[文章编号] 1003－4684(2026)04-0007-05

一种新的互补集合经验模态分解呼吸提取方法

刘 扬，陈云帆，梁雅梦，曾春艳，万相奎
（湖北工业大学电气与电子工程学院，湖北 武汉 430068）

[摘 要] 呼吸与心脏疾病、睡眠呼吸暂停和情绪有关，监测呼吸对于诊断和管理多种疾病具有重要意义。提出一种新的互补经验模态分解的呼吸提取方法，对心电信号和高斯白噪声分别进行 EEMD 分解，将得到的 IMF 分量进行复合降噪处理，选择呼吸频段内新的 IMF 与实测呼吸信号做相关分析，由相关性增量最大原则自适应地确定最佳幅值噪声系数，从心电中导出呼吸信号。在 MIT-BIH 多导睡眠数据库中进行实验验证，提出的呼吸提取方法与 CEEMD 算法对比，平均 MSE 减小 3.95%、平均 RMSE 减小 2.74%、平均 MAE 减小 2.52%，计算耗时减少 37.5% 且 IMF 分量物理意义更明确。本算法具有较好的准确性、鲁棒性和自适应性，为呼吸信号的提取提供了一种新的解决思路。

[关键词] 心电图；互补经验模态分解；心电导出呼吸
[中图分类号] TN911.71 [文献标识码] A

呼吸是人体重要的生理参数，通常与心脏疾病、睡眠呼吸暂停综合征和焦虑情绪有关[1]，呼吸和心率之间已被证明存在耦合作用[2]。然而监测呼吸需要笨重的设备，可能会干扰自然呼吸。从心电信号中获得呼吸信号（ECG-derived respiratory，EDR）能有效降低监护成本，提高使用者的舒适度，更适合门诊和家庭监护。

国内外学者在基于心电信号提取 EDR 方面进行了大量的探索和研究。文献[3]通过从心电信号 QRS 复合物的斜率和角度的变化中提取 EDR，但该方法容易受到噪声的影响且只能用于估计呼吸速率，无法得到呼吸波形。文献[4-5]利用毫米波雷达技术非接触式地获取心电和呼吸信号，能够做到实时监测，但信号质量会受到环境因素、人体移动和其他干扰的影响，适用范围有限。文献[6]通过线性主成分分析（PCA）从心电中导出 EDR 信号，通过计算特征向量和特征值提取主要成分，但 PCA 无法捕捉到心电信号与呼吸信号之间的非线性关系，导致降维结果失真。文献[7]提出了基于核的主成分分析，通过引入核技巧将非线性特征提取引入 PCA 中，但核参数的优化过程比较复杂。离散小波变换（DWT）能够捕捉心电信号中的瞬时变化和非线性成分，用于重建细节信号和估计 EDR 信号，但小波变换的时频窗口对数据并非完全自适应，且尺度和分解级数的选择需要一定的经验。文献[8]发现基于（empirical mode decomposition，EMD）原理的 EDR 提取技术优于基于离散小波变换的算法，可以作为间接提取呼吸的一种较好的替代算法，但它会在时频分布中造成严重的模式混叠，使单个本征模态函数的物理意义模糊。Wu 和 Huang 提出了一种集合经验模态分解（ensemble empirical mode decomposition，EEMD）算法[9-10]，克服了 EMD 的模态混合问题，但该方法叠加的白噪声幅值和总体平均迭代次数依靠人为经验选择，信号重构之后残留的白噪声的影响不可忽略。Yeh 等[11]提出一种互补集合经验模态分解（complementary ensemble empirical mode decomposition，CEEMD）主要通过向源信号中添加一对相反的白噪声信号，并进行 EMD 分解。CEEMD 对比 EEMD 算法减小了由白噪声引起的重构误差[12]，但缺点是运算翻倍，如果添加白噪声幅值和迭代次数不合适，还会分解出较多的伪分量，需要对 IMF 分量重新组合或后续处理。

为了解决 EEMD 和 CEEMD 分解方法中噪声幅值系数需要人工设置的缺陷，进一步减小重构呼吸中的噪声残留，本文提出一种新的互补经验模态分解（new complementary empirical mode decomposition，NCEEMD）的呼吸提取方法，该算法不仅

[收稿日期] 2023－08－31
[基金项目] 国家自然基金项目(61901165)
[第一作者] 刘 扬(1996－)，男，湖北荆州人，湖北工业大学硕士研究生，研究方向为生物医学信号处理。
[通信作者] 万相奎(1976－)，男，湖北广水人，工学博士，湖北工业大学教授，研究方向为生物医学信号处理。

在选择最佳幅值噪声系数方面具有自适应性，而且通过额外引入白噪声的 EEMD 分解，能更好地消除重构呼吸信号中的噪声残留，克服了 EEMD 和 CEEMD 不足，具有一定的优越性。

本文的组织结构如下：第一节提出了基于 NCEEMD 的 EDR 算法及算法评估性能指标；第二、三节介绍了本文采用的数据集、实验结果和讨论；最后给出结论。

1 方法

1.1 NCEEMD 算法

EMD 算法可以用于分析非线性、非平稳的信号序列，具有很高的信噪比和良好的时频聚焦性，但是算法本身的缺陷使单个本征模态函数的物理意义模糊，在时频分布中造成严重的模式混叠。CEEMD 比原来的 EMD 有了很大的改进，通过叠加互为相反数的正负白噪声的多次 EMD 分解，利用了高斯白噪声具有频率均匀分布的统计特性，基于噪声辅助分析的手段有效的解决了模式混叠的问题。在 CEEMD 分解算法中，噪声幅值系数的设置仍然依赖于人为经验；虽然随着总体平均迭代次数增加，噪声对结果的影响减小，但是算法的时间成本也相应增加，且添加白噪声的残留不可忽视。基于此，本文提出了一种 NCEEMD 算法，通过对高斯白噪声的 EEMD 分解，与原始信号的 EEMD 分解结果相减，利用高斯白噪声的特性，稀释或者消除本身信号分解中的噪声残留，提高算法的准确性。

NCEEMD 算法的具体流程如下：

1）假设原始信号为 $y(t)$，高斯白噪声信号 $g(t)$，预设总体平均次数为 $m=100$，噪声幅值系数为 α（待定）。

2）第 i 次加入的具有标准正态分布的白噪声序列为 $n_i(t)$，则第 i 次实验的含噪信号 $y_i(t)$、$g_i(t)$ 为：

$$y_i(t)=y(t)+\alpha n_i(t) i=1,2,\cdots,m \tag{1}$$

$$g_i(t)=g(t)+\alpha n_i(t) i=1,2,\cdots,m \tag{2}$$

3）对 $y_i(t)$、$g_i(t)$ 进行第 i 次 EMD 处理。得到原始信号的多分辨率特征，反映更多的细节尺度信息；观察高斯白噪声在各个频段的细节特性，用于模拟 EEMD 添加的白噪声在重构中的误差残留。

$$y_i(t)=\sum_{j=1}^{n} x_{ij}(t)+r_i(t) j=1,2,\cdots,n \tag{3}$$

$$g_i(t)=\sum_{j=1}^{n} k_{ij}(t)+l_i(t) j=1,2,\cdots,n \tag{4}$$

其中，$x_{ij}(t)$ 为原始信号 EMD 分解得到的第 j 个 IMF 分量平均值；$r_i(t)$ 为残余项平均值；$k_{ij}(t)$ 为高斯白噪声 EMD 分解得到的第 j 个 IMF 分量平均值；$l_i(t)$ 为残余项平均值。(4)将(2)、(3)得到的各 IMF 分量在对应频段内相减，得到新的 IMF 分量 $W_{ij}(t)$，用于消除原始信号 EEMD 分解中的白噪声残留。

$$W_{ij}(t)=x_{ij}(t)-k_{ij}(t) \tag{5}$$

$$T_{ij}(t)=r_i(t)-l_i(t) \tag{6}$$

其中，$W_{ij}(t)$ 为新得到的第 j 个 IMF 分量平均值；$T_{ij}(t)$ 为新残余项平均值。

5）重复(3)和(4)的流程，直至 $i=m$，求经过 m 次 EMD 分解得到的第 j 个 IMF 分量平均值 $A_j(t)$ 和残余项平均值 $B_n(t)$，公式如下：

$$A_j(t)=\frac{1}{n}\sum_{i=1}^{n} W_{ij}(t) \tag{7}$$

$$B_n(t)=\frac{1}{n}\sum_{i=1}^{n} T_{ij}(t) \tag{8}$$

6）利用高斯白噪声复合降噪处理后的最终结果 $C(t)$ 为：

$$C(t)=\sum_{j=1}^{n} A_j(t)+B_n(t) \tag{9}$$

1.2 基于 NCEEMD 的 EDR 算法

为解决 CEEMD 算法中的噪声幅值系数需要人为经验设置的缺陷和降低引入的噪声干扰，考虑到随着原始信号分解中噪声残留的减小，信号之间的相关性会逐渐增加，本文提出了一种基于 NCEEMD 的 EDR 算法。通过预设不同的噪声系数，对比 CEEMD 分解和 NCEEMD 分解得到的 IMF 分量与原始呼吸的相关性，由相关系数增量最大原则确定算法中的最佳幅值噪声系数 α，用于重构呼吸信号，根据数据特征自动调整参数，提升算法的自适应性。

选择重构呼吸的 IMF 频段范围：由于呼吸和心跳分别处在不同的频段，通过滤波或分解的方法可以将呼吸从心电信号中分离出来。正常情况下人的呼吸频率一般在 0.1～0.5 Hz，而心跳频率一般在 0.8～2 Hz，考虑到患者存在呼吸急促或呼吸暂停的情况，本文选择的呼吸频率范围为0.07～0.75 Hz，以频段中的 IMF 分量作为重构呼吸的分量。

计算 IMF 与实测呼吸信号的相关性：由 NCEEMD 分解原始信号得到多个 IMF 分量，本文利用 *Pearson* 相关系数 R 指标来衡量 IMF 分量与实测呼吸信号的相关性，相关系数 R 的大小反映了两个信号之间的相关程度。P 值是检验值，是检验两变量在样本来自的总体中是否存在和样本一样的相关性，使用显著性 P 值评估 IMF 分量的统计学意义，若 P 值小于 0.05，则具有统计学意义，相关性 R 被视为显著。

$$R(X,Y)=\frac{Cov(X\cdot Y)}{\sqrt{Var[X]\,Var[Y]}} \tag{10}$$

其中，$Cov(X \cdot Y)$ 为 X 与 Y 的协方差；$Var[X]$ 为 X 的方差；$Var[Y]$ 为 Y 的方差。

确定算法的最佳幅值噪声系数：分别比较心电信号的 CEEMD 分解分量 $x_{ij}(t)$、NCEEMD 分解分量 $W_{ij}(t)$ 与实测呼吸信号之间相关系数的增量情况，由相关系数增量最大原则确定算法的最佳幅值噪声系数 α，用于重构呼吸信号。

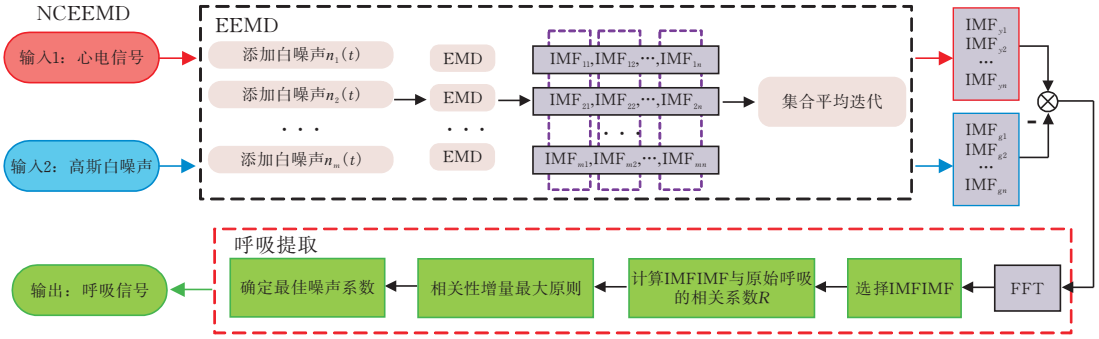

图 1　基于 NCEEMD 的呼吸提取算法

2　实验

2.1　数据集

MIT-BIH 多导睡眠数据库[13]（mit-bih-polysomnographic-database，MBPD）中包括 18 个连续记录，这些记录来自 16 名患有睡眠呼吸暂停综合征的男性受试者。slp01a 和 slp01b 两条数据是同一位患者的多导睡眠图片段，slp02a 和 slp02b 则是另一个患者的多导睡眠图片段，其余 14 条数据记录属于 14 个不同的患者。数据库中的各个记录时长在 2～7 h 之间，以 250 Hz 和 12 位分辨率进行数字化处理。记录的生理信号包括心电图、肌电图、眼电图、动脉血压、呼吸、动脉血氧饱和度，呼吸信号由电感容积描记仪或鼻热敏电阻记录。

本文使用该数据库的心电信号和同时记录的原始鼻腔呼吸进行验证，与其他方法进行比较来评估本算法的性能。

2.2　评价指标

为量化 EDR 与原始呼吸的误差情况，本文以计算均方误差（mean square error，MSE）、均方根误差（root mean square error，RMSE）、平均绝对误差（mean absolute error，MAE）来评估算法的准确性。

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2 \tag{11}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2} \tag{12}$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i - y_i| \tag{13}$$

其中，$\hat{y}_i$ 表示估计值；y_i 为实际测量值。

2.3　实验结果

本文以 MBPD 中前 60 秒的 slp01a 数据为例，比较 EMD、EEMD、CEEMD 和 NCEEMD 四种分解算法得到的 EDR 信号，将其分别与数据库中的实测原始呼吸进行比较。

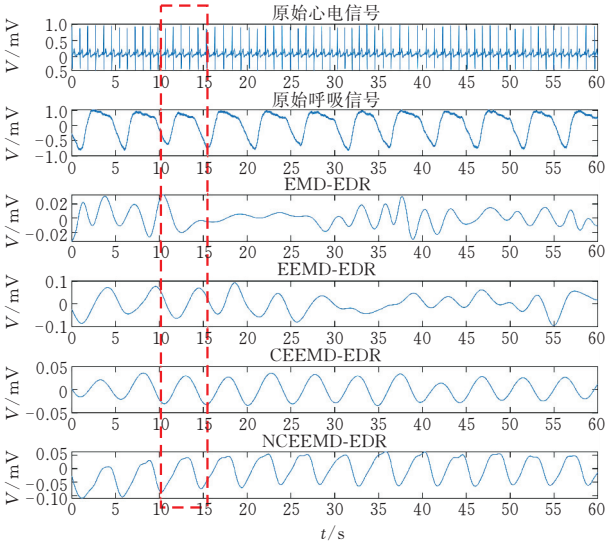

图 2　slp01a 记录的不同 EDR 与原始呼吸的比较示例

图 2 显示了在 60 秒的时间内，使用 slp01a 记录的腹腔呼吸片段的不同 EDR 比较示例。上述每一种 EDR 技术都能提供吸气和呼气的高峰与低谷以及呼吸速率的信息，但基于 NCEEMD-EDR 算法提取的呼吸与原始呼吸在形态上更相似。

使用 MBPD 中 18 个连续记录数据，分别计算 EMD/EEMD/CEEMD/NCEEMD-EDR 与原始呼吸的 MSE、RMSE 和 MAE，所有记录的误差比较列表如下。表 1 中以 MBPD 中的 slp01a 记录为例，本算法提取的 EDR 与原始呼吸的 MSE、RMSE、MAE 误差最小，且与 CEEMD 算法对比，平均 MSE 减小 3.95%、平均 RMSE 减小 2.74%、平均 MAE 减小 2.52%。表 2 中在相同噪声幅值系数和噪声个数下，本算法计算耗时为 25.14 s，比 CEEMD 算法速度提升了 37.5%。本算法的正交性指标仅为 0.01，其分解分量具有更高的独立性，能够有效地提取出数据中的独立特征或成分，IMF 分量的物理意义更

明确。

表 1 所有记录的误差比较表

记录	EMD			EEMD			CEEMD			NCEEMD		
	MSE	RMSE	MAE	MSE	RMSE	MAE	MSE	RMSE	MAE	MSE	RMSE	MAE
Slp01a	0.1674	0.4091	0.3696	0.1686	0.4106	0.3704	0.1682	0.4101	0.3704	**0.1668**	**0.4084**	**0.3681**
Slp01b	0.2518	0.5018	0.4314	0.2521	0.5021	0.4315	0.2528	0.5027	0.4322	**0.2431**	**0.4931**	**0.4313**
Slp02a	0.2206	0.4697	0.3898	0.2176	0.4665	0.3881	0.2178	0.4667	0.3877	**0.2158**	**0.4645**	**0.3861**
slp02b	0.1946	0.4411	0.3821	0.1945	0.441	0.3816	0.194	0.4404	0.3816	**0.1932**	**0.4395**	**0.3816**
Slp03	0.0604	0.2458	0.196	0.0616	0.2482	0.1991	0.061	0.2469	0.1971	**0.06**	**0.2449**	**0.1948**
Slp04	**0.0223**	**0.1493**	0.1204	0.0313	0.1769	0.1412	0.0259	0.161	0.1314	0.024	0.1549	**0.1143**
Slp14	0.0296	0.172	0.1451	0.0313	0.1769	0.1424	0.0285	0.169	0.1414	**0.0266**	**0.1651**	**0.1321**
Slp16	0.0414	0.2035	0.1719	0.0468	0.2163	0.1766	0.0415	0.2038	0.1712	**0.0406**	**0.2015**	**0.1697**
Slp32	**0.098**	0.313	0.2524	0.1063	0.326	0.2641	0.1021	0.3196	0.2577	0.1002	**0.3112**	**0.2487**
Slp37	0.0322	0.1794	0.1697	0.0337	0.1836	0.1707	0.0321	0.179	**0.1692**	**0.0281**	**0.1619**	0.1696
Slp45	0.0616	0.2482	**0.218**	0.0769	0.2773	0.2394	0.0707	0.2658	0.2315	**0.0588**	**0.2425**	0.2282
Slp48	0.0899	0.2998	0.2587	0.092	0.3033	0.2617	0.091	0.3016	0.2608	**0.0805**	**0.2837**	**0.2408**
Slp60	0.0313	0.1769	0.1478	0.0338	0.1838	0.1515	0.0335	0.1831	0.151	**0.0304**	**0.1744**	**0.1369**
Slp61	0.0544	0.2332	0.1939	0.0551	0.2347	0.1946	0.0546	0.2336	0.194	**0.0542**	**0.2328**	**0.1919**
Slp66	0.0176	0.1327	**0.1114**	0.0191	0.1382	0.1153	0.0183	0.1354	0.1134	**0.0165**	**0.1285**	0.1136
Slp67x	0.0265	0.1628	0.1539	0.0278	0.1667	0.1513	0.0264	0.1624	0.1526	**0.0249**	**0.154**	**0.1424**
Average Error	0.0875	0.2711	0.232	0.0905	0.2783	0.2362	0.0887	0.2738	0.234	**0.0852**	**0.2663**	**0.2281**

表 2 slp01a 记录的 EEMD,CEEMD 和 NEEMD 各项指标比较

方法	添加噪声幅值：α	添加噪声个数：Ne	计算耗时/ s	正交性指标[10]
EEMD	0.2	100	**21.01**	0.21
CEEMD	0.2	100(50×2)	40.23	0.26
NCEEMD	0.2	100	25.14	0.01

3 讨论

从表 1 可知,在绝大多数情况下,NCEEMD 算法提取的 EDR 与原始呼吸的各种误差均最小(见表 1 中加粗部分),基于 NCEEMD 的 EDR 算法具有更高的准确性。以 MBPD 中前 60 秒的 slp01a 数据为例,对原始心电信号做 NCEEMD 分解,得到不同的 IMF 分量,如图 3 所示。

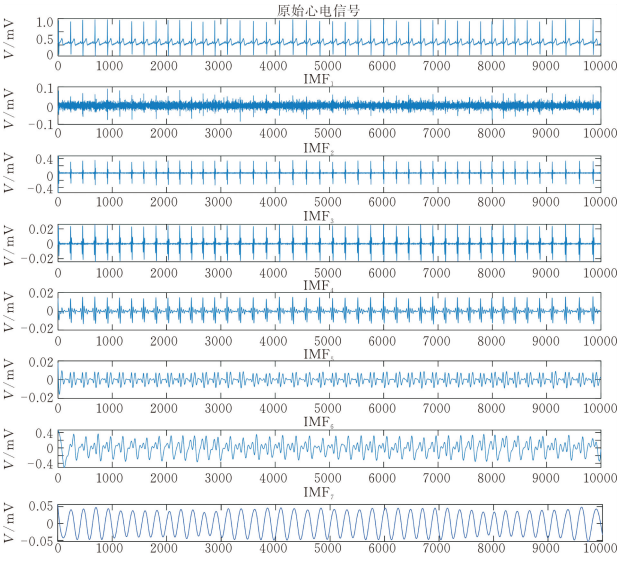

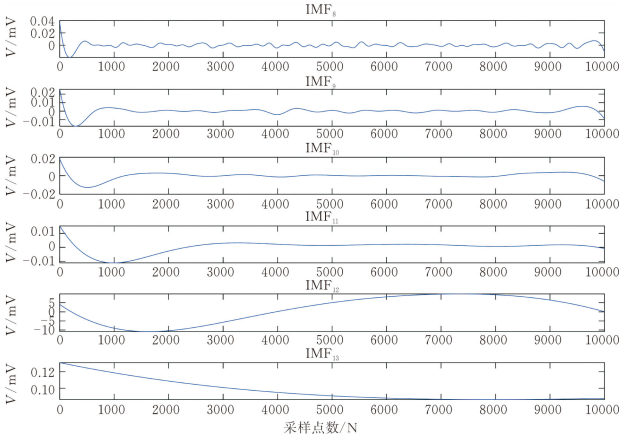

图 3 NCEEMD 算法分解细节图

分别对 EMD、EEMD、CEEMD 和 NCEEMD 的分解得到不同的 IMF 分量,由 FFT 计算并筛选出呼吸频段内的 IMF(0.07～0.75 Hz),如表 3 所示。

表 3 IMF 分量频率

方法	频率/Hz					
	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10
EMD	**0.45**	**0.3**	**0.15**	**0.075**	0.025	/
EEMD	3.3	1.125	1.125	**0.4**	**0.15**	**0.075**
CEEMD	3.3	1.125	1.125	**0.4**	**0.15**	**0.075**
NCEEMD	3.3	1.125	1.125	**0.325**	**0.2**	**0.1**

计算呼吸频段内的 IMF 与实测呼吸信号的 P 值、R 值,如表 4、表 5 所示。在 P 值<0.05 具有统计学意义的情况下,在分量 IMF7 至 IMF10 中,NCEEMD 与原始呼吸的相关系数 R 值最大(见表 5 中加粗部分),表示本算法分解的 IMF 分量与原始呼吸的相关性最强。在不同幅值噪声系数 α 下,对比 CEEMD 分解算法,计算 NCEEMD-IMF 与原

始呼吸的相关系数增量的变化情况，如图 4 所示。

表 4　不同 IMF 分量与原始呼吸的 P 值对比

方法	显著性 P 值					
	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10
EMD	0.2033	0	0	0	0.5684	/
EEMD	0.5411	0.4435	0.0252	0	0	0
CEEMD	0.4646	0.1196	0.6107	0	0	0
NCEEMD	0.5412	0.4385	0.0234	0	0	0

表 5　不同 IMF 分量与原始呼吸的 R 值对比

方法	相关系数 R 值					
	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10
EMD	0.0127	0.0826	0.0889	0.0416	0.0057	/
EEMD	−0.0061	−0.0077	−0.0067	0.1628	0.2198	0.0787
CEEMD	0.0073	0.0156	−0.0051	0.1413	0.1945	−0.174
NCEEMD	0.0111	−0.0136	**0.1635**	**0.2261**	**0.2338**	**0.0876**

从图 4 可以看到，在噪声幅值系数 $\alpha=0.55$ 下，各分量的相关性均有所提升且 IMF8 分量的相关系数增量最大。IMF8 分量的频率为 0.4 Hz，也与原始呼吸频率 0.3 Hz 最为接近，表明本算法分解的分量更突出呼吸特征信息。在其他不同的噪声系数下，IMF5 和 IMF10 的相关性有所下降，可能的原因是 IMF5 分量携带心电信号的特征信息，IMF10 分量携带部分基线漂移的特征信息，使得其与呼吸的相关性减弱，表现为相关系数增量减小。基于 NCEEMD 的 EDR 算法在噪声幅值系数的确定上具有更好的自适应性。

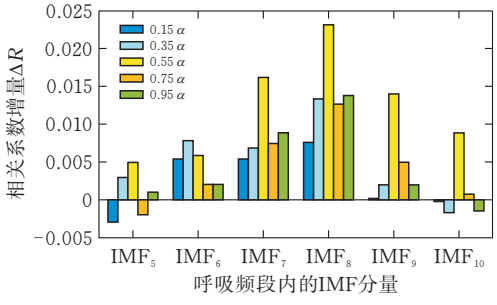

图 4　不同噪声系数下 IMF 相关系数增量

4　结论

本文提出了一种基于复合经验模态分解的呼吸提取算法，用于从心电信号中导出呼吸信号，其不需对心电数据进行预处理，即可获得良好的 EDR 信号。经实验对比分析，NCEEMD 分解比 EMD 分解得到了更多的细节尺度，比 EEMD 和 CEEMD 分解得到的 IMF 分量中残留噪声更少。本文提出的基于 NCEEMD 的呼吸提取方法与 CEEMD 算法对比，平均 MSE 减小 3.95%、平均 RMSE 减小 2.74%、平均 MAE 减小 2.52%，同时计算耗时减少 37.5%，得到的 IMF 分解分量的正交性更好。本算法得到的 EDR 信号与商用仪器同步记录的呼吸信号具有较高的相似性，利用心电信号即可导出呼吸，可用于睡眠呼吸暂停检测和基于家庭的呼吸监测等不同应用。

[参　考　文　献]

[1] Qi M S, Xing L, Chao W, et al. Cardiopulmonary coupling analysis predicts early treatment response in depressed patients: A pilot study[J]. Psychiatry Research, 2019, 276: 6-11.

[2] Hietakoste S, Armanac-Julian P, Karhu T, et al. Acute cardiorespiratory coupling impairment in worsening sleep apnea-related intermittent hypoxemia[J]. IEEE Trans Biomed Eng, 2023, 99: 1-9.

[3] Maier C, Wenz H, Dickhaus H. Robust detection of sleep apnea from Holter ECGs. Joint assessment of modulations in QRS amplitude and respiratory myogram interference[J]. Methods Inf Med, 2014, 53(04): 303-307.

[4] 韩宇，张兴敢. 基于改进变分模态分解的生命体征检测[J]. 南京大学学报(自然科学)，2022，8：680-688.

[5] 杨俊，黄俊，陶威. 基于 FMCW 雷达的自适应生命信号提取方法[J]. 雷达科学与技术，2022，20：187-194.

[6] Gao Y, Yan H, Xu Z, et al. A principal component analysis based data fusion method for ECG-derived respiration from single-lead ECG[J]. Australas Phys Eng Sci Med, 2018, 41(01): 59-67.

[7] Zhao F, Xu F Y, Cai L. Application of KPCA and AdaBoost algorithm in classification of functional magnetic resonance imaging of Alzheimer's disease[J]. Neural Computing and Applications, 2020(10): 5329-5338.

[8] Labate D, Foresta F L, Occhiuto G, et al. Emirical mode decomposition vs. wavelet decomposition for the extraction of respiratory signal from single-channel ECG: A comparison[J]. IEEE Sensors Journal, 2013, 13(07): 2666-2674.

[9] Wu Z, Huang N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1: 1-41.

[10] Ying S, Jian Q, Li P, et al. A novel non-contact heart rate measurement method based on EEMD combined with FastICA[J]. Physiol Meas, 2023, 44(05): 055002.

[11] Yeh J R, Shieh J S, Huang N E. Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method[J]. Advances in Adaptive Data Analysis, 2010, 2(02): 135-156.

[12] 杨克元，邓忠文，陈文军. 基于互补集合经验模态分解结合希尔伯特变换的光频扫描干涉信号相位提取方法[J]. 中国光学(中英文)，2023，16(03)：682-700.

[13] Ichimaru Y, Moody G B. Development of the polysomnographic database on CD-ROM[EB/OL]. Psychiatry and Clinical Neurosciences 1999, 53: 175-177. https://physionet.org/content/slpdb/1.0.0/.

(下转第 29 页)

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]