

基于数据驱动碳排放流模型的配电网电碳协同调度方法

陈 荃¹, 罗梓铭², 邝嘉嘉¹, 刘志勇¹, 张丹宏¹, 李 阳¹, 姜源媛¹, 朱健全²

(1. 广东电网有限责任公司, 广东 广州 510699; 2. 华南理工大学 电力学院, 广东 广州 510640)

摘要:配电网电碳协同调度中的碳排放流计算存在因矩阵求逆而导致误差累积与计算效率下降的问题。为此,提出一种基于数据驱动碳排放流模型的配电网电碳协同调度方法。采用相关向量机构建数据驱动碳排放流模型,在实现参数自主寻优的同时获得极稀疏的回归模型,有效提升碳排放流计算的精度和速度。在数据驱动碳排放流模型的基础上,提出一种基于需求响应的配电网电碳协同调度模型,将需求响应机制与节点碳强度控制机制相结合,在合理减少能源消耗的同时,有效降低用户对高碳能源的依赖,实现配电网的低碳经济运行。算例验证了所提方法的有效性。

关键词:电碳协同;碳流理论;数据驱动;相关向量机;需求响应;调度;碳排放;配电网

中图分类号:TM73

文献标志码:A

DOI:10.16081/j.epae.202601002

0 引言

近年来,在国家“双碳”战略引领下,电力系统的低碳化进程持续加快^[1]。配电网作为分布式资源及可调节负荷接入的重要载体,其电碳协同调度对于电力系统低碳化具有重要意义。

碳排放的精确核算和分析是实现配电网低碳调度的基础。部分学者通过核算发电侧的“可观测”碳排放进行减排。文献[2]构建考虑碳排放与经济性指标的综合能源系统多目标优化模型。为详细描述碳排放的经济成本,文献[3]通过构建考虑阶梯式碳交易机制的低碳经济模型,实现系统的低碳转型。文献[4]提出综合能源系统双层优化模型,通过融合供需双侧奖惩与用户满意度改进碳交易机制。然而,上述方法会削弱发电侧的积极性,难以反映负荷侧的碳排放责任,进而无法有效激励用户节能。为此,文献[5]提出碳排放流(carbon emission flow, CEF)模型。与传统基于发电侧碳排放的核算方法不同,CEF模型通过计算和分析能源系统的动态排放来明确碳排放责任,能够跟踪从发电侧到负荷侧的电力分配过程中伴随的碳排放,实现碳责任合理分摊,激发负荷侧的低碳潜力,从而提升能源利用率,促进减排,并提供更精细的计算结果^[6]。当前已有部分研究利用CEF模型分析系统排放以促进低碳运行。例如:文献[7]基于CEF模型,将碳排放责任

分摊至源荷双侧,在多级灵活性资源规划中实现供需平衡;文献[8]在考虑灵活组群的配电网-微电网群低碳经济调度中引入CEF模型,有效降低了系统碳排放量与运行总成本;文献[9]针对交通-电力耦合网络,提出一种CEF模型,通过电碳耦合定价机制引导电动汽车快充站动态追踪低碳电能。

上述研究虽然能基于给定最优潮流结果实现CEF的显式计算,但目前的计算方法是基于矩阵求逆运算^[10],随着系统规模的扩大,大规模稀疏矩阵求逆运算存在数值稳定性问题,可能导致计算的误差累积,且其计算复杂度随着系统节点数的增加而显著增长,使得计算效率显著下降。这些缺陷导致无法将CEF作为易处理的约束直接嵌入优化模型中,严重制约了电力系统CEF的实时计算能力。为解决计算问题,数据驱动方法被应用于电力系统的拓扑辨识^[11]、参数辨识^[12]、稳定性评估^[13]、潮流计算^[14]等方面。常用的数据驱动方法有随机森林^[15](random forest, RF)、人工神经网络^[16](artificial neural network, ANN)及支持向量机^[17](support vector machine, SVM)。RF是一种使用多个决策树来执行预测任务的集成学习模型,具有易于理解和计算效率高的优势。文献[18]提出一种基于RF的电网动态频率预测方法;文献[19]提出基于RF与摄动灵敏度分析的机组优化方法,有效消除了系统弱阻尼风险。但RF对复杂非线性的建模能力有限,ANN凭借多层非线性结构克服了该缺陷。文献[20]使用ANN进行频率的约束学习,并将其集成到机组组合问题中;文献[21]基于集成ANN实现并行化短期最优发电调度,显著提升了预测精度与效率。但ANN参数量大、训练过程易受局部极值影响的特点易引发过拟合问题。为此,引入SVM,其高维特征空间中线性函数作为假设空间,利用少量训练样本实现良好预测,这是避免过拟合的有效机制。然而,SVM仍

收稿日期:2025-07-23;修回日期:2025-11-03

在线出版日期:2026-01-07

基金项目:广东电网有限责任公司科技项目(0300002024030201GH00100);国家自然科学基金资助项目(52477099)

Project supported by the Science and Technology Project of Guangdong Power Grid Co.,Ltd.(0300002024030201GH00100) and the National Natural Science Foundation of China (52477099)

存在以下显著缺陷^[22]:尽管稀疏性较好,但支持向量的数量随着训练样本规模的增大而呈线性增长,增加了计算复杂度;需估计不敏感参数,通常需要额外计算和参数设置。为解决上述问题,文献[22-23]基于稀疏贝叶斯学习理论,将其发展为相关向量机(relevance vector machine, RVM)方法。与SVM类似,RVM的输出函数也是一组以训练样本为中心的核函数加权和,但RVM基于完全的贝叶斯推理框架进行设计,具有如下优势:RVM通过自动相关性确定机制实现了特征的自适应稀疏化(仅保留了对学习目标具有显著贡献的相关向量),从而具有更低的计算代价;RVM通过贝叶斯框架实现参数优化,规避了对不敏感参数的设定与调节^[24-25]。

本文对配电网的电碳协同调度问题进行研究。首先,基于RVM构建一种数据驱动CEF模型,以提升计算精度和速度。然后,在此基础上,将所提CEF模型嵌入配电网电碳协同调度方法中,并充分考虑需求响应(demand response, DR)情况,以实现配电网低碳经济运行。

1 基于数据驱动的CEF模型

1.1 CEF模型

CEF模型的核心参数包括碳流率、支路碳强度及节点碳强度^[6]。碳流率通过支路碳强度与相应的潮流相乘获得,支路碳强度通过识别CEF方向由对应的节点碳强度确定。因此,CEF模型是围绕节点碳强度构建的,其数学表达式为:

$$e_{i,t} = \frac{\sum_{i \in \Omega_{Gi}} e_{Gi} P_{Gi,t} + \sum_{j \in \Omega_{Ni}} \rho_{ij,t} |P_{ij,t}|}{\sum_{i \in \Omega_{Gi}} P_{Gi,t} + \sum_{j \in \Omega_{Ni}} |P_{ij,t}|} \quad (1)$$

$$\rho_{ij,t} = \begin{cases} e_{i,t} & P_{ij,t} \geq 0 \\ e_{j,t} & P_{ij,t} < 0 \end{cases} \quad (2)$$

式中: $e_{i,t}$ 为 t 时段节点 i 的碳强度; Ω_{Gi} 为向节点 i 注入功率的发电机所在节点集合; e_{Gi} 为位于节点 i 的发电机的碳强度,表示该机组每发出 $1 \text{ kW} \cdot \text{h}$ 电所产生的碳排放量,通常可视为一个常数; $P_{Gi,t}$ 为 t 时段发电机向节点 i 注入的有功功率; Ω_{Ni} 为与节点 i 相连且向节点 i 注入功率的节点集合; $\rho_{ij,t}$ 为 t 时段节点 i 与节点 j 之间的支路碳强度; $P_{ij,t}$ 为 t 时段从节点 i 流向节点 j 的有功功率。

1.2 CEF常规计算

直接基于式(1)和式(2)计算CEF效率较低。为此,本节将式(1)的分子和分母分别改写为式(3)和式(4)的矩阵形式,重构传统CEF模型。

$$\sum_{i \in \Omega_{Gi}} e_{Gi} P_{Gi,t} + \sum_{j \in \Omega_{Ni}} \rho_{ij,t} |P_{ij,t}| = \boldsymbol{\eta}_N^{(i)} (\mathbf{P}_B^T \mathbf{e}_N + \mathbf{P}_G^T \mathbf{e}_G) \quad (3)$$

$$\sum_{i \in \Omega_{Gi}} P_{Gi,t} + \sum_{j \in \Omega_{Ni}} |P_{ij,t}| = \boldsymbol{\eta}_N^{(i)} \mathbf{P}_N (\boldsymbol{\eta}_N^{(i)})^T \quad (4)$$

式中: $\boldsymbol{\eta}_N^{(i)}$ 为一个 N 维行向量,其第 i 个元素为1,其余元素均为0; \mathbf{P}_B 为支路流出功率分布矩阵,描述了电力系统中功率的流出分布特性,若有功功率 P 从节点 i 流向节点 j ,则 \mathbf{P}_B 元素 $P_{B,ij} = P$ 且 $P_{B,ji} = 0$; \mathbf{e}_N 为节点碳强度; \mathbf{P}_G 为发电机注入分布矩阵,若第 k 台发电机连接于节点 i 且输出有功功率 P_g ,则 \mathbf{P}_G 元素 $P_{Gki} = P_g$,否则, $P_{Gki} = 0$; \mathbf{e}_G 为发电机碳强度向量; \mathbf{P}_N 为对角矩阵,其元素满足 $P_{Nii} = \sum_{i \in \Omega_{Gi}} P_{Gi,t} + \sum_{j \in \Omega_{Ni}} |P_{ij,t}|$,因此 \mathbf{P}_N 可通过式(5)计算得到。

$$\mathbf{P}_N = \text{diag} \left\{ \boldsymbol{\zeta}_{N+K} [\mathbf{P}_B^T, \mathbf{P}_G^T]^T \right\} \quad (5)$$

式中: $\boldsymbol{\zeta}_{N+K}$ 为一个 $N+K$ 维的单位行向量。

由此,基于式(3)~(5),CEF模型重构为:

$$\mathbf{e}_{Nt} = \frac{\boldsymbol{\eta}_N^{(i)} (\mathbf{P}_B^T \mathbf{e}_N + \mathbf{P}_G^T \mathbf{e}_G)}{\boldsymbol{\eta}_N^{(i)} \mathbf{P}_N (\boldsymbol{\eta}_N^{(i)})^T} \quad (6)$$

$$\mathbf{P}_N \mathbf{e}_N = \mathbf{P}_B^T \mathbf{e}_N + \mathbf{P}_G^T \mathbf{e}_G \quad (7)$$

$$\mathbf{e}_N = (\mathbf{P}_N - \mathbf{P}_B^T)^{-1} \mathbf{P}_G^T \mathbf{e}_G \quad (8)$$

1.3 基于RVM的数据驱动CEF计算

式(8)定义了从 $[\mathbf{P}_N, \mathbf{P}_B, \mathbf{P}_G, \mathbf{e}_G]^T$ 到节点碳强度 \mathbf{e}_N 的映射,而 $[\mathbf{P}_N, \mathbf{P}_B, \mathbf{P}_G, \mathbf{e}_G]^T$ 由潮流模型确定的节点功率注入 $\mathbf{P}_{inj} = [\mathbf{P}_G, \mathbf{P}_D]^T$ 决定,其中 \mathbf{P}_D 为负荷节点的负荷有功功率矩阵。为简化表示,令 $[\mathbf{P}_N, \mathbf{P}_B, \mathbf{P}_G, \mathbf{e}_G]^T = \mathbf{M}$ 。因此,可以通过式(10)中定义的函数 $f(\cdot)$ 构建CEF计算中节点功率注入 \mathbf{P}_{inj} 与碳强度 \mathbf{e}_N 之间的映射关系,即:

$$\mathbf{P}_{inj} \rightarrow \mathbf{M} \rightarrow \mathbf{e}_N \quad (9)$$

$$\mathbf{e}_N = f(\mathbf{P}_{inj}) \quad (10)$$

该映射高度依赖潮流计算结果,且包含矩阵求逆计算,在优化模型中难以高效处理。从数据驱动的视角来看,可通过数据挖掘技术得到式(10)的映射关系,避免繁琐的物理模型计算,显著缩短运算时间,用于实时碳强度的计算。同时,这种数据驱动模型是在特定系统物理拓扑结构下训练得到的,在不改变物理拓扑结构的情况下,得到的注入功率与碳强度之间的关系式(10)能够保持其有效性。

本文选择RVM建立回归模型。输入、输出变量数据集 \mathbf{x} 、 \mathbf{z} 分别为:

$$\mathbf{x} = [\mathbf{x}_1, \dots, \mathbf{x}_s, \dots, \mathbf{x}_L] = [\mathbf{P}_{inj,1}, \dots, \mathbf{P}_{inj,s}, \dots, \mathbf{P}_{inj,L}] \quad (11)$$

$$\mathbf{z} = [\mathbf{z}_1, \dots, \mathbf{z}_s, \dots, \mathbf{z}_L] = [\mathbf{e}_{N,1}, \dots, \mathbf{e}_{N,s}, \dots, \mathbf{e}_{N,L}] \quad (12)$$

式中:输入变量 $\mathbf{x}_s \in \mathbf{R}^p$,为节点功率注入向量 $\mathbf{P}_{inj,s} = [\mathbf{P}_{G,s}, \mathbf{P}_{D,s}]^T$, D 为输入变量的特征数, $\mathbf{P}_{G,s}$ 、 $\mathbf{P}_{D,s}$ 分别为第 s 个样本的发电机注入向量和负荷有功功率向量;输出变量 \mathbf{z}_s 为节点碳强度向量 $\mathbf{e}_{N,s}$; L 为数据集的数量。为消除不同特征间的量纲差异,避免数值跨度的特征在模型训练中占据主导地位,在模型训

练前,对所有数据均进行Z-score标准化处理。

构建RVM回归模型如下:

$$y(\mathbf{x}_s; \mathbf{w}) = \mathbf{w}^T \boldsymbol{\phi}(\mathbf{x}) = \sum_{s=1}^L w_s K(\mathbf{x}, \mathbf{x}_s) + w_0 \quad (13)$$

$$z_s = y(\mathbf{x}_s; \mathbf{w}) + \epsilon_s \quad (14)$$

式中: $\mathbf{w} = [w_1, w_2, \dots, w_L]$ 为待学习的权重向量, w_s 为与第 s 个样本对应的权重参数; w_0 为偏置项; $\boldsymbol{\phi}(\mathbf{x})$ 为由核函数 $K(\mathbf{x}, \mathbf{x}_s)$ 构成的基函数向量, 为保障模型计算效率, 本文采用计算复杂度更低的线性核函数, 以避免非线性核函数带来的额外计算负担; 输出变量 z_s 满足以 $y(\mathbf{x}_s; \mathbf{w})$ 为均值、 σ^2 为方差的高斯分布, 即给定输入 \mathbf{x}_s 时输出 z_s 的条件概率分布为 $p(z_s | \mathbf{x}_s) \sim N(z_s | y(\mathbf{x}_s; \mathbf{w}), \sigma^2)$, 且 z_s 独立同分布, 因此输出变量数据集的似然函数 $p(\mathbf{z} | \mathbf{w}, \sigma^2)$ 如式(15)所示; ϵ_s 服从均值为0的高斯分布, 即 $\epsilon_s \sim N(0, \sigma^2)$ 。

$$p(\mathbf{z} | \mathbf{w}, \sigma^2) = (2\pi\sigma^2)^{-L/2} e^{-\frac{1}{2\sigma^2} \|\mathbf{z} - \boldsymbol{\Phi}\mathbf{w}\|^2} \quad (15)$$

式中: $\boldsymbol{\Phi}$ 为设计矩阵, 其第 s 行为 $\boldsymbol{\phi}^T(\mathbf{x}_s)$ 。

为引入稀疏性并避免过拟合, 对每个权重参数 w_s 均施加一个先验概率分布的约束, 即:

$$p(\mathbf{w} | \boldsymbol{\alpha}) = \prod_{s=0}^L N(w_s | 0, \alpha_s^{-1}) \quad (16)$$

式中: $\boldsymbol{\alpha}$ 为 $L+1$ 维向量, 称为超参数。在参数优化过程中, 大多数 $\alpha_s \rightarrow \infty$, 对应的 $w_s = 0$, 这导致核矩阵中的大多数项不参与预测计算, 从而实现了RVM的极度稀疏, 这也称为RVM的自动相关性确定机制。

给定似然函数和先验分布, 可通过贝叶斯公式得到未知输入的后验分布, 即:

$$p(\mathbf{w} | \mathbf{z}, \boldsymbol{\alpha}, \sigma^2) \propto p(\mathbf{z} | \mathbf{w}, \sigma^2) p(\mathbf{w} | \boldsymbol{\alpha}) \quad (17)$$

由于似然函数和先验分布均为高斯分布, 后验分布也为高斯分布, 可进一步表示为:

$$p(\mathbf{w} | \mathbf{z}, \boldsymbol{\alpha}, \sigma^2) = (2\pi)^{-\frac{L+1}{2}} |\boldsymbol{\Sigma}|^{-1/2} e^{-\frac{1}{2}(\mathbf{w}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{w}-\boldsymbol{\mu})} \quad (18)$$

式中: $\boldsymbol{\Sigma}$ 、 $\boldsymbol{\mu}$ 分别为均值和方差, 如式(19)、(20)所示。

$$\boldsymbol{\Sigma} = (\sigma^{-2} \boldsymbol{\Phi}^T \boldsymbol{\Phi} + \mathbf{A})^{-1} \quad (19)$$

$$\boldsymbol{\mu} = \sigma^{-2} \boldsymbol{\Sigma} \boldsymbol{\Phi}^T \mathbf{z} \quad (20)$$

式中: $\mathbf{A} = \text{diag}(\boldsymbol{\alpha})$ 为超参数对角矩阵。

利用后验分布, 可对任一新输入 \mathbf{x}^* 进行预测, 其预测的输出 z^* 的后验分布为:

$$p(z^* | \mathbf{x}^*, \mathbf{z}) \sim N(z^* | \boldsymbol{\phi}^T(\mathbf{x}^*) \boldsymbol{\mu}, \sigma^2 + \boldsymbol{\phi}^T(\mathbf{x}^*) \boldsymbol{\Sigma} \boldsymbol{\phi}(\mathbf{x}^*)) \quad (21)$$

式中: $\boldsymbol{\phi}^T(\mathbf{x}^*) \boldsymbol{\mu}$ 为预测均值; $\sigma^2 + \boldsymbol{\phi}^T(\mathbf{x}^*) \boldsymbol{\Sigma} \boldsymbol{\phi}(\mathbf{x}^*)$ 为预测方差。

模型训练过程中超参数 $\boldsymbol{\alpha}$ 和 σ^2 通过最大边际似然估计方法迭代更新, 公式为:

$$\alpha_s^{\text{new}} = \frac{1 - \alpha_s \sum_{ss}}{\mu_s^2} \quad (22)$$

$$\sigma^{2\text{new}} = \frac{\|\mathbf{z} - \boldsymbol{\Phi}\boldsymbol{\mu}\|^2}{L - \sum_{s=1}^L (1 - \alpha_s \sum_{ss})} \quad (23)$$

式中: α_s^{new} 、 $\sigma^{2\text{new}}$ 分别为更新后的 α_s 和 σ^2 ; \sum_{ss} 为 $\boldsymbol{\Sigma}$ 的第 s 个对角元素; $\boldsymbol{\mu}_s$ 为 $\boldsymbol{\mu}$ 中的第 s 个后验均值。

在迭代过程中删除 $w_s = 0$ 的项, 剩余权重对应的向量称为相关向量。不断重复迭代过程, 当达到最大迭代次数后, 得到超参数最优值 $\boldsymbol{\alpha}_{\text{MP}}$ 和 σ_{MP}^2 , 此时RVM回归模型式(13)训练完成。训练流程如附录A图A1所示。

2 基于数据驱动的配电网电碳协同调度模型

基于得到的数据驱动CEF模型, 本章构建基于数据驱动的配电网电碳协同调度模型, 以实现配电网的需求侧资源管理和碳排放管理。

2.1 整体框架

图1展示了基于数据驱动的配电网电碳协同调度模型框架。该框架由数据驱动学习与优化调度两部分组成。数据驱动学习部分利用传统CEF计算得到的大量运行数据, 通过RVM实现CEF模型的数据驱动学习; 将在数据驱动学习中得到的CEF模型作为约束嵌入本文提出的优化调度模型中, 计算节点实时碳强度, 将DR机制与节点碳强度控制机制相结合, 实现配电网的低碳经济运行。




图1 基于数据驱动的配电网电碳协同调度模型框架

Fig.1 Framework of data-driven based electric-carbon coordinated dispatch model for distribution network

2.2 配电网电碳协同调度模型

2.2.1 目标函数

以配电网总运行成本最小为目标, 即:

$$F = \min \sum_{t=1}^T C_t \quad (24)$$

$$C_t = C_{t,1} + C_{t,2} + C_{t,3} + C_{t,4} + C_{t,5} \quad (25)$$

式中: F 为目标函数; T 为调度时段数; C_t 为 t 时段配电网总运行成本; $C_{t,1} - C_{t,5}$ 分别为配电网分布式电源发电成本、向主网的购电成本、弃光成本、储能成本和激励用户DR的补偿成本, 可通过式(26) - (30)计算。

$$C_{t,1} = \sum_{i \in \Omega_c^D} \left[a_i (P_{Gi,t}^F)^2 + b_i P_{Gi,t}^F + c_i \right] \Delta t + \sum_{i \in \Omega_c^{PV}} \lambda_i^{PV} P_{Gi,t}^{PV} \Delta t \quad (26)$$

$$C_{t,2} = p_t P_{\text{grid},t} \Delta t \quad (27)$$

$$C_{i,3} = \sum_{i \in \Omega_C^{PV}} \beta (P_{Gi,t}^{PV} - P_{Gi,t}^{PV}) \Delta t \quad (28)$$

$$C_{i,4} = \sum_{i \in \Omega_{BESS}} \lambda_i^{BESS} (P_{BESSi,t}^c + P_{BESSi,t}^d) \Delta t \quad (29)$$

$$C_{i,5} = \sum_{i \in \Omega_D} \Delta P_{Di,t} \kappa_{i,t} \Delta t \quad (30)$$

式中： Ω_C^F 为电网中化石燃料机组节点的集合； a_i 、 b_i 、 c_i 分别为位于节点*i*的化石燃料机组的一阶、二阶和三阶成本系数； $P_{Gi,t}^c$ 、 $P_{Gi,t}^{PV}$ 分别为*t*时段化石燃料机组和光伏机组向节点*i*注入的实际有功功率； Ω_C^{PV} 为电网中光伏机组节点的集合； λ_i^{PV} 为位于节点*i*的光伏机组基于资本回收系数的单位运营成本； Δt 为每个时段的长度； p_t 为*t*时段日前能量市场的电价； $P_{grid,t}$ 为*t*时段配电网向主网的购电功率； β 为光伏的弃光成本系数； $P_{Gi,t}^{PV}$ 为日前预测的光伏功率； Ω_{BESS} 为电网中储能电池节点的集合； λ_i^{BESS} 为节点*i*的储能电池的运行成本系数； $P_{BESSi,t}^c$ 、 $P_{BESSi,t}^d$ 分别为*t*时段节点*i*的储能电池充、放电功率； Ω_D 为电网中负荷所在节点的集合； $\Delta P_{Di,t}$ 为*t*时段节点*i*的用电DR量； $\kappa_{i,t}$ 为*t*时段节点*i*的用户DR补偿价格。

2.2.2 约束条件

配电网电碳协同调度模型需满足电网、机组、购电量、储能电池、DR等方面的约束，具体如下。

1) 电网约束。本文采用交流潮流约束，包括节点功率平衡约束、线路潮流约束、节点电压约束和线路传输容量约束，具体表达式如附录B式(B1)—(B7)所示。

2) 化石燃料机组及光伏机组相关约束为：

$$\underline{P}_{Gi} \leq P_{Gi,t} \leq \bar{P}_{Gi} \quad t=1, 2, \dots, T; i \in \Omega_C^F \quad (31)$$

$$\begin{cases} P_{Gi,t}^F - P_{Gi,t-1}^F \leq P_{Gi}^{up} \\ P_{Gi,t-1}^F - P_{Gi,t}^F \leq P_{Gi}^{down} \end{cases} \quad t=2, 3, \dots, T; i \in \Omega_C^F \quad (32)$$

式中： $P_{Gi,t}$ 为*t*时段发电机组向节点*i*注入的实际有功功率； \underline{P}_{Gi} 、 \bar{P}_{Gi} 分别为机组向节点*i*注入的最小和最大功率值； P_{Gi}^{up} 、 P_{Gi}^{down} 分别为机组的上爬坡和下爬坡速率。

3) 与主网交换功率的上、下限约束为：

$$\underline{P}_{grid,t} \leq P_{grid,t} \leq \bar{P}_{grid,t} \quad t=1, 2, \dots, T \quad (33)$$

式中： $\underline{P}_{grid,t}$ 、 $\bar{P}_{grid,t}$ 分别为*t*时段配电网与主网交换功率的最小、最大值。

4) 储能电池相关约束，具体表达式如附录B式(B8)—(B13)所示。

5) DR相关约束。

本文模型DR机制以碳强度基准 e^{Bench} 为约束，确保所有用户的碳强度不大于 e^{Bench} ，以实现减排，碳强度基准约束为：

$$e_{i,t} \leq e^{Bench} \quad t=1, 2, \dots, T; i \in \Omega_D \quad (34)$$

碳强度超过 e^{Bench} 越多，对环境的影响越大，应给用户更高的补偿价格以进一步促进碳强度的降

低。为此，本文以指数函数的形式对DR补偿价格进行描述，即：

$$\kappa_{i,t} = \kappa_i + e^{\alpha(e_{i,t} - e^{Bench})} \quad t=1, 2, \dots, T; i \in \Omega_D \quad (35)$$

式中： κ_i 为基准补偿价格； α 为补偿价格系数。

同时，采用文献[26]的指数价格弹性函数描述用户需求对价格的敏感度，即：

$$\Delta P_{Di,t} = P_{Di,t} \left[1 - e^{-\epsilon_{i,t}(\kappa_{i,t} - \varpi_i)} \right] \quad t=1, 2, \dots, T; i \in \Omega_D \quad (36)$$

式中： $P_{Di,t}$ 为*t*时段节点*i*的初始有功负荷； $\epsilon_{i,t}$ 为*t*时段节点*i*的用户的价格弹性系数； ϖ_i 为节点*i*的用户愿意调整需求的补偿价格阈值。

此外，用户需满足DR量上、下限约束，即：

$$0 \leq \Delta P_{Di,t} \leq \Delta \bar{P}_{Di} \quad t=1, 2, \dots, T; i \in \Omega_D \quad (37)$$

式中： $\Delta \bar{P}_{Di}$ 为用户的DR量上限。

6) 碳强度约束。

前述基于数据驱动的CEF模型(式(13))经过训练后，便可被作为节点碳强度的等式约束嵌入电碳协同调度模型中。该方式可以避免常规CEF模型产生的大规模矩阵求逆运算，从而简化计算。

基于上述约束，本文构建最终的基于数据驱动的配电网电碳协同调度模型，目标函数为式(24)，约束条件为式(13)、附录B式(B1)—(B13)及式(31)—(37)。该模型可通过商业求解器进行求解，具体流程如附录A图A2所示。

3 算例验证

本章通过IEEE 12与IEEE 33节点的配电网系统验证所提数据驱动CEF模型的准确性，并使用改进的IEEE 33节点配电网系统验证优化调度模型的有效性。先利用MATLAB R2023b对基于数据驱动的CEF模型进行训练，再将其嵌入电碳协同调度模型中，并采用GAMS 42.4进行求解。储能相关参数及分时电价和负荷预测数据如附录C表C1及图C1所示，系统拓扑及发电机数据参考文献[27]。计算机配置为：Intel Core i5处理器，2.6 GHz主频，16 GB内存。

3.1 数据驱动CEF模型性能分析

采样不同负荷水平下的节点注入功率，并基于1.2节的传统CEF计算方法得到各注入功率对应的节点碳强度，由此形成1个样本。模型使用含15000个样本的训练数据集进行训练，并通过含3800个样本的测试数据集验证精度。

表1对比了RVM、SVM、ANN^[28]和常规线性回归(linear regression, LR)方法在不同系统(系统1—3分别为IEEE 12、IEEE 33、IEEE 141节点系统)中的仿真结果，并通过平均绝对百分比误差(mean absolute percentage error, MAPE)、均方根误差(root mean square error, RMSE)、均方误差(mean square error, MSE)、平均绝对误差(mean absolute error, MAE)和

决定系数(R^2)反映各种方法的性能。随着系统规模的增大,各种方法的计算精度均有所下降,这是因为系统规模增大会使节点增多,映射关系更为复杂。但得益于SVM、ANN和所提方法对复杂问题的良好映射能力,其计算精度均保持在较为理想的范围内。相对而言,LR方法的精度明显更低。需要说明的是,ANN虽然有最高的精度,但其具有“黑箱”性质,无法显式描述CEF模型,这意味着基于神经网络建立的CEF模型难以嵌入电碳协同调度模型进行求解。图2展示了所提方法在不同系统负荷低谷及高峰时段的节点碳强度计算误差百分比。大部分节

点的误差均小于0.8%,这证明了所得到的数据驱动模型具有良好的精度。

表2对比了不同系统中RVM与SVM模型的向量数和模型训练时间。尽管RVM与SVM的逼近能力相近,但在不同系统中,RVM拥有的向量数均不超过SVM的2%。得益于相关向量的稀疏,RVM在训练阶段显著提升了效率。

表2 RVM与SVM模型的对比

Table 2 Comparison between RVM and SVM models

系统	模型	相关向量 / 支持向量数	模型训练时间 / s
1	RVM	434	40.46
	SVM	35275	572.35
2	RVM	688	149.77
	SVM	168803	2523.60
3	RVM	7316	1146.66
	SVM	888262	17548.69

表1 不同模型的性能分析

Table 1 Performance analysis of different models

系统	模型	MAPE / %	RMSE	MSE	MAE	R^2
1	RVM	0.35	3.19×10^{-3}	1.29×10^{-5}	2.33×10^{-3}	0.988
	SVM	0.34	3.13×10^{-3}	1.24×10^{-5}	2.25×10^{-3}	0.988
	ANN	0.33	2.29×10^{-3}	1.14×10^{-5}	2.18×10^{-3}	0.990
	LR	0.41	3.75×10^{-3}	1.68×10^{-5}	2.68×10^{-3}	0.984
2	RVM	0.86	5.97×10^{-3}	8.42×10^{-5}	4.20×10^{-3}	0.983
	SVM	0.89	5.98×10^{-3}	8.49×10^{-5}	4.29×10^{-3}	0.983
	ANN	0.84	6.95×10^{-3}	1.30×10^{-5}	5.86×10^{-3}	0.989
	LR	1.24	8.38×10^{-3}	1.56×10^{-4}	5.79×10^{-3}	0.966
3	RVM	0.93	6.92×10^{-3}	1.08×10^{-4}	4.53×10^{-3}	0.980
	SVM	0.92	7.00×10^{-3}	1.10×10^{-4}	4.49×10^{-3}	0.980
	ANN	0.90	6.82×10^{-3}	2.09×10^{-4}	5.80×10^{-3}	0.987
	LR	1.51	9.77×10^{-3}	2.29×10^{-4}	6.71×10^{-3}	0.956

在CEF计算效率方面,传统方法在最小规模系统(IEEE 12节点系统)中需近12 min完成15 000个样本的计算,而所提出的基于RVM的数据驱动模型在2个系统中的计算耗时均未超过5 s,显著提升了CEF计算效率。

3.2 调度模型结果分析

在改进的IEEE 33节点系统上对本文提出的调度模型进行测试,改进的系统增加了3台分布式光伏机组PV₁—PV₃(分别位于节点14、21、29)、3台分布式燃气机组G₁—G₃(分别位于节点8、24、25)以及1台储能电池系统Bess(位于节点9)。根据文献[5],设置燃气机组、光伏机组及储能电池初始碳强度分别为520、0、780 g/(kW·h)。为验证模型性能,设计以下3种方案:方案1,设定碳强度基准值 e^{Bench} 等于上级电网的碳强度(875 g/(kW·h)),即不实施碳强度控制策略;方案2,设定碳强度基准值 e^{Bench} 为780 g/(kW·h);方案3,设定碳强度基准值 e^{Bench} 为上级电网和本地燃气机组碳强度的平均值。

表3展示了不同方案在一天内的碳排放量对比结果。总体而言,DR机制有效降低了碳排放。尽管方案1未实施碳强度控制,但通过经济补偿鼓励用户减少用电,仍实现了相当可观的碳减排,通过DR机制降低的碳排放量约占原总碳排放量的3.1%,但该策略仍有进一步减排的潜力;方案2通过碳强度基准约束进一步强化减排,通过DR机制降低的碳排放量高于方案1,约占原总排放量的5.9%;方案3的减排效果最优,通过DR机制降低的碳排放量约占原总排放量的11.7%,从而使得方案3的当前总碳排放量最低。每个节点的具体碳排放量在不同方案下的变化趋势如附录C图C2所示。由图可知,绝大多数节点的碳排放量随着碳强度约束的逐步收紧而下降,进一步印证了所提调度策略减排的有效性。此外,储能存储的碳排放量从方案1到方案3逐渐减

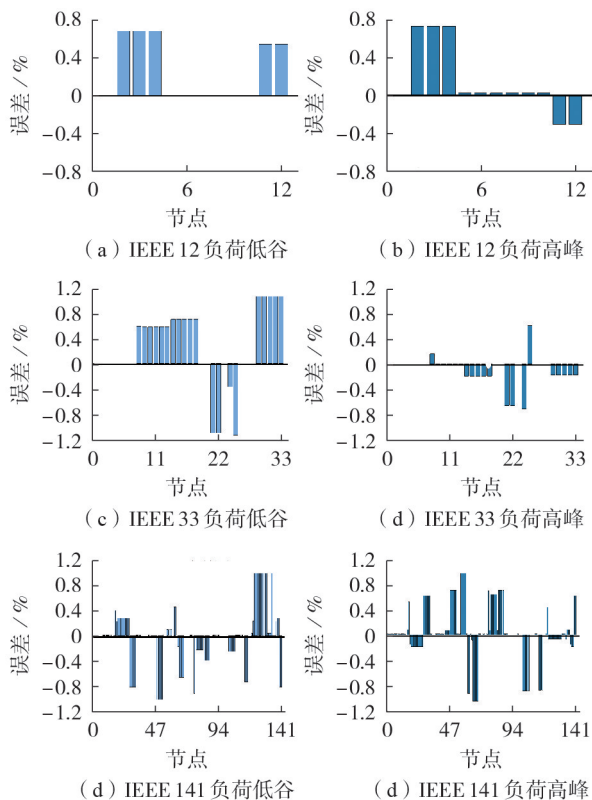


图2 所提方法在不同情况下的碳强度计算误差

Fig.2 Calculation errors of carbon intensity under different cases for proposed method

少,这表明碳强度控制策略降低了储能所在节点的碳强度,并降低了储能储存的碳排放量。

表3 3种方案的碳排放量比较

Table 3 Comparison of carbon emission among three schemes

方案	当前总碳排放量 / t	DR降低的碳排放量 / t	储能储存的碳排放量 / t
1	51.27	1.65	0.0824
2	47.85	2.98	0.0780
3	43.47	5.78	0.0757

图3展示了负荷高峰时段不同方案需求侧各节点的负荷削减量。由图可知,在同一方案下,不同节点在减少用电方面表现各异,其主要原因在于,每个用户的价格弹性不同且对高碳源依赖程度不同,客户会不同程度地减少可接受的负载,并以此换取经济收益。此外,对比3种方案可见,从方案1到方案3,多数节点的负荷削减量呈递增趋势,但从方案2到方案3的增幅比从方案1到方案2的增幅更为显著,这是由于方案2可通过优先调度低碳机组优化能源结构来实现大部分目标,仅需适度的需求侧负荷调整,而方案3为了满足更严格的碳强度约束,需要更大规模的负荷调整。负荷高峰时段各方案的机组出力情况如附录C图C3所示,结果进一步佐证了上述机制。具体而言,随着碳强度约束的收紧,系统必须降低整体碳强度。由于燃气机组 G_1 — G_3 具有较小的机组碳强度,在满足运行约束的前提下,调度策略倾向于提高其出力,以替代部分从主网获取的高碳电力;而光伏机组 PV_1 — PV_3 的出力均保持不变,原因在于,此时处于负荷高峰时段,且光伏成本较低,因此光伏出力均被充分消纳。




图3 负荷高峰时段不同方案的减负荷情况

Fig.3 Load shedding condition of different schemes during peak load period

表4展示了3种方案的经济性对比。方案1的总成本最低,其次是方案2,方案3的总成本最高。发电成本从方案1到方案3逐步增加,DR成本从方案1到方案3也逐步增加,这是由于随着碳强度约束

越来越紧,系统通过2条协同路径促进系统减排:一方面,提高本地分布式低碳机组出力占比,优化能源结构以降低单位用电的碳强度,因此,随着低碳机组出力的增加,发电成本也相应增加;另一方面,增加DR量,一些用户选择通过削减更多自身负荷参与DR,随着DR量的增加,补偿成本也相应增加。在分布式机组发电量和用户DR量均增加的情况下,购电成本相应下降。

表4 3种方案的经济性对比

Table 4 Comparison of economy among three schemes

方案	总成本 / 元	购电成本 / 元	发电成本 / 元	DR成本 / 元
1	48 335.51	45 552.49	1 846.57	928.40
2	49 171.22	39 995.48	7 635.55	1 529.02
3	49 423.98	33 857.78	13 021.10	2 526.19

在环境效益方面,与方案1相比:方案2以1.73%的总成本增幅换来了6.67%的碳减排效益;方案3以2.25%的总成本增幅换来了15.20%的碳减排效益。这表明所提出的调度模型在低碳与经济目标间具备平衡能力。

图4为不同方案下各节点的平均碳强度。各节点碳强度变化趋势存在显著差异,主要原因在于节点所能调用的低碳资源不同。具体而言:节点24、25等靠近低碳机组,具有较强的低碳调节能力,因此节点碳强度下降明显;相比之下,节点2—7等远离低碳机组,难以在碳强度控制下实现调整,因此节点碳强度几乎不变。这表明所提出的优化调度方法能够有效区分并利用节点的差异化灵活资源,实现系统节点碳强度的有效降低。




图4 3种方案的平均碳强度对比

Fig.4 Comparison of average carbon intensity among three schemes

4 结论

本文提出一种基于数据驱动CEF模型的配电网电碳协同调度方法,得到以下结论。

1)所提基于RVM的数据驱动CEF模型在各系统中均有较好性能。同时,相较于SVM,该模型所需的向量数显著减少,大幅降低了模型的复杂度,提高了训练及求解效率。

2)所提配电网优化调度模型通过DR及节点碳强度控制的策略,在兼顾经济效益的同时有效降低了系统碳排放量。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 李奇,霍莎莎,蒲雨辰,等. 面向含氢综合能源系统的电-碳-氢耦合交易市场研究综述[J]. 电力自动化设备,2023,43(12):175-187.
LI Qi, HUO Shasha, PU Yuchen, et al. Review on electricity-carbon-hydrogen coupling trading market for integrated energy system with hydrogen[J]. Electric Power Automation Equipment, 2023, 43(12):175-187.
- [2] WANG Y L, WANG X H, YU H Y, et al. Optimal design of integrated energy system considering economics, autonomy and carbon emissions[J]. Journal of Cleaner Production, 2019, 225:563-578.
- [3] WANG R T, WEN X Y, WANG X Y, et al. Low carbon optimal operation of integrated energy system based on carbon capture technology, LCA carbon emissions and ladder-type carbon trading[J]. Applied Energy, 2022, 311:118664.
- [4] LU Q, GUO Q S, ZENG W. Optimization scheduling of an integrated energy service system in community under the carbon trading mechanism: a model with reward-penalty and user satisfaction[J]. Journal of Cleaner Production, 2021, 323:129171.
- [5] 周天睿,康重庆,徐乾耀,等. 电力系统碳排放流的计算方法初探[J]. 电力系统自动化,2012,36(11):44-49.
ZHOU Tianrui, KANG Chongqing, XU Qian Yao, et al. Preliminary investigation on a method for carbon emission flow calculation of power system[J]. Automation of Electric Power Systems, 2012, 36(11):44-49.
- [6] CHENG Y H, ZHANG N, WANG Y, et al. Modeling carbon emission flow in multiple energy systems[J]. IEEE Transactions on Smart Grid, 2019, 10(4):3562-3574.
- [7] 边晓燕,吴珊,赵健,等. 考虑源荷碳责任分摊的新型电力系统多级灵活性资源规划[J]. 电力自动化设备,2024,44(2):155-164.
BIAN Xiaoyan, WU Shan, ZHAO Jian, et al. Multi-level flexible resource planning of new power system considering source-load carbon responsibility allocation[J]. Electric Power Automation Equipment, 2024, 44(2):155-164.
- [8] 刘运鑫,姚良忠,赵波,等. 考虑灵活组群的配电网-微电网群低碳经济调度方法[J]. 电力系统自动化,2024,48(20):59-68.
LIU Yunxin, YAO Liangzhong, ZHAO Bo, et al. Low-carbon economic dispatch of distribution network-microgrid clusters considering flexible clustering[J]. Automation of Electric Power Systems, 2024, 48(20):59-68.
- [9] YUAN Q, YE Y J, TANG Y, et al. Low carbon electric vehicle charging coordination in coupled transportation and power networks[J]. IEEE Transactions on Industry Applications, 2023, 59(2):2162-2172.
- [10] POURAKBARI-KASMAEI M, LEHTONEN M, CONTRERAS J, et al. Carbon footprint management: a pathway toward smart emission abatement[J]. IEEE Transactions on Industrial Informatics, 2020, 16(2):935-948.
- [11] 彭寒梅,吴行,胡磊,等. 基于CatBoost算法的配电网分区拓扑辨识[J]. 电力自动化设备,2024,44(5):95-102.
PENG Hanmei, WU Hang, HU Lei, et al. Partition topology identification of distribution network based on CatBoost algo-
- [12] 汪颖,刘慧自,胡文曦. 基于分布式电源关键控制参数辨识的配电网电压暂降评估方法[J]. 电网技术,2025,49(2):727-737.
WANG Ying, LIU Huizi, HU Wenxi. A voltage sag assessment method for distribution networks based on key control parameter identification of distributed generator[J]. Power System Technology, 2025, 49(2):727-737.
- [13] 赵冬梅,谢家康,杜泽航,等. 基于统计信息系数和Wasserstein生成对抗网络的风火系统暂态特征选择与两阶段稳定评估[J]. 电力自动化设备,2023,43(4):106-113.
ZHAO Dongmei, XIE Jiakang, DU Zehang, et al. Transient feature selection and two-stage stability assessment of wind-fire system based on uniform information coefficient and Wasserstein-generative adversarial network[J]. Electric Power Automation Equipment, 2023, 43(4):106-113.
- [14] 翁宗龙,李滨,肖佳文,等. 基于数据-物理模型融合驱动的原始-对偶自监督学习最优潮流求解方法[J]. 电力自动化设备,2025,45(4):202-208.
WENG Zonglong, LI Bin, XIAO Jiawen, et al. Primal-dual self-supervised learning optimal power flow solution method driven by data-physical model fusion[J]. Electric Power Automation Equipment, 2025, 45(4):202-208.
- [15] 郑翔,王慧芳,姜宽,等. 机理与数据融合驱动的含IIDG配电网短路电流计算方法[J]. 电力自动化设备,2021,41(1):41-48.
ZHENG Xiang, WANG Hui Fang, JIANG Kuan, et al. Mechanism and data-driven combined short circuit current calculation method for distribution network with IIDG[J]. Electric Power Automation Equipment, 2021, 41(1):41-48.
- [16] KUMAR S, TYAGI B, KUMAR V, et al. PMU-based voltage stability measurement under contingency using ANN[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 71:1-11.
- [17] 肖白,邢世亨,王茂春,等. 基于改进KDE法和GA-SVM的多风电场聚合后输出功率长期波动特性预测方法[J]. 电力自动化设备,2022,42(2):77-84.
XIAO Bai, XING Shiheng, WANG Maochun, et al. Prediction method of output power long-term fluctuation characteristic for multiple wind farms after aggregation based on improved KDE method and GA-SVM[J]. Electric Power Automation Equipment, 2022, 42(2):77-84.
- [18] 丁婷婷,杨明,于一潇,等. 基于误差修正的短期风电功率集成预测方法[J]. 高电压技术,2022,48(2):488-496.
DING Tingting, YANG Ming, YU Yixiao, et al. Short-term wind power integration prediction method based on error correction[J]. High Voltage Engineering, 2022, 48(2):488-496.
- [19] 姚海成,李豹,黄兆琴. 基于随机森林算法的电力系统小干扰稳定评估校正[J]. 广东电力,2023,36(7):60-69.
YAO Haicheng, LI Bao, HUANG Zhaochen. Small signal stability assessment and correction control of power system based on random forest algorithm[J]. Guangdong Electric Power, 2023, 36(7):60-69.
- [20] ZHANG Y C, CUI H T, LIU J Z, et al. Encoding frequency constraints in preventive unit commitment using deep learning with region-of-interest active sampling[J]. IEEE Transactions on Power Systems, 2022, 37(3):1942-1955.
- [21] MEHMOOD K, CHEEMA K M, TAHIR M F, et al. Short term power dispatch using neural network based ensemble classifier[J]. Journal of Energy Storage, 2021, 33:102101.
- [22] TIPPING M E. Sparse Bayesian learning and the relevance vector machine[J]. J Mach Learn Res, 2001, 1:211-244.

- [23] TIPPING M E. The relevance vector machine[J]. *Advances in Neural Information Processing Systems*, 2000, 13: 652-658.
- [24] WANG X L, JIANG B, DING S X, et al. Extended relevance vector machine-based remaining useful life prediction for DC-link capacitor in high-speed train[J]. *IEEE Transactions on Cybernetics*, 2022, 52(9): 9746-9755.
- [25] CHOI J, SON Y, JEONG M K. Restricted relevance vector machine for missing data and application to virtual metrology [J]. *IEEE Transactions on Automation Science and Engineering*, 2022, 19(4): 3172-3183.
- [26] MNATSAKANYAN A, KENNEDY S. Optimal demand response bidding and pricing mechanism: Application for a virtual power plant[C]//2013 1st IEEE Conference on Technologies for Sustainability (SusTech). Portland, OR, USA: IEEE, 2013: 167-174.
- [27] ZIMMERMAN R D, MURILLO-SÁNCHEZ C E, THOMAS R J. MATPOWER: steady-state operations, planning, and analysis tools for power systems research and education[J]. *IEEE Transactions on Power Systems*, 2011, 26(1): 12-19.
- [28] AL-SUBHI A, MOSAAD M I, FARRAG T A. PV parameters estimation using optimized deep neural networks[J]. *Sustainable Computing: Informatics and Systems*, 2024, 41: 100960.

作者简介:

陈 荃(1981—),女,高级工程师,硕士,主要研究方向为电力市场、电力规划和清洁能源(**E-mail**: chenquan300@163.com);

朱建全(1982—),男,教授,博士,主要研究方向为电力系统建模、分析与优化及电力市场等(**E-mail**: zhujianquan@scut.edu.cn)。

(编辑 王锦秀)

Data-driven carbon emission flow model based electric-carbon coordinated dispatch method for distribution network

CHEN Quan¹, LUO Ziming², HUAN Jiajia¹, LIU Zhiyong¹, ZHANG Danhong¹, LI Yang¹,

LOU Yuanyuan¹, ZHU Jianquan²

(1. Guangdong Power Grid Co., Ltd., Guangzhou 510699, China;

2. School of Electric Power Engineering, South China University of Technology, Guangzhou 510640, China)

Abstract: The carbon emission flow calculation in electric-carbon coordinated dispatch of distribution network exists the problems of error accumulation and reduced calculation efficiency due to matrix inversion. Therefore, a electric-carbon coordinated dispatch method of distribution network is proposed based on data-driven carbon emission flow model. The relevance vector machine is adopted to construct the data-driven carbon emission flow model, which obtains extremely sparse regression model while realizing autonomous parameter optimization, and effectively improves the accuracy and speed of carbon emission flow calculation. On the basis of data-driven carbon emission flow model, an electric-carbon coordinated dispatch model of distribution network based on demand response is proposed, which combines the demand response mechanism and a nodal carbon intensity control mechanism, effectively reduces the dependence of user on high-carbon energy while rationally reducing the energy consumption, and realizes low-carbon and economic operation of distribution network. The example verifies the effectiveness of proposed method.

Key words: electric-carbon coordination; carbon flow theory; data-driven; relevance vector machine; demand response; dispatch; carbon emission; distribution network