[文章编号] 1003－4684(2026)04-0020-10

基于 SSA-VMD-GCN-GM 的短期负荷预测

邓　心，方　娜

（湖北工业大学电气与电子工程学院，湖北 武汉 430068）

[摘　要] 针对时间序列波动性大、负荷预测精度较差等问题，提出奇异谱分析、变分模态分解、图卷积神经网络和灰色模型结合的短期负荷预测方法。首先，采用 SSA 对负荷序列进行降噪，以减少负荷数据噪声干扰。然后，利用 VMD 分解去噪后的序列，加快计算效率，得到分解精度更高的数据。接着，使用互信息筛选模型输入参数，并构造图数据，利用 GCN 网络进行预测，并将预测值送入全连接层作为初步预测结果。最后，通过 GM 对负荷误差值进行修正，将修正后的误差预测结果与初步预测结果相加作为模型最终预测值。算例仿真证明：模型预测效果良好。

[关键词] 奇异谱分析；变分模态分解；图卷积神经网络；短期负荷预测；灰色模型

[中图分类号] TM715　　[文献标识码] A

负荷预测为电力系统合理经济调度、实时控制以及发展和运行计划提供必要的数据。随着社会经济的快速发展，电力生产和消费的市场化，人们对负荷预测的可靠性和精确性有更高的要求[1]。时间序列分析法对非线性问题预测效果不理想，回归分析法无法解决变量间存在的非线性和动态问题，这些传统方法无法满足电力工业对短期负荷预测精度的要求[5]。现代智能方法包括神经网络方法、随机森林[6]和组合预测方法等。经典的神经网络包含长短期记忆（long and short-term memory，LSTM）、卷积神经网络（convolutional neural networks，CNN）等。文献[7]提出了多任务学习的 CNN-LSTM 模型，利用 CNN 深度挖掘数据特征，使用 LSTM 进行负荷预测，从而得出了该模型的适应能力强。以上方法不能细致地分析时间序列数据的规律和变化趋势，LSTM 对超长时间序列获取的信息存在缺陷[8]。图神经网络是一种新颖的神经网络，能有效捕捉时间序列数据中的规律和变化趋势，还考虑了节点之间的依赖关系，已经在交通流预测[9]、风电预测[10]、人体动作识别[11]等应用领域，取得了良好成果。文献[12]采用 CNN、LSTM 和图傅里叶变换进行图数据的特征提取，再利用残差网络进行预测，提高了负荷预测精度。文献[13]利用 K-means 算法对居民用户用电行为进行分组，采用自适应时空同步图卷积进行用户集群负荷预测，提高了居民用户集群负荷预测精度。但这些方法未考虑输入因素之间的相关性，导致预测结果不精确。本文采用互信息方法筛选出与历史负荷相关性强的因素作为模型输入。

近年来，新兴预测方法不断涌现。一方面，单一预测方法的适用范围有局限性，组合模型能得到较为满意的预测精度。文献[14]采用 CNN-LSTM 组合模型进行负荷预测，获得较好的预测结果。另一方面，信号处理技术逐渐渗透在负荷预测领域。常用的信号处理方法有经验模态分解（empirical mode decomposition，EMD）[15]、经验小波变换（empirical wavelet transform，EWT）[16]、变分模态分解（variational mode decomposition，VMD）[17-18]等。以上方法都没有考虑到噪声信号对时间序列分解结果的影响，可能导致分解结果存在偏差。EMD 容易出现模态混叠；EWT 分解精度较好，但会产生冗余成分，计算成本大[19]；VMD 抗噪能力强，但计算复杂度高，计算速度慢。针对上述问题，本文提出了结合奇异谱分析（Singular Spectrum Analysis，SSA）、VMD、图卷积神经网络（graph convolutional neural network，GCN）和灰色模型（gray model，GM）的负荷预测方法。算例仿真分析表明：本文提出的预测模型能快速提高负荷预测精度。

[收稿日期] 2023－11－30

[基金项目] 国家自然科学基金青年科学基金资助项目（51809097）；湖北省重点研发计划项目（2021BAA193）

[第一作者] 邓　心（1997－），女，湖北黄冈人，湖北工业大学硕士研究生，研究方向为深度学习在电力负荷分析与预测中的应用。

[通信作者] 方　娜（1979－），女，湖北黄冈人，工学博士，湖北工业大学讲师，研究方向为深度学习在电网运行监测、电力负荷分析与预测中的应用。

1　基本原理

1.1　奇异谱分析

SSA 是一种减少时间序列噪声的处理方法[20-21]。SSA 的基本操作如下：

1)构建轨迹矩阵：首先，SSA 分解被中心化的一维时间序列 $[X_1, X_2, \cdots, X_N]$，N 为序列长度。然后，初始序列经过合适的窗口大小 L 延迟嵌入，构建轨迹矩阵。一般取 $L < N/2L < N/2$，令 $K = N - L + K = N - L + 1$，轨迹矩阵 $= L * K$，对应的表达式如下：

$$\boldsymbol{X} = \begin{bmatrix} X_1 & X_2 & \cdots & X_K \\ X_2 & X_3 & \cdots & X_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ X_L & X_{L+1} & \cdots & X_N \end{bmatrix} \tag{1}$$

2)奇异值分解(singular value decomposition，SVD)：使用 SVD 分解轨迹矩阵。假设 $\boldsymbol{A}$ 是一个 $m * n$ 的矩阵，$\boldsymbol{A}$ 分解后的表达式为 $\boldsymbol{A} = \boldsymbol{U}\boldsymbol{\Sigma}\boldsymbol{V}^{\mathrm{T}}$，其中，$\boldsymbol{U} \in R^{m*m}$，$\boldsymbol{\Sigma} \in R^{m*n}$，$\boldsymbol{V} \in R^{n*n}$，$\boldsymbol{\Sigma}$ 为对角矩阵，$\boldsymbol{U}$ 和 $\boldsymbol{V}$ 分别是左右奇异向量矩阵，即满足 $\boldsymbol{U}^{\mathrm{T}}\boldsymbol{U} = I$，$\boldsymbol{V}^{\mathrm{T}}\boldsymbol{V} = I$。

3)分组：利用奇异值的贡献率对保留的成分进行分组。

4)重构：采用保留的成分，并与对应的奇异值向量相乘得到新重构的时间序列。

1.2　变分模态分解

VMD 是一种新型的非平稳信号自适应分解估计方法，目的是将原始复杂信号分解为 k 个本征模态函数(intrinsic mode function，IMF)。它通过对有限带宽 α 参数初始化，获得 k 个估算的中心角频率 W_k，然后，更替每个模态函数和中心频率，使每个模态估计带宽之和最小。时间序列 $f(t)$ 分解为一系列有限带宽模态函数 $\{u_k(t)\}$，$k = 1, 2, \cdots, k$，主要过程如下：

1)求解每个模态信号带宽的变分问题，其表达式为：

$$\begin{cases} \min\left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \dfrac{j}{\pi t} \right) * u_k(t) \right] e^{-jwkt} \right\|^2 \right\} \\ \text{s.t.} \sum_k u_k = f(t) \end{cases} \tag{2}$$

式中，∂_t 是对 t 求导；$\delta(t)$ 是脉冲信号；j 是虚数；$*$ 是卷积符号。$\{u_k\} = \{u_1, u_2, \cdots, u_k\}$；$\{w_k\} = \{w_1, w_2, \cdots, w_k\}$；$k$ 是模态分量数目。

2)采用二次惩罚系数 α 和拉格朗日参数 λ，将变分问题转换成非变分问题，表达式如下：

$$L(\{u_k\}, \{w_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jwkt} \right\|^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \tag{3}$$

式中，$\lambda(t)$ 是信号的约束条件。

3)采用交替的方向乘子法更新 ${u_k}^{n+1}$、${w_k}^{n+1}$ 及 λ^{n+1}，寻求变分问题的最优解。${u_k}^{n+1}$、${w_k}^{n+1}$ 及 λ^{n+1} 更新的表达式为：

$$\tilde{u}_k^{n+1}(w) = \frac{\tilde{f}(w) - \sum_{i \neq k} \tilde{u}_i(w) + \dfrac{\tilde{\lambda}^n(w)}{2}}{1 + 2\alpha (w - w_k^n)^2} \tag{4}$$

$$w_k^{n+1} = \frac{\int_0^\infty w \left| \tilde{u}_k^{n+1}(w) \right|^2 dw}{\int_0^\infty \left| \tilde{u}_k^{n+1}(w) \right|^2 dw} \tag{5}$$

$$\tilde{\lambda}^{n+1}(w) = \tilde{\lambda}^n(w) + t\left(\tilde{f}(w) - \sum_{k=1}^{k} \tilde{u}_k^{n+1}(w) \right) \tag{6}$$

式中，n 是更新迭代次数；t 为噪声容限；上标~是 ${u_k}^{n+1}$、${w_k}^{n+1}$ 及 λ^{n+1} 的傅里叶变换。

1.3　图卷积神经网络

图是由节点集合和节点之间的连接关系构成，图数据结构一般用 $G = (V, E)$ 表示。其中，V 表示节点集合，E 表示节点边的集合。根据 E 的集合，构建邻接矩阵 $\boldsymbol{A}$，获取完整的负荷信息。邻接矩阵 $\boldsymbol{A}$ 的表达式为 $\boldsymbol{A} = [A_{ij}]_N \times_N$，$N$ 表示节点的个数，A_{ij} 表示节点 i 和节点 j 之间的连接关系。当 A_{ij} 不为 0 时，表示节点 i，j 为邻居，反之，节点 i，j 之间不存在边连接。GCN 是一种处理图数据的深度学习方法，可以自动地学习节点自身特征和周围节点的关联特征，以便预测整个图的性质。图卷积神经网络的计算公式如下：

$$\hat{\boldsymbol{A}} = \boldsymbol{A} + \boldsymbol{I} \tag{7}$$

$$\hat{\boldsymbol{A}} = \hat{\boldsymbol{D}}^{-\frac{1}{2}} \hat{\boldsymbol{A}} \hat{\boldsymbol{D}}^{-\frac{1}{2}} \tag{8}$$

$$\boldsymbol{H}^{l+1} = \sigma(\hat{\boldsymbol{D}}^{-\frac{1}{2}} \hat{\boldsymbol{A}} \hat{\boldsymbol{D}}^{-\frac{1}{2}} \boldsymbol{H}^l \boldsymbol{W}^l) \tag{9}$$

式中，$\boldsymbol{A}$ 是邻接矩阵；$\hat{\boldsymbol{A}}$ 是对称归一化后的邻接矩阵；$\boldsymbol{I}$ 是单位矩阵；$\hat{\boldsymbol{D}}$ 是 $\hat{\boldsymbol{A}}$ 的度矩阵；$\boldsymbol{H}^{l+1}$ 表示所有经过一次卷积操作后的特征向量矩阵；σ 是非线性激活函数；$\boldsymbol{H}^l$ 表示当所有阶段在 l 层的特征向量矩阵；$\boldsymbol{W}^l$ 表示当前层卷积变换的可训练的参数矩阵。GCN 网络的结构如图 1 所示。

1.4　灰色模型

灰色模型 GM(1,1)是一种对误差修正的模型。它的原理是对误差序列做累加得到新序列，并对新序列进行预测，然后经过逆运算得到原始数据，进而得到误差预测结果。GM 的建立过程如下：

1)已知原始误差序列为 $x^0 = (x_1^0, x_2^0, \cdots, x_n^0)$，通过累加得到新序列为 $x^1 = (x_1^1, x_2^1, \cdots, x_n^1)$。

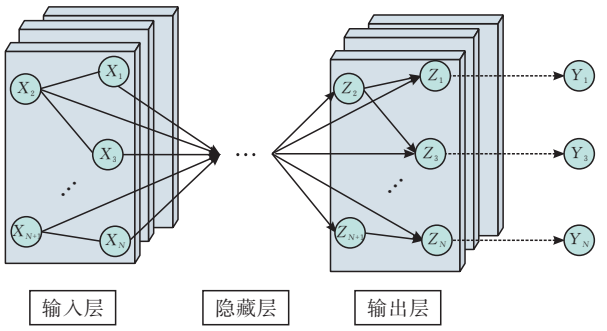

图 1 GCN 网络结构

2)建立关于 x^1 的一阶微分方程为：

$$\frac{\mathrm{d}x^1}{\mathrm{d}t}+ax^1(t)=b \tag{10}$$

式中，a 是发展系数；b 是灰色参数。

3)利用最小二乘法求式(11)的解为：

$$\hat{x}^0(t+1)=\hat{x}^1(t+1)-\hat{x}^1(t) \tag{11}$$

4)将式(12)中的解进行累减，得到负荷的误差预测值。

$$\hat{x}^0=(\hat{x}^0{}_1,\hat{x}^0{}_2,\cdots,\hat{x}^0_n,\hat{x}^0_{n+1},\cdots,\hat{x}^0_{n+m}) \tag{12}$$

式中，$\hat{x}^0_1,\hat{x}^0_2,\cdots,\hat{x}^0_n$ 是初始负荷误差值；$\hat{x}^0_{n+1},\cdots,\hat{x}^0_{n+m}$ 是负荷误差预测值。

2 基于 SSA-VMD-GCN-GM 的预测方法

通过采用 SSA-VMD 分解方法，负荷序列的分解精度得到了提高。将时间序列数据转换为图数据是进行 GCN 预测的关键步骤。电力负荷数据是一个时间序列，每个时刻都包含不同的特征因素。本文将时间序列中的每个时间点视为一个节点，每条边表示两个时间点之间的关系，并为每个节点赋予了干球温度、电价和历史负荷等特征。其次，根据节点之间连续性的特点构建稀疏的邻接矩阵。这种方法可以有效地挖掘负荷数据中的规律和关联性，提高预测精度。

本文提出的模型由输入层、GCN 层、全连接层、GM 模块和输出层组成。其中，SSA-VMD 用于得到平滑的序列，GCN 用于负荷预测，全连接层用于输出初步负荷预测值，GM 用于误差修正。SSA-VMD-GCN-GM 的预测流程如图 2 所示。

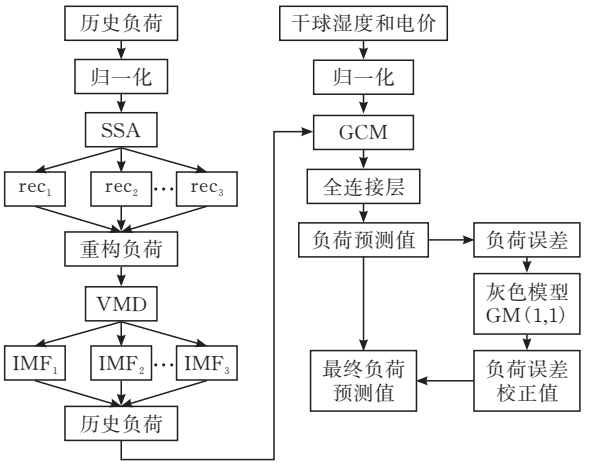

图 2 SSA-VMD-GCN-GM 的预测流程

3 模型参数的设置

3.1 SSA 参数的选取

SSA 分解序列时需要设置窗口长度 L，根据日负荷的特点，L 为 48，SSA 分解后产生 48 个特征值。SSA 重建过程中，需要确定特征值分组(eigenvalue grouping，EVG)。通过观察特征三元组在序列中的重要性程度，确定重构的特征三元组。SVD 与奇异值的对数如图 3 所示。春季负荷分解后的前 8 个主成分如图 4 所示。

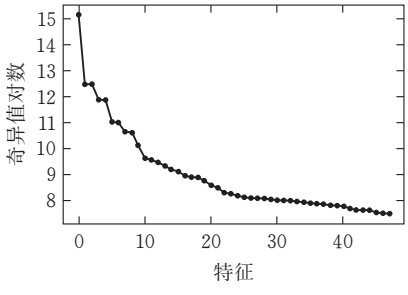

图 3 特征三元组奇异值对数

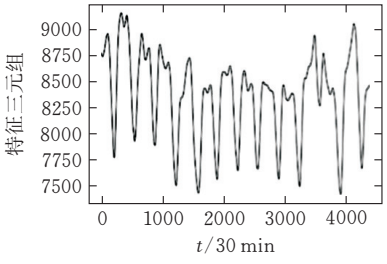

(a)贡献率=75.490%

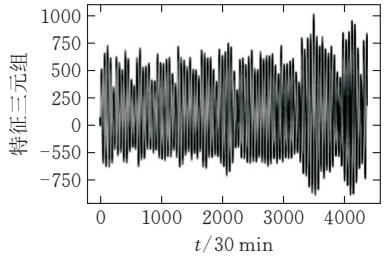

(b)贡献率=5.331%

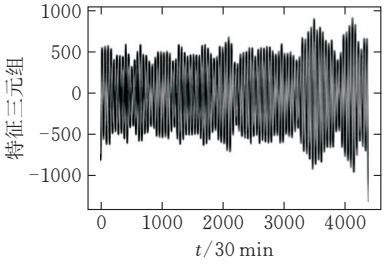

(c)贡献率=5.214%

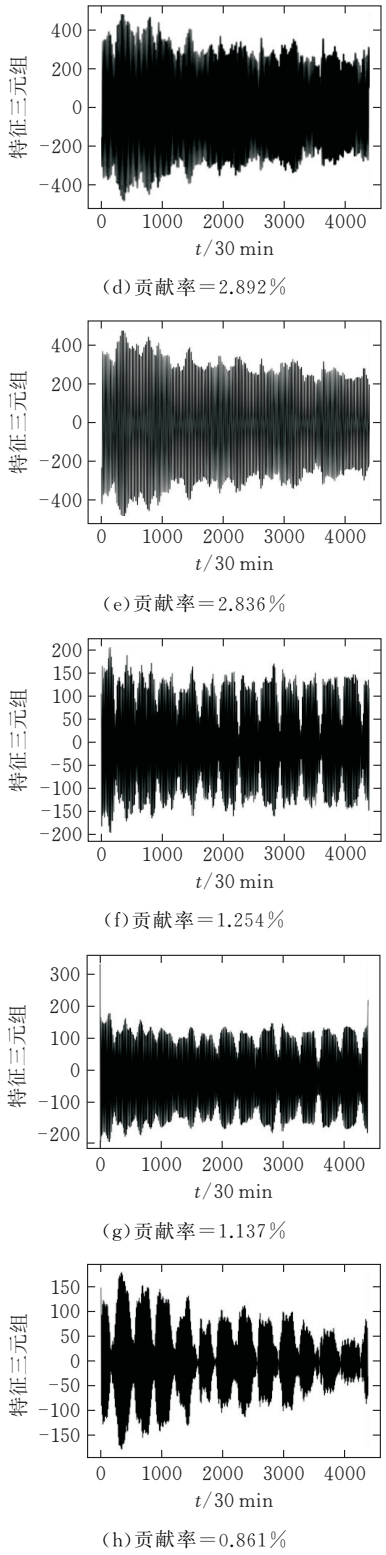

图 4　前 8 个特征三元组

图 4 中，第一个主成分图重要程度较大。结合奇异值对数图和主成分图，选取前 18 个特征三元组进行重构，剩余成分视为噪声。同理，采用相同的方法，选取前 18 个特征三元组重建其他三个季节的负荷序列。

综上所述，SSA 能保留原始负荷序列主要特征，简化复杂计算过程。

3.2　VMD 模态数 k 的选取

VMD 分解效果主要由模态数 k 确定，当 k 较小时，原始信号中的重要信息被过滤掉，影响后续预测精度；当 k 过大时，出现模态重复。因此需要选取 VMD 分解数 k。为了研究电力负荷季节性因素的特点，选择春季和夏季的负荷数据能够满足实际需求。本文通过中心频率观察法确定 VMD 的 k 值，春季降噪的负荷序列经过 VMD 分解，得到的各模态中心频率如表 1 所示。由表 1 可知，当 $k=7$ 时，W_3 和 W_4 的频率相隔很近，VMD 出现了模态混叠，因此，选择 $k=6$ 作为 VMD 分解数。由于四个季节的训练数据以及数量不一致，采用同样的方法，夏季负荷的 VMD 最佳模态数为 3，秋季和冬季负荷的 VMD 最佳模态数为 6。春季负荷数据经过 VMD 分解后，得到的分解图如图 5 所示。

表 1　VMD 的中心频率

中心频率	模态 k 值				
W	3	4	5	6	7
W_1	0.223	0.217	0.190	0.183	0.053
W_2	13.759	13.453	13.459	6.255	4.825
W_3	24.676	20.950	20.876	13.442	13.382
W_4		24.635	23.976	20.097	13.450
W_5			24.714	24.701	20.117
W_6				27.130	24.690
W_7					27.112

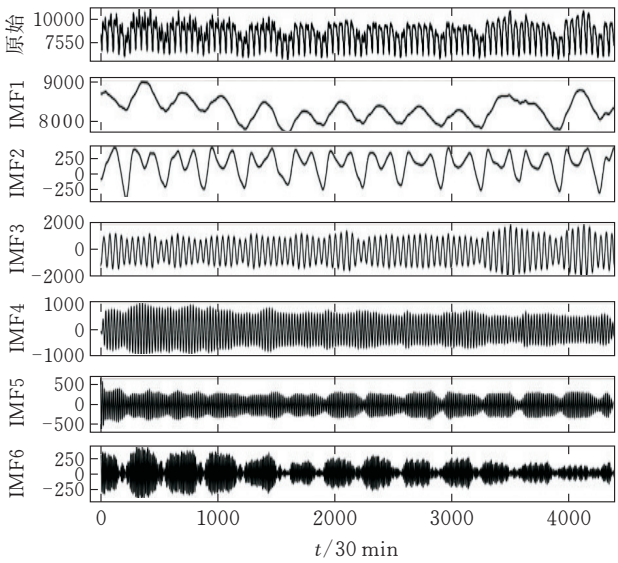

图 5　VMD 分解图

3.3　特征筛选

采用互信息特征选择方法能筛选出与标签相关性强的最小特征子集，有利于提高负荷预测精度。通过计算每个特征与标签之间的互信息量，从而确定最小特征组合。互信息（mutual information，MI）表示两个变量 X 与 Y 之间是否有联系，以及关系的强弱。两个变量之间的互信息量越大，表明变

量之间的相关性越强；反之，信息量越小或值为 0，则变量间相关性越弱或变量间相互独立。MI 值的计算公式如下：

$$I(X;Y)=\iint p(x,y)\log(p(x,y)/p(x)p(y))\mathrm{d}x\mathrm{d}y \tag{13}$$

式中，$p(x,y)$是 X 和 Y 的联合概率密度函数；$p(x)$和 $p(y)$是 X 和 Y 的边缘概率密度函数。

利用互信息方法计算不同输入特征与标签之间的互信息值。其中，干球温度的 MI 值为 0.579，露点温度 MI 值为 0.221，湿球温度的 MI 值为 0.378，湿度的 MI 值为 0.331，电价的 MI 值为 0.741。综上所述，干球温度和电价同历史负荷相关性强，因此，选择干球温度、电价和历史负荷为本文模型输入参数。

3.4 GCN 层数的选取

GCN 不仅能获取节点内部特征，而且可以挖掘节点与节点之间的特征。选择不同的 GCN 层数，对图信息的提取效果不同，过多的 GCN 层会丢失图原本的特征信息，使得负荷预测精度下降。表 2 给出了不同 GCN 层训练后的三种评价指标结果。由表 2 分析可知，当 GCN 层固定在 1 层时，三种模型评估指标最小，GCN 网络预测效果最理想。

表 2 不同 GCN 层的结果对比

层数	训练次数	学习率	MAE/MW	RMSE/MW	MAPE/%
1	100	0.01	70.536	90.400	0.875
2	100	0.01	141.202	179.842	1.752
3	100	0.01	209.122	267.175	2.595

4 算例分析

4.1 数据预处理与误差评价指标

本文采用南半球的澳大利亚电力负荷数据。即 2010 年 9—11 月(春季)、2010 年 12—2 月(夏季)、2010 年 3—5 月(秋季)和 2010 年 6—8 月(冬季)的数据作为样本数据，选择历史负荷、干球温度、电价为输入特征。将 11 月、2 月、5 月和 8 月，分别作为四个季节的测试集，其他视为训练集。该数据集的取样周期为 30 min，每天 48 组数据，春季包含 4368 条数据，夏季包含 4320 条数据，秋季包含 4416 条数据，冬季包含 4416 条数据。由于电力负荷数据和影响因素之间的量纲不一致，需要进行归一化处理。本文采用 z-score 处理方法，对训练数据进行归一化操作。z-score 的计算公式如下：

$$D=\frac{\theta-\mu}{s} \tag{14}$$

式中，D 为归一化后的数据；θ 是初始训练数据；μ 为均值；s 为标准差。

为了验证本文预测方法的优越性，采用训练时间、平均绝对误差(mean absolute error，MAE)、均方根误差(root mean square error，RMSE)以及平均绝对百分比误差(mean absolute percent error，MAPE)四种指标。其中，MAE、RMSE 和 MAPE 的计算公式如下：

$$\mathrm{MAE}=\frac{1}{n}\sum_{i=1}^{n}|y_i-\tilde{y}_i| \tag{15}$$

$$\mathrm{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i-\tilde{y}_i)^2} \tag{16}$$

$$\mathrm{MAPE}=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{\tilde{y}_i-y_i}{y_i}\right|\times 100\% \tag{17}$$

式中，n 表示所有负荷预测点总数；y_i 表示第 i 个时刻的负荷真实值，$\tilde{y}_i$ 表示第 i 个时刻的负荷预测值。

4.2 仿真结果分析

4.2.1 不同单一模型预测结果对比 为了验证 GCN 的有效性，同 LSTM、CNN 等方法比较，分别预测四季最后一周的电力负荷。与 GCN 参数设置保持同步，LSTM、CNN 均为 1 层，神经元数目都为 256，学习率为 0.01，训练批次为 20。差分自回归移动平均模型(autoregressive integrated moving average model，ARIMA)是一种典型的时间序列预测方法，对预测结果有较好的解释性。经过反复验证 ARIMA 的(p，d，q)参数选择(12，1，0)预测结果较好。四种模型的预测曲线如图 6 所示，图 6a 是 LSTM、CNN、ARIMA 和 GCN 春季预测曲线，图 6b 是夏季预测曲线，图 6c 是秋季预测曲线，图 6d 是冬季预测曲线。由图 7 可知，GCN 的预测效果优于 LSTM、CNN 和 ARIMA。具体的误差结果如表 3 所示。由表 3 可知，在春季，GCN 与 LSTM、CNN、ARIMA 对比，MAE 降低了 44.715 MW、83.309 MW 和 124.931 MW，RMSE 降低了 51.314 MW、103.814 MW 和 139.569 MW，MAPE 降低了 0.546%、1.021%和 1.402%；在夏季，MAE 降低了 229.623 MW、99.354 MW 和 105.905 MW，RMSE 降低了 345.588 MW、136.949 MW 和 138.109 MW，MAPE 降低了 2.833%、1.103%和 1.1%。在秋季，MAE 降低了 22.604 MW、130.93 MW 和 117.773 MW，RMSE 降低了 36.902 MW、174.29 MW 和 142.896 MW，MAPE 降低了 0.232%、1.401%和 1.366%；在冬季，MAE 降低了 48.762 MW、121.021 MW 和 79.85 MW，RMSE 降低了 53.542 MW、143.712 MW 和 88.259 MW，MAPE 降低了 0.556%、1.3%和 0.881%。此外，GCN 与 CNN、LSTM 和 ARIMA 对比，模型的训练时间较短，预测精度较高。

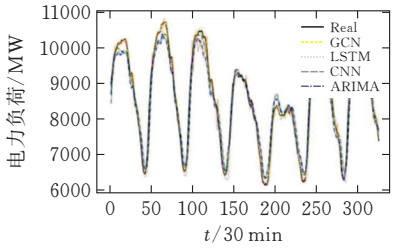

(a)春季

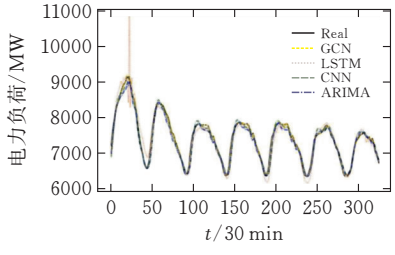

(b)夏季

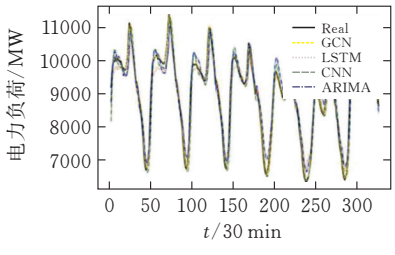

(c)秋季

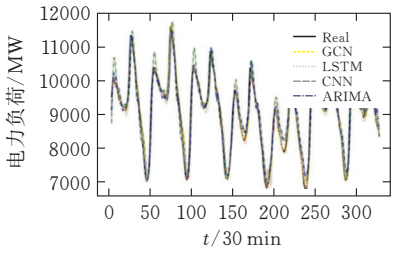

(d)冬季

图 6　单一模型预测

表 3　单一模型预测结果

季节	模型	MAE/MW	RMSE/MW	MAPE/%	训练时间/s
春季	LSTM	121.781	150.938	1.494	146.071
	CNN	160.375	203.438	1.969	3.837
	ARIMA	201.997	239.193	2.350	83.778
	GCN	77.066	99.624	0.948	2.441
夏季	LSTM	320.293	462.148	3.871	146.533
	CNN	190.024	253.509	2.141	3.871
	ARIMA	196.575	254.669	2.138	54.723
	GCN	90.670	116.560	1.038	2.559
秋季	LSTM	124.194	168.435	1.380	183.891
	CNN	232.520	305.823	2.549	3.846
	ARIMA	219.363	274.429	2.514	70.802
	GCN	101.590	131.533	1.148	2.307
冬季	LSTM	150.114	194.914	1.686	164.705
	CNN	222.373	285.084	2.430	3.850
	ARIMA	181.202	229.631	2.011	68.815
	GCN	101.352	141.372	1.130	2.524

4.2.2　不同分解方法预测结果对比　为了说明 SSA-VMD 的优势，将 VMD-GCN、SSA-GCN、SSA-VMD-GCN 及 SSA-VMD-GCN-GM 四种方法比较，分别预测四季最后一周的负荷趋势，预测曲线如图 7 所示。为进一步验证 SSA-VMD 的可行性，同 EMD、EWT 等方法比较，预测曲线如图 8 所示。

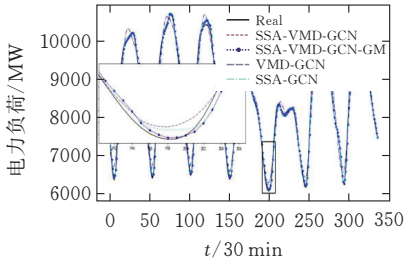

(a)春季

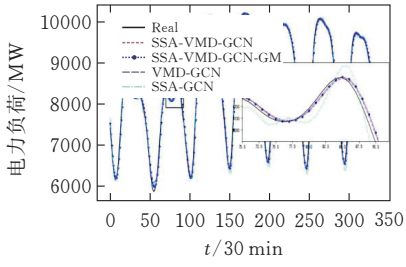

(b)夏季

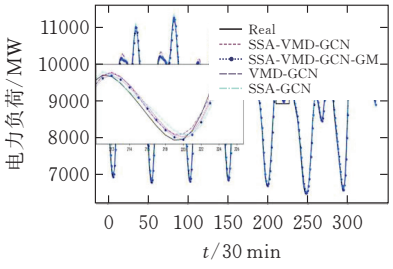

(c)秋季

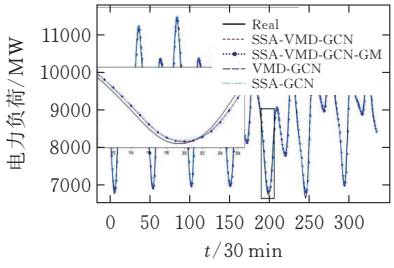

(d)冬季

图 7　基于 VMD、SSA 与 SSA-VMD 分解方法的预测

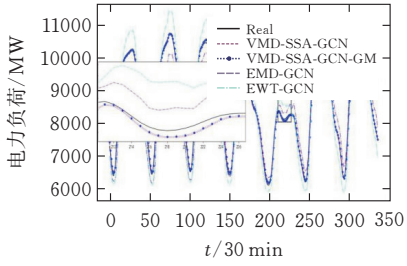

(a)春季

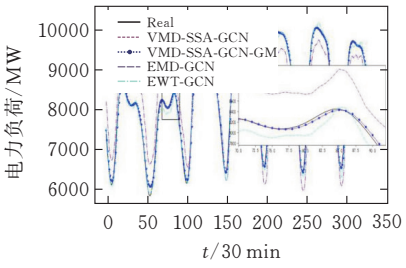

(b)夏季

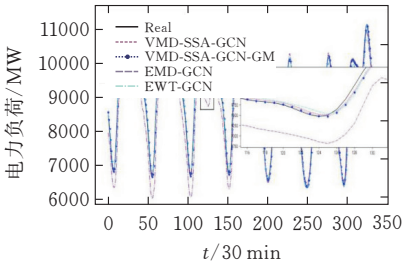

(c)秋季

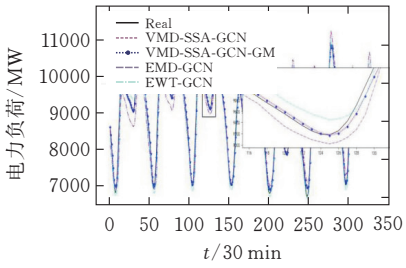

(d)冬季

图 8 基于 EMD、EWT 与 SSA-VMD 分解方法的预测

VMD 模态数、EWT 的信号分量数 N 均与文中的参数设置一致，SSA 特征三元组参数为 18，其他为默认设置。由图 7、8 可知，本文的 SSA-VMD-GCN-GM 预测曲线与真实曲线拟合程度更高。

为准确评估本文预测方法，给出了 MAE、RMSE、MAPE 和训练时间的计算结果(表 4、5)。

表 4 不同分解方法的春季和夏季预测结果

季节	模型	MAE/MW	RMSE/MW	MAPE/%	训练时间/s
春季	EMD-GCN	86.901	108.000	1.123	6.224
	EWT-GCN	96.802	120.421	1.217	7.641
	VMD-GCN	76.388	96.989	0.965	5.747
	SSA-GCN	78.016	99.306	0.975	6.369
	SSA-VMD-GCN	74.134	93.403	0.926	7.265
	SSA-VMD-GCN-GM	70.536	90.400	0.875	9.636
夏季	EMD-GCN	89.112	116.858	1.009	6.692
	EWT-GCN	89.405	116.813	1.018	7.821
	VMD-GCN	81.057	104.332	0.946	6.124
	SSA-GCN	84.823	112.066	0.979	6.700
	SSA-VMD-GCN	74.859	102.758	0.948	6.484
	SSA-VMD-GCN-GM	71.647	94.579	0.913	9.842

表 5 不同分解方法的秋季和冬季预测结果

季节	模型	MAE/MW	RMSE/MW	MAPE/%	训练时间/s
秋季	EMD-GCN	109.652	134.066	1.297	6.901
	EWT-GCN	110.171	134.385	1.246	7.883
	VMD-GCN	100.071	120.602	1.142	6.647
	SSA-GCN	108.804	130.625	1.233	6.370
	SSA-VMD-GCN	102.960	122.879	1.178	7.388
	SSA-VMD-GCN-GM	97.152	121.146	1.112	9.954
冬季	EMD-GCN	112.576	145.708	1.291	9.238
	EWT-GCN	108.428	142.268	1.216	8.824
	VMD-GCN	99.795	119.434	1.123	5.780
	SSA-GCN	101.396	135.118	1.133	6.610
	SSA-VMD-GCN	100.239	128.448	1.130	7.360
	SSA-VMD-GCN-GM	98.418	127.159	1.104	9.895

由表 4、5 可知，SSA-VMD-GCN-GM 的四种指标均最小。在春季，MAE、RMSE、MAPE 分别为 70.536 MW、90.400 MW 及 0.875%，训练时间为 9.636 s；在夏季，MAE、RMSE、MAP 分别为 71.647 MW、94.579 MW 及 0.913%，训练时间为 9.842 s；在秋季，MAE、RMSE、MAPE 分别为 97.152 MW、121.146 MW 和 1.112%，训练时间为 9.954 s；在冬季，MAE、RMSE、MAPE 分别为 98.418 MW，127.159 MW 和 1.104%，训练时间为 9.895 s。随着预测模型的组合，模型训练时间有所

增加，但均在允许范围内，且负荷预测精度较高。此外，在四个季节中，春季预测结果相对较好，冬季预测结果相对较差，但误差均在正常范围内。这可能是由于春季气温以及负荷变化平稳，冬季负荷变化幅度大等外界因素造成的。综上所述，SSA-VMD 优于 EMD、EWT、VMD 和 SSA 的分解效果，并且 GM 能进一步提高整个模型的预测精度。

4.2.3　不同组合模型预测结果对比　为验证本文组合方法的有效性，分别同几种典型的组合模型 EMD-LSTM、VMD-CNN-LSTM、EWT-ARIMA 及 SSA-VMD-CNN 等方法比较，同样预测四季最后一周的电力负荷，预测误差曲线以及预测误差结果分别如图 9 和表 6 所示。从图 9 看出，SSA-VMD-GCN-GM 的误差曲线在 0 值附近出现的概率最高，所以它的误差最小。

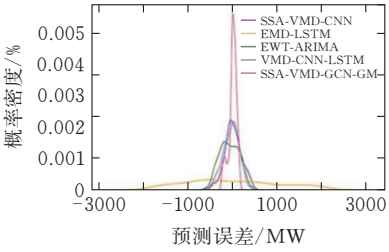

(a)春季

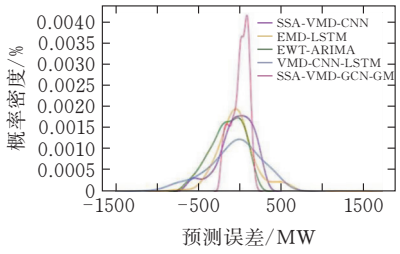

(b)夏季

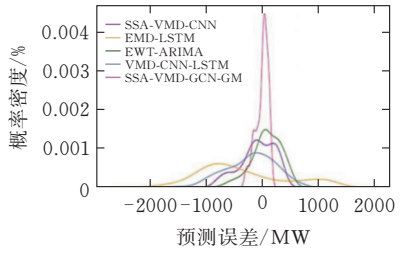

(c)秋季

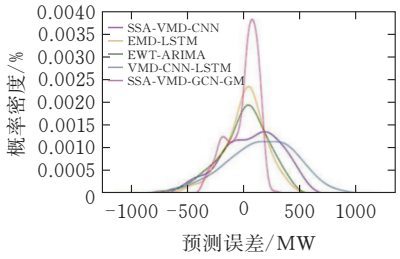

(d)冬季

图 9　组合模型误差概率密度曲线

表 6　组合模型各季节的预测结果

季节	模型	MAE/MW	RMSE/MW	MAPE/%	训练时间/s
春季	EMD-LSTM	194.069	266.714	2.322	154.107
	VMD-CNN-LSTM	224.542	269.655	2.806	28.668
	EWT-ARIMA	189.074	226.679	2.222	27.205
	SSA-VMD-CNN	143.397	179.206	1.770	9.430
	SSA-VMD-GCN-GM	70.536	90.400	0.875	9.636
夏季	EMD-LSTM	153.814	264.702	1.658	150.933
	VMD-CNN-LSTM	309.000	396.177	3.504	41.179
	EWT-ARIMA	198.969	257.767	2.161	26.972
	SSA-VMD-CNN	189.790	244.165	2.168	7.552
	SSA-VMD-GCN-GM	71.647	94.579	0.913	9.842
秋季	EMD-LSTM	149.210	196.741	1.791	156.757
	VMD-CNN-LSTM	192.531	246.603	2.186	25.595
	EWT-ARIMA	224.013	278.614	2.580	30.878
	SSA-VMD-CNN	202.196	244.545	2.251	9.200
	SSA-VMD-GCN-GM	97.152	121.146	1.112	9.954
冬季	EMD-LSTM	145.153	186.676	1.631	177.091
	VMD-CNN-LSTM	173.290	214.223	1.946	30.087
	EWT-ARIMA	175.881	227.945	1.943	28.497
	SSA-VMD-CNN	216.796	261.126	2.427	8.941
	SSA-VMD-GCN-GM	98.389	127.702	1.106	9.895

由表 6 可知，SSA-VMD-GCN-GM 与 EMD-LSTM、VMD-CNN-LSTM、EWT-ARIMA 以及 SSA-VMD-CNN 对比，在春季，MAE 分别减少了 123.533 MW、154.006 MW、118.538 MW 和 72.861 MW，RMSE 分别减少了 176.314 MW、179.255 MW、136.279 MW 和 88.806 MW，MAPE

分别减少了1.447%、1.931%、1.347%和0.895%；在夏季，MAE降低了82.167 MW、237.353 MW、127.322 MW和118.143 MW，RMSE降低了170.123 MW、301.598 MW、163.188 MW和149.586 MW，MAPE降低了0.745%、2.591%、1.248%和1.255%；在秋季，MAE降低了52.058 MW、95.379 MW、126.861 MW和105.044 MW，RMSE降低了75.595 MW、125.457 MW、157.468 MW和123.399 MW，MAPE降低了0.679%、1.071%、1.468%和1.139%；在冬季，MAE降低了46.764 MW、74.901 MW、77.492 MW和118.407 MW，RMSE降低了58.974 MW、86.521 MW、100.243 MW和133.422 MW，MAPE降低了0.525%、0.84%、0.837%和1.132%。另外，本文组合模型的训练时间相对较少，预测误差值较小。因此，本文组合方法预测效果好、预测精度高。

5 结论

本文提出了一种SSA-VMD-GCN-GM的短期负荷组合预测方法，该方法包括序列分解、预测和误差校正三个部分，通过仿真分析得出的结论如下：

1)使用SSA-VMD组合分解法，提高了时间序列分解准确度，减少负荷数据噪声干扰。

2)利用GCN网络进行预测，能提高预测精度。GCN可以通过分析节点之间的关系，来挖掘数据中潜在的规律。

3)采用GM对负荷的初步预测结果进行修正，可以进一步提高模型预测精度。

本文的组合模型与VMD-CNN-LSTM、SSA-VMD-CNN等模型对比，训练时间较少，预测精度较高。同时，本文组合模型还考虑了电力负荷的季节性，由仿真结果分析可知，模型春季预测结果较好，冬季预测结果较差。在后续研究中，将继续深入挖掘电力负荷的特点，以进一步提高负荷预测结果的准确性。

[参 考 文 献]

[1] 廖旎焕，胡智宏，马莹莹，等.电力系统短期负荷预测方法综述[J].电力系统保护与控制，2011(01)：147-152.

[2] 杨胡萍，余阳，汪超，等.基于VMD-CNN-BIGRU的电力系统短期负荷预测[J].中国电力，2022(10)：71-76.

[3] 万昆，柳瑞禹.区间时间序列向量自回归模型在短期电力负荷预测中的应用[J].电网技术，2012(11)：77-81.

[4] 王典礼.指数平滑日负荷预测[J].水电能源科学，1986(01)：91-97.

[5] 黎祚，周步祥，林楠.基于模糊聚类与改进BP算法的日负荷特性曲线分类与短期负荷预测[J].电力系统保护与控制，2012，40(03)：56-60.

[6] 李焱，贾雅君，李磊，等.基于随机森林算法的短期电力负荷预测[J].电力系统保护与控制，2020(21)：117-124.

[7] Zhang S，Chen R，Cao J，et al. A CNN and LSTM-based multi-task learning architecture for short and medium-term electricity load forecasting[J]. Electric Power Systems Research，2023，222：109507.

[8] 姬莉霞，赵耀，马郑祎，等.基于iForest-BiLSTM-Attention的数据库负载预测方法[J].郑州大学学报(理学版)，2022，54(06)：66-73.

[9] 汪鸣，彭舰，黄飞虎.基于门控循环图卷积网络的交通流预测[J].计算机应用研究，2022，39(08)：2301-2305.

[10] Song Y，Tang D，Yu J，et al. Short-term forecasting based on graph convolution networks and multiresolution convolution neural networks for wind power[J]. IEEE Transactions on Industrial Informatics，2022，19(02)：1691-1702.

[11] 杜启亮，向照夷，田联房，等.用于动作识别的双流自适应注意力图卷积网络[J].华南理工大学学报(自然科学版)，2022，50(12)：20-29.

[12] 史含笑，王雷春.结合LSTM和自注意力机制的图卷积网络短期电力负荷预测[J/OL].计算机应用：1-9[2023-05-09]. http：//kns.cnki.net/kcms/detail/51.1307.TP.20230411.0901.002.html.

[13] 董雷，陈振平，韩富佳，等.基于图卷积神经网络与K-means聚类的居民用户集群短期负荷预测[J/OL].电网技术：1-11[2023-05-09]. http：//kns.cnki.net/kcms/detail/11.2410.TM.20221013.1648.003.html.

[14] Rafi S H，Deeba S R，Hossain E. A Short-Term Load Forecasting Method Using Integrated CNN and LSTM Network[J]. IEEE Access，2021，9：32436-32448.

[15] 王荣茂，谢宁，于海洋，等.基于EMD-LSTM模型的台区负荷短期预测方法[J].实验室研究与探索，2022，41(01)：62-66.

[16] Liao Z，Huang J，Cheng Y，et al. A novel decomposition-based ensemble model for short-term load forecasting using hybrid artificial neural networks[J]. Applied Intelligence，2022，52(10)：11043-11057.

[17] 叶剑华，曹旌，杨理，等.基于变分模态分解和多模型融合的用户级综合能源系统超短期负荷预测[J].电网技术，2022，46(07)：2610-2622.

[18] He F，Zhou J，Feng Z，et al. A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm[J]. Applied Energy，2019，237：103-116.

[19] Jiang Y M，Liu M S，Li Y Y，et al. Enhanced neighborhood node graph neural networks for load forecasting in smart grid[J]. International Journal of Machine Learning and Cybernetics，2023，1：20. https：// doi.

org/10.1007/s13042-023-01796-8
[20] Zhu D, Wang Y, Zhang F. Energy price prediction integrated with singular spectrum analysis and long short-term memory network against the background of carbon neutrality[J]. Energies, 2022, 15(21): 8128.
[21] Neeraj N, Mathew J, Agarwal M, et al. Long short-term memory-singular spectrum analysis-based model for electric load forecasting[J]. Electrical Engineering, 2021, 103:1067-1082.

Short-term Load Forecasting Based on SSA-VMD-GCN-GM

DENG Xin, FANG Na
(*School of Electrical and Electronic Engineering, Hubei Univ. of Tech., Wuhan* 430068, *China*)

Abstract: A short-term load forecasting method is proposed, which combines singular spectrum analysis (SSA), variational modal decomposition (VMD), graph convolutional neural network (GCN) and gray model(GM) to address the problems of large fluctuation in time series and poor load forecasting accuracy. First, SSA is used to denoise the load sequence and reduce the noise interference in load data. Then, VMD is used to decompose the denoised sequence, which improves the decomposition accuracy and accelerates the computation. Next, the input parameters are selected using the mutual information and graph data are constructed, predictions are made using the GCN network, and the predicted values are fed to a fully connected layer as preliminary prediction results. Finally, GM is used to correct the load error values, and the corrected error prediction results are added to the preliminary prediction results as the final prediction value of the model. Through the simulation of arithmetic cases, the proposed model show good performance in load forecasting.

Keywords: singular spectrum analysis; variational modal decomposition; graph convolutional neural network; short-term load prediction; gray model

[责任编校: 赵　瞳]

(上接第 11 页)

A New Complementary Empirical Ensemble Mode Decomposition Method for Respiration Extraction

LIU Yang, CHEN Yunfan, LIANG Yameng, ZENG Chunyan, WAN Xiangkui
(*School of Electrical and Electronic Engineering, Hubei Univ.of Tech., Wuhan* 430068, *China*)

Abstract: Respiration has been linked to heart disease, sleep apnea, and mood, and monitoring respiration is important for diagnosing and managing a variety of conditions. In this paper, a novel breath extraction method based on complementary empirical mode decomposition is proposed, the ECG signal and Gauss white noise were respectively decomposed by integrated empirical mode, and the obtained eigenmode function was combined with noise reduction. The new IMF in the respiratory band was selected for correlation analysis, and the optimal amplitude noise factor was determined adaptively by the principle of maximum correlation increment, and the respiratory signal was derived from the ECG. Experimental verification was carried out in MIT-BIH-Polysomnographic database. Compared with CEEMD method, the EDR extraction method proposed in this paper reduced the average MSE by 3.95%, the average RMSE by 2.74%, and the average MAE by 2.52%. The decomposition calculation time was decreased by 37.5% and the physical significance of IMF component was clearer. The method has good accuracy, robustness and adaptability, and provides a new solution for respiration signal extraction.

Keywords: Electrocardiography (ECG); new complementary ensemble empirical mode decomposition; ECG-derived respiration (EDR)

[责任编校: 赵　瞳]