge pattern recognition. *Power System Technology*, 2016, 40(10): 3272 – 3278.  
(张新伯, 唐炬, 潘成, 等. 用于局部放电模式识别的深度置信网络方法. 电网技术, 2016, 40(10): 3272 – 3278.)
- [16] KUREMOTO T, KIMURA S, KOBAYASHI K, et al. Time series forecasting using a deep belief network with restricted boltzmann machines. *Neurocomputing*, 2014, 137(15): 47 – 56.
- [17] DEDINEC A, FILIPOSKA S, DEDINEC A, et al. Deep belief network based electricity load forecasting: An analysis of macedonian case. *Energy*, 2016, 115: 1688 – 1700.
- [18] SHI Jiaqi, TAN Tao, GUO Jing, et al. Multi-task learning based on deep architecture for various types of load forecasting in regional energy system integration. *Power System Technology*, 2018, 42(3): 698 – 707.  
(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. 电网技术, 2018, 42(3): 698 – 707.)
- [19] GAO Ciwei, LI Qianyu, LI Huixing, et al. Demand response resource integration method and operation mechanism based on load aggregator business. *Automation of Electric Power Systems*, 2013, 37(17): 78 – 86.  
(高赐威, 李倩玉, 李慧星, 等. 基于负荷聚合商业务的需求响应资源整合方法与运营机制. 电力系统自动化, 2013, 37(17): 78 – 86.)
- [20] PARVANIA M, FOTUHI-FIRUZABAD M, SHAHIDEHPOUR M. Optimal demand response aggregation in wholesale electricity markets. *IEEE Transactions on Smart Grid*, 2013, 4(4): 1957 – 1965.
- [21] HINTON G E. A practical guide to training restricted boltzmann machines. *Momentum*, 2012, 9(1): 599 – 619.
- [22] HINTON G E. Training products of experts by minimizing contrastive divergence. *Neural Computation*, 2002, 14(8): 1771 – 1800.
- [23] HAYKIN S S. *Neural Networks: A Comprehensive Foundation*. Beijing: Tsinghua University Press, 2001.
- [24] Australian energy market operator. Aggregated price and demand data[R/OL]. <http://www.aemo.com.au>.
- [25] HITON G, DENG L, YU D, et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *Signal Processing Magazine IEEE*, 2012, 29(6): 82 – 97.

### 作者简介:

胡 实 硕士研究生, 目前研究方向为电力系统负荷预测、深度学习, E-mail: hushi@mail.hfut.edu.cn;

唐 昊 博士, 教授, 目前研究方向为离散事件动态系统、强化学习、深度强化学习等, E-mail: htang@hfut.edu.cn;

吕 凯 博士研究生, 目前研究方向为学习优化技术及其在智能电网中的应用, E-mail: kail@mail.hfut.edu.cn;

杨晨芳 硕士研究生, 目前研究方向为电力系统负荷预测、调度优化, E-mail: yangchenfang@mail.hfut.edu.cn.