

基于快速确定隐层神经元数的BP神经网络算法

郑绪枝¹ 雷靖^{1,2} 夏薇¹

(云南民族大学数学与计算机科学学院 昆明 650500)¹ (云南省软件工程重点实验室 昆明 650091)²

摘要 根据多项式理论构造一种以正交多项式作为隐层神经元激活函数的BP神经网络模型。针对该网络提出一种算法,即一种隐层的激励函数为正交多项式及其神经元数目可快速确定的算法。首先通过数学证明从理论上验证了该算法的有效性。然后利用计算机对该算法进行仿真与校验,并与传统的BP算法进行比较。结果表明该算法不仅突破了传统BP神经网络的局限性,如收敛速率慢、最佳隐神经元数难确定等,而且能够达到更高的工作精度,从而从实验上验证了该算法的有效性。

关键词 正交基函数,隐神经元,权值,学习算法,函数逼近

中图分类号 O29 **文献标识码** A

Algorithm for BP Neural Networks by Identifying Numbers of Hidden Layer Neurons Quickly

ZHENG Xu-zhi¹ LEI Jing^{1,2} XIA Wei¹

(School of Mathematics and Computer Science, Yunnan Nationalities University, Kunming 650500, China)¹

(Key Laboratory in Software Engineering of Yunnan Province, Kunming 650091, China)²

Abstract Based on polynomial curve-fitting theory, an orthogonal basis feed-forward neural network is constructed. The model is adopted by a three-layer structure, where the hidden-layer neurons are activated by orthogonal polynomial functions. In view of the network, an algorithm is proposed that a kind of hidden layer activation function is the orthogonal polynomial and the number of neurons can be quickly determined. Through mathematical proof, the validity of the algorithm is theoretically proved. The algorithm is verified by computer simulations, comparing with the conventional BP algorithm. The results show that this algorithm not only breaks through the traditional BP neural network limitations, such as slow convergence rate, optimal number of hidden neurons that difficult to be determined, but also can achieve higher precision. The effectiveness of the designed algorithm is validated.

Keywords Orthogonal base function, Hidden neuron, Weight, Learning algorithm, Function approximation

1 引言

近几十多年来, BP类神经网络在理论研究方面和实践应用方面都得到了显著的发展,大量新的BP类神经网络模型和方法不断地被发明^[1-6]。在国外,已有许多学者尝试将各神经元的激励函数设为正交或线性无关的激励函数组,因此取得了不少成就^[1,2];在国内,陈玉芳和雷霖提出了一种提高网络效率的算法^[3],其中令最优隐神经元数为 $m = \log_2 n$ (n 为输入层神经元数);张雨浓教授等人也陆续研究了将多层前向神经网络各隐层神经元的激励函数选取为正交或线性无关的激励函数系的情况,并在此基础上逐渐提出了神经网络权值直接确定法和理论^[4-6],例如他在文献^[5,6]中利用神经网络衍生算法来确定最佳隐神经元数(初始化隐神经元数为1)。目前, BP类神经网络是研究最为成熟、应用最为广泛的人工神经网络模型之一,它被广泛应用于信号处理、自动控制和模式识别等学科的理论研究和实践中^[7-12],而大部分应用都被转化为运用神经网络逼近函数的问题^[5,13,14]。然而,虽然

BP类神经网络得到了广泛的应用,但其固有的缺陷也是众所周知的:一是,在网络训练的过程中,其易陷入局部极小点的状况;再者,学习率(或学习步长)过大或者过小都会使得网络收敛速度变慢;然后是网络结构较难确定,至今仍然没有找到能够确定隐层神经元数目的统一、有效的方法。

本文提出了一种隐层的激励函数为正交多项式及其神经元数目可快速确定的算法。首先给出相关概念、定理;然后给出了BP神经网络的模型及其基本原理;继而给出改进算法的具体描述及网络设计等;最后利用本文提出的算法对目标函数的逼近进行仿真与校验,并且使其与传统的BP算法进行比较,所得到的结果表明,该算法在收敛速率、快速确定较好的网络结构(最佳隐层神经元数)和工作精度等方面上有很好的效果,验证了该算法的有效性。

2 相关概念和定理

本节主要介绍所需要的一些关于正交基函数的定义和函数逼近的理论。

本文受云南省自然科学基金项目(2011FZ169),云南省软件工程重点实验室开放基金项目(2011SE15)资助。

郑绪枝(1986-),男,硕士生,主要研究方向为函数逼近论;雷靖(1969-),女,硕士生导师,主要研究方向为网络控制系统的综合与应用, E-mail: cynthin. lei@163.com(通信作者);夏薇(1986-),女,硕士生,主要研究方向为图像处理。

2.1 正交基函数

关于正交多项式、Jacobi 多项式和 Hermite 多项式的概念具体描述如下。

定义 1^[4] 对于 $a_n \neq 0$ 的 n 次多项式 $g_n(x) = \sum_{i=0}^n a_i x^i$ ($n=0, 1, 2, \dots$); 若满足如下内积关系:

$$(g_l(x), g_k(x)) = \int_a^b \rho(x) g_l(x) g_k(x) dx = \begin{cases} \int_a^b \rho(x) g_l^2(x) dx > 0, & l = k \\ 0, & l \neq k \end{cases} \quad (1)$$

则称多项式序列 $\{g_n(x), n=0, 1, 2, \dots\}$ 在 $[a, b]$ 上带权 $\rho(x)$ 正交, 并称 $g_n(x)$ 为 $[a, b]$ 上带权 $\rho(x)$ 的 n 次正交多项式基函数, 简称 n 次多项式。

定义 2^[4] Jacobi 多项式可直接定义为:

$$J_n^{(\alpha, \beta)}(x) = \frac{1}{n!} \frac{d^n}{dx^n} [(x^2-1)^n \rho(x)], x \in [-1, 1] \quad (2)$$

式中, $\rho(x) = (1+x)^\alpha (1-x)^\beta$ 为权函数, $\alpha > -1, \beta > -1$ 是给定的实数。

定义 3^[4] Hermite 正交多项式可定义如下:

$$\varphi_{j-1}(x) = (-1)^{j-1} e^{x^2} \frac{d^{j-1}}{dx^{j-1}} e^{-x^2}, -\infty < x < +\infty \quad (3)$$

是区间 $(-\infty < x < +\infty)$ 上关于权函数 $\rho(x) = e^{-x^2}$ 的 $j-1$ 次正交多项式, 即

$$\int_{-\infty}^{+\infty} \varphi_i(x) \varphi_j(x) e^{-x^2} dx = \begin{cases} 0, & i \neq j \\ 2^i i! \sqrt{\pi}, & i = j \end{cases} \quad (4)$$

2.2 最佳逼近理论

所谓的函数逼近, 是用较简单、明晰的函数 $\phi(x)$ 来近似代替未知目标函数 $f(x)$, 使两者之间的误差达到最小。下面给出利用本文所提网络逼近函数时所需的定义与定理。

定义 4^[6] 假定某目标函数 $f(x)$ 和线性无关函数系 $\{\phi_i(x)\}_{i=0}^{n-1}$ 中的 $\forall \phi_i(x)$ 在闭区间 $[a, b]$ 上都连续。给定闭区间 $[a, b]$ 上的权函数 $\rho(x)$, 对于广义多项式

$$y = \phi(x) = \sum_{i=0}^{n-1} w_i \phi_i(x) \quad (5)$$

确定一组系数 w_0, w_1, \dots, w_{n-1} , 使得 $\int_a^b \rho(x) (f(x) - \phi(x))^2 dx$ 为最小。如此得到的函数 $\phi(x)$ 称为 $f(x)$ 在闭区间 $[a, b]$ 上关于权函数的最小二乘逼近函数。

定理 1^[6] 若某目标函数 $f(x)$ 在闭区间 $[a, b]$ 上连续, 则其最小二乘逼近函数 $\phi(x)$ 存在且唯一。

定理 1 的详细证明可参考文献[4-6]。定理 1 和文献[5]之定理 2 表明: 最优稳态权值可以直接确定, 进而解决了网络易陷入局部极小点的问题。

定理 2^[15] 对于任意给定的 n 个不同的样本对 (x_i, y_i) , 任意小误差 $e > 0$, 及在任意区间无限可导的激励函数 $\phi, R \rightarrow R$, 总存在一个包含 $\tilde{n} (\tilde{n} \leq n)$ 个隐神经元的单隐层前馈神经网络, 使得在 $a_i \in R$ 和 $b_i \in R$ 任意取值的情况下, 误差 $E(W) \leq e$ 。

定理 2 的详细证明可参考文献[15, 16]。定理 2 和文献[13]之定理 1 表明: 当隐层神经元足够多时, 单隐层前馈神经网络就能在输入权随机赋值的情况下逼近任何连续函数。但值得注意的是: 为了使单隐层前馈神经网络具有良好的泛化性能, 一般设 $\tilde{n} \leq n$ 。

3 BP 类神经网络模型

本节我们给出要建构的网络的拓扑结构, 具体地描述网络各层之间的关系, 并简洁地阐述 BP 学习算法。

3.1 网络的拓扑结构

本文提出的用于函数逼近的神经网络是一类前向 3 层的神经网络, 拓扑结构为 $n-m-1$ 。网络拓扑结构如图 1 所示。




图 1 单隐层的神经网络

3.2 网络各层之间的关系

图 1 中, 易见输入层有 n 个样本点, 隐层有 m 个节点。总的网络输入输出之间的映射关系为:

$$y = g\left(\sum_{i=1}^m w_i \phi_i(h(x_j)) - \theta_i^{(1)}\right) - \theta \quad (6)$$

式中, $h(\cdot)$ 为输入层节点 j 到隐层节点 i 的连接权函数, w_i 为隐层节点 i 到输出节点的连接权值, $\theta_i^{(1)}$ 为隐层节点 j 的激励阈值, g 为输出节点激励函数, θ 为输出节点阈值, ϕ_i 为隐神经元激励函数且为正交基函数。

3.3 BP 神经网络的基本原理

BP 标准算法的指导思想是^[17]: 对网络权值和阈值的修正要沿着表现函数下降最快的方向, 即负梯度方向。整个学习算法由两部分组成: 1) 信号的正向传递; 2) 误差反向传播。其具体的学习过程描述如下:

- (1) 输入学习样本, 通过已设置好的网络和前一次迭代的权值和阈值, 从网络的头层向后计算各个神经元的输出;
- (2) 修正权值和阈值, 反过来从末层向前计算各权值和阈值对总误差的影响, 并依此修正各权值和阈值;
- (3) 以上两个步骤反复交替运行, 直至收敛。

4 算法的学习及网络设计

本节我们给出算法的推导和具体的描述。

4.1 算法的推导

本文研究的是 BP 类神经网络, 其所采用的 BP 算法属于 δ 学习规则。 δ 学习规则是由认知心理学家 McClelland 和 Rumelhart 等学者提出的, δ 规则的学习信号如下规定:

$$r = [d_i - \phi(w_i^T x)] \phi'(w_i^T x) = (d_i - y_i) \phi'(w_i^T x) \quad (7)$$

式中, d_i 表示期望输出。 δ 学习规则可由输出值和期望值的最小平方误差推导出来, 将神经元的实际输出和期望输出之间的平方误差定义如下:

$$E = 1/2 (d_i - y_i)^2 = 1/2 (d_i - \phi(w_i^T x))^2 \geq 0 \quad (8)$$

由上式可知, 要使该式有界的误差函数 E 最小, 则权值向量的调整应正比于该误差函数的负梯度, 即 $\Delta w_i = -\eta \nabla E$, 其中 η 为学习率。另外, 由误差函数 E 的定义可得: $\nabla E = -(d_i - y_i) \phi'(w_i^T x) x$ 。特别而言, 对于权值调整向量中的每个元素分量的调整公式, 可以相应推导得到: $\Delta w_{ji} = \eta (d_i - y_i) \phi'(w_i^T x) x_i, i=1, 2, \dots, n$ 。

给定 n 个学习样本 $(x_1, d_1), (x_2, d_2), \dots, (x_n, d_n)$, 其中,

d_n 为第 n 个样本的期望输出。设对应第 i 个学习样本输入网络的实际输出为 y_i , 则网络关于所有样本对的批处理误差定义为:

$$E = \sum_{i=1}^n 1/2(y_i - d_i)^2 = (g(\sum_{i=1}^m w_i \phi_i(h(x_j) - \theta^{(1)})) - \theta) - d_i \quad (9)$$

按照基于梯度下降的 BP 学习算法进行权值修正:

$$\Delta w_i = -\eta \frac{\partial E}{\partial w_i} = \eta(d_i - y_i) \phi_i(x_j),$$

$$i=1, 2, \dots, m; j=1, 2, \dots, n \quad (10)$$

$$w_i(k+1) = w_i(k) + \Delta w_i(k) \quad (11)$$

$$\theta_i^{(1)} = \theta_i^{(1)} + \alpha \Delta \theta_i^{(1)}, i=1, 2, \dots, m \quad (12)$$

$$\theta = \theta + \beta \Delta \theta \quad (13)$$

式中, α, β, η 为学习效率。若 h 和 g 都为线性恒等函数, 则 $h(x) = g(x) = x$ 。令 $\theta_i^{(1)} = 0, \theta = 0$ 时, 则式(6)变为:

$$y = \sum_{i=1}^m w_i \phi_i(x_j) \quad (14)$$

4.2 隐层数的设计

理论分析证明^[18], 具有单隐层的前馈神经网络能够映射所有连续函数。具体地说, 在无限制隐神经元数的情况下, 单隐层的 BP 网络可以实现任意的非线性映射。因此, 本文仍运用这种模型。

4.3 隐层神经元数的设计

隐层神经元数的设计既是本文的创新点, 也是本文的重中之重。因为我们知道, BP 类神经网络一个极关键问题(也是难点)是隐神经元数的确定。为确定最佳隐神经元数, 已经有许多学者通过试凑法^[17,19]归纳出一些确定隐神经元数的经验公式, 例如以下 3 个经验公式^[17,19]:

$$m = \log_2 n \quad (15)$$

$$m = \sqrt{nl} \quad (16)$$

$$m = \sqrt{0.43nl + 0.12l^2 + 2.54n + 0.77l + 0.35} + 0.51 \quad (17)$$

但值得提出的是, 这些经验公式计算出来的隐神经元数仅仅是一种粗略的估计值, 一般少于实际所需的隐神经元数, 因为考虑到过多的隐神经元数会延长训练时间, 同时也会增加网络的空间复杂度, 出现过度吻合等现象, 这反而会降低网络学习效率, 不符合实际要求。

本文考虑到在处理大量的数据时, 网络需要较多的隐神经元去学习、记忆, 故当采用初始化隐神经元为 1 的网络衍生算法^[5,6]确定最佳隐神经元数时, 会耗费更多时间。因此, 为了加快收敛速率, 本文采用令初始化隐神经元数为 $m_1 = -1 + \log_2 n$ (左取整) 的网络衍生算法来确定最佳隐神经元数 m 。在这种条件下, 我们根据定理 2 提出如下定理来确定最佳隐层神经元数, 并予以证明。

定理 3 若给定任意 n 个不同的样本对 (x_i, y_i) , 任意小误差 $e > 0$, 及一个正交的激励函数 $\phi, R \rightarrow R$, 它在任意闭区间上是无限可导的, 则总存在一个包含 $\tilde{n} (\log_2 n \leq \tilde{n} \leq n)$ 个隐神经元的单隐层前馈网络, 使得 $a_i \in R$ 和 $b_i \in R$ 在任意取值的情况下, 误差 $E(W) \leq e$ 。

证明: 设 $n_1 = \log_2 n$, 由于过多的隐神经元数会延长训练时间, 同时也增加了网络的空间复杂度, 出现过度吻合等现象, 因此设计出来的经验公式所确定的隐神经元数一般少于实际所需的隐神经元数。于是由式(16)可知: $n_1 = \log_2 n \leq \tilde{n}$; 且有 $\tilde{n} \leq n^{[5]}$, 因而 $n_1 = \log_2 n \leq \tilde{n} \leq n$, 得证。

通过定理 3 可知, 在初始隐层神经元数为 \tilde{n} 的前提下, BP 类神经网络的最佳隐层神经元数能够在较短的时间内得到确定, 大大加快了网络的收敛速率。

4.4 各层连接权值的设置

将神经网络输入层神经元与隐层神经元之间的连接权值设置为 1, 输入层和输出层神经元使用线性恒等激励函数, 隐层神经元使用正交多项式激励函数。非线性网络的误差面比线性网络的误差面复杂得多, 其问题在于多层网络中非线性传递函数有多个局部最优解。根据定义 4 以及定理 1 和文献[5]之定理 2, 我们可以直接计算出权值, 很好地避开了冗长的迭代, 因而具有更高的计算速度, 并且不再需要选取学习率等参数; 重要的是, 通过定理 1 和文献[5]之定理 2 可以看到直接计算所得到的网络权值是该网络的最优稳态权值, 从而避免了局部极小点问题。

4.5 改进算法的具体步骤

1) 按照图 1 所示, 构建一个前向三层(单隐层)结构的基于正交多项式的 BP 网络, 其各层连接权值的设置如 4.3 节所述;

2) 初始化基于正交多项式的 BP 神经网络。若网络输入层神经元数为 n , 则初始隐层神经元数为 $m_1 = -1 + \log_2 n$ (左取整);

3) 令 N 为数据点数, E_{expect} 为期望达到的学习精度。利用权值直接确定法直接计算出网络隐层神经元与输出神经元之间的连接权值向量 W 及相应的网络批处理学习误差 E_k ;

4) 若 $\frac{E_k}{N} > E_{expect}$, 则增加一个隐神经元, 即 $m_2 = -1 + \log_2 n + 1 = \log_2 n$, 返回至第 3) 步继续运算。反之, 停止运算。

5 仿真实验与结果分析

为了能够比较直观、简便地验证本文所提算法的优越性, 采用一维输入为例进行仿真与校验。理论推导和结果相同, 并且仿真实验也能够证明实验所得结论同样适用于多维情形。

先用参数为 $\alpha = \beta = 0$ 的 Jacobi 正交多项式的神经网络对目标函数 $f(x) = 2xe^{x^2} + \sin(5\pi x)$ 的逼近进行仿真和验证; 然后用 Hermite 正交多项式神经网络对目标函数 $h(x) = 0.8e^x \cos(2\pi x)$ 的逼近进行仿真和验证。

第一步 用参数为 $\alpha = \beta = 0$ 的 Jacobi 正交多项式的神经网络对目标函数 $f(x) = 4e^x \sin(x) / (3x^2 + 2x + 1)$ 的逼近进行仿真和验证。首先, 在区间 $[-1, 1]$ 内以 0.005 的采样间隔得到的 401 个数据作为训练数据集; 然后, 分别用改进算法、带动量项的 BP 算法、自适应 lrBP 的梯度递减训练算法和 Levenberg-Marquardt 训练算法(简称 L-M 训练法)训练网络, 并对 $f(x)$ 进行逼近 ($E_{expect} = 10^{-9}$) 及对未训练过的数据点(取 $x = 0.99$) 进行校验。改进算法与其它 3 种方法的对比和校验结果如表 1 和图 2 所列。

表 1 改进算法与其它 3 种方法的对比

算法类型	迭代次数 (Epochs)	运行时间 (s)	最佳隐神经元数
改进算法	1	0.101	22
带动量项的 BP 算法	50000	386.111	22
自适应 lrBP 的梯度递减训练算法	30000	221.894	22
Levenberg-Marquardt 训练算法	251	4.0560	22

表 2 改进算法与其它 3 种方法的校验结果

算法类型	MSE	校验误差
改进算法	7.1384×10^{-10}	5.8193×10^{-5}
带动量项的 BP 算法	0.0315	0.0874
自适应 lrBP 的梯度递减训练算法	0.0324	0.1266
Levenberg-Marquardt 训练算法	9.9832×10^{-10}	0.3811

从表 1 可以明显地看到改进算法只要一步确定并且仅用 0.101s 就能确定 $f(x)$ 最佳隐神经元数(22 个), 计算时间 ($0.101s < 4.056s < 221.894s < 386.111s$)、迭代次数 ($1 < 251 < 30000 < 50000$)、均方误差(MSE) ($7.1384 \times 10^{-10} < 9.9832 \times 10^{-10} < 0.0324 < 0.0315$) 和校验误差 ($5.8193 \times 10^{-5} < 0.0874 < 0.1266 < 0.3811$) 都远远小于与它比较的带动量项的 BP 算法、自适应 lrBP 的梯度递减训练算法和 L-M 训练法。图 2 显示了改进的 Jacobi 正交多项式 BP 神经网络的函数逼近和误差情况。




图 2 改进算法训练网络后的逼近及误差情况

第二步 用 Hermite 正交多项式神经网络对目标函数 $h(x) = 0.8e^x \cos(2\pi x)$ 的逼近进行仿真和验证。首先, 在区间 $[-1, 0.7]$ 内以 0.01 的采样间隔得到的 171 个数据作为训练数据集; 然后, 分别用改进算法、带动量项的 BP 算法、自适应 lrBP 的梯度递减训练算法和 Levenberg-Marquardt 训练算法(简称 L-M 训练法)训练网络, 并对 $h(x)$ 进行逼近 ($E_{expect} = 10^{-11}$) 及对未训练过的数据点(取 $x = 0.653$) 进行校验; 所得到的实验结果见表 2。

表 3 改进算法与其它 3 种方法的对比

算法类型	迭代次数 (Epochs)	运行时间 (s)	最佳隐神经元数
改进算法	1	0.0155	27
带动量项的 BP 算法	40000	272.922	27
自适应 lrBP 的梯度递减训练算法	30000	206.981	27
Levenberg-Marquardt 训练算法	1460	14.009	27

表 4 改进算法与其它 3 种方法的校验结果

算法类型	MSE	校验误差
改进算法	5.0136×10^{-12}	2.0831×10^{-5}
带动量项的 BP 算法	0.06774	0.2698
自适应 lrBP 的梯度递减训练算法	0.0991	0.3551
Levenberg-Marquardt 训练算法	9.9993×10^{-12}	2.2366×10^{-7}

从表 3 可以明显地看到改进算法只要一步确定并且仅用 0.0155s 就能确定 $f(x)$ 最佳隐神经元数(27 个), 计算时间 ($0.0155s < 14.009s < 206.981s < 272.922s$)、迭代次数 ($1 < 1460 < 30000 < 40000$) 和均方误差(MSE) ($5.0136 \times 10^{-12} < 9.9993 \times 10^{-12} < 0.06774 < 0.0991$) 都远远小于与它比较的带动量项 BP 算法、自适应 lrBP 的梯度递减训练算法和 L-M

训练法; 改进算法的校验误差为 2.0831×10^{-5} , 虽然比 L-M 训练法大, 却远小于带动量项 BP 算法和自适应 lrBP 的梯度递减训练算法 ($2.0831 \times 10^{-5} < 0.2698 < 0.3551$), 这已经达到了很高的精度, 并不会因此掩盖它的整体优越性。图 3 显示了改进的 Hermite 正交多项式 BP 神经网络的函数逼近和误差情况。




图 3 改进算法训练网络后的逼近及误差情况

结束语 针对传统 BP 神经网络的局限性, 本文构造了一种基于正交多项式的 BP 神经网络, 并提出了一种算法, 即隐层的激励函数为正交多项式及其神经元数目可快速确定的算法。仿真实验结果表明, 与带动量项 BP 算法、自适应 lrBP 的梯度递减训练算法和 L-M 训练法相比, 该算法能够在极短时间内快速确定最佳隐神经元数, 并且可以达到更高的工作精度; 同时也突破了传统 BP 神经网络的局限性, 效果相当不错。利用正交基函数对过程神经网络的学习将是下一步研究的方向。

参考文献

- [1] Purwar S, Kar I N, Jha A N. On-line system identification of complex systems using Chebyshev neural networks [J]. Applied Soft Computing, 2007, 7: 364-372
- [2] Jenkins W M. Neural network weight training by mutation [J]. Computers and Structures, 2006, 84: 2107-2112
- [3] 陈玉芳, 雷霆. 提高 BP 网络效率的又一种算法 [J]. 计算机仿真, 2004, 21(11): 74-76
- [4] 张雨浓, 杨逸文, 李巍. 神经网络权值直接确定法 [M]. 广州: 中山大学出版社, 2010
- [5] 张雨浓, 郭东生, 谭宁. 幂激励前向神经网络最优结构确定算法 [J]. 计算机工程与应用, 2011, 47(2): 29-31
- [6] 邹阿金, 张雨浓. 基函数神经网络及应用 [M]. 广州: 中山大学出版社, 2009
- [7] 王军, 谭继文, 战卫侠. 基于 BP 神经网络的钢丝绳断丝信号处理 [J]. 煤矿机械, 2011, 32(8): 256-258
- [8] Lin W-M, Hong C-M. A new Elman Neural Network-based control algorithm for adjustable-pitch variable-speed wind-energy conversion systems [J]. IEEE Transactions on Power Electronics, 2011, 26(2): 473-481
- [9] Georgieva A, Jordanov I. Intelligent visual recognition and classification of cork tiles with Neural Networks [J]. IEEE Transactions on Neural Networks, 2009, 20(4): 675-685
- [10] 殷英, 纪焜. 基于权值直接确定法的任意基函数神经网络建模 [J]. 云南民族大学: 自然科学版, 2010, 19(6): 428-431

- [11] 娄申,干晓蓉. 基于 BP 神经网络的水质评价[J]. 云南民族大学:自然科学版,2007,16(2):165-167
- [12] 黄国宏,熊志化,邵惠鹤. 一种新的基于构造型神经网络分类算法[J]. 计算机学报,2005,28(9):1519-1523
- [13] 邓万宇,郑庆华,陈琳,等. 神经网络极速学习方法研究[J]. 计算机学报,2010,33(2):279-287
- [14] 王建军,徐宗本. 多元多项式函数的三层前向神经网络逼近方法[J]. 计算机学报,2009,32(12):2482-2488
- [15] Huang G-B, Zhu Q-Y, Siew C-K. Extreme learning machine: Theory and applications [J]. Neurocomputing, 2006, 70 (1-3): 489-501
- [16] Huang G-B. Learning capability and storage capacity of two hidden-layer feedforward networks [J]. IEEE Transactions on Neural Networks, 2003, 14(2): 224-229
- [17] 张德丰. MATLAB 神经网络应用设计[M]. 北京:机械工业出版社,2009
- [18] Chen T, Chen H, Liu R-W. Approximation Capability in $C(\bar{R}^n)$ by Multilayer Feedforward Networks and Related Problems [J]. IEEE Transactions on Neural Networks, 1995, 6(1): 25-30
- [19] 褚辉,赖惠成. 一种改进的 BP 神经网络算法及应用[J]. 计算机仿真,2007,24(4):75-77

(上接第 400 页)

GS_2 、 GS_3 即停止,无法完成服务组合,服务组合满意度为 0,未满足用户需求。

由此可以看出,本文提出的基于语义推理和相似度相结合的服务组合算法,与文献[1]提出的 TPM 比较,在服务间语义关联度较弱的情况下,具有更强的服务匹配能力,提高了用户请求与服务间的输出参数以及中间服务间输出参数与输入参数的匹配概率。

4.4 算法效率实验

算法效率实验中,选取如表 1 所列的 7 个服务实例以及随机产生一定数量的干扰服务作为测试用例,当干扰服务样本数量分别为 100、400、600、800、1000、1200、1400、1600、1800、2000 时,与 TPM 算法的算法效率的仿真结果如图 3 所示。




图 3 服务组合算法效率比较

由图 3 可以看出,由于算法 TPM 采用了服务聚类方法对网络服务组合进行了预处理,且在服务匹配过程中直接采用语义相似度的计算方法来获得服务间的关联程度,因此其在执行效率上优于本文算法。可以考虑在本文算法中加入文献[1]提出的服务聚类方法,以降低服务匹配次数从而提高算法效率。

实例分析表明:本文提出的 LMDSCM 算法,由于将用户请求与服务之间、服务与服务之间输入输出参数的匹配程度划分为: *exactM*、*superM*、*subM*、*partM*、*failM* 5 个匹配等级,并运用基于语义相似度的计算方法对匹配度进行量化计算,将其作为服务组合图构建时边的权值进行赋值,为利用最短路径法确定最优服务组合提供了计算依据。由于采用由粗粒度离散量匹配到细粒度服务匹配度量化计算的两阶段匹配算法,因此服务间的匹配概率明显优于仅考虑语义关联度计

算的 TPM 算法,具有较高的服务组合满意度。

结束语 本文基于语义推理和语义相似度计算方法,提出了弱关联程度下的服务匹配算法 LMDSCM,其以服务匹配度作为服务组合图构建的依据,采用最短路径法完成最优服务组合路径的选择和服务组合满意度的计算。LMDSCM 算法与基于 workflow 模型的服务组合方法相比,具有较高的自动化程度,与一般基于语义的服务组合算法相比具有更高的匹配概率,与文献[1]提出的 TPM 算法相比具有更高的服务组合满意度。但由于算法采取粗粒度和细粒度的分阶段计算方法,因此算法效率低于 TPM。可采用 TPM 提出的服务聚类方法对服务集合进行预处理,达到提高算法效率的目的。

参考文献

- [1] 倪晚成. 基于概念关联程度的网络服务组合方法[J]. 清华大学学报:自然科学版,2007,47(10):581-585
- [2] 李玉鑫. 基于本体的动态 Web 服务组合的研究与应用[D]. 大连:大连理工大学,2008:21-22
- [3] Pfeffer H, Linner D, Steglich S. Modeling and Controlling Dynamic Service Compositions[C]// Computing in the Global Information Technology, The Third International Multi-Conference on (ICCGI '08). 2008:210-216
- [4] Papazoglou M P, Traverso P, Dustdar S, et al. Service Oriented Computing: State of the Art and Research Challenges[J]. Computer, 2007, 40(11): 38-45
- [5] Narayanan S, McIlraith S A. Simulation, Verification and Automated Composition of Web Services[C]// Proceedings of the eleventh international conference on World Wide. 2006:77-88
- [6] McDermott D. Estimated-regression planning for interactions with services[C]// Proc. of the 6th International Conference on AI Planning and Scheduling. Toulouse France, AI Press, 2005
- [7] Shina D-H, Lee K-H, Sudab T. Automated generation of composite Web services based on functional semantics[J]. Web Semantics: Science, Services and Agents on the World Wide Web, 2009(7): 332-343
- [8] 宋巍,马晓星,吕建. Web 服务组合动态演化的实例可迁移[J]. 计算机学报,2009,32(9):1816-1831