Vol.43 No.3 Mar. 2023

# 基于改进的 Transformer 神经网络辅助的 两阶段机组组合决策方法

武新章<sup>1</sup>,赵子巍<sup>1</sup>,代 伟<sup>1</sup>,谢代钰<sup>2</sup>,郭苏杭<sup>1</sup>,王泽宇<sup>1</sup>,张冬冬<sup>1</sup> (1. 广西大学 电气工程学院,广西 南宁 530004;2. 广西电网电力调度控制中心,广西 南宁 530023)

摘要:为了解决大规模电力系统机组组合的"维数灾"问题,提出基于Transformer神经网络的两阶段机组组合 决策方法,该方法兼顾求解精度与速度。在第一阶段,考虑机组组合时段耦合的特性,提出基于多头注意力 机制的特征向量构建方法,进而基于Transformer神经网络的全局视野与并行化优势,提出一种改进的 Transformer神经网络来预辨识机组启停值。在第二阶段,基于预辨识的机组状态设计置信度阈值,并将机组 启停判定可信度定义为启停可信与启停不可信状态,对于启停可信机组的状态进行直接确定,对于启停不可 信机组的状态,通过机组组合物理模型进行求解来保证求解的可行性。IEEE 30节点和IEEE 2383节点系统 的仿真结果验证了所提方法的有效性。

关键词:Transformer神经网络;深度学习;机组组合;数据驱动;特征构造中图分类号:TM73文献标志码:A

DOI:10.16081/j.epae.202209014

## 0 引言

机组组合是日前交易市场中的核心环节,也是 电力系统安全运行的重要保障。在电力市场出清 中,电力运营商需要在规定的时间内接受所有的投 标报价并提供最优的发电计划,仅能预留很短的时 间用于机组组合的结算<sup>[1]</sup>。机组组合本质上是非确 定性多项式(non-deterministic polynomial,NP)-hard 问题。在大规模电力系统中,机组组合的求解会出 现"维数灾"问题。如何高精度、快速求解大规模机 组组合问题是目前面临的一项挑战。

现有的机组组合优化求解方法主要分为启发式 算法、数学优化算法和智能优化算法。启发式算法 没有严格的理论依据,依靠直观判断或实际调度经 验寻找最优解,其典型方法主要有穷举法、优先顺序 法等。启发式算法应用简便,计算速度快,由于其性 能取决于具体问题和设计者经验,算法泛化能力弱, 求解稳定性较差<sup>[2]</sup>。数学优化算法是应用解析方法 对模型进行直接求解,具有理论基础及明确的物理 意义<sup>[3]</sup>。文献[4]利用分支定界法将离散空间组织 设定为树状结构分支进行求解,遍历搜索最优解,算 法求解时间较长。文献[5]应用动态规划法对机组 多时段优化过程进行分阶段寻优求解,其可有效压 缩求解空间,提升求解效率,但在求解大规模机组时

收稿日期:2022-04-15;修回日期:2022-07-13

在线出版日期:2022-09-20

基金项目:国家自然科学基金资助项目(52107082);广西自 然科学基金资助项目(2021GXNSFBA220032)

Project supported by the National Natural Science Foundation of China (52107082) and the Natural Science Foundation of Guangxi(2021GXNSFBA220032) 可能出现"维数灾"问题。文献[6-7]应用 Benders 分 解,通过约束条件或决策变量将原问题分解为主问 题和若干连续变量的子问题,降低了数学模型的求 解难度,但实际系统的计算量大,求解速度较慢。智 能优化算法主要是将随机优化算法应用于机组组合 领域,其中具有代表性的算法有粒子群优化算法<sup>[8]</sup>、 遗传算法<sup>[9]</sup>等。采用随机优化算法求解机组组合问 题具有理论要求较低、适用性高等优势,但由于其无 法利用系统的物理模型结构与特点,在面对复杂大 规模系统时,求解机组组合的计算效率较低。

随着人工智能技术在电力系统中的应用和发 展,基于深度学习算法求解机组组合决策成为一种 新的研究思路。文献[10]引入长短期记忆(long short-term memory,LSTM)神经网络建立机组组合 的输入、输出映射关系,证明了深度学习方法对机组 组合决策的可行性。文献[11]利用K近邻算法提高 混合整数规划求解器对考虑安全约束的机组组合 (security constrained unit commitment, SCUC)问题 的计算效率。文献[12]应用序列到序列(sequence to sequence, Seq2Seq)技术, 以门限循环神经网络为 基础构建 Seq2Seq 模型,能够有效处理弹性多序列 映射型样本,仿真结果表明该模型具有更高的精度 与更好的适应能力。相比于传统 SCUC 算法, 文献 [13]提出基于卷积神经网络(convolutional neural network, CNN)的SCUC求解方法,消除了考虑基于 场景的安全约束的必要性,从而降低了模型求解复 杂度。文献[14]应用结合深度Q网络的机组组合算 法来避免求解过程中的"维数灾"问题,并通过仿真 验证了该算法的有效性。

然而,目前应用机组组合的深度学习方法仍然

存在一定的局限性。LSTM 等具有时序特性的神经 网络仅有短期记忆能力,这使得网络在经过每个时 间步长的转换计算后会丢失部分信息。CNN关注二 维局部数据间的相互关联信息,受感受野的限制,其 无法捕获远距离特征。对于机组组合问题,机组的 决策方案是根据负荷的全局时段信息进行计算的, 对局部信息的求解会造成部分信息的损失,从而影 响全局决策方案的求解精度。

近年来, Transformer神经网络在自然语言处理 领域的应用取得了良好成效,其通过自注意力(Self-Attention)机制建立全局关联信息,具有更强的时序 耦合和全局关联特征提取能力<sup>[15]</sup>。机组组合模型中 的爬坡耦合和启停耦合使得全时段紧密关联,因此, 本文引入Transformer神经网络的全局视野思想来求 解机组组合问题,但Transformer神经网络自身的 Encoder-Decoder架构与滚动解码预测方式不能直接 应用于机组组合问题。

为解决上述问题,本文首先提出基于多头注意 力机制的特征向量构建方法,解决Transformer神经 网络应用于机组组合的结构限制问题,然后提出基 于改进的Transformer神经网络辅助的机组组合两阶 段快速决策方法。在机组组合决策方法中:在第一 阶段,提出改进的Transformer神经网络对机组状态 进行预辨识,提升预测全局机组决策的精度;在第二 阶段,设定置信度评估指标来区分机组的可信状态, 并结合机组组合物理模型的求解,减小深度学习带 来的预测误差,提高大规模机组组合问题的求解 效率。

### 1 基于多头注意力的全局关联特征构建方法

本节基于负荷与机组多时段的数据结构特点重 构数据样本,采用多头注意力机制构建负荷与机组 时段数据间的关联性,充分提取关联性特征。构建 方式如下。

将系统中所有节点在*t*时段的负荷构成时序向 量*P*<sub>*i*</sub>,将*P*<sub>*i*</sub>按照时序依次排列构成矩阵*P*<sub>*a*</sub>,如式(1) 所示,并将*P*<sub>*a*</sub>作为输入神经网络的特征。

$$\boldsymbol{P}_{a} = \begin{bmatrix} P_{1,1} & P_{1,2} & \cdots & P_{1,n} \\ P_{2,1} & P_{2,2} & \cdots & P_{2,n} \\ \vdots & \vdots & & \vdots \\ P_{T,1} & P_{T,2} & \cdots & P_{T,n} \end{bmatrix} = \begin{bmatrix} \boldsymbol{P}_{1} \\ \boldsymbol{P}_{2} \\ \vdots \\ \boldsymbol{P}_{T} \end{bmatrix}$$
(1)

式中:*P<sub>t,d</sub>*(*t*=1,2,…,*T*; *d*=1,2,…,*n*)为*t*时段节点 *d*的负荷,*T*为时段总数,*n*为负荷节点总数。

将系统中t时段的所有机组启停值构成输出 Transformer神经网络的目标向量 $u_t$ ,将 $u_t$ 元素按照 时序依次排列构成 $u_a$ ,如式(2)所示,并将 $u_a$ 作为神 经网络的输出值。

$$\boldsymbol{u}_{a} = \begin{bmatrix} u_{1,1} & u_{1,2} & \cdots & u_{1,m} \\ u_{2,1} & u_{2,2} & \cdots & u_{2,m} \\ \vdots & \vdots & & \vdots \\ u_{T,1} & u_{T,2} & \cdots & u_{T,m} \end{bmatrix} = \begin{bmatrix} \boldsymbol{u}_{1} \\ \boldsymbol{u}_{2} \\ \vdots \\ \vdots \\ \boldsymbol{u}_{T} \end{bmatrix}$$
(2)

式中: $u_{t,i}(t=1,2,...,T; i=1,2,...,m)为t时段机组i$ 的启停预测值,m为机组总数。

结合Transformer神经网络模型的输入、输出结构特点,本文所提分时段构建负荷特征与目标输出的方法能够解决Transformer神经网络应用于机组组合的结构限制问题,同时为后续采用多头注意力机制充分提取不同时段之间的全局特征奠定基础。多头注意力机制用于提取不同时段之间负荷特征的相关性,将负荷特征转换为多组输入特征,分别对每组输入特征进行Self-Attention机制的计算,实现对不同子空间的负荷特征提取,从而提升Self-Attention机制提取不同时段之间负荷特征的鲁棒性。多头注意力机制的求解流程如下。

将输入特征  $P_a$ 通过全连接层线性变换为  $P_Q$ 、  $P_K$ 、 $P_V$ 这3种不同的输入特征,并调用 Self-Attention 机制求解这3种输入特征之间的关联性。由式(3) 可知, $P_Q$ 、 $P_K$ 、 $P_V$ 仅在数据维度上相等,其取值由  $P_a$ 与相应的网络权重参数两部分决定,其中网络权重 参数在模型训练过程中迭代变化,因此 $P_Q$ 、 $P_K$ 、 $P_V$ 的 取值也随之变化。

$$\begin{cases} P_{Q} = P_{a}W^{Q} \\ P_{K} = P_{a}W^{K} \\ P_{V} = P_{a}W^{V} \end{cases}$$
(3)

式中: $W^{\varrho}$ 、 $W^{\kappa}$ 、 $W^{\nu}$ 分别为对应于 $P_{\varrho}$ 、 $P_{\kappa}$ 、 $P_{\nu}$ 的网络权 重参数, $P_{\varrho}$ 、 $P_{\kappa}$ 、 $P_{\nu}$ 由 $P_{a}$ 分别经过 $W^{\varrho}$ 、 $W^{\kappa}$ 、 $W^{\nu}$ 线性 变换( $\mathbf{R}^{T\times n} \rightarrow \mathbf{R}^{T\times d_{a}}$ )求得, $d_{a}$ 为 $P_{\varrho}$ 、 $P_{\kappa}$ 、 $P_{\nu}$ 的特征维 度,且 $d_{a}$ 能被多头注意力分组数h整除。

将 $P_{q}$ 、 $P_{\kappa}$ 、 $P_{\nu}$ 按照负荷节点对应维度拆分为数 量相同的h组子矩阵,如式(4)所示。

$$\begin{cases} \boldsymbol{P}_{Q} = \left[ \boldsymbol{P}_{Q1}, \boldsymbol{P}_{Q2}, \cdots, \boldsymbol{P}_{Qh} \right] \\ \boldsymbol{P}_{K} = \left[ \boldsymbol{P}_{K1}, \boldsymbol{P}_{K2}, \cdots, \boldsymbol{P}_{Kh} \right] \\ \boldsymbol{P}_{V} = \left[ \boldsymbol{P}_{V1}, \boldsymbol{P}_{V2}, \cdots, \boldsymbol{P}_{Vh} \right] \end{cases}$$
(4)

式中: $P_{Q\alpha}$ 、 $P_{K\alpha}$ 、 $P_{V\alpha} \in \mathbf{R}^{T \times (d_a/h)} (\alpha = 1, 2, \dots, h)$ ,将具有相同索引的子矩阵 $P_{Q\alpha}$ 、 $P_{K\alpha}$ 、 $P_{V\alpha}$ 视为同一分组。对每个分组采用 Self-Attention 机制进行计算,提取节点负荷特征在不同子空间下的不同时段之间的关联性,如式(5)所示。

$$A^{\mathrm{u}}\left(\boldsymbol{P}_{\mathrm{Q}\alpha},\boldsymbol{P}_{\mathrm{K}\alpha},\boldsymbol{P}_{\mathrm{V}\alpha}\right) = \operatorname{Softmax}\left(\frac{\boldsymbol{P}_{\mathrm{Q}\alpha}\boldsymbol{P}_{\mathrm{K}\alpha}^{\mathrm{T}}}{\sqrt{d_{\mathrm{k}}}}\right)\boldsymbol{P}_{\mathrm{V}\alpha} \quad (5)$$

式中: $A^{\text{tr}}(\cdot)$ 为Self-Attention机制;Softmax(·)为归一 化指数函数; $d_k$ 为矩阵 $P_{Q\alpha}$ 的行数,通过将 $P_{Q\alpha}P_{K\alpha}^{\text{tr}}$ 除 以 $\sqrt{d_k}$ 防止 $P_{Q\alpha}$ 与 $P_{K\alpha}$ 的内积过大。 $P_{Q\alpha}$ 与 $P_{K\alpha}$ 的点 将每组 $P_{Q\alpha}$ 、 $P_{K\alpha}$ 、 $P_{V\alpha}$ 经 Self-Attention 机制计算 后按列进行拼接,进而经过全连接层的线性变换后 得到多头注意力的总特征,即:

$$\boldsymbol{H}_{\alpha} = A^{\mathrm{tt}} \left( \boldsymbol{P}_{\mathrm{Q}\alpha}, \boldsymbol{P}_{\mathrm{K}\alpha}, \boldsymbol{P}_{\mathrm{V}\alpha} \right) \tag{6}$$

$$M^{\mathrm{HA}}(\boldsymbol{P}_{\mathrm{Q}},\boldsymbol{P}_{\mathrm{K}},\boldsymbol{P}_{\mathrm{V}}) = C^{\mathrm{on}}(\boldsymbol{H}_{1},\boldsymbol{H}_{2},\cdots,\boldsymbol{H}_{h})\boldsymbol{W}^{\mathrm{o}} \qquad (7)$$

式中: $H_{\alpha}$ 为Self-Attention机制的输出; $M^{\text{HA}}(\cdot)$ 为多头注意力机制; $C^{\text{on}}(\cdot)$ 为Concat函数,用于将多头注意力求解的输出矩阵按列进行拼接<sup>[17]</sup>; $W^{\circ} \in \mathbb{R}^{d_{a} \times d_{a}}$ 为全连接网络权重参数。基于多头注意力机制的负荷特征计算流程图如附录B图B1所示。

# 2 基于改进的 Transformer 神经网络的一阶 段预辨识模型

本文基于多头注意力机制的特征向量构建方法,利用Self-Attention机制充分提取节点负荷不同时段间的关联特征,并提出基于改进的Transformer神经网络预辨识模型,以提升辨识机组状态的精度。

#### 2.1 基于机组组合的Transformer神经网络模块

改进的Transformer神经网络基于Self-Attention 模块、前向传递模块和交叉注意力(Cross-Attention) 模块构建而成,模块的具体构建方式如下。

1)Self-Attention 模块。

Self-Attention模块的计算过程如式(8)所示。

$$\boldsymbol{P}_{z\beta} = L^{N} \left( \boldsymbol{P}_{x\beta} + D^{r} \left( M^{HA} \left( \boldsymbol{P}_{x\beta}, \boldsymbol{P}_{x\beta}, \boldsymbol{P}_{x\beta} \right) \right) \right)$$
(8)

式中: $P_{x\beta}$ 、 $P_{x\beta}$ ( $\beta$ =1,2,…,q)分别为第 $\beta$ 个 Self-Attention 模块的输出值和输入的全局关联性负荷特征,q为所接入的模块总数; $L^{N}(\cdot)$ 为层归一化函数,其计算公式如附录A式(A3)—(A5)所示; $D^{r}(\cdot)$ 为随机失活函数。

2)前向传递模块。

本文设置前向传递模块来增强模型的拟合能 力,前一模块的输出首先经过前馈神经网络,然后经 过随机失活与残差连接,最后通过层归一化输出。 前馈神经网络公式为:

$$F^{\text{FN}}(\boldsymbol{x}) = s(\boldsymbol{x}\boldsymbol{W}_1 + \boldsymbol{b}_1)\boldsymbol{W}_2 + \boldsymbol{b}_2$$
(9)

式中: $F^{FN}(\cdot)$ 为前馈神经网络函数;x为前一模块的输出,同时为该模块的输入; $s(\cdot)$ 为ReLU函数,其能够减少参数之间的相互依存关系,提高泛化能力<sup>[18]</sup>,如式(10)所示; $W_1$ 、 $W_2$ 为前馈神经网络的权重参数;  $b_1$ 、 $b_2$ 分别为前馈神经网络第一层与第二层的偏置。

$$s(\boldsymbol{x}) = \max\left(0, \boldsymbol{x}\boldsymbol{W}_1 + \boldsymbol{b}_1\right) \tag{10}$$

$$\mathbf{y} = L^{\mathrm{N}} \left( \mathbf{x} + D^{\mathrm{r}} \left( F^{\mathrm{FN}}(\mathbf{x}) \right) \right)$$
(11)

式中:y为前向传递模块的输出。

3)Cross-Attention 模块。

Cross-Attention模块处于模型解码部分,用于结 合全局编码特征并解码目标序列,该模块的计算过 程为:

$$\boldsymbol{P}_{z\eta} = L^{N} \left( \boldsymbol{P}_{y\eta} + D^{r} \left( M^{HA} \left( \boldsymbol{P}_{e} \boldsymbol{W}^{b}, \boldsymbol{P}_{e} \boldsymbol{W}^{b}, \boldsymbol{P}_{y\eta} \right) \right) \right) \quad (12)$$

式中: $P_{xn}(\eta=1,2,\dots,q)$ 为第 $\eta$ 个 Cross-Attention 模 块的输出; $P_{yn}(\eta=1,2,\dots,q)$ 为上层模块的输出,同 时作为第 $\eta$ 个 Cross-Attention 模块的输入; $P_e$ 为编码 部分的输出值;通过  $W^b$ 线性变换( $\mathbf{R}^{T\times n} \rightarrow \mathbf{R}^{T\times n}$ )将负 荷序列特征维度 n转换为维度m,并结合上层模块 输出共同进行多头注意力机制计算。

# 2.2 基于 Transformer 神经网络的机组组合预辨识 模型

改进的Transformer神经网络由Encoder与Decoder两部分模型组成。Encoder模型由Self-Attention模块与前向传递模块依次堆叠搭建而成,其功 能是通过Self-Attention模块对建立的负荷时序耦合 矩阵提取负荷向量之间的时序关联特征,再由前向 传递模块构建负荷向量节点间的映射关系,实现 Transformer神经网络在机组组合模型中的全局视野 能力。

Encoder模型的数学模型为:

$$\boldsymbol{P}_{e} = f_{1} \left( \boldsymbol{P}_{1}, \boldsymbol{P}_{2}, \cdots, \boldsymbol{P}_{T} \right)$$
(13)

式中:  $f_1(\cdot)$ 为将输入负荷转换为全局关联性特征的 过程函数,如附录 B 图 B2 中 Transformer Encoder 部 分所示。

Decoder模型结合编码提取的输入序列信息,利用Self-Attention机制映射机组目标序列信息,辨识机组启停决策。该模型由Self-Attention模块、Cross-Attention模块与前向传递模块依次堆叠搭建而成。模型输入由加权序列组与编码信息两部分组成,其中,加权序列组的维度与目标序列的维度相同。Decoder模型的数学模型为:

 $[u_1, u_2, \dots, u_T] = f_2(w_1, w_2, \dots, w_T, P_e)$  (14) 式中:  $f_2(\cdot)$ 为 Decoder 模型中将编码特征与加权序列 转换为目标序列的转化函数,如附录 B 图 B2 中 Transformer Decoder 模型部分所示;  $w_i(t=1, 2, \dots, T)$ 为加权序列组在t时段的权重,其值由深度学习训练 得到。

在模型训练阶段,加权序列组的值为待训练的 权重,因此在训练Transformer神经网络内部网络权 重参数的同时训练加权序列的权重值。加权序列组 通过编码提取输入负荷序列的全局关联性特征,结 合目标机组的输出序列启停结果,在不同历史样本 的学习中构建系统机组启停与全时段负荷波动之间 的映射关系,通过训练权重辨识系统中各机组的决 策状态。

将加权序列组结合已训练的权重和输入负荷序 列编码所提取的特征,通过Decoder模型判别每台机 组在相应时段的决策值。设置加权序列组使Encoder模型的全局关联性特征结合Decoder模型的Self-Attention机制,利用全局关联性特征对所有机组进 行预辨识决策,提升全局决策精度。

由于机组组合模型的机组决策值为二值变量,因此选取二分类交叉熵(binary cross entropy, BCE) 作为损失函数,如式(15)所示。

$$B = -\sum_{s=1}^{v} \left[ \hat{\sigma}_{s} \ln \sigma_{s} + (1 - \hat{\sigma}_{s}) \ln (1 - \sigma_{s}) \right] \quad (15)$$

式中:B为BCE的值;v为样本数; $\sigma_s$ 为样本s的预测概率; $\hat{\sigma}_s$ 为样本s的二分类标签。

均方根传递(root mean square prop,RMSprop) 算法集成自适应的学习率与加权平均二阶动量的特 点<sup>19]</sup>,使得在训练过程中避免学习率的急剧下降以 及更快逼近最优解,因此,本文采用RMSprop算法优 化BCE训练的Transformer神经网络模型的权重,如 附录A式(A6)所示。由于Transformer神经网络模 型的复杂度较高,应提前终止训练模型,以减少模型 训练成本,缩短训练时间,防止模型训练过程中的过 拟合,提升训练效率。提前终止训练模型的流程如 附录B图B3所示。

# 3 基于改进的 Transformer 神经网络的两阶 段深度学习辅助机组组合求解策略

本节基于一阶段预辨识模型与机组组合物理模型,提出两阶段深度学习辅助机组组合求解策略,流程图如图1所示,详细流程如附录B图B4所示。

将机组组合问题的求解过程分为2个阶段。在 第一阶段,对输入负荷序列的特征建立时序耦合特 征矩阵,并将该矩阵并行接入改进的Transformer神 经网络,从而对负荷特征进行并行化计算,进而对系 统的机组启停方案进行预辨识,最后输出机组决策 序列矩阵。在使用改进的Transformer神经网络模型 对机组启停方案进行预辨识后,在网络最后的输出 层利用式(16)所示Sigmoid激活函数将预辨识结果 以输出概率值表示,一阶段预辨识模型的输出经过 Sigmoid激活函数映射至(0,1)区间。

$$S(\gamma) = \frac{1}{1 + e^{-\gamma}} \tag{16}$$

式中: $S(\cdot)$ 为 Sigmoid 激活函数; $\gamma$ 为改进的 Transformer 神经网络的输出。

在第二阶段,将第一阶段的机组预测值作为第 二阶段辅助机组组合问题求解的输入值。本文通过 设置置信度阈值δ确定机组预测值的置信状态,如



图 1 基于 Transformer 神经网络辅助的两阶段机组 组合求解策略流程

Fig.1 Flowchart of two-stage unit commitment solution strategy based on auxiliary of Transformer neural network

式(17)所示。当 $u_{i,i}$ > $\delta$ 或 $u_{i,i}$ <1- $\delta$ 时,可认为模型预测值具有高置信度,从而将该预测值认定为可信的机组决策值;当1- $\delta$ < $u_{i,i}$ < $\delta$ 时,由于模型无法准确判断机组决策值,将在该范围内的机组预测值设定为不可信的机组变量 $x_{i,i}$ 。

$$u_{\iota,i} = \begin{cases} 1 & u_{\iota,i} > \delta \\ x_{\iota,i} & 1 - \delta \le u_{\iota,i} \le \delta \\ 0 & u_{\iota,i} < 1 - \delta \end{cases}$$
(17)

由于在第一阶段没有考虑机组的约束关系,因此,有极小的概率会出现经过判别机组置信状态的 预辨识结果不满足约束的情况,从而导致在第二阶 段出现不可信机组求解的启停状态与真实值不同或 出现不可解的情况。针对该问题,本文提出基于最 小启停机约束的修正策略,对最小启停时段内不符 合约束条件的预测值进行修正以满足约束,在提升 机组辨识准确率的同时保证第二阶段求解的可行 性,具体流程如附录B图B4所示。

在第二阶段,将不可信的机组变量认定为待求 解的决策变量,将负荷输入序列,并将可信的机组决 策值与不可信的机组变量相结合输入机组组合物理 模型进行求解。基于物理模型的约束求解不可信的 机组决策变量,得到最终的机组决策方案,物理模型 可描述为:

$$\begin{cases} \min \tau \left( U_s, P_s \right) \\ \omega \left( U_s, P_s \right) = 0 \\ \kappa \left( U_s, P_s \right) \le 0 \end{cases}$$
(18)

式中: $P_s$ 为样本s的机组出力; $U_s$ 为样本s的机组启 停值; $\tau(U_s, P_s)$ 为目标函数; $\omega(U_s, P_s)$ 与 $\kappa(U_s, P_s)$ 分 别为等式约束和不等式约束。本文采用文献[20]中 构建直流潮流网络约束的机组组合物理模型,如附 录A式(A7)—(A18)所示。

相较于常规机组组合求解方法,深度学习辅助 机组组合两阶段求解方法利用深度学习辨识部分机 组的决策值,利用辅助物理模型求解不可信的机组 变量,减小了深度学习带来的预测误差,提高了机组 组合的求解效率和机组的决策精度。

#### 4 算例验证与分析

#### 4.1 算例参数

1)软硬件与网络参数配置情况。

操作系统为Win10 64 bit。硬件为:CPU i7-7700 HQ;GPU NVIDIA GeForce RTX 2060;8 GB运行 内存。软件为:MATLAB R2019b;Anaconda3;Python 3.8.5(64 bit)环境;Pytorch-1.7.1,GPU-11;Pycharm代 码编辑器。改进的Transformer神经网络模型参数配 置情况如附录C表C1所示。

2) 机组组合样本的生成。

实际负荷数据来源于2016年和2017年我国某 地区负荷样本数据(采样时间间隔为1h),基于此, 构建适用于IEEE 30节点与IEEE 2383节点的系统 日负荷样本。使用MATLAB R2019b软件构建机组 组合决策程序,采用CPLEX 工具包进行求解,生成 8000个样本作为训练集数据,500个样本作为测试 集数据。

#### 4.2 时序网络训练过程对比分析

本节基于机组组合训练集,以IEEE 2383节点 为例进行仿真实验,将时序预测算法中具有代表性 的LSTM神经网络与改进的Transformer神经网络对 机组组合数据的训练过程进行对比分析。设置2种 神经网络的训练批次与迭代次数均相同。训练过程 中的损失值变化图如图2所示。

由图2可知:在对机组组合模型的训练过程中, 在相同的迭代次数下,改进的Transformer神经网络 比LSTM神经网络的收敛速度更快,这是由于Transformer神经网络的多头注意力机制对系统全局视野 的学习能力使其可以更快地学习到日负荷特征与机 组决策之间的映射信息,同时Transformer神经网络 具有并行化训练的能力,这使其比时序信息传递训 练方式的效率更高。



#### 4.3 深度学习模型一阶段辨识对比分析

为了验证所提改进的Transformer神经网络的 有效性,将其与深度学习中具有代表性的传统方 法——反向传播(back propagation, BP)神经网络、 极限学习机(extreme learning machines, ELM)神经网 络、CNN、LSTM神经网络进行对比分析。以CPLEX 求解的机组组合问题为例,其中训练与测试神经网 络的样本均以CPLEX 求解结果的准确率为基准。 随机选取50个测试样本进行仿真验证,对深度学习 的输出设置模型置信度,将低于置信度的不可信机 组启停以未识别率表示,进而对区分机组置信状态 后的模型进行对比分析。

判别置信度后深度学习模型的预辨识结果如表 1所示。由表可知,在IEEE 30节点系统算例中,BP 神经网络与改进的Transformer神经网络的准确率仅 相差1.1%,但在IEEE 2383节点系统算例中相差 11.2%,这是由于BP神经网络在低维度特征下具有 较高的非线性映射能力,但在高维度特征下可能陷 入局部极值,导致训练失败,从而降低辨识准确率。 此外,在IEEE 2383节点系统中,改进的Transformer 神经网络比CNN与LSTM神经网络的准确率更高且 未识别率更低。这是由于:机组的决策方案是根据 负荷的全局时段信息进行计算的,局部信息的求解 会造成部分信息的损失,影响求解全局决策的精度, 因此,LSTM神经网络经过每个时间步长的处理会损 失一定的信息,仅保持短期的时序记忆信息,从而影 响机组组合模型的预测精度;CNN关注二维局部数 据间的相互关联信息,无法捕获远距离特征,受感受

表1 判别置信度后深度学习模型的预辨识结果

 
 Table 1
 Pre-identification results of deep learning models after discriminating confidence

	IEEE 30		IEEE 2383	
方法	准确率 /	未识别率 /	准确率 /	未识别率 /
	%	%	%	%
BP	97.9	7.4	85.2	33.2
ELM	96.7	3.3	82.4	15.4
CNN	98.0	6.5	90.6	15.2
LSTM	96.4	18.2	91.5	19.2
Transformer	99.0	15.3	96.4	8.2

野的限制,其割裂了全局特征的关联性信息,导致机 组启停的辨识精度低于改进的Transformer神经网络;改进的Transformer神经网络由于多头注意力机 制可提取全局关联性特征,长序列预测能力使其辨 识机组启停的准确率高于其他传统方法。

一阶段深度学习训练时间的对比如表2所示。 由表可知,ELM 神经网络的训练时间比改进的 Transformer 神经网络的训练时间在 IEEE 30 和 IEEE 2383节点系统中分别少50%和34%,这是由 于 ELM 神经网络的训练不同于梯度下降算法的更 新迭代模式,其使用计算矩阵的数学求解方式来训 练网络参数,ELM 神经网络的浅层模型对高维度负 荷与机组的映射能力欠佳,并且网络易过度训练,从 而导致泛化能力下降。

#### 表2 一阶段深度学习训练时间的对比

Table 2 Comparison of training time of one-stage deep learning

答庙			训练时	间∕s	
异例	BP	ELM	CNN	LSTM	Transformer
IEEE 30	7 5 4 4	1 3 2 2	5640	5990	2637
IEEE 2383	9377	1988	6952	7055	3014

# 4.4 基于深度学习辅助的机组组合两阶段求解方 法的仿真验证

为验证两阶段求解方法的有效性,采用CPLEX 求解深度学习辅助的第二阶段机组组合物理模型, 其中测试样本均以CPLEX求解结果的准确率为基 准,并使用4.3节的深度学习算法结合两阶段决策方 法进行对比分析。

本节进行如下处理:设置深度学习模型的置信 状态,结合机组组合物理模型对不可信机组的求解 进行对比分析。

两阶段深度学习模型辨识结果的对比如表3所示。由表可知,改进的Transformer神经网络在2个算例上的准确率均为最高,其中在IEEE 2383节点系统算例中的准确率比其他神经网络提升更明显,这是由于在第一阶段判别置信度后,改进的Transformer神经网络的准确率达到最高且未识别率达到最低,在第二阶段需修正的不可信机组的数量较少,这使系统中可能出现误差的机组预测值较少。

表3 两阶段深度学习模型辨识结果的对比

Table 3 Comparison of identification results among two-stage deep learning models

<del>之</del> )+	准确率 / %		
刀伝	IEEE 30	IEEE 2383	
BP	95.3	81.2	
ELM	95.4	79.4	
CNN	92.4	90.2	
LSTM	91.5	88.3	
Transformer	98.5	95.4	

由于采用两阶段的物理模型辅助求解会增加机 组组合问题的整体求解时间,因此以CPLEX求解机 组组合为例,将不同神经网络的两阶段方法与常规 求解方法的求解时间进行对比分析。其中第二阶段 与常规求解方法均使用CPLEX进行求解。对不同 阶段的求解时间进行对比,如表4所示。表中:t<sub>1</sub>为 第一阶段深度学习预辨识的求解时间;t<sub>2</sub>为第二阶 段辅助机组组合的求解时间;t<sub>3</sub>为两阶段机组组合 的求解总时间;每个阶段的求解时间为计算每个样 本的平均时间。

#### 表4 机组组合两阶段求解时间的对比

Table 4 Comparison of unit commitment

two-stage solution time	单位:s
-------------------------	------

算例	方法	$t_1$	$t_2$	$t_3$
	BP	0.05	0.10	0.15
	ELM	0.03	0.15	0.18
IEEE 30	LSTM	0.71	0.18	0.89
	Transformer	0.43	0.16	0.59
	常规求解方法	—	—	0.40
	BP	0.23	31.58	31.81
IEEE 2383	ELM	0.14	24.84	24.98
	LSTM	2.13	28.12	30.25
	Transformer	1.95	19.12	21.07
	常规求解方法	—	_	77.78

由表4可知,在IEEE 30节点系统算例中,BP神 经网络与ELM神经网络的t<sub>3</sub>分别比常规求解方法减 少62.5%与55%,而LSTM神经网络与改进的Transformer神经网络的t<sub>3</sub>均高于常规求解方法。这是由 于:LSTM神经网络与改进的Transformer神经网络的 参数数量相对较多,网络计算时间较长,而复杂度较 低的 BP神经网络与ELM神经网络需要计算的参数 数量较少,因此,BP神经网络与ELM神经网络的t<sub>1</sub> 远低于LSTM神经网络与改进的Transformer神经网 络;由于IEEE 30节点系统算例的复杂度较低,负荷 与机组数量较少,运用常规求解方法的求解维度较 低,从而CPLEX的求解时间较短,这导致高复杂度 的神经网络运用两阶段求解方法比常规求解方法的 计算时间长。

IEEE 2383 节点系统的负荷节点与机组数量较 多,使用常规求解方法的基准时间较长。由表4可 知,改进的Transformer神经网络的t<sub>3</sub>均低于其他方 法,因此在高维度算例下改进的Transformer神经网 络更适合采用两阶段求解方法来求解机组组合问 题,这是由于改进的Transformer神经网络具有较低 的未识别率,这使不可信机组的数量最少,从而使第 二阶段采用物理模型待求解的机组数量最少,比其 他网络模型减少了第二阶段的辅助求解时间。此 外,所有神经网络的t<sub>3</sub>均低于 CPLEX 的基准时间。 由此可知,在求解规模较大的机组组合问题时,常规 求解方法的时间较长,两阶段辅助求解机组决策的 速度快于常规求解方法,另外,采用改进的Transformer神经网络进行辅助求解能够在保证精度的同 时获得较高的求解效率。

# 5 结论

本文基于多时段负荷与机组启停数据的特点, 提出改进的Transformer神经网络模型,进而结合机 组组合物理模型,提出两阶段机组组合决策方法。 基于算例仿真得到结论如下。

1)本文提出基于多头注意力机制的特征向量构 建方法,进而基于机组组合模型提出改进的Transformer神经网络,该神经网络比常规神经网络对大 规模机组组合模型的预测精度更高。同时,改进的 Transformer神经网络比LSTM神经网络在训练时更 快收敛,全局视野与并行化的求解参数能力使改进 的Transformer神经网络模型的训练效率更高。

2)本文提出基于深度学习辅助的机组组合两阶 段求解策略,基于网络约束物理模型的辅助求解比 直接运用神经网络预测可以有效减小深度学习的预 测误差。同时,两阶段的求解方法相较于常规求解 方法可提升机组组合的求解效率。

附录见本刊网络版(http://www.epae.cn)。

#### 参考文献:

 [1] 邵成成,冯陈佳,王秀丽,等.基于负荷状态转移曲线的中长期 快速机组组合[J].中国电机工程学报,2019,39(增刊1): 141-147.

SHAO Chengcheng, FENG Chenjia, WANG Xiuli, et al. Midlong term fast unit commitment based on load state transfer curve[J]. Proceedings of the CSEE, 2019, 39(Supplement 1): 141-147.

[2] 刘艳芳,夏昌浩. 电力系统机组组合问题研究综述[J]. 电气 开关,2015,53(3):5-8,25.

LIU Yanfang, XIA Changhao. A summary of electric power system unit combination proplem[J]. Electric Switchgear, 2015, 53(3):5-8,25.

- [3] 杨楠. 电力系统机组组合问题的建模与求解[M]. 北京:科学 出版社,2020:3-15.
- [4]谢国辉,张粒子,舒隽,等.基于分层分枝定界算法的机组组合
  [J].电力自动化设备,2009,29(12):29-32.
  XIE Guohui, ZHANG Lizi, SHU Jun, et al. Unit commitment based on layered branch and bound algorithm[J]. Electric Power Automation Equipment,2009,29(12):29-32.
- [5] 韦化,龙丹丽,黎静华. 求解大规模机组组合问题的策略迭代 近似动态规划[J]. 中国电机工程学报,2014,34(25):4420-4429.

WEI Hua, LONG Danli, LI Jinghua. Policy iteration-approximate dynamic programming for large scale unit commitment problems[J]. Proceedings of the CSEE,2014,34(25):4420-4429.

[6] 吉静,郝丽丽,王昊昊,等. 大规模风电参与一次调频下基于机 组快速启动能力的日内滚动调度[J]. 电力自动化设备,2020, 40(5):121-130.

JI Jing, HAO Lili, WANG Haohao, et al. Intra-day rolling dispatch considering large-scale wind power participating in primary frequency regulation based on unit fast start-up capability [J]. Electric Power Automation Equipment, 2020, 40(5): 121-130.

- [7]杨艳红,裴玮,邓卫,等. 基于 Benders 分解的微电网联网运行 优化[J]. 电力自动化设备,2014,34(10):21-27.
   YANG Yanhong, PEI Wei, DENG Wei, et al. Optimal operation of grid-connected microgrid based on Benders decomposition[J]. Electric Power Automation Equipment,2014,34(10): 21-27.
- [8]周任军,晁岱旭,李新军,等.空间耦合粒子群优化算法及峰谷 电价下 IES-CCHP 区域联合调度[J].电力自动化设备,2016, 36(12):11-17.
  ZHOU Renjun, CHAO Daixu, LI Xinjun, et al. SC-PSO algorithm and IES-CCHP regional joint dispatch with TOU price [J]. Electric Power Automation Equipment,2016,36(12):11-17.
- [9] 吴大立,郑中祥,尹项根,等. 基于Petri网和多种群遗传算法 的海洋核动力平台电力系统网络重构[J]. 电力自动化设备, 2020,40(8):160-168.
   WU Dali, ZHENG Zhongxiang, YIN Xianggen, et al. Network reconstruction of offshore nuclear power platform power system based on Petri net and multi-population genetic algorithm[J].

Electric Power Automation Equipment, 2020, 40(8):160-168.

[10] 杨楠,叶迪,林杰,等. 基于数据驱动具有自我学习能力的机组 组合智能决策方法研究[J]. 中国电机工程学报,2019,39(10): 2934-2946.

YANG Nan, YE Di, LIN Jie, et al. Research on data-driven intelligent security-constrained unit commitment dispatching method with self-learning ability[J]. Proceedings of the CSEE, 2019,39(10):2934-2946.

- [11] XAVIER Á S, QIU F, AHMED S. Learning to solve largescale security-constrained unit commitment problems [J]. Informs Journal on Computing, 2020, 33(2):739-756.
- [12] 杨楠,贾俊杰,邢超,等. 基于 E-Seq2Seq技术的数据驱动型机 组组合智能决策方法[J]. 中国电机工程学报,2020,40(23): 7587-7600.

YANG Nan, JIA Junjie, XING Chao, et al. Data-driven intelligent decision-making method for unit commitment based on E-Seq2Seq technology[J]. Proceedings of the CSEE, 2020, 40 (23):7587-7600.

- [13] WU T, ZHANG Y J A, WANG S. Deep learning to optimize: security-constrained unit commitment with uncertain wind power generation and BESSs[J]. IEEE Transactions on Sustainable Energy, 2022, 13(1):231-240.
- [14] 温裕鑫,杨军,朱旭.基于深度强化学习的电网机组组合算法
  [J].河北电力技术,2021,40(5):6-10.
  WEN Yuxin, YANG Jun, ZHU Xu. Power grid unit commitment algorithm based on deep reinforcement learning[J]. Hebei Electric Power,2021,40(5):6-10.
- [15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems. Long Beach, USA: [s.n.], 2017:5998-6008.
- [16] 张强,杨吉斌,张雄伟,等. CS-Softmax:一种基于余弦相似性的 Softmax损失函数[J]. 计算机研究与发展,2022,59(4):936-949.
   ZHANG Qiang, YANG Jibin, ZHANG Xiongwei, et al. CS-Softmax: a cosine similarity-based softmax loss function[J]. Journal of Computer Research and Development,2022,59(4): 936-949.
- [17] 罗棕,杜春,陈浩,等. 基于Transformer层次预测的多星应急观测任务规划方法[J]. 航空学报,2021,42(4):524721.
   LUO Zong, DU Chun, CHEN Hao, et al. Multi-satellite scheduling approach for emergency scenarios based on hierarchical forecasting with Transformer network [J]. Acta Aeronautica

et Astronautica Sinica, 2021, 42(4):524721.

- [18] 杨燕,杨知方,余娟,等.基于深度学习的含不确定性N-1安全 校核方法[J].中国电机工程学报,2021,41(8):2716-2725.
  YANG Yan,YANG Zhifang,YU Juan, et al. Fast analysis of N-1 contingency screening with uncertainty scenarios based on deep learning[J]. Proceedings of the CSEE,2021,41(8): 2716-2725.
- [19] TIELEMAN T, HINTON G E. Divide the gradient by a running average of its recent magnitude [J]. Neural Networks for Machine Learning, 2012, 4(2):26-31.
- [20] 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. Model and constraint-reduction method for security-constrained unit commitment considering N-1 contingency[J]. Electric Power Automa-

tion Equipment, 2021, 41(7):167-175.

#### 作者简介:



武新章

武新章(1968—),男,教授,博士,研究 方向为人工智能在电力系统的应用、机器 人、电磁理论等(E-mail:xwu@gxu.edu.cn); 赵子巍(1996—),男,硕士研究生,研 究方向为深度学习在机组组合中的应用 (E-mail:1021313804@qq.com);

代 伟(1990—),男,助理教授,博士, 通信作者,研究方向为人工智能在电力系 统中的应用、综合能源系统优化调度等

(**E-mail**:weidai2019@163.com)<sub>o</sub>

(编辑 王锦秀)

# Two-stage unit commitment decision-making method based on auxiliary of improved Transformer neural network

WU Xinzhang<sup>1</sup>, ZHAO Ziwei<sup>1</sup>, DAI Wei<sup>1</sup>, XIE Daiyu<sup>2</sup>, GUO Suhang<sup>1</sup>, WANG Zeyu<sup>1</sup>, ZHANG Dongdong<sup>1</sup>

(1. College of Electrical Engineering, Guangxi University, Nanning 530004, China;

2. Power Dispatching Control Center of Guangxi Power Grid Co., Ltd., Nanning 530023, China)

**Abstract**: In order to solve the "curse of dimensionality" problem of unit commitment in large-scale power system, a two-stage unit commitment decision-making method based on Transformer neural network is proposed, which considers both the solving accuracy and speed. In the first stage, considering the coupling characteristic of unit commitment periods, a feature vector construction method based on multi-Attention mechanism is proposed, further an improved Transformer neural network is proposed to predetermine the unit start-stop values based on the advantages of global view and parallelization of Transformer neural network. In the second stage, the credibility threshold is designed based on the predetermined unit states, and the unit start-stop determination credibility is defined as start-stop credible and start-stop incredible states, the state of start-stop credible unit is determined directly, while the state of start-stop incredible state unit is solved by the unit commitment physical model to ensure the solving feasibility. The simulative results of IEEE 30-bus and IEEE 2383-bus systems verify the effectiveness of the proposed method. **Key words**; Transformer neural network; deep learning; unit commitment; data driven; feature construction

Softmax 
$$(z) = \frac{e^{z}}{\sum_{c=0}^{\theta} e^{z}}$$
 (A1)

$$z = \frac{\boldsymbol{P}_{Q\alpha} \boldsymbol{P}_{K\alpha}^{\mathrm{T}}}{\sqrt{d_{\mathrm{k}}}}$$
(A2)

式中: $\theta$ 为类标签。由于辨识机组启停为二分类问题,可将所属类别表示为 $\theta = \{0,1\}$ , z为 Softmax 函数的输入,Softmax 的输出代表对 *m*类标签估计的概率值。

附寻∧

$$\hat{\psi}_I^{(l)} = L^{\mathrm{N}}\left(\psi_I^{(l)}\right) \tag{A3}$$

$$\mu^{(l)} = \frac{\sum_{I=1}^{V^{(l)}} \psi_I^{(l)}}{n^{(l)}} \tag{A4}$$

$$\sigma^{(l)^2} = \frac{\sum_{I=1}^{n^{(l)}} \left(\psi_I^{(l)} - \mu^{(l)}\right)^2}{n^{(l)}}$$
(A5)

$$\hat{\psi}_{I}^{(l)} = \frac{\psi_{I}^{(l)} - \mu^{(l)}}{\sqrt{\sigma^{(l)^{2}} + \varepsilon}} \zeta + \beta \tag{A6}$$

式中: $\psi_{I}^{(l)}$ 为第 I 层第 I 神经元的输出值; $V^{(l)}$ 为该层的神经元个数; $\mu^{(l)}$ 和 $\sigma^{(l)^{2}}$ 分别为第 I 层的均值与 方差; $\epsilon \pi \beta$ 分别为层归一化中设置的可训练缩放与偏移参数; $\hat{\psi}_{I}^{(l)}$ 为层归一化输出; $\epsilon$ 为常数,用于 防止分母为 0。

$$\begin{cases} g_{\lambda} = \frac{\partial B}{\partial w} = \frac{1}{m} \sum_{i=1}^{m} \nabla_{w} L(\boldsymbol{P}_{s}, \boldsymbol{U}_{s}, w) \\ G_{\lambda} = \zeta G_{\lambda-1} + (1-\zeta) g_{\lambda}^{2} \\ \Delta_{\lambda} = \vartheta \Delta_{\lambda-1} - \frac{\chi}{\sqrt{G_{\lambda} + \varepsilon}} g_{\lambda} \\ w_{\lambda} = w_{\lambda-1} + \Delta_{\lambda} \end{cases}$$
(A7)

式中:  $g_{\lambda}$ 为 t 次迭代时权重使用的梯度;  $\nabla_{w}$ 表示损失函数  $B \perp w$ 的梯度;  $\chi$  为学习率;  $G_{\lambda}$ 为累计梯度 值;  $\Delta_{\lambda}$ 为更新增量;  $\zeta$  为衰减系数; B为控制增量迭代系数。

$$\min \sum_{t=1}^{T} W_{G,t} = \min \sum_{i=1}^{m} \left( \sum_{t=1}^{T} C_i^f \left( P_{t,i} \right) + C_i^U + C_i^D \right)$$
(A8)

$$C_{i}^{f}(P_{t,i}) = a_{i}P_{t,i}^{2} + b_{i}P_{t,i} + c_{i}$$
(A9)

$$\sum_{i=1}^{n} u_{t,i} P_{t,i} = \sum_{i=1}^{n} P_{t,d}$$
(A10)

$$\sum_{i=1}^{n} \left( u_{t,i} P_{i,\max} - P_{t,i} \right) \ge \rho \sum_{i=1}^{n} P_{t,d}$$
(A11)

$$u_{t,i}P_{i,\min} \le P_i \le u_{t,i}P_{i,\max} \tag{A12}$$

$$-R_{o} \le P_{t,i} - P_{t-1,i} \le R_{u} \tag{A13}$$

$$\left(X_{up,t-1,i} - T_{up,i}\right) \left(u_{t-1,i} - u_{t,i}\right) \ge 0$$
(A14)

$$(X_{\text{down},t-1,i} - T_{\text{down},i}) (u_{t-1,i} - u_{t,i}) \ge 0$$
(A15)

$$\begin{cases} C_i^{\mathrm{U}} \ge Z_i \left( u_{t,i} - u_{t-1,i} \right) \\ C_i^{\mathrm{U}} \ge 0 \end{cases}$$
(A16)

$$\begin{cases} C_i^{\mathrm{D}} \ge J_i \left( u_{t-1,i} - u_{t,i} \right) \\ C_i^{\mathrm{D}} \ge 0 \end{cases}$$
(A17)

$$P_{j,\min} \le P_{t,j} \le P_{j,\max} \tag{A18}$$

$$P_{t,j} = Y\left(P_{t,i} - P_{t,d}\right) \tag{A19}$$

式中:  $W_{G,i}$ 为机组时段 t 的发电成本;  $P_{t,i}$ 为 t 时段机组 i 的有功出力;  $C_i^U \ C_i^D$ 分别为机组 i 的启动与 关停成本;  $C_i^f$ 为其煤耗成本;  $a_i \ b_i \ c_i$ 分别为机组的二次费用、一次费用和固定费用;  $R_o \ R_u$ 分别 为机组的下、上爬坡速率;  $P_{i,max} \ P_{i,min}$ 分别为机组 i 的最大、最小出力限制;  $\rho$  为热备用系数;  $T_{down,i} \ T_{up,i}$ 分别为机组 i 最小关停、开机时间;  $X_{down,t,i} \ X_{up,t,i}$ 分别为连续停、开机小时数;  $Z_i \ J_i$ 分别为机 组 i 的单次启动、关停成本;  $P_{j,max} \ P_{j,min}$ 分别为线路 j的潮流约束最大、最小限制;  $P_{t,j}$ 为线路潮流; Y为功率转移分布因子。

# 附录B



图 B1 基于多头注意力机制的负荷特征计算流程图

Fig. B1 Flowchart of load feature calculation based on multi-head attention mechanism



图 B2 基于 Transformer 的机组组合深度学习预辨识模型流程图 Fig.B2 Flowchart of deep learning pre-recognition model of unit commitment based on Transformer



图 B3 提前终止训练模型流程图

Fig.B3 Flowchart of early termination training model

*E*为迭代数,当*E*小于最大连续迭代次数*E*<sub>max</sub>,则进行下一次反向传播更新权值。每次迭代的损失 值与历史迭代最小损失进行比较,若小于最小损失值,则保存训练网络权重并将当前损失值更新为最小 损失值,由此保存模型最优的训练参数。设置阈值*σ*用于减少训练模型时间,若迭代的损失函数减小值 都低于阈值,则结束训练迭代。





Fig. B4 Flowchart of two-stage unit commitment solution strategy with Transformer auxiliary

# 附录 C

通过大量仿真测试发现,按照表 C1 设置模型的网络参数时,本文建立的深度学习模型能够在辨识机 组启停的训练过程中快速收敛,并且决策精度较高。

表 C1 Transformer 模型的参数配置情况

Table C1 Parameter configuration condition of Transformer model

	Source of framerormer model
项目	参数
	6
Decoder 模块	6
训练批次大小(batch)	64
参数更新优化求解器	RMSprop
$D_{ m ff}$	3 000
h	6

注: **D**<sub>ff</sub>为前馈神经网络中隐藏层的神经元个数。