

基于 mRMR 与多级 LSTM 网络的火电机组响应 AGC 调控能力评估

郝晓光¹, 金飞¹, 张庆浩², 张文彬¹

(1. 国网河北能源技术服务有限公司, 河北 石家庄 050021; 2. 华北电力大学 控制与计算机工程学院, 北京 102206)

摘要:为准确预测火电机组响应自动发电控制 (Automatic Generation Control, AGC) 调控的能力, 提出一种基于特征提取和多级深度学习的火电机组响应 AGC 调控效果的 mRMR-mLSTM 预测模型: 首先, 采用最大相关最小冗余算法 (Minimum Redundancy Maximum Relevance, mRMR) 对机组运行数据进行特征提取, 获得影响 AGC 调控效果的相关变量集以提高建模效率; 其次, 采用多级长短期记忆神经网络模型 (Multi-stage Long Short Term Memory, mLSTM) 对实发功率进行预测, 得到未来一段时间的功率曲线图, 结合功率指令曲线计算 AGC 调节能力指标; 最后, 使用某 600 MW 机组实际运行数据进行验证, 预测偏差在 10 MW 以内。结果表明: 本文所提模型的预测精度相较于未进行特征提取的模型和单一 LSTM 模型分别提高了 21% 和 40%, 证明该模型可精确评估深度调峰下火电机组响应 AGC 调控的能力。

关键词: 火电机组; 自动发电控制; 响应能力预测; 最大相关最小冗余法; 长短期记忆神经网络

中图分类号: TM74 文献标识码: A DOI: 10.16146/j.cnki.mdlgc.2024.05.007

[引用本文格式] 郝晓光, 金飞, 张庆浩, 等. 基于 mRMR 与多级 LSTM 网络的火电机组响应 AGC 调控能力评估[J]. 热能动力工程, 2024, 39(5): 57-64. HAO Xiaoguang, JIN Fei, ZHANG Qinghao, et al. Assessment of AGC regulation capability of thermal power units based on mRMR and multi-level LSTM networks[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(5): 57-64.

Assessment of AGC Regulation Capability of Thermal Power Units based on mRMR and Multi-level LSTM Networks

HAO Xiaoguang¹, JIN Fei¹, ZHANG Qinghao², ZHANG Wenbin¹

(1. State Grid Hebei Energy Technology Service Co., Ltd., Shijiazhuang, China, Post Code: 050021;

2. School of Control and Computer Engineering, North China Electric Power University, Beijing, China, Post Code: 102206)

Abstract: In order to accurately predict the automatic generation control (AGC) regulation capability of thermal power units, this paper proposed a mRMR-mLSTM prediction model based on feature extraction and multi-stage deep learning for thermal power units to respond to the effect of AGC regulation. Firstly, the minimum redundancy maximum relevance (mRMR) algorithm was used to extract features from the unit operation data to obtain the relevant variable set affecting the effect of AGC regulation in order to improve the modeling efficiency; secondly, the actual power was predicted by using the multi-stage long short term memory (mLSTM) neural network model, to obtain the power curve for the future period of time and to compute the indexes of the AGC regulation capability combining with the power command curve; finally, the actual operating data of a 600 MW unit were used to verify the prediction deviation was within

收稿日期: 2023-05-16; 修订日期: 2023-06-06

基金项目: 国网河北省电力有限公司科技项目 (TSS202104)

Fund-supported Project: Technology Project of State Grid Hebei Electric Power Co., Ltd. (TSS202104)

作者简介: 郝晓光 (1980-), 男, 国网河北能源技术服务有限公司正高级工程师。

10 MW. The results show that the prediction accuracy of the model proposed in this paper is 21% and 40% higher than that of the model without feature extraction and the single LSTM model, respectively, which proves that the model can accurately assess the AGC regulation capability of thermal power units under deep peak shaving.

Key words: thermal power units, automatic generation control, responsiveness forecasting, mRMR, LSTM

引 言

为了实现能源的绿色低碳发展,我国政府提出“碳达峰、碳中和”发展战略,电力行业也不断进行能源结构调整。在大量不确定性、波动性新能源电力接入电网的背景下,机组响应自动发电控制的效果直接影响着电网的调节能力。由于深度调峰工况的需要,电网对火电机组的协调控制能力提出了更高的要求。因此,实现对燃煤火电机组响应 AGC 调控能力的精确预测对评估及保障电网系统运行的安全性都具有重要意义^[1-3]。

燃煤火电机组 AGC 调节能力与机组的协调控制系统密切相关。文献[4]通过现场试验的方法,依据电厂实际运行情况判断机组的 AGC 控制效果,但是现场试验过程较为繁琐,同时会影响正常的生产过程;文献[5]提出一种对比 AGC 机组实际调节曲线和标准曲线进行定性分析的模糊评价方法,较之现场试验过程更为简便,但该方法未充分考虑机组的动态特性,且难以避免噪声和死区干扰;文献[6]提出一种可自动划分静态、动态响应阶段的基于趋势提取的 AGC 性能评价方法,解决了模糊评价方法易受噪声影响计算不精确的问题,弥补了在目标负荷附近无法计算性能评价指标的缺点。

考虑到火电机组运行过程的不确定性和非线性,有研究采用神经网络模型预测机组响应 AGC 调控的能力。文献[7]将传统预测控制的优化策略与神经网络相结合,基于 BP(Back Propagation)神经网络提出了一种新的系统拟合算法,由于其未考虑变量及特征的筛选,易导致网络训练时间长及预测精度不高;文献[8]提出了一种最大相关最小冗余算法(Minimum Redundancy Maximum Relevance, mRMR)并进行特征提取,降低了变量间的冗余性,预测结果的平均绝对百分误差降低到了 10% 以内;文献[9]提出了一种基于 AGC 指令预测的火电机

组出力曲线预测方法,为机组安全稳定调节提供有效保障;文献[10]采用长短期记忆神经网络(Long Short Term Memory, LSTM)对火电机组性能进行评价,相较于 BP 网络预测结果更加精准稳定,但仍未考虑特征选择问题。

在上述研究基础上,本文提出一种基于特征筛选和多级神经网络的火电机组响应 AGC 调控能力的预测模型(mRMR-mLSTM)。首先,为提高模型训练速度,采用 mRMR 法对输入变量进行精简筛选,提高模型的训练效率;其次,为了准确描述机组动态特性并提高预测精准度,采用 mLSTM 神经网络作为模型框架,利用机组 AGC 功率指令序列分别实现对主蒸汽流量、主蒸汽压力、阀门开度的预测,再利用上述变量的预测值进一步得到实发功率;同时,结合电网发布的《发电厂并网运行管理实施细则》和《并网发电厂辅助服务管理实施细则》(以下简称“两个细则”),实现对机组 AGC 调节能力的评估。

1 理论基础

1.1 mRMR 特征选择理论

最大相关最小冗余法(mRMR)是一种过滤式的特征选择算法,其评价函数同时考虑了特征与类别、特征与特征之间的相关性,所筛选出的数据集可在保证数量最小的情况下最大限度地保留数据之间的相关性联系特征^[11]。该算法采用互信息衡量变量之间的相关性,两个变量的互信息表示为:

$$I(M;N) = \iint P(m,n) \log \left(\frac{P(m,n)}{P(m)P(n)} \right) dmdn \quad (1)$$

式中: M, N —两个特征变量; $P(m), P(n)$ —相应变量的边际概率函数; $P(m,n)$ —联合概率分布。

考虑所选特征子集的相关性和冗余性,设特征与类别之间相关性的度量值为 D ,特征与特征之间冗余度的度量值为 R ,得到 mRMR 特征选择算法的评价函数为:

$$\begin{cases} \max J(D, R) \\ J = D - R \end{cases} \quad (2)$$

方程(2)可通过逐渐增加单个变量来求解。假设集合 S 为全部特征集, S_{t-1} 为已经选出的具有 $t-1$ 个特征的特征集, 再从特征集合 S 中选择与 S_{t-1} 特征集合中元素不相同的第 t 个特征, 使上式最大化, 即通过式(3)最大化单变量相关性和冗余度的差值来确定添加的第 t 个特征^[12]。

$$\max_{f_i \in S - S_{t-1}} [I(f_i, c) - \frac{1}{t-1} \sum_{f_j \in S_{t-1}} I(f_i, f_j)] \quad (3)$$

式中: f_i —第 i 个特征; c —目标类别; $I(f_i, c)$ —特征 i 和目标类别 c 之间的互信息; $I(f_i, f_j)$ —特征 i 和特征 j 之间的互信息。

1.2 LSTM 神经网络模型

长短期记忆神经网络(LSTM)在循环神经网络(RNN)的基础上增加了 3 个逻辑控制门单元, 可通过逻辑控制来决定需要遗忘的数据, 对目标数据进行继续更新, 克服了 RNN 权重影响过大、容易产生梯度爆炸和梯度消失的问题, 能够有效提高电力负荷的预测精度^[13-17]。LSTM 神经网络结构如图 1 所示。




图 1 LSTM 神经网络结构图

Fig. 1 LSTM neural network structure diagram

每一个 LSTM 单元均有 1 个元组, 可被视为 LSTM 的记忆单元。在 t 时刻每个记忆单元有当前时刻记忆单元的输入值 x_t 和上一时刻记忆单元的输出值 h_{t-1} 、上一时刻的记忆单元状态 c_{t-1} 3 个输入, 有当前时刻记忆单元的输出值 h_t 和当前时刻记忆单元状态 c_t 两个输出。

LSTM 可通过输入门 i_t 、输出门 o_t 和遗忘门 f_t 3 个门对每个记忆单元内的信息进行读取和修改, 遗忘门决定上一时刻的单元状态 c_{t-1} 有多少保留到当前时刻, 输入门决定当前时刻网络的输入 x_t 有多

少保存到单元状态; 输出门控制单元状态 c_t 有多少输出到 LSTM 的当前输出值 h_t 。

LSTM 层可以根据上一时刻的网络输出和当前时刻的网络输入联合计算此时的单元状态更新值 $\tilde{c}_t$, 进而结合遗忘门与输入门计算当前的单元状态 c_t , 计算方法为:

$$\begin{cases} \tilde{c}_t = \tanh(\mathbf{w}_c[h_{t-1}, x_t] + b_c) \\ c_t = f_t c_{t-1} + i_t \tilde{c}_t \end{cases} \quad (4)$$

式中: $\mathbf{w}_c$ —权重矩阵; b_c —偏置项, 由网络训练时自行学习优化得到最佳值。

此时, 单元状态有两个流向。一是作为长期信息特征, 在反馈结构中传入下一时刻的 LSTM 层; 二是与 $\tanh$ 函数结合, 并与输出门的结果相乘得到当前时刻的预测结果, 即 $h_t = o_t \tanh(c_t)$, h_t 为网络最终输出。

2 AGC 调节能力预测模型构建

2.1 数据预处理

建立模型前首先要收集所需要的发电机组历史运行数据, 经过处理后才能作为模型的输入输出参量。选取 AGC 参与调节的时段数据, 尽量减少非调节时段数据的干扰, 然后对数据进行异常点检测并删除, 填补空缺点数据^[18]。根据实际电厂中 AGC 的调节过程时间来选定时间尺度, 对数据做好划分^[19]。

2.2 输入、输出变量选取

模型训练需要合适的输入输出变量, 才能准确预测 AGC 调节能力。采集与 AGC 调节能力相关性较大的数据, 包括主蒸汽压力 p 、主蒸汽温度 T 、主蒸汽流量 g 、高压缸排汽压力 p_g 、调节级温度 T_0 、调节级压力 p_a 、综合阀位指令 R_f 、阀门开度 r 、功率指令 P_{AGC} 、转速 n 和实发功率 W , 通过 mRMR 算法对这些参数进行相关度排序^[20]。由于 AGC 调节评价指标与实发功率直接相关, 因此将实发功率作为目标参量进行相关度测量, 各参数与实发功率的相关度分数排序结果如图 2 所示。相关度分数越高, 说明该参数对实发功率的影响越大, 作为模型的输入输出参数预测效果会更好。结合工程经验, 最终选用相关度分数大于 0.35 的参数作为输入输出变量。

将功率指令作为一级网络的输入变量,主蒸汽流量、主蒸汽压力和阀门开度作为一级网络的输出变量,同时也是二级网络的输入变量,实发功率作为二级网络的输出变量。




图2 变量相关度排序图

Fig.2 Variable correlation ranking chart

2.3 预测模型构建

为了考查机组对不同 AGC 指令的响应能力,将 AGC 指令序列作为已知量,根据 AGC 调度指令的响应过程,机组调节能力预测模型采用两级预测方式构建来提高预测精度。其中,在模型第 1 级中由 AGC 指令预测未来时刻的主蒸汽压力、阀门开度和主蒸汽流量;在模型第 2 级中,将未来时刻的主蒸汽压力、阀门开度和主蒸汽流量作为输入来预测对应的实发功率值。

当 AGC 指令下达后,主蒸汽压力、阀门开度和主蒸汽流量响应过程与历史时刻值有关。因此,可将历史时刻主蒸汽压力、阀门开度、主蒸汽流量和 AGC 指令共同作为模型第 1 级输入,预测过程如式(5)~式(7)所示。

$$\begin{cases} \hat{p}_t = f_{LSTM1}(P_{AGCt-2}, P_{AGCt-1}, p_{t-2}, p_{t-1}) \\ \hat{p}_{t+1} = f_{LSTM1}(P_{AGCt-1}, P_{AGCt}, p_{t-1}, \hat{p}_t) \\ \dots \\ \hat{p}_{t+T} = f_{LSTM1}(P_{AGCt+T-2}, P_{AGCt+T-1}, \hat{p}_{t+T-2}, \hat{p}_{t+T-1}) \end{cases} \quad (5)$$

$$\begin{cases} \hat{r}_t = f_{LSTM2}(P_{AGCt-2}, P_{AGCt-1}, r_{t-2}, r_{t-1}) \\ \hat{r}_{t+1} = f_{LSTM2}(P_{AGCt-1}, P_{AGCt}, r_{t-1}, \hat{r}_t) \\ \dots \\ \hat{r}_{t+T} = f_{LSTM2}(P_{AGCt+T-2}, P_{AGCt+T-1}, \hat{r}_{t+T-2}, \hat{r}_{t+T-1}) \end{cases} \quad (6)$$

$$\begin{cases} \hat{g}_t = f_{LSTM3}(P_{AGCt-2}, P_{AGCt-1}, g_{t-2}, g_{t-1}) \\ \hat{g}_{t+1} = f_{LSTM3}(P_{AGCt-1}, P_{AGCt}, g_{t-1}, \hat{g}_t) \\ \dots \\ \hat{g}_{t+T} = f_{LSTM3}(P_{AGCt+T-2}, P_{AGCt+T-1}, \hat{g}_{t+T-2}, \hat{g}_{t+T-1}) \end{cases} \quad (7)$$

式中: t —当前时刻; T —要预测的最大时刻($T \geq 2$);
 $\hat{p}_t, \hat{r}_t, \hat{g}_t$ —预测值。

当前时刻之前的主蒸汽压力值序列 $[p_{t-2}, p_{t-1}]$ 和阀门开度值序列 $[r_{t-2}, r_{t-1}]$ 、主蒸汽流量值序列 $[g_{t-2}, g_{t-1}]$ 可通过采集数据得到,当前时刻及之后的序列通过式(5)~式(7)预测得到,AGC 指令值序列 $[P_{AGCt-1} \sim P_{AGCt+T-1}]$ 为已知给定值。

在第 1 级 LSTM 网络中预测得到 3 个中间变量主蒸汽压力 p 、阀门开度 r 和主蒸汽流量 g ,再将其作为下一级 LSTM 网络的输入变量来预测最终的实发功率:

$$\begin{cases} \hat{W}_t = f_{LSTM4}(\hat{p}_{t-1}, \hat{r}_{t-1}, \hat{g}_{t-1}, \hat{p}_t, \hat{r}_t, \hat{g}_t) \\ \hat{W}_{t+1} = f_{LSTM4}(\hat{p}_t, \hat{r}_t, \hat{g}_t, \hat{p}_{t+1}, \hat{r}_{t+1}, \hat{g}_{t+1}) \\ \hat{W}_{t+T} = f_{LSTM4}(\hat{p}_{t+T-1}, \hat{r}_{t+T-1}, \hat{g}_{t+T-1}, \hat{p}_{t+T}, \hat{r}_{t+T}, \hat{g}_{t+T}) \end{cases} \quad (8)$$

预测模型原理如图 3 所示。第 1 级网络中利用给定的 AGC 指令序列 $[P_{AGCt-2} \sim P_{AGCt+T-1}]$ 、历史数据中主蒸汽压力值序列 $[p_{t-2}, p_{t-1}]$ 、阀门开度值序列 $[r_{t-2}, r_{t-1}]$ 和主蒸汽流量序列 $[g_{t-2}, g_{t-1}]$ 分别预测未来时刻的主蒸汽压力值序列 $[\hat{p}_t \sim \hat{p}_{t+T}]$ 、阀门开度值序列 $[\hat{r}_t \sim \hat{r}_{t+T}]$ 和主蒸汽流量值序列 $[\hat{g}_t \sim \hat{g}_{t+T}]$;第 2 级网络中,用所预测的主蒸汽压力值序列、阀门开度值序列、主蒸汽流量值序列得到未来时刻的实发功率预测值 $[\hat{W}_t \sim \hat{W}_{t+T}]$,以此表征机组响应 AGC 指令的调控能力。

2.4 响应能力评价

依据“两个细则”标准,计算表征 AGC 调节能力的 3 个指标:响应时间(s)、调节速率(MW/min)和调节精度(MW)^[21-23]。图 4 为机组 AGC 出力的过程曲线,响应死区为机组额定容量的 1%,调节死区为机组额定容量的 0.5%。

响应时间为图 4 中机组从 P_0 升出力到 P_1 所用的时间:

$$t = t_1 - t_0 \quad (9)$$




图 3 模型预测原理图

Fig. 3 Schematic diagram of model prediction




图 4 AGC 出力过程

Fig. 4 AGC output process

调节速率指机组在 AGC 指令方向,出力越过响应死区到进入调节死区这段时间的速率,即图 4 中 $t_1 \sim t_2$ 或 $t_3 \sim t_4$ 两段时间内机组的调节速率 v ,以升出力为例,计算方法为:

$$v = \frac{P_2 - P_1}{t_2 - t_1} \quad (10)$$

调节精度指在一时段内,对实际出力与功率指令之差的绝对值进行积分(结果如图中阴影部分),然后用积分值除以积分时间,即为该时段的调节精度,计算方法为:

$$\Delta P = \frac{\int_{t_2}^{t_3} |P(t) - P_e| dt}{t_3 - t_2} \quad (11)$$

式中: ΔP —调节精度; $P(t)$ —机组实际出力; P_e —AGC 指令值。

2.5 AGC 调节能力预测流程

mRMR-mLSTM 预测模型网络流程如图 5 所示。采集的运行数据经过处理后使用 mRMR 法对其进行相关度排序,选择合适的变量作为 LSTM 网络的输入输出量,训练网络,计算相应的评价指标。

3 实例分析

以某 600 MW 超临界火电机组为例,使用该机组在深度调峰工况进行 AGC 调节实验,采集相关的机组运行数据,采样时间间隔为 1 s,剔除运行故障等异常数据,得到如图 6 所示的 AGC 调节数据。图 6 中,共 2 138 个样本,包含 3 次升/降负荷的过程。其中:第 1 ~ 第 221 个样本为升 10 MW 过程,第 376 ~ 第 573 个样本为降 10 MW 过程;第 720 ~ 第 980 个样本为升 30 MW 过程,第 1 053 ~ 第 1 274 个样本为降 30 MW 过程;第 1 343 ~ 第 1 650 个样本为升 50 MW 过程,第 1 738 ~ 第 2 138 个样本为降 50 MW 过程。预测功率的时间尺度设定为 1 次升/降负荷的时间段。




图5 mRMR-mLSTM 网络流程图

Fig.5 Flowchart of mRMR-mLSTM network




图6 AGC 调节数据

Fig.6 AGC regulation data

采用 Z-score 标准化法对数据进行处理,使其符合标准正态分布,即均值为 0,标准差为 1,数据处理函数为:

$$x' = \frac{x - \mu}{\sigma} \tag{12}$$

式中: x' —归一化后的数据; μ —样本均值; σ —样本标准差。

将升/降 10 MW、升/降 30 MW、升 50 MW 的 AGC 调节过程数据作为训练集,用以训练 LSTM 神经网络,将降 50 MW 数据作为测试集,用以测试 AGC 能力辨识模型的预测精度。设置 LSTM 网络第 1 级预测主蒸汽压力、阀门开度和主蒸汽流量,设置 LSTM 网络第 2 级用于预测最终的实发功率值。为验证本文所提方法的精确性,分别采用单一 LSTM 网络以及 mLSTM 网络对火电机组响应 AGC 功率调节能力进行了预测。各模型功率预测结果和误差分别如图 7 和图 8 所示。可以看出:mRMR-mLSTM 模型的预测值曲线与实际值曲线近乎重合,采用 mRMR 法筛选模型变量使得参数选取更具科学性,采用 mLSTM 网络模型可以更大限度地模拟机组协调控制状况,LSTM 中每个记忆单元都会对数据进行评估和筛选,从而保证了预测的稳定性;汽轮机实发功率与模型预测值的绝对误差均在 10 MW 以内,证明该模型对于功率的预测较为准确;单一 LSTM 神经网络预测的功率结果与实际功率相差较大,这是由于单一模型不能很好地拟合机组的协调控制状况,预测误差达到 15 MW;mLSTM 神经网络较之单独 LSTM 网络精确度有所提高,但由于没有对输入输出变量进行相关度分析,导致预测精度不够,误差仍大于 mRMR-mLSTM 网络模型。




图7 各模型功率预测结果

Fig.7 Model power prediction result




图8 各模型功率预测误差

Fig.8 Model power prediction error

采用平均相对误差、均方根误差和归一化均方根误差为指标来衡量模型的辨识效果^[24-25]。各指标定义如下:

$$\text{ARE} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{W}_i - W_i|}{\bar{W}_{\max} - \bar{W}_{\min}} \times 100\%$$

(13)

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{W}_i - W_i)^2}$$

(14)

$$\text{NRMSE} = \frac{1}{\bar{W}} \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{W}_i - W_i)^2} \times 100\%$$

(15)

式中: $\bar{W}$ —实发功率的平均值; $W_{\max}, W_{\min}$ —实发功

率的最大值和最小值; n —测试集样本数量。

由表 1 可知,mRMR-mLSTM 模型在训练集和测试集上的 ARE, RMSE 和 NRMSE 分别为 2.4%、0.22 MW、2.6%和 3.3%、0.34 MW、3.7%。为验证模型精度,对机组运行数据建立 LSTM 神经网络模型并与其进行对比。结果表明,mRMR-mLSTM 网络模型的误差明显低于 LSTM 网络模型以及 mLSTM 网络模型的误差,表明 mRMR-mLSTM 模型有较高的预测精度,预测效果良好。

表 1 模型的预测误差

Tab. 1 Prediction error of model

模 型	训练集			测试集		
	ARE/%	RMSE/MW	NRMSE/%	ARE/%	RMSE/MW	NRMSE/%
LSTM	3.5	0.41	3.8	3.8	0.49	4.9
mLSTM	3.3	0.34	3.5	3.4	0.41	4.2
mRMR-mLSTM	2.4	0.22	2.6	3.3	0.34	3.7

图 9 为功率指令与功率预测值数据,对图 9 数据按式(9)~式(11)进行计算,得到该机组 AGC 响应时间为 25 s,调节速率为 1.88 MW/s,调节精度为 7.359 5 MW。




图 9 功率指令与功率预测值

预测结果的 ARE, RMSE 和 NRMSE 分别为 3.3%、0.34 MW 和 3.7%,预测结果较为准确。与 mLSTM 神经网络和单一 LSTM 神经网络预测结果进行对比,预测精度有显著提高。

参考文献:

[1] 王 焰. 电网自动发电控制(AGC)技术应用探讨[J]. 工业计量,2010,20(3):17-20.
WANG Yan. The exploration of application of automatic generation control (AGC) of power grid[J]. Industrial Measurement, 2010, 20(3):17-20.

[2] 李 俊,应光耀,包劲松,等. 改进型 630 MW 汽轮机低压缸宽负荷特性研究[J]. 汽轮机技术,2021,63(2):141-143,160.
LI Jun, YING Guangyao, BAO Jinsong, et al. Study on wide load characteristics of 630 MW improved turbine low pressure cylinder [J]. Turbine Technology, 2021, 63(2):141-143,160.

[3] 谢尉扬. 西门子超超临界汽轮机问题分析与改进[J]. 汽轮机技术,2015,57(2):86-88,150.
XIE Weiyang. Analysis and improvement of problems for Siemens ultra-supercritical turbine[J]. Turbine Technology, 2015, 57(2): 86-88,150.

[4] 杨凯翔,谢灵鸥,靳允立. 燃煤机组 30% 深度调峰全程自动控制技术开发与应用[J]. 自动化应用,2021(4):123-125.
YANG Kaixiang, XIE Lingou, JIN Yunli. Development and application of full-process automatic control technology for 30% deep peak

4 结 论

为了实现对火电机组响应 AGC 调控能力的评估,提出了一种基于 mRMR 与多级 LSTM 神经网络的 mRMR-mLSTM 预测模型。使用 mRMR 法对采集的数据与实发功率的相关性进行分析,挑选出合适的输入输出变量,利用 mLSTM 神经网络建立模型对响应 AGC 调控的能力进行预测。该模型实发功率的预测值和功率实际值偏差均在 10 MW 以内,模型

- shaving of coal-fired units[J]. Automation Application, 2021(4): 123–125.
- [5] 王淑娟. AGC 机组调节性能的模糊综合评价研究[D]. 大连: 大连理工大学, 2010.
- WANG Shujuan. A comprehensive method using fuzzy function for evaluating the performance of AGC units[D]. Dalian: Dalian University of Technology, 2010.
- [6] 崔世君, 王建东, 赵泽宁, 等. 基于趋势提取的火电机组负荷响应能力评价[J]. 山东科技大学学报(自然科学版), 2021, 40(1): 109–116.
- CUI Shijun, WANG Jiandong, ZHAO Zening, et al. Evaluation of load response capability of thermal power unit based on trend extraction[J]. Journal of Shandong University of Science and Technology (Natural Science Edition), 2021, 40(1): 109–116.
- [7] 陈 博, 钱 锋, 刘漫丹. 一种基于 BP 网络的预测控制算法及其应用[J]. 华东理工大学学报, 2003, 29(4): 400–404.
- CHEN Bo, QIAN Feng, LIU Mandan. A predictive control algorithm based on BP neural network and its application[J]. Journal of East China University of Science and Technology, 2003, 29(4): 400–404.
- [8] 钟劲松, 王少林, 冉 懿, 等. 基于互信息和 LSTM 的用户负荷短期预测[J]. 电力建设, 2022, 43(7): 96–102.
- ZHONG Jinsong, WANG Shaolin, RAN Yi, et al. Short-term consumer load forecasting based on mutual information and LSTM[J]. Electric Power Construction, 2022, 43(7): 96–102.
- [9] 邢 峰, 褚文超, 苏智东, 等. 基于 AGC 预测指令的火电机组控制策略[J]. 现代电力, 2023, 40(5): 742–750.
- XING Feng, CHU Wenchao, SU Zhidong, et al. A control strategy of thermal power unit based on AGC prediction command[J]. Modern Electric Power, 2023, 40(5): 742–750.
- [10] 罗雨颀. 基于 Hurst 指数的火电机组控制系统性能评价方法研究[D]. 北京: 华北电力大学, 2019.
- LUO Yuting. Performance assessment method of thermal power unit control system based on hurst exponent[D]. Beijing: North China Electric Power University, 2019.
- [11] 刘 岳, 于 静, 金秀章. 基于特征优化和改进长短期记忆神经网络的 NO_x 质量浓度预测[J]. 热力发电, 2021, 50(7): 162–169.
- LIU Yue, YU Jing, JIN Xiuzhang. NO_x mass concentration prediction based on feature optimization and improved LSTM network[J]. Thermal Power Generation, 2021, 50(7): 162–169.
- [12] 孙 林, 徐 枫, 王 振, 等. 基于标记权重和 mRMR 的多标记特征选择[J]. 山西大学学报(自然科学版), 2023, 46(1): 40–52.
- SUN Lin, XU Feng, WANG Zhen, et al. Multilabel feature selection using label weight and mRMR[J]. Journal of Shanxi University (Natural Science Edition), 2023, 46(1): 40–52.
- [13] 雷 萌, 吕 游, 魏 玮, 等. 基于 LSTM 神经网络与贝叶斯优化的电站风机故障预警[J]. 热能动力工程, 2022, 37(8): 213–220.
- LEI Meng, LYU You, WEI wei, et al. Fault warning of power plant fans based on long short-term memory neural network and Bayesian optimization[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(8): 213–220.
- [14] 刘立巍, 周建新, 刘培栋, 等. 基于 KNN-LSTM 的区域热负荷短期预测及在机组热电可行域的应用研究[J]. 热能动力工程, 2023, 38(3): 91–97.
- LIU Liwei, ZHOU Jianxin, LIU Peidong, et al. Short-term regional heat load prediction using KNN-LSTM and its application in CHP feasible operation region[J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(3): 91–97.
- [15] 金江涛, 许子非, 李 春, 等. 基于深度学习与支持向量机的滚动轴承故障诊断研究[J]. 热能动力工程, 2022, 37(6): 176–184.
- JIN Jiangtao, XU Zifei, LI Chun, et al. Research on rolling bearing fault diagnosis based on deep learning and support vector machine[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(6): 176–184.
- [16] 韩国栋, 曹云鹏, 王伟影, 等. 基于 LSTM 神经网络的燃气轮机排温预测方法[J]. 热能动力工程, 2022, 37(3): 28–34.
- HAN Guodong, CAO Yunpeng, WANG Weiyang, et al. Prediction method of gas turbine exhaust temperature based on LSTM neural network[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(3): 28–34.
- [17] 董渊博, 茅大钧, 章明明. 基于 CNN-LSTM 的燃气轮机 NO_x 排放预测研究[J]. 热能动力工程, 2021, 36(9): 132–138.
- DONG Yuanbo, MAO Dajun, ZHANG Mingming. Research on NO_x emission prediction of gas turbine based on CNN-LSTM[J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(9): 132–138.
- [18] 石志标, 陈长河, 曹丽华. 基于云 PSO-SVM 的汽轮机转子故障诊断研究[J]. 热能动力工程, 2018, 33(6): 41–47.
- SHI Zhibiao, CHEN Changhe, CAO Lihua. Study of the diagnosis of any fault occurred to the rotor of a steam turbine based on the cloud particle swarm optimization-supporting vector machine (CPSO-SVM)[J]. Journal of Engineering for Thermal Energy and Power, 2018, 33(6): 41–47.
- [19] 庄 伟, 康 磊, 孙安娜, 等. 火电机组 AGC 协调控制系统优化[J]. 发电设备, 2022, 36(4): 266–271.
- ZHUANG Wei, KANG Lei, SUN Anna, et al. Optimization of AGC coordination control system in a thermal power unit[J]. Power Equipment, 2022, 36(4): 266–271.