

DOI:10.19651/j.cnki.emt.2108434

基于残差修正的含小水电网供负荷预测研究^{*}

胡尧¹ 李黄强² 舒征宇¹ 姚钦² 李世春¹ 许布哲¹

(1.三峡大学电气与新能源学院 宜昌 443000; 2.国网湖北省电力有限公司宜昌供电公司 宜昌 443000)

摘要:针对小水电高渗透率地区网供负荷预测准确率较低的问题,提出一种基于人工智能和残差修正的网供负荷预测模型,对蕴含在网供负荷中的周期分量和随机分量进行预测和结果修正。采用集合经验模态分解(EEMD)提取网供负荷中不同频段的分量,构建基于模态分量的多层次门控循环单元(GRU)网络模型,通过提升网络模型的复杂程度提高测试集上预测结果的准确率。此外,引入费歇值表征降雨对小水电出力的累积效应影响,在预测结果输出环节加入费歇信息加权的马尔科夫(FI-WMC)残差修正步骤,降低小水电出力不确定性导致的预测结果偏差。仿真验证的结果表明,多层级 EEMD-GRU-FIWMC 模型可以更好地适用于小水电高渗透率地区的网供负荷预测,在小水电渗透率为 20%以上的地区,相对于传统的 GRU 模型和无残差修正模型,其预测准确率分别提升 7.61%、3.85%。

关键词:网供负荷;小水电;集合经验模态分解;门控循环单元;费歇信息;马尔科夫链

中图分类号: TM715 文献标识码: A 国家标准学科分类代码: 470

Research on power supply and load forecasting of small water grid based on residual error correction

Hu Yao¹ Li Huangqiang² Shu Zhengyu¹ Yao Qin² Li Shichun¹ Xu Buzhc¹

(1. College of Electrical Engineering & New Energy, Three Gorges University, Yichang 443000, China;

2. State Grid Hubei Electric Power Co., Yichang Power Supply Company, Yichang 443000, China)

Abstract: Aiming at the problem of the low accuracy of grid supply load forecasting in high permeability areas of small hydropower, a grid supply load forecasting model based on artificial intelligence and residual correction is proposed to predict and correct the periodic and random components contained in the grid supply load. Ensemble empirical mode decomposition (EEMD) is used to decompose and extract the components of different frequency bands in the network load, and a multi-level gated recurrent unit (GRU) network model based on modal components is constructed, the accuracy of the prediction results on the test set is improved by increasing the complexity of the network model. In addition, the Fischer value is introduced to characterize the cumulative effect of rainfall on the output of small hydropower, and the fisher information-weighted Markov chain (FI-WMC) residual correction step is added in the output of prediction results, reduce the deviation of prediction result caused by the uncertainty of small hydropower output. The results of simulation verification show that the multi-level EEMD-GRU-FIWMC model can be better applied to the grid load forecasting in areas with high permeability of small hydropower. In areas where the penetration rate of small hydropower is above 20%, compared with the traditional GRU model and the no-residual correction model, its prediction accuracy is increased by 7.61% and 3.85%, respectively.

Keywords: grid supply load; small hydropower; clustering empirical mode decomposition; gated recurrent unit; Fischer information; Markov chain

0 引言

根据我国现行的电力调度体制,地市电网公司需要预测“网供负荷”并上报给省级电网公司,作为制定发电计划

的依据^[1-2]。网供负荷预测结果的准确率直接影响电网的频率稳定和经济运行。考虑网供负荷受到本地用电负荷以及本地发电负荷两方面的影响,随着小水电、光伏以及风电等清洁能源接入规模的不断扩大,准确预测网供负荷逐渐

收稿日期:2021-11-24

*基金项目:国家自然科学基金(51907104)项目资助

成为电网潮流优化、合理制定运行方式和促进清洁能源消纳的关键要素。

目前,国内外负荷预测的方法主要分为数学统计模型预测法和人工智能预测法两大类。其中,基于传统数学统计模型的预测方法包括时间序列法^[3]、指数平滑法^[4]、多元线性回归^[5]、灰色模型法^[6-7],这类方法的优点是模型构造简单,计算速度较快。如文献[8]基于混沌理论重构相空间建立了最大 Lyapunov 指数模型模型,从而优化输入参数,达到提高预测精度的目的。文献[9]提出了一种综合 FCMs、时间序列分割和模糊聚类的长期时间序列预测方法,可直观地反映时间序列的主要特征和变化趋势。文献[10]采用 3 重指数平滑技术进行河流流量预测的时间序列建模。文献[11]采用多元线性回归分析法,建立燃机功率与效率的数学模型并预测燃气轮机发电机组的性能。文献[12]基于等维新息矩阵构建改进的灰色理论预测模型,避免了传统灰色预测模型泛化能力差的缺陷。文献[13]基于多准则决策中的 CRITIC 方法建立一阶单变量灰色模型,对未来电动汽车销量及市场份额进行综合评价。这类算法在处理时序性较强、波动性较低的电力负荷时,能够迅速得出预测结果,但对于处理较为复杂的非线性负荷数据,因统计学算法自身的缺陷,预测精度较低。人工智能方法有着较强的参数学习能力,在处理复杂非线性负荷数据方面具有优越性。人工智能方法包括人工神经网络法^[14]和支持向量机^[15]等。文献[16]提出基于变精度粗糙集和支持向量机理论的负荷滚动预测模型,充分挖掘核心变量,实现复杂非线性数据高维模型建立,但是其设置超参数的过程较为复杂。文献[17]提出一种针对区域级负荷的长短期记忆(long short-term memory, LSTM)网络预测方法,并采用随机搜索的方法寻找最优参数,提高模型的泛化能力。国外有学者基于人工神经网络提出一种新的最优相似日选择的短期负荷预测模型^[18]。Furqan 等^[19]采用数据驱动的集合经验模态分解(ensemble empirical mode decomposition, EEMD)算法,从负荷和价格时间序列中提取隐含特征,建立多头自注意机制的混合深度学习预测模型,取得了良好的预测效果。但是 LSTM 网络参数较多,计算速度慢,如文献[20]提出了一种基于卷积神经网络和门控循环单元(gated recurrent unit, GRU)网络组合预测方法,大大减少了模型训练的时间。为提高负荷预测的精度,还有学者采用“对预测结果进行残差修正”的思路,国外有学者采用动态模式分解的误差修正预测方法^[21],以及基于径向基函数网络的误差修正预测日峰值电力负荷的方法^[22]。国内如文献[23]采用傅里叶变换对灰色预测模型进行改进,有效提高了负荷预测精度;文献[24]针对光伏发电的不稳定性,搭建了加权马尔科夫链修正预测模型,进一步表明在负荷预测中加入残差修正模型有利于提高模型的预测精度。

综合以上,统计模型预测和人工智能预测两种类型方

法均在负荷预测领域有对应的研究成果。但网供负荷预测受到本地小电源出力波动的影响,传统的数学统计预测模型无法体现本地新能源的随机波动特性,而单一的人工智能算法又存在输入变量较多导致的预测模型过拟合的风险。有鉴于此,本文按照“变量分解—分量筛选—模型预测—结果修正”的思路,构建基于 EEMD-GRU 的组合预测模型。通过“分解—筛选—预测”对网供负荷中强周期性分量进行提取和预测,采用“残差修正”方法消除由清洁能源出力随机性带来的误差,从而提高网供负荷预测的精度。

1 网供负荷预测模型的构建

1.1 网供负荷曲线分析

网供负荷由本地用电负荷以及本地发电负荷两部分组成,其中的用电负荷部分,表现出不同频段的周期性,而发电负荷由小电源的发电构成,表现出较强的随机性。用电负荷曲线以及本地小电源发电负荷曲线分别如图 1、2 所示。

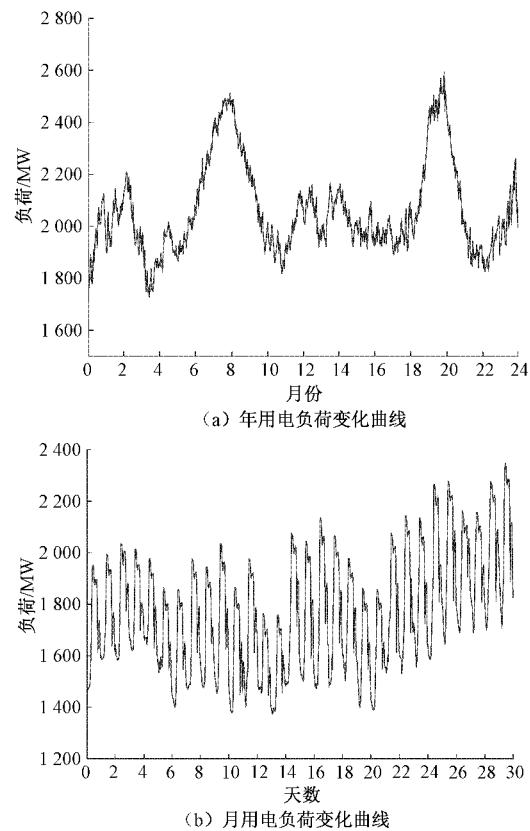


图 1 区域用电负荷变化曲线

图 1 中用电负荷表现出不同频段的周期性,即以天为周期的早晚用电高峰、以周为周期的双休日低谷以及以年为周期的冬季和夏季用电高峰等。与之对应,本地小电源受到本地气象要素的影响,表现为长时间跨度上的周期性以及短时间跨度上的随机性。如图 2 所示,在长时间跨度上,受到季节降雨的影响,每年夏季为发电负荷的峰值。而

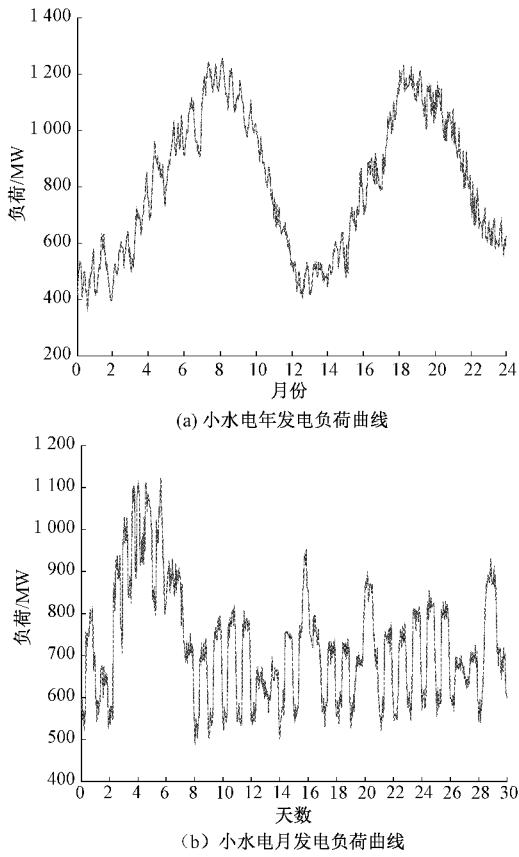


图 2 小水电发电负荷曲线

短期的发电负荷受到降雨强度波动的影响则表现为随机性。

综上,网供负荷中的用电负荷部分受到气象、作息时间等要素的影响,存在较强的周期性,而发电负荷部分受到季节变化以及短时降雨强度波动的影响。对应的网供负荷预测则可以看作是对周期分量的预测以及针对随机波动的残差修正。为此,本文分别引入“EEMD-GRU”以及“FI-WMC”实现对周期分量的分解与预测以及随机波动的残差修正,以此来提升预测结果的准确率。

1.2 基于 EEMD-GRU 预测模型构建

针对网供负荷中的周期分量的预测,本文采用的 EEMD 对历史负荷数据进行分解,通过提取网供负荷中不同频段的分量,构建以 GRU 为基础的多层网络模型。其中 EEMD 可以将样本数据分解为频率由高到低的若干个本征模态函数(intrinsic mode function, IMF)分量和一个残余(Res)分量,每个 IMF 分量都代表了某种时间尺度上的局部特征,可以充分挖掘原始数据上所包含的信息,EEMD 算法对信号详细分解的步骤见文献[25]。

门限循环单元 GRU 是 LSTM 网络的一种改进模型^[26]。考虑到多小水电地区网供负荷是用电负荷与小水电出力的叠加,二者均受当前时刻状态以及上一时刻状态的影响,利用 GRU 网络处理时间序列数据的优势,本文将

其作为网供负荷预测的主体模型。相较于 LSTM,GRU 只有更新门与重置门两个门结构,其中更新门是由遗忘门与输入门合并产生的。GRU 神经网络保持了基本的 LSTM 结构,可以有效缓解 RNN 网络中“梯度消失”的问题、缩短模型训练时间。GRU 网络的基本结构如图 3 所示,数学描述如式(1)所示。

$$\begin{cases} \mathbf{r}_t = \sigma(\mathbf{W}_r \cdot [\mathbf{h}_{t-1} \cdot \mathbf{x}_t]) \\ \mathbf{z}_t = \sigma(\mathbf{W}_z \cdot [\mathbf{h}_{t-1} \cdot \mathbf{x}_t]) \\ \hat{\mathbf{h}}_t = \tanh(\mathbf{W}_{\hat{h}} \cdot [\mathbf{r}_t \times \mathbf{h}_{t-1} \cdot \mathbf{x}_t]) \\ \mathbf{h}_t = (1 - \mathbf{z}_t) \times \mathbf{h}_{t-1} + \mathbf{z}_t \times \hat{\mathbf{h}}_t \\ \mathbf{y}_t = \sigma(\mathbf{W}_y \cdot \mathbf{h}_t) \end{cases} \quad (1)$$

其中, \mathbf{x}_t 为当前时刻输入向量; \mathbf{h}_{t-1} 为 $t-1$ 时刻的记忆状态量; \mathbf{r}_t 为重置门神经元; \mathbf{z}_t 为更新门神经元; $\hat{\mathbf{h}}_t$ 为当前时刻状态量候选集; \mathbf{h}_t 为当前时刻 t 的记忆状态量; \mathbf{y}_t 为当前时刻的输出向量; $\mathbf{W}_r, \mathbf{W}_z, \mathbf{W}_{\hat{h}}, \mathbf{W}_y$ 分别为重置门、更新门、候选集、输出向量与 \mathbf{x}_t 及 \mathbf{h}_{t-1} 构成的连接矩阵相乘的权重参数; $[\cdot]$ 表示向量连接; \cdot 表示矩阵点乘; \times 表示矩阵乘积; σ 表示 sigmoid 激活函数。

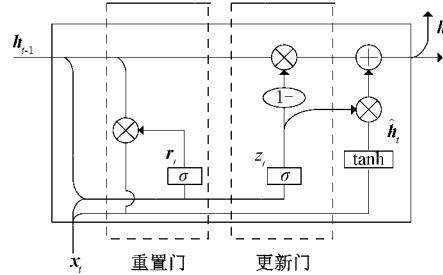


图 3 GRU 结构

考虑影响网供负荷的相关影响要素,本文采用预测点前 24 h 内的最高气温 T_{hi} 、平均温度 T_{ai} 、降雨量 R_{ai} 、是否为工作日 X_w 作为训练数据集的输入,分解后的网供负荷 \mathbf{X}_q 数据作为输出,数据间隔为 1 h,每天 24 个样本点,各变量表达式如式(2)所示。(其中 X_w 取值为 0 或 1,其中 1 代表工作日,0 代表非工作日)

$$\begin{cases} \mathbf{x}_t = \{T_{hi}, T_{ai}, R_{ai}, X_w, \mathbf{X}_q\} \\ \mathbf{T}_{hi} = \text{Max}\{T_{h0}, \dots, T_{h23}\} \\ \mathbf{T}_{ai} = \text{Avg}\{T_{a0}, \dots, T_{a23}\} \\ \mathbf{R}_{ai} = \{R_{a0}, R_{a1}, \dots, R_{a23}\} \\ \mathbf{X}_w = \{X_w\} \\ \mathbf{X}_q = \{x_{q0}, x_{q1}, \dots, x_{q23}\} \end{cases} \quad (2)$$

针对多小水电地区网供负荷周期性与随机性并存的特点,本文将数据处理算法和神经网络模型相结合,提出了基于集合经验模态分解的循环神经网络预测模型。

基于 EEMD-GRU 的预测模型训练步骤如下所述。

1) 数据分解。对历史网供负荷数据 $Q(t)$ 进行 EEMD 分解,得到 n 个 IMF 分量(分别记作 IMF_1, \dots, IMF_n)和

残余分量 Res 。

2) 本征模态分量预测。将处理好的 $n+1$ 组数据分别输入到 GRU 神经网络进行预测。

3) 对每一组预测值进行线性叠加, 得到 EEMD-GRU 模型的预测值 y_t 。

EEMD-GRU 模型的预测流程如图 4 所示。

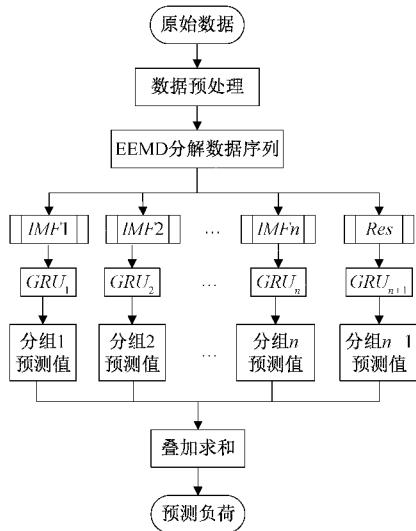


图 4 基于 EEMD 的 GRU 预测流程

2 基于费歇信息的网供负荷预测残差修正模型

小水电高渗透率地区的小水电装机容量比重一般较大, 但利用率较低。当有降雨发生时, 一方面由于降温导致用电负荷降低, 另一方面本地小水电发电会进一步降低网供负荷, 从而使得网供负荷波动进一步加剧。考虑到降雨与小水电发电负荷之间的时滞效应与累积效应, 本文引入费歇信息 (fisher information, FI) 值作为输入代入加权马尔科夫链 (weighted Markov chain, WMC) 修正模型对预测结果进行修正, 使预测结果更加接近真实值, 提升模型预测精度。

2.1 基于费歇信息的降雨数据处理

考虑本地小水电的发电负荷与降雨要素之间存在滞后效应以及累积效应, 即小水电发电与降雨在时间尺度上存在滞后, 且降雨累积超过小水电发电的死水位后才开始发电。其外在表现为, 连续若干日的降雨和单日强降雨对小水电出力的影响是大不相同的。而费歇信息能够利用降雨量数据定量地表征出当前、之前若干时间段内降雨所产生的累积效应。费歇信息的计算公式如式(3)所示^[27]。

$$I = \int \frac{ds}{P(s)} \left[\frac{dP(s)}{ds} \right]^2 \quad (3)$$

式中: s 为系统的状态变量; $P(s)$ 为该变量的一种概率密度分布 (probability density function, PDF)。

考虑对于发电负荷越靠近当前时刻的时间段内的降雨

影响越大, 时间越往前, 降雨的影响越小。本文采用采用短中长 3 个时段加权的方法计算降雨量的费歇信息值。3 个时段划分为: 1) 当前时刻前 2 h 内的 8 个降雨量数据 (采样间隔为 15 min); 2) 预测时刻前一日当前时刻前 4 h 内的 4 个降雨量数据 (采样间隔为 1 h); 3) 预测时刻前两日当前时刻前 8 h 内的 4 个降雨量数据 (采样间隔为 2 h)。数据序列如式(4)所示。

$$\begin{cases} R_{t,i}, R_{t,i-1}, \dots, R_{t,i-7}; \\ R_{t-1,i}, R_{t-1,i-1}, \dots, R_{t-1,i-3}; \\ R_{t-2,i}, R_{t-2,i-1}, \dots, R_{t-2,i-3} \end{cases} \quad (4)$$

式中: t 表示预测日, i 表示预测时刻。延迟影响是指当前时刻下雨不会立即对小水电出力产生明显的改变, 而是在接下来的几个小时内显现出来, 而且这种延迟在降雨强度越低时延时越长; 多日累积效应是指小水电出力在降雨停止后仍然持续增长。前者的影响主要来源于第 1 个时段、第 2 个时段降雨的大小, 后者的影响主要来源于第 3 个时段的降雨。考虑到负荷预测中应对距离预测点较近的影响因素给予更多的关注, 即按照“近大远小”的原则, 计算一次费歇值的数据窗由式(4)中的 16 个数据点组成, 计算降雨量费歇值的流程如图 5 所示。

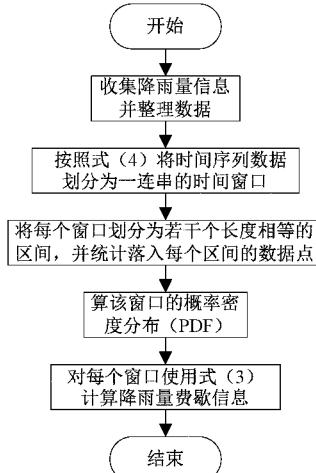


图 5 降雨量费歇值计算的流程

2.2 费歇信息加权的改进马尔可夫残差修正模型

马尔科夫残差修正模型是对预测结果进行修正, 提高预测精度, 其核心是确定状态转移概率矩阵, 以预测值与真值之间的残差为样本序列, 应用马尔科夫链。设残差序列包括了 m 个状态 (即状态空间 $E = \{H_1, H_2, \dots, H_m\}$), 对于其中一个状态, 经过任意一次的转移, 其必出现 m 个状态中的一个, 这种状态之间的转移称为转移概率。用 f_{ij} 表示残差序列中状态 i 经一步转移到状态 j 的频次 (其中 $i, j \in m$), 由 f_{ij} 组成的矩阵称为转移频次矩阵, 再将 f_{ij} 除以对应行的频次总和可得到状态转移概率 P_{ij} , 则一阶转移概率矩阵为:

$$\mathbf{P}^{(1)} = \mathbf{P}_{ij}^{(1)} = \begin{bmatrix} P_{11}^{(1)} & P_{12}^{(1)} & \cdots & P_{1m}^{(1)} \\ P_{21}^{(1)} & P_{22}^{(1)} & \cdots & P_{2m}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ P_{m1}^{(1)} & P_{m2}^{(1)} & \cdots & P_{mm}^{(1)} \end{bmatrix} \quad (5)$$

经 l 步转移后, 矩阵变成

$$\mathbf{P}^{(l)} = \begin{bmatrix} P_{11}^{(l)} & P_{12}^{(l)} & \cdots & P_{1m}^{(l)} \\ P_{21}^{(l)} & P_{22}^{(l)} & \cdots & P_{2m}^{(l)} \\ \vdots & \vdots & \ddots & \vdots \\ P_{m1}^{(l)} & P_{m2}^{(l)} & \cdots & P_{mm}^{(l)} \end{bmatrix} \quad (6)$$

其中, $\mathbf{P}_{ij} = \frac{f_{ij}}{\sum_{j=1}^m f_{ij}}, i, j \in m, l$ 为转移步长。

本文采用费歇加权马尔科夫链(FI-WMC)依照历史日的残差情况以及预测日前降雨量信息对预测日的残差情况进行预测, 具体步骤如下:

1) 划分预测残差的状态: 将网供负荷实际值 $Q(t)$ 与 EEMD-GRU 模型预测值 y_t 作差, 得到残差序列 $(\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n)$, 并计算残差序列的样本均值 \bar{y} 和标准差 S 。本文采用均值—标准差分级法, 将样本划分为 5 个区间: $H_1(-\infty, \bar{y}-S]$, $H_2(\bar{y}-S, \bar{y}-0.5S]$, $H_3(\bar{y}-0.5S, \bar{y}+0.5S]$, $H_4(\bar{y}+0.5S, \bar{y}+S]$, $H_5(\bar{y}+S, +\infty)$ 。

2) 计算残差序列与降雨量费歇值的相关系数 C_l , 并标准化 w_l 。

$$C_l = \frac{\sum_{i=1}^n (y_i - \bar{y})(I_i - \bar{I})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (I_i - \bar{I})^2}} \quad (7)$$

$$w_l = \frac{|C_l|}{\sum_{l=1}^m |C_l|} \quad (8)$$

式中: C_l 表示第 l 阶(步长为 l)残差序列与降雨量费歇值的相关系数; y_i 表示残差序列样本值; \bar{y} 表示残差序列的样本均值; I_i 表示时间窗口序列费歇值; \bar{I} 表示时间窗口序列费歇信息值的平均值; n 表示残差序列样本总量; w_l 表示步长为 l 的马尔科夫链权重; m 为预测时根据实际情况确定要计算的最大阶数。

3) 对步骤 1) 的结果进行统计, 得到不同步长的状态转移概率矩阵。分别以残差序列后 m 个残差所在的状态为初始状态, 并结合其对应的状态转移概率矩阵计算出预测日残差的状态概率 P_i^l , 其中 l 为步长。

4) 将同一状态不同步长的各预测概率 P_i^l 加权作为残差在该状态的转移概率。

$$P_i = \sum_{l=1}^m w_l P_i^l \quad (9)$$

取转移概率的最大值, 即 $\max\{P_i, i \in E\}$ (E 为状态空间) 所在的状态为预测残差状态。

5) 修正预测值。

$$Y_t = y_t(1 - \delta) \quad (10)$$

其中, Y_t 为修正后的模型预测值; y_t 为上文 1.2 中模型的预测值; $\delta = 0.5(H_{ilow} + H_{iup})$, H_{ilow}, H_{iup} 为步骤 4) 中所确定的残差状态区间的下阈值和上阈值, 如果残差状态所在区间是 H_1 , 则 H_{ilow} 取序列的最小值; 如果残差状态所在区间是 H_5 , 则 H_{iup} 取序列的最大值。

综上所述, 本文提出一种基于残差修正的小水电高渗透率地区网供负荷预测模型。整个模型主要分为两个部分, 如图 6 所示。

1) EEMD-GRU 模型预测部分。按照 1.2 的方法依次进行数据预处理、EEMD 分解、归一化, 最后使用 GRU 循环神经网络预测, 并将预测结果进行线性叠加, 得到初步的预测值。

2) 残差修正部分。采用上文所述的方法对 EEMD-GRU 模型预测结果进行修正, 并得到修正后的预测值。

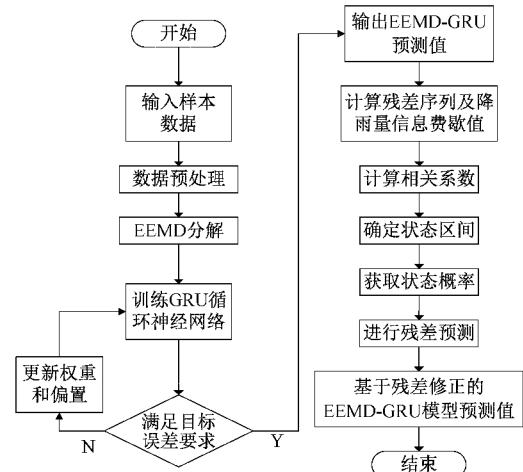


图 6 基于残差修正的 EEMD-GRU 模型流程

整个模型以 GRU 循环神经网络为预测模型的主体, 并辅之以 EEMD 算法、残差修正, 从而解决因小水电出力随机波动性大、不确定性强导致网供负荷预测精度不高的问题。本文后续将结合实例验证该模型的有效性和实用性。

3 案例分析

3.1 案例介绍

算例的数据来源为我国西南地区 3 个地级市 2016 年 6 月 1 日~2019 年 8 月 31 日的发电负荷数据及其他气象数据。样本数据采集间隔为 1 h, 共计 28 488 个数据点, 将 2016 年 6 月 1 日~2019 年 5 月 31 日的数据作为训练集, 用于模型训练, 2019 年 6 月 1 日~2019 年 8 月 31 日的数据作为测试集, 用于负荷的预测。其中, 3 市小水电装机容量及地区用电负荷如表 1 所示。

为评价预测模型的性能, 采用平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE)作为评价指标, 定义如下:

表 1 3 市小水电装机容量一览表

地区	小水电装机容量/MW	最大用电负荷容量/MW	平均用电负荷容量/MW
A 市	950	3 077	2 603
B 市	465	2 281	1 912
C 市	140	1 363	1 155

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |Y_i - y'_i| \quad (11)$$

$$E_{MAPE} = \frac{100}{n} \sum_{i=1}^n \frac{|Y_i - y'_i|}{y'_i} \quad (12)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - y'_i)^2} \quad (13)$$

式中: Y_i 为预测值; y'_i 为实际值; n 为样本数据总量。

3.2 EEMD-GRU 模型预测结果分析

为更加体现本文所提预测模型的优越性,选择小水电占比最高的 A 市网供负荷数据作为案例数据。即将处理好的 A 市历史网供负荷数据经 EEMD 分解后得到 10 个分量,包括 9 本征模态分量和 1 个残余分量。展示部分数据分解后的序列如图 7 所示。

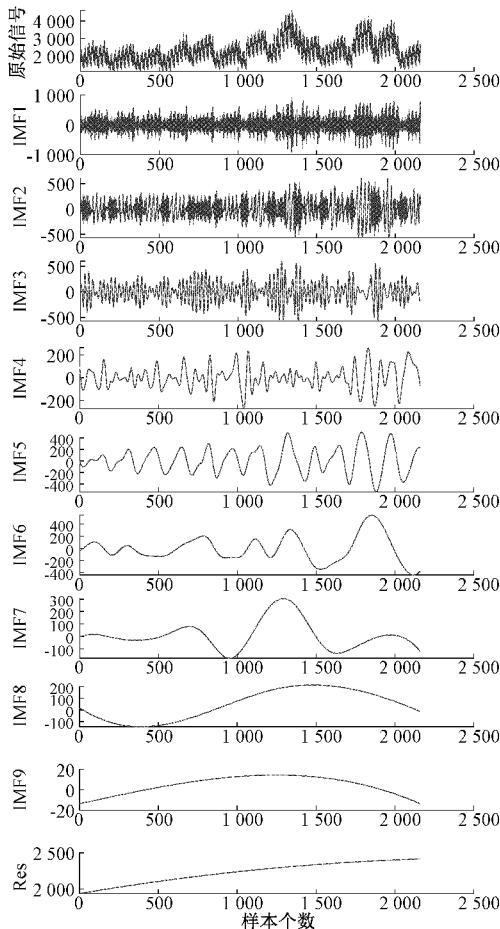


图 7 负荷数据分解后的 IMF 分量

将上述数据序列结合其他气象数据构造为神经网络的输入数据分别传入到 GRU 循环神经网络中进行预测,其中 2019 年 5 月 31 日前的数据作为训练集用于模型训练,将训练好的模型用于预测 2019 年 8 月 31 日的 24 点网供负荷,为更好体现本文所提模型的优越性,将 EEMD-GRU 模型和 GRU 模型预测值与真实值进行对比,其中, A 市 8 月 31 日的 24 点预测值与真实值的比较如图 8 所示。

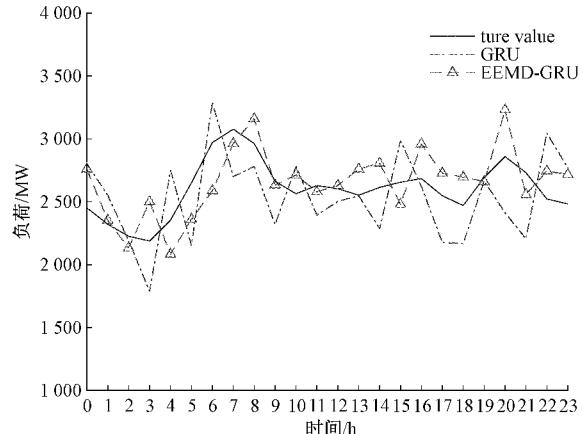


图 8 A 市网供负荷 EEMD-GRU 模型、GRU 模型预测值与实际值对比

同理,按照上述方法分别对 B、C 市历史负荷进行分解,模型训练与测试,并预测 8 月 31 日的 24 点网供负荷,其中 EEMD-GRU 模型和 GRU 模型预测值与真实值的对比如图 9 所示。

3 市网供负荷在 EEMD-GRU 模型、GRU 模型下的预测误差如表 2 所示。

由表 2 可知,经过 EEMD 对数据处理后,网供负荷预测精度明显得到提高,说明该模型能够很好地提取网供负荷中所蕴含的周期分量。此外,小水电渗透率最高的 A 市网供负荷预测误差最大,小水电渗透率最低的 C 市网供负荷预测误差最小。这是由于小水电渗透率越高的地区,降雨对小水电出力大小的影响以及降温对用电负荷的改变就越明显,使得该模型的预测值与实际值之间有着较大的偏差,无法达到预测的效果。为解决降雨时滞效应产生的问题,后文将采用费歇信息—加权马尔科夫链的残差修正模型,考虑降雨时滞效应对小水电出力的影响,并结合残差状态转移概率矩阵,对 EEMD-GRU 模型预测值修正,从而提高小水电高渗透率地区网供负荷预测的精度。

3.3 费歇-加权马尔科夫链模型修正的预测结果分析

为进一步提高 EEMD-GRU 模型的预测准确率,将按照上文 2.2 节步骤对 A 市网供负荷预测值进行残差修正。根据 EEMD-GRU 模型和真实值计算残差序列,并得到残差序列的均值 $\bar{y} = -54.85$ 和样本标准差 $S = 214.20 \text{ MW}$ 。采用均值—标准差分级法将残差状态划分为 5 种: $H_1(-\infty, -269.05]$, $H_2(-269.05, -161.95]$, $H_3(-161.95, 52.25]$, $H_4(52.25, 159.35]$, $H_5(159.35, +\infty)$ 。

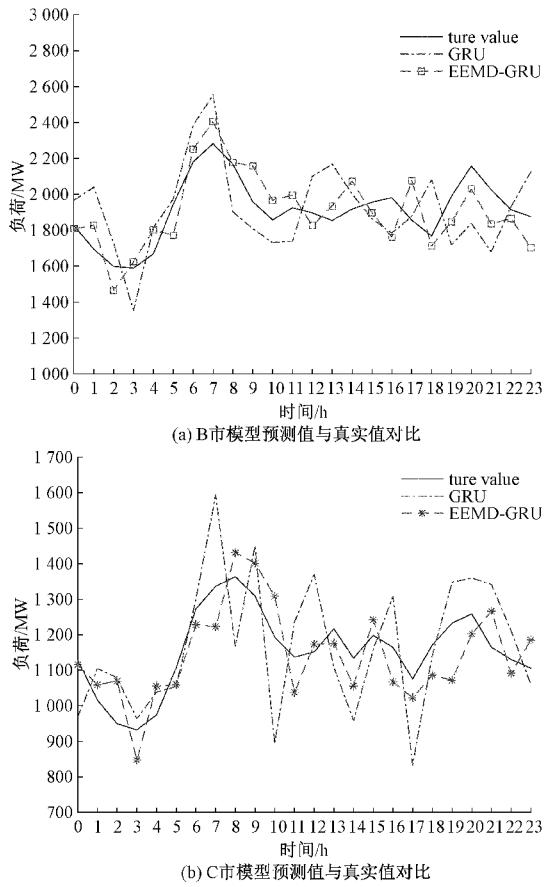


图 9 EEMD-GRU 模型、GRU 模型预测值与真实值对比

表 2 不同渗透率的小水电在不同模型下的预测误差

渗透率	模型	MAE	RMSE	MAPE/%
A 市(30%)	EEMD-GRU	189.27	216.74	7.30
	GRU	287.27	324.74	11.06
B 市(20%)	EEMD-GRU	132.62	148.93	6.89
	GRU	202.52	232.04	10.55
C 市(10%)	EEMD-GRU	67.14	76.54	5.94
	GRU	109.32	121.68	9.4

按照 2.1 节计算预测日前 3 天的降雨量费歇信息，并根据式(7)与(8)计算出前 5 阶残差序列与降雨量费歇值的相关系数以及对应的权重，得： $C_l = (0.1273, -0.0258, 0.3407, 0.0321, -0.1850)$ ； $w_l = (0.3812, 0.1108, 0.3024, 0.1341, 0.2659)$ 。

根据上述残差状态区间对残差序列进行区间划分，再统计各残差所在的状态区间，由此确定的一步状态转移概率矩阵如下：

$$\mathbf{P}^{(1)} = \begin{bmatrix} 0 & 1/4 & 1/4 & 0 & 2/4 \\ 0 & 1/2 & 1/3 & 0 & 1/6 \\ 1/6 & 1/6 & 1/2 & 1/6 & 0 \\ 1/2 & 1/2 & 0 & 0 & 0 \\ 1/5 & 1/5 & 0 & 1/5 & 2/5 \end{bmatrix}$$

利用马尔科夫链的齐次性可知： $\mathbf{P}^{(2)} = (\mathbf{P}^{(1)})^2, \mathbf{P}^{(3)} = (\mathbf{P}^{(1)})^3, \mathbf{P}^{(4)} = (\mathbf{P}^{(1)})^4, \mathbf{P}^{(5)} = (\mathbf{P}^{(1)})^5$ 。选择预测时刻前 7 天所对应时刻的残差，采用 1~5 阶权重系数，预测待预测日 24 点残差所在状态区间，结合式(10)计算预测日的负荷修正值，如图 10 所示。

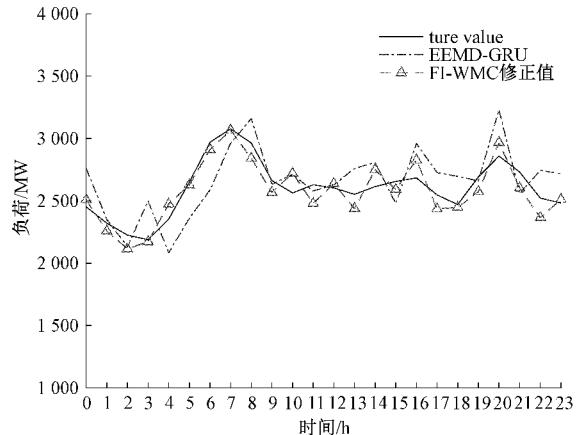
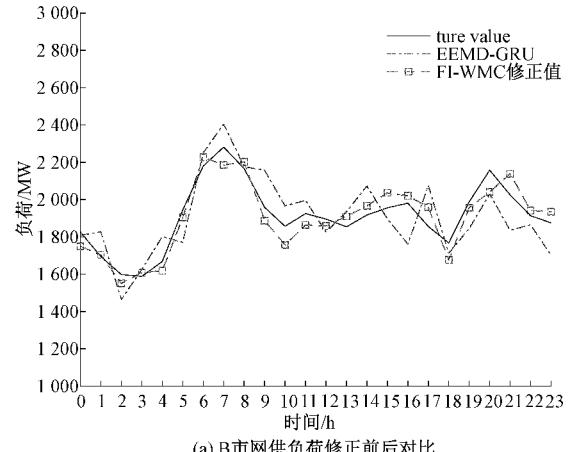
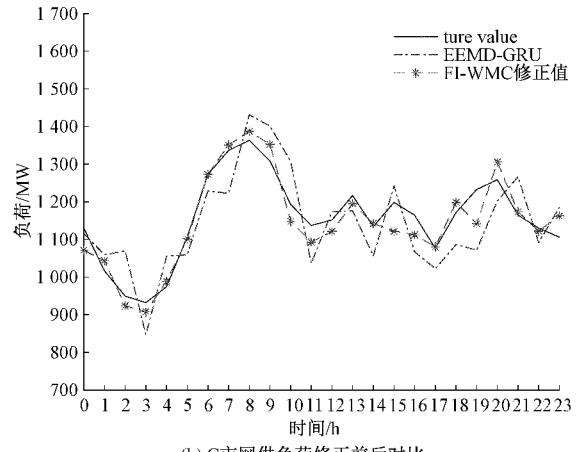


图 10 费歇-加权马尔科夫链修正前后预测模型结果对比(A 市)

同理可得，按照上述步骤对 B、C 市网供负荷预测值进行残差修正，其结果如图 11 所示。



(a) B 市网供负荷修正前后对比



(b) C 市网供负荷修正前后对比

图 11 费歇加权马尔科夫链修正前后预测模型结果对比

由图 11 可知, 经过残差修正的预测值与真实值更加接近, 基本达到修正的目的。修正后的模型误差如表 3 所示。

表 3 不同渗透率的小水电地区网供负荷预测误差对比

模型	渗透率/%	MAE	RMSE	MAPE/%
FI-WMC	30	89.49	101.43	3.45
修正模型	20	60.72	67.58	3.15
	10	34.91	41.82	3.06

与表 2 对比可知, 小水电渗透率最高的地区网供负荷平均绝对百分误差从 7.3% 降到了 3.45%, 小水电渗透率最低的地区网供负荷平均绝对百分误差从 5.94% 降到了 3.06%, 表明了在小水电渗透率越高的地区, 网供负荷预测精度提升较为明显, 模型修正效果较好。因此, 本文所提的残差修正模型, 在小水电比重较大的地区进行网供负荷预测有着很好的适应性。

4 结 论

针对小水电高渗透率地区网供负荷预测精度不高的问题, 本文提出了一种基于人工智能和残差修正的网供负荷预测方法。首先采用 EEMD 分解提取历史数据不同频段的分量, 计及不同影响要素的周期特性, 在提升网络复杂度的同时提高模型预测精度。再引入费歇信息表征区域降雨对小水电出力的累积效应影响, 构造费歇加权马尔科夫链残差环节, 降低了小水电出力随机性对网供负荷预测结果带来的影响。通过 3 个检验分析样本可知, 本文所提残差修正模型在小水电渗透率最高的地区网供负荷预测精度提高了 3.85%, 渗透率最低的地区网供负荷预测精度提高了 2.88%。

参考文献

- [1] 曾洁. 小水电发电负荷预测的研究[D]. 武汉: 华中科技大学, 2017.
- [2] 刘艳红, 倪秋龙, 黄民翔. 多小水电地区网供负荷预测研究[J]. 浙江电力, 2015, 34(12): 7-10.
- [3] WANG Q Y, AHMED F, CHETAN G, et al. Deep time series models for scarce data [J]. Neurocomputing, 2021: 504-518.
- [4] 徐杰, 陈忠孝, 秦刚, 等. 基于统计预报模型的滑坡位移预测研究[J]. 国外电子测量技术, 2019, 38(8): 44-47.
- [5] 张波, 赵永红, 唐亮, 等. 基于 AMI 数据的城市低压配电网拓扑校验方法研究[J]. 电子测量技术, 2019, 42(6): 67-71.
- [6] 杨楠, 李宏圣, 袁景颜, 等. 计及灰色关联度分析的中长期负荷灰色预测方法[J]. 电力系统及其自动化学报, 2018, 30(6): 108-114.
- [7] 黄海宏, 颜碧琛, 王海欣. 改进灰色 GM(1,1) 模型的 EAST 快控电源输出电流预测[J]. 电子测量与仪器学报, 2021, 35(5): 128-136.
- [8] 李东东, 章子珊, 林顺富, 等. 基于混沌时间序列法的微网短期负荷预测[J]. 电力系统及其自动化学报, 2015, 27(5): 14-18.
- [9] FENG G L, ZHANG L Y, YANG J H, et al. Long-term prediction of time series using fuzzy cognitive maps [J]. Engineering Applications of Artificial Intelligence, 2021, 102: 104274.
- [10] MELLY L, BENYAMIN T. Time series modeling by using exponential smoothing technique for river flow discharge forecasting(case study: Cabenge, Walanae, and Cenranee rivers system) [J]. IOP Conference Series: Materials Science and Engineering, 2021, 1088(1): 012100.
- [11] 刘闯, 金仁瀚, 巩二磊, 等. 多元线性回归方法预测燃气轮机发电机组性能[J]. 中国电机工程学报, 2017, 37(16): 4731-4738, 4898.
- [12] 刘宇, 郭林, 阳锋, 等. 基于改进灰色理论的中长期负荷预测方法研究[J]. 电网与清洁能源, 2016, 32(8): 51-56, 61.
- [13] NGUYEN T K L, LE H N, NGO V H, et al. CRITIC method and grey system theory in the study of global electric cars[J]. World Electric Vehicle Journal, 2020, 11(4): 79-79.
- [14] ZHENG J, XU C, ZHANG Z, et al. Electric load forecasting in smart grids using long-short-term-memory based recurrent neural network[C]. 2017 51st Annual Conference on Information Sciences and Systems(CIIS), IEEE, 2017: 1-6.
- [15] 谢波, 高建宇, 张惠娟, 等. 短期风电功率预测中的 IOFA-SVM 算法实现[J]. 电子测量技术, 2021, 44(12): 63-69.
- [16] 谢敏, 邓佳梁, 吉祥, 等. 基于信息熵和变精度粗糙集优化的支持向量机降温负荷预测方法[J]. 电网技术, 2017, 41(1): 210-214.
- [17] 张宇帆, 艾萍, 林琳, 等. 基于深度长短时记忆网络的区域级超短期负荷预测方法[J]. 电网技术, 2019, 43(6): 1884-1892.
- [18] JANKOVIC Z, SELAKOV A, BEKUT D, et al. Day similarity metric model for short-term load forecasting supported by PSO and artificial neural network[J]. Electrical Engineering, 2021, 103(6): 1-16.
- [19] FURQAN A M, SHAHZAD Y M. Multi-horizon electricity load and price forecasting using an interpretable multi-head self-Attention and EEMD-based framework [J]. IEEE ACCESS, 2021, 9: 85918-85932.
- [20] 姚程文, 杨苹, 刘泽健. 基于 CNN-GRU 混合神经网

- 络的负荷预测方法[J]. 电网技术, 2020, 44(9): 3416-3424.
- [21] KONG X Y, LI C, ZHANG Y S, et al. Short-term electrical load forecasting based on error correction using dynamic mode decomposition [J]. Applied Energy, 2020, 261(C): 114368.
- [22] JEONG H M, KIM K H, PARK J H. Error correction algorithm based radial basis function network for daily peak electric load forecasting [J]. The transactions of The Korean Institute of Electrical Engineers, 2019, 68(2): 221-227.
- [23] 黄元生, 方伟. 基于灰色傅里叶变换残差修正的电力负荷预测模型[J]. 电力自动化设备, 2013, 33(9): 105-107, 112.
- [24] 张静, 褚晓红, 黄学安, 等. 一种基于加权马尔科夫链修正的 SVM 光伏出力预测模型[J]. 电力系统保护与控制, 2019, 47(19): 63-68.
- [25] 贾亚超, 李国龙, 何坤, 等. 基于灰色准则与 EEMD 的滚刀振动信号降噪方法[J]. 仪器仪表学报, 2019, 40(7): 187-194.
- [26] SRI H M, RAO P, KAMMARDI P K, et al. A smart adaptive LSTM technique for electrical load forecasting at source[C]. 2017 2nd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology(RTEICT), IEEE, 2017: 1717-1721.
- [27] 蔡舒平, 张保会, 汤大海, 等. 短期负荷预测中气象因素处理的费歇信息方法[J]. 电力自动化设备, 2020, 40(3): 141-146.

作者简介

胡尧(通信作者),硕士研究生,主要研究方向为电力系统运行与控制。

E-mail: 531436869@qq.com

舒征宇,博士,副教授,主要研究方向为电力系统保护与控制。

E-mail: 18702031@qq.com