基于阶次小波包与 Markov 链模型的转子早期故障诊断

王国庆[1]，牛　伟[1]，成　娟[2]，翟正军[1]，郭阳明[1]

(1. 西北工业大学 计算机学院，陕西 西安　710072；2. 西安应用光学研究所，陕西 西安　710065)

摘　要：针对转子启动过程中振动信号表现为非平稳、非高斯特征及传统诊断方法精度不高的现状，将阶次小波包和 Markov 链模型引入转子的早期故障诊断中，提出了一种新的自适应故障诊断模型。首先利用阶次跟踪算法对瞬态振动信号重采样，得到等角度分布诊断信号；其次采用小波包对该信号分解——重构，提取其在各频带的能量特征向量，通过 Markov 链模型对其进行预测；最后通过故障实例验证，结果表明：将阶次小波包变换和 Markov 链模型相结合进行故障诊断是可行而有效的。

关　键　词：阶次跟踪，小波包，Markov 链模型，粒子群算法，故障诊断
中图分类号：TM381　　**文献标识码**：A　　**文章编号**：1000-2758(2012)03-0466-06

在故障诊断振动分析中，航空发动机转子的振动信号大多数情况下是非平稳的，传统频谱分析方法难以提取非线性、非平稳的信息[1]，对非平稳信号的分析效果不好。

故障信号与正常信号相比，在某些频带内的能量存在较大的差异，某个或某几个频带内能量的改变则表征某种故障状态[2]。小波包分析能有效地提取诊断信号中的故障特征，该特征对变工况不敏感，而阶次跟踪将时域变工况转变为角域平稳工况。因此，将小波包分析和阶次跟踪相结合会取得较好的效果。另一方面，由于转子故障现象、故障原因及故障机理之间存在大量的随机性和模糊性，预测模型需要随时间变化，Markov 链模型是建立系统运行趋势模型的有效方法，并且适合于动态中长期预测。

本文采用阶次小波包变换作为信号处理工具，提取特征参数，结合 Markov 链模型对其进行预测。考虑到传统 Markov 链模型对中长期预测准确率不高等缺点，在分析模型参数对其预测精度影响的基础上，提出了一种基于粒子群优化的二阶加权 Markov 链模型。并以某型号飞机转子系统振动信号为例，验证了该模型具有较高的准确性和有效性。

1　阶次跟踪小波包分析法

阶次跟踪技术是针对转频不稳定机械的一种专门的振动测量技术，它可将机械变速过程中产生的与转速有关的振动信号有效地分离出来，同时对与转速无关的信号起到一定的抑制作用。对于转速变化的机械，由于其按转角位置分配采样间隔，所以剔除了转速变化对频谱图的影响。阶次跟踪算法(Computed Order Tracking，COT)比传统的方法更加灵活，可产生相同或更高的精度[3]。

在实际应用中，采集的故障信号为数字信号。为了实现数字信号的小波包分解，设 $\{S_k, k \in N\}$ 为离散序列，算子为

$$\begin{cases} F_0\{S_k\}_{(j)} = \sum_{k\in N} h_{k-2j} S_k \\ F_1\{S_k\}_{(j)} = \sum_{k\in N} g_{k-2j} S_k \end{cases} \tag{1}$$

设 $\{f_p(0,0), p \in N\}$ 为原始故障信号的离散序列，小波包分解的算法为

$$\begin{cases} f_p(2n, j+1) = F_0\{f(n,j)\}_{(p)} \\ f_p(2n+1, j+1) = F_1\{f(n,j)\}_{(p)} \end{cases} \tag{2}$$

式中，p 为小波包分解各序列点；j 为小波包分解层

收稿日期：2011-06-10　　**基金项目**：国家自然科学基金(61001023，61101004)、陕西省自然科学基金(2010HQ8005)和航空科学基金(2010ZD53039)资助
作者简介：王国庆(1956—)，西北工业大学教授、博士，主要从事嵌入式系统、航空电子系统综合化技术研究。

数[4]。

分解后各频段信号的能量特征值综合了信号在时域和频域内所包含的全部故障信息,对各频段内的信号能量进行统计分析,可形成反映故障信号的特征向量[5,6]。各个频段能量可表示为

$$E_i = | S_{jk} |^2 \tag{3}$$

式中, E_i 为频带 i 的能量分量; $i = 1,2,\cdots,m, m = 2^j - 1$。选取频带上的能量分量 E_i 构造如下特征向量

$$\boldsymbol{T} = [E_1, E_2, \cdots, E_m] \tag{4}$$

对特征向量 $\boldsymbol{T}$ 归一化处理,令 $E = \sqrt{\sum_{i=1}^{m} E_i^2}$,则

$$\boldsymbol{T}' = \left[\frac{E_1}{E}, \frac{E_2}{E}, \cdots, \frac{E_m}{E}\right] \tag{5}$$

向量 $\boldsymbol{T}'$ 即为归一化小波包能量特征向量。

2　基于粒子群优化的 Markov 链模型

Markov 链可以描述一个随机变化的动态系统。它根据状态之间的转移概率来推测一个系统未来的发展变化,而转移概率反映了各随机因素的影响程度,反映了各状态之间转移的内在规律性[7]。

2.1　状态划分

为构造状态转移概率矩阵,需要进行状态的划分,即将数据序列分成若干状态。本文状态划分以小波频带的能量分量 $E_i(i = 1,2,\cdots,m)$ 的分布为基准。

首先构造每个时间段($k = 1,2,\cdots,n$) 的能量特征向量

$$\begin{cases} \boldsymbol{T}(1) = [E_1(1), E_2(1), \cdots, E_m(1)] \\ \qquad\qquad \vdots \\ \boldsymbol{T}(n) = [E_1(n), E_2(n), \cdots, E_m(n)] \end{cases} \tag{6}$$

从而得到能量时间序列

$$E_i = [E_i(1), E_i(2), \cdots, E_i(k)]$$
$$k = 1,2,\cdots,n, i = 1,2,\cdots,m \tag{7}$$

令 $E_i'(k)$ 曲线反映原始序列 $E_i(k)$ 的变化趋势,把与 $E_i'(k)$ 曲线平行的若干条形区域划分成不同的状态,即状态划分。对于一个符合 Markov 链特点的非平稳随机序列,令划分的状态数为 1,则任一个状态表达为

$$\delta_j = [\alpha_{1j}, \beta_{2j}], j = 1,2,\cdots,l \tag{8}$$

式中, α_{1j}、β_{2j} 为状态 δ_j 上下边界。

2.2　状态转移矩阵的构建

定义 1　若 M_{jg} 由状态 δ_j 经过一步转移到 δ_g 状态的原始数据样本数。M_j 为处于 δ_j 的原始数据样本数,称 $p_{jg} = M_{jg}/M_j(j,g = 1,2,\cdots,n)$ 为状态转移概率,称

$$\boldsymbol{P} = [p_{jg}] = \begin{bmatrix} p_{11} & \cdots & p_{1n} \\ \cdots & \ddots & \cdots \\ p_{n1} & \cdots & p_{nn} \end{bmatrix} \tag{9}$$

为状态转移矩阵。

状态转移矩阵 $\boldsymbol{P}$ 反映了未来状态的转向。设预测对象处于 j 状态,则考察 $P(1)$ 中第 j 行,若 $\max_g p_{jg} = p_{jh}$,则认为下一时刻系统最有可能由 j 状态转向 h 状态。

对转子研究发现,故障发生时刻的系统状态与其邻近的状态关系非常密切,尤其是最临近的时刻。因此,为了提高能量序列的预测准确率,本文采用二阶加权组合模型,充分利用系统状态信息,见(10) 式

$$E_i(k) = w_1 E_i(k-1) \times P^1 + (1 - w_1) E_i(k-2) \times P^2 \tag{10}$$

式中, $E_i(k)$ 为频带 i 在第 k 个时间段的能量分量; $\boldsymbol{P}$ 为能量序列的状态转移矩阵; w_1 为权值因子,$0 \leqslant w_1 \leqslant 1$。

2.3　确定预测值

利用转移概率矩阵计算出系统未来状态 δ_j 后,也就确定了 α_{1j}、β_{2j}。因此能量序列预测值 $\hat{E}_i(k+1)$ 和相对误差 $\varepsilon(k+1)$ 为

$$\hat{E}_i(k+1) = \alpha_{1j} + w_2(\beta_{2j} - \alpha_{1j}) = (1 - w_2)\alpha_{1j} + w_2\beta_{2j}$$
$$i = 1,2,\cdots,n; \quad j = 1,2,\cdots,l \tag{11}$$

$$\varepsilon(k+1) = \frac{\hat{E}_i(k+1) - E_i(k+1)}{E_i(k+1)}$$
$$i = 1,2,\cdots,n \tag{12}$$

式中, w_2 为权值因子,$0 \leqslant w_2 \leqslant 1$。

2.4　参数优化的自适应算法

粒子群优化(PSO) 算法是基于群体的演化算法,其思想来源于人工生命和演化计算理论,由 Kennedy 和 Eberhart 于 1995 年提出[8,9]。本文利用 PSO 算法的强大全局寻优能力,在参数空间中对 Markov 链模型的参数 w_1 和 w_2 寻找最优或者近似最优值,以提高拟合和预测精度。其步骤如下:

1) 按粒子群的规模 M 生成初始群体(n_{01},n_{02},

…, n_{0M}) 、惯性权值 w、加速系数 c_1 和 c_2、最大允许迭代次数 G 以及各个粒子的初始位置和初始速度;

2) 以模型预测值和原始值误差最小为目标函数;

3) 比较每个粒子当前适应值和个体历史最好适应值,获得全局历史最好适应值;

4) 根据(13) 式和(14) 式计算各粒子的新速度和新位置

$$v_{id}(t+1) = wv_{id}(t) + c_1r_1(p_{id}(t) - x_{id}(t)) + c_2r_2(g_i(t) - x_{id}(t)) \quad (13)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (14)$$

式中, w 是惯性权重; r_1、r_2 是在(0,1) 区间上的随机数; c_1、c_2 为学习因子; p_{id} 为粒子本身所找到的最优解,即个体极值; g_i 为整个种群目前找到的最优解,全局极值。

5) 当适应值误差达到设定的误差限或迭代次数超过最大允许迭代次数时,停止搜索,输出搜索结果。否则,返回步骤 2) 继续搜索。

3 预测步骤

由此得到本文模型的预测步骤,描述如下: (其中 $k = 1,2,\cdots,n$; $i = 1,2,\cdots,m$; $j = 1,2,\cdots,l$)

1) 对各时段时域信号进行阶次跟踪小波包分解,得到不同时间段能量序列 $E_i(k)$;

2) 对各频带能量序列 $E_i(k)$ 进行状态划分 δ_j;

3) 利用各频带能量序列 $E_i(k)$ 构建状态转移矩阵,通过 PSO 算法确定 w_1 和 w_2 值,根据(11) 式建立最佳预测公式进行预测;

4) 计算求出能量序列预测值 $E_i(k+1)$,进而重构出预测能量序列,得到新的振动特征向量;

5) 将一步预测值充实到原始序列中,重复步骤 2) ~步骤 4) 。

4 实验分析

本文选择转子系统的振动信号作为状态信号。转子实验系统的一阶临界转速约为 4 500 r/min,转子运行到转速约为 2 700 r/min 时记录涡流传感器信号,采样频率为 850 Hz。转子原始振动信号波形如图 1 所示。

图 1 中信号的幅值随着输入转速的升高而逐渐增大。这说明该信号为非平稳的过程信号,不满足 FFT 对信号平稳性的要求,需要对其进行角域重采样,采样后信号波形如图 2 所示。与图 1 相比,其稳定性大为改善。

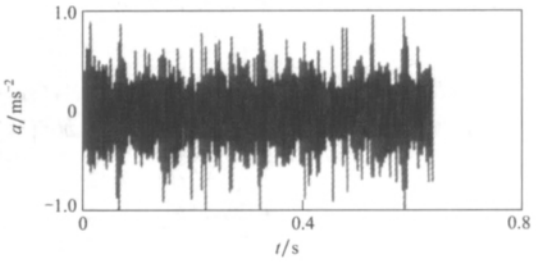


图 1 原始振动信号波形

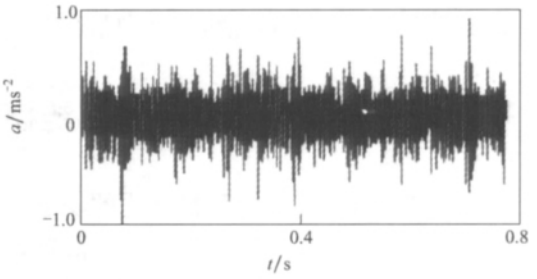


图 2 重采样后振动信号波形

对各组信号进行阶次跟踪后,选用 db1 小波对重采样后的角域故障信号进行 3 层小波包分解,重构第 3 层各结点的系数,如图 3 所示。 s_0 ~ s_7 分别代表频段 0 ~50Hz、50 ~106. 5Hz、106. 5 ~170. 5Hz、

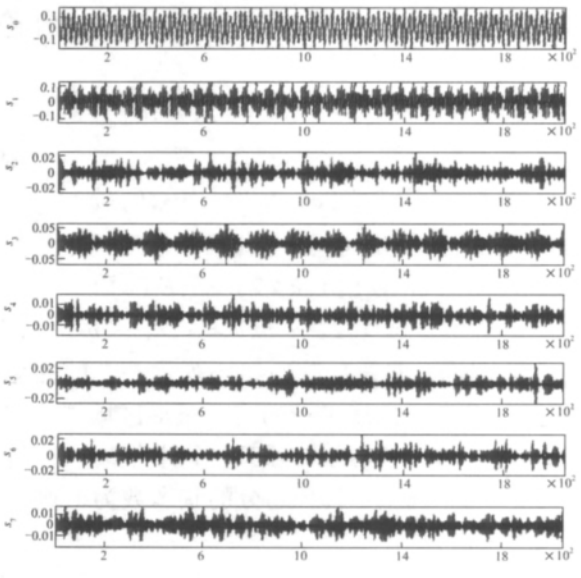


图 3 3 层小波包节点重构系数

170.5 ~ 220Hz、220 ~ 268.5Hz、268.5 ~ 331.5Hz、331.5 ~ 380.5Hz、380.5 ~ 430Hz 8 个等宽频带。可以看出,一倍频(46Hz) 在 s_0 频段内,二倍频(89Hz) 在 s_1 频段内,s_0 和 s_1 频段的振动幅值较大,而高频段的振动幅值微弱。

计算 $s_0 \sim s_7$ 上 8 个频段的能量值,并作归一化处理,可以得到正常信号分解成的 8 个频段的能量比例分布,如图 4 所示。从图中仍然可以看出 s_0 和 s_1 频段上的能量比例较大,这是因为一倍频和二倍频分别处于 s_0 和 s_1 频段内。

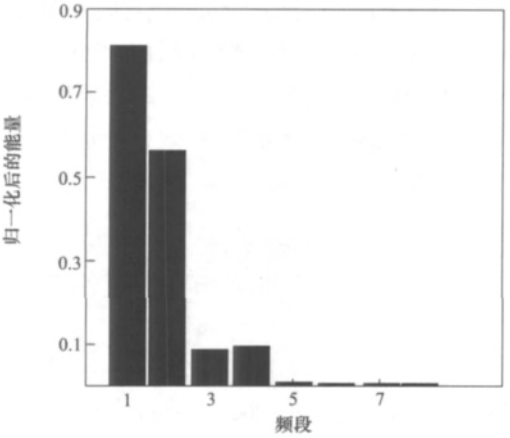


图 4　正常信号的 8 频段能量分布

对转子正常情况下振动信号进行连续 20 个小时的采样,如表 1 所示。利用表 1 中前 18 组数据建立本文模型,最后 2 组数据用于预测检验。由于各频带能量序列 $E_i(i = 1,2,\cdots,8)$ 预测方法相同,选取 E_1 为例说明本文模型的预测过程。

表 1　原始数据

No	$E_1(k)$	No	$E_1(k)$
1	31.689 75	11	30.136 69
2	31.178 92	12	31.414 32
3	31.611 43	13	30.900 72
4	29.962 99	14	31.411 83
5	30.738 58	15	30.013 34
6	30.131 14	16	30.556 01
7	31.054 13	17	30.734 06
8	29.459 87	18	30.152 15
9	29.398 76	19	30.866 37
10	30.755 76	20	30.319 23

利用表 1 中前 18 组数据进行状态划分,以 18 组数据的平均值为基准,数值每隔 0.5 为一个状态,共分为 7 个状态。计算得出一步状态转移矩阵为

$$\boldsymbol{P} = \begin{bmatrix} 0 & 0.500\,0 & 0 & 0 & 0.500\,0 & 0 & 0 \\ 0.333\,3 & 0 & 0.333\,3 & 0 & 0.333\,3 & 0 & 0 \\ 0 & 0.200\,0 & 0 & 0.600\,0 & 0 & 0.200\,0 & 0 \\ 0 & 0.250\,0 & 0.500\,0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.500\,0 & 0.500\,0 & 0 & 0 & 0 \\ 0 & 0 & 0.500\,0 & 0 & 0 & 0.500\,0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

再利用 PSO 算法优化 w_1 和 w_2 值。PSO 的参数设置为: 种群大小 $M = 200$,加速度系数 $c_1 = c_2 = 2$,惯性权值 $w = 0.25$,最大允许迭代次数 $G = 30$。得到 w_1 约为 0.899,w_2 约为 0.498 时,模型的拟合相对误差最小,建立预测模型。

利用公式(11) 进行预测,将一步预测值 $E_1(19)$ 加入到原始序列中,再建立预测模型。保持 PSO 算法参数设置不变,用 PSO 算法优化参数,得 w_1 约为 0.916,w_2 约为 0.394 19 时,模型的拟合相对误差为最小,结果如表 2 所示。

表 2　预测值及相对误差

No	$\hat{E}_1(k)$	相对误差(%)
$k = 19$	30.848 50	0.058
$k = 20$	30.348 50	0.097

同理求出其它 $\hat{E}_i(20)$ $(i = 2,3,\cdots,8)$,将实际值与预测值进行比较,其结果见表 3。

表3 频带能量实际值和预测值归一化及其相对误差

频带	实际值	归一化	预测值	归一化	相对误差(%)
1	30.319 23	0.813 87	30.297 01	0.813 49	0.073
2	20.940 01	0.562 10	20.953 83	0.562 62	0.066
3	3.720 79	0.099 88	3.717 78	0.099 82	0.081
4	3.804 46	0.102 12	3.807 43	0.102 23	0.078
5	0.928 62	0.024 93	0.960 19	0.025 78	0.034
6	0.853 14	0.022 90	0.802 80	0.021 56	0.059
7	0.195 52	0.005 25	0.180 86	0.004 86	0.075
8	0.384 53	0.010 32	0.404 53	0.010 86	0.052

由表2和表3可以看出,本文模型的短期预测结果与实际值很接近,其最大相对误差仅为0.081%,模型具有很高的预测精度,完全达到了信号预测的目的。

5 结 论

由于早期故障征兆还没有对系统造成破坏,多数情况下被强烈的背景噪声所淹没,且幅值较小,难以用一般的方法检测出。

本文结合阶次跟踪小波包和Markov链模型,利用阶次跟踪小波包提取转子的振动信号,并将转子的振动分解到不同的频带,由于各频带信号相对于整个信号而言所受的影响大大减小,随机性也大大降低,易于早期诊断分析;然后利用PSO算法建立参数最优的Markov链模型。实验结果表明,本文模型对转子早期故障诊断合理、有效,并且具有很高的预测精度。

参考文献:

[1] 冯志鹏,宋希庚,薛冬新等. 旋转机械振动故障诊断理论与技术进展综述. 振动与冲击, 2001, 20(4): 36-39
Feng Zhipeng, Song Xigeng, Xue Dongxin, et al. Survey of Vibration Fault Diagnosis of Rotational Machinery. Journal of Vibration and Shock, 2001, 20(4): 36-39 (in Chinese)

[2] Gui Z H, Han F Q. Wavelet Packet-Maximum Entropy Spectrum Estimation and Its Application in Turbine's Fault Diagnosis. Automation of Electric Power Systems, 2004, 28(2): 62-66

[3] 郭 瑜,秦树人. 旋转机械非稳定信号的伪转速跟踪阶比分析. 振动与冲击,2004, 23(1): 61-66
Guo Yu, Qin Shuren. Pseudo-Speed Tracking Order Analysis for Non-Stationary Vibration Signals of Rotating Machinery. Journal of Vibration and Shock, 2004, 23(1): 61-66 (in Chinese)

[4] 唐友怀,张海涛,罗 珊等. 基于小波包能量谱分析的电机故障诊断. 国外电子测量技术,2008, 27(2): 54-63
Tang Youhuai, Zhang Haitao, Luo Shan, et al. Based on Wavelet Packed Energy Spectrum Analysis of Motor Fault Diagnosis. Foreign Electronic Measurement Technology, 2008, 27(2): 54-63 (in Chinese)

[5] Gaing Z L. Wavelet-Based Neural Network for Power Disturbance Recognition and Classification. IEEE Trans on Power Delivery, 2004, 19(4): 1560-1568

[6] 朱大奇,易建雄,袁 芳. 基于小波灰色预测理论的旋转机械故障预测分析仪. 仪器仪表学报, 2008, 29(6): 1176-1181
Zhu Daqi, Yi Jianxiong, Yuan Fang. Fault Analysis Instrument for Rotating Machinery Based on Wavelet Analysis and Grey Theory. Chinese Journal of Scientific Instrument, 2008, 29(6): 1176-1181 (in Chinese)

[7] 王双成,苑森森. 基于贝叶斯网络的马尔科夫毯预测学习. 模式识别与人工智能,2004, 17(l): 17-21
Wang Shuangcheng, Yuan Sensen. Learning Markov Blanket Prediction Based on Bayesian Network. Pattern Recognition and Artificial Intelligence, 2004, 17(1): 17-21 (in Chinese)

[8] Bo Li, Koichi Wada. Communication Latency Tolerant Parallel Algorithm for Particle Swarm Optimization. Parallel Computing, 2011, 37(1): 1-10

[9] Abd-El-Wahed W F, Mousa A A, El-Shorbagy M A. Integrating Particle Swarm Optimization with Genetic Algorithms for Solving Nonlinear Optimization Problems. Journal of Computational and Applied Mathematics, 2011, 235(5): 1446-1453

A New and Effective Early Fault Diagnosis of Rotor Using Order Wavelet Packet and Markov Chain Model

Wang Guoqing[1], Niu Wei[1], Cheng Juan[2], Zhai Zhengjun[1], Guo Yangming[1]

(1. Department of Computer Science and Engineering, Northwestern Polytechnical University, Xi´an 710072, China
2. Xi´an Institute of Applied Optics, Xi´an 710065, China)

Abstract: The vibration signals at the start-up stage are non-stationary and non-Gaussian, and their diagnosis precision obtained with traditional diagnosis methods is not good. So we introduce the order wavelet packet and the Markov chain model that is based on particle swarm optimization into the early fault diagnosis of a rotor, thus proposing a new adaptive model of fault diagnosis. Sections 1 through 3 explain the early fault diagnosis mentioned in the title, which we believe is new and effective. Their core consists of: (1) we use the order tracking algorithm to carry out the resampling of the transient vibration signal, thus obtaining the diagnosis signal with equal angle distribution; (2) with the order wavelet packet, we decompose and reconstruct the equal angle distribution diagnosis signals and then extract their energy feature vectors at every frequency band; section 3 gives a five-step procedure for predicting the vectors with the Markov chain model. Section 4 conducts experiments on the early fault diagnosis of the rotor which uses vibration signals as its state signals; the experimental results, given in Tables 2 and 3, and their analysis show preliminarily that the short-term prediction results with our fault diagnosis model are very close to the actual values and have good prediction accuracy.

Key words: algorithms, diagnosis, efficiency, error analysis, experiments, feature extraction, Markov processes, models, particle swarm optimization (PSO), rotors, transfer matrix method, vibrations(mechanical), wavelet transforms; fault diagnosis, Markov chain model, order tracking algorithm, order wavelet packet, vibration signal

2011 版武书连主编的《挑大学　选专业》上有 15 所大学办工学航空航天类飞行器设计与工程本科专业

大学	西北工业	北京航空航天	南京航空航天	哈尔滨工业	复旦	北京理工	浙江	清华	沈阳航空航天	西安交通	南京理工	哈尔滨工程	大连理工	南昌航空	中北
等	A++	A+	A	B+	B	B	C+	C	C	D+	D	D	E+	E+	E
名次	1	2	3	无	无	无	无	无	无	无	无	无	无	无	无

胡沛泉

2012 年 6 月