

文章编号: 1000-8055(2012)08-1758-07

基于 RBFNN 自适应混合学习算法的航天测控系统任务可靠性分配

张新贵, 武小悦

(国防科学技术大学 信息系统与管理学院, 长沙 410073)

摘 要: 为解决执行航天测控任务的各设备存在复杂的时空关联、可视与信息关联等动态约束关系, 使得航天测控系统任务可靠性分配建模和分析极其困难, 同时模型求解效率低的问题, 提出了自适应混合学习算法的径向基神经网络建模方法。算法通过训练样本相关性矩阵的主成分分析确定网络隐含层初始节点数; 在此基础上, 利用梯度信息衰减因子改进了迭代过程中网络参数的梯度信息计算方式, 避免了学习过程早熟的不足, 且加快了迭代收敛速度。最后, 通过采集航天测控系统输入-输出数据, 将自适应混合学习算法应用于参数训练, 并给出了具体实现步骤。通过算例仿真, 表明算法在解决航天测控系统任务可靠性分配问题时具有较高泛化能力和分配结果稳定等优点。

关 键 词: 航天测控系统; 任务可靠性; 分配; 径向基神经网络; 自适应混合学习算法

中图分类号: V221; TP18

文献标志码: A

Mission reliability allocation of spaceflight TT&C system based on RBFNN adaptive hybrid learning algorithm

ZHANG Xin-gui, WU Xiao-yue

(College of Information Systems and Management,
National University of Defense Technology, Changsha 410073, China)

Abstract: Due to the existence of a complex spatial and temporal correlation, visualization and information related dynamic constraints to each equipment when they executed TT&C (telemetry tracking & commanding) mission, it was extremely difficult to model and analyze, and the solving efficiency was low. Therefore a radial basis function neural network (RBFNN) modeling method with adaptive hybrid learning (AHL) algorithm was proposed. Principal component analysis were used to determine the initial number of hidden units. Intelligence optimization algorithm combined with decaying gradient descent information was used to train parameters of RBFNN which were improved to accelerate convergence and guarantee the result to converge at the global optimum with high probability. The algorithm was employed in the offline training of model parameters by sampling the input/output data of the system, and the realization details were also provided. By simulation, it shows that the AHL has higher generalization power and can reach more optimal results in solving the mission reliability allocation of spaceflight TT&C system.

收稿日期: 2012-02-22

网络出版地址: http://www.cnki.net/kcms/detail/11.2297.V.20120830.1200.201208.1758_012.html

基金项目: 国家自然科学基金(71071159)

作者简介: 张新贵(1982—), 男, 湖南永州人, 博士生, 主要从事航天装备可靠性技术研究。

Key words: TT&C (telemetry tracking & commanding) system; mission reliability; allocation; RBFNN (radial basis function neural network); AHL (adaptive hybrid learning)

航天测控系统的任务可靠性分配是在给出系统任务可靠度的基础上,结合所执行的航天测控任务(单任务或者多任务),根据参与任务的各地面站、测量船、中继卫星、控制中心、路由等设备的时空关联、逻辑结构等动态约束关系,按照一定的分配方法把系统规定的任务可靠性指分配到各设备的过程。它直接关系到整个航天测控系统的工作效能,有着深刻的实际应用背景和研究价值^[1]。

由于航天测控系统的任务类型多样,而且同一类型的任务可能包含多个时段,现有系统的任务数在 50 个以上,而参与的设备数在 150 以上,所以参与可靠性分配的任务和设备数量巨大,当前研究中,多采用遗传算法^[2-3]、启发式算法^[4-5]、动态规划法^[6-7]等对系统资源进行分配,以得到全局最优的分配方案,而目前直接运用现有的可靠性分配算法只能解决 20 个设备以内。此外,在执行任务时,航天测控系统站点之间存在着复杂时空关联、可视与信息关联等动态约束关系,导致对系统可靠性分配进行建模和分析的极大困难,再加上它是一类高可靠度系统,导致任务可靠性预计计算时间长、计算量大,使得分配过程效率低下。

本文拟通过建立系统可靠度计算的径向基神经网络(radial basis function neural network,简称 RBFNN)元模型,降低分配搜索时间。RBFNN 元建模过程中的关键问题是结构学习和参数学习。近年来,利用智能算法指导 RBFNN 参数学习受到了充分重视,特别是遗传算法^[8]和粒子群算法^[9]得到了广泛的应用。智能算法在迭代学习过程中的早熟现象,影响了最优结构 RBFNN 的生成。本文针对航天测控系统任务可靠性分配的实际,利用样本误差的梯度信息,设计了一种自适应混合学习(adaptive hybrid learning,简称 AHL)算法来获取较优的分配结果。

1 航天测控系统任务可靠性分配描述

航天测控系统任务可靠性分配是一类复杂系统优化问题,要求在满足航天测控系统可靠性需求条件下,求解各测控资源的可靠性指标。为了有效完成可靠性分配,必须针对具体的任务建立相应的任务可靠性模型。航天测控系统执行一个任

务可划分为多个时段,只有当所有时段任务都成功时,测控业务才算成功,为此必须建立各个时段设备的逻辑关系。可靠性框图建模方法从可靠性与任务完成的角度出发,可以反映在完成任务的条件下,与任务有关的所有单元间的相互逻辑依赖关系^[5]。

由于航天测控通信系统是一个多阶段多任务系统,设备的可靠度 $R = e^{-\lambda t}$, 其中 λ 是设备的故障率, t 是任务时间,所以同一设备参加不同的业务和阶段的可靠度值是不一样的,为此要合理的对航天测控通信系统进行可靠性分配,本论文选择平均故障间隔时间(MTBF)作为测控资源的性能参数,用 M 表示,航天测控通信系统任务可靠性分配要保证分配完成后系统的可靠度必须大于设定的可靠度指标,可以建立以系统可靠度为目标函数,以可靠性指标或费用等作为约束条件的任务可靠性分配模型,如下所示:

$$\begin{aligned} R &= f[R_1(x), R_2(x), \dots, R_N(x)] = \\ &f(m_1, m_2, \dots, m_n) \\ &\text{s. t.} \\ &R > R^* \\ &U_i > m_i > L_i \end{aligned} \quad (1)$$

式中 n 为测控资源数量; N 为系统业务数量; R^* 为系统任务可靠性指标, R 为分配完成后系统的可靠度预计值, $R_l(x)$ 为第 l 个业务的可靠度要求; m_i 为第 i 个测控资源的平均故障间隔时间; 第 i 个测控资源工程实际中可靠性的上限指标为 U_i , 可靠性的下限指标为 L_i 。

对于式(1),由于航天测控系统的元素之间存在着动态约束关系,难以采用常规的数学方法进行预计求解,只能对每个可行的分配方案进行运算,计算其相应的可靠性指标,这使得航天测控系统任务可靠性分配过程十分复杂、耗时较长,严重影响了问题解决的效率。因此,本文提出了通过建立航天测控系统任务可靠性分配过程的径向基神经网络元模型,进行航天测控系统任务可靠性分配的策略。

2 径向基神经网络模型及其学习算法

为进一步分析航天测控系统的 RBFNN 网络

模型及求解过程,本文首先给出了 RBFNN 基本原理,在此基础上,设计了基于主成分分析和梯度下降的 RBFNN 自适应混合学习算法。

2.1 RBFNN 网络模型

RBFNN 是一类 3 层结构的前馈神经网络^[10],其中,输入层代表系统的输入向量;隐含层通过节点的激活函数实现输入向量到高维空间的非线性映射;输出层利用隐含层节点的线性组合表示网络的响应值。

考虑航天测控系统的特点,同时不失一般性,文中采用 $l-k-1$ 结构的 RBFNN,即网络输入层、隐含层、输出层的节点数分别为 l, k 和 1。如图 1 所示。




图 1 RBFNN 结构图

Fig. 1 Structure diagram of RBFNN

RBFNN 实现了从输入空间到输出空间的非线性映射,径向基神经网络输出为 k 个径向基函数的线性加权和,即

$$f(x) = \sum_{i=1}^k \omega_i \phi(c_i, \sigma_i, x) \quad (2)$$

其中 ω_i 表述第 i 个隐含层节点到输出层节点的连接权重, $\phi(c_i, \sigma_i, x)$ 表示第 i 个隐含层 RBF(radial basis function)对输入向量 x 的响应值, c_i 是 RBF 的中心, σ_i 是 RBF 的宽度。

RBFNN 采用径向对称的函数(即径向基函数)作为隐含层节点的激活函数。本文采用的隐含层径向基函数为高斯函数,高斯函数是最常用的径向基函数,表达形式如下:

$$\phi(c_i, \sigma_i, x) = \exp\left(-\frac{\|x - c_i\|^2}{\sigma_i^2}\right) \quad (3)$$

当扩展常数 σ_i 较小时,高斯径向基函数 ϕ 具有较高的选择能力; $\|\cdot\|$ 是向量之间的 Euclidean 距离。

2.2 RBFNN 自适应混合学习算法思路

该算法首先采用主成分分析法(principal

components analysis,简称 PCA)来确定 RBFNN 模型的初始结构;在此基础上,利用衰减因子来改进梯度学习算法的参数以增强算法的收敛性。

2.2.1 RBFNN 初始结构确定

RBFNN 初始结构学习即确定隐含层节点的初始数量。PCA 是一种处理数据相关性的统计方法,能够有效的降低统计数据的维数。假定训练样本集合为 $X = \{(M_i, R_i) \mid i = 1, \dots, N\}$,其中 N 为训练样本数量,各测控设备的 M_i 为样本输入向量,系统的预计可靠度 R_i 为样本实际输出值,基于 PCA 方法^[11]确定初始的 RBFNN 隐含层最少节点数 k ,算法步骤如下:

Step 1 根据训练样本集 X 产生各样本之间的相关性矩阵

$$\tilde{\Phi} = \begin{bmatrix} \phi_{11} & \phi_{12} & \cdots & \phi_{1N} \\ \phi_{21} & \phi_{22} & \cdots & \phi_{2N} \\ \vdots & \vdots & & \vdots \\ \phi_{N1} & \phi_{N2} & \cdots & \phi_{NN} \end{bmatrix}$$

其中 $\phi_{ij} = \exp(-\|M_i - M_j\|^2)$ 。

Step 2 计算样本相关性矩阵 Φ 的特征值,并按降序排列,得到特征值序列 $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_N)$ 。RBFNN 的初始隐含层节点数 k 可根据公式(2)得到

$$k = \min\left(k' \mid \sum_{i=1}^{k'} \lambda_i / \sum_{i=1}^N \lambda_i > \theta, k' = 1, \dots, N\right) \quad (4)$$

式中 θ 为影响重要度阈值,一般取值范围为 $[0.9, 0.99]$ 。

2.2.2 RBFNN 参数学习

传统的梯度下降法通过最小化目标函数(如均方误差 MSE)实现对各隐含层节点中心向量、宽度和连接权值的调节^[12]。当隐含层节点数量确定后,梯度下降法是 RBFNN 参数学习的一种有效方法。

定义:RBFNN 样本系统实验误差为

$$E = \frac{1}{2} \sum_{i=1}^N e_i^2$$

其中 $e_i = R_i - f(M_i)$ 为 RBFNN 对训练样本 (M_i, R_i) 的误差。

根据梯度下降学习方法,得到 RBFNN 参数的调整量表示为

$$\nabla c_j = \eta_c \frac{\omega_j}{\sigma_j^2} \sum_{i=1}^N e_i \phi_j(M_i) (M_i - c_j) \quad (5)$$

$$\nabla \sigma_j = 2\eta_\sigma \frac{\omega_j}{\sigma_j^3} \sum_{i=1}^N e_i \phi_j(M_i) \|M_i - c_j\|^2 \quad (6)$$

$$\nabla \omega_j = \eta_\omega \sum_{i=1}^N e_i \phi_j(M_i) \quad (7)$$

式中 η_c 、 η_σ 和 η_ω 分别为隐含层节点中心、宽度和输出权重的学习率。

本文针对梯度下降算法易早熟的不足,选取梯度信息衰减系数 γ ,用于控制梯度信息在种群进化中的作用,通常取值为 $\gamma=0.95$,设计了自适应调整策略来解决参数学习问题。此时,RBFNN 参数的调整策略变为

$$\nabla c_j(t) = \gamma^{t-1} \eta_c \frac{\omega_j}{\sigma_j^2} \sum_{i=1}^N e_i \phi_j(M_i) (M_i - c_j) \quad (8)$$

$$\nabla \sigma_j(t) = 2\gamma^{t-1} \eta_\sigma \frac{\omega_j}{\sigma_j^3} \sum_{i=1}^N e_i \phi_j(M_i) \|M_i - c_j\|^2 \quad (9)$$

$$\nabla \omega_j(t) = \gamma^{t-1} \eta_\omega \sum_{i=1}^N e_i \phi_j(M_i) \quad (10)$$

其中 $\nabla c_j(t)$ 、 $\nabla \sigma_j(t)$ 和 $\nabla \omega_j(t)$ 分别为第 t 步迭代时隐含层节点的中心值、扩展常数和连接权值对应的梯度调节量。

由式(8)~式(10)可知,迭代过程中,算法为梯度信息的计算增加了衰减因子。随着迭代的进行,受衰减因子的影响,梯度信息在个体进化中的作用逐渐降低,而进化信息的作用相对增强。这样有利于算法在执行前期对参数空间进行广泛探索,而后期对局部区域细致搜索,以避免早熟现象,且增强算法的收敛性。

3 航天测控系统任务可靠性分配的 RBFNN 建模与优化

基于上文设计的自适应混合学习算法,航天测控通信系统任务可靠性分配 RBFNN 结构和参数的自适应训练流程如下:

Step 1 从航天测控系统资源空间随机选取样本,组成 RBFNN 元模型训练样本集 $M = \{M_1, \dots, M_N\}$ 和验证样本集 $\bar{M} = \{\bar{M}_1, \dots, \bar{M}_L\}$,计算训练样本集和验证样本集的期望结果 $R = [R_1, \dots, R_N]^T$ 和 $\bar{R} = [\bar{R}_1, \dots, \bar{R}_L]^T$ 。

Step 2 根据训练样本计算 RBFNN 隐含层节点的相关性矩阵 Φ ,设定影响重要度阈值 $\theta = 0.95$,利用 PCA 方法,根据公式(2)确定隐含层节点数 k 。

Step 3 随机选择数量为 k 的训练样本作为隐含层节点中心,计算相应节点宽度为 $\sigma_j = \kappa$

$\min_{i=1, \dots, N} \|M_i - c_j\|$, κ 为重叠系数。根据最小二乘法

得到初始的输出权重向量为 $W = (H^T H)^{-1} H^T R$,式中 H 为隐含层节点对各训练样本的输出矩阵, $H = [\phi(c_j, \sigma_j, M_i)]_{N \times k}$ 。设定迭代步数 $t = 0$ 。

Step 4 根据公式(8)~式(10)更新 RBFNN 参数,产生新的 RBFNN 元模型。

Step 5 计算平均验证误差

$$\hat{E} = \frac{1}{M} \sum_{i=1}^M [\bar{M}_i - \sum_{j=1}^k \omega_j(t+1) \phi(c_j(t+1), \sigma_j(t+1), \bar{M}_i)]^2$$

当 $\hat{E}$ 小于验证误差阈值 δ 或者达到最大迭代步数 T 时,停止参数学习,转到 Step 6;否则, $t = t + 1$,返回 Step 4。

Step 6 最优分配方案搜索。

分配方案 $M^* = (M_1^*, \dots, M_l^*)$ 称为 R^* 最优分配方案当且仅当 M^* 对应的任务可靠度 $R_s \geq R^*$,并且对于任意任务可靠度满足 R^* 的分配方案的可靠度 R^{**} ,必存在 $R^{**} > R_s$ 。分配方案优化搜索过程就是利用航天测控系统任务可靠性分配 RBFNN 元模型,对分配方案空间进行探索式搜索,确定系统所有 R^* 最优分配方案的过程。

Step 7 结束。

4 算例分析

4.1 想定设计

为验证算法的有效性,以下选择航天测控系统某飞行阶段的两个业务为例。其任务可靠性框图模型如图 2 和图 3 所示。其中 S1~S10 代表 10 个不同的站点,各个站点由相应的设备按照一定的逻辑关系组成,逻辑结构如表 1 所示,图中时间刻度为 h:min:s,如 5:0:40 表示 5 h 0 min 40 s。




图 2 业务 1 的任务可靠性框图

Fig. 2 Sequence diagram of spaceflight mission 1

表 1 站点设备逻辑组成表
Table 1 Logic table of equipments

地面站名称	组成设备	逻辑结构						
S1	S11 P11 P12	—[S11]—[P11]—[P12]—						
S2	S21 P11 P12	—[S21]—[P11]—[P12]—						
S3	S31 P11 P12	—[S31]—[P11]—[P12]—						
S4	S41 P11 P12	—[S31]—[P11]—[P12]—						
S5	S51 S52 S53 S54 S55 S56 P11 P12 P13 P14	—[S51]—[S52]— <table><tr><td>[S53]</td><td>[S54]</td><td>[P13]</td></tr><tr><td>[S55]</td><td>[S56]</td><td>[P14]</td></tr></table> —[P11]—[P12]—	[S53]	[S54]	[P13]	[S55]	[S56]	[P14]
[S53]	[S54]	[P13]						
[S55]	[S56]	[P14]						
S6	S61 S62 S63 S64 S65 S66 P11 P12 P13 P14	—[S61]—[S62]— <table><tr><td>[S63]</td><td>[S64]</td><td>[P13]</td></tr><tr><td>[S65]</td><td>[S66]</td><td>[P14]</td></tr></table> —[P11]—[P12]—	[S63]	[S64]	[P13]	[S65]	[S66]	[P14]
[S63]	[S64]	[P13]						
[S65]	[S66]	[P14]						
S7	S71 S72 S73 S74 S75 S76 P11 P12 P13 P14	—[S71]—[S72]— <table><tr><td>[S73]</td><td>[S74]</td><td>[P13]</td></tr><tr><td>[S75]</td><td>[S76]</td><td>[P14]</td></tr></table> —[P11]—[P12]—	[S73]	[S74]	[P13]	[S75]	[S76]	[P14]
[S73]	[S74]	[P13]						
[S75]	[S76]	[P14]						
S8	S81 S82 S83 S84 S85 S86 P11 P12 P13 P14	—[S81]—[S82]— <table><tr><td>[S83]</td><td>[S84]</td><td>[P13]</td></tr><tr><td>[S85]</td><td>[S86]</td><td>[P14]</td></tr></table> —[P11]—[P12]—	[S83]	[S84]	[P13]	[S85]	[S86]	[P14]
[S83]	[S84]	[P13]						
[S85]	[S86]	[P14]						
S9	S91 S92 S93 S94 S95 S96 P11 P12 P13 P14	—[S91]—[S92]— <table><tr><td>[S93]</td><td>[S94]</td><td>[P13]</td></tr><tr><td>[S95]</td><td>[S96]</td><td>[P14]</td></tr></table> —[P11]—[P12]—	[S93]	[S94]	[P13]	[S95]	[S96]	[P14]
[S93]	[S94]	[P13]						
[S95]	[S96]	[P14]						
S10	S101 S102 S103 S104 S105 S106 P11 P12 P13 P14	—[S101]—[S102]— <table><tr><td>[S103]</td><td>[S104]</td><td>[P13]</td></tr><tr><td>[S105]</td><td>[S106]</td><td>[P14]</td></tr></table> —[P11]—[P12]—	[S103]	[S104]	[P13]	[S105]	[S106]	[P14]
[S103]	[S104]	[P13]						
[S105]	[S106]	[P14]						




图 3 业务 2 的任务可靠性框图
Fig. 3 Sequence diagram of spaceflight mission 2

其中 S11~S106 分别代表各个地面站完成任务所用设备、P11~P14 分别代表公用的控制中心、通信设备和路由等. 假设系统的可靠度指标为 $R^* = 0.995$, 各个设备的初始可靠度指标为 0.95, 站属设备的可靠性指标限制条件为 $800 > M_{Sm} > 10$, 公用设备的可靠性指标限制条件为 $800 > M_{Pm} > 20$, 单位为 h. 算例的目标为确定系统的综合可靠度不小于 0.995 的各设备 MTBF 最优配置方案.

通过限制抽样仿真^[13] 计算可知, 随着各设备 MTBF 的增加, 其系统的任务可靠度递增, 因此其分配方案空间无穷大, 如果采用原始模型对其直接进行探索性分析, 则运算时间过长, 本文中采用的元模型方法可有效解决计算效率问题. 算例

通过对比二阶多项式回归元模型、Kriging 元模型、RBFNN 元模型和本文设计 AHL 算法对测试样本的误差统计, 以证明本文提出学习算法的有效性和优越性.

本文利用 Visual C# 2008 开发了 AHL 算法, 以实现航天测控系统任务可靠度分配的 RBFNN 建模和资源配置寻优.

4.2 RBFNN 拟合分析

梯度迭代学习算法的控制参数如表 2 所示.

表 2 学习算法控制参数
Table 2 Control parameters of gradient learning

控制参数	数值
影响重要度 θ	0.95
宽度重叠系数 κ	1.2
节点有效性阈值 ξ_c	0.000 01
节点中心相似性阈值 ξ_c	0.000 01
节点宽度相似性阈值 ξ_s	0.000 01
验证误差阈值 δ	0.000 01
最大迭代步数 T	200

通过多次仿真,得到 AHL 过程中各个参数的最优学习率,如表 3 所示.

表 3 学习率参数

Table 3 Parameters of learning rate

学习率参数	数值
中心学习率	0.02
宽度学习率	0.01
连接权值学习率	0.02

基于本文提出的 AHL 过程为

阶段 1 从输入空间随机抽取 70 个训练样本和 30 个验证样本, 计算得到各样本对应的输出结果值。

阶段 2 根据学习算法,确定 RBFNN 初始结构为 44-62-1,即,输入层节点数为 44,隐含层节点数为 62,输出层节点数为 1.

针对这 30 个测试样本,对比二阶多项式回归元模型、Kriging 元模型、RBFNN 元模型和 AHL 算法对这些测试样本的平均误差统计结果,如表 4 所示。从数据中可见:改进梯度学习后的 RBFNN,其平均测试误差最小,能够得到比其他元模型更优的拟合结果;同时,本文提出的算法有效改进了梯度学习的拟合效果,使得 RBFNN 元模型具有更好的泛化能力。但是,由于训练样本对输入空间代表性较低,AHL 对个别测试样本的统计误差较大,因此,对训练样本集的优化设计是进一步提高 RBFNN 泛化性能的关键因素。

表 4 测试样本误差结果对比

Table 4 Comparison of test sample errors

元模型	平均测试误差	最大测试误差
二阶多项式回归	0.00056	0.0016
Kriging	0.00083	0.0037
RBFNN	0.00048	0.0022
AHL	0.00039	0.0024

阶段3 在AHL基础上,对输入空间的所有设备配置方案进行探索性寻优,进而得到系统的 R^* 最优配置方案为 S1-P14=(142.79,142.79,142.79,209.43,142.79,142.79,142.79,142.79,142.79,142.79,224.91,224.91,224.91,224.91,224.91,224.91,142.79,142.79,142.79,142.79,42.79,142.79,142.79,142.79,142.79,142.79,142.79,142.79,142.79,142.79).

142.79, 142.79, 142.79, 142.79, 142.79, 142.79,
142.79, 142.79, 142.79, 293.92, 293.92, 293.92,
293.92, $R_s = 0.99533$.

5 结 论

本文设计了航天测控系统任务可靠性分配的 RBFNN 模型,并改良了 RBFNN 的学习过程,提出了自适应混合学习算法.算法由 RBFNN 初始结构的 PCA 构造过程、隐含层节点的改进梯度参数学习过程和隐含层结构调整过程组成,算法提高了 RBFNN 的泛化能力.同时,仿真算例验证了基于 RBFNN 元模型的航天测控系统任务可靠性分配配置优化策略的有效性.但是,在 RBFNN 元模型学习过程中,由于受训练样本对输入空间代表性低的影响,训练后的元模型对个别测试样本产生较大误差,因此,训练样本集的优化设计成为进一步提高 RBFNN 元模型泛化能力的研究内容.

参考文献:

- [1] 于志坚. 航天测控系统工程[M]. 北京: 国防工业出版社, 2008.
- [2] Khoshbakht A F, Raoofat M. Optimal allocation of DGs and RCSs to improve distribution network reliability and network energy loss[C]//Proceedings of 2nd IEEE International Conference on Power and Energy (PECon 08). Johor Baharu, Malaysia: IEEE, 2008: 1586-1592.
- [3] Vidyarthi D P, Tripathi A K. Maximizing reliability of distributed computing system with task allocation using simple genetic algorithm[J]. Journal of System Architecture, 2001, 47(6): 549-554.
- [4] Tom P A, Murthy C S R. Algorithms for reliability-oriented module allocation in distributed computing systems[J]. Journal Systems Software, 1998, 40(2): 125-138.
- [5] ZHANG Xingui, WU Xiaoyue. A heuristic algorithm for mission reliability allocation of spaceflight TT&C system[C]//The Proceedings of 2011 9th International Conference on RMS. Guiyang, China: IEEE, 2011: 1208-1213.
- [6] Yalaoui A, Chatelet E, Chu C B. A new dynamic programming method for reliability & redundancy allocation in a parallel-series system[J]. IEEE Transactions on Reliability, 2005, 54(2): 254-262.
- [7] Khan M G M, Ahmad N, Rafi L S. Optimal testing resource allocation for modular software based on a software reliability growth model: a dynamic programming approach[C]//Proceeding of International Conference on Computer Science and Software Engineering. Washington, DC, USA: IEEE, 2008: 759-762.
- [8] LI Minqiang, TIAN Jin, CHEN Fuzan. Improving multi-class pattern recognition with a co-evolutionary RBFNN[J]. Pattern Recognition Letters, 2008, 29(4): 392-406.

- [9] LIN Faajeng, TENG Litao, YU Menghsiung. Radial basis function network control with improved particle swarm optimization for induction generator system [J]. IEEE Transactions on Power Electronics, 2008, 23(4): 2157-2169.
- [10] Casasent D, CHEN Xuewen. Radial basis function neural networks for nonlinear Fisher discrimination and Neyman-Pearson classification [J]. Neural Networks, 2003, 16(5/6): 529-535.
- [11] JIA Mingxing, ZHAO Chunhui, WANG Fuli, et al. A new method for decision on the structure of RBF neural network [C] // Proceeding of International Conference on Computational Intelligence and Security, Guangzhou, China: IEEE, 2006: 147-150.
- [12] Karayiannis N B. Reformulated radial basis neural networks trained by gradient descent [J]. IEEE Transactions on Neural Networks, 1999, 10(3): 657-671.
- [13] XU Shuangwei, WU Xiaoyue, YAN Hua. An efficient and approximate evaluation method for mission reliability of TT&C system [C] // Proceeding of the 7th International Conference on Mathematical Method in Reliability. Beijing, China: Beijing Institute of Technology, 2011: 687-692.