

# 基于 DIndRNN-RVM 深度融合模型的 AGC 指令 执行效果精准辨识及置信评估研究

陈光宇<sup>1</sup>, 孙叶舟<sup>1</sup>, 江海洋<sup>2</sup>, 王宁<sup>2</sup>, 康春雷<sup>2</sup>, 张仰飞<sup>1</sup>, 郝思鹏<sup>1</sup>

(1. 南京工程学院电力工程学院, 江苏省南京市 211167;

2. 国网黑龙江省电力有限公司, 黑龙江省哈尔滨市 150090)

## Research on Accurate Identification and Confidence Evaluation of AGC Command Execution Effect Based on DIndRNN-RVM Deep Fusion Model

CHEN Guangyu<sup>1</sup>, SUN Yezhou<sup>1</sup>, JIANG Haiyang<sup>2</sup>, WANG Ning<sup>2</sup>, KANG Chunlei<sup>2</sup>,  
ZHANG Yangfei<sup>1</sup>, HAO Sipeng<sup>1</sup>

(1. School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing 211167, Jiangsu Province, China;

2. State Grid Heilongjiang Electric Power Co., Ltd. Harbin 150090, Heilongjiang Province, China)

**ABSTRACT:** With the increasing complexity of the power grid structure, the accuracy of automatic generation control (AGC) instructions executed by units is gradually increasing the impact on the online control of the power grid. In view of the fact that the effect of AGC command tracking in some stations is not accurate, this paper introduced “deep learning” technology to accurately perceive and evaluate the effect of AGC control command execution. Firstly, an accurate identification framework of AGC command execution effect based on deep learning was proposed, which used deep independent recurrent neural network (DIndRNN) to accurately perceive the effect of unit execution command. Secondly, a preprocessing strategy to speed up model training was proposed, which realized model input identification based on historical data of unit operation by analyzing the correlation characteristics between different input attributes. Finally, an uncertainty evaluation method for the effect of instruction execution was proposed, and the DIndRNN-RVM deep fusion technology was used to give the credibility of the prediction results within the given output deviation range, which enhanced the usability of the prediction results from the perspective of probability. The simulation results showed that the proposed identification framework and model optimization method could accurately perceive the accuracy of unit execution instructions and the reliability of execution results.

**基金项目:** 国家自然科学基金项目(51707089); 江苏省配电网智能技术与装备协同创新中心开放基金资助项目(XTCX202003)。

Supported by National Natural Science Foundation of China (51707089); Open Research Fund of Jiangsu Collaborative Innovation Center for Smart Distribution Network, Nanjing Institute of Technology (XTCX202003).

The method proposed in this paper improves the power grid's accurate perception and prediction of AGC command execution effect, and can provide support for AGC online decision-making.

**KEY WORDS:** independent recurrent neural network; preprocessing strategy; cross validation; deep fusion; confidence evaluation

**摘要:** 随着电网结构的日益复杂, 机组执行(automatic generation control, AGC)指令的精准性对电网在线调控的影响正逐渐增强。针对当前部分厂站对 AGC 指令跟踪效果不理想的实际问题, 该文引入“深度学习”技术对 AGC 调控指令执行效果进行精准感知和评估。首先提出一种基于深度学习的 AGC 指令执行效果精准辨识框架, 采用深度独立循环神经网络(deep independent recurrent neural network, DIndRNN)对机组执行指令的调节效果进行精准感知; 其次, 提出一种加快模型训练的预处理策略, 基于机组运行历史数据通过分析不同输入属性间的关联特性, 实现对模型输入属性的降维; 进一步提高模型的收敛性和预测精度; 最后提出一种对指令执行效果的不确定性评估方法, 采用深度独立循环神经网络关联向量机(deep independent recurrent neural network relevance vector machine, DIndRNN-RVM)深度融合技术给出预测结果在给定出力偏差范围内的可信度, 从概率的角度增强了预测结果的使用价值。算例采用真实电网数据进行仿真分析, 计算结果表明, 该文提出的辨识框架和模型优化方法能较为准确的感知机组执行指令的精度和执行结果的可信度。该文所述方法提高了电网对 AGC 指令执行效果的精准感知和预判, 能够为 AGC 在线决策提供支撑。

**关键词:** 独立循环神经网络; 预处理策略; 交叉验证; 深度融合; 置信评估

## 0 引言

自动发电控制(automatic generation control, AGC)经过多年的研究已经日趋成熟并且取得了广泛的应用<sup>[1-3]</sup>。近年来随着新能源电站的持续增加,其出力的不确定性对电网调控的影响已不可忽视,因此,在传统调控的基础上,如何实现新形势下电网运行的精准判断,尤其是对机组执行 AGC 调控指令的精准感知提出了更高的要求<sup>[4-5]</sup>。

在新能源发电背景下的有功调度领域,文献[6]讨论了在高比例可再生能源接入的背景下如何解决临界断面的时间尺度问题,提出了一种调度临界时间尺度的解析公式,给出了时间尺度、出力不确定性以及 AGC 调节范围三者间的函数表达式,仿真结果表明该方法能有效的解决新能源高渗透下电网功率的平衡问题。文献[7]则从系统调频的角度出发,讨论了不同频段内的风电出力波动性对系统频率的影响,并以大规模风电接入为背景提出一种火电机组动态一次调频策略,仿真结果表明新策略能有效降低风电波动对电网频率的影响。文献[8]以风电集群控制为背景,提出一种三层有功滚动预测控制方法,提高系统安全性的同时尽可能的提高风电消纳能力,合理分配集群内风电的出力。文献[9]从区域互联系统出发,提出一种考虑区域调节边际成本的多区域 AGC 联合调频策略,实现了多区域的 AGC 最优联合调频控制。

在含新能源调度模型的求解方面,鲁棒优化已越来越被研究人员所关注,尤其是对于含新能源调度问题的鲁棒优化更是当下研究的热点,自适应鲁棒调度<sup>[10-11]</sup>和仿射鲁棒调度<sup>[12-13]</sup>是当前研究的两个主要方向,文献[14]在文献[11]的基础上,针对风电随机性和区域调度的安全性,提出一种分层协同鲁棒优化方法,将 AGC 控制量和可消纳的风电容量一同参与模型的优化,并将模型进行分解提高求解效率,仿真结果表明该方法的有效性。文献[15]针对一阶和二阶矩不确定性调度模型难以转化和求解问题,提出一种分布鲁棒实时调度模型,将矩等价转化为确定性二次规划约束问题,最终通过模型的松弛转化为线性规划问题求解,仿真表明该方法的可行性和有效性。

此外,近年来基于人工智能技术的调控技术正逐步被研究人员所关注,文献[16]提出一种基于深度学习和蒙特卡洛搜索的机组恢复在线决策方法,

获得了鲁棒性较高的在线恢复方案。文献[17]基于长短时深度学习网络提出一种具有自我学习能力的机组组合决策方法,相比传统方法提高了决策的精度和效率,决策结果鲁棒性更强。文献[18]则将深度强化学习用于 AGC 控制,提出将深度网络作为行为预测,而强化学习作为动作选择机制的策略,仿真结果表明相比现有的智能优化方法具有更好的学习能力,能获得区域最优控制。

以上文献对新能源接入背景下 AGC 的控制方法和求解策略进行了深入的研究,并取得了较好的效果,但这些研究大多建立在 AGC 控制命令能精准执行的基础上,然而在一些地区,由于发电机组设备以及环境的影响,常会出现发电机组对 AGC 指令的执行结果偏差较大的情况,这不但会导致 AGC 控制方案无法实现预想控制效果,有时甚至会出现边界联络线由于指令执行能力差进而造成越限情况的发生。

针对以上问题,本文考虑引入人工智能技术,构建深度神经网络模型,并采用海量历史数据进行模型训练,最后实现主站调控系统在运行周期内能对 AGC 控制指令的执行情况给出精准感知和评估,为新能源接入背景下增强 AGC 控制方案的有效性提供有力支撑。基于这一思想,本文首先提出一种 AGC 指令执行效果精准感知的智能辨识框架,采用深度循环神经网络(deep recurrent neural network, DRNN)对 AGC 控制命令执行精准性进行预测和感知。其次,为提高网络模型的训练速度和收敛精度,提出一种深度网络模型输入参量预处理策略,基于历史数据采用核主成分分析方法对输入变量进行降维处理,从而进一步减少输入变量的维度,提高模型整体的训练速度和输出精度,最后为了解决对预测结果不确定性评估问题,提出一种基于深度独立循环神经网络关联向量机(deep independent recurrent neural network relevance vector machine, DIndRNN-RVM)的深度融合网络用于评估预测结果的可信度范围,增强了预测结果的可用性。进一步为 AGC 在线决策中指令执行的可信度提供量化决策支撑。

算例以某省级电网中真实机组运行数据进行仿真分析,从模型构建和优化求解两个层面对本文提出的模型及策略进行验证,模型部分的计算分析突出了本文构建的模型在机组出力精准预测上的优势,模型求解中不同优化方法的计算分析,则验

证本文提出的预处理策略在模型训练和收敛性上的优势，而对深度融合技术的仿真分析则从概率的角度进一步对预测结果的可用性进行评估，增强了调控人员对预测结果可靠性的直观判别。

### 1 基于DRNN的指令执行效果精准辨识框架

DRNN 是一种通常意义上的深度神经网络(多层感知机)，其特点在于每层都有时间反馈循环，并可以实现层内连接的添加<sup>[19]</sup>。这使得该模型更加适合处理序列数据相关的机器学习任务。

#### 1.1 循环神经网络

循环神经网络(recurrent neural networks, RNN)是一种反馈型神经网络。在 RNN 中，隐藏层中的神经元之间不再是彼此无连接情况，而是互相连接；并且隐藏层的输入包括两个部分：1) 当前输入层的输出，2) 上一时刻隐藏层的输出。

标准的 RNN 通常由 1 个输入层、1 个隐藏层和 1 个输出层组成，如图 1 所示。




图 1 循环神经网络

Fig. 1 Recurrent neural network

标准 RNN 的训练过程包括两个部分：前向传播和反向传播。

##### 1) 前向传播。

对于给定  $n$  维输入序列  $x_1, x_2, \dots, x_n$ ,  $m$  维网络的隐层状态序列  $h_1, h_2, \dots, h_m$ ,  $k$  维输出序列  $y_1, y_2, \dots, y_k$ , 迭代公式如式(1)—(2)所示<sup>[4]</sup>。

对于  $t$  时刻：

$$h_t = \sigma(Wx_t + Uh_{t-1} + b_h) \tag{1}$$

$$o_t = Vh_t + b_y \tag{2}$$

最终模型的预测输出为

$$\hat{y}^{(t)} = \phi(o^{(t)}) \tag{3}$$

式中： $W, U, V$  为权值矩阵； $b_h, b_y$  为偏置； $o^{(t)}$  为输出单元的输入； $\sigma, \phi$  为预定义的激活函数，一般选择  $\tanh$  函数和  $\text{softmax}$  函数。

##### 2) 反向传播。

全局误差  $E$  为

$$E = \sum_{i=1}^t e_i = \sum_{i=1}^t f_e(y_i - d_i) \tag{4}$$

式中： $e_i$  为第  $i$  个时间步的误差； $y$  为输出层预测结果； $d$  为实际结果；误差函数  $f_e$  为交叉熵(cross entropy, CE)。

由于 RNN 模型与时间序列有关，因此不能直接使用反向传播(back propagation, BP)算法。针对 RNN 问题的特殊情况，使用“随时间变化的反向传播算法”(back propagation through time, BPTT)算法。利用输出层的误差  $e$ ，求解各个权重  $\nabla V, \nabla U, \nabla W$ ，然后梯度下降更新各个权重。

各个权重的更新的递归公式。

$$\begin{cases} V(t+1) = V(t) + \alpha \cdot \nabla V \\ U(t+1) = U(t) + \alpha \cdot \nabla U \\ W(t+1) = W(t) + \alpha \cdot \nabla W \end{cases} \tag{5}$$

#### 1.2 深度循环神经网络

深度循环神经网络(deep recurrent neural networks, DRNN)模型建立在多层 RNN 上，使得模型更加的非线性化，也使得模型可以承载更多的参数<sup>[7]</sup>。图 2 给出具有 3 层隐藏层的 DRNN 结构简图。

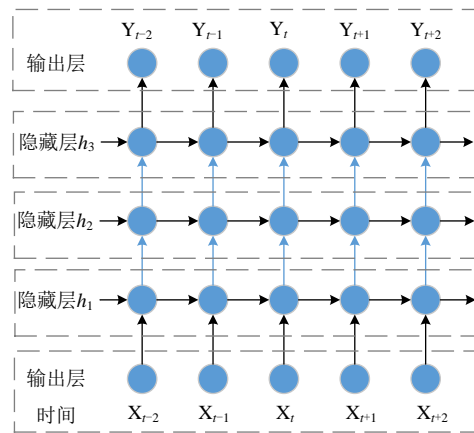


图 2 深度循环神经网络

Fig. 2 Deep recurrent neural network

输入层和输出层分别有  $k$  和  $n$  个神经元，对应  $k$  个特征输入和  $n$  个输出。其中，每层神经元的个数、循环神经网络中的时间步长以及神经元的激活函数需要根据训练经验不断调试得出。

第一层是输入层(input)，主要是将经过预处理的数据集的特征数据作为网络的输入，用于下一层的学习。

第二到四层是隐藏层(hidden)，主要是对输入层输入的特征数据进行自动学习，提取数据中隐藏的有用信息。

第五层是输出层(output), 负责将隐藏层学习到的信息转成最终结果输出。通过将最终的预测结果与真实结果进行对比, 将误差信息反向传回到隐藏层中进行网络参数的微调, 以减少预测值与真实值的误差, 然后将更新的网络参数用于下一次的训练, 通过不断的训练迭代来不断减小预测值与真实值之间的误差。

在深度循环神经网络的训练过程中, 主要分为前向传播和反向传播两步。

#### 1) 前向传播。

采用 Xavier 初始化方法对神经网络的权重进行初始化, 从而避免了随机赋予初始权值导致的训练周期过长及模型易陷入局部最优的问题。

第一层隐藏层的公式如式(6)所示。

$$h^{(1)}(x_t) = \sigma(W^{(1)}x_t + b^{(1)} + Uh^{(1)}(x_{t-1})) \quad (6)$$

DRNN 使用当前时刻的输入数据  $x_t$  和前一时刻对  $x_{t-1}$  重构值  $h^{(1)}(x_{t-1})$  计算隐藏层  $h^{(1)}(x_t)$  激活值;  $W^{(1)}$  和  $U$  为连接权值;  $b^{(1)}$  为当前层的偏置;  $\phi$  为激活函数  $\tanh$ 。

则 DRNN 网络在  $t$  方向的状态更新公式为

$$h^{(i)}(x_t) = \sigma(W^{(i)}h^{(i-1)}(x_t) + b^{(i)}) \quad (7)$$

式中  $h^{(i)}(x_t)$  为第  $i$  层的激活值, 且  $i$  大于 1, 对于每个隐藏层都有一个对应的权值  $W^{(i)}$  和偏置  $b^{(i)}$ 。

#### 2) 反向传播。

通过 BPTT 算法, 更新 DRNN 的权重参数  $W$ ,  $U$ ,  $V$ 。BPTT 算法的核心思想是用随机梯度下降算法进行一步步的迭代, 直到得到最终需要的参数  $W$ ,  $U$ ,  $V$ 。BPTT 算法与 BP 算法的区别在于, BPTT 算法同时考虑了层级间的纵向传播和时间上的横向传播, 同时在两个方向进行参数优化, 最终使整个 DRNN 网络的映射达到最优。

### 1.3 深度循环神经网络的改进

DRNN 处理时间序列的问题的效果很好, 但是仍然存在着一些问题, 其中较为严重的是容易出现梯度消失或者梯度爆炸的问题, 这使得 RNN 学习长期依赖关系的能力比较差, 导致 DRNN 在处理长序列问题上性能降低。为解决这些问题, 在 RNN 的基础上做出了改进, 提出了长短时记忆网络<sup>[20]</sup> (long short-term memory, LSTM) 和门控循环单元<sup>[21]</sup> (gated recurrent unit, GRU)。这 2 种网络结构在一定程度上改善了梯度消失或者梯度爆炸的问题, 但是由于 LSTM 和 GRU 使采用  $\tanh$  或者 sigmoid 作

为激活函数, 会导致网络层之间的梯度衰减, 因此, 构建和训练基于 RNN 的深度 LSTM 或 GRU 存在困难。

通过使用独立循环神经网络 (independently recurrent neural network, IndRNN) 可以有效地解决上述问题<sup>[22]</sup>。IndRNN 的状态更新公式为

$$h_t = \sigma(Wx_t + U \odot h_{t-1} + b_h) \quad (8)$$

式中  $\odot$  为哈达马积 (hadamard product, HP), 这是与传统 RNN 网络最大的区别。IndRNN 的每一个时刻的 cell 内的某个神经元只与其他时刻的 cell 中对应的神经元有关, 与其他神经元无关。因此, 神经元之间的连接可以通过堆叠多层 IndRNN 单元实现, 使 IndRNN 向深层拓展。

对于第  $n$  个神经元, 时刻  $t$  的隐藏状态可通过计算得到:

$$h_{n,t} = \sigma(W_n x_t + u_n h_{n,t-1} + b_h) \quad (9)$$

式中  $w_n$  和  $u_n$  分别为第  $n$  行神经元的输入权重和隐藏层权重。

与传统 RNN 相比, IndRNN 可以更好的与 non saturate 函数结合起来工作, 例如 Relu, 并且更具鲁棒性。传统 RNN 在反传梯度时变化更大, 不容易控制, 稳定性差, 而 IndRNN 的梯度只是与  $U$  有关, 波动性不大。

IndRNN 展现了一种随着时间步的延伸 (通过  $U$ ) 独立地聚集空间模式 (通过  $W$ ) 的新视角。通过堆叠多层神经元, 下一层中的每个神经元独立地处理前一层中所有神经元的输出, 降低了构建深度网络结构的难度, 增强了对长序列问题的处理能力。

### 1.4 AGC 指令执行效果精准辨识及框架

图 3 展示了基于深度循环神经网络的 AGC 指令执行效果精准辨识的整体框架。

## 2 基于 KPCA 的模型输入预处理策略

第 1 节分析了辨识模型的主要框架, 就本文的实际问题而言, 模型的输入变量并没有确定的规则, 若输入变量太多, 无疑会对训练的效率产生极大的影响, 甚至造成训练难以收敛, 若输入变量太少, 则有可能导致影响输出的关联变量丢失, 从而影响模型的精度, 因此在模型训练前期, 确定合理的输入变量 (即: 对所有相关输入变量进行降维处理) 将能极大的提高训练的效率, 加快模型训练的收敛性<sup>[23]</sup>, 因此如何降低模型的输入变量维度将是决定模型训练能否高效的关键。

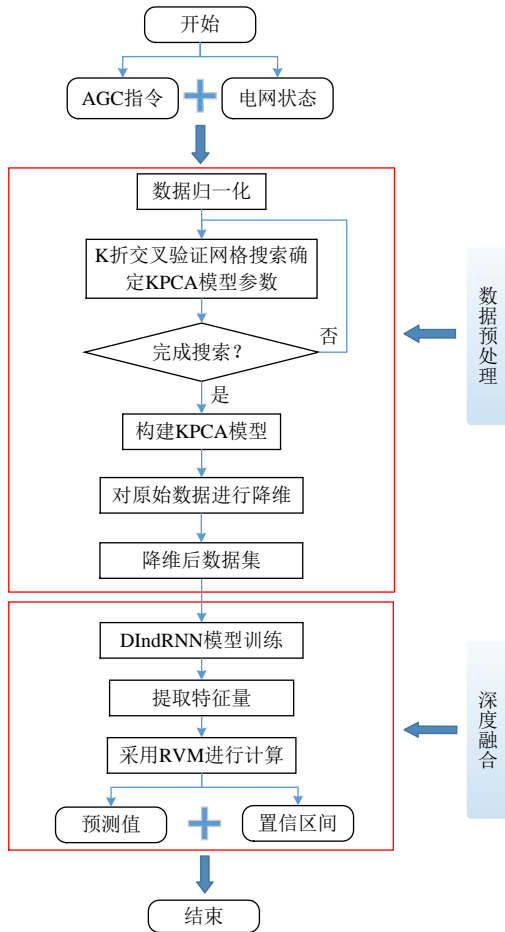


图3 AGC指令执行效果精准辨识框架

Fig. 3 Precise identification framework of AGC instruction execution effect

2.1 KPCA 原理

核主成分分析(kernel principal component analysis, KPCA)是一种基于核函数的非线性数据集降维策略<sup>[24]</sup>,该方法不但能保留全局特征而且能发掘数据集中的非线性信息。KPCA 主要思想是将一组集合样本  $S=\{w_1, \dots, w_n\}$ , 通过非线性映射  $\phi:R^N \rightarrow G$  投影到高维空间  $G$ , 然后对高维空间的数据样本采用主成分分析(principal component analysis, PCA), 最终再通过从高维  $G$  空间投影回  $R^N$  空间得到分析结果。

在高维空间  $G$  中协方差矩阵为

$$\bar{C} = \frac{1}{N} \sum_{j=1}^N \phi(w_j) \phi(w_j)^T \quad (10)$$

根据 Mercer 定理, 对式(10)进行分解得到特征方程:

$$\lambda v = \bar{C} v \quad (11)$$

式中:  $\lambda$  为特征值;  $v$  为特征向量。改写式(11)可得:

$$\lambda(\phi(w_k) \cdot v) = (\phi(w_k) \cdot \bar{C} v) \quad (12)$$

而特征向量又可通过数据集线性表示, 则:

$$v = \sum_{i=1}^N \gamma_i \phi(w_i) \quad (13)$$

式中  $\gamma_i$  为第  $i$  个线性项的系数。综合式(10)—(12) 可得:

$$\lambda \sum_{i=1}^N \gamma_i [\phi(w_k), \phi(w_i)] = \frac{1}{N} \sum_{i=1}^N \gamma_i [\phi(w_k), \sum_{j=1}^N \gamma_j \phi(w_j)] \quad (14)$$

令核函数  $k(w_i, w_j) = [\phi(w_j), \phi(w_i)]$ , 则投影  $p(i)$  为

$$p(i) = \sum_{j=1}^N \gamma_j k(w_i, w_j) \quad (15)$$

2.2 基于 KPCA 的输入变量预处理流程

影响机组真实出力的因素较多, 通常是各种因素共同作用所导致, 主要包括: 机组的规模和类型、机组接受 AGC 指令时的有功出力, 无功出力, 电压, 电流, 负荷情况, AGC 指令下发的日期(季节, 工作日, 节假日等), 时间(峰谷情况), 当时的天气情况(温度, 湿度等), 以及是否有其他极端情况(台风, 雨雪, 地震等)。因此, 如何确定合理的输入变量, 将关系到模型的训练效率和收敛性, 本文采用 KPCA 方法来挑选与机组真实出力关联性较强的输入变量, 从而实现对模型输入维度的确定, 具体步骤为:

- 1) 选定影响机组出力的所有相关特征变量构成输入向量  $A, A=\{a_1, \dots, a_u\}$  ( $u$  为输入变量的个数)。
- 2) 对向量  $A$  中所有的相关变量所对应的数据集进行标准化处理, 利用式(11)进行归一化处理, 映射到  $[0,1]$  范围内。

$$f: x \rightarrow y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (16)$$

$$x, y \in R^n, \quad x_{\min} = \min(x), x_{\max} = \max(x)$$

- 3) 构建高斯径向基核函数。

$$k(\|x - x_c\|) = \exp\left(-\frac{\|x - x_c\|^2}{4\sigma^2}\right) \quad (17)$$

式中:  $x$  为空间  $R^n$  中的任意一点;  $x_c$  为核中心;  $\sigma$  为控制径向大小的参数。

- 4) 根据式(10)得到协方差矩阵  $C$ , 并计算协方差矩阵  $C$  的特征向量  $v$  和特征值  $\lambda$ , 并对特征值排序有  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_u$ 。

- 5) 计算各特征值的贡献率  $r_i$  如式(18)所示。

$$r_i = \frac{\lambda_i}{\sum_{i=1}^u \lambda_i} \quad (18)$$

根据特征值贡献率的结果，给定阈值 $\gamma$ ，选取贡献率大于给定阈值 $\gamma$ 的特征值存入集合  $Q$  中  $Q=\{\lambda_1, \lambda_2, \dots, \lambda_z\}$ ，确定主成分，并计算主成分的累计贡献率  $r_{\Sigma}(Z)$ ，如式(19)所示。

$$r_{\Sigma}(Z) = \sum_{i=1}^z \lambda_i / \sum_{i=1}^n \lambda_i \quad (19)$$

6) 若  $r_{\Sigma}(Z) \geq \varepsilon$  ( $\varepsilon$ : 给定阈值)保存主元序号以及主元个数，并计算  $z$  个特征值对应的特征向量，构成新的特征向量集合  $B=\{b_1, b_2, \dots, b_z\}$ ，否则重新确定主成分。

7) 寻找特征值向量所对应的主元序号，保存降维后的主元个数到集合  $P=\{p_1, p_2, \dots, p_z\}$ ，将集合  $P$  作为后续模型的输入变量。

图 4 给出基于 KPCA 的模型输入预处理流程。

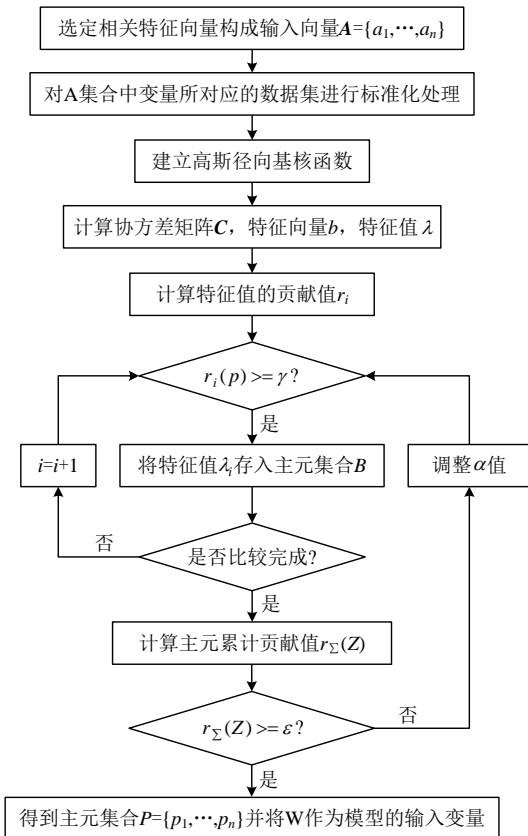


图 4 基于 KPCA 的输入变量预处理流程图  
Fig. 4 Flow chart of input variable preprocessing based on KPCA

在构建 KPCA 模型时需要确定最优降维维度和高斯核函数 $\sigma$ 的值。降维维度和高斯核函数 $\sigma$ 决定了后续模型的复杂度。复杂度过高，降维的目的没有达到；复杂度过低，降维模型会造成较多的信息丢失，影响后续模型的精度。本文采用 K 折交叉验证网格搜索算法(grid search with K-fold Cross-Validation, GS-KCV)确定 KPCA 模型参数。将降维

维度和高斯核函数 $\sigma$ 作为优化对象；降维模型的评价标准在于能够最大化保留原始数据的信息，因此，可以使用具有较强回归能力的多层感知机模型(multilayer perceptron, MLP)对降维后数据进行拟合，用 MLP 模型预测均方误差作为降维模型的评价指标。

网格搜索<sup>[25]</sup>是一种机器学习模型调参方法。它通过遍历给定参数组合来优化模型。传统的网格搜索算法存在的问题是原始数据除了用作调整参数，也用来作为网格搜索的评价标准。这种做法会导致最终的评分效果比实际的好。为解决这个问题，可以采用 K 折交叉验证法。

图 5 给出 K 折交叉验证网格搜索法执行过程。

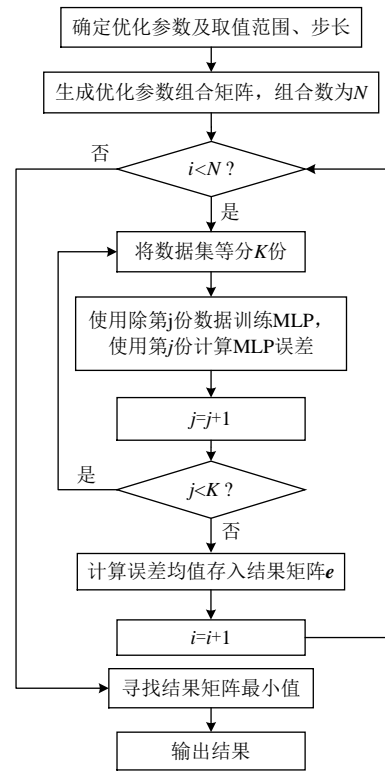


图 5 KPCA 模型最优参数确定流程图  
Fig. 5 Determination of optimal parameters of KPCA model

### 3 基于 DIndRNN-RVM 机组出力趋势预测

#### 3.1 基于关联向量机输出不确定性研究

传统的机器学习算法输出常是一个决策结果并没有后验概率，而在许多现实场景中(例如本文机组实际出力问题)，不仅需要预测值，还需要评估预测结果的可靠程度。为此引入基于贝叶斯模型的关联向量机<sup>[26]</sup>(relevance vector machine, RVM)，该方法在一个新的输入向量  $x$  的情况下，能够输出目标变量  $t$  的概率分布，如式(20)所示。

$$p(t|x, \omega, \beta) = N(t|y(x), \beta^{-1}) \quad (20)$$

其中  $\beta = \sigma^{-2}$ , 为噪声方差的倒数, 均值由一个线性模型给出, 形式如式(21)所示。

$$y(x) = \sum_{n=1}^N \omega_n k(x, x_n) + b \quad (21)$$

需要求解的参数规模为  $M=N+1$ ,  $N$  为样本规模, RVM 模型训练过程如下:

1) 将所有训练集的输入合在一起, 记作数据矩阵  $\mathbf{X}$ , 对应的目标输出为  $t$ , 似然函数如式(22)所示。

$$p(t|\mathbf{X}, \omega, \beta) = \prod_{n=1}^N p(t_n|x_n, \omega, \beta) \quad (22)$$

2) 计算参数向量  $\omega$  上的先验分布:

$$p(\omega|\alpha) = \prod_{i=1}^M N(\omega_i|0, \alpha_i^{-1}) \quad (23)$$

式中  $\alpha_i$  为  $\omega_i$  的独立超参数。

3) 计算参数向量  $\omega$  上的后验分布:

$$p(\omega|t, \mathbf{X}, \alpha, \beta) = N(\omega|m, \Sigma) \quad (24)$$

均值为  $m = \beta \sum \Phi^T t$

方差为  $\Sigma = (A + \beta \Phi^T \Phi)^{-1}$

式中:  $\Phi$  是  $N \times M$  的矩阵,  $\Phi_{ni} = k(x_i, x_n)$ , 且  $\Phi_{nM} = 1 (n=1, \dots, N)$ ;  $A = \text{diag}(\alpha_i)$ 。

$\alpha$  和  $\beta$  的值使用第二类最大似然法来确定。边缘似然函数为:

$$p(t|\mathbf{X}, \alpha, \beta) = \int p(t|\mathbf{X}, \omega, \beta) p(\omega|\alpha) d\omega \quad (25)$$

$$\ln p(t|\mathbf{X}, \alpha, \beta) = -\frac{1}{2} \{N \ln(2\pi) + \ln |C| + t^T C^{-1} t\} \quad (26)$$

4) 为最大化超参数  $\alpha$  和  $\beta$ , 可以令边缘似然函数的导数等于 0, 得到重估计方程, 求极值点。

$$\alpha_i^{\text{新}} = \frac{\gamma_i}{m_i^2} \quad (27)$$

$$(\beta^{\text{新}})^{-1} = \frac{\|t - \Phi m\|^2}{N - \sum_i \gamma_i} \quad (28)$$

5) 找到最大化边缘似然函数的超参数  $\alpha^*$  和  $\beta^*$  的值之后, 对于新的输入  $x$ , 可以计算  $t$  上的预测分布。预测分布为

$$p(t|x, \mathbf{X}, t, \alpha^*, \beta^*) = \int p(t|x, \omega, \beta^*) p(\omega|\mathbf{X}, t, \alpha^*, \beta^*) d\omega = N(t|m^T \phi(x), \sigma^2(x)) \quad (29)$$

方差和均值为:

$$\sigma^2(x) = (\beta^*)^{-1} + \phi(x)^T \Sigma \phi(x) \quad (30)$$

$$y(x) = \sum_{n=1}^N \omega_n k(x, x_n) + b \quad (31)$$

### 3.2 DIndRNN-RVM 深度融合算法

根据第 1 节的内容可知 DIndRNN 具有强大的时间序列处理能力与长期预测能力, 然而在实际的电网中, 为了使模型更好的接入 AGC 系统, 我们不仅需要模型输出预测值, 而且还需要模型给出预测值的不确定度表达, 而这种能力是 DIndRNN 模型所欠缺的。传统机器学习算法关联向量机具备给出不确定度表达的能力, 它所给出的结果不是一个确定的值, 而是一个服从正态分布的随机量。但是关联向量机在处理复杂输入时训练时间较长收敛性较差<sup>[27]</sup>。考虑到两种方法在特点上的互补性, 本文提出将两种模型进行深度融合, 提高算法整体性能。

融合后的模型本质上还是一个 DIndRNN 模型, 不同之处在于其最后的输出层用关联向量机来替代, 这样处理既可以充分发挥其处理长序列的能力, 同时又能降低关联向量机处理复杂输入能力不足的缺点对融合模型的影响。而对 RVM 的输入而言, 此时已经是经 DIndRNN 特征提取后的数据, 其复杂度与时间依赖关系已经大幅下降, 因此可以充分发挥其输出不确定度的优势, 两种算法融合后互相取长补短, 进一步提高模型预测的整体性能。

DIndRNN-RVM 融合算法框架的训练分为两个部分: 训练阶段和测试阶段。

1) 训练阶段。

训练阶段将对两个模型进行单独训练。首先训练 DIndRNN 网络, 需要注意的是, 在单独训练 DIndRNN 时, 由于网络只含 IndRNN 层, 输出的是原始序列特征, 需要在网络最后加入全连接层, 将特征映射到训练标签上, 保证训练正常进行。其次训练关联向量机网络, 此时用已完成训练的 DIndRNN 网络进行原始数据序列特征的提取, 并将提取的特征送入关联向量机网络, 再使用标签进行训练。

2) 测试阶段。

测试阶段选取测试集合中的一组 AGC 指令和对应的输入变量输入模型, 计算得到单个预测值和不确定度, 实现机组出力周期内的单步预测功能。

融合算法具体步骤如下：

- 1) 根据原始输入数据的维数和序列长度，建立 DIndRNN 模型。
- 2) 通过从原始输入数据中提取特征，借助最后的全连接层将特征映射到标签进行训练。模型使用 Tensorflow2.0 构建，并使用梯度下降法和 Adam 优化方法反复调整内部权重参数以完成模型训练。
- 3) 用训练好的 DIndRNN 模型提取原始数据特征，将新的提取特征输入 RVM 网络，借助标签完成关联向量机内部参数的求解，得到最终的融合模型。
- 4) 将一组测试样本输入融合模型，得到输出结果的分布输出，包括均值与方差，实现单步预测。
- 5) 得到本次预测结果后，将预测结果的均值与真实数据进行比较，评估模型精度，若预测结果误差小于给定阈值 $\xi$ 则结束训练，否则加入新的样本重新训练模型，直到模型精度满足要求为止。

图 6 展示了融合算法训练框架。

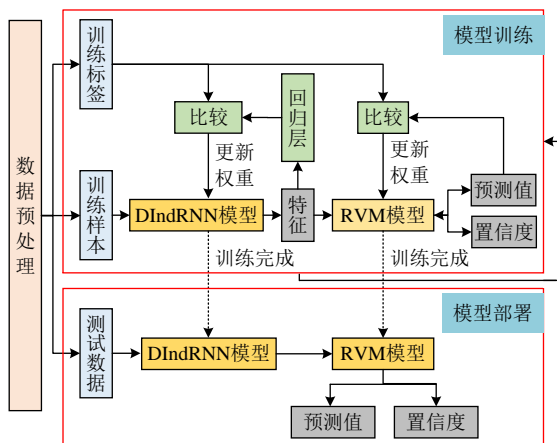


图 6 融合算法框架图

Fig. 6 Framework of fusion algorithm

### 3.3 基于 DIndRNN-RVM 的机组出力态势预测

DIndRNN-RVM 模型能够根据过去一段时间内序列数据预测未来一个周期的数据。在需要预测多个周期时，可以采用滚动预测的方法进行。

具体步骤为每当预测出一个数据后，将预测的数据加入到历史数据中作为新的模型输入用于预测下一个周期，通过不断循环可以实现多步预测。

由于关联向量机模型所给出的是一个服从正态分布的随机量，随机量可以用均值和方差来表达，不是传统的单个预测值。融合模型也是如此，因此在滚动预测中，需要做出如下假设：1) 假定方差在 DIndRNN 模型中不变，随机量在 DIndRNN 部分中按均值计算；2) 由于关联向量机模型中从

输入到输出为线性计算，方差计算遵循平方叠加；3) 假定原始输入历史数据方差为 0。

具体原理如图 7 所示。




图 7 基于 DIndRNN-RVM 的机组出力趋势预测

Fig. 7 Trend prediction of unit output based on DIndRNN-RVM

### 3.4 融合模型的应用部署分析

融合模型在实际应用中常出现以下问题，1) 融合模型训练耗费大量时间，难以满足在线要求。2) 机组的运行状态常受电网变化、天气等原因影响，预测和评估精度难以保证。为了解决以上问题，在实际应用中除了预测模型需要被接入 AGC 系统，还需要部署一套离线训练服务器。离线训练服务器通过平台提供的 API 接口，实时读取机组运行数据，当数据累积至给定周期后，使用获取到的周期数据再次训练预测模型并得到新的预测模型，将新模型更新到 AGC 系统并覆盖原有预测模型，以此实现模型的动态更新。

模型训练和模型调用分别由训练服务器和 AGC 服务器完成，二者互不干扰。由于模型的调用和模型的覆盖都是毫秒级，而调度通常是分钟级，因此算法能够满足在线应用。此外，采用“离线训练+在线调用”的框架模式，能通过周期性的离线训练不断完善融合模型，最终通过模型的动态更新来适应不同外部条件下融合模型的精准预测。图 8 给出了融合模型的应用部署情况。

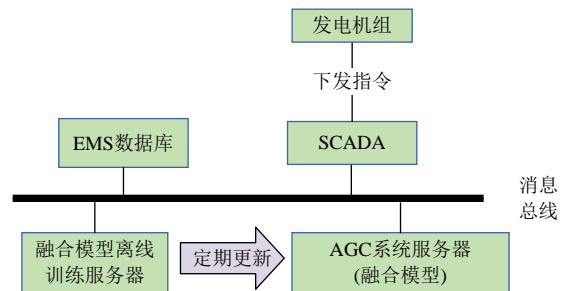


图 8 应用部署结构图

Fig. 8 Application deployment structure diagram

### 3.5 基于融合模型的 AGC 指令修正方法

在实际电网中会出现部分发电机对 AGC 指令值跟踪偏差较大的情况，为缩小发电机组对 AGC



计算指令的执行偏差,提高电网运行的安全性,AGC 系统在计算指令下达前,可先通过融合模型对指令执行效果进行预测,根据预测结果修正计算指令值,进一步提高调控的精度。具体实施方法为:AGC 系统在下发计算指令前,首先以上一个周期指令的执行偏差( $\Delta P_{\text{before}}$ )为基准,模拟机组在偏差方向上的递增出力,递增步长为 $\lambda_{\Delta}=\Delta P_{\text{before}}/N_{\Delta}$  ( $N_{\Delta}$ 取 100),并以此生成新的模拟指令集合。最后通过调用本文提出的融合模型,计算指令集合内所有指令对应的机组出力预测值,将最接近 AGC 计算指令的预测值所对应的模拟指令作为 AGC 指令修正值,并进行下发控制。

### 4 算例分析

#### 4.1 算例基本情况

为验证本文提出模型和控制方法的有效性和合理性,引入电网真实数据作为分析对象。数据时间跨度为半年,采样频率为 1min,原始数据共 262080 条。算例所用模型均采用 Google 公司旗下深度学习框架 Tensorflow2.0 构建;编写的语言为 python3.7.6;所用计算机配置为 Intel(R) Core(TM) i7-9750H CPU @2.60GHz,内存 16G。

#### 4.2 训练集和测试集的对比分析

DIndRNN 模型在测试集与训练集的单步预测结果如图 9 所示。

从图 9 可以看出,在不同数据集上 DIndRNN 模型的预测值均能较好的拟合机组实际出力,这表明模型的泛化能力较好。表 1 则进一步给出不同

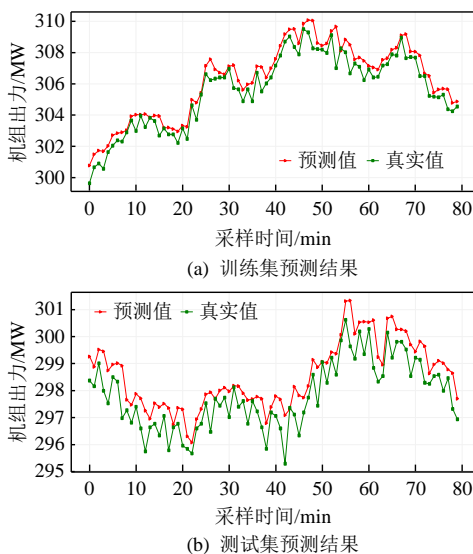


图 9 训练集与测试集预测对比分析

Fig. 9 Comparative analysis of training set and test set prediction

表 1 训练集与测试集的评价量化对比

Table 1 Quantitative comparison of evaluation between training set and test set

变量	平均绝对值误差	均方误差
训练集	3.2432	29.8237
测试集	3.2769	43.3386

训练数据集上的量化分析结果,从表 1 可以看出,模型在训练集和测试集得到的预测结果在和机组真实值比较时的平均绝对值误差(mean absolute error, MAE)相差较小,误差率为 0.009%,这说明 DIndRNN 模型能较好的适应机组出力的预测,而不同集合上的均方误差(Mean Squared Error, MSE)结果却相差较大,这反映了在训练集上误差分布更为分散,且存在误差较大的测试点,这也进一步说明在测试集上的误差波动相比较训练集要更大。

#### 4.3 不同模型的对比分析

为进一步论证本文提出模型在出力预测上的有效性,本节将 DIndRNN 模型与不同类型机器学习模型的预测结果进行对比分析。

##### 4.3.1 DINDRNN 模型和 BP 模型比较

DIndRNN 模型与传统机器学习算法 BP 模型对比预测结果如图 10 所示。

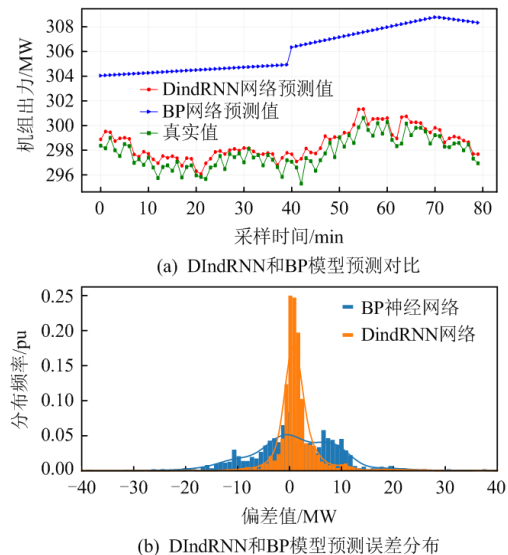


图 10 DIndRNN 和 BP 模型对比分析

Fig. 10 Comparative analysis of DIndRNN and BP model

从图 10(a)可以看出, BP 模型的预测值呈现出线性特征且与真实值偏差较大,这是因为在 BP 模型中,神经元无法保存历史信息;因此 BP 模型难以对时间序列做出预测。而 DIndRNN 模型因具有保存过往周期预测结果的特性,因此能够在时间序列预测上较好的拟合真实值。

图 10(b)则从误差分布的角度给出了两种模型的误差分布图，横坐标为误差分布区间，纵坐标为出现频率；直方图给出了预测值与真实值的误差在各个区间内出现的频率，曲线则是对误差直方图的拟合。从图 10(b)中可以看出，BP 模型误差分布较为分散，而 DIndRNN 模型误差则较为集中且分布于 0 附近，这也直观的反应了 DIndRNN 模型的预测偏差更小。

表 2 进一步给出两种模型定量对比分析结果，从表中可以看出 DIndRNN 模型预测结果的 MSE 和 MAE 都显著优于 BP 模型，这和图 10(b)的分析结果一致。

表 2 DIndRNN 与 BP 模型的评价量化对比


Table 2 Quantitative comparison between and BP model

变量	BP	DIndRNN
MAE	7.0218	2.7235
MSE	96.1483	29.3118


4.3.2 不同深度神经网络效果的比较分析

DIndRNN 模型与其它深度神经网络模型(LSTM 和 RNN)比较结果如图 11 所示。

图 11(a)给出了不同网络模型预测结果的曲线图，从图 11(a)中可以看出，总体上深度神经网络模型均能较好的模拟真实值，但从局部放大图可以发现红色曲线更贴近真实值(即：DIndRNN 网络更贴近真实值)。图 11(b)则给出了不同深度模型的预测误差分布情况，从图 11(b)中可以看出，3 种模型误



(a) DIndRNN、LSTM、RNN模型预测对比



(b) DIndRNN、LSTM、RNN模型预测误差分布

图 11 DIndRNN、LSTM、RNN 对比分析

Fig. 11 Comparative analysis of DIndRNN, LSTM and RNN

差分布都集中于 0 附近，但是 DIndRNN 模型的最大分布频率更高，这也间接反映了 DIndRNN 模型预测结果相比其他模型和真实值更贴近。

表 3 给出了不同模型单周期预测的量化比较结果，从表 3 中可以看出，在 MAE 和 MSE 两个指标上，DIndRNN 模型预测精度都优于 RNN 和 LSTM。

表 3 不同模型预测精度量化对比

Table 3 Quantitative comparison of prediction accuracy of different networks

变量	RNN	LSTM	DIndRNN
MAE	3.2770	3.0681	2.7235
MSE	43.3387	32.0106	27.6217

4.3.3 不同深度模型的多步滚动预测分析

为了进一步分析深度模型在较长时间段内的预测效果，本节将 DIndRNN 模型用于多周期预测，并与其他深度模型的预测结果进行对比分析。

图 12 给出了不同深度模型在多步滚动预测下的出力情况分析，从图中可以看出，蓝色曲线在初始时刻就严重偏离真实值，这是因为 RNN 模型受限于模型结构，神经元在时间上进行参数共享，所以会出现梯度消失与爆炸问题，因此在进行多步滚动预测初期就出现了较大偏离。




图 12 不同深度模型多步滚动预测分析

Fig. 12 Multi step long term prediction analysis of different depth models

红色曲线和黄色曲线分别代表 LSTM 和 DIndRNN 模型的预测结果，从图 12 中可以看出，两条曲线在初始的 10min 内都能较好的拟合真实曲线，但在红色曲线在 10min 后出现了较大的预测误差，虽然 LSTM 网络引入了遗忘机制，但仍然会出现梯度层间衰减，这使得它无法捕捉长序列信息。而黄色曲线尽管在 10 到 30min 内拟合真实值曲线略有偏差(但偏差率不大于 5%)，但总体上前 30min 内都一直能够较好地贴近真实曲线。

因此从以上的分析可以看出 DIndRNN 模型在短期预测中相比另外两种深度模型的拟合效果略好，尤其是在中长期预测能力上明显优于另外两种

模型，这是因为模型中引入 Relu 非饱和激活函数，使得 DIndRNN 较好的解决了梯度消失与爆炸问题，进一步说明本文引入的 DIndRNN 模型能够提高中长期预测精度。

#### 4.4 预处理策略对运行结果影响分析

模型的输入特征包括：AGC 指令值、指令执行时间、机组当前出力、机组所在电网总负荷、机组所在电网频率、机组所在地空气温度、机组绕组电流、机组母线电压，共 8 个特征。较多的特征不仅会使模型训练过程变得缓慢，而且会使模型训练过程中难以找到全局最优进而降低模型精度。因此，本文采用基于 KPCA 的降维策略对模型原始输入数据进行预处理，进一步提高模型收敛性和精度。

##### 4.4.1 多种降维方式比较分析

KPCA 模型需要指定核函数，除了某些特定场景的问题，如何选取合适的核函数，目前并无定论。在众多核函数中，由于高斯核函数具有参数少，满足 Mercer 条件等优点，被广泛使用。本文采用高斯核作为模型的核函数<sup>[28]</sup>。

使用 K 折交叉验证网格搜索算法确定高斯核函数最优  $\sigma$  值和最优降维数，最终所求得最优  $\sigma$  值为 8.433；最优降维数为 4。

为验证 KPCA 降维模型的有效性，本节将其与常用的降维模型：局部线性嵌入 (locally linear embedding, LLE) 和线性降维模型主成分分析 (principal component analysis, PCA) 模型进行对比分析；进一步分析不同降维方法在相同维度下的应用差异，采用 MLP 和 DIndRNN 输出模型对降维效果进行测试，训练后均方误差和平均绝对值误差<sup>[29]</sup> 如表 4 所示。

表 4 DIndRNN 与 BP 模型的评价量化对比

Table 4 Quantitative comparison between DIndRNN and BP model

变量	测试模型	KPCA	LLE	PCA
MAE	MLP	6.0864	11.0939	110.5678
	DIndRNN	3.1079	4.5653	37.6988
MSE	MLP	108.84864	388.7492	17 531.5742
	DIndRNN	33.4935	46.7214	1693.9397

从表 4 中可以看出，KPCA 模型和 LLE 模型在处理非线性降维问题时，相比于 PCA 线性降维模型有着较大的优势。经过 K 折交叉验证网格搜索算法参数优化后的 KPCA 模型则在预测精度略优于 LLE 模型。

#### 4.4.2 输入变量规模对预测效果的影响分析

表 5 给出不同维度下模型训练的误差对比。

表 5 DIndRNN 与 BP 模型的评价量化对比

Table 5 Quantitative comparison between DIndRNN and BP model

降维后的维度	平均绝对值误差	均方误差
3	6.8685	93.5082
4	2.8996	25.4714
5	3.0041	29.8051

从表 5 中可以看出，降维维度从 3 维变为到 4 维时，预测精度有所上升；但从 4 维变为 5 维时，预测精度则略微下降。由此可以看出，维度为 4 时是最优选择，这和 4.3.1 节的分析结果一致。

#### 4.4.3 基于 KPCA 的预处理对模型训练的影响

图 13 给出了是否采用预处理策略下模型训练过程中的损失下降情况。从图中可以看出，黄色曲线在初始 5 代内的训练误差值下降迅速，这表明模型经过预处理后输入变量减少，消除了数据维度上的冗余，模型得到了简化收敛加快，此外，黄色曲线在 30 代后逐渐趋于平缓但误差值相比蓝色曲线更小，这也表明预处理能简化模型，使模型在训练过程中能够更容易找到全局最优。




图 13 预处理对模型训练的影响

Fig. 13 Prediction results based on pretreatment DIndRNN-RVM model

#### 4.5 基于预处理的 DIndRNN-RVM 深度融合分析

##### 4.5.1 DINDRNN-RVM 输出不确定分析

图 14(a)给出了融合模型预测图，绿色、黄色、棕色着色区域分别对应 99.73%、95.45 和 68.27% 的随机取值区间。从图中可以发现，模型在单周期预测中，各个采样点概率分布差异不大且符合预期。真实值取值基本在 68.27% 区间，偶尔进入 95.45% 区间，这说明采用 RVM 层设计后模型输出的概率分布能够较好地贴近真实情况。图 14(b)给出了在 DIndRNN-RVM 融合模型和 DIndRNN 模型预测误差分布对比，从图 14(b)中可以看出，融合模型的误差分布更加集中且贴近于零点，这也进一步表明了融合模型的预测精度更高。

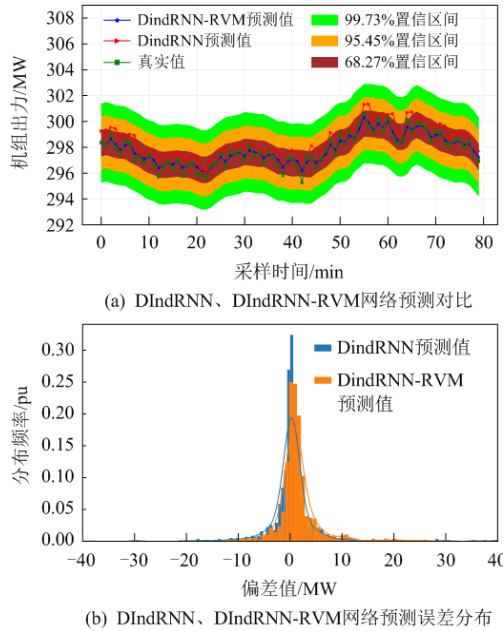


图 14 基于预处理 DIndRNN-RVM 模型的预测结果  
Fig. 14 Prediction results based on pretreatment DIndRNN-RVM model

4.5.2 融合模型的滚动预测结果分析

图 15 为融合模型滚动预测结果图。从图 15 中可以看出，蓝色曲线为不同位置预测值概率分布曲线，预测时长的增加，概率分布曲线逐渐趋于平缓，模型预测结果的方差遵循平方叠加原则并逐渐增加，不同概率取值区间也随之扩大，模型具有短期预测精度高，长期预测精度低的特点。此外，从图 15 中还可以看出，预测均值在前 30min 内能够较好的贴近真实值的变化，这也说明融合模型在中长期预测能力上与 DIndRNN 模型相近，随着时间步长的推进，预测值概率分布曲线趋于平缓，预测值方差扩大。

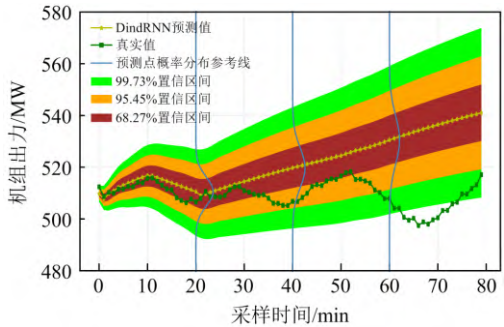


图 15 融合模型的长期预测结果

Fig. 15 Long-term prediction of DIndRNN-RVM model

从特定区间概率来看，取预测值与真实值偏差  $\pm 1$ 、 $\pm 2$ 、 $\pm 3$  的概率进行分析，如图 16 所示。

图 16 中曲线展示了真实值落在预测值固定偏差范围内的概率，可以明显看出随着滚动预测时间的推移，真实值落在各个取值区间内的概率在不断




图 16 不同区间的概率分析

Fig. 16 Probability analysis of different intervals

下降，前十分钟内概率快速下降，随后下降速度逐渐趋于平缓，这也反映了模型短期预测精度较高，但随着时间推移中长期预测精度变低。

4.5.3 多机出力预测结果分析

以上给出了电网中单台机组的出力辨识分析。为了证明本文所述方法具有普适性，本节将该方法应用在不同的火电机组，并验证所建模型的有效性和鲁棒性。从电网中随机选取 8 台机组进行出力预测和评估分析。

当融合模型应用到多台机组时，由于每台机组的运行环境各不相同，需要对每台机组进行单独的特征选取、输入降维和模型训练分析；训练得到的模型也仅适用于该台机组的预测，当 AGC 调用模型对多台机组进行预测时，需要分别调用各机组对应的模型进行分别预测。

图 17 给出了通过该方法在多台机组上的建模预测结果，从图中可以看出，多台机组预测结果(预测值和置信度)与上文算例相似，这表明通过该方法对不同运行状态的火电机组建立的模型均能较好的给出预测值和置信度，也进一步说明本文提出融合模型建模方法具有较强的普适性和鲁棒性。

4.5.4 融合模型的应用分析

以某省级电网实际运行断面为例，AGC 计算指令为：调节机组 A 出力至 304.34MW (即：指令 A)。表 6 给出了机组执行指令 A 后实际出力的变化情况 (第二列)。从表 6 可以看出，机组出力在 6min 后逐渐趋于稳定，稳定时段内的平均出力为 309.04MW，第 10min 出力为 309.29MW，与计算下发指令的差值为 4.95MW，控制偏差较大。采用本文 3.5 节的方法对 AGC 计算指令进行修正，指令修正值为 302.67MW (即：指令 B)，机组在 10min 后出力为 304.69MW，与 AGC 下发的计算指令值相差仅为 0.35MW，基本和 AGC 计算指令一致，表 6 的第 3 列给出了预测执行结果。




图 17 多台机组的长期预测结果

Fig. 17 Long term prediction of the model on units

表 6 机组实际出力和预测出力表

Table 6 Unit actual output and predicted output table

时间/min	指令 A 时的机组	指令 B 时的机组
	实际出力/MW	预测出力/MW
1	314.15	314.03
2	313.62	306.62
3	313.14	305.02
4	312.59	304.89
5	310.13	303.21
6	308.48	303.86
7	309.81	304.13
8	308.86	303.97
9	308.74	304.03
10	309.29	304.69

从以上分析可以看出, AGC 系统通过调用融合模型, 完成了对 AGC 计算指令的修正, 进而实现了调控机组精准执行 AGC 计算指令值的效果。

### 5 结论

本文提出一种基于 DIndRNN-RVM 深度融合模型的 AGC 指令执行效果精准辨识技术, 主要特点如下:

1) 给出一种基于深度学习技术的 AGC 指令执行效果精准辨识框架, 实现了调控人员对 AGC 指令执行效果的精准预测和感知。

2) 提出一种加快深度网络模型训练的预处理策略, 通过分析不同输入属性间的关联特性, 实现对模型输入属性的降维, 提出的预处理策略能够减

少训练时间并提高模型的收敛精度。

3) 提出一种基于 DIndRNN-RVM 的深度融合技术, 用于对预测结果进行不确定性评估, 给出预测结果在给定出力偏差范围内的可信度, 从概率的角度增强了预测结果的使用价值,

4) 采用传统神经网络模型, 不同深度学习网络模型以及本文提出的深度融合模型对机组执行指令的效果进行辨识和对比分析, 得到了在不同模型在短期和中长期预测精度上的优劣, 验证了本文提出模型和方法的优势。

本文对 AGC 指令执行效果的精准性进行了研究, 随着新能源的高渗透, 电网功率波动性进一步加大, AGC 如何依据对机组执行态势的精准感知, 进一步优化在线调控策略, 从而避免由于新能源波动导致的断面阻塞等问题, 将是值得继续深入研究的问题。

### 致谢

本文还得到了江苏省“六大人才高峰”创新人才团队(TD-XNY-004)、江苏省高校自然科学研究重大项目(17KJA470003, 18KJA470002)的资助, 在此表示感谢!

### 参考文献

[1] 李嘉文, 余涛, 张孝顺, 等. 基于改进深度确定性梯度算法的 AGC 发电功率指令分配方法[J]. 中国电机工程学报, 2021, 41(21): 7198-7212.

LI Jiawen, YU Tao, ZHANG Xiaoshun, et al. AGC

- generation power command allocation method based on improved depth deterministic gradient algorithm[J]. Proceedings of the CSEE, 2021, 41(21): 7198-7212(in Chinese).
- [2] 席磊, 张乐黄, 悦华, 等. 基于贪婪策略的多层自动发电控制[J]. 中国电机工程学报, 2020, 40(16): 5204-5217. XI Lei, ZHANG Le, HUANG Yuehua, et al. Multiple level automatic generation control based on the greedy strategy[J]. Proceedings of the CSEE, 2020, 40(16): 5204-5217(in Chinese).
- [3] 陈雪梅, 陆超, 刘杰, 等. 考虑调频性能考核的储能-机组联合调频控制策略[J]. 中国电机工程学报, 2021, 41(10): 3383-3391. CHEN Xuemei, LU Chao, LIU Jie, et al. Control strategy considering AGC performance assessment for BESS coordinated with thermal power unit in AGC[J]. Proceedings of the CSEE, 2021, 41(10): 3383-3391 (in Chinese).
- [4] 袁桂丽, 苏伟芳. 计及电动汽车不确定性的虚拟电厂参与 AGC 调频服务研究[J]. 电网技术, 2020, 44(7): 2538-2548. YUAN Guili, SU Weifang. Research on participation of virtual power plant in AGC frequency modulation service considering uncertainty of electric vehicle[J]. Power System Technology, 2020, 44(7): 2538-2548(in Chinese).
- [5] 闫何贵枝, 王克文, 刘艳红. 计及小干扰稳定约束的互联系统 AGC 最优经济控制策略[J]. 高电压技术, 2020, 46(4): 1302-1309. YAN Heguizhi, WANG Kewen, LIU Yanhong. AGC optimal economic control strategy for interconnected systems considering small disturbance stability constraints [J]. High Voltage Engineering, 2020, 46(4): 1302-1309(in Chinese).
- [6] 王宗杰, 郭志忠, 王贵忠, 等. 高比例可再生能源电网功率平衡的实时调度临界时间尺度研究[J]. 中国电机工程学报, 2017, 37(S1): 39-46. WANG Zongjie, GUO Zhizhong, WANG Guizhong, et al. On the critical timescale of real-time dispatch considering power balancing under power systems with high proportional intermittent power sources[J]. Proceedings of the CSEE, 2017, 37(S1): 39-46(in Chinese).
- [7] 王琦, 郭钰锋, 万杰, 等. 适用于高风电渗透率电力系统的火电机组一次调频策略[J]. 中国电机工程学报, 2018, 38(4): 974-984. WANG Qi, GUO Yufeng, WAN Jie, et al. Primary frequency regulation strategy of thermal units for a power system with high penetration wind Power [J]. Proceedings of the CSEE, 2018, 38(4): 974-984(in Chinese).
- [8] 叶林, 张慈杭, 汤涌, 等. 多时空尺度协调的风电集群有功分层预测控制方法[J]. 中国电机工程学报, 2018, 38(13): 3767-3780. YE Lin, ZHANG Cihang, TANG Yong, et al. Active power stratification predictive control approach for wind power cluster with multiple temporal and spatial scales coordination[J]. Proceedings of the CSEE, 2018, 38(13): 3767-3780(in Chinese).
- [9] 张磊, 罗毅, 叶婧, 等. 考虑联络线支援波动约束的多区域 AGC 最优联合调频控制策略[J]. 中国电机工程学报, 2017, 37(3): 676-684. ZHANG Lei, LUO Yi, YE Jing, et al. Optimal cooperation frequency control strategy of AGC in multi-area under tie-line support volatility constraint [J]. Proceedings of the CSEE, 2017, 37(3): 676-684(in Chinese).
- [10] DING Tao, LI Cheng, YANG Yongheng, et al. A two-stage robust optimization for centralized-optimal dispatch of photovoltaic inverters in active distribution networks[J]. IEEE Transactions on Sustainable Energy, 2017, 8(2): 744-754.
- [11] LORCA A, SUN X A. Adaptive robust optimization with dynamic uncertainty sets for multi-period economic dispatch under significant wind[J]. IEEE Transactions on Power Systems, 2015, 30(4): 1702-1713.
- [12] JABR R A, KARAKI S, KORBANE J A. Robust multi-period OPF with storage and renewables[J]. IEEE Transactions on Power Systems, 2015, 30(5): 2790-2799.
- [13] LORCA Á, SUN X A, LITVINOV E, et al. Multistage adaptive robust optimization for the unit commitment problem[J]. Operations Research, 2016, 64(1): 32-51.
- [14] 翟俊义, 周明, 李庚银, 等. 考虑可消纳风电区间的多区电力系统分散协调鲁棒调度方法[J]. 电网技术, 2018, 42(3): 745-754. ZHAI Junyi, ZHOU Ming, LI Gengyin, et al. A decentralized and robust dispatch approach for multi-area power system considering accommodated wind power interval[J]. Power System Technology, 2018, 42(3): 745-754(in Chinese).
- [15] 周安平, 杨明, 翟鹤峰, 等. 计及风电功率矩不确定性的分布鲁棒实时调度方法[J]. 中国电机工程学报, 2018, 38(20): 5937-5946. ZHOU Anping, YANG Ming, ZHAI Hefeng, et al. Distributionally robust real-time dispatch considering moment uncertainty of wind generation[J]. Proceedings of the CSEE, 2018, 38(20): 5937-5946(in Chinese).
- [16] 孙润稼, 刘玉田. 基于深度学习和蒙特卡洛搜索的机组恢复在线决策[J]. 电力系统自动化, 2018, 42(14): 40-47. SUN Runjia, LIU Yutian. Online decision-making for generator start-up based on deep learning and monte carlo

- tree search[J]. Automation of Electric Power Systems, 2018, 42(14): 40-47(in Chinese).
- [17] 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): 2934-2945.  
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): 2934-2945(in Chinese).
- [18] 席磊, 余璐, 付一木, 等. 基于探索感知思维深度强化学习的自动发电控制[J]. 中国电机工程学报, 2019, 39(14): 4150-4160.  
XI Lei, YU Lu, FU Yimu, et al. Automatic generation control based on deep reinforcement learning with exploration awareness[J]. Proceedings of the CSEE, 2019, 39(14): 4150-4160(in Chinese).
- [19] ZENG Peng, LI Hepeng, HE Haibo, et al. Dynamic energy management of a Microgrid using approximate dynamic programming and deep recurrent neural network learning[J]. IEEE Transactions on Smart Grid, 2019, 10(4): 4435-4445.
- [20] YU Xuejun, ZHU Yiqun, SUN Shuxian, et al. LSTM network for carrier module detection data classification [C]//2019 International Conference on Smart Grid and Electrical Automation (ICSGEA). Xiangtan: IEEE, 2019.
- [21] DONG Ming, GRUMBACH L. A hybrid distribution feeder long-term load forecasting method based on sequence prediction[J]. IEEE Transactions on Smart Grid, 2020, 11(1): 470-482.
- [22] LI Shuai, LI Wanqing, COOK C, et al. Independently recurrent neural network (IndRNN): building a longer and deeper RNN[C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT: IEEE, 2018: 5457-5466.
- [23] 张斌, 庄池杰, 胡军, 等. 结合降维技术的电力负荷曲线集成聚类算法[J]. 中国电机工程学报, 2015, 35(15): 3741-3749.  
ZHANG Bin, ZHUANG Chijie, HU Jun, et al. Ensemble clustering algorithm combined with dimension reduction techniques for power load profiles[J]. Proceedings of the CSEE, 2015, 35(15): 3741-3749(in Chinese).
- [24] CHATTERJEE K, MAHAPATRA K, CHAUDHURI N R. Robust recovery of PMU signals with outlier characterization and stochastic subspace selection[J]. IEEE Transactions on Smart Grid, 2020, 11(4): 3346-3358.
- [25] LI Zhihao, GENG Guangchao, JIANG Quanyuan. Transient stability emergency control using asynchronous parallel mixed-integer pattern search[J]. IEEE Transactions on Smart Grid, 2018, 9(4): 2976-2985.
- [26] MORI H, TAKAHASHI A. Hybrid intelligent method of relevant vector machine and regression tree for probabilistic load forecasting[C]//Proceedings of the 2011 2nd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies. Manchester: IEEE, 2011.
- [27] ALAMANIOTIS M, BARGIOTAS D, BOURBAKIS N G, et al. Genetic optimal regression of relevance vector machines for electricity pricing signal forecasting in smart grids[J]. IEEE Transactions on Smart Grid, 2015, 6(6): 2997-3005.
- [28] 李元诚, 邱日轩, 曾婧. 基于核主成分分析的智能电网盲在线虚假数据注入攻击[J]. 电网技术, 2018, 42(7): 2270-2278.  
LI Yuancheng, QIU Rixuan, ZENG Jing. Blind online false data injection attack using kernel principal component analysis in smart grid[J]. Power System Technology, 2018, 42(7): 2270-2278(in Chinese).
- [29] 林茂, 李颖晖, 朱喜华, 等. 基于改进核主元分析法的三电平逆变器故障检测[J]. 电网技术, 2016, 40(3): 972-977.  
LIN Mao, LI Yinghui, ZHU Xihua, et al. Fault detection for three-level inverter based on improved kernel principal component analysis method[J]. Power System Technology, 2016, 40(3): 972-977(in Chinese).



陈光宇

在线出版日期: 2021-03-12.

收稿日期: 2020-12-15.

作者简介:

陈光宇(1980), 男, 博士, 副教授, 硕士生导师, 主要研究方向: 电力系统运行与控制, 优化调度, 人工智能等, cgyhhu@163.com;

孙叶舟(1997), 男, 硕士研究生, 主要研究方向为电力系统运行与控制, 优化调度, sunyeyzhou20@163.com;

江海洋(1985), 男, 工程师, 主要研究方向为电力系统安全稳定分析及调度控制, jhy\_03@126.com;

王宁(1972), 男, 高级工程师, 主要研究方向为电网调度运行及安全稳定控制, wn007@126.com;

康春雷(1972), 男, 教授级高工, 主要研究方向为电力系统潮流计算及安全稳定分析, kclhepc@163.com.

(实习编辑 张文鑫)

# Research on Accurate Identification and Confidence Evaluation of AGC Command Execution Effect Based on DIndRNN-RVM Deep Fusion Model

CHEN Guangyu<sup>1</sup>, SUN Yezhou<sup>1</sup>, JIANG Haiyang<sup>2</sup>, WANG Ning<sup>2</sup>, KANG Chunlei<sup>2</sup>,  
ZHANG Yangfei<sup>1</sup>, HAO Sipeng<sup>1</sup>

(1. Nanjing Institute of Technology; 2. State Grid Heilongjiang Electric Power Co., Ltd)

**KEY WORDS:** independent recurrent neural network; preprocessing strategy; cross validation; deep fusion; confidence evaluation

After years of research, automatic generation control (AGC) has become increasingly mature and has been widely used. In recent years, with the continuous increase of new energy power plants, the impact of the uncertainty of their output can not be ignored. In engineering practice, AGC often adjusts the output of thermal power units to keep the power balance of the system. However, in some areas, due to the aging of generator equipment and environment, the execution result of AGC commands often deviates greatly, which not only leads to the failure of AGC control strategy to achieve the desired control effect, but also leads to the occurrence of boundary tie line overrun due to poor command execution ability.

In view of the above problems, this paper constructs a deep neural network model and uses historical data for model training. By using this model, the AGC system can predict and evaluate the execution of unit instructions in the operation cycle, so as to improve the control efficiency.

Based on this idea, this paper proposes a deep fusion network based on DIndRNN-RVM to predict the unit output and give the confidence of the prediction results. The network uses the historical data of the unit for training, and uses KPCA model to reduce the dimension of the input variables. This model provides quantitative decision support for the effect and reliability of instruction execution in AGC online decision-making.

The specific implementation steps are as follows:

- 1) The historical data of unit operation is obtained through API of power grid database.
- 2) KPCA is used to preprocess the data and reduce the data dimension. KPCA parameters are determined by k-fold cross validation grid search algorithm.
- 3) The DIndRNN model is trained with the reduced dimension data, and the data features are extracted with the model.
- 4) The RVM model is trained with data features to obtain the prediction output and confidence, and then connected with DIndRNN model to form a fusion model.
- 5) The pretreatment model and DIndRNN-RVM model are combined to give the prediction and confidence evaluation of unit output.


3) The DIndRNN model is trained with the reduced dimension data, and the data features are extracted with the model.

4) The RVM model is trained with data features to obtain the prediction output and confidence, and then connected with DIndRNN model to form a fusion model.

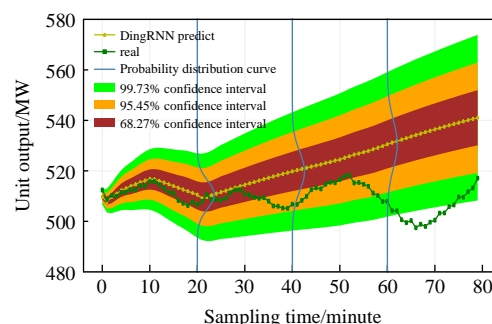
5) The pretreatment model and DIndRNN-RVM model are combined to give the prediction and confidence evaluation of unit output.

Real data of power grid is used for verification. The data scale is half a year, the sampling period is 1 minute, and the total number of data is 262080.

Fig. 1 shows the prediction results of the fusion model proposed in this paper and other models, and Fig. 2 shows the prediction and confidence evaluation results of the fusion model proposed in this paper.



**Fig. 1 Multi step long term prediction analysis of different depth models**



**Fig. 2 Long-term prediction of DIndRNN-RVM model**