

基于长短时序预测的拓扑构建与控制

严莉¹,呼海林¹,王高洲¹,张闻彬¹,潘法定¹,张啸²,郑艳伟^{2*}

(1.国网山东省电力公司信息通信公司,山东 济南 250013; 2.山东大学计算机科学与技术学院,山东 青岛 266237)

摘要:为优化动态网络的拓扑构建与资源分配,提出基于长短时序预测的拓扑构建与控制(long short-term prediction-based topology construction and control, LSPTCC)框架。采用长短期记忆(long short-term memory, LSTM)网络和Informer模型进行多维时间序列的长时和短时预测,精准捕捉数据中的时间依赖性与非平稳性波动。基于预测结果,使用增强容量约束设计(enhanced capacity constrained design, ECCD)算法构建最小生成树(minimum spanning tree, MST),优化节点间的连接,减少传输路径的总损耗。利用最大网络流算法实现动态的流量分配与调整,确保系统在流量波动情况下的高效流量资源利用。实验采用光伏消纳数据集,结果表明该框架能够准确预测发电量和用电量,并通过优化拓扑结构和资源分配,减少电力传输损耗,验证LSPTCC框架的有效性和鲁棒性。

关键词:长短时序预测;最小生成树;最大网络流算法;动态网络拓扑

中图分类号:TP183;O232 **文献标志码:**A

引用格式:严莉,呼海林,王高洲,等.基于长短时序预测的拓扑构建与控制[J].山东大学学报(理学版),2025,60(9):41-51.

Topology construction and control based on long short-term prediction

YAN Li¹, HU Hailin¹, WANG Gaozhou¹, ZHANG Wenbin¹, PAN Fading¹, ZHANG Xiao², ZHENG Yanwei^{2*}

(1. State Grid Shandong Electric Power Company Information and Communication Company, Jinan 250013, Shandong, China;
2. School of Computer Science and Technology, Shandong University, Qingdao 266237, Shandong, China)

Abstract: To optimize dynamic network topology construction and resource allocation, a long short-term prediction-based topology construction and control (LSPTCC) framework is proposed. Long short-term memory (LSTM) network and Informer models are employed for long short-term prediction of multivariate time series. Temporal dependencies and non-stationary fluctuations in the data are accurately captured. Based on the prediction results, the enhanced capacity constrained design (ECCD) algorithm is used to construct a minimum spanning tree (MST) and to optimize the connections between nodes to minimize overall transmission losses. Additionally, a maximum network flow algorithm is applied to dynamically adjust resource allocation, ensuring efficient utilization of resources under fluctuating conditions. Experiments conducted on a photovoltaic consumption dataset demonstrate that the proposed framework can accurately predict power generation and consumption. The power transmission losses are effectively reduced by optimizing both the topology and resource allocation. The efficiency and robustness of the proposed algorithms are validated.

Key words: long short-term prediction; minimum spanning tree; maximum network flow algorithm; dynamic network topology

0 引言

动态网络系统面临着日益复杂的拓扑优化和资源分配挑战,比如在光伏发电等新能源并网场景中,发电量和用电量的双重不确定性给网络规划带来了很大困难。传统的静态规划算法难以适应这种动态变化的特点,而基于历史数据的简单预测算法又无法准确把握长期趋势。为解决这些问题,本文提出了基于长短时序预测的拓扑构建与控制(long short-term prediction-based topology construction and control,

收稿日期:2024-11-18; 网络出版时间:2025-08-20

基金项目:国网山东省电力公司科技资助项目(52062723000B)

第一作者:严莉(1975—),女,高级工程师,硕士,研究方向为电力信息技术。E-mail:yanli@sd.sgcc.com.cn

*通信作者:郑艳伟(1977—),男,副研究员,博士,研究方向为时序数据预测、计算机视觉。E-mail:zhengyw@sdu.edu.cn

LSPTCC)框架。通过深度学习算法进行多维时间序列预测,准确预测系统变化趋势,基于预测结果构建最小生成树(minimum spanning tree, MST),优化网络拓扑结构,最后利用改进的最大网络流算法实现资源的分配优化。

在时间序列预测领域,不同时间尺度下时间序列呈现出显著的波动特性差异,给预测工作带来挑战。由于多种因素在较长跨度内相互制衡,长期时间序列波动相对较小;而短期时间序列受突发及随机因素影响大,波动幅度较大。长短期记忆(long short-term memory, LSTM)模型凭借其特殊的门控机制,能够有效捕捉序列数据中的长期依赖关系^[1]。门控循环单元(gated recurrent unit, GRU)模型作为简化版本,能有效控制计算效率和预测精度^[2]。Transformer模型^[3]能够处理长序列预测任务^[4],Informer模型通过稀疏注意力机制提高预测精度^[5]。此外,一些研究还结合了小波变换^[6]和经验模态分解^[7]等技术提升预测精度。集成学习算法如Stacking算法^[8]通过组合多个基础模型提升了预测稳定性。本文结合LSTM模型和Informer模型,引入注意力机制和残差连接,不仅能够捕捉长期趋势,而且能有效处理短期波动,解决了传统算法难以同时兼顾长短期预测精度的问题。

在网络拓扑优化方面,MST算法是一个经典而有效的算法。传统的Kruskal^[9-10]、Prim算法^[11-12]虽然能够找到MST,但未考虑动态变化的权重。改进的增强容量约束设计(enhanced capacity constrained design, ECCD)算法和求解度约束MST算法^[13]引入容量约束和动态权重更新机制,更适合实际应用场景。为了提高算法的适应性,研究者将强化学习^[14]、图神经网络^[15]、MST算法融合。本文基于ECCD算法提出了一种动态拓扑优化算法,实时优化网络结构,通过自适应权重调整机制,兼顾传输成本、资源负载平衡和需求满足,提升了网络的适应性和稳定性。

资源分配优化问题中,最大网络流算法提供了一个有效的解决方案框架。Ford-Fulkerson算法^[16]和改进版本Edmonds-Karp算法^[17]是最基础的算法。推送重贴标签算法^[18]在大规模网络的资源分配优化问题中表现更好。近期研究开始关注动态网络流问题,提出了在线算法^[19]和自适应算法^[20]。为处理不确定性,常采用随机规划^[21]和鲁棒优化算法^[22],引入多目标优化^[23]和分布式计算^[24]提升算法性能。本文采用改进的最大网络流算法,结合短期预测结果实现资源的动态调度。未显著增加边权成本的前提下,改进的最大网络流算法显著降低了网络流量浪费并提高了需求满足率,有效缓解了供需波动带来的不利影响。

本文提出的LSPTCC框架通过多层次优化目标的协同作用,实现了对动态网络系统的高效管理。相比于传统算法,该框架克服了单一算法的局限性,通过模块化设计实现了从预测到优化的无缝衔接。在预测准确性、网络适应性和资源利用效率等方面均取得了显著提升。本框架有3点创新:将长短期预测、拓扑优化和资源分配有机结合,形成统一的动态优化体系,解决了传统算法中模块割裂、难以协同的问题;通过实时调整网络结构和资源分配策略,框架能够有效应对各种不确定性,提高了系统的鲁棒性和适应性;在控制成本的同时,显著提升了资源利用效率和需求满足率,为网络规划提供了新的解决方案。

1 算法框架与问题定义

本文提出的LSPTCC框架为

$$F(X_s, X_l) = f_c(f_l(f_{pl}(X_l)), f_{ps}(X_s)), \quad (1)$$

式中: X_l 表示长期历史时序数据, X_s 短期历史时序数据, f_{pl} 表示长期预测函数, f_{ps} 表示短期预测函数, f_l 为拓扑构建函数, f_c 为网络控制函数。通过长短期预测结果,本文LSPTCC框架指导网络拓扑构建和资源控制,实现网络结构的动态优化。

对于预测函数 f_{pl} 和 f_{ps} ,优化目标分别为

$$\min(f_{pl}) L_l(E_l, \hat{E}_l) + \lambda_l R(f_{pl}), \quad (2)$$

$$\min(f_{ps}) L_s(E_s, \hat{E}_s) + \lambda_s R(f_{ps}), \quad (3)$$

式中: L_l 和 L_s 分别为长期和短期预测的损失函数, λ_l 和 λ_s 为相应的正则化系数, E_l 、 E_s 是长、短时序的真实值, \hat{E}_l 、 \hat{E}_s 是长、短时序的预测值, $R(\cdot)$ 为正则化项,用于防止长期和短期预测模型过拟合。

拓扑构建函数 f_l 中,输入长期预测结果 $f_{pl}(X_l)$,输出网络拓扑结构 $G' = (V, E')$, V 为网络节点集, E' 为

边集。网络节点 V 包括资源供给节点集 $S = \{s_1, s_2, \dots, s_a\}$ 和需求节点集 $N = \{n_1, n_2, \dots, n_b\}$, 其中 a, b 分别为供给节点和需求节点的数量。网络节点集、供给节点集和需求节点集之间的关系为

$$V = S \cup N, \tag{4}$$

$$S \cap N = \emptyset, \tag{5}$$

式中 \emptyset 表示空集。

动态网络的拓扑构建优化目标为

$$\min \sum_{s_i \in S, n_j \in N} w_{ij} e_{ij}, \tag{6}$$

式中: w_{ij} 为节点 s_i 和 n_j 之间的连接成本, $e_{ij} \in \{0, 1\}$ 表示节点 s_i 和 n_j 之间的连接决策变量, i 和 j 分别是资源供给节点 s_i 和需求节点 n_j 的编号。

网络控制函数 f_c 在拓扑结构 G' 的基础上, 结合短期预测结果 $f_{ps}(X_s)$ 进行资源分配优化, 其优化目标为

$$\min \sum_{s_i \in S, n_j \in N} l_{ij} x_{ij}, \tag{7}$$

式中: l_{ij} 、 x_{ij} 分别为从供给节点 s_i 到需求节点 n_j 的损耗系数和资源分配量。

通过求解上述优化问题, LSPTCC 框架能够实现网络拓扑的动态构建和资源的最优分配。LSPTCC 框架的创新之处在于将长短期预测与网络优化有机结合, 通过多层次的优化目标实现网络的动态优化, 如图 1 所示。




图 1 本文的 LSPTCC 框架

Fig.1 Proposed LSPTCC framework in this paper

2 长期序列预测

2.1 长期序列模型输入

长期预测模型的输入包含多个时间序列。设时间为 t , 影响因素为 $1, 2, \dots, n$ 时, 时间序列分别为 $F_{11}(t), F_{12}(t), \dots, F_{1n}(t)$ 。时间序列数据在输入 LSTM 模型前需要进行预处理, 包括但不限于数据清洗、异常值处理、去噪和标准化, 以确保数据质量和模型训练效果。

2.2 LSTM 模型

长期时间序列通常波动较小, 由于在较长时间内, 多种影响因素相互制衡, 使得序列整体变化较为平缓。LSTM 模型能够捕捉时间序列中的依赖关系, 根据输入的多维特征调整预测结果, LSTM 模型用于分析这类波动较小的长期序列。

假设 LSTM 模型的输入多个时间节点的数据, 定义 t 的输入特征向量为

$$\mathbf{X}(t) = (F_{11}(t), F_{12}(t), \dots, F_{1n}(t))^T. \tag{8}$$

假设 LSTM 模型在 $t-1$ 的输出是 $\mathbf{Y}(t-1)$, 则 LSTM 模型输出为

$$\mathbf{Y}(t) = f_{pl}(\mathbf{Y}(t-1), \mathbf{X}(t)). \tag{9}$$

式中 $(\mathbf{Y}(t-1), \mathbf{X}(t))$ 表示向量 $\mathbf{Y}(t-1)$ 和 $\mathbf{X}(t)$ 的连接。

LSTM 模型中的超参数设置: 隐藏层单元数为 128, 学习率初始为 0.001, 优化器为 Adam。训练采用早停策略, 当验证集上损失函数不再下降时停止训练。

如图 2 所示, LSTM 模型的核心机制在于其门控单元和隐状态 (hidden state), 门控单元包括遗忘门 (forget gate)、输入门 (input gate)、输出门 (output gate), 每个门控单元都是一个带有激活函数的神经网络。这些组件共同协作, 确保了 LSTM 模型在处理序列数据时的稳定性和高效性。




图2 LSTM模型结构示意图

Fig.2 Schematic diagram of LSTM network structure

3 短期序列预测

3.1 短期模型输入

短期序列为 $F_{s_1}(t), F_{s_2}(t), \dots, F_{s_n}(t)$, 输入模型前短期序列也需要进行预处理。

3.2 Informer 模型

短期时间序列受突发因素、随机干扰等影响更为显著,短期时间序列波动幅度较大。相比于传统循环神经网络和标准 Transformer 模型,Informer 模型提供了概率稀疏自注意力、自注意力蒸馏机制、生成式解码器,具有更好的预测能力。

图3为Informer模型的结构。编码器接收序列输入,通过概率稀疏自注意力模块和自注意力蒸馏模块,得到特征表示。相比传统的自注意力层,概率稀疏自注意力层利用蒸馏机制提取最重要的注意力区域,多层堆叠的自注意力层能有效提升模型鲁棒性。解码器接受一组占位符输入,标定预测目标的位置,同时接受编码器输出的特征图,经过多头注意力层和全连接层计算后生成预测的输出序列。已知的序列数据被输入编码器并进行编码。解码过程为:解码器接收编码器输出的特征,通过多头注意力与编码特征进行交互,最后直接预测输出完整的目标序列。

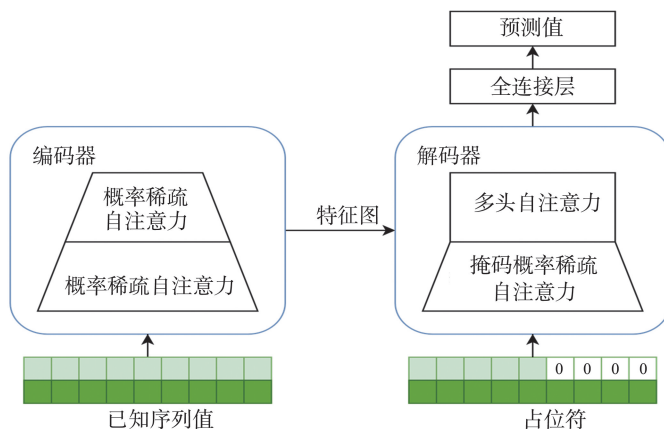


图3 Informer模型结构示意图

Fig.3 Schematic diagram of Informer model structure

编码器中采用自注意力机制提升特征的获取能力。自注意力机制存在稀疏性,利用相对熵评估观测到的分布与假设的分布的差距,差距越大,相对熵越大。

解码器的设计目标为通过一次前向计算预测长序列的所有输出。原始解码器采用堆叠2个相同的多头注意力层,一步一步进行迭代输出。Informer模型则采用批量生成式预测,直接输出多步预测结果,避免多步预测中累积误差的扩散,有效地解决了预测长期输出的效率问题。

Informer模型的编码器层数为2层,注意力头数为8,隐藏单元为128,学习率为0.0005,优化器为Adam。

4 网络拓扑构建

基于长期预测数据,本章提出一种结合 MST 和 ECCD 算法的网络拓扑构建算法,用于解决动态网络中的资源分配问题。

网络节点分为资源供给节点和资源需求节点。资源供给节点的权重由其供给能力决定,资源需求节点的权重由其需求量决定。节点间的边权重表示资源传输成本,成本与传输距离和传输量成正比,供给节点 s_i 和需求节点 n_j 之间的连接成本为

$$w_{ij} = l_{ij} p_{ij}, \quad (10)$$

式中: l_{ij} 表示 s_i 和 n_j 之间的损耗系数, p_{ij} 表示 s_i 传输到 n_j 的资源传输量。系统的损耗总功率为

$$L_{\text{total}} = \sum_{s_i \in S, n_j \in N} w_{ij} e_{ij}, \quad (11)$$

式中: e_{ij} 表示连接决策变量, $e_{ij} = 0$ 时,节点 s_i 和 n_j 之间没有连接, $e_{ij} = 1$ 时,节点 s_i 和 n_j 之间有连接。

为了实现最佳的资源配置,考虑资源需求和距离因素,通过以下步骤完成网络的拓扑构建:

(1) 初始网络构建。基于 MST 算法,初步构建一个连接所有节点的基础拓扑 G ,此处选择了 Prim 算法构建初始的 MST。MST 算法能够确保所有节点之间通过最短距离连接,减少传输损耗。

(2) 边的优化与添加。在初始网络基础上,根据节点的供给量和需求量优化边,边的权重不仅要考虑距离,还需要结合各节点的供给量和需求量,确保资源能够从供给节点高效传输到需求节点。为了避免节点负载过高或过低,采用改进的 ECCD 算法均衡负载。改进的 ECCD 算法通过调整边的连接方式或添加新的边,优化资源分配,平衡不同节点的资源供给和需求,避免资源短缺或过剩,优化资源供给节点的连接度和负载平衡。

利用 Prim 算法和 ECCD 算法构建网络拓扑,采用 MST 算法构建初始网络拓扑结构。在初始结构上依次添加一定数量的边,得到最终的光伏拓扑架构。

通过 Prim 算法创建进行 MST 的构建,计算每个资源供给节点的负载,对于每个资源供给节点 s_i ,计算资源需求节点的总需求为

$$D_i = \sum_{n_j \in N_i} p_{ij}, \quad (12)$$

式中: $N_i \subseteq N$, N 是与 s_i 相连的资源需求节点的集合, $D_i \in D$, D 为节点需求量集合。需要计算供给节点的负载比为

$$L_i = \frac{D_i}{P_i}. \quad (13)$$

式中: P_i 为供给节点 s_i 的供给能力, $P_i \in P$ 为节点供给量集合, $L_i \in L$, L 为传输成本集合。

对于每个供给节点 s_i ,若 $L_i > L_{\text{threshold}}$,则 L_i 为过载资源供给节点,否则,若 $L_i \leq L_{\text{threshold}}$, L_i 为负载不足资源供给节点,其中 $L_{\text{threshold}}$ 是设定的阈值。由此得到 2 个节点集合,即过载资源供给节点集合 S_o 和负载不足资源供给节点 S_u 。

基于拓扑结构中各个资源需求单位的需求情况和资源供给单位的供给情况,通过 ECCD 算法调整拓扑网络中的边,优化节点的连接度和负载,使得网络达到资源负载平衡,并最小化传输成本。

对过载的资源供给节点 $s_m \in S_o$ 的传输成本进行排序,选取

$$n_q^* = \arg \max_{n_j \in N_m} w_{mj}, \quad (14)$$

式中: N_m 为与 s_m 相连的资源需求节点的集合, n_q^* 为与过载的资源供给节点 s_m 连接的传输成本最高的资源需求节点, w_{mj} 为节点 s_m 与 $n_j \in N_m$ 之间的传输成本。

从负载不足资源供给节点 S_u 中寻找与需求节点 n_m^* 相连的负载比最低的节点

$$s_k^* = \arg \min_{s_k \in S_u} L_k, \quad (15)$$

式中, $S_u \subseteq S_u$ 是与节点 n_m^* 相连的供给节点的集合。

更新边,令 $e_{mq}=0, e_{kq}=1$ 。重复以上操作找到所有供给节点的负载降低到允许范围内。

调整连接时,为了保证网络连通性,需要确保网络中所有的资源需求节点都至少连接到一个资源供给节点,避免产生孤立的节点和过长的链路。

通过以上步骤进行多次迭代,达到负载平衡和减少传输成本的目标,构建网络拓扑结构,算法流程图如图4所示。

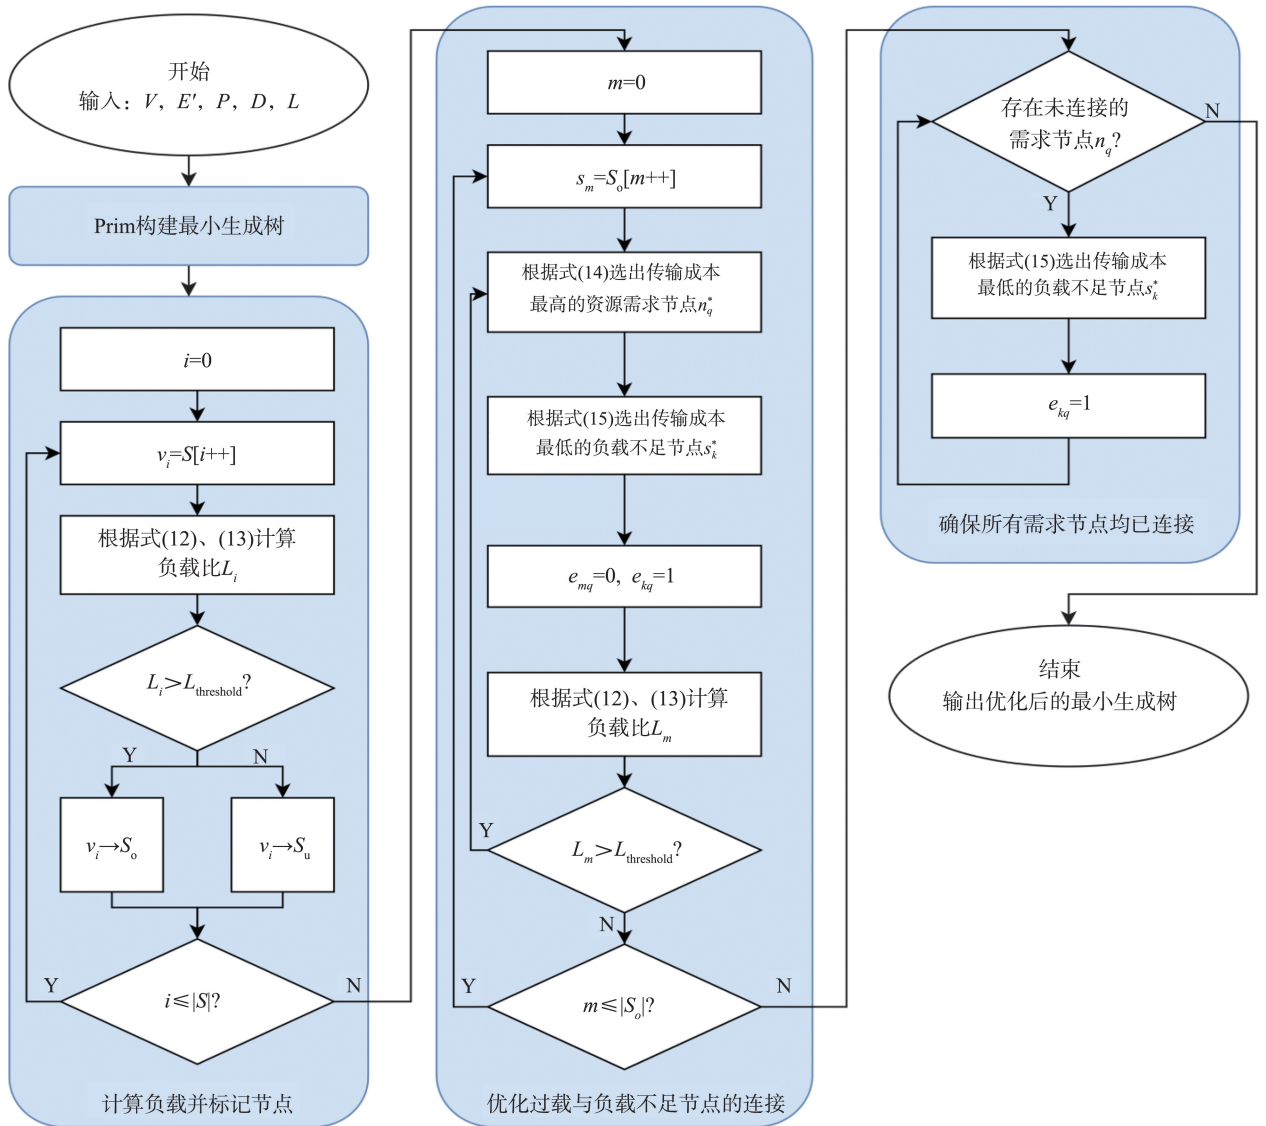


图4 网络拓扑构建算法
Fig.4 Topology construction algorithm

5 网络控制

对于网络拓扑图 $G'=(V,E')$ 上,优化得到子图 $G''=(V,E'')$,其中 E' 为供给和需求结点间的连接关系, E'' 为基于短期预测数据优化得到的结点连接关系, $E'' \subseteq E'$ 。

图5中每个绿色的资源供给节点都与每个红色的资源需求节点相连。规定只能由供给节点送电到需求节点,节点之间的边为由供给节点到需求节点的有向边。实线边表示存在于图 G' 中且存在于图 G'' 中的边,虚线边表示存在于图 G' 中但不存在于图 G'' 中的边,即断开边。所有边的传输成本 L_{total} 衡量连接供给和需求节点的代价。




图 5 网络控制算法示意图

Fig.5 Schematic diagram of network control algorithm

为保证需求节点获得足够的资源分配,减少供给节点的资源浪费,本文采用最大网络流算法进行网络控制。采用图 G'' 的传输成本、未分配资源占比和需求满足比衡量控制效果。

6 实验分析

为了验证本文 LSPTCC 框架在动态光伏电力系统中的有效性,本文进行了仿真实验。由于光伏发电量和用电量的双重不确定性和电力网络的动态变化,而深度学习模型能够准确预测光伏发电量和用电量的波动,为后续的拓扑优化和资源分配提供可靠的数据基础,因此 LSPTCC 框架适用于光伏电力系统。基于 MST 和 ECCD 算法的网络拓扑构建算法能够有效地适应光伏电力系统中节点数和连接关系的动态变化,构建高效可靠的电力网络。最大网络流算法能够实现光伏电力资源的动态分配,最大限度地提高资源利用率并减少电力损耗。

实验验证了深度学习预测模型中光伏发电量、用电量的预测精度和稳定性,评估了基于 MST 和 ECCD 算法的光伏电力网络拓扑优化效果,分析了改进的最大网络流算法在光伏电力系统中的资源分配效率。

6.1 实验设计

6.1.1 长期数据预测

长期数据预测需要考虑多个外部因素,例如经济增长、人口规模变化、节假日安排等。作为长期数据预测模型的输入,实验采用近 20 年多个省的历史发电量、经济指标包括经济增长率 $G(t)$ 、人口规模 $P(t)$ (百万人)、是否为假期 $H(t)$ 、季节 $S(t)$ (春、夏、秋、冬)。

训练前的模型数据经过预处理,包括去噪、标准化和时间对齐,得到输入特征向量为

$$\mathbf{X}(t) = (G(t), P(t), H(t), S(t))^T. \quad (16)$$

6.1.2 短期数据预测

光伏发电的发电量主要受天气条件的影响,例如辐射量、气温、光照时长、湿度、风速等因素影响。分析历史数据,建立天气与光伏系统发电量之间的关系。

通过历史的负荷数据推测未来用电量。用电量预测中,总负荷为

$$C_t = N_t + W_t + T_t + S_t + R_t, \quad (17)$$

式中: N_t 为典型负荷分量, W_t 为气候因素, T_t 为时间因素, S_t 为异常或特殊事件因素, R_t 为随机因素。典型负荷分量 N_t 为短期负荷的基本组成部分,与时间、天气没有关系, N_t 具有线性及周期变化的特点。 W_t 中最重要的变量是温度。 T_t 包括人们的作息时间、季节的转换以及特殊节假日。人们活动频繁时用电量增加,晚上 11 点后用电量会缓慢降低直至次日凌晨又开始增加。大多数情况下节假日的用电量远低于工作日的用电量,因为工厂和公司的用电量减少。 S_t 是偶然的特殊事件对负荷的影响。自然灾害如洪水、地震、台风等对负荷有巨大影响,具有偶然性的事件对结果有影响却难以预测。 R_t 指其他可能的因素对负荷造成的影响。由于负荷变化具有随机性,因此会存在计算误差。

6.2 评估方法

6.2.1 时序数据预测评估方法

对于时序数据,利用均方根误差 E (root mean squared error, RMSE) 和决定系数 R^2 评估算法的性能,即

$$E = \left(\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \right)^{\frac{1}{2}}, \quad (18)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2}, \quad (19)$$

式中: N 为样本数量, Y_i 为样本的实际标签值, \hat{Y}_i 为模型在该样本点上预测值, \bar{Y} 为在所有样本上的实际标签的平均值。

6.2.2 光伏拓扑构建和控制评估方法

对于光伏拓扑构建和控制,采用传输成本、电力浪费比例和电力需求满足比例评估算法的性能。传输成本为传输过程中电力的损耗,即

$$\sum_{s_i \in S, n_j \in N} l_{ij} x_{ij}. \quad (20)$$

电力浪费比例为

$$1 - \frac{\sum_{s_i \in S} D_i}{\sum_{s_i \in S} P_i}. \quad (21)$$

电力需求满足比例为

$$\frac{\sum_{s_i \in S, n_j \in N} x_{ij}}{\sum_{n_j \in N} d_j}, \quad (22)$$

式中 d_j 为节点 n_j 的需求量。

6.3 实验结果与分析

6.3.1 长期数据预测

本文采用历史发电量、经济指标对模型进行训练和测试,使用 LSTM、GRU 和马尔科夫链模型,如表 1 所示,LSTM 模型由于其门控结构更擅长捕捉长期依赖关系, E 最小, R^2 最大,表现最佳。具体来说,LSTM 模型的门控结构能够有效地学习长期数据中的模式和关系,提高了预测准确率。相比之

下,GRU 模型的结构较为精简,虽然能够捕捉短期依赖关系,但在处理长期数据时精度不高。马尔科夫链模型假设未来状态仅与当前时刻相关,无法刻画复杂依赖关系, E 最大, R^2 最小,效果最差。因此,本文 LSTM 算法的预测精度大于 GRU 模型和马尔科夫链模型的预测精度。

6.3.2 短期数据预测

为训练和评估短期数据模型,本文收集 2021—2023 年某光伏电站的 7 万条光伏发电时序数据。采样频率为 15 min/次,其中每条时序数据包括了气压(Pa)、湿度(g/m³)、云量(tenths)、温度(°C)、风速(m/s)、日照强度(W/m²)等气象数据,以及发电功率(kWh)。

如表 2 所示,在短期数据预测场景下,Informer 模型结合稀疏自注意力,大幅降低序列依赖关系的冗余,预测精度最好。Informer 模型通过稀疏自注意力机制能够有效地捕捉短期数据中的局部模式和关系,具有更高的预测精度。Transformer 模型的预测精度低于 Informer 模型,因为 Transformer 模型虽然能够捕捉长期依赖关系,但在处理短期数据时

表 1 长期数据预测实验结果
Table 1 Long-term sequence data prediction experimental results

模型	E	R^2
LSTM(本文)	1.576	0.751
GRU	2.264	0.693
马尔科夫链	3.037	0.660

表 2 短期数据预测实验结果
Table 2 Short-term sequence data prediction experimental results

模型	E	R^2
Informer(本文)	2.102	0.693
Transformer	2.460	0.650
LSTM	3.492	0.604
GRU	3.509	0.595

可能会受到冗余信息的影响。LSTM 模型和 GRU 模型在短期波动剧烈场景下的预测精度比基于注意力机制的模型的预测精度低,这是因为 LSTM 模型和 GRU 模型虽然能够捕捉长期依赖关系,但在处理短期数据时可能会受到历史信息的影响。因此,在对传统 Transformer 进行改进后得到的 Informer 模型在该预测任务上优于其余模型,为光伏发电控制的实现提供数据基础。

6.3.3 光伏拓扑构建

本文随机生成了 5 万条不同规模的模拟数据进行测试。每条模拟数据包括多个发电节点和用电节点,每个发电和用电节点带有二维位置坐标和发电量或用电量模拟数据。如图 6—7 所示,其中红色节点代表发电节点,蓝色节点代表用电节点。

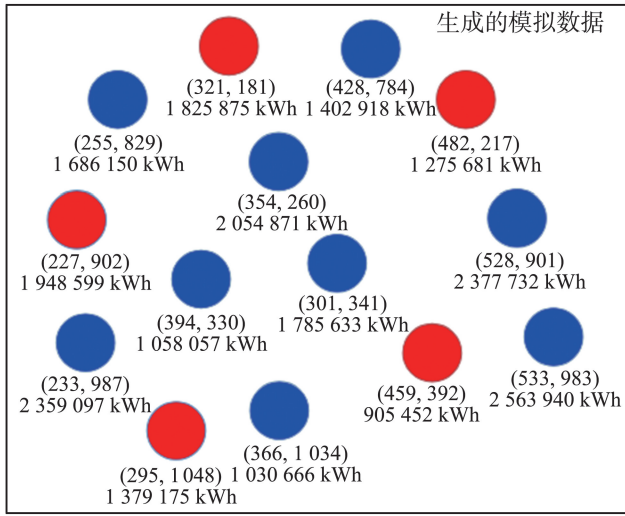


图 6 光伏拓扑构建算法输入数据示意图
Fig.6 Schematic for input data of photovoltaic topology construction algorithm

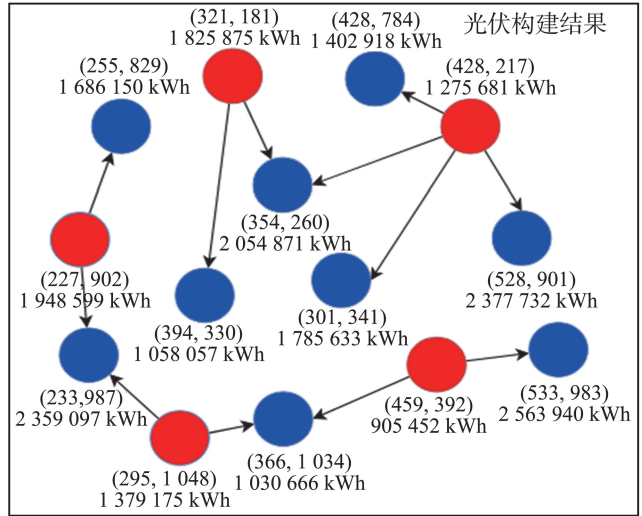


图 7 光伏拓扑构建算法输出数据示意图
Fig.7 Schematic for output data of photovoltaic topology construction algorithm

实验中使用完全二分图算法和贪心算法作为基准进行对比。完全二分图算法中,建立所有发电节点到用电节点的边,发电节点的电量可以完全自由地分配给用电节点,电力浪费水平最低,满足最大的电力需求。贪心算法只为每个用电节点建立到距离其最近的用电节点的边,达到较小的边权代价。不同光伏拓扑构建算法的性能如表 3 所示。

表 3 光伏拓扑构建实验结果
Table 3 Photovoltaic topology construction experimental results

算法	传输成本/kWh	电力浪费比例	电力需求满足比例
ECCD(本文)	23 561.279	0.182	0.893
完全二分图	102 6037.284	0.092	0.962
贪心	12 843.664	0.513	0.463

在光伏拓扑构建算法的性能评估中,ECCD 算法在电网建设成本与电力分配效率之间取得了显著平衡。实验结果显示,ECCD 算法的传输成本为 23 561.279 kWh,远低于完全二分图算法的传输成本,ECCD 算法的电力浪费比为 0.182,电力需求满足比为 0.893,均优于贪心算法。完全二分图算法虽然理论上实现最低电力浪费和最高需求满足,但是边权成本高,无法在实际中应用;贪心算法虽边权成本较低,但是注重局部最优而忽视了全局电力分配效率。本文 ECCD 算法通过优化电力分配路径,不仅有效控制了电网建设成本,还显著提高了电力资源利用效率和需求满足率。

6.3.4 光伏网络控制

为模拟短周期内发电量与用电量的波动以对光伏发电控制进行评估,将所有发电节点的发电量数据以及所有用电节点的用电量数据进行随机的增加或减小,将更新后的一系列光伏拓扑图作为模拟数据对光伏发电控制进行测试。如图 8 所示,其中虚线边表示在光伏控制删除的边。

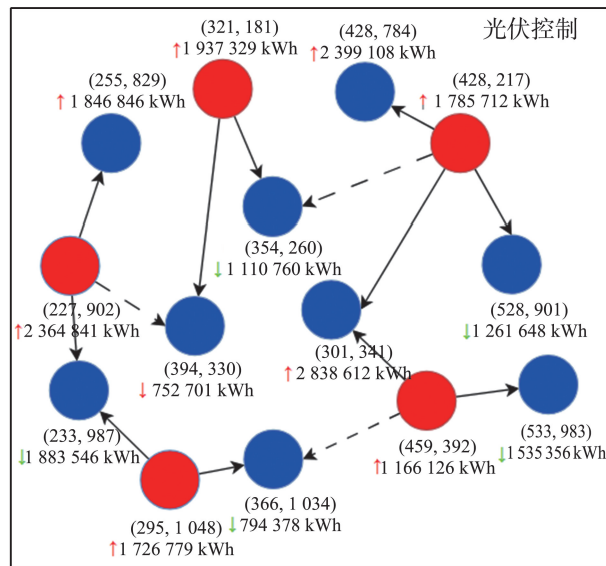


图8 光伏网络控制模拟数据和结果示意图

Fig.8 Schematic for photovoltaic power generation control simulation data and results

使用最大网络流算法进行光伏网络控制之后,光伏发电控制策略的传输成本相较于不使用控制优化算法的情况仅增加了5.8%,显著降低了电力浪费比例(减少9.8%),提高了电力需求满足比例(增加10%)。说明最大网络流算法能够在短期内灵活分配电力资源,有效缓解供需波动带来的不利影响。在未显著增加电网建设成本的前提下,光伏发电控制算法显著减轻了发电量和用电量波动导致的电力浪费和供电不足问题,验证了光伏发电控制算法在电力资源优化调度中的实用性和有效性。

7 结论

LSPTCC 框架通过集成长短期预测、动态拓扑优化和资源分配控制,实现对动态网络系统的多层次协同优化。长短期预测模型的结合为优化策略提供精准的输入数据,动态拓扑优化和资源分配控制策略则确保系统能够实时调整网络结构和资源分配,从而控制传输成本、降低电力浪费比例,提高电力需求满足比例。LSPTCC 框架不仅解决单一算法的局限性,而且通过模块化设计实现从全局到局部的优化,为动态网络系统的高效运行提供可靠的技术支持。在光伏发电系统的实际应用评估中,相比单纯的贪心策略或完全二分图方案,本文提出的框架能够有效地构建和调整系统拓扑结构,为光伏发电系统的高效运行提供可靠的技术支持。这种框架具有良好的通用性,可以推广应用到其他类似的资源分配场景中。

参考文献:

- [1] YU Yong, SI Xiaosheng, HU Changhua, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. *Neural Computation*, 2019, 31(7):1235-1270.
 - [2] DEY R, SALEM F M. Gate-variants of gated recurrent unit (GRU) neural networks [C] // 2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS). Medford: IEEE, 2017:1597-1600.
 - [3] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // *Advances in Neural Information Processing Systems*. Vancouver: Curran Associates, 2017:6000-6010.
 - [4] HAN Kai, WANG Yifan, CHEN Huazhong, et al. A survey on vision transformer [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 45(1):87-110.
 - [5] ZHOU Haibo, ZHANG Shuang, PENG Jianxin, et al. Informer: beyond efficient transformer for long sequence time-series forecasting [C] // *Proceedings of the 35th AAAI Conference on Artificial Intelligence*. Virtual: AAAI, 2021:11106-11115.
 - [6] 王红瑞, 刘晓红, 唐奇, 等. 基于小波变换的支持向量机水文过程预测 [J]. *清华大学学报(自然科学版)*, 2010, 50(9):1378-1382.
- WANG Hongrui, LIU Xiaohong, TANG Qi, et al. Hydrological process prediction based on wavelet transform and support vector machine [J]. *Journal of Tsinghua University (Science and Technology)*, 2010, 50(9):1378-1382.

- [7] 李洁,林永峰,陈亮,等. 基于深度经验模态分解的金融市场时序预测[J]. 计算机工程与设计,2019,40(12):3613-3619.
LI Jie, LIN Yongfeng, CHEN Liang, et al. Financial market time series prediction based on deep empirical mode decomposition[J]. Computer Engineering and Design, 2019, 40(12):3613-3619.
- [8] PAVLYSHENKO B. Using stacking approaches for machine learning models[C]//2018 IEEE Second International Conference on Data Stream Mining & Processing (DSMP). Lviv: IEEE, 2018:255-258.
- [9] OSIPOV V, SANDERS P SINGLER J. The filter-kruskal minimum spanning tree algorithm[C]//The Eleventh Workshop on Algorithm Engineering and Experiments (ALENEX). New York: Society for Industrial and Applied Mathematics, 2009:52-61.
- [10] LI Haiming, XIA Qiyang, WANG Yong. Research and improvement of Kruskal algorithm[J]. Journal of Computer and Communications, 2017, 5(12):63-69.
- [11] MANEN S, GUILLAUMIN M, GOOL L V. Prime object proposals with randomized Prim's algorithm[C]//Proceedings of the IEEE International Conference on Computer Vision (ICCV). Sydney: IEEE, 2013:2536-2543.
- [12] DAGAR Sunny. Modified Prim's algorithm[J]. Journal of Computer and Information Technology, 2012, 3(2):26-29.
- [13] 来卫国,李鸥,程军,等. 一种新的求解度约束最小生成树的遗传算法[J]. 计算机仿真,2008,25(8):162-165.
LAI Weiguo, LI Ou, CHENG Jun, et al. A new genetic algorithm for solving degree-constrained minimum spanning tree[J]. Computer Simulation, 2008, 25(8):162-165.
- [14] 周毅,周良才,丁佳立,等. 基于深度强化学习的电网拓扑优化和潮流控制的方法[J]. 上海交通大学学报,2021,55(增刊2):25-31.
ZHOU Yi, ZHOU Liangcai, DING Jiali, et al. Method for topology optimization and power flow control based on deep reinforcement learning[J]. Journal of Shanghai Jiao Tong University, 2021, 55(Suppl.2):25-31.
- [15] 富坤,高金辉,赵晓梦,等. 融合全局结构信息的拓扑优化图卷积网络[J]. 计算机应用,2022,42(2):357-364.
FU Kun, GAO Jinhui, ZHAO Xiaomeng, et al. Topology optimization graph convolutional network integrating global structural information[J]. Computer Applications, 2022, 42(2):357-364.
- [16] CORMEN T H, LEISERSON C E, RIVEST R L, et al. Introduction to algorithms[M]. Cambridge: MIT Press, 2009:714-731.
- [17] EDMONDS J, KARP R M. Theoretical improvements in algorithmic efficiency for network flows[J]. Journal of the ACM, 1972, 19(2):248-264.
- [18] GOLDBERG A V, TARJAN R E. A new approach to the maximum flow problem[J]. Journal of the ACM, 1988, 35(4):921-940.
- [19] KORTE B, VYGEN J. Combinatorial optimization: theory and algorithms[M]. Berlin: Springer, 2012:177-214.
- [20] ORLIN J B. Max flows in $O(nm)$ time or better[C]//Proceedings of the 45th Annual ACM Symposium on Theory of Computing (STOC). Palo Alto: ACM, 2013:765-774.
- [21] BIRGE J R, LOUVEAUX F. Introduction to stochastic programming[M]. New York: Springer, 2011.
- [22] BEN-TAL A, NEMIROVSKI A. Robust optimization: methodology and applications[J]. Mathematical Programming, 2000, 92(3):453-480.
- [23] MIETTINEN K. Nonlinear multiobjective optimization[M]. Dordrecht: Kluwer Academic Publishers, 1999:239-249.
- [24] DEAN J, GHEMAWAT S. Mapreduce: simplified data processing on large clusters[J]. Communications of the ACM, 2008, 51(1):107-113.

(编辑:陈丽萍)