

互补集合经验模式分解与奇异值能量谱在 风电齿轮故障识别中的应用

张文斌, 江 洁, 俞利宾, 郭德伟, 闵 洁, 普亚松

(红河学院工学院, 云南省高校高原机械性能分析与优化重点实验室, 蒙自 661199)

摘 要: 针对风电机组齿轮系统故障模式的有效识别问题, 提出一种互补集合经验模式分解(CEEMD)与奇异值能量谱相结合的故障识别方法。利用CEEMD将齿轮非平稳信号分解为有限个平稳的本征模态函数, 并将其组成初始特征向量矩阵, 对矩阵进行奇异值分解并求出风电齿轮不同工况下的奇异值能量谱分布, 以奇异值能量谱为元素构造特征向量, 通过计算不同工况振动信号的灰色关联度来判断齿轮的故障类型。实例表明, 该方法能有效应用于风电机组齿轮系统的故障诊断。

关键词: 故障分析; 齿轮; 信号处理; 互补集合经验模式分解; 奇异值能量谱

中图分类号: TN911

文献标志码: A

0 引 言

齿轮箱是风力发电机传动链上的重要部件, 是连接主轴和发电机的重要枢纽。齿轮箱的故障率在风力发电机各主要部件的故障统计中居高不下, 据统计, 齿轮箱是机组中故障发生率最高的部件, 故障百分比已超过60%, 由于风电机组安装在几十米高的塔架上, 齿轮箱一旦发生问题维修不便。因此, 加强对风电机组齿轮箱的监测和故障诊断, 对降低风电场维护费用, 提高风电场运行经济效益具有重要意义^[1-2]。现场采集到的风电齿轮箱故障信号多表现为非线性、非平稳特征。在非平稳信号的分析方法中, 短时傅里叶变换、Wigner-Ville分布、小波变换和经验模式分解(EMD)均存在一定的局限性。Wu等^[3-4]提出集合经验模式分解(EEMD)方法, 可有效解决EMD模态混叠现象。而Yeh等^[5]对EEMD方法进行改进, 提出互补集合经验模式分解(CEEMD)方法, 该方法采用加入正、负成对形式的白噪声, 这样就能更好地消除重构信号的残余辅助噪声, 而且加入噪声集合的次数相比EEMD方法更低, 极大地提高了计算效率, 更适合处理风电齿轮系统的非平稳振动信号。

在确定合适的特征提取方法后, 如何有效选择故障特征参数就显得很关键。由文献[6]可知, 信号的能量可表示为信号所有奇异值平方的总和, 因此, 可将信号

奇异值平方所构成的序列定义为奇异值能量谱, 这样就可建立奇异值与信号能量分布的联系。

但是, 在奇异值求取过程中需要人为确定嵌入时间和延时常数, 常规的方法是将原始信号重构为Hankel矩阵^[7-9]或是将原始信号进行分段来进行相空间重构。本文在前期深入研究集合经验模式分解的基础上^[10], 尝试将CEEMD引入奇异值分解中, 首先将原始信号进行CEEMD分解, 由分解得到的各阶本征模态函数(IMF)组成一个矩阵, 这样就可克服奇异值分解相空间重构矩阵的行列数难以确定的问题, 然后对此矩阵进行奇异值分解, 并求出奇异值能量谱, 最后计算以奇异值能量谱为元素的特征向量的灰色关联度来进行故障识别和分类。通过在风电齿轮箱模拟实验平台上对风电齿轮系统正常、齿面轻度磨损、齿面中度磨损和断齿等工况进行试验, 结果表明该方法能有效用于风电齿轮系统典型故障的识别。

1 互补集合经验模式分解

互补集合经验模式分解通过叠加具有频率均匀分布统计特性的正、负成对的高斯白噪声, 使信号在不同尺度上具有连续性, 使分解得到的IMF分量更能反映信号的本质。CEEMD分解流程如下^[5]:

1) 向原始输入信号中加入正、负成对的随机高斯白

收稿日期: 2018-09-25

基金项目: 国家自然科学基金(51769007); 云南省中青年学术带头人后备人才(2014HB026); 云南省高校重点实验室建设计划(2018ZD) 022

通信作者: 张文斌(1981—), 男, 博士、教授, 主要从事旋转机械模式识别与智能诊断方面的研究。190322507@qq.com

噪声序列。

2) 将加入白噪声的信号进行 EMD 分解, 得到各 IMF 分量。

3) 重复执行步骤 1) 和 2), 每次加入不同的成对的正、负白噪声序列。

4) 将多次 EMD 分解得到的对应的 IMF 分量进行总体平均运算, 作为最终的 IMF 分量。

通过 CEEMD 分解可把任何一个输入信号分解为若干个 IMF 和一个残余分量之和, 通过在原始输入信号中叠加正、负成对的随机白噪声, 可改变一次 EMD 分解的特征尺度, 通过进行多次 EMD 分解, 相当于从多个特征尺度来提取原始信号的本质, 而且各 IMF 分量代表信号从高到低的不同频段成分, 每个频段所包含的频率成分不同, 具有良好的自适应性, 而且加入符号相反的白噪声, 可减小重构误差, 最大限度地中和所添加的辅助白噪声, 实现对 EEMD 方法的改进。

2 基于 CEEMD 的奇异值能量谱

由 CEEMD 算法原理可知, CEEMD 对离散信号 $x(t)$ ($t=1, 2, \dots, N$ 为观测的时间序列, N 为采样点数) 进行自适应分解, 可得到 k 个 IMF 分量和一个残余分量 R_n , IMF 分量分别代表原始信号从高到低的不同频率成分, 不同的频率段包含了信号的不同故障信息, 因此可将这 k 个 IMF 分量组成初始特征向量矩阵 B , 即:

$$B = [\text{IMF}_1 \text{ IMF}_2 \cdots \text{IMF}_k]^T \quad (1)$$

然后对矩阵 B 进行奇异值分解, 得到初始特征向量矩阵 B 的奇异值为:

$$\sigma = \{\sigma_1, \sigma_2, \dots, \sigma_k\} \quad (2)$$

根据文献[6]可知, 信号能量可表示为:

$$E = \sum_{i=1}^k \sigma_i^2 \quad (3)$$

当风电齿轮系统发生故障时, 故障信号与正常信号相比, 相同频带内的能量会有较大差别, 在这些频带内信号的能量包含了丰富的故障信息, 某个或某几个频带内信号能量的改变即代表了一种故障, 因此可根据风电齿轮系统振动信号的频带能量的变化来进行故障分析。由于信号的奇异值描述了信号在采样时间内各频率段的故障特征, 而风电齿轮在各种工况下的特征主要表现为各不同频率段内奇异值的差异, 因此各频率段内奇异值的大小可反映风电齿轮各种运行工况的差别。

由此可定义观测时间序列的奇异值能量谱为:

$$q = \{q_1, q_2, \dots, q_k\} \quad (4)$$

式中, q_i ——第 i 个分量的信号能量在整个信号能量中

所占的比重, 且满足 $\sum_{i=1}^k q_i = 1$, $q_i = \frac{\sigma_i^2}{\sum_{i=1}^k \sigma_i^2}$ 。因此, 可用奇

异值能量谱分布来描述信号在不同故障状态下的能量分布。

3 风电齿轮故障识别原理

1) 在风电齿轮系统正常、齿面轻度磨损、齿面中度磨损和断齿故障状态下, 按一定的采样频率分别进行 N 次采样, 共得到 $4N$ 个数据样本。

2) 对风电齿轮振动信号进行 CEEMD 分解, 得到若干个 IMF 分量;


3) 根据式(1)构造奇异值分解矩阵进行奇异值分解, 并由式(4)求出反映每个样本信号故障特征的奇异值能量谱;

4) 求出同类状态下 N 个训练样本的奇异值能量谱向量 q_j 的平均值 \bar{q}_j 作为标准故障模式, 其中, $j=1, 2, 3, 4$ 分别对应风电齿轮正常、齿面轻度磨损、齿面中度磨损和断齿故障 4 种状态;

5) 计算待检测信号的奇异值能量谱向量 q_s 与各状态下的标准故障模式 \bar{q}_j 的灰色关联度, 与待识别样本灰色关联度最大的标准故障模式即被认为是待识别样本的故障类型。灰色关联度识别的详细过程可参见作者前期的研究成果^[11]。

4 实例分析

利用风电齿轮箱模拟实验平台上采集到的齿轮系统正常、齿面轻度磨损、齿面中度磨损和断齿 4 种工况下的齿轮数据, 以便测试所提出的算法在齿轮故障识别中的实际效果。被试齿轮转频为 $f_r = 23.6 \text{ Hz}$, 啮合频率为 $f_s = 686 \text{ Hz}$, 振动信号的采样频率为 16384 Hz ^[12-14]。对齿轮 4 种工况分别采样, 各取 20 个样本, 采用 CEEMD 对信号进行分解, 以齿面轻度磨损故障信号为例, 该信号经过 CEEMD 分解后得到 11 个 IMF 分量和 1 个残余分量, 如图 1 所示, a 代表加速度。




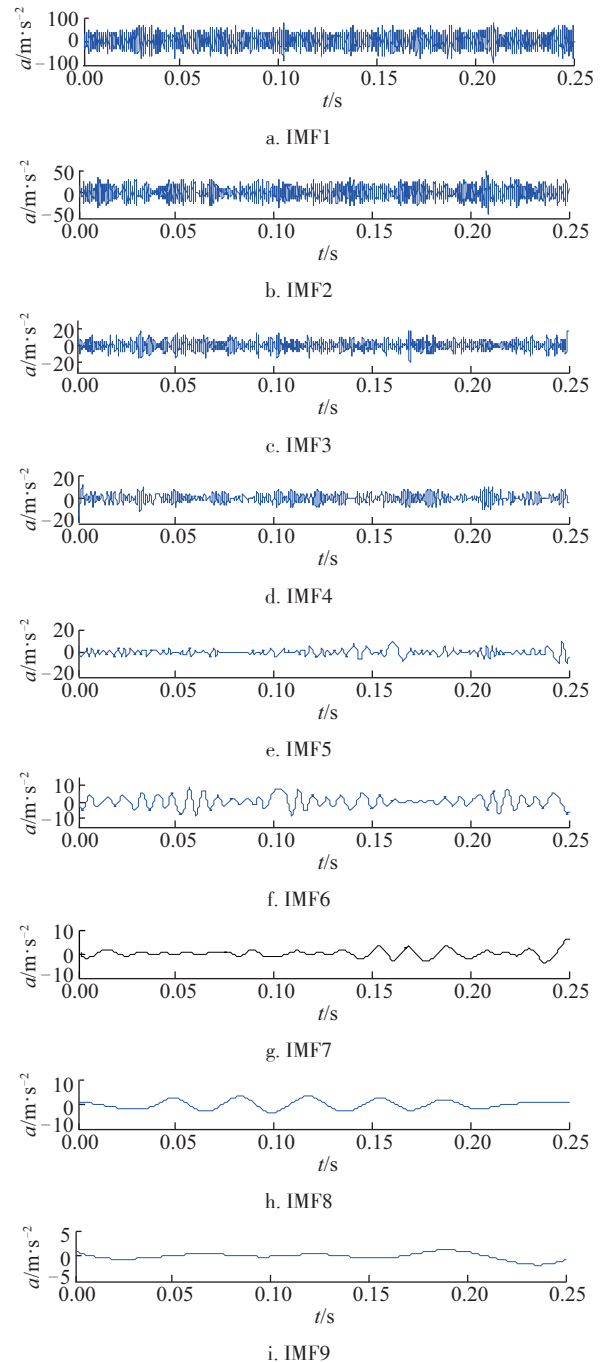


图1 齿面轻度磨损故障信号的CEEMD分解结果

Fig. 1 CEEMD decomposition results of slight-worn signal on tooth surface

从图1可知,CEEMD把非平稳的齿轮故障信号分

解为若干个平稳的IMF分量,各个IMF分量含有不同的时间特征尺度和能量分布。为便于比较,图2为采用EMD方法对同一齿面轻度磨损信号进行自适应分解的结果。图1的第5个IMF分量和图2的第5个IMF分量,在同等坐标范围内,明显前者的模态混叠程度轻。图1的第6~8个IMF分量和图2的6~8个IMF分量,从波形上看较类似,但两者幅值的波动范围不同,幅值波动小的模态混叠程度明显较轻,这也充分说明了CEEMD在添加了正、负成对白噪声后,能有效抑制模态混叠现象。








图2 齿面轻度磨损故障信号的EMD分解结果

Fig. 2 EMD decomposition results of slight-worn signal on tooth surface


现随机抽取每种状态的 10 个样本为训练样本,根据故障特征提取步骤,可求得各状态下相应的奇异值能量谱分布,如图 3 所示,图中的值为 10 个训练样本所求奇异值能量谱的平均值,经过多次实验发现,信号的奇异值能量谱向量中前 6 阶所占的比重较大,表明信号经过奇异值分解后,有用信号集中在前 6 阶奇异值,而其余奇异值的比重较小,这也反映了奇异值分解能实现有用信号与噪声的分离。因此取奇异值能量谱向量的前 6 阶作为特征向量进行分类识别。从图 3 可看出,不同齿轮故障状态的奇异值能量谱具有明显差异,风电齿轮系统在正常情况下,振动信号以啮合频率、转频为主,能量集中在很少的模式,因此信号经过 CEEMD 分解后,由各 IMF 构成的矩阵经过奇异值分解后得到的第一阶奇异值较大,其他阶次较小;随着齿轮故障的出现,振动信号中出现了更丰富的频率成分,因此除了第 1 阶奇异值外,其他阶次的奇异值也逐渐增大;断齿故障时,振动信号以转频及其高次谐波和啮合频率为主,但其主要振动模式的频带范围较磨损故障窄,因此第 1 阶奇异值所




a. 正常



b. 齿面轻度磨损



c. 齿面中度磨损



d. 断齿

图3 风电齿轮系统4种工况前6阶奇异值能量谱分布图
Fig. 3 Distribution map of first six order singular value energy spectrum of wind power gear system under four working conditions

表现出的能量比磨损故障更集中,其值介于正常状态和磨损故障之间。而且由于在分解中添加正、负成对的白噪声,可以更好地消除重构信号的残余辅助噪声,极大地提高计算效率。

限于篇幅,从每种状态采样得到的剩余 10 个样本中随机抽取 5 个样本作为待检测样本,表 1 给出了待测样本计算得到的奇异值能量谱。

表1 风电齿轮系统4种工况下前6阶奇异值能量谱
Table 1 First six order singular value energy spectrum of wind power gear system under four working conditions

工况	序号	q_1	q_2	q_3	q_4	q_5	q_6
正常	1	0.9458	0.0399	0.0069	0.0029	0.0022	0.0010
	2	0.9433	0.0436	0.0061	0.0026	0.0022	0.0011
	3	0.9439	0.0395	0.0076	0.0037	0.0023	0.0011
	4	0.9477	0.0385	0.0058	0.0033	0.0019	0.0014
	5	0.9447	0.0417	0.0062	0.0027	0.0022	0.0013
齿面轻度磨损	1	0.8362	0.1203	0.0227	0.0103	0.0047	0.0037
	2	0.8311	0.1240	0.0214	0.0112	0.0054	0.0044
	3	0.8300	0.1219	0.0220	0.0151	0.0051	0.0035
	4	0.8416	0.1208	0.0202	0.0064	0.0051	0.0038
	5	0.8346	0.1209	0.0204	0.0133	0.0052	0.0034
齿面中度磨损	1	0.7663	0.1894	0.0205	0.0127	0.0070	0.0023
	2	0.7533	0.1978	0.0204	0.0169	0.0066	0.0031
	3	0.7684	0.1884	0.0204	0.0099	0.0070	0.0031
	4	0.7586	0.2040	0.0194	0.0075	0.0055	0.0024
	5	0.7672	0.1942	0.0191	0.0093	0.0065	0.0020
断齿	1	0.8780	0.1002	0.0120	0.0042	0.0026	0.0016
	2	0.8234	0.1529	0.0139	0.0044	0.0027	0.0014
	3	0.8308	0.1435	0.0154	0.0041	0.0027	0.0016
	4	0.8703	0.1115	0.0094	0.0035	0.0024	0.0014
	5	0.8739	0.1057	0.0104	0.0037	0.0028	0.0016

最后计算待检测样本的奇异值能量谱与各状态下的标准特征向量之间的灰色关联度。根据关联度的值进行故障的模式识别。其结果如表2所示。从表2中可看出,采用灰色关联度方法对风电齿轮故障模式识别取得了理想的效果,说明灰色关联度能对小样本故障识别问题进行准确分类。对剩余的样本进行识别,也能得到正确的分类结果。

为检验灰色关联度分析在小样本分类识别中的优势,将灰色关联度分析与BP神经网络进行识别性能比较。每种工况的数据各取10个作为训练样本,再各取10个作为测试样本,表3给出了识别结果。可见在小样本情况下,灰色关联度分析具有较好的分类识别能力。

表2 待检测样本与标准故障模式的灰色关联度
Table 2 Grey relevance degree between tested samples and standard fault patterns

样本编号	正常	齿面轻度磨损	齿面中度磨损	断齿	识别结果
1	0.9527	0.4892	0.4574	0.7666	正常
2	0.9373	0.4841	0.4529	0.7587	正常
3	0.9445	0.4985	0.4677	0.8072	正常
4	0.9577	0.4904	0.4686	0.7861	正常
5	0.9666	0.4894	0.4626	0.7782	正常
6	0.4618	0.8733	0.6437	0.5819	齿面轻度磨损
7	0.4959	0.8658	0.7358	0.6024	齿面轻度磨损
8	0.5078	0.9043	0.7330	0.6153	齿面轻度磨损
9	0.5056	0.8791	0.6382	0.6311	齿面轻度磨损
10	0.4797	0.9323	0.7472	0.5968	齿面轻度磨损
11	0.4695	0.7357	0.9476	0.5402	齿面中度磨损
12	0.4932	0.7550	0.8742	0.5569	齿面中度磨损
13	0.4604	0.7170	0.8489	0.5290	齿面中度磨损
14	0.5319	0.7121	0.8377	0.6026	齿面中度磨损
15	0.5169	0.6801	0.8677	0.5927	齿面中度磨损
16	0.7555	0.5702	0.5057	0.9338	断齿
17	0.7139	0.5697	0.5577	0.8448	断齿
18	0.6922	0.5959	0.5629	0.8421	断齿
19	0.8226	0.5764	0.4972	0.9506	断齿
20	0.7605	0.5720	0.5030	0.9390	断齿

表3 灰色关联度与BP神经网络性能比较
Table 3 Comparisons of grey relevance degree and BP neural network performance

识别方法	训练 测试		测试精度/%			
	样本数量	样本数量	正常	齿面轻度磨损	齿面中度磨损	断齿
BP神经网络	10	10	100	80	90	90
灰色关联度	10	10	100	100	100	100

5 结 论

- 1)CEEMD 方法是一种自适应的信号处理方法,通过叠加正、负成对的白噪声序列,有效解决了EMD分解中存在的模态混叠现象,更利于信号特征的提取。
- 2)将CEEMD分解后的各IMF构造矩阵并进行奇异值分解,可解决奇异值分解相空间重构矩阵的行列数

难以确定的问题。

3) 由于信号的奇异值与信号的能量密切相关, 而采用 CEEMD 分解后得到的各 IMF 包含不同频带的频率信息, 因此通过求取各 IMF 的奇异值能量谱分布来对不同故障类型进行分类识别的方法是合理可行的。

[参考文献]

- [1] 章翔峰, 孙文磊, 温广瑞. 基于全矢频带能量谱的风电机组齿轮箱故障诊断方法研究[J]. 太阳能学报, 2017, 38(8): 2090-2096.
ZHANG X F, SUN W L, WEN G R. Fault diagnosis method of wind turbine gearbox based on full vector frequency band energy spectrum[J]. Acta energiae solaris sinica, 2017, 38(8): 2090-2096.
- [2] 龙泉, 刘永前, 杨勇平. 基于粒子群优化 BP 神经网络的风电机组齿轮箱故障诊断方法[J]. 太阳能学报, 2012, 33(1): 120-125.
LONG Q, LIU Y Q, YANG Y P. Fault diagnosis method of wind turbine gearbox based on BP neural network trained by particle swarm optimization algorithm[J]. Acta energiae solaris sinica, 2012, 33(1): 120-125.
- [3] WU Z H, HUANG N E. A study of the characteristics of white noise using the empirical mode decomposition method[J]. Proceedings of the Royal Society of London A: mathematical, physical and engineering sciences, 2004, 460(2046): 1579-1611.
- [4] WU Z H, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in adaptive data analysis, 2009, 1(1): 1-41.
- [5] 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(2): 135-156.
- [6] 王林鸿, 吴波, 杜润生, 等. 用奇异谱和奇异熵研究数控工作台动态特性[J]. 振动、测试与诊断, 2012, 32(1): 116-119.
WANG L H, WU B, DU R S, et al. Dynamic characteristics of numerical control table with singular spectrum and singular entropy[J]. Journal of vibration, measurement & diagnosis, 2012, 32(1): 116-119.
- [7] 钱征文, 程礼, 李应红. 利用奇异值分解的信号降噪方法[J]. 振动、测试与诊断, 2011, 31(8): 459-463.
QIAN Z W, CHENG L, LI Y H. Noise reduction method based on singular value decomposition[J]. Journal of vibration, measurement & diagnosis, 2011, 31(8): 459-463.
- [8] 赵学智, 叶邦彦, 陈统坚. 基于小波-奇异值分解差分谱的弱故障特征提取方法[J]. 机械工程学报, 2012, 48(7): 37-48.
ZHAO X Z, YE B Y, CHEN T J. Extraction method of fault feature based on wavelet-SVD difference spectrum[J]. Journal of mechanical engineering, 2012, 48(7): 37-48.
- [9] 徐锋, 刘云飞. 基于中值滤波-奇异值分解的胶合板拉伸声发射信号降噪方法研究[J]. 振动与冲击, 2011, 30(12): 135-140.
XU F, LIU Y F. Noise reduction of acoustic emission signals in a plywood based on median filtering-singular value decomposition[J]. Journal of vibration and shock, 2011, 30(12): 135-140.
- [10] 张文斌, 苏艳萍, 普亚松, 等. 基于集合经验模式分解能量分布与灰色相似关联度的齿轮故障诊断[J]. 机械工程学报, 2014, 50(7): 70-77.
ZHANG W B, SU Y P, PU Y S, et al. Gear fault diagnosis method using ensemble empirical mode decomposition energy distribution and grey similar incidence[J]. Journal of mechanical engineering, 2014, 50(7): 70-77.
- [11] 张文斌, 郭德伟, 普亚松, 等. 谐波窗分解样本熵与灰色关联度在转子故障识别中的应用[J]. 中国电机工程学报, 2013, 33(21): 132-137.
ZHANG W B, GUO DW, PU Y S, et al. Harmonic window decomposition sample entropy and grey relation degree in rotor fault recognition[J]. Proceedings of the CSEE, 2013, 33(21): 132-137.
- [12] RAFIEE J, ARVANI F, HARIFI A, et al. Intelligent condition monitoring of a gearbox using artificial neural network[J]. Mechanical systems and signal processing, 2007, 21: 1746-1754.
- [13] RAFIEE J, TSE P W, HARIFI A, et al. A novel technique for selecting mother wavelet function using an intelligent fault diagnosis system[J]. Expert systems with applications, 2009, 36: 4862-4875.
- [14] RAFIEE J, TSE P W. Use of autocorrelation of wavelet coefficients for fault diagnosis[J]. Mechanical systems and signal processing, 2009, 23: 1554-1572.

APPLICATION OF COMPLEMENTARY ENSEMBLE EMPIRICAL MODE DECOMPOSITION AND SINGULAR VALUE ENERGY SPECTRUM IN WIND POWER GEAR FAULT IDENTIFICATION

Zhang Wenbin, Jiang Jie, Yu Libin, Guo Dewei, Min Jie, Pu Yasong

(College of Engineering, Honghe University, Key Laboratory of Mechanical Performance Analysis and Optimization of Plateau in Yunnan Province, Mengzi 661199, China)

Abstract: Aiming at the problem of effective fault pattern recognition of wind turbine gear system, a fault recognition method based on complementary ensemble empirical mode decomposition and singular value energy spectrum was proposed. The non-stationary signals of gears were decomposed into a finite number of stationary intrinsic mode functions by CEEMD, and the initial feature vector matrix was formed. The singular value decomposition of the matrix was carried out and the singular value energy spectrum distribution of wind power gears under different working conditions was obtained. The feature vector was constructed with the singular value energy spectrum as the element, and the vibration under different working conditions was calculated. The grey relevance degree of dynamic signal was used to judge the fault type of gear. The example showed that the proposed method can be effectively applied to the fault diagnosis of wind turbine gear system.

Keywords: failure analysis; gear; signal processing; complementary ensemble empirical mode decomposition (CEEMD); singular value energy spectrum