

基于动静态组合特征参数的语音识别^{*})

王旭 韩志艳 王健 薛丽芳

(东北大学信息科学与工程学院 沈阳 110004)

摘要 基于语音信号的时变特性,本文提出了动静态特征参数结合的语音信号识别方法,首先在特征参数提取中引入了小波包变换,借助 MFCC(Mel-Frequency Cepstrum Coefficient)参数的提取方法,用小波包变换代替傅立叶变换和 Mel 滤波器组,提取了新的静态特征参数 DWPTMFCC(Discrete Wavelet Packet Transform Mel-Frequency Coefficient),然后把它与一阶 DWPTMFCC 差分参数相结合成一个向量,作为一帧语音信号的特征参数,通过试验和仿真,此参数具有很高的识别率,是一种很好的语音特征参数。并且把混沌特性引入到神经元,构成混沌神经网络,把这种神经网络用于语音识别,并与常用的 BP 神经网络识别方法进行了比较。试验结果表明,混沌神经网络的平均识别率要高于同等条件下常用的神经网络方法的识别率。

关键词 语音识别,特征参数,小波包变换,混沌神经网络

Speech Recognition Based on Dynamic and Static Feature Parameter Integration

WANG Xu HAN Zhi-yan WANG Jian XUE Li-fang

(School of Information Science & Engineering, Northeastern University, Shenyang 110004, China)

Abstract In this paper, we propose a new speech recognition method of dynamic and static feature integration. Wavelet packet transformation method is introduced to feature parameters in virtue of MFCC(Mel-Frequency Cepstrum Coefficient), then combined difference feature formed dynamic and static feature parameter integration. The simulation results indicate that the new feature parameter is better than MFCC, that is a very nice speech feature parameter. At the same time, chaotic dynamics is introduced to neurons, and a chaotic neural network(CNN) is built. And compared the performance of the network with BP neural network, the experimental results show that chaotic neural network method outperforms the BP method.

Keywords Speech recognition, Feature parameter, Wavelet packet transformation, Chaotic neural network

1 引言

从 20 世纪 60 年代人类便开始了语音识别技术的研究,其目的就是要使机器能够理解人类的自然语言。由于语言信号本身非常复杂,加上人类对语音学知识还很缺乏,因而目前的任何一种语音识别方法在识别率和实时反应速度上都很难达到人类本身的听觉效果^[1]。人工神经网络方法^[2]自 80 年代起开始应用于语音识别,为该课题注入了新的活力。然而,目前神经网络方法受到各种条件的限制,仍无法充分发挥它的优势,为了改善这一状态,本文引入了混沌神经网络,它具有响应速度快,识别精度高等优点。由于网络的输入是语音信号的特征参数,所以本文在特征参数提取上下了功夫,提出动静态特征参数相结合的方法,这样大大地提高了系统的识别率,是一种很好的特征参数。

2 语音特征参数提取

2.1 MFCC 参数提取

MFCC 参数是基于人的听觉特性利用人的听觉临界带效应^[3]。Mel 标度频率域提取出来的倒谱特征参数,提取过程如下^[4]:

(1)对输入的语音信号进行分帧、加窗,然后作离散傅立叶变换,获得频谱分布信息。

设语音信号的 DFT 为:

$$X_a(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi nk/N} \quad (0 \leq k \leq N-1) \quad (1)$$

式中 $x(n)$ 为输入的语音信号; N 表示傅立叶变换的点数。

(2)再求频谱幅度的平方,得到能量谱。

(3)将能量谱通过一组 Mel 尺度的三角形滤波器组,滤波器的个数 M 和临界带的个数相近,中心频率为 $f(m)$, $0 \leq m < M$, 本文取 $M=24$ 。

(4)计算每个滤波器组输出的对数能量:

$$s(m) = \ln \left(\sum_{k=0}^{M-1} |X_a(k)|^2 H_m(k) \right) \quad (0 \leq m < M) \quad (2)$$

其中 $H_m(k)$ 为三角滤波器的频率响应。

(5)经离散余弦变换(DCT)得到 MFCC 系数:

$$C(n) = \sum_{m=0}^{M-1} s(m) \cos(\pi n(m-0.5)/M) \quad (0 \leq m < M) \quad (3)$$

MFCC 系数个数一般取 12~16 个,通常不用 0 阶倒谱系数,因为它反映的是频谱能量,故在一般识别系统中,将 C_0 称为能量系数,而不作为倒谱系数,本文取倒谱系数个数为 12。

2.2 DWPTMFCC 参数提取

小波变换在各分析频段的恒 Q(品质因数)特性与人耳听觉对信号的加工特点相一致,生理学研究表明,对听觉起关键作用的耳蜗内基底膜,其作用相当于一组建立在薄膜振动基础上的恒 Q 带通滤波器,这一良好特性为利用小波变换提取语音特征参数奠定了基础^[5]。小波变换中的多分辨率分析其最终目的就是力求构造一个在频率上高度逼近 $L^2(R)$ 空间的正

^{*}基金项目:国家自然科学基金重大资助项目(50477015)。王旭 教授,博士生导师,主要研究方向为智能控制技术、交流调速技术、神经网络技术和生物信息技术等;韩志艳 博士研究生,主要研究方向为智能化信息检测与处理;王健 硕士研究生,主要研究方向为信号分析与故障检测;薛丽芳 博士研究生,主要研究方向为语音信号的可视化研究。

交小波基,这些频率和分辨率不同的正交小波基相当于带宽各异的带通滤波器,给定一个信号,开始对其进行多分辨分析时,得到的高频信号和低频信号分别占一半的带宽,继续进行只是对低频信号部分进行进一步分解,而高频部分不予考虑^[6]。小波包分析^[7]就是在多分辨分析的基础上,对高频信号部分进一步分解,这样根据被分析信号的特性,从而提取感兴趣频带的信息,为信号提供了一种更为精细的分析方法。

从 MFCC 参数提取的过程来看,就是把信号的频谱通过一系列的带通滤波器,求得每个滤波器输出的对数能量,再进行 DCT 变换得到的。而小波包分析,从滤波器的角度看,就是信号通过一系列不同频带范围的带通滤波器,从而获得信号在各频带内的信息。因此 MEL 滤波器组与小波包分析的作用在某种意义上可以互换,一个很自然的想法就是用小波包分析来代替 FFT 与 MEL 滤波器组,然后再进行 DCT 变换,从而得到一组新的语音特征参数 DWPTMFCC。由于人耳对语音信号的感知是非线性的, MEL 滤波器组在频带上的分布及带宽类似于临界频带的划分,这对选取小波包分析后的结点频带具有指导意义。因此,信号在经过小波包分析后,应选取与 MEL 滤波器组频带相一致的范围内的小波包系数。本文对语音信号的采样频率为 11025Hz,即最高语音频率约为 5500Hz,根据临界带的划分与 MEL 滤波器组在频带上的分布,本文选取 24 个小波包分析结点频带,进行 6 层小波包分解,小波包分解树中结点及其频带的选取如表 1 所示。

表 1 小波包分解结点选取

小波包结点	频率范围/HZ	中心频率/HZ
[6,0]	0-86	43
[6,1]	86-172	129
[6,2]	172-258	215
[6,3]	258-344	301
[6,4]	344-430	387
[6,5]	430-516	473
[6,6]	516-602	559
[6,7]	602-688	654
[5,4]	688-860	774
[5,5]	860-1032	946
[5,6]	1032-1204	1118
[5,7]	1204-1376	1290
[5,7]	1376-1548	1462
[5,9]	1548-1720	1634
[5,10]	1720-1892	1806
[5,11]	1892-2064	1978
[4,6]	2064-2408	2236
[4,7]	2408-2752	2580
[4,8]	2752-3096	2924
[4,9]	3096-3440	3268
[4,10]	3440-3784	3612
[4,11]	3784-4128	3956
[3,6]	4128-4816	4472
[3,7]	4816-5504	5160

DWPTMFCC 提取计算过程如下:

(1) 预加重,减少工频干扰,提升高频信号,使用一阶数字滤波器。然后进行分帧,并通过端点检测(通过短时能量与过零率)提取出有用帧,加 Hamming 窗,减小 Gibbs 效应。

$$w(n) = 0.54 - 0.46 \cos 2\pi n / (N-1), 0 \leq n \leq N-1 \quad (4)$$

(2) 对语音信号进行小波包分析,计算所选结点频带内信号的对数能量。

$$S_k = \ln \sum \{WPT[x(n)]\}^2, k=1, 2, \dots, K \quad (5)$$

其中, $K=24$ 为所选频带的数目。

(3) 将上述 S_k 经 DCT 得到 DWPTMFCC 参数。

$$C(i) = \sum_{k=1}^K S_k \cos \left[\frac{\pi i(k-1/2)}{K} \right], 0 \leq k \leq K, i=1, 2, \dots, P \quad (6)$$

其中, $P=12$ 是 DWPTMFCC 的维数。

2.3 动态特征参数提取

除 LPCC, MFCC 和 PLP 参数外,可用于语音识别的语音参数还有语音短时谱、共振峰频率及带宽、鼻音联合特征、谱相关特征、音调特征、K-L 特征等等,这些都反映语音的静态特征,语音信号的动态特征是指从连续几帧语音中提取的特征参数,它们主要反映了讲话者语音的瞬变特征。动态特征可以通过静态特征的差分谱来获取,动态特征和静态特征相结合,能有效提高系统的性能。

设 $C_m(t)$ 是语音信号 t 时刻的 m 维倒谱系数,则短时语音谱的对数可用下式表示:

$$\log |S(\omega, t)| = \sum_{m=-\infty}^{\infty} C_m(t) e^{-j\omega m} \quad (7)$$

短时谱随时间的变化表示为:

$$\frac{\partial \log |S(\omega, t)|}{\partial t} = \sum_{m=-\infty}^{\infty} \left(\frac{\partial C_m(t)}{\partial t} \right) e^{-j\omega m} \quad (8)$$

由于 $\frac{\partial C_m(t)}{\partial t}$ 一般只能通过有限差分来近似,可利用在有限长度函数内的多项式来拟合倒谱系数的微分。一阶正交多项式系数可表示为:

$$\frac{\partial C_m(t)}{\partial t} \approx \Delta C_m(t) = \frac{\sum_{k=-K}^K h_k C_m(t+k)}{\sum_{k=-K}^K h_k k^2} \quad (9)$$

式中, h_k 是宽度为 $2K+1$ 帧的窗,一般可采用 Hamming 窗, $C_m(t)$ 是 t 时刻的倒谱系数。这种 Δ 倒谱是连续几帧语音谱的动态特征的表示形式, K 的经验值可取为 4。

这种差分提取动态参数的算法把一些与个性特征有关的信息丢掉了,所以适于作为辅助特征来使用,若单独使用的话,其识别性能并不理想。

3 动态时间规整

将特征提取后的数据进行压缩,充分利用语音模式中的时间相关性作为识别的线索,通过动态规划方法可以对语音的时间失真加以规整,规整到特定帧数,以此作为神经网络的输入。由于篇幅有限,本文不作详解。

4 混沌神经网络结构

4.1 混沌神经元模型

本文采用的混沌神经网络是通过修改和扩展的 Nagumo-Sato model^[8],其方程如下

$$x(t+1) = f[A(t) - \alpha \sum_{d=0}^t k^d g(x(t-d)) - \theta] \quad (10)$$

其中: $x(t)$ 为离散时刻神经元的输出,其值为 $0 \sim 1$; f 为输出函数; $A(t)$ 为 t 时刻的外部激励; g 为不应性函数; α 为不应性度量参数; k 为不应性衰减参数; θ 为阈值。定义

$$y(t+1) = A(t) - \alpha \sum_{d=0}^t k^d g(x(t-d)) - \theta \quad (11)$$

可以推的差分方程:

$$y(t+1) = ky(t) - \alpha g(f(y(t))) + a(t) \quad (12)$$

式中, $a(t) = A(t) - kA(t-1) - (1-k)\theta$ 为简化模型,取 $g(x) = x, a(t) = a$, 则神经元模型可描述为

$$y(t+1) = ky(t) - \alpha f(y(t)) + a \quad (13)$$

$$x(t+1) = f(y(t+1)) \quad (14)$$

文中, f 取为 sigmoid 型函数。

4.2 多层混沌神经网络

如果考虑外部输入和内部神经元的反馈输入,上述混沌神经元可以构成神经网络(称为 CNN)。CNN 中第 i 个混沌神经元的动力学方程描述如下:

$$x_i(t+1) = f\left[\sum_{j=1}^M w_{ij} \sum_{d=0}^t k^d h_j(x_j(t-d)) + \sum_{j=1}^N v_{ij} \sum_{d=0}^t k^d I_j(t-d) - \alpha \sum_{d=0}^t k^d g_i(x_i(t-d) - \theta_i)\right] \quad (15)$$

其中, $x_i(t+1)$ 为 $t+1$ 时刻第 i 个混沌神经元的输出; M 为混沌神经元的个数; w_{ij} 为第 j 个混沌神经元到第 i 个神经元的联接权; N 为混沌神经元外部输入的个数; v_{ij} 为第 j 个外部输入到第 i 个神经元的联接权; I_j 为第 j 个外部输入; h_j 为转移函数。

因此, 上两式可描述网络中一个混沌神经元的动力学行为, 网络中第 i 个混沌神经元如图 1 所示。




图 1 第 i 个混沌神经元




图 2 MLCNN 结构

基于以上的混沌神经元模型, 本文设计了一种能适应像短时语音信号一类时间序列 CNN, 如图 2 所示。网络在隐层和输出层含有混沌神经元, 即每层的神经元内部存在相互反馈输入, 而整个网络则通过每层之间单向的联接权构成一个多层的前馈网络。

4.3 CNN 学习算法

针对语音识别问题, CNN 的作用就是当输入一个随时间变化的语音序列模式时, 得到这一模式类别的平稳输出。由静态神经元组成的多层前馈神经网络的误差反向传播 (BP)^[9] 算法已经非常成熟, 但一般的 BP 算法不能直接应用于 CNN 的权值学习, 这是因为混沌神经元中含有自反馈输入, 因而无法直接计算其梯度。本文利用变分的方法^[10], 把 BP 算法推广到 CNN 的学习。不失一般性, 先考虑连续情形, 那么 CNN 输出层中第 i 个神经元的动力学方程可以写成:

$$y_i(t+1) = -y_i(t) + \sum_{j=1}^M w_{ij} x_j(t) + \sum_{j=1}^N v_{ij} A_j(t) - \alpha x_i(t) + k y_i(t) \quad (16)$$

$$x_i(t) = f(y_i(t)) \quad (17)$$

其中, $A_j(t)$ 为 t 时刻第 j 个外部输入; k, α 分别为神经元的参数。假设输入一特定类别的语音序列, 则在 $[t_0, t_1]$ 时间间隔内, 总误差代价函数为

$$E = \frac{1}{2} \int_{t_0}^{t_1} \sum_{i=1}^M (x_i(t) - d_i(t))^2 dt \quad (18)$$

式中: $x_i(t)$ 为网络的实际输出; $d_i(t)$ 为教师信号。采用最速梯度下降法来更新权值:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}}, \Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}} \quad (19)$$

其中, $\eta > 0$, 成为学习率, 为计算 $\partial E / \partial w_{ij}$ 和 $\partial E / \partial v_{ij}$, 使用变分法, 引入 Lagrange 乘子 $L_i(t)$, 则

$$E = \int_{t_0}^{t_1} \left\{ \left[\frac{1}{2} \sum_{i=1}^M (x_i(t) - d_i(t))^2 - \sum_{i=1}^M L_i(t) [y_i(t+1) + \right. \right.$$

$$\left. (1-k)y_i(t) - \sum_{j=1}^M w_{ij} x_j(t) - \sum_{j=1}^N v_{ij} A_j(t) + \alpha x_i(t) \right] \} dt \quad (20)$$

对 E 取变分, 由 Euler 方程得到:

$$L_i(t+1) = (1-k)L_i(t) - \sum_{j=1}^M L_j(t) w_{ij} f'(y_i(t)) + \alpha f'(y_i(t)) L_i(t) - (x_i(t) - d_i(t)) f'(y_i(t)) \quad (21)$$

当上面的方程满足边界条件: $\delta x_i(t_0) = 0, L_i(t_1) = 0$ 时, 可以推导出:

$$\frac{\partial E}{\partial w_{ij}} = \int_{t_0}^{t_1} L_i(t) x_j(t) dt, \frac{\partial E}{\partial v_{ij}} = \int_{t_0}^{t_1} L_i(t) A_j(t) dt \quad (22)$$

采用离散时间形式, CNN 输出层的学习算法描述如下:

(1) 给定初始条件 $x_i(0)$ 和外部输入 (上一层的输出) $A_j(t)$, 初始化权值 w_{ij} 和 v_{ij} ;

(2) 计算 $0 \sim T$ 时间内网络的实际输出 $x_i(t)$:

$$y_i(t+1) = \sum_{j=1}^M w_{ij} x_j(t) + \sum_{j=1}^N v_{ij} A_j(t) - \alpha x_i(t) + k y_i(t) \quad (23)$$

$$x_i(t) = f(y_i(t)) \quad (24)$$

(3) 在给定教师信号 $d_i(t)$ 下, 依据

$$L_i(t-1) = k L_i(t) + \sum_{j=1}^M L_j(t) w_{ij} f'(y_i(t)) - \alpha f'(y_i(t)) L_i(t) + (x_i(t) - d_i(t)) f'(y_i(t)) \quad (25)$$

后向计算 Lagrange 乘子。

(4) 修改权值:

$$\Delta w_{ij} = -\eta \sum_{t=0}^T L_i(t) x_j(t), \Delta v_{ij} = -\eta \sum_{t=0}^T L_i(t) A_j(t) \quad (26)$$

上面用变分的方法得出了网络输出层的权值训练算法, 这是整个 MLCNN 学习算法的基本单元和重要组成部分, 因为其他各层可以按照输出层类似的方法来训练权值。

结束语 实验中选用“0~9”10 个汉语数字音作为待识别语音, 试验数据取自 5 名学生在实验室环境下的录音, 每人每个数字各发音 40 次, 其中 30 次作为训练样本, 另外 10 次作为测试样本。采样频率为 11.025kHz, 量化精度为 16bit, 语音的帧长取为 256 个采样点, 帧移为 80 个采样点, 分帧后的语音进行端点检测, 然后提取 12 阶 MFCC 系数和动静态组合系数作为语音识别的特征。本文共设计了两个神经网络, 分别对 MFCC 系数和动静态组合系数进行训练, 一个神经网络的输入层为 48 个, 另一个输入层为 52 个, 输出层都为 10 个, 隐层的神经元个数通过仿真试验来确定, 通过试验选择隐含层数为 60 个。表 2 为所做仿真试验的结果。

表 2 试验结果

测试样本 序号	CNN				BP			
	MFCC		DWPTMFCC		MFCC		DWPTMFCC	
	正识	误识	正识	误识	正识	误识	正识	误识
0	46	4	49	1	44	6	47	3
1	48	2	50	0	45	5	47	3
2	45	5	48	2	43	7	46	4
3	47	3	48	2	47	3	46	4
4	46	4	48	2	45	5	46	4
5	46	4	49	1	45	5	46	4
6	46	4	47	3	45	5	47	3
7	48	2	49	1	47	3	48	2
8	45	5	47	3	44	6	45	5
9	46	4	50	0	45	5	46	4
平均正确 识别率	92.1%		97%		90%		92.8%	

从试验结果可以看出, 用小波包提取的组合特征参数明

显优于用傅立叶变换提取的参数,然而用不同小波函数提取的参数识别率也不一样,本文通过试验 db6 效果为最佳。而且用混沌神经网络的识别率明显优于用 BP 神经网络识别率。在以后的研究中,为了进一步提高语音识别的识别率,可以考虑以下几个方面:更合理地选择较多的输入样本;更好地对输入数据进行处理,提取较好的特征参数,尤其是动静态组合的特征参数;改进神经网络的结构等等。神经网络语音识别的研究将会提高到一个全新的水平。

参考文献

[1] Juang B H. The past, present, and future of speech processing, IEEE Signal Processing Magazine, May, 1998
 [2] Ryeu J K, Chung H S. Chaotic recurrent neural networks and their application to speech recognition [J]. Neurocomputing, 1996, 13(2-4): 281/294
 [3] Rabineer L R, Juang B H. Fundamentals of speech Processing and Recognition[M]. Prentice-Hall, 1993

[4] 何强,何英. MATLAB 扩展编成[M]. 北京:清华大学出版社, 2002, 6
 [5] Rioul O, Vetterli M. Wavelets and signal processing. IEEE signal processing Mag. pps, October 1991: 14-38
 [6] Wassner H, Chollet G. New Cepstral Representation Using Wavelet Analysis an Spectral Transformation for Robust Speech Recognition// Proceedings. Acoustics, Speech, and Signal Processing. IEEE, 2001: 260-263
 [7] Torres Humberto M, Rufiner Hugo L. Automatic Speaker Identification by means of Mel Cepstrum, Wavelet and Wavelets Packets// Proceedings of the 22nd Annual EMBS international Conference. IL Chicago; July 2000: 978-981
 [8] Aihara K, Takabe T, Toyoda M. Chaotic neural networks[J]. PhysLettA, 1990(144): 333-340
 [9] 王旭,王宏,王文辉. 人工神经元网络原理与应用[M]. 沈阳:东北大学出版社, 2000: 41-46
 [10] 任晓林,等. 基于混沌神经网络的语音识别方法[M]. 上海:上海交通大学学报, 1999, 33(12): 1517-1520

(上接第 121 页)

$$P_3 = P(I_j \text{ 中 } A, B \text{ 故障, } C \text{ 无故障}) + P(I_j \text{ 中 } B, C \text{ 故障, } A \text{ 无故障}) + P(I_j \text{ 中 } A, C \text{ 故障, } B \text{ 无故障}) + P(I_j \text{ 中 } A, B, C \text{ 均故障})$$

$$= 3(1 - e^{-\lambda T})^2 e^{-\lambda T} + (1 - e^{-\lambda T})^3;$$

显然有: $P_1 + P_2 + P_3 = 1$;
 同样在最后一个检查点间隔中有:

$$\bar{\tau}_1 = P_1 t_1 + (1 - P_1)(\bar{\tau}_1 + T + t_r)$$

即

$$\bar{\tau}_1 = t_1 + \frac{1 - P_1}{P_1}(T + t_r) = T + (\frac{1}{P_1} - 1)(T + t_r) = \frac{T + t_r}{e^{-\lambda T}} - t_r \quad (6)$$

而当 $n \geq 2$ 时,根据数学期望的定义可得下列递归式:

$$\bar{\tau}_n = P_1(\bar{\tau}_{n-1} + t_1) + P_2(\bar{\tau}_{n-1} + t_2) + P_3(\bar{\tau}_n + t_3) \quad (7)$$

由(7)式解得

$$\bar{\tau}_n = \bar{\tau}_{n-1} + (t_1 + \frac{P_2}{P_1} t_2) = \bar{\tau}_{n-2} + 2(t_1 + \frac{P_2}{P_1} t_2)$$

$$= \dots$$

$$= \bar{\tau}_1 + (n-1)(t_1 + \frac{P_2}{P_1} t_2) \quad (8)$$

将(6)式代入(8)式得

$$\bar{\tau}_n = n(t_1 + \frac{P_2}{P_1} t_2) = n(\frac{T + t_r}{e^{-\lambda T}} - t_r) \quad (9)$$

4.3 性能比较

设 $\bar{\tau}_{n/f}$ 表示 TMR 系统中,进程执行期间至少发生一次故障时进程完成时间的数学期望值,则由上节计算得到的 $\bar{\tau}_n$, 有

$$\bar{\tau}_{n/f} = \frac{\bar{\tau}_n - P_1 n T}{1 - P_1} \quad (10)$$

将(5),(9)分别代入(10)就可得到两种恢复策略各自的 $\bar{\tau}_{n/f}$ 。

从图 6 中我们可看到有模块 D 参加(称为策略 2)要比没有模块 D 参加(称为策略 1)故障定位时对进程的影响小,因为在前一种方案中在模块出现故障时尽量采用向前恢复,避免向后恢复。 λ 的大小对 $\bar{\tau}_{n/f}$ 有一定影响,因为 λ 越大模块发生故障的可能性越大。图 6 是在 $\lambda=1/1000$ 和 $\lambda=1/4000$ 时 $\bar{\tau}_{n/f}$ 与设置得检查点数的关系图,从图中还可看到并非检查点设置得越多越好。

例 1: 各参数设置如下(单位:时间单位)

T_u	t_{cp}	t_r	t_{cc}	t_{ch}	t_{cr}
100	0.4	0.4	0.6	0.6	0.4

结束语 为了节约资源,文中模块 D 在 TMR 工作正常时可作它用,也可以是图 1 中负载较轻的计算机,还可被几个 TMR 共享。从本文的计算可知,在使用 TMR 提高系统可靠性的同时,通过增加少量资源可有效提高 TMR 的效率,实现高可靠、高可用和高性能。




图 6 $\bar{\tau}_{n/f}$ 与检查点个数的关系图

参考文献

[1] Yuan Youguang. The Reliability Techniques in Real-Time Systems (in Chinese). Beijing: Tsinghua University Press, September 1995
 [2] 西沃赖克 D P, 斯沃兹 R S. 可靠系统的设计理论与实践(上、下). 袁由光,曹泽翰,刘志模,等译. 科学出版社, 1988, 1993
 [3] 袁由光,陈以农. 容错与避错技术及其应用. 科学出版社, 1992.
 [4] 戴新发. 基于主动任务复制的透明容错计算研究与实现. 哈尔滨工程大学博士学位论文. 2005. 3
 [5] WANG Kuo Chen, WANG Chien-Chun. A Cost-Effective Forward Recovery Checkpointing Scheme in Multiprocessor Systems. Journal of Information Science and Engineering, 2000, 16: 65-80
 [6] Long J, Fuchs W K, Abraham J A. Forward Recovery Using Checkpointing in Parallel Systems// Proc. 19th Int'l Conf. Parallel Processing. Aug. 1990: 272-275
 [7] Ziv A, Bruck J. Analysis of Checkpointing Schemes for Multiprocessor Systems// Proc. 13th Symp. Reliable Distributed Systems. Oct. 1994: 52-61