

基于量子自适应粒子群优化径向基函数神经网络的网络流量预测

郭通* 兰巨龙 李玉峰 江逸茗

(国家数字交换系统工程技术研究中心 郑州 450002)

摘要: 该文提出一种量子自适应粒子群优化算法,该算法中,粒子位置的编码采用量子比特实现,利用粒子飞行轨迹信息动态更新量子比特的状态,并引入量子非门实现变异操作以避免陷入局部最优。用该算法训练神经网络,实现了径向基函数(RBF)神经网络参数优化,建立了基于量子自适应粒子群优化 RBF 神经网络算法的网络流量预测模型。对真实网络流量的预测结果表明,该方法的收敛速度和预测精度均要优于传统 RBF 神经网络法、粒子群-RBF 神经网络法、混合粒子群-RBF 神经网络法和自适应粒子群-RBF 神经网络法,并且预测效果不易受时间尺度变化的影响。

关键词: 径向基函数神经网络; 自适应粒子群优化; 量子比特; 流量预测

中图分类号: TP393

文献标识码: A

文章编号: 1009-5896(2013)09-2220-07

DOI: 10.3724/SP.J.1146.2012.01343

Network Traffic Prediction with Radial Basis Function Neural Network Based on Quantum Adaptive Particle Swarm Optimization

Guo Tong Lan Ju-long Li Yu-feng Jiang Yi-ming

(National Digital Switching System Engineering & Technological R&D Center, Zhengzhou 450002, China)

Abstract: A novel Quantum Adaptive Particle Swarm Optimization (QAPSO) method is proposed. In this algorithm, the position encoding of the particle is achieved with quantum bits, and the state of quantum bit is updated dynamically with particle trajectory information. Then the mutation operation is performed by quantum non-gate to avoid falling into local optimum, which increases the diversity of particles. Afterwards, the Radial Basis Function (RBF) neural network is trained with QAPSO to implement the optimization of RBF neural network parameters. The network traffic prediction model is established based on the Quantum Adaptive Particle Swarm Optimization and RBF Neural Network (QAPSO-RBFNN). Forecasting results on real network traffic demonstrate that the convergence speed of the proposed method is faster and prediction accuracy is more accurate than that of traditional RBF neural network, the Particle Swarm Optimization and RBFNN (PSO-RBFNN), Hybrid Particle Swarm Optimization and RBFNN (HPSO-RBFNN), Adaptive Particle Swarm Optimization and RBF Neural Network (APSO-RBFNN). Furthermore, the forecasting effect of this method is stable on different scales.

Key words: Radial Basis Function Neural Network (RBFNN); Adaptive Particle Swarm Optimization (APSO); Quantum bit; Traffic prediction

1 引言

网络流量的建模与预测对于大规模网络的规划设计、网络资源管理以及用户行为的调节等方面具有重要意义^[1]。神经网络以其良好的非线性映射能力和对历史数据的强大的训练学习能力而被广泛地应用于流量数据的建模及预测方面。径向基函数(Radial Basis Function, RBF)神经网络是近年较为

常用的网络流量预测工具,文献[2]利用 RBF 神经网络对网络流量建模,同时进行了预测,并取得了较好的效果,但径向基层与输出层间联接权的求解存在病态问题,而且径向基层单元参数的设置是基于参数空间局部信息的,不是参数空间的全局最优值^[3]。对于具有随机性的网络流量而言,要达到较高的预测精度,必须对其结构参数从全局进行动态搜索。

粒子群优化(Particle Swarm Optimization, PSO)算法是一种基于群智能的随机全局优化计算方法^[4]。该算法以其建模简单、收敛速度快且易于实现等优点,在组合优化^[5]、多目标辨识^[6]、资源分

2012-10-19 收到, 2013-05-03 改回

国家 973 计划项目(2012CB315900)和国家 863 计划项目(2011AA01A103)资助课题

*通信作者: 郭通 guotong1984@yahoo.com.cn

配^[7]、聚类分析^[8]、神经网络训练^[9]等领域得到了广泛的应用。同时，这也推动了将 PSO 算法与 RBF 神经网络相结合的研究，相关文献先后提出了 PSO 优化 RBF 神经网络(PSO-RBF)^[10]、混合粒子群优化 RBF 神经网络(HPSO-RBF)^[11]和自适应粒子群优化 RBF 神经网络(APSO-RBF)^[12]等方法。然而，尽管这些 PSO 算法使得 RBF 网络能够获得更为优越的收敛性能和较低的出错率，但它们也呈现出了不少亟需改进的问题，即要么算法的全局寻优能力得以提升时，而收敛速度却降低了，要么算法的收敛速度提高时，而陷入局部极值的情况又增多了。因此，如何做到收敛速度和全局寻优能力的有效兼顾已成为当前 PSO 算法研究中的热点方向。

近年来，量子计算(Quantum Computing, QC)以其具有的高度并行性、指数级存储容量和对经典的启发式算法的指数加速作用等特点^[13]引起了广泛关注。PSO 算法与量子计算有许多可类比之处，故而，它们之间的融合在理论上有着良好的预期。本文受文献[14]提出的 APSO 算法的启发，并在此基础上改进，融合量子计算方法，提出了一种量子自适应粒子群优化(QAPSO)算法。将该算法用来优化 RBF 神经网络参数，建立了基于量子自适应粒子群优化 RBF 神经网络(QAPSO-RBFNN)的流量预测模型。

全文结构如下：第2节介绍 RBF 网络模型和参数选择问题；第3节提出 QAPSO 算法；第4节描述 QAPSO-RBFNN 算法的具体实现流程；第5节使用真实网络流量对本文提出的算法进行测试，并与现有的4种方法进行比较；第6节是结束语。

2 RBF 神经网络结构和参数选择

RBF 神经网络结构如图1所示^[5]。

图1中，径向基函数采用高斯函数：

$$\phi_i(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{2\sigma_i^2}\right), \quad 1 \leq i \leq N \quad (1)$$

RBF 网络的输出为

$$\mathbf{y} = \sum_{i=1}^N \mathbf{w}_i \exp\left(-\frac{\|\mathbf{X} - \mathbf{C}_i\|^2}{2\sigma_i^2}\right) \quad (2)$$




图1 RBF 神经网络结构

式中 $\mathbf{X} \in \mathbf{R}^n$ 为输入向量， $\phi(\cdot)$ 是高斯核函数， $\|\cdot\|$ 是欧几里德范数， \mathbf{w}_i 为隐藏层和输出之间的连接权值， \mathbf{C}_i, σ_i 分别为高斯函数的中心和宽度， N 为隐藏层神经元数， m 为输入向量数。

在 RBF 神经网络参数选择前，必须确定好隐藏层神经元数，即训练集的群数。一旦隐藏层神经元数确定后，RBF 的性能就依赖于网络参数的选择。本文采用对手受罚的竞争学习(Rival Penalized Competitive Learning, RPCL)算法^[15]来确定群数，应用 QAPSO 方法搜索 RBF 神经网络的3类参数：(1)基函数中心 \mathbf{C}_i ；(2)基函数宽度 σ_i ；(3)输出层权值 \mathbf{w}_i 。

3 量子自适应粒子群优化算法

3.1 PSO 算法基本原理

设在一个 D 维的目标搜索空间中，由 N 个粒子组成一个群落，其中第 i 个粒子的位置表示为向量 $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{iD}]$ ，速度为向量 $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ ，第 i 个粒子“飞行”历史中的过去最优位置为 $\mathbf{P}_i = [p_{i1}, p_{i2}, \dots, p_{iD}]$ ，整个粒子群搜索到的最优位置 $\mathbf{P}_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 。将 \mathbf{X}_i 代入目标函数计算其适应值，每个粒子的速度和位置更新策略分别为

$$v_{id}(t+1) = w * v_{id}(t) + c_1 * r_{1d} * (p_{id}(t) - x_{id}(t)) + c_2 * r_{2d} * (p_{gd}(t) - x_{id}(t)) \quad (3)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (4)$$

其中 $i=1, 2, \dots, N$; $d=1, 2, D$ ；在式(3)中， w 是惯性加权； c_1, c_2 是加速系数； r_{1d}, r_{2d} 为 $[0, 1]$ 之间的随机数； p_{id} 为粒子本身所找到的最优解，即个体极值； p_{gd} 是整个粒子群目前找到的最优解，称之为全局极值。

3.2 QAPSO 算法

QAPSO 算法主要由种群初始化、进化状态估计、参数自适应控制和变异处理4部分组成。

3.2.1 种群初始化 量子比特是一个双态量子系统，其与经典比特的不同之处就在于它可以落在 $|0\rangle$ 和 $|1\rangle$ 之外的线性组合态，通常称其为叠加态^[16]，即

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (5)$$

其中 α 和 β 是一对复数，称为量子态的概率幅，且满足

$$|\alpha|^2 + |\beta|^2 = 1 \quad (6)$$

同传统 PSO 一样，QAPSO 算法首先也要对粒子的位置进行初始化，直接采用量子位的概率幅作为粒子当前位置的编码。对于第 i 个粒子，其位置编码表示为

$$\mathbf{X}_i = \begin{bmatrix} x_{\alpha_{i1}} & x_{\alpha_{i2}} & \cdots & x_{\alpha_{ij}} & \cdots & x_{\alpha_{iD}} \\ x_{\beta_{i1}} & x_{\beta_{i2}} & \cdots & x_{\beta_{ij}} & \cdots & x_{\beta_{iD}} \end{bmatrix} \quad (7)$$

其中 $i=1,2,\dots,N$; $j=1,2,\dots,D$; N 是种群规模; D 是空间维数。 $x_{\alpha_{ij}}$ 和 $x_{\beta_{ij}}$ 分别为 x_{ij} 对应量子态 $|0\rangle$ 和 $|1\rangle$ 的概率幅, 初始值均设为 $1/\sqrt{2}$ 。由此可见, 每个粒子在种群空间中占据着两个位置, 分别对应于状态 $|0\rangle$ 和 $|1\rangle$ 的概率幅为

$$X_{i\alpha} = [x_{\alpha_{i1}}, x_{\alpha_{i2}}, \dots, x_{\alpha_{ij}}, \dots, x_{\alpha_{iD}}] \quad (8)$$

$$X_{i\beta} = [x_{\beta_{i1}}, x_{\beta_{i2}}, \dots, x_{\beta_{ij}}, \dots, x_{\beta_{iD}}] \quad (9)$$

因此, 种群中每个粒子的位置 $X_{i\alpha}$ 和 $X_{i\beta}$ 对应优化问题的两个解, 从而极大扩展了算法搜索的遍历性。

3.2.2 进化状态估计 进化状态估计过程如下:

步骤 1 对于每个粒子 i , 采用等式(10)估计它与其它粒子的平均距离:

$$d_{ix} = \frac{1}{N-1} \sum_{j=1, j \neq i}^N \sqrt{\sum_{k=1}^D (x_{ik} - x_{jk})^2} \quad (10)$$

其中 N 和 D 分别为粒子群个数和空间维数。

步骤 2 类似于式(10), 粒子与其它粒子的平均速率差异可按式(11)计算得出:

$$d_{iv} = \frac{1}{N-1} \sum_{j=1, j \neq i}^N \sqrt{\sum_{k=1}^D (v_{ik} - v_{jk})^2} \quad (11)$$

步骤 3 在粒子群优化算法中, 粒子的飞行轨迹是由位置和速度共同决定的, 综合式(10)和式(11), 定义一种混合平均距离与平均速率差异信息的粒子平均轨迹差异 d_{ic} , 为

$$d_{ic} = d_{ix} + \rho_{X_i V_i} * d_{iv} \quad (12)$$

$$\begin{aligned} \rho_{X_i V_i} &= \frac{E(\mathbf{X}_i \mathbf{V}_i) - E(\mathbf{X}_i)E(\mathbf{V}_i)}{\sqrt{E(\mathbf{X}_i^2) - E^2(\mathbf{X}_i)}\sqrt{E(\mathbf{V}_i^2) - E^2(\mathbf{V}_i)}} \\ &= \frac{\sum_{j=1}^D x_{ij} v_{ij} - \frac{1}{D} \sum_{j=1}^D x_{ij} \sum_{j=1}^D v_{ij}}{\sqrt{\sum_{j=1}^D x_{ij}^2 - \frac{1}{D} \left(\sum_{j=1}^D x_{ij} \right)^2} \cdot \sqrt{\sum_{j=1}^D v_{ij}^2 - \frac{1}{D} \left(\sum_{j=1}^D v_{ij} \right)^2}} \end{aligned} \quad (13)$$

其中 $\rho_{X_i V_i}$ 为位置 \mathbf{X}_i 和速度 \mathbf{V}_i 的皮尔逊相关系数 (Pearson Correlation Coefficient, PCC)。

步骤 4 比较所有的 d_{ic} , 确定最大轨迹差异 d_{cmax} 和最小轨迹差异 d_{cmin} 。设 d_{cg} 为全局最优粒子与其它粒子的平均轨迹差异。定义基于平均轨迹差异的进化因子 f_c 为

$$f_c = \frac{d_g - d_{cmin}}{d_{cmax} - d_{cmin}} \in [0, 1] \quad (14)$$

步骤 5 将 f_c 值通过模糊集映射函数分类为探测、开拓、收敛和跃出 4 种不同的状态。

3.2.3 参数自适应控制 惯性权重是用来平衡粒子群的全局和局部搜索能力, 在 QAPSO 中, 按照式(15)调整惯性权重, 并采用表 1 中的规则来调整不同状态时的加速系数。

$$w_c(f_c) = \frac{1}{1 + 1.5e^{-2.6f_c}} \in [0.4, 0.9], \quad \forall f_c \in [0, 1] \quad (15)$$

表 1 加速系数 c_1 和 c_2 的调整策略

状态	c_1	c_2
探测	增加	减少
开拓	微增	微减
收敛	微增	微增
跃出	减少	增加

表 1 中的“微”调采用式(16)来定量定义。

$$c_i(g+1) = c_i(g) \pm \delta, \quad i = 1, 2 \quad (16)$$

其中 δ 为 $[0.05, 0.1]$ 范围内均匀产生的随机数。

3.2.4 变异处理 在 QAPSO 算法中引入变异算子, 依变异概率对收敛状态时全局最优粒子的量子位施加量子非门变换, 使该粒子量子位的两个概率幅互换。这样可使粒子代表的两个空间位置同时得到变异, 不仅扩展了对种群空间的遍历能力, 能够避免算法陷入局部最优, 而且实现简单。令 $[p_{\alpha_i}, p_{\beta_i}]^T$ 为全局最优粒子历史最佳位置的第 i 个量子比特 p_{g_i} , 由量子非门实施变异操作的过程可描述为

$$\begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} p_{\alpha_i} \\ p_{\beta_i} \end{bmatrix} = \begin{bmatrix} p_{\beta_i} \\ p_{\alpha_i} \end{bmatrix}, \quad 1 \leq i \leq D \quad (17)$$

4 QAPSO 训练 RBF 神经网络

QAPSO 训练 RBF 神经网络算法的实现步骤可概括如下:

步骤 1 确定 RBF 神经网络的拓扑结构;

步骤 2 初始化粒子群: 确定粒子数 N 及空间维数 D , 设定最大迭代代数 t_{max} , 指定位置和速度的上限及下限, 随机生成粒子速度 \mathbf{V}_i , 根据式(7)生成粒子位置的初始编码 \mathbf{X}_i , 并使 $\mathbf{P}_i = \mathbf{X}_i$;

步骤 3 构造 RBF 神经网络, 将每个粒子的位置向量 \mathbf{X} 对应的状态 $|0\rangle$ 和 $|1\rangle$ 的概率幅分别表示 RBF 神经网络参数(初始连接权值 \mathbf{w}_i , 中心节点宽度 σ_i 和中心节点位置 \mathbf{C}_i)的两个解集合;

步骤 4 使用训练样本集训练 RBF 网络;

步骤 5 采用适应度函数对每个粒子进行适应度评估, 得到初始的个体历史最佳位置和全局历史最佳位置, 相应的量子位状态就是初始的个体历史最佳状态和全局历史最佳状态;

步骤 6 开始迭代, 进化代数增加 1;

步骤 7 对粒子群中所有粒子, 执行如下操作:

(1)根据式(10)~式(13)得到粒子的平均轨迹差异, 根据式(14)和式(15)更新惯性加权, 根据表 1 中策略和式(16)调整加速系数, 在上述参数更新的基础上, 应用式(3), 式(4)实现粒子位置和速度更新;

(2)对更新状态后的粒子的适应度值进行评估, 若粒子当前位置优于自身历史最佳位置, 则用当前位置替换, 更新个体最优位置; 若当前个体历史最优位置优于到目前为止搜索到的全局最优位置, 则用此个体历史最优位置替换全局历史最优位置, 并将此粒子当前状态作为全局历史最佳状态;

步骤 8 为了防止算法陷入局部最优, 当全局最佳适应度值在一定代数内没有变化时, 对全局历史最佳状态的粒子, 根据式(17)实现变异操作。如果变异后粒子的适应度值优于原值, 则用其当前位置取代全局历史最优位置, 并更新粒子状态;

步骤 9 判断是否满足收敛条件或达到代数最大限制, 若满足则确定 RBFNN 相应的最佳参数, 转向步骤 10; 否则, 转向步骤 7;

步骤 10 使用步骤 9 得到的 RBFNN 最优参数组合进行时间序列预测。

5 网络流量预测的应用实例

5.1 数据来源与仿真环境

本文采用贯穿太平洋主干链路(MAWI 数据集)采样节点 F 上^[17]的 3 组不同时间粒度的网络数据进行仿真分析。一组来自于 2005 年 9 月 13 日从 14:00~14:15 的 15 min 的流量(对其 1 s 时间尺度上的流量字节数进行聚集, 获得数据 MAWI01, 时间粒度为 s, 数据长度为 900, 见图 2(a)), 一组来自于 2009 年 3 月 30 日 0:00 至 4 月 2 日 23:45 的 96 h 长的

流量(MAWI02, 时间粒度为 15 min, 数据长度为 384, 见图 2(b)), 另一组来自于 2010 年 1 月 1 日至 2012 年 5 月 25 日通过该主干链路 876 d 的流量(MAWI03, 时间粒度为 d, 数据长度为 876, 见图 2(c))。

由于流量数据差别较大, 直接用于训练容易引起预测精度的波动, 同时为了加快神经网络的收敛速度, 需要对网络流量数据进行预处理, 将它们归一化到[0,1]区间范围内。

$$\delta_{\text{norm}} = (\delta - \delta_{\text{min}}) / (\delta_{\text{max}} - \delta_{\text{min}}) \quad (18)$$

其中 δ_{max} 和 δ_{min} 分别代表网络流量数据集中最大值和最小值, δ 为原始流量数据值, δ_{norm} 表示归一化值。

本文中所使用的仿真软件为 MATLABR 2008b, 仿真环境: CPU 为 Intel Pentium 4 3.20 GHz, 内存为 2 GB, 操作系统为 Microsoft Windows XP Professional SP2。各文献 PSO 算法的初始参数设置如表 2 所示。为了保证比较的公平性, 所有 PSO 均采用: 粒子数 $N=30$, 空间维数 D 为 24, 最大迭代次数 $t_{\text{max}}=200$ 。

5.2 网络流量预测精度比较

针对 MAWI01, MAWI02 和 MAWI03 流量序列, 将其前 600 个、前 256 个和前 584 个数据作为训练数据, 用于参数估计及模型建立; 后 300 个、128 个和 292 个数据作为预测数据, 用来检测预测

表 2 各文献 PSO 算法的参数设置

参考文献	算法	参数
[10]	PSO	$w: 0.9-0.4, c_1=c_2=2$
[11]	HPSO	$w: 0.8-0.2, c_1=c_2=2.5, V_{\text{MAX},d}=0.5 \times \text{Range}$
[12,14]	APSO	自动选择
本文	QAPSO	$w: 0.9-0.4, c_1: 1.5-2.5, c_2: 1.5-2.5, \delta: 0.05-0.10, r_{1,d}: 0-1, r_{2,d}: 0-1, V_{\text{MAX},d}=\text{Range}$




图 2 3 组不同时间粒度的网络流量时序图

值与实际值的差别。以RBF神经网络均方误差MSE (Mean Square Error)作为适应度评估函数。

$$F = \frac{1}{n} \sum_{i=1}^n [\hat{x}(i) - x(i)]^2 \quad (19)$$

(19)式中, n 表示流量数据的个数, $\hat{x}(i)$ 为网络流量预测数据的第 i 个值, $x(i)$ 为实际网络流量数据的第 i 个值。为了检验预测效果,用平均绝对误差MAE (Mean Absolute Error)、均方误差MSE和归一化均方误差NMSE(Normalized Mean Square Error)等指标对性能进行评价,MAE和NMSE的定义如下:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (20)$$

$$\text{NMSE} = \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (21)$$

其中 \bar{x} 为实际网络数据集的平均值。显然,MAE和

NMSE值越小,说明预测精度越高。

首先,我们采用RPCL算法确定隐藏层神经元数为8。然后,采用本文提出的QAPSO-RBFNN方法对这3组流量数据进行建模与预测,预测结果如图3所示。横坐标为采样时间单元,纵坐标为归一化后的网络流量值。从图3中可以看出,对于不同时间尺度下的流量数据,QAPSO-RBFNN方法的预测值与真实网络流量的重合度均较高。

为了进一步说明本文方法的预测效果,表3定量比较了它与RBFNN, PSO-RBFNN, HPSO-RBFNN, APSO-RBFNN 4种方法对这3组经过预处理的流量数据的具体预测性能指标。我们发现,在3组不同时间粒度的网络流量数据的预测中,QAPSO-RBFNN方法的预测结果MAE, MSE和NMSE均低于其它几种方法,这说明:相比于现有的4种方法,QAPSO-RBFNN算法具有更高的预测精度,且预测效果不易受流量数据时间尺度变化的影响。

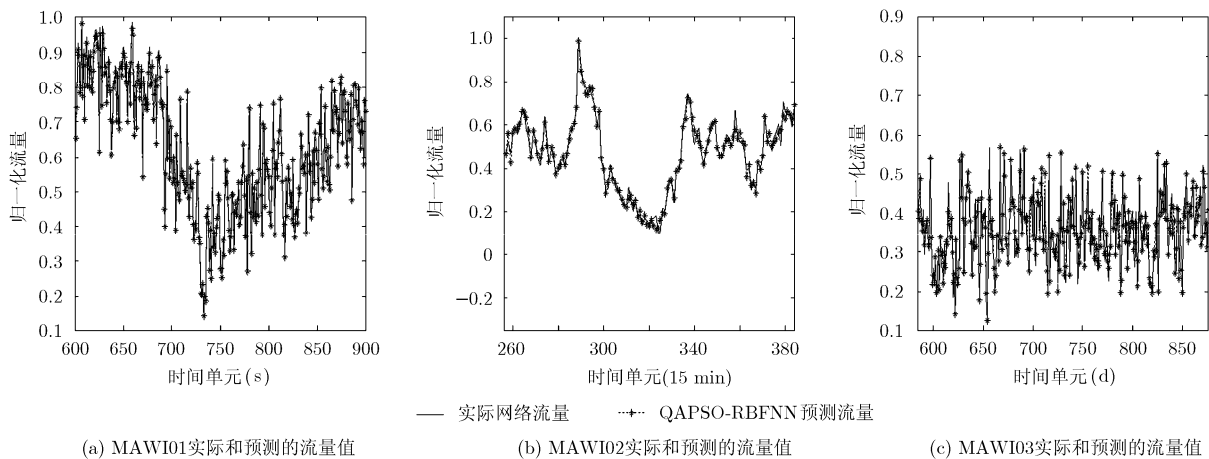


图3 各算法对3组流量数据预测结果的比较

表3 各种方法对3组不同粒度网络流量的预测性能指标

预测误差	流量数据	RBFNN神经网络方法	PSO-RBFNN神经网络方法	HPSO-RBFNN神经网络方法	APSO-RBFNN神经网络方法	QAPSO-RBFNN神经网络方法
MAE	MAWI01	0.1310	0.0981	0.0789	0.0579	0.0427
	MAWI02	0.0998	0.0833	0.0653	0.0474	0.0314
	MAWI03	0.0606	0.0487	0.0373	0.0200	0.0116
MSE	MAWI01	6.5170	4.6080	2.8835	1.8205	0.8730
	MAWI02	2.0748	1.5045	0.8978	0.4836	0.1869
	MAWI03	1.6687	1.0852	0.6614	0.2883	0.1462
NMSE	MAWI01	0.5957	0.4212	0.2636	0.1664	0.0798
	MAWI02	0.5261	0.3815	0.2277	0.1046	0.0474
	MAWI03	0.6416	0.4107	0.2503	0.1091	0.0553

5.3 算法的优化性能比较

对 MAWI01, MAWI02 和 MAWI03 分别进行建模与预测时, PSO-RBF 算法、HPSO-RBF 算法、APSO-RBF 算法与本文提出的 QAPSO-RBF 算法的收敛曲线的对比见图 4(a)~4(c)。横坐标为粒子群的迭代次数, 纵坐标是适应度函数 MSE 的适应度值。

在图 4(a)中, PSO-RBF, HPSO-RBF, APSO-RBF 与 QAPSO-RBF 算法的适应度函数达到稳定时的迭代代数分别为 149, 135, 122 和 110; 在图 4(b)中, 对应的迭代代数分别为 138, 120, 105 和 90; 在图 4(c)中, 对应的迭代代数则为 126, 121, 115 和 104。其相应的函数值从大到小依次均为 PSO-RBF, HPSO-RBF, APSO-RBF 和 QAPSO-RBF 算法。由于粒子群的适应度函数设定为 RBF 神经网络的训练误差, 适应度函数越大, 输出误差就越大, 可见, 相比于现有方法, QAPSO-RBF 算法模型不仅

具有较高的收敛精度, 同时具有较快的收敛速度。此外, 从图 4 中我们还可以看出, 相比于现有的粒子群算法, 本文提出的量子自适应粒子群算法在经过若干代运算之后仍保持较高的活性, 可以从局部最优中跳离出来, 极大地提高了对最优值的全局搜索能力。

5.4 算法的计算复杂度分析

按照“天下没有免费的午餐(No Free Lunch, NFL)”理论^[18], 一种算法不可能在每一个方面或在每一个问题上都能够提供比其它所有算法更好的性能。在我们的实验结果中也观察到了这点。考察算法在给定 300 次的迭代代数内对上述 3 组流量数据训练与预测的计算复杂度, 采用 5 种方法分别进行 30 次实验, 每种方法所需的平均计算时间如图 5 所示。从中可以看出: PSO-RBF 和 HPSO-RBF 的算法复杂度要明显高于其它算法, 而 QAPSO-RBF 的算法复杂度又要高于 APSO-RBF, RBF 算法的计算

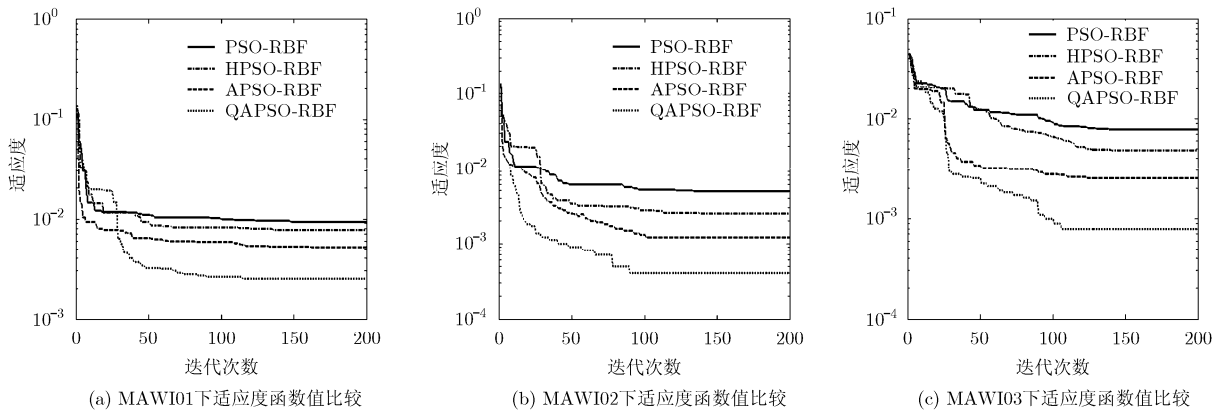


图 4 不同流量数据预测时各算法的收敛曲线

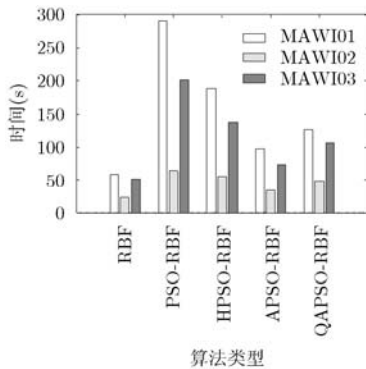


图 5 5 种不同算法的计算复杂度比较

能力最快。这表明, QAPSO-RBF 算法具有的较高收敛精度和较快的收敛速度是以牺牲一定计算复杂度为代价获得的, 并进一步验证了文献[18]中 NFL 理论的正确性。

6 结论

本文提出了一种量子自适应粒子群优化(QAPSO)算法, 基于量子位概率幅的编码机制扩展了 QAPSO 对种群空间的遍历能力, 有利于提高算法的优化效率; 算法充分利用了粒子的位置和速度信息, 能够实现对惯性权重与加速系数等参数的自适应控制; 在收敛状态基于量子非门的变异方式避免了算法陷入局部最优。应用 QAPSO 算法对 RBF 神经网络的权值、宽度和中心位置等网络参数进行快速、高精度的估计, 实现了 RBF 神经网络参数优化, 建立了基于 QAPSO-RBFNN 的网络流量预测模型。对真实网络流量的预测结果表明, 该方法的收敛速度和预测精度均要优于传统的 RBF 神经网络法、粒子群-RBF 神经网络法、混合粒子群-RBF 神经网络法和自适应粒子群-RBF 神经网络法, 并且预测效果不易受时间尺度变化的影响。

参 考 文 献

- [1] 王升辉, 裘正定. 结合多重分形的网络流量非线性预测[J]. 通信学报, 2007, 28(2): 45-57.
Wang Sheng-hui and Qiu Zheng-ding. Network traffic nonlinear prediction combined with multifractal[J]. *Journal on Communications*, 2007, 28(2): 45-57.
- [2] Wang J S and Gao Z W. Network traffic modeling and prediction based on RBF neural network[J]. *Computer Engineering and Applications*, 2008, 44(13): 6-11.
- [3] Pan Yumin, Huang Chengyu, and Zhang Quanzhu. A forecasting model of RBF neural network based on particle swarm optimization[J]. *Applied Mechanics and Materials*, 2011, 65: 605-612.
- [4] Kennedy J and Eberhart R. Particle swarm optimization[C]. Proceedings of IEEE International Conference on Neural Networks, 1995, 4: 1942-1948.
- [5] Chen W N, Zhang J, Chung H S H, *et al.* A novel set-based particle swarm optimization method for discrete optimization problem[J]. *IEEE Transactions on Evolutionary Computation*, 2010, 14(2): 278-300.
- [6] Zhang Tao, Hu Tiesong, Zheng Yue, *et al.* An improved particle swarm optimization for solving bi-level multiobjective programming problem[J]. *Journal of Applied Mathematics*, 2012, DOI: 10.1155/2012/626717.
- [7] Ho S Y, Lin H S, Liauh W H, *et al.* OPSO: orthogonal particle swarm optimization and its application to task assignment problems[J]. *IEEE Transactions on Systems, Man, Cybernetics: Systems, Humans*, 2008, 38(2): 288-298.
- [8] Niknam T and Amiri B. An efficient hybrid approach based on PSO, ACO and k-means for cluster analysis[J]. *Applied Soft Computing*, 2010, 10(1): 183-197.
- [9] Varshney Sarika, Srivastava Laxmi, and Pandit Manjaree. Parameter tuning of Statcom using particle swarm optimization based neural network[J]. *Advances in Intelligent and Soft Computing*, 2012, 130: 813-824.
- [10] Noman S, Shamsuddin S, and Hassanien A. Hybrid learning enhancement of RBF network with particle swarm optimization[J]. *Foundations of Computational, Intelligence*, 2009, 1: 381-397.
- [11] Gao H, Feng B, Hou Y, *et al.* Training RBF neural network with hybrid particle swarm optimization[J]. *Advances in Neural Networks*, 2006, 3971: 577-583.
- [12] Zhou Li-kun and Liu Hong-zhao. Operating parameter optimization of centrifuge based on APSO-RBF[C]. International Conference on Transportation, Mechanical, and Electrical Engineering (TMEE), Changchun, 2011: 2111-2114.
- [13] Shaktikanta Nayak, Sitakanta Nayak, and Singh J P. An introduction to quantum neural computing[J]. *Journal of Global Research in Computer Science*, 2011, 2(8): 50-55.
- [14] Zhan Z H, Zhang J, Li Y, *et al.* Adaptive particle swarm optimization[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2009, 39(6): 1362-1381.
- [15] Xu L, Krzyzak A, and Oja E. Rival penalized competitive learning for clustering analysis, RBF net, and curve detection[J]. *IEEE Transactions on Neural Networks*, 1993, 4(4): 636-649.
- [16] 李士勇, 李盼池. 求解连续空间优化问题的量子粒子群算法[J]. 量子电子学报, 2007, 24(4): 463-468.
Li Shi-yong and Li Pan-chi. Quantum particle swarms algorithm for continuous space optimization[J]. *Chinese Journal of Quantum Electronics*, 2007, 24(4): 463-468.
- [17] The MAWI working group traffic archive of the WIDE Project [EB/OL]. <http://traver.csl.sony.co.jp/mawi>.
- [18] Wolpert D H and Macready W G. No free lunch theorems for optimization[J]. *IEEE Transactions Evolutionary Computation*, 1997, 1(1): 67-82.
- 郭 通: 男, 1984 年生, 博士生, 研究方向为高速网络流量测量与流量预测.
- 兰巨龙: 男, 1962 年生, 博士, 教授, 博士生导师, 主要研究方向为宽带信息网络、高速路由器核心技术等.
- 李玉峰: 男, 1976 年生, 博士, 讲师, 主要研究方向为高速网络业务管控等.
- 江逸茗: 男, 1984 年生, 博士生, 研究方向为宽带信息网络.