

基于深度神经网络实现电力削峰填谷的需求响应模型研究

王永彬, 贾 凤, 朱国梁

(1. 山东汇智电力科技有限公司, 山东 济南 250000; 2. 国网山东省电力公司物资公司, 山东 济南 250000;
3. 国网山东综合能源服务有限公司, 山东 济南 250000)

摘要: 随着环境问题日益突出和“双碳”目标的推进, 需求侧响应资源参与负荷调峰和填谷对电力行业发展具有重要意义。针对我国需求侧响应快速发展的情况, 首先考虑了发电机 (PG)、电网公司和服务厂商 (SPs) 之间的相互作用; 然后利用深度神经网络 (DNNs) 收集数据, 并通过开发精确的需求价格弹性矩阵 (PEMD) 来模拟客户行为; 最后基于该模型预测了未来每小时短期负荷预测以及前一天每小时的电力需求。结果表明, 此模型可以减小电网负荷峰谷差, 使发电、用电趋于平衡。

关键词: 深度神经网络; 需求响应系统; 需求价格弹性矩阵

Research on deep neural network-based demand response model for power peak shaving and valley filling

WANG Yongbin, JIA Feng, ZHU Guoliang

(1. Shandong Huizhi Electric Power Technology Co., Ltd., Jinan 250000, China; 2. State Grid Shandong Electric Power Company Materials Company, Jinan 250000, China; 3. State Grid Shandong Comprehensive Energy Service Co., Ltd., Jinan 250000, China)

Abstract: As environmental issues become more prominent and the “double carbon” goal is promoted, the participation of demand-side response resources in load peaking and valley filling is of great importance to the development of the power industry. Based on the rapid development of demand-side response in China, this paper first considers the interactions between generators (PG), Power grid companies and service providers (SPs), then collects data using deep neural networks (DNNs) and simulates customer behavior by developing an accurate price elasticity of demand matrix (PEMD). Finally, based on this model, future hourly short-term load forecasts and hourly electricity demand for the previous day are predicted. The results show that the model can reduce the peak-to-valley load differential on the grid and bring the generation and consumption of electricity into balance.

Key words: deep neural networks; demand response systems; demand price elasticity matrix

0 引言

电力系统是复杂的系统, 电力的供需平衡是电力系统稳定运行的基础。在一些特定的时间段内, 由于负荷的突然增加或电力的供应不足, 电

力系统容易发生电力削峰填谷现象^[1-2], 导致电力系统的供需失衡, 从而影响电力系统的稳定性和可靠性。

在需求响应 (DR) 系统中^[3-4], 电力分销商

和电网公司通过提供激励措施或实施动态定价方法影响消费者改变、减少和重新安排能源消耗和电器使用。

近年来,随着深度学习技术的发展^[5],基于神经网络的需求响应模型逐渐受到了广泛关注。通过对历史用电数据的分析,利用神经网络建立了一个经过优化的需求响应模型,实现高效、准确的电力削峰填谷调度,提高电力系统的运行效率和可靠性,用于精确的日前每小时短期负荷预测(STLF)。

本文介绍基于深度神经网络实现电力削峰填谷的需求响应模型。首先,简要介绍我国电力行业的现状;然后,详细介绍基于深度神经网络的电力削峰填谷需求响应模型的设计和实现;最后,进行实验验证和性能分析。本文的研究成果对于推动电力系统的智能化和可持续发展具有重要的意义^[6]。

1 我国电力行业现状

需求响应是指电力系统根据市场需求和供需平衡情况,通过调整电力生产、输送和消费等环节,实现对电力需求的灵活调度和管理。

中国政府大力推动新能源发展,包括太阳能、风能和水能等。这些新能源具有波动性和不确定性,对电力系统的需求响应能力提出了更高的要求,需要通过技术手段(如储能、智能电网等)实现新能源的有效融入和调度。为了应对电力需求的快速变化和新能源的不稳定性,中国电力行业正在努力提升电力系统的灵活性。包括建设灵活的电力调度和管理系统,提升电力市场化程度,推广智能电网和储能技术等,实现对电力需求的及时响应。

中国政府正在加大能源消费结构的优化力度,推动能源消费从传统的高碳能源向低碳能源转变。这对电力系统提出了新的需求响应要求,包括促进清洁能源的生产和消费,提升能源利用效率,以及推动能源供需侧管理的协调发展。

用户参与电力需求响应是实现灵活调度的重要手段。中国电力行业正在推动用户参与电力市

场化交易,鼓励用户在高峰时段降低用电负荷或通过自发自用的方式参与能源管理,实现对电力需求的灵活响应。

总的来说,中国电力行业在需求响应方面面临诸多挑战和机遇,包括电力需求快速增长、新能源发展、电力系统灵活性提升、能源消费结构优化和用户参与增强等方面。

2 构建模型

2.1 需求响应(DR)系统的优化模型

基于激励的每小时DR系统对消费者来说是很难实现的,因为没有足够的时间提前重新安排他们的需求。因此,提前一天的DR模型更适合住宅用户,因为足够的时间来调整对其电费影响最大的负荷,并且可以提高能源使用效率,例如优化供暖和制冷负荷。本研究提出的DR模型如图1所示。




图1 提出的我国日前需求响应模型

Fig. 1 Proposes a response model for China's current demand

电力需求、发电可用性、发电成本和可再生能源的预期发电量等精确的信息对于DR系统的实施至关重要。优化电网的目标是:降低能源生产成本,增加非高峰时期的需求,以最大化其净利润。

DR系统从高峰到非高峰影响消费者的行为,允许电网在高预期需求的情况下具有更高的灵活性。

利用电力供需关系预测不同电价对居民用户的影响,确定最优电价,通过在高峰负荷时提高电价,在非高峰负荷时降低电价,实现高峰需求减少和非高峰填充的目标。

在本研究中,假设发电计划由电网公司通过单位承诺分析给出,其中可再生能源工厂也提供

可再生能源发电预测。电网公司的逐利最大化模型表示为

$$\max \sum_{d=1}^D \sum_{h=1}^H \left(\sum_{c=1}^C I_{c,h} (sp_{c,h}, ds_{c,h}) - \sum_{ps=1}^{PS} C_{ps,h} (bp_{ps,h}, dp_{ps,h}) \right) + \sum_{c=1}^C PCI_c (dp_c, dpp_c) \quad (1)$$

$$ds_{c,h} = ds_{c,h}^0 \left[1 + \varepsilon_h \frac{sp_{c,h} - sp_{c,h}^0}{sp_{c,h}^0} + \sum_{h=1}^{24} \varepsilon'_h \frac{sp_{c,h} - sp_{c,h}^0}{sp_{c,h}^0} \right] \quad (2)$$

$$spp_{c,h,\min} \geq sp_{c,h} \geq spp_{c,h,\max} \quad (3)$$

式中, $I_{c,h}$ 为每小时 $h \in \{1, 2, \dots, 24\}$ 的收入来自此类型的消费者 $c \in \{1, 2, \dots, 5\}$,是消费者在 h 小时的大宗供应价格($sp_{c,h}$)和销售需求($ds_{c,h}$)的函数; $C_{ps,h}$ 是指在 $h \in \{1, 2, \dots, 24\}$ 从电力供应商 $ps \in \{1, 2, \dots, ps\}$ 购买电力的成本,是购买价格($bp_{ps,h}$)和购买需求($dp_{ps,h}$)的函数。根据电网公司提供的数据,在每小时 h 从每个 ps 购买需求的所有成本描述了根据哪个发电厂使用的总小时成本; PCI_c 为每个消费者 c 的峰值容量收入,是各自消费者 c 的最高需求峰值(dp_c)及需求峰值价格(dpp_c)的函数; ps 为各小时使用的总供电单元; $spp_{c,h,\max}$ 和 $spp_{c,h,\min}$ 是由电网公司确定的大宗供货价格的上下限; ε_h 和 ε'_h 分别表示需求的自弹性和交叉价格弹性,其中捕获了用户电价变化对其电力消耗的影响。这种关系是DR系统的核心,决定了电力公司设定的价格,实现电力市场的经济效益以及与电力系统运行相关的技术效益。

为了获取24 h需求的价格弹性,假设生产的重新调度不超过24 h的间隔,需求价格弹性矩阵(PEMD)的公式为

$$\begin{pmatrix} \Delta ds_{c,1} / ds_{c,1}^0 \\ \vdots \\ \Delta ds_{c,i} / ds_{c,i}^0 \\ \vdots \\ \Delta ds_{c,24} / ds_{c,24}^0 \end{pmatrix} = \begin{pmatrix} \varepsilon_{1,1} & \cdots & \varepsilon_{1,j} & \cdots & \varepsilon_{1,24} \\ \vdots & & \vdots & & \vdots \\ \varepsilon_{i,1} & \cdots & \varepsilon_{i,i} & \cdots & \varepsilon_{i,j} \\ \vdots & & \vdots & & \vdots \\ \varepsilon_{24,1} & \cdots & \varepsilon_{24,j} & \cdots & \varepsilon_{24,24} \end{pmatrix} \times \begin{pmatrix} \Delta sp_{c,1} / sp_{c,1}^0 \\ \vdots \\ \Delta sp_{c,i} / sp_{c,i}^0 \\ \vdots \\ \Delta sp_{c,24} / sp_{c,24}^0 \end{pmatrix} \quad (4)$$

PEMD涉及价格变化在所描述的一天中任何时间的影响由 i 到小时本身的需求变化以及 $\varepsilon_{i,j}$ 描述的其他小时表示自我弹性,而 $\varepsilon_{i,j}$ 代表交叉弹性。

提出的模型在以下假设下建立:


- 1) 每日环境和住宅需求数据以每小时为样本。
- 2) 每个发电厂的日前发电电价都是一个单独的值。
- 3) 按机组承诺调度的日前选定电厂每天都有。
- 4) 每小时的自弹性和交叉弹性都是已知的,并且对于电网公司来说每天都是可用的,在本研究中假设它们恒定。
- 5) 需求响应算法在新一天的00:00运行并实现,当接收到前一天的最终需求小时后,在24 h内宣布新的价格。

2.2 消费者行为建模

PEMD反映了消费者对DR计划的反应,该计划由自弹性和交叉弹性值表示,其中不同的DR政策和消费者对价格变化的反应模式影响PEMD的估计。在日前DR政策中,价格在一天前或一天开始时公布,消费者可以在一天中的每个间隔 i 重新安排需求,因此PEMD中的所有元素都可以不为零。而在一小时前DR中,消费者只能重新安排下一小时的需求,他们只有当前价格和一小时前价格的信息,因此不能提前重新安排需求。

PEMD还与不同市场的消费者如何将需求重新安排到一天中的不同时间有关,这由PEMD中的交叉弹性分布表示。图2显示了不同类型消费者的重新调度行为。

一天前需求响应的行为类别是图2a、图2b和图2e,其中最后两个是最可能的,因为消费者不可能完全重新安排需求到价格最低的小时。灵活的消费者和不灵活的消费者之间的区别在于,特定时间的需求重新安排到一天中其他时间范围,如图2中的箭头长度所示。



- (a) 优化消费者：针对价格最低的时间重新安排
 (b) 灵活消费者：在较长的时间范围内向前和向后重新安排其消费时间
 (c) 推迟消费的消费者：将消费时间从高价格的时段重新安排到之前的时段
 (d) 有预见性的消费者：将消费时间从高价位的时段重新安排到较晚的时段
 (e) 不灵活的消费者：在很短的时间范围内向前或向后重新安排消费时间

图2 DR市场中不同的消费者重新调度行为

Fig. 2 Different consumer rescheduling behaviors in the DR market

2.3 日前每小时需求估计

目前，深度神经网络（DNN）已经在不同领域得到了广泛的应用，特别是电力需求的宏观短期负荷预测（STLF），该网络用于需求预测。DNN是三层以上的神经网络，用于监督学习，其中算法训练计算机从给定数据中学习，并对未来进行预测或分类。由于它们的复杂连接和非线性激活，DNN可以模拟任何非线性函数。神经网络如图3所示。

神经元是神经网络的组成部分，其中， z_j^l 表示隐藏层 l 激活前神经元 j 的输出； w 为该神经元的权向量； b 为偏置； a_i^l 为第 i 个训练样例对神经元的输入； g^l 的选择影响训练网络的性能。本研究中，指数线性单元（ELU）是整流线性单元（ReLU）的改进变体，由于其更快的收敛速度

和性能，更好的稀疏性，并且避免了神经元死亡问题，因此用作激活函数。




图3 神经网络表示

Fig. 3 Neural network representation

训练神经网络的主要目标是更新隐藏层和输出层中的所有权值和偏差，减小神经网络的误差，其中均方误差（MSE）用于回归问题。将输入数据前向传播到网络中计算总误差，用于衡量神经网络在每次训练迭代时的性能，并将误差函数与后向传播算法一起使用梯度下降更新模型的参数，即

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta_t} J(\theta_t) \quad (5)$$

式中，误差函数 $J(\theta_t)$ 相对于网络中每个参数 θ_t 的偏导数 $\nabla_{\theta_t} J(\theta_t)$ 来更新； η 表示学习率，决定梯度下降的速度。

本研究用于预测一天前24 h需求的深度神经网络模型预测从前一天结束时开始的某一特定时刻 h 的前一天需求。该模型运行24次，以逐小时预测第二天的小时需求。90%的训练数据用于训练模型，5%的验证数据用于调优超参数并选择最佳架构，5%的测试数据作为模型泛化性能的最终测试。

实现高预测准确度对于DR模型至关重要，可以通过选择最佳的神经网络架构实现。此外，由于深度神经网络易出现过拟合，利用 l_2 正则化和Dropout技术，并结合早期停止来提高模型的

泛化性能。使用平均绝对百分比误差（MAPE）和均方根误差（RMSE）比较所有提到数据的最终模型性能。

3 结果与讨论

3.1 电力需求特征分析结果

电力需求是一个高度复杂的时间序列，是人类日常和季节性行为以及天气条件的函数，具有异质性和不确定性。用电需求的周变化由一周中不同天数的概率密度分布表示。高峰需求在周六到周三明显增加，在周五下降。每日需求也受到一天中时间的影响，其中高峰需求发生在特定日期的18:00，而最低需求发生在4:00。因此，一天中的一小时、一周中的一天、一年中的一周等时间序列特征为STLF提供了必要的信息。

最后，自相关分析表示某一小时的需求与其滞后值的相关性，表明需求的前几个小时具有最高的相关性，可作为STLF的预测特征。在（-1，-24，-168，-48）小时的滞后需求分别显示出最高的相关性，代表了本周前两天同一小时和前一周期同一天的需求。与待预测时刻需求相关的外生特征见表1。待预测时刻需求相关的内生特征见表2。

假设前三个特征是从一天前的天气预测中收集的，这些天气预测的时间是预期的早晨、晚上和一天中需要预测需求的最低高峰时间。特征2~6表示时间序列特征，指定一天中一小时、一周中的一天、一年中的一天和一年中的一周。根据自相关分析选择滞后需求特征，当涉及周末出现问题，因此，将上周的同一天及其前一天作为模型的输入。

表 1 与待预测时刻需求相关的外生特征

Tab. 1 Exogenous characteristics related to demand at the predicted time

外生输入特征	范围
1 最低负载时间温度 /℃	- 1 ~ 24
2 一天中的一小时	1 ~ 24
3 一年中的一天	1 ~ 365
4 一年中的一周	1 ~ 53
5 工作日	[0,1]
6 周末	[0,1]

表 2 与待预测时刻需求相关的内生特征

Tab. 2 Endogenous characteristics related to demand at the predicted time

内生输入特征	范围
1 -	1 195 ~ 3 380
2 滞后需求（- 25 h）	1 195 ~ 3 380
3 滞后需求（- 48 h）	1 195 ~ 3 380
4 滞后需求（- 49 h）	1 195 ~ 3 380
5 滞后需求（- 168 h）	1 195 ~ 3 380
6 滞后需求（- 169 h）	1 195 ~ 3 380
7 滞后需求（- 193 h）	1 195 ~ 3 380
8 滞后需求（- 194 h）	1 195 ~ 3 380

3.2 深度学习模型的训练与优化

基于敏感性分析选择了深度神经网络架构，其中将每小时需求数据分为90%的训练数据用于训练模型，5%的验证数据用于调整超参数并选择最佳架构，5%的测试数据与作为模型泛化性能的最终测试。然后使用相对于训练数据的平均值和标准差对数据进行归一化。通过敏感性分析选择最终模型的隐藏层（HL）配置，见表3。

表 3 最终的深度神经网络架构

Tab. 3 Final deep neural network architecture

层	HL-1	HL-2	HL-3	HL-4
神经元	1024	512	256	218
激活	ELU	ELU	ELU	ELU
失误概率	0.1	0.1	0	0
l_2 参数	0.18	0.18	0.18	0.18

该架构从大量神经元开始，然后下降到较低的数值，ELU激活函数比RELU激活函数表现出更高的性能。Dropouts应用在前两层，结合 l_2 正则化表现出更好的性能。表4显示了训练、验证和测试数据的最终性能结果。

表 4 最终性能结果

Tab. 4 Final performance results

数据	MAPE（%）	RMSE	R_2
训练	1.205	31.17	0.993 2
验证	1.365	38.69	0.989 7
测试	1.411	43.18	0.987 1

测试数据的MAPE达到1.411%，略高于验证和训练误差。因此，该模型具有良好的泛化能力

和较高的准确度。最终模型预测结果的MAPE仅高于测试数据,为2.03%,因为在训练结束时最难预测。表明了每天在获得新数据时,持续训练模型以保持高准确性和泛化的重要性。误差由于多种原因发生,导致消费者行为异常变化或影响配电层面的光伏能源生产。

3.3 住宅物业耗电量分析

在实施DR之前,需要对PEMD进行完善估计,分析价格范围对需求的影响。短期价格弹性是对自弹性(ε_h)的最佳估计,因为显示了短期内价格与需求变化之间的负相关关系。

然而,由于需求的价格响应在一天中的不同时段是不同的,所以假设两种情况:①假设 ε_h 每小时不变;②假设 ε_h 在高峰时段为两倍。每小时交叉弹性表示一天中从一个小时转移到其他小时的能量,在时间上既向后又向前。为了估计高峰负荷时段的潜在可转移能量及其时间范围,对影响DR的不同负荷及其在住宅领域的渗透率进行了详细分析。

住宅负荷根据其灵活性和DR特性可分为不同类型:恒温控制负荷(TCL)、可延迟负荷和不间断负荷。TCL与温度和环境因素高度相关,由于储热特性,其需求可以更灵活,对消费者舒适度的影响更小。可延迟负荷指的是可灵活使用的设备,可以在对消费者舒适度影响较小的情况下转移。不间断负荷是指在使用过程中需要持续能源需求的设备,并且与消费者舒适度相关,因此它们通常没有DR潜力。

TCL和可延迟负荷估计占住宅部门的82.9%,意味着住宅部门的DR潜力巨大。延迟负荷可以很容易地在高峰需求期间转移,从而导致调峰。根据前面的讨论,在如下两种与高峰时段重新分配的能量有关的情况下估计交叉弹性。

1) 一种无损情况,将某一小时减少的能量重新分配到一天中的其他时间,而不损失总能量消耗。因此,PEMD中所有交叉弹性之和等于该时刻的自弹性。

2) 75%的再分配场景,减少需求的75%重

新分配到其他时间,25%消费者不再使用。因此,PEMD中的所有交叉弹性之和等于每小时自弹性的75%。

3.4 高峰期DR政策对PEMD估计的影响

本文提出的DR政策是根据电网公司的运营和安全目标,通过改变高峰时段价格来降低高峰负荷,这对居民部门DR行为的估计有直接影响。

消费者倾向于将需求转移到高峰时段以外最近的时段。需求重新分配的时间范围(T_b 为向后时间范围和 T_f 为向前时间范围)取决于转移的设备类型。在大多数转移的设备是可延迟负荷情况下,假设转移的时间范围是最接近峰值定价的4 h,同时假设在高峰时段的最后一个小时,他们的一部分需求在24:00后转移到第二天,目前的PEMD模型没有考虑到这一点。

表5显示了本研究最终确定的PEMD结构。C1~C4代表基本自弹性,等于住宅部门的短期自弹性,而C5~C8假设高峰时期弹性是其两倍。

C1、C2、C5和C6是一种无损的PEMD,其中交叉弹性的总和等于交叉弹性的大小,而对应情形是前面提到的75%的情形。

C3、C4、C7和C8考虑了更多参与DR的AC使用情况,其中使用了二级交叉弹性(L2),权重是(L1)的两倍。

表5 PEMD 结构
Tab. 5 PEMD structure

层	自弹性	交叉弹性 L1	交叉弹性 L2
C1	-0.057 5	-0.014 3	-
C2		-0.009 58	-0.019 2
C3		0.010 8	-
C4		0.007 19	0.014 4
C5	-0.115	-0.028 8	-
C6		-0.019 2	-0.038 4
C7		0.021 6	-
C8		0.014 4	0.028 8

3.5 PEMD场景分析

日前DR模型应用于表5中讨论的所有PEMD情

况，假设供电公司时间段的最大峰值价格 $spp_{c,h,max}$ 分别设置为其初始值的200%、250%和300%。

DR计划的主要目标是减少昂贵的峰值电力供应商的能源消耗。同样值得注意的是，在300%峰值定价的最坏情况下（C6）也实现了节约，这主要是因为21:00形成的新高峰比原来的峰值宽度（时间范围）更小，下降更急剧，而在15:00形成的峰值，光伏发电是可用的。这表明将需求转移到可再生能源可用时期的重要性。C3、C4、C7和C8在两种自弹性情景下都实现了更好的节约，因为高峰时段每小时减少的需求中有25%从电网中移除。

在高峰时期减少的需求和新形成的高峰之间存在明显的权衡。C6在峰值价格为300%时，峰值增加了-1.46%。值得注意的是，在自弹性较低的情况下（C1~C4），价格上涨导致当天的高峰需求稳步下降。相反，在自弹性较高的情况下（C5~C8），由于新形成的峰值，较高的价格可能导致较低的日减峰。图4显示了每种场景下全天的峰值减少百分比。

负荷系数的计算方法是将全天的平均需求除以最大需求。图5表示了每个场景的负荷因子与原始需求之间的比较。结果表明，在低自弹性情况下设置高价格，在高自弹性情况下设置低价格，可将负荷系数提高5%左右。每种情况下的峰值减少和负荷系数的详细结果见表6和表7，基于每种情况的峰值价格的最终结果突出显示。

结果表明，在具有基础自弹性的情况下，提高价格对各指标的改善效果好，特别是在C3和C4中，由于峰时价格弹性较低，峰后和峰前没有形成新的高峰，因此峰期的能量减少了。高峰时期的价格弹性越高，高峰时期的需求转移越高，在高能源价格下形成新的高峰。无论是节省成本方面的直接利润具有更高的优先级，还是通过减少峰值和改善载客率来提高运营绩效的间接利润，价格应该基于电网公司的优先级来设定。




图 4 日高峰需求减少百分比

Fig. 4 Percentage reduction in daily peak demand




图 5 负荷系数分析

Fig. 5 Load factor analysis

表 6 C1 ~ C4 结果

Tab. 6 C1 ~ C4 results

	C1			C2			C3			C4		
峰值价格	200%	250%	300%	200%	250%	300%	200%	250%	300%	200%	250%	300%
峰值减少	2.729	4.093	5.458	2.729	4.093	4.582	2.729	4.093	5.458	2.729	4.093	5.458
负荷系数	0.780	0.791	0.802	0.780	0.791	0.795	0.779	0.789	0.799	0.779	0.789	0.799

表 7 C5 ~ C8 结果

Tab.7 C5 ~ C8 results

	C5			C6			C7			C8		
峰值价格	200%	250%	300%	200%	250%	300%	200%	250%	300%	200%	250%	300%
峰值减少	5.458	2.880	0.266	4.582	1.511	-1.45	5.458	4.841	2.880	5.458	3.814	1.511
负荷系数	0.802	0.781	0.760	0.795	0.770	0.747	0.799	0.793	0.775	0.799	0.784	0.764

4 结束语

本文旨在提出我国电力部门的综合需求响应模型，此模型具有很高的准确性和稳定性。深度神经网络具有多层结构，可以自动学习电力系统的非线性特征，提高了模型的预测准确度和稳定性。基于对住宅短期价格弹性的研究以及对不同设备和日常操作的分析，对住宅部门进行了精确的PEMD估计。

将DR模型应用于PEMD的多个场景的结果表明，提出的DR模型在电力削峰填谷方面的预测效果比传统方法要好很多。

此DR模型可以为电力系统的优化调度提供重要支撑。通过实时监测电力系统的负荷变化和价格波动，预测未来电力需求，提供相应的电力削峰填谷方案，有效平衡电力供求关系，优化电力系统的运行效率。有助于提高电力系统的经济性和可靠性，降低对环境的影响。

综上所述，实施以价格和激励为基础的可行的DR计划，以此加强对DR系统和成熟能源使用重要性的认识。该模型可以实现更智能的电网，以应对高需求和高可再生能源渗透率所面临的日益严峻的挑战，并实现环境目标。

参考文献

- [1] 潘宇航,王青松,陈力.应用于电网侧削峰填谷的储能系统配置及日出力优化策略[J].供用电,2022,39(7):9-16.
- [2] 王瑜.基于储能系统的电网削峰填谷优化策略研究[D].兰州:兰州理工大学,2022.
- [3] 于昊正,赵寒杰,李科,等.计及需求响应的分布式光伏集群承载能力评估[J].电力建设,

2023,44(2):122-131.

- [4] 李国荣.基于用户需求响应的分时电价优化研究[D].南京:南京邮电大学,2022.
- [5] 俞峰.基于深度学习的配电设备视觉识别技术研究[D].杭州:浙江大学,2021.
- [6] 陈冠忠.电力系统电气工程自动化中智能化技术的运用探讨[J].电气开关,2021,59(1):1-2,8.
- [7] 黄奎皓.基于电力系统电气工程自动化的智能化应用分析[J].上海大中型电机,2020(2):20-21,33.
- [8] 谭勇林.新能源电力系统中的储能技术分析[J].光源与照明,2022(11):152-154.
- [9] 刘一欣,郭力,王成山.多微电网参与下的配电侧电力市场竞价博弈方法[J].电网技术,2017,41(8):2469-2476.
- [10] 付宗强.微电网群能量协调管理模型与优化调度策略研究[D].贵阳:贵州大学,2022.
- [11] 李洪珠,曹人众,张馨瑜.家庭用电背景下基于实时电价的需求响应模型[J].电力系统及其自动化学报,2018,30(11):26-31,51.
- [12] 刘永春,朱程燕,张运长,等.基于需求响应的虚拟电厂调度模型构建与仿真[J].自动化与仪器仪表,2022(6):94-98.
- [13] 张成刚.基于深度神经网络的短期电力负荷概率预测[D].武汉:武汉大学,2021.

作者简介

王永彬(1989—),男,工程师,主要研究方向:能源动力工程、节能工程与能源综合利用。

(收稿日期:2023-03-20)