第49卷 第22期 2025年11月25日
DOI：10.7500/AEPS20240427005
电力系统自动化
Automation of Electric Power Systems
Vol. 49 No. 22 Nov. 25，2025

基于冗余约束快速辨识的电力系统前瞻调度鲁棒决策方法

王麒宁[1]，陈思远[1]，徐　箭[1]，陈亦平[2]，颜　融[3]，郭　岩[3]
（1. 武汉大学电气与自动化学院，湖北省武汉市 430072；2. 南方电网新型电力系统（北京）研究院有限公司，北京市 102218；3. 中国南方电网电力调度控制中心，广东省广州市 510663）

摘要：为应对新能源日内功率偏差导致的系统电力平衡问题，电力调度部门需要从前瞻性视野对日前计划进行分钟级修正。为此，提出一种基于冗余约束快速辨识的电力系统前瞻调度鲁棒决策方法，在保证短时间高效求解的同时，提升极端运行场景下电力系统的新能源消纳率和保供能力。首先，在前瞻调度决策模式下，考虑风电/光伏的不确定性，结合水电、火电、储能及联络线多资源协同控制建立两阶段优化模型，第1阶段考虑系统的经济性和安全性，第2阶段考虑系统的新能源消纳和保供能力。进一步，考虑到新能源不确定性将增加模型复杂度，提出基于图卷积神经网络-长短期记忆网络的冗余约束辨识与削减方法，并利用列与约束生成算法对约简后的前瞻调度模型进行鲁棒优化求解。最后，在IEEE 118节点系统中进行算例仿真验证，通过数值结果验证了所提模型能够实现冗余约束的快速辨识，所提鲁棒决策方法能对多种不同类型场景的前瞻调度策略进行高效求解。

关键词：新能源；决策；极端运行场景；前瞻调度；冗余约束；图卷积神经网络；长短期记忆网络；鲁棒优化

0　引言

随着“双碳”目标下中国新型电力系统建设的不断推进，以风电、光伏为主的可再生能源在电力系统的电量占比将逐步提升，未来电网将呈现高新能源渗透率这一特征[1]。由于新能源存在随机性、波动性，高新能源渗透率下电力系统的日内平衡难度加剧，在极端天气场景出现时则更为严峻[2-3]。以广东省电网为例，2023年春节期间受寒潮影响，系统出现了海上风电大发但负荷持续低水平的情况，新能源出力预测偏差超50%，灵活性资源不足导致大规模弃电；2023年夏季台风期间，风电出现大范围切入切出，运行方式急剧变化，波幅超过40%，对日内平衡产生了巨大影响。因此，为了应对极端天气下新能源极端运行场景对电力系统功率平衡带来的挑战，电力系统前瞻调度的概念应运而生。

电力系统前瞻调度利用日内超短期预测，综合考虑前瞻窗口内短期预测误差导致的调度方案与日前计划偏差[4]，滚动修正日内调度方案，有效保证调度方案的安全性与经济性。前瞻调度面临的主要挑战在于，如何在日前计划的基础上，通过前瞻性视野，在考虑新能源不确定性的同时快速制定满足安全约束的多资源协同再调度方案。现阶段国内外学者主要通过鲁棒优化对新能源的不确定性进行处理。鲁棒优化的核心思想是要求决策者在不确定性变量可能发生的最恶劣场景下实现方案寻优。针对新能源强不确定性所导致的电力系统面临净负荷过大或者过小的极端运行场景，鲁棒优化能够保障新能源出力场景多变时电力系统的安全可靠运行。文献[5]基于分布鲁棒优化考虑电-热-氢综合能源系统中风电/光伏的不确定性问题；文献[6]考虑输电线路热定值，提出储能与输电网协同的鲁棒规划模型，从而提升输电线路的利用效率；文献[7]针对光伏、负荷的不确定性构建了min-max-min结构的两阶段鲁棒优化模型，考虑了源荷两侧都处在极端运行场景下的日前优化问题。在此基础上，文献[8]进一步引入协变量因素，通过模糊集的方法刻画源荷两侧的不确定性；文献[9]则综合考虑微电网中多类型资源的不确定性，通过鲁棒优化决策出最恶劣运行场景下的经济最优日前调度方案。上述研究为电力系统调度中鲁棒理论的应用发展奠定了良好基础。

然而，随着电力系统中源、荷、储等调度对象的

收稿日期：2024-04-27；修回日期：2024-10-25。
上网日期：2025-01-07。
国家重点研发计划资助项目（2022YFB2403500）。

类型和数量日益增加，以及电网运行方式多样性的加剧，前瞻调度模型的复杂度呈指数级增长[10]，上述传统鲁棒优化方法在考虑不确定性时引入的新增变量和约束将进一步加剧这个问题，使得优化求解的计算复杂度高、效率低、耗时长。因此，需要对前瞻调度问题的模型进行约简以提高求解效率，通过削减冗余约束来降低调度模型的复杂度。文献[11-12]表明，混合整数优化问题中往往存在大量冗余约束，这些约束并不会改变问题的最优解，仅仅只影响问题规模。文献[10]通过线路开断分布因子和支路潮流削减机组组合问题的基态和$N-1$故障态约束，但其侧重点主要在$N-1$故障态的约束削减，基态环境下仅考虑并联支路的约束削减。文献[13-14]采用深度强化学习辅助电网日内调度优化求解，但对日内滚动调度的时序相关性考虑不足。

为此，本文提出基于冗余约束快速辨识的电力系统前瞻调度鲁棒决策方法。在前瞻调度决策模式下，综合考虑多种资源的协调控制，构建了min-max-min结构的三层两阶段鲁棒经济调度模型。通过基于图卷积神经网络(GCN)-长短期记忆(LSTM)网络(下文简称GCN-LSTM)的冗余约束辨识与削减方法，并结合列与约束生成算法，将两阶段非线性模型分解为混合整数形式的主子问题交替求解，实现前瞻调度滚动鲁棒优化。本文的主要工作如下：

1)构建了考虑风电/光伏新能源不确定性及水电、火电、储能和联络线多资源协同的前瞻调度鲁棒优化模型。模型通过前瞻调度策略滚动更新，可有效应对极端运行场景下系统的功率平衡问题，提升新能源消纳和保供能力。

2)针对前瞻调度模型中的大量安全约束，提出一种基于GCN-LSTM的冗余约束快速辨识模型，通过对模型的约简降低模型复杂度与计算复杂度。

1　前瞻调度决策模式

前瞻调度发电计划的制定以时间Δt为一个决策周期，即调度计划每Δt滚动更新一次，全天共计24 h/Δt个决策时段[15]。前瞻调度决策模式是在当前决策时段根据实时更新的未来N_{F}个时段的预测数据制定未来N_{P}个时段的发电计划。为与电力系统实际调度计划制定相符，令二者都为同一值N，并将二者称为前瞻调度窗口。同时，由于前瞻调度时间尺度属于日内调度，且所采用的超短期预测数据窗口为4 h，不失一般性，取决策周期$\Delta t=15$ min对应日内调度时间尺度，取前瞻调度窗口长度$N=16$对应4 h超短期预测窗口，前瞻调度决策流程如图1所示。

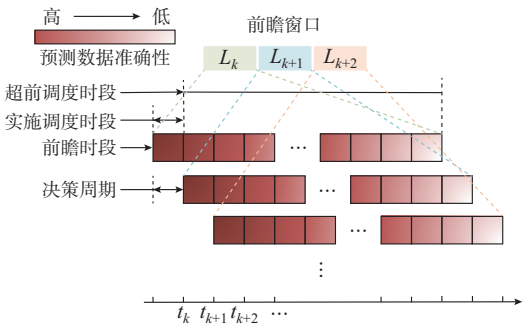

图1　前瞻调度决策流程

Fig. 1　Decision-making process of look-ahead dispatch

令初始时段$t_0=0$，对于决策时段$t_k=k\Delta t(k\in\mathbf{N})$的前瞻窗口$L_k=\{t_k,t_{k+1},\cdots,t_{k+N-1}\}$，滚动更新的信息包含以下几个部分。

1)负荷预测序列$\boldsymbol{Q}_{\mathrm{d},k}$

$$\boldsymbol{Q}_{\mathrm{d},k}=\{\boldsymbol{p}_{\mathrm{d},t_k},\boldsymbol{p}_{\mathrm{d},t_{k+1}},\cdots,\boldsymbol{p}_{\mathrm{d},t_{k+N-1}}\}\tag{1}$$

式中：$\boldsymbol{p}_{\mathrm{d},t_{k+n}}=[p_{\mathrm{d},t_{k+n},0},p_{\mathrm{d},t_{k+n},1},\cdots,p_{\mathrm{d},t_{k+n},N_{\mathrm{d}}-1}](n\in\{0,1,\cdots,N-1\})$为前瞻窗口$L_k$中前瞻时段$t_{k+n}$内系统负荷功率预测向量，其中，$N_{\mathrm{d}}$为系统负荷节点数，$p_{\mathrm{d},t_{k+n},i_{\mathrm{d}}}(i_{\mathrm{d}}\in\{0,1,\cdots,N_{\mathrm{d}}-1\})$为决策时段$t_{k+n}$节点$i_{\mathrm{d}}$处负荷功率预测值。

2)新能源预测序列$\boldsymbol{Q}_{\mathrm{ne},k}$

$$\boldsymbol{Q}_{\mathrm{ne},k}=\{\boldsymbol{p}_{\mathrm{ne},t_k},\boldsymbol{p}_{\mathrm{ne},t_{k+1}},\cdots,\boldsymbol{p}_{\mathrm{ne},t_{k+N-1}}\}\tag{2}$$

式中：$\boldsymbol{p}_{\mathrm{ne},t_{k+n}}=[p_{\mathrm{ne},t_{k+n},0},p_{\mathrm{ne},t_{k+n},1},\cdots,p_{\mathrm{ne},t_{k+n},N_{\mathrm{ne}}-1}]$为前瞻窗口$L_k$中前瞻时段$t_{k+n}$内系统新能源出力预测向量，其中，$N_{\mathrm{ne}}$为系统新能源节点数量，$p_{\mathrm{ne},t_{k+n},i_{\mathrm{ne}}}(i_{\mathrm{ne}}\in\{0,1,\cdots,N_{\mathrm{ne}}-1\})$为决策时段$t_{k+n}$节点$i_{\mathrm{ne}}$处新能源出力预测值。

3)调节资源当前执行计划$\boldsymbol{p}_{\mathrm{s},k-1}$

在前瞻窗口L_k中，各调节资源当前执行的是上一前瞻窗口L_{k-1}计算得到的前瞻调度计划的首个前瞻时段t_{k-1}，则各调节资源当前执行计划向量为：

$$\boldsymbol{p}_{\mathrm{s},k-1}=[p_{\mathrm{s},t_{k-1},0},p_{\mathrm{s},t_{k-1},1},\cdots,p_{\mathrm{s},t_{k-1},N_{\mathrm{s}}-1}]\tag{3}$$

式中：N_{s}为系统调节资源节点数；$p_{\mathrm{s},t_{k-1},i_{\mathrm{s}}}(i_{\mathrm{s}}\in\{0,1,\cdots,N_{\mathrm{s}}-1\})$为前瞻时段$t_{k-1}$节点$i_{\mathrm{s}}$处调节资源的当前出力值。

根据上述前瞻窗口L_k对应的负荷功率预测序列$\boldsymbol{Q}_{\mathrm{d},k}$、新能源出力预测序列$\boldsymbol{Q}_{\mathrm{ne},k}$和调节资源当前执行计划$\boldsymbol{p}_{\mathrm{s},k-1}$，可得前瞻窗口$L_k$中各调节资源的前瞻调度计划$\boldsymbol{Q}_{\mathrm{s},k}=\{\boldsymbol{p}_{\mathrm{s},k},\boldsymbol{p}_{\mathrm{s},k+1},\cdots,\boldsymbol{p}_{\mathrm{s},k+N-1}\}$，其中，$\boldsymbol{p}_{\mathrm{s},k+n}=[p_{\mathrm{s},t_{k+n},0},p_{\mathrm{s},t_{k+n},1},\cdots,p_{\mathrm{s},t_{k+n},N_{\mathrm{s}}-1}]$。

前瞻调度计划中包括实施调度计划和超前调度计划，下面就二者含义具体阐述。

1)实施调度计划

实施调度计划即前瞻调度计划中实际被执行的

调度计划，在前瞻调度中，对于每个前瞻调度窗口，实际执行首个时段的调度计划。以前瞻窗口L_k为例，L_k内首个时段t_k的调度计划$\boldsymbol{p}_{s,k}$将被执行，执行方式为在当前执行计划$\boldsymbol{p}_{s,k-1}$的基础上，调整各调节资源的出力，即

$$\boldsymbol{p}_{s,k}=\boldsymbol{p}_{s,k-1}+\Delta\boldsymbol{p}_{s,k} \tag{4}$$

式中：$\Delta\boldsymbol{p}_{s,k}$为调节资源的调整功率向量。

2）超前调度计划

超前调度计划即为前瞻调度计划中辅助计算未被执行的调度计划，在前瞻调度中，除首个时段t_k的调度计划外，其余时段的调度计划均为超前调度计划。对于前瞻窗口L_k中的超前调度时段t_{k+r}（$r\in\{1,2,\cdots,N-1\}$），其调节资源出力计划如下：

$$\boldsymbol{p}_{s,k+r}=\boldsymbol{p}_{s,k+r-1}+\Delta\boldsymbol{p}_{s,k+r} \tag{5}$$

式中：$\Delta\boldsymbol{p}_{s,k+r}$为$t_{k+r}$时段出力计划$\boldsymbol{p}_{s,k+r}$相对于$t_{k+r-1}$时段出力计划$\boldsymbol{p}_{s,k+r-1}$的调整功率向量。

在前瞻决策时段t_k计算得到前瞻窗口L_k的调度计划$\boldsymbol{Q}_{s,k}$后，立即执行实施调度计划，并滚动更新信息至决策时段t_{k+1}及其前瞻窗口L_{k+1}，循环直至调度结束。

2　前瞻调度三层两阶段鲁棒优化模型

2.1　鲁棒不确定集

电力系统中，以风电、光伏为代表的新能源和负荷的预测误差均会对前瞻调度产生影响，但是传统日前风电、光伏功率预测误差为15%～20%[16]，而传统日前负荷预测误差只有1%～3%[17]。相较于风电/光伏新能源预测误差，负荷的预测误差较小。本文为了凸显风电/光伏不确定性对前瞻调度的影响，暂时忽略负荷的预测误差。

考虑盒式鲁棒不确定集[18]，风电/光伏新能源不确定性可以描述为：

$$Z=\begin{cases}\boldsymbol{z}=[\,p_{w,t},p_{v,t}\,]^{\mathrm{T}}\\ p_{w,t}=\bar{p}_{w,t}-q_{\mathrm{d},t}\hat{p}_{w,t}^{\max}+q_{\mathrm{u},t}\hat{p}_{w,t}^{\max}\\ p_{v,t}=\bar{p}_{v,t}-q_{\mathrm{d},t}\hat{p}_{v,t}^{\max}+q_{\mathrm{u},t}\hat{p}_{v,t}^{\max}\\ \sum_{t=1}^{T}q_{\mathrm{d},t}\leqslant\Gamma\\ \sum_{t=1}^{T}q_{\mathrm{u},t}\leqslant\Gamma\end{cases} \tag{6}$$

式中：$\boldsymbol{z}$为不确定性变量；$p_{w,t}$、$p_{v,t}$分别为考虑不确定性引入的t时段风电机组w、光伏单元v出力的不确定性变量；$\bar{p}_{w,t}$、$\bar{p}_{v,t}$分别为风电机组w、光伏单元v在t时段的出力预测值；$\hat{p}_{w,t}^{\max}$、$\hat{p}_{v,t}^{\max}$分别为风电机组w、光伏单元v在t时段出力预测允许的最大波动偏差；T为考虑优化的总时段数，以15 min为一个时段；$q_{\mathrm{d},t}$、$q_{\mathrm{u},t}$为引入的0-1辅助变量；Γ为引入的保守度系数[19]，即风电、光伏等新能源出力处在极值的时段个数，用于调节不确定集的保守度，Γ取值越大，所得到的调度方案越保守，对风电/光伏出力恶劣极端场景的抵御能力越强。参照文献[7]，本文设定保守度系数为优化时段数量的50%，即$\Gamma=8$。

2.2　目标函数

在电力系统保安全、促消纳、保供应、保经济性的调度目标下，为了应对新能源强不确定性对前瞻调度的影响，所制定的前瞻调度策略需要保证在最恶劣运行场景下仍具备可行性与趋优性。针对这一问题，本文综合考虑水电、火电、储能和联络线多种资源的协调控制[20-21]，构建min-max-min结构的三层两阶段鲁棒调度模型。通过第1阶段min结构与第2阶段max-min双层结构的交替求解，考虑最恶劣运行场景的最大边界，并对整体调度问题进行最小优化。模型的目标函数如下：

$$\min_{\boldsymbol{x}}\left\{\sum_{t=1}^{T}C_{\Delta p,t}+\sum_{t=1}^{T}C_{s,t}+\max_{\boldsymbol{z}\in Z}\min_{\boldsymbol{y}\in\boldsymbol{\Omega}(\boldsymbol{x},\boldsymbol{z})}\sum_{t=1}^{T}(C_{d,t}+C_{\mathrm{n},t})\right\} \tag{7}$$

式中：$C_{\Delta p,t}$为各可调资源在t时段的功率调节代价，对不同可调资源类型设定不同的调节代价，可实现对灵活性较高资源的优先调用；$C_{s,t}$为考虑线路断面s时在t时段的基态及故障态潮流越限惩罚；$C_{d,t}$为所有可控负荷在t时段的切负荷惩罚；$C_{\mathrm{n},t}$为所有可控新能源在t时段的弃电惩罚；$\boldsymbol{x}$为第1阶段优化变量；$\boldsymbol{y}$为第2阶段优化变量；$\boldsymbol{\Omega}(\boldsymbol{x},\boldsymbol{z})$为给定变量$\boldsymbol{x}$和$\boldsymbol{z}$下优化变量$\boldsymbol{y}$的可行域。式(7)总体以满足电力系统调度目标出发，第1阶段中考虑系统调节成本和网络安全，第2阶段中考虑风电/光伏最恶劣场景下系统的消纳和保供目标，从而整体实现风电/光伏极端场景下的电力系统鲁棒调度。

式(7)中涉及的各参数具体如下。

对于$C_{\Delta p,t}$有：

$$C_{\Delta p,t}=\sum_{g=1}^{G}C_g|\,p_{0,g,t}-p_{g,t}\,|+\sum_{h=1}^{H}C_h|\,p_{0,h,t}-p_{h,t}\,|+\sum_{l=1}^{L}C_l|\,p_{0,l,t}-p_{l,t}\,|+\sum_{e=1}^{E}C_{e,t}(u_{e,t}^{\mathrm{cha}}+u_{e,t}^{\mathrm{dis}}) \tag{8}$$

式中：G、H、L、E分别为优化的常规火电机组g、水电机组h、联络线l以及储能e的数量；C_g、C_h、C_l为对应可控资源的调节成本系数；$p_{g,t}$、$p_{h,t}$、$p_{l,t}$为t时段对应可控资源的有功出力；$p_{0,g,t}$、$p_{0,h,t}$、$p_{0,l,t}$为t时段对应可控资源的日前计划出力；$C_{e,t}$为t时段储能e的动作调节成本系数；$u_{e,t}^{\mathrm{cha}}$、$u_{e,t}^{\mathrm{dis}}$为0-1状态变量，是t时

段储能e的动作标识符。

对于$C_{s,t}$有：

$$C_{s,t}=\sum_{s=1}^{S}M_{s,0}(S^{+}_{\mathrm{Ls},t,0}+S^{-}_{\mathrm{Ls},t,0})+\sum_{k_{\mathrm{f}}\in K_{\mathrm{fa}}}\sum_{s=1}^{S}M_{s,k_{\mathrm{f}}}(S^{+}_{\mathrm{Ls},t,k_{\mathrm{f}}}+S^{-}_{\mathrm{Ls},t,k_{\mathrm{f}}}) \tag{9}$$

式中：S为考虑的线路断面数量；$M_{s,0}$为线路断面s的基态潮流越限罚因子；$S^{+}_{\mathrm{Ls},t,0}$、$S^{-}_{\mathrm{Ls},t,0}$分别为线路断面s在t时段的基态潮流正、反向越限松弛变量；$M_{s,k_{\mathrm{f}}}$为线路断面s的故障态k_{f}潮流越限罚因子；$S^{+}_{\mathrm{Ls},t,k_{\mathrm{f}}}$、$S^{-}_{\mathrm{Ls},t,k_{\mathrm{f}}}$分别为线路断面$s$在$t$时段的故障态$k_{\mathrm{f}}$潮流正、反向越限松弛变量；$K_{\mathrm{fa}}$为$N-1$故障集合。本文中$K_{\mathrm{fa}}$为网络中传输线路的$N-1$故障。

对于$C_{\mathrm{n},t}$、$C_{d,t}$有：

$$C_{\mathrm{n},t}=\sum_{w=1}^{W}M_{w}\Delta p_{w,t}+\sum_{v=1}^{V}M_{v}\Delta p_{v,t} \tag{10}$$

$$C_{d,t}=\sum_{d=1}^{D}M_{d}\Delta p_{d,t} \tag{11}$$

式中：W、V、D分别为优化的风电机组w、光伏单元v及可控负荷d的数量；M_{w}、M_{v}、M_{d}为对应资源的切负荷罚因子；$\Delta p_{w,t}$、$\Delta p_{v,t}$、$\Delta p_{d,t}$分别为t时段风电机组w、光伏单元v的弃电功率及可控负荷d的切负荷功率。

对于第1、第2阶段优化变量$\boldsymbol{x}$,$\boldsymbol{y}$有：

$$\begin{cases}\boldsymbol{x}=[\,p_{g,t},p_{h,t},p_{l,t},u^{\mathrm{cha}}_{e,t},u^{\mathrm{dis}}_{e,t},S^{+}_{\mathrm{Ls},t,0},S^{-}_{\mathrm{Ls},t,0},S^{+}_{\mathrm{Ls},t,k_{\mathrm{f}}},S^{-}_{\mathrm{Ls},t,k_{\mathrm{f}}}\,]^{\mathrm{T}}\\ \boldsymbol{y}=[\,\Delta p_{w,t},\Delta p_{v,t},\Delta p_{d,t}\,]^{\mathrm{T}}\end{cases} \tag{12}$$

2.3 约束条件

1)火电功率和爬坡约束

$$\begin{cases}p_{g}^{\min}\leqslant p_{g,t}\leqslant p_{g}^{\max}\\ p_{g,t}-p_{g,t-1}\leqslant R^{\max}_{\mathrm{pg,u}}\\ p_{g,t-1}-p_{g,t}\leqslant R^{\max}_{\mathrm{pg,d}}\end{cases} \tag{13}$$

式中：$p_{g}^{\min}$、$p_{g}^{\max}$分别为火电机组g的最小、最大有功出力限值；$R^{\max}_{\mathrm{pg,u}}$、$R^{\max}_{\mathrm{pg,d}}$分别为火电机组g的最大向上、向下爬坡速率。

2)水电功率和电量约束

$$\begin{cases}p_{h}^{\min}\leqslant p_{h,t}\leqslant p_{h}^{\max}\\ \sum_{t=1}^{T}p_{h,t}\Delta t\leqslant E_{h}\end{cases} \tag{14}$$

式中：$p_{h}^{\min}$、$p_{h}^{\max}$分别为水电机组h的最小、最大有功出力限值；E_{h}为水电机组h在优化总时段T的电量限值。

3)外部联络线功率约束

$$p_{l}^{\min}\leqslant p_{l,t}\leqslant p_{l}^{\max} \tag{15}$$

式中：$p_{l}^{\min}$、$p_{l}^{\max}$分别为联络线l的最小、最大功率限值。

4)储能约束

(1)有功功率及荷电状态(SOC)约束

$$\begin{cases}S_{e}^{\min}\leqslant S_{e,t}\leqslant S_{e}^{\max}\\ p_{e}^{\mathrm{cha,min}}\leqslant p^{\mathrm{cha}}_{e,t}\leqslant p_{e}^{\mathrm{cha,max}}\\ p_{e}^{\mathrm{dis,min}}\leqslant p^{\mathrm{dis}}_{e,t}\leqslant p_{e}^{\mathrm{dis,max}}\\ |S_{e,T}-S_{e,1}|\leqslant k_{e,\mathrm{soc}}\end{cases} \tag{16}$$

式中：$S_{e,t}$为储能e在t时段的SOC；$S_{e}^{\min}$、$S_{e}^{\max}$分别为储能e的最小、最大SOC限值；$k_{e,\mathrm{soc}}$为储能e在优化过程中的首尾SOC限值；$p^{\mathrm{cha}}_{e,t}$、$p^{\mathrm{dis}}_{e,t}$分别为储能e在t时段的充、放电功率；$p_{e}^{\mathrm{cha,min}}$、$p_{e}^{\mathrm{cha,max}}$和$p_{e}^{\mathrm{dis,min}}$、$p_{e}^{\mathrm{dis,max}}$分别为储能e的最小、最大充电和放电功率限值。

(2)充放电及等式约束

$$\begin{cases}S_{e,t+1}=S_{e,t}+\dfrac{1}{P_{e}}\left(u^{\mathrm{cha}}_{e,t}p^{\mathrm{cha}}_{e,t}\eta_{\mathrm{stg}}-u^{\mathrm{dis}}_{e,t}\dfrac{p^{\mathrm{dis}}_{e,t}}{\eta_{\mathrm{stg}}}\right)\\ u^{\mathrm{cha}}_{e,t}+u^{\mathrm{dis}}_{e,t}\leqslant 1\end{cases} \tag{17}$$

式中：η_{stg}为储能的充放电效率；P_{e}为储能e的额定功率。

5)风电和光伏的弃电功率及切负荷约束

$$\begin{cases}0\leqslant\Delta p_{w,t}\leqslant\Delta p^{\max}_{w,t}\\ 0\leqslant\Delta p_{v,t}\leqslant\Delta p^{\max}_{v,t}\\ 0\leqslant\Delta p_{d,t}\leqslant\Delta p^{\max}_{d,t}\end{cases} \tag{18}$$

式中：$\Delta p^{\max}_{w,t}$、$\Delta p^{\max}_{v,t}$、$\Delta p^{\max}_{d,t}$分别为t时段风电机组w、光伏单元v的弃电功率及可控负荷d的切负荷功率的最大值。

6)有功平衡约束

$$\sum_{g=1}^{G}p_{g,t}+\sum_{h=1}^{H}p_{h,t}+\sum_{l=1}^{L}p_{l,t}+\sum_{e=1}^{E}(u^{\mathrm{dis}}_{e,t}p^{\mathrm{dis}}_{e,t}-u^{\mathrm{cha}}_{e,t}p^{\mathrm{cha}}_{e,t})+\sum_{w=1}^{W}(p_{w,t}-\Delta p_{w,t})+\sum_{v=1}^{V}(p_{v,t}-\Delta p_{v,t})=\sum_{d=1}^{D}(p_{d,t}-\Delta p_{d,t}) \tag{19}$$

7)基态网络安全约束

采用直流潮流，则对于节点i有：

$$p_{i,g,t}+p_{i,h,t}+p_{i,l,t}+u^{\mathrm{dis}}_{i,e,t}p^{\mathrm{dis}}_{i,e,t}-u^{\mathrm{cha}}_{i,e,t}p^{\mathrm{cha}}_{i,e,t}+p_{i,w,t}-\Delta p_{w,t}+p_{i,v,t}-\Delta p_{v,t}-p_{i,d,t}+\Delta p_{d,t}=\sum_{j\in i,j\neq i}b_{ij}(\theta_{i,t}-\theta_{j,t}) \tag{20}$$

式中：下标i表示节点i处对应的变量，下同；b_{ij}为节点i、j之间的导纳；$\theta_{i,t}$为t时段节点i处的电压相角。

$$|P_{\mathrm{Ls},t,0}|=|-b_{ij}(\theta_{i,t}-\theta_{j,t})+S^{+}_{\mathrm{Ls},t,0}-S^{-}_{\mathrm{Ls},t,0}|\leqslant P^{\max}_{\mathrm{ns}} \tag{21}$$

式中：$P_{\mathrm{Ls},t,0}$为t时段基态网络下连接节点i、j线路断面s的有功潮流；$P^{\max}_{\mathrm{ns}}$为线路断面s长期允许的载流量。

8）故障态网络安全约束

考虑$N-1$故障，根据线路开断分布因子，故障态网络安全约束为：

$$|P_{\mathrm{L}s,t,k_{\mathrm{f}}}|=|(1+L_{s,m,k_{\mathrm{f}}})P_{\mathrm{L}s,t,0}+S^{+}_{\mathrm{L}s,t,k_{\mathrm{f}}}-S^{-}_{\mathrm{L}s,t,k_{\mathrm{f}}}|\leqslant P^{\max}_{\mathrm{fs}} \tag{22}$$

式中：$P_{\mathrm{L}s,t,k_{\mathrm{f}}}$为$t$时段故障态$k_{\mathrm{f}}$下线路断面$s$的故障态潮流；$L_{s,m,k_{\mathrm{f}}}$为故障态$k_{\mathrm{f}}$下故障线路$m$对于正常线路断面$s$的线路开断分布因子；$P^{\max}_{\mathrm{fs}}$为线路断面$s$短期允许的载流量。

3　前瞻调度鲁棒决策方法

3.1　基于GCN-LSTM的冗余约束快速辨识模型

前瞻鲁棒模型中的冗余安全约束主要包含机组安全运行约束和网络基态及故障态安全约束，这些安全约束在机组、负荷功率等时序数据与网络拓扑、线路节点信息等空间数据上均具有较强的耦合性。GCN通过卷积操作将节点与其邻居节点的特征进行聚合，能够有效捕捉电力系统中节点之间的关联性和拓扑结构特征；LSTM网络通过门控机制记住长期的历史信息，能够有效提取电力系统中各类时序数据的时序特征。因此，本文通过建立图模型描述线路网络的空间特性，同时，通过建立时间序列模型描述节点资源的时间特性，并综合两者判断当前模型中的冗余约束，所提出基于GCN-LSTM的冗余约束辨识模型如图2所示。

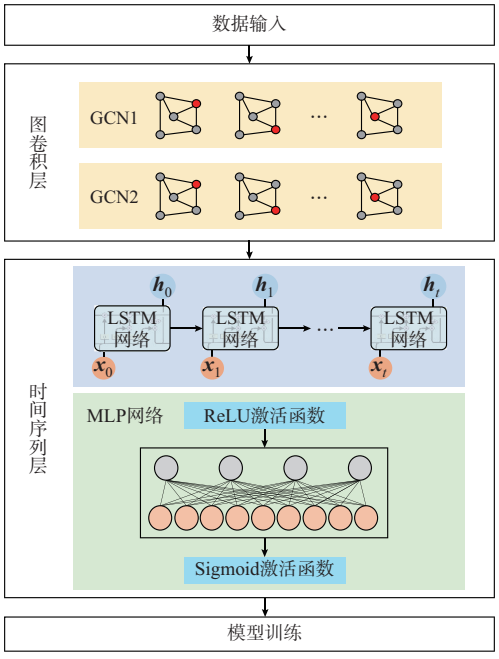

图2　基于GCN-LSTM的冗余约束辨识模型

Fig. 2　Redundant constraint identification model based on GCN-LSTM

为实现前瞻调度鲁棒模型冗余约束的快速辨识，首先，通过系统网络拓扑及线路信息建立图模型，并对建立的图模型采用GCN，提取系统内各节点间的关联信息。其次，将GCN在不同时刻提取的信息构建成时间序列，使用LSTM网络对未来时刻可能越限的约束进行辨识。以下介绍模型的具体结构。

输入层输入当前前瞻窗口中各调控资源的日前计划出力$\boldsymbol{x}_{\mathrm{P}}$、负荷日前预测数据$\boldsymbol{x}_{\mathrm{L}}$、风电/光伏出力超短期预测与负荷日前预测的偏差$\boldsymbol{x}_{\mathrm{Nd}}$和冗余约束标签$\boldsymbol{y}_{\mathrm{label}}$。为方便后续将$\boldsymbol{x}_{\mathrm{P}}$、$\boldsymbol{x}_{\mathrm{L}}$、$\boldsymbol{x}_{\mathrm{Nd}}$输入图卷积层，均预先将其处理为$bn'\times t_{\mathrm{GL}}$维数据，其中，$b$为批处理样本数量，$n'$为特征向量维度，$t_{\mathrm{GL}}$为时间序列长度。

图卷积层包含两层GCN，GCN利用所构建图模型中边的结构信息以及边的属性信息，通过基于谱域的局部一阶近似计算方法来处理图数据并提取图信息。GCN的具体更新过程描述如下：

$$\boldsymbol{X}_{q+1}=\boldsymbol{f}(\boldsymbol{X}_q,\boldsymbol{A})=\boldsymbol{\sigma}\left(\tilde{\boldsymbol{D}}^{-\frac{1}{2}}\tilde{\boldsymbol{A}}\tilde{\boldsymbol{D}}^{-\frac{1}{2}}\boldsymbol{X}_q\boldsymbol{W}_q\right) \tag{23}$$

式中：$\boldsymbol{X}_q$为第q层网络输入的特征矩阵，维度为$n_G\times d_G$，其中，n_G为图G的节点数量，d_G为图G节点的特征数量；$\boldsymbol{A}$为图的邻接矩阵；$\tilde{\boldsymbol{A}}$为加入自环的邻接矩阵，$\tilde{\boldsymbol{A}}=\boldsymbol{A}+\boldsymbol{I}$，$\boldsymbol{I}$为单位矩阵；$\tilde{\boldsymbol{D}}$为$\tilde{\boldsymbol{A}}$的度矩阵；$\boldsymbol{W}_q$为第$q$层的可学习权重矩阵；$\boldsymbol{\sigma}(\cdot)$为激活函数。

将输入层数据沿时间序列维度依次输入GCN并提取节点关联信息，更新节点状态得到$bn'\times h_{\mathrm{gcn}}$维数据，其中，$h_{\mathrm{gcn}}$为GCN输出维度。将得到的$bn'\times h_{\mathrm{gcn}}$维数据进行维度变换，沿时间序列维度拼接得到$b\times n'h_{\mathrm{gcn}}\times t_{\mathrm{GL}}$维数据并输入时间序列层进一步处理。

时间序列层为LSTM网络和多层感知器（MLP）网络。LSTM网络相较于普通循环神经网络（RNN），包含4个主要结构，分别为遗忘门、输入门、单元状态更新以及输出门。LSTM网络的具体更新过程描述如下：

$$\begin{cases}\boldsymbol{f}_t=\boldsymbol{\sigma}(\boldsymbol{W}_f[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_f)\\ \boldsymbol{i}_t=\boldsymbol{\sigma}(\boldsymbol{W}_i[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_i)\\ \boldsymbol{C}_t=\boldsymbol{f}_t\boldsymbol{C}_{t-1}+\boldsymbol{i}_t\tanh(\boldsymbol{W}_C[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_C)\\ \boldsymbol{o}_t=\boldsymbol{\sigma}(\boldsymbol{W}_o[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_o)\\ \boldsymbol{h}_t=\boldsymbol{o}_t\tanh(\boldsymbol{C}_t)\end{cases} \tag{24}$$

式中：$\boldsymbol{x}_t$为t时段的输入向量；$\boldsymbol{h}_{t-1}$为$t-1$时段的隐藏状态；$\boldsymbol{f}_t$为t时段遗忘门激活向量；$\boldsymbol{i}_t$为t时段输入门激活向量；$\boldsymbol{C}_t$为t时段单元状态向量；$\boldsymbol{o}_t$为t时段输出门激活向量；$\boldsymbol{W}_f$、$\boldsymbol{W}_i$、$\boldsymbol{W}_C$、$\boldsymbol{W}_o$为各结构中的权重

矩阵；$\boldsymbol{b}_f$、$\boldsymbol{b}_i$、$\boldsymbol{b}_C$、$\boldsymbol{b}_o$为各结构中的偏置向量。

LSTM网络将提取图卷积层的输出数据时序信息，更新节点状态得到$b\times t_{GL}\times h_{lstm}$维数据，其中，$h_{lstm}$为LSTM网络隐藏层维度。利用平均池将$b\times t_{GL}\times h_{lstm}$维数据降维至$b\times h_{lstm}$输入MLP网络。MLP网络第1层采用ReLU激活函数以增加模型的非线性度；第2层输出维度为$b\times h_{out}$，其中，h_{out}为需要辨识的约束数量；第3层采用Sigmoid激活函数对应分类问题。最后，将时间序列层得到的输出数据和冗余约束标签$\boldsymbol{y}_{label}$计算交叉熵损失并反向传播训练模型。

3.2 两阶段鲁棒优化模型求解

3.2.1 模型线性化

原模型经过约束削减后仍然会存在形如目标函数式(8)和约束条件式(17)中均含有的非线性项，对于目标函数式(8)中的绝对值项，通过文献[22]所述方法即可线性化；对于约束条件式(17)中的双线性项，通过文献[23]所述大M法即可线性化。在对模型进行线性化处理后，原模型可以表述为如下紧凑形式：

$$\begin{cases}\min\limits_{\boldsymbol{x}} \boldsymbol{c}^{\mathrm{T}}\boldsymbol{x}+\max\limits_{\boldsymbol{z}\in Z}\min\limits_{\boldsymbol{y}\in\boldsymbol{\Omega}(\boldsymbol{x},\boldsymbol{z})}\boldsymbol{b}^{\mathrm{T}}\boldsymbol{y}\\ \text{s.t. } \boldsymbol{G}_1\boldsymbol{y}=\boldsymbol{h}_1-\boldsymbol{E}_1\boldsymbol{x}-\boldsymbol{M}_1\boldsymbol{z}\\ \quad \boldsymbol{G}\boldsymbol{y}\geqslant\boldsymbol{h}-\boldsymbol{E}\boldsymbol{x}-\boldsymbol{M}\boldsymbol{z}\\ \quad \boldsymbol{x},\boldsymbol{y}\geqslant 0\end{cases}\tag{25}$$

式中：$\boldsymbol{c}$、$\boldsymbol{b}$分别为目标函数中第1、2阶段优化变量的系数向量；$\boldsymbol{G}_1$、$\boldsymbol{E}_1$、$\boldsymbol{M}_1$为等式约束下对应变量的系数矩阵；$\boldsymbol{h}_1$为等式约束常数列向量；$\boldsymbol{G}$、$\boldsymbol{E}$、$\boldsymbol{M}$为不等式约束下对应变量的系数矩阵；$\boldsymbol{h}$为不等式约束常数列向量。

3.2.2 模型求解

本文采用列与约束生成算法求解两阶段鲁棒优化模型[24]。列与约束生成算法将原问题分解为主问题和子问题，通过在迭代过程中对主问题引入子问题相关的变量和约束交替求解，以得到原问题的最优解。对于本文模型，主问题目标为求解第1阶段决策变量，其形式为：

$$\begin{cases}\min\limits_{\boldsymbol{x}} \boldsymbol{c}^{\mathrm{T}}\boldsymbol{x}+\eta\\ \text{s.t. } \eta\geqslant\boldsymbol{b}^{\mathrm{T}}\boldsymbol{y}^{(\tau)}\\ \quad \boldsymbol{G}_1\boldsymbol{y}^{(\tau)}=\boldsymbol{h}_1-\boldsymbol{E}_1\boldsymbol{x}-\boldsymbol{M}_1\boldsymbol{z}^{(\tau)}\\ \quad \boldsymbol{G}\boldsymbol{y}^{(\tau)}\geqslant\boldsymbol{h}-\boldsymbol{E}\boldsymbol{x}-\boldsymbol{M}\boldsymbol{z}^{(\tau)}\\ \quad \boldsymbol{x}\geqslant 0\\ \quad \forall\tau\leqslant n_{\mathrm{d}}\end{cases}\tag{26}$$

式中：η为引入的第2阶段目标函数辅助变量；$\boldsymbol{y}^{(\tau)}$为第τ次迭代后根据子问题解向主问题中添加的辅助变量；$\boldsymbol{z}^{(\tau)}$为第τ次迭代后子问题所得到的风电、光伏出力最恶劣场景；n_{d}为当前迭代次数。

子问题目标为基于第1阶段所得决策，求解第2阶段决策变量，其形式为：

$$\begin{cases}\max\limits_{\boldsymbol{z}\in Z}\min\limits_{\boldsymbol{y}\in\boldsymbol{\Omega}(\boldsymbol{x},\boldsymbol{z})}\boldsymbol{b}^{\mathrm{T}}\boldsymbol{y}\\ \text{s.t. } \boldsymbol{G}_1\boldsymbol{y}=\boldsymbol{h}_1-\boldsymbol{E}_1\bar{\boldsymbol{x}}-\boldsymbol{M}_1\boldsymbol{z}\\ \quad \boldsymbol{G}\boldsymbol{y}\geqslant\boldsymbol{h}-\boldsymbol{E}\bar{\boldsymbol{x}}-\boldsymbol{M}\boldsymbol{z}\\ \quad \boldsymbol{y},\boldsymbol{z}\geqslant 0\end{cases}\tag{27}$$

式中：$\bar{\boldsymbol{x}}$为主问题求解所得的第1阶段决策变量。

对于分解所得的主子问题，主问题为一个优化方向为min的常规混合整数线性规划问题，求解较为容易。子问题为一个max-min形式的最大最小化双层问题，需要将其转化为单层问题进行求解。根据KKT(Karush-Kuhn-Tucker)条件[25]，通过引入辅助变量可将子问题内层的min形式转化为一系列新增约束，从而得到只保留外层max方向优化的单层问题。经过KKT条件转换后的子问题形式为：

$$\begin{cases}\max\limits_{\boldsymbol{z}\in Z,\boldsymbol{y},\lambda,\pi}\boldsymbol{b}^{\mathrm{T}}\boldsymbol{y}\\ \text{s.t. } \boldsymbol{G}_1\boldsymbol{y}=\boldsymbol{h}_1-\boldsymbol{E}_1\bar{\boldsymbol{x}}-\boldsymbol{M}_1\boldsymbol{z}\\ \quad \boldsymbol{G}\boldsymbol{y}\geqslant\boldsymbol{h}-\boldsymbol{E}\bar{\boldsymbol{x}}-\boldsymbol{M}\boldsymbol{z}\\ \quad (\boldsymbol{b}-\boldsymbol{G}^{\mathrm{T}}\lambda-\boldsymbol{G}_1^{\mathrm{T}}\pi)^{\mathrm{T}}\boldsymbol{y}=0\\ \quad (\boldsymbol{h}-\boldsymbol{E}\bar{\boldsymbol{x}}-\boldsymbol{M}\boldsymbol{z}-\boldsymbol{G}\boldsymbol{y})^{\mathrm{T}}\lambda=0\\ \quad \boldsymbol{b}-\boldsymbol{G}^{\mathrm{T}}\lambda-\boldsymbol{G}_1^{\mathrm{T}}\pi\geqslant 0\quad \lambda\geqslant 0\end{cases}\tag{28}$$

式中：λ、π为KKT条件新增的辅助决策变量。对于式(28)新增等式约束存在的双线性项，由于等式约束的常数项均为0，同样可以采用3.2.1节中的大M法对模型进行线性化，从而转化为混合整数线性问题进行求解。

通过上述的推理和转换过程，本文提出的二阶段鲁棒模型被分解为形如式(26)、式(28)所示的混合整数线性规划问题，可通过列与约束生成算法进行求解。具体步骤如下：

1)给定一组不确定性变量$\boldsymbol{z}$的集合作为初始极端场景，设定目标函数的下界$L_{\mathrm{B}}=-\infty$，上界$U_{\mathrm{B}}=+\infty$，迭代次数$\tau=1$；

2)根据极端场景$\boldsymbol{z}$求解主问题，得到主问题最优解$\bar{\boldsymbol{x}}$，并将主问题的目标函数值作为新的下界L_{B}；

3)代入求解主问题得到的解$\bar{\boldsymbol{x}}$求解子问题，得到不确定性变量$\boldsymbol{z}$的极端场景$\boldsymbol{z}^{(\tau)}$，并根据子问题的目标函数值更新上界U_{B}；

4)给定算法的收敛阈值ε，若$U_{\mathrm{B}}-L_{\mathrm{B}}<\varepsilon$，则停止迭代，返回最优解和极端场景$\boldsymbol{z}^{(\tau)}$；否则，令$\tau=$

$\tau+1$，同时在主问题中增加变量$\boldsymbol{y}^{(\tau)}$以及如下约束：

$$\begin{cases}\boldsymbol{G}_1\boldsymbol{y}^{(\tau)}=\boldsymbol{h}_1-\boldsymbol{E}_1\boldsymbol{x}-\boldsymbol{M}_1\boldsymbol{z}^{(\tau)}\\ \boldsymbol{G}\boldsymbol{y}^{(\tau)}\geqslant\boldsymbol{h}-\boldsymbol{E}\boldsymbol{x}-\boldsymbol{M}\boldsymbol{z}^{(\tau)}\end{cases}\tag{29}$$

继续步骤2）直至算法收敛。

3.3　基于冗余约束快速辨识的前瞻鲁棒决策方法

结合前述前瞻调度决策模式、冗余约束辨识模型及两阶段鲁棒优化模型，本文提出基于冗余约束快速辨识的前瞻调度鲁棒决策方法，如图3所示。决策步骤如下：

1）根据历史调度数据构建冗余约束场景集，训练基于GCN-LSTM的冗余约束快速辨识模型。

2）从调度系统中获取当前前瞻调度窗口的电力系统网架参数、风电、光伏和负荷的超短期预测数据及各被控资源当前执行计划，构建前瞻调度两阶段鲁棒优化模型。

3）通过冗余约束快速辨识模型，依据当前前瞻窗口中各类型资源的相关时序信息，削减前瞻鲁棒模型中的冗余约束。

4）通过列与约束生成算法求解削减约束后的前瞻两阶段鲁棒模型，校验所得前瞻调度计划中被削减的冗余约束是否越限。若发生越限，则将相关越限约束添加至模型中再次计算；若未发生越限，则将所得前瞻调度计划中的实施调度计划输出至调度系统，作为当前决策时段的实际调度计划。

5）每隔一个决策时段重复步骤2）至4），形成前瞻滚动优化调度过程，直至系统调度时段结束。

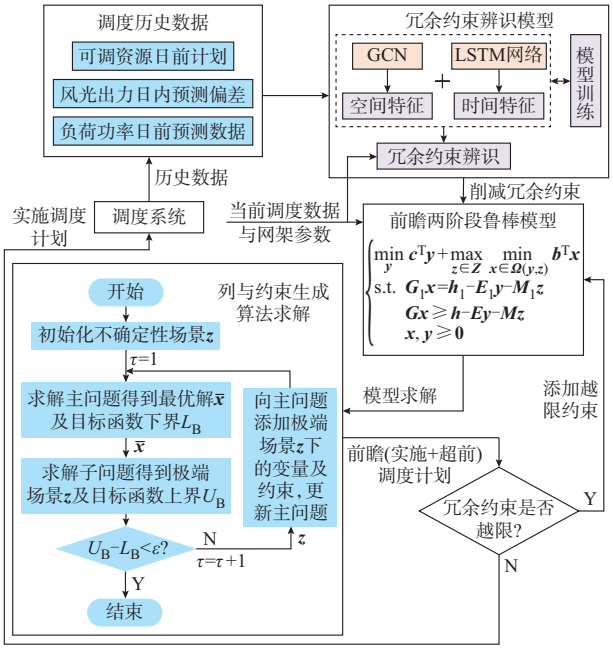

图3　前瞻调度鲁棒决策方法

Fig. 3　Robust decision-making method for look-ahead dispatch

4　算例分析

4.1　算例说明

4.1.1　算例基本信息

为了验证本文提出策略的可行性和有效性，本文基于IEEE 118节点系统进行分析，并根据第2章所提优化模型中考虑的调控资源对系统进行部分修改。IEEE 118节点系统具体的网络拓扑和机组参数详见文献[26]，本文算例修改添加的调控资源信息如表1所示。计算环境为Intel Core i7-12700H 32 GB个人电脑，采用Gurobi 10.0.2进行优化计算，计算误差设置为0.5%。

表1　调控资源信息

Table 1　Regulatory resource information

类型	数量	容量/MW	接入节点编号
风电	15	100	58、61、73、88、115
		120	9、14、26、33、48、54、79、84、89、91
光伏	10	90	17、39、41、53、55、60、69、75、76、111
水电	10	200	7、11、30、60、64、71
		180	23、45、103、110
储能	6	60	4、11、31、48、58、95

4.1.2　算例场景设置

本文根据中国南方某区域2020年全年历史风电、光伏和负荷日前预测数据和日内超短期数据，综合考虑风电/光伏出力、负荷功率及日前日内预测差异，选取3种场景。其中，日内功率不平衡最为严重的场景1和2作为考虑的极端运行场景，分别验证本文策略对于电力系统新能源消纳和保供能力的提升效果，日内功率较为平衡的场景3则作为对照场景，验证本文策略在非极端运行场景下的优化效果。场景具体描述如下：

场景1：场景日期为2020年12月1日，水电处于枯水期。该场景的风电、光伏日前预测和日内超短期预测数据如附录A图A1(a)所示，二者偏差在时段49达到最大值。此时，日内超短期预测的风电、光伏出力值超出日前预测出力值48.2%，风电、光伏出力显著偏高，系统源侧功率严重过剩。

场景2：场景日期为2020年8月13日，水电处于丰水期。该场景的风电、光伏日前预测和日内超短期预测数据如附录A图A1(b)所示，二者偏差在时段45达到最大值。此时，日内超短期预测的风电/光伏出力值低于日前预测出力值43.6%，风电/光伏出力显著偏低，系统源侧功率严重短缺。

场景3：场景日期为2020年7月19日，水电处于丰水期。该场景的风电、光伏日前预测数据和日内

超短期预测数据如附录A图A1(c)所示，二者全时段偏差较小，系统源荷功率较为平衡。

4.2　冗余约束快速辨识模型的性能比较与分析

4.2.1　数据集构建

根据4.1节所述算例系统及风电、光伏日前预测数据，首先生成大量满足所有安全约束的日前运行场景。在无安全约束越限的日前场景基础上，对风电、光伏日前预测数据叠加扰动模拟日内超短期预测偏差，并判断扰动后发生越限的安全约束。若安全约束发生越限记为真，反之则为未生效冗余约束记为假，生成包含冗余安全约束标签的样本。共生成14 400条带标签的样本，划分训练集、验证集、测试集的比值为8∶1∶1。

4.2.2　模型训练与性能分析

为防止模型出现过拟合，通过学习率调度器每轮训练逐步降低学习率，并在每轮训练后用验证集验证损失，将验证集中损失率最低的模型作为输出模型。经过200轮训练后，输出模型的训练集损失$L_{\text{train}}=0.029\,9$，验证集损失$L_{\text{val}}=0.034\,3$。

对于模型辨识效果，采用准确率、召回率、冗余约束辨识率与平均辨识时间来评价辨识效果，冗余约束辨识率即为所辨识削减的冗余安全约束占全部考虑的安全约束中的百分比，平均辨识时间即为辨识单个测试样本所需的平均时间。采用单GCN模型与单LSTM网络模型作为本文模型的对比方法，采用样本测试集测试，各指标结果如表2所示。

表2　样本测试结果
Table 2　Test results of samples

模型	准确率/%	召回率/%	冗余约束辨识率/%	平均辨识时间/ms
本文模型	96.42	93.56	88.44	95.6
GCN	90.52	85.32	67.35	56.4
LSTM网络	87.46	79.16	70.87	63.5

根据表2可知，本文模型相较于单GCN模型与单LSTM网络模型在前3项指标方面均有不同程度的提升，这是由于模型数据集同时在时间和空间上都具备耦合性，单GCN模型能够提取出节点之间的依赖关系和拓扑结构特征，但无法处理时序依赖关系，单LSTM网络模型则相反。本文提出的GCN-LSTM模型则结合了GCN和LSTM网络的优势，能够同时捕捉数据的空间和时间特征，更全面地理解数据的复杂性，从而获得更优辨识效果。而在平均辨识时间方面，尽管GCN-LSTM模型由于模型复杂度相较GCN模型和LSTM网络模型有所提升，其辨识时间有所增长，但其所需时间仍处在毫秒级，符合冗余约束快速辨识要求。

4.2.3　模型有效性分析

为验证本文提出的冗余约束快速辨识模型的有效性，选取场景1～3中的时段45～61进行16轮前瞻滚动计算，对比约束削减前后前瞻鲁棒模型求解所得实施调度方案的差异。场景1约束削减前后各资源调度计划如图4所示，场景2、3中各资源调度计划如附录A图A2所示。场景1～3计算所得目标函数的值与计算时间如表3所示。

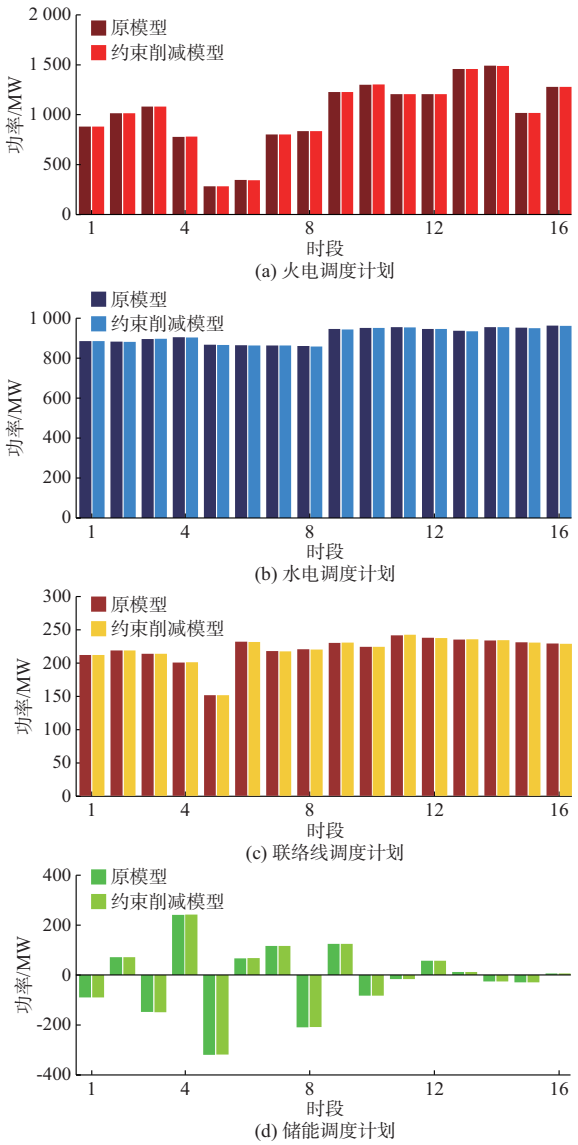

图4　场景1的可控资源调度方案
Fig. 4　Controllable resource dispatch plan in scenario 1

根据图4、表3可知，模型约束削减前后3种场景下目标函数值的差异都处在0.1%范围以内，各场景中约束削减前后所得各可调资源的调度方案也无明显差异。同时，相较于原模型，约束削减后模型的求解速度在3种场景下平均提升了41%，提高了

表3　冗余约束辨识模型有效性分析
Table 3　Effectiveness analysis of redundant constraint identification model

场景编号	目标函数值		计算时间/s	
	已削减	未削减	已削减	未削减
1	12 603.5	12 603.5	47.42	78.61
2	14 456.6	14 456.3	50.97	90.54
3	7 102.1	7 101.9	42.95	65.33

模型的计算效率。这一结果表明，冗余约束辨识模型能在不影响模型优化求解一致性的前提下，提高模型的计算效率，缩短模型求解所需时间。

4.3　前瞻鲁棒决策方法有效性分析

4.3.1　优化调度结果分析

场景1中优化调度源荷平衡结果见图5(a)，火电、外部联络线调度资源在本文调度策略(以下统称前瞻计划)下的出力情况与日前计划的对比见图5(b)。场景2、3中对应的优化调度结果见附录A图A3。所有场景中线路潮流均未产生越限。

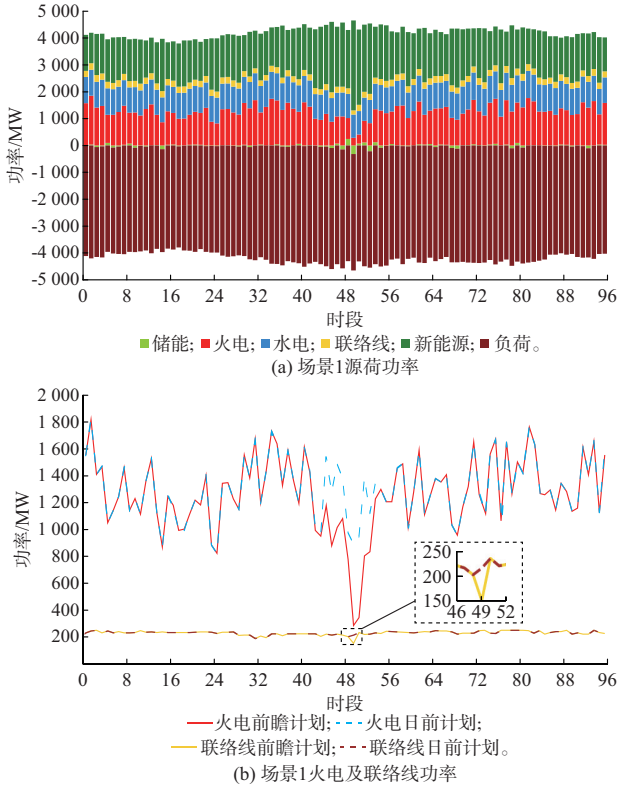

图5　场景1调度结果
Fig. 5　Dispatch results in scenario 1

根据图5、附录A图A3所示优化调度结果可知，当时间处于场景1中的时段0～43和时段53～95与场景2中的时段0～39和时段52～95时，由于风电/光伏出力日内超短期预测与日前预测的偏差较小，通过设定前瞻鲁棒模型目标函数中各类资源的调节代价，系统可以优先利用具有较高调度灵活性的水电和储能资源来有效平衡功率偏差。在这两个时段内，火电和联络线的出力则严格遵循日前计划，不进行额外调整；当时间处于场景1中的时段43～53与场景2中的时段39～52时，风电、光伏出力的日内预测和日前预测的偏差较大，仅通过系统中的水电和储能资源无法平衡功率波动，由此前瞻计划调度火电偏离日前计划，调整出力以平衡系统功率。同时，当场景1中风电/光伏出力偏差达到最大值时，由于该场景下水电处于枯水期，调节性能较弱，火电、水电和储能资源仍不足以平衡波动，联络线也偏离日前计划参与系统调节。而对于场景3，其风电/光伏出力日前预测与日内超短期预测全时段差距较小，前瞻计划仅通过调控系统中的储能和水电即可应对新能源预测偏差产生的功率波动，系统中的火电和联络线则可严格按照日前计划出力，以获得最优经济性。

场景1～3中，日前计划和前瞻计划所产生的系统总成本如表4所示。

表4　日前计划和前瞻计划所产生的成本对比
Table 4　Comparison of costs generated by day-ahead plan and look-ahead plan

场景编号	调度方案	弃电或切负荷成本/元	系统运行成本/万元	调节成本/元	总成本/万元
1	日前计划	70 865.2	150.6		157.7
	前瞻计划		152.6	12 153.6	153.8
2	日前计划	90 652.3	112.5		121.6
	前瞻计划		114.2	10 325.8	115.2
3	日前计划		78.8		78.8
	前瞻计划		79.2	5 032.5	79.7

根据表4可知，在场景1、2中，面对日内风电/光伏出力显著偏差所导致的系统功率严重波动，日前计划下系统灵活性调度资源的承受能力不足，无法满足系统功率平衡需求，被迫采取了弃电/切负荷措施，并产生了大量额外成本；前瞻计划则通过对多个时段不断进行滚动鲁棒优化，为可能到来的极端场景预留充足的调节空间，仅利用第1阶段调节资源即可平抑波动，无须再进行弃电/切负荷操作。尽管仍会因为对各资源的再调度产生额外成本，前瞻计划对系统消纳保供能力的提升使得系统的总运行经济性更优。而在场景3这一非极端运行场景下，前瞻计划为平抑日内预测偏差带来的不平衡功率对日前计划进行了修正，以及为应对可能到来的新能源极端运行场景预留了更多的调节裕度，使得系统的运行成本相较日前计划有所上升。

4.3.2 求解效率验证

本文选取目标函数值、迭代次数和计算时间作为性能指标，采用Benders分解法作为两阶段鲁棒模型求解的对比方法，并对比相应求解算法下是否进行约束削减的性能差异。对场景1~3进行全天前瞻滚动计算，并采用每轮计算中各项性能指标的平均值作为结果，各方法的计算结果如表5所示。

表5 各场景下的计算效果对比

Table 5 Comparison of calculation effect in each scenario

优化算法	场景1				场景2				场景3			
	是否削减	目标函数值	迭代次数	计算时间/s	是否削减	目标函数值	迭代次数	计算时间/s	是否削减	目标函数值	迭代次数	计算时间/s
列与约束生成	是	10 054.8	5	45.43	是	11 030.1	5	46.46	是	6 799.5	4	39.56
	否	10 054.8	9	82.13	否	11 029.9	8	83.12	否	6 799.5	6	65.21
Benders分解	是	10 053.4	8	73.75	是	11 031.1	8	74.37	是	6 799.8	7	58.67
	否	10 053.4	16	127.23	否	11 031.3	13	122.58	否	6 800.1	10	94.83

根据表5可知，在目标函数值上，各算法的优化效果十分接近，而在计算时间与迭代次数方面，约束削减后的模型相较于未经削减的模型在这两项指标上对于两种算法都存在较大提升。而在相同条件下，列与约束生成算法则相较于Benders分解法的求解效率更高，这是由于相较于Benders分解法直接将子问题最优解对应的Benders割传入主问题，列与约束生成算法仅将求解子问题得到的最恶劣场景传入，并在主问题中新增该场景下子问题相关的变量和约束，这可以有效降低迭代次数，提升计算效率。

5 结语

本文考虑了极端运行场景下风电和光伏不确定预测误差对系统功率平衡的影响，建立水电、火电、储能及联络线多资源协同优化的两阶段鲁棒调度模型，提出了基于GCN-LSTM的冗余约束快速辨识模型，构建了基于冗余约束快速辨识的电力系统前瞻调度鲁棒决策方法。分析结果表明：

1)所提出的冗余约束快速辨识模型能够快速有效地辨识优化模型中的冗余约束，在不影响优化模型结果一致性的前提下，提升模型的求解效率。

2)所提出的前瞻鲁棒决策方法在面对极端运行场景时，能够快速求解修正日前计划，有效地再调度各项资源，提升电力系统的新能源消纳能力和负荷保供能力，提高电力系统运行的安全性和经济性。

将基于冗余约束辨识的前瞻鲁棒决策方法推广到更大规模的主网系统，优化冗余约束辨识模型以进一步提升调度优化模型的求解效率，深入发掘电力系统中各调度资源协同控制的优势，将是下一步的工作重点。

附录见本刊网络版，点击http://www.aeps-info.com/aeps/article/abstract/20240427005，或扫描英文摘要后二维码，可阅读全文。

参考文献

[1] 林舜江，冯祥勇，梁炜焜，等.新能源电力系统不确定优化调度方法研究现状及展望[J].电力系统自动化，2024，48(10)：20-41.
LIN Shunjiang, FENG Xiangyong, LIANG Weikun, et al. Research status and prospect of uncertain optimal dispatch methods for renewable energy power systems[J]. Automation of Electric Power Systems, 2024, 48(10): 20-41.

[2] 黄馨仪，刘明波，林舜江，等.考虑风电不确定性的输配电系统鲁棒经济调度分布式算法[J].电力系统自动化，2025，49(4)：165-177.
HUANG Xinyi, LIU Mingbo, LIN Shunjiang, et al. Distributed algorithm for robust economic dispatch of integrated transmission and distribution system considering wind power uncertainty[J]. Automation of Electric Power Systems, 2025, 49(4): 165-177.

[3] PANTELI M, MANCARELLA P. Operational resilience assessment of power systems under extreme weather and loading conditions[C]// 2015 IEEE Power & Energy Society General Meeting, July 26-30, 2015, Denver, USA: 1-5.

[4] XIE L, CARVALHO P M S, FERREIRA L A F M, et al. Wind integration in power systems: operational challenges and possible solutions[J]. Proceedings of the IEEE, 2011, 99(1): 214-232.

[5] 吴孟雪，房方.计及风光不确定性的电-热-氢综合能源系统分布鲁棒优化[J].电工技术学报，2023，38(13)：3473-3485.
WU Mengxue, FANG Fang. Distributionally robust optimization of electricity-heat-hydrogen integrated energy system with wind and solar uncertainties[J]. Transactions of China Electrotechnical Society, 2023, 38(13): 3473-3485.

[6] 张智，周明，郭尊，等.考虑架空线路动态热定值的输电网与储能协同鲁棒规划方法[J/OL].中国电机工程学报：1-14[2024-07-20].http://kns.cnki.net/kcms/detail/11.2107.tm.20240401.1022.002.html.
ZHANG Zhi, ZHOU Ming, GUO Zun, et al. Coordinated robust planning method for transmission network and energy

storage considering dynamic thermal rating of overhead lines[J/OL]. Proceedings of the CSEE: 1-14[2024-07-20]. http://kns.cnki.net/kcms /detail/ 11.2107.tm.20240401.1022.002.html.

[7] 刘一欣，郭力，王成山．微电网两阶段鲁棒优化经济调度方法[J]．中国电机工程学报，2018，38(14)：4013-4022.
LIU Yixin, GUO Li, WANG Chengshan. Economic dispatch of microgrid based on two stage robust optimization[J]. Proceedings of the CSEE, 2018, 38(14): 4013-4022.

[8] 李鸿，朱继忠，董瀚江．考虑协变量因素的多能微电网两阶段分布鲁棒优化调度[J/OL]．中国电机工程学报：1-12[2024-07-20]. http://kns. cnki. net/kcms/detail/11.2107. TM. 20240507.2003.012.html.
LI Hong, ZHU Jizhong, DONG Hanjiang. Two-stage distributionally robust optimization scheduling of multi-energy microgrid considering covariate factors[J/OL]. Proceedings of the CSEE: 1-12[2024-07-20]. http://kns.cnki.net/kcms/detail/11.2107.TM.20240507.2003.012.html.

[9] 邵嗣杨，马翔，袁伟，等．含电动汽车的不确定性微电网鲁棒优化调度方法[J]．电气工程学报，2023，18(2)：201-209.
SHAO Siyang, MA Xiang, YUAN Wei, et al. Robust optimal dispatching method for uncertain microgrid including electric vehicles[J]. Journal of Electrical Engineering, 2023, 18(2): 201-209.

[10] 王砚平，鲍威，李赢，等．考虑$N-1$故障的安全约束机组组合模型及约束削减方法[J]．电力自动化设备，2021，41(7)：167-175.
WANG Yanping, BAO Wei, LI Ying, et al. Security-constrained unit commitment model considering $N-1$ contingency and constraint reduction method[J]. Electric Power Automation Equipment, 2021, 41(7): 167-175.

[11] ZHAI Q Z, GUAN X H, CHENG J H, et al. Fast identification of inactive security constraints in SCUC problems[J]. IEEE Transactions on Power Systems, 2010, 25(4): 1946-1954.

[12] 郭瑞鹏，边麟龙，宋少群，等．安全约束最优潮流的实用模型及故障态约束缩减方法[J]．电力系统自动化，2018，42(13)：161-168.
GUO Ruipeng, BIAN Linlong, SONG Shaoqun, et al. Practical model of security constrained optimal power flow and reduction methods for contingency constraints[J]. Automation of Electric Power Systems, 2018, 42(13): 161-168.

[13] GUAN J Y, TANG H, WANG K, et al. A parallel multi-scenario learning method for near-real-time power dispatch optimization[J]. Energy, 2020, 202: 117708.

[14] LV K, TANG H, BAK-JENSEN B, et al. Hierarchical learning optimisation method for the coordination dispatch of the inter-regional power grid considering the quality of service index[J]. IET Generation, Transmission & Distribution, 2020, 14(18): 3673-3684.

[15] 王珂，姚建国，余佩遥，等．基于深度强化学习的电网前瞻调度智能决策架构及关键技术初探[J]．中国电机工程学报，2022，42(15)：5430-5439.
WANG Ke, YAO Jianguo, YU Peiyao, et al. Architecture and key technologies of intelligent decision-making of power grid look-ahead dispatch based on deep reinforcement learning[J]. Proceedings of the CSEE, 2022, 42(15): 5430-5439.

[16] YORINO N, HAFIZ H M, SASAKI Y, et al. High-speed real-time dynamic economic load dispatch [J]. IEEE Transactions on Power Systems, 2012, 27(2): 621-630.

[17] LEW D, MILLIGAN M, JORDAN G, et al. Value of wind power forecasting[R]. Golden, USA: National Renewable Energy Lab (NREL), 2011.

[18] BERTSIMAS D, LITVINOV E, SUN X A, et al. Adaptive robust optimization for the security constrained unit commitment problem[J]. IEEE Transactions on Power Systems, 2013, 28(1): 52-63.

[19] WANG C S, JIAO B Q, GUO L, et al. Robust scheduling of building energy system under uncertainty[J]. Applied Energy, 2016, 167: 366-376.

[20] 吕崇帅．含风光水储电源的电力系统优化调度研究[D]．哈尔滨：哈尔滨工业大学，2016.
LÜ Chongshuai. Research on optimization scheduling of power systems with wind, photovoltaic, hydro, and storage energy sources[D]. Harbin: Harbin Institute of Technology, 2016.

[21] 辛禾．考虑多能互补的清洁能源协同优化调度及效益均衡研究[D]．北京：华北电力大学，2019.
XIN He. Research on coordinated optimization scheduling and benefit balance of clean energy considering multi-energy complementarity[D]. Beijing: North China Electric Power University, 2019.

[22] 徐伟宣，何建秋，邹庆云．目标函数带绝对值号的特殊非线性规划问题[J]．优选与管理科学，1987，(3)：9-13.
XU Weixuan, HE Jianqiu, ZOU Qingyun. Special nonlinear programming problems with absolute values in the objective function [J]. Optimization and Management Science, 1987, (3): 9-13.

[23] FLOUDAS C A. Nonlinear and mixed-integer optimization fundamentals and applications [J]. Journal of Global Optimization, 2000, 12(1): 108-110.

[24] ZENG B, ZHAO L. Solving two-stage robust optimization problems using a column-and-constraint generation method[J]. Operations Research Letters, 2013, 41(5): 457-461.

[25] AGARWAL D, SINGH P, EL SAYED M A. The Karush-Kuhn-Tucker (KKT) optimality conditions for fuzzy-valued fractional optimization problems [J]. Mathematics and Computers in Simulation, 2023, 205: 861-877.

[26] WANG Y, ZHAO S Q, ZHOU Z, et al. Risk adjustable day-ahead unit commitment with wind power based on chance constrained goal programming [J]. IEEE Transactions on Sustainable Energy, 2017, 8(2): 530-541.

王麒宁(2001—)，男，博士研究生，主要研究方向：电力系统优化调度。E-mail：wangqining@whu.edu.cn

陈思远(1993—)，男，博士，主要研究方向：人工智能在电力系统运行与控制中的应用。E-mail：wddqcsy@whu.edu.cn

徐　箭(1980—)，男，通信作者，博士，教授，博士生导师，主要研究方向：柔性负荷调度与控制、新型电力系统运行与控制、综合能源系统建模分析与运行控制。E-mail：xujian@whu.edu.cn

（编辑　鲁尔姣）

Robust Decision-making Method for Look-ahead Dispatch in Power System Based on Fast Identification of Redundant Constraints

WANG Qining[1], *CHEN Siyuan*[1], *XU Jian*[1], *CHEN Yiping*[2], *YAN Rong*[3], *GUO Yan*[3]

(1. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China;
2. Southern Power Grid New Energy System (Beijing) Research Institute Co., Ltd., Beijing 102218, China;
3. Power Dispatch and Control Center of China Southern Power Grid, Guangzhou 510663, China)

Abstract: To address the electric power balance issues in systems caused by intraday power deviations of renewable energies, power dispatch departments require minute-level revisions to the day-ahead plans from a look-ahead perspective. Therefore, a robust decision-making method for the look-ahead dispatch in power system is proposed based on the fast identification of redundant constraints. The method improves the renewable energy accommodation rate and supply capacity of the power system in extreme operation scenarios while ensuring efficient solving in a short time. First, in the look-ahead dispatch decision-making mode, a two-stage optimization model is constructed considering the uncertainty of wind and photovoltaic power, along with the coordinated control of multiple resources such as hydro, thermal, storage, and tie-lines. The first stage considers the economy and safety of the system, while the second stage considers the renewable energy accommodation and power supply guarantee. Furthermore, considering the model complexity added by the uncertainty of renewable energy, an identification and reduction method for redundant constraints based on graph convolution neural network and long short-term memory network is proposed, followed by a robust optimization solution for the reduced look-ahead dispatch model using column and constraint generation algorithm. Finally, the effectiveness of the proposed model for the fast identification of redundant constraints is validated through numerical results in the IEEE 118-bus system, and the proposed robust decision-making method can efficiently solve look-ahead dispatch strategies in various types of scenarios.

This work is supported by National Key R&D Program of China (No. 2022YFB2403500).

Key words: renewable energy; decision-making; extreme operation scenario; look-ahead dispatch; redundant constraint; graph convolution neural network; long short-term memory network; robust optimization