

认知网络中基于蚁群算法的 网络流量预测模型

李丹丹,张润彤,王传臣,肖东坡
(北京交通大学信息系统研究所,北京 100044)

摘 要: 认知网络能够感知外部环境,并能根据周围环境的变化智能、自主、自适应的动态变化,这种特性更适合作为用户提供 QoS(Quality of Service)保障.设计高精度的流量预测模型,可以提高认知网络的认知特性.本文针对原有预测模型预测精度低、对训练数据依赖程度高以及不能很好的刻画网络流量特征的不足,提出了一个混合的流量预测模型.它使用蚁群算法训练 BP 网络的权值,避免了梯度下降法收敛速度慢、容易陷入局部最优的问题,并且在预测之前,首先使用 BP(Back Propagation)网络剔除原始数据中的异常数据信号,再对其进行小波分解,最后使用混合模型预测网络流量,实现了认知网络中高精度的流量预测.

关键词: 认知网络; 网络流量预测; 神经网络; 蚁群算法; 小波

中图分类号: TP393 **文献标识码:** A **文章编号:** 0372-2112 (2011) 10-2245-06

A New Network Traffic Prediction Model Based on Ant Colony Algorithm in Cognitive Networks

LI Dan-dan, ZHANG Run-tong, WANG Chuan-chen, XIAO Dong-po
(Institute of Information Systems, Beijing Jiaotong University, Beijing 100044, China)

Abstract: Cognitive networks can perceive the external environment, and intelligently and automatically change their behavior to adapt to the environment, so it is more suitable to provide users security with QoS. Designing a high-precision traffic prediction model can improve the cognitive feature of cognitive networks. For the models of low forecasting precision, highly independence to training samples and bad description of network traffic, we propose a new model. It trains BP with Ant Colony Algorithm, which avoids slow convergence speed and easily falling into local optimum problems existed in the gradient descent method. Besides, we reject the abnormal data using BP1, do wavelet decomposition, and predict the network traffic with hybrid model. Experimental results show its high-precision in cognitive networks.

Key words: cognitive networks; network traffic prediction; neural network; ant colony algorithm; wavelet

1 引言

认知网络(Cognitive Network)^[1]是具有认知过程、能感知当前网络条件,然后依据这些条件作出规划、决策和采取行动的网络.因其具有对网络环境的自适应能力,具有对于以前决策的评判和未来决策判定的学习能力,使得它能更好的为用户提供端到端的服务.随着多媒体应用的普及,网络的 QoS(Quality of Service)问题变得越来越重要,而认知网络的特性使得它能更好的为用户提供 QoS 保障.

网络流量特性反映了数据传输过程中的相互作用和影响,通过对流量数据的分析,有助于人们了解网络

内部运行机制并建立全面刻画流量过程的数学模型.设计具有认知特性的网络流量预测模型,能够使网络更加合理的进行带宽分配、流量控制、选路控制、接纳控制和差错控制等^[2],是提高 QoS 的有效途径.认知网络具有自主学习和自适应的特点,因此在认知网络的基础上研究流量的实时预测模型,可以很好地解决负载均衡滞后性的问题.而高精度的网络流量预测模型,特别是短期的流量预测模型,可以提高网络的认知特性.

2 文献综述

现有的网络流量预测分为线性预测和非线性预测.线性预测的方法如文献[3,4]的自回归移动平均模型

(Auto-Regressive Integrated Moving Average Model, ARIMA) 应用广泛,但是 ARIMA 的理论前提是网络流量具有线性宽平稳过程特征,而网络流量在不同的时间频率尺度上具有多尺度特征,并且具有多构性、自相似特性,因此使用 ARIMA 模型无法准确地描述出网络的全部特征。

神经网络 (Neural Network, NN) 具有很好的非线性逼近功能和自学习、自适应特点,这使得它在预测中相比其他时间序列方法^[5]显示出很大的优越性,近年来对于神经网络算法的研究也日益广泛^[6]。小波变换是处理非平稳时间序列最有效的一种方法,结合两者的优点,将小波变换与人工神经网络进行结合,出现了以小波神经网络为代表的非线性预测研究^[7],即小波神经网络 (Wavelet Neural Network, WNN),该模型是目前应用最广泛、最具代表性的模型之一。这些应用均很好的刻画了网络流量特征^[8,9],并且达到了较高的预测精度。目前应用广泛的是 BP 算法,主要是因为它依据坚实、推导过程严谨、通用性强。

蚁群算法^[10]是一种具有自适应特性的分布式算法,它具有快速、全局收敛以及启发式学习等特点。近些年出现了很多将蚁群算法和 BP 神经网络相结合的模型^[11-13],这样可以兼有神经网络的广泛映射能力和蚁群算法的快速、全局收敛以及启发式学习的特点,有效的避免神经网络收敛速度慢、容易陷入局部最优的问题。但是由于网络具有复杂性和不确定性,接入网络的用户也是复杂多样的,容易使网络流量产生异常值,从而影响到预测的精度。所以,有必要对原始数据进行预处理,剔除异常数据。

本文综合认知网络的特点,提出了一种新的流量预测模型。因为该模型中的 BP 网络使用两次,并用蚁群算法训练其权值,所以命名为 Ant Double-BP 模型。

3 Ant Double-BP 模型

本节将详细介绍 Ant Double-BP 模型的思路、步骤和 BP 网络训练过程。

3.1 模型思路

由于原始信号通常会存在一些异常,其一,这些数据对网络流量的预测没有意义,使用它们训练 BP 网络会增加模型复杂度,同时也降低了预测的准确度;其二,利用小波变换处理数据或是对数据进行归一化处理时,由于这些异常点的存在,势必对精度造成影响,从而影响预测的准确度。所以,本文首先使用异常信号剔除网络,即 BP1 网络,剔除异常的数据信号。

网络流量呈现出自相似、非稳定、多尺度特征,本文使用小波变换对流量数据信号进行预处理,使之变成平稳信号,并且处理后的信号要比原序列信号平滑得多,这样就提高了预测的精度。然后将小波分解得到

的小波变换尺度系数序列和小波系数序列分别作为 ARIMA 和 Elman 神经网络的输入,最后采用 BP2 神经网络对它们的输出结果整合,利用其很好的函数逼近功能预测,输出预测结果。

BP 神经网络采用梯度下降法,从数学角度看,它是一种局部搜索的优化算法,但它要解决的问题是求解复杂非线性函数的全局极值,所以容易出现局部最优,使训练失败。另外,网络的逼近、推广能力同学习样本的典型性密切相关,而从问题中选取典型样本实例组成训练集是一个很困难的问题。所以本文采用蚁群算法训练网络的权值,避免局部最优和收敛速度慢的问题,并且使其权值不受训练样本的约束。

3.2 Ant Double-BP 模型具体步骤

Ant Double-BP 模型的框架如图 1 所示。




图1 Ant Double-BP网络流量预测模型

根据 Kolmogorov 定理:只要使用三层 BP 神经网络模型就可以实现对一般非线性函数的刻画。所以 Ant Double-BP 模型中两个 BP 神经网络的结构均为三层,即一个输入层,单隐层,一个输出层。为了便于描述,我们把该模型的具体预测过程分为四个阶段:

第一阶段,异常数据剔除。该阶段使用 BP1 神经网络剔除原始数据中的异常数据信号。网络采用三层结构。输出层只包含一个节点:当数据信号有效时输出 1,当数据信号为异常的无效信号时输出 0。

第二阶段,小波分解。将所有输出结果为 1 的数据信号利用 Mallat 算法,即式(1)进行小波分解,使得原来非稳定、非线性、自相似的网络信号分解为两部分:具有平稳特征的尺度系数序列和低频小波系数序列。

$$\begin{cases} A_0(k) = f(k) \\ A_j(k) = 2^{-1/2}[A_{j+1}(2k) + A_{j+1}(2k+1)] \\ D_j(k) = 2^{-1/2}[D_{j+1}(2k) + D_{j+1}(2k+1)] \end{cases} \quad (1)$$

其中 $j \in [1, L]$, L 为分阶层数; $A_j(k)$, $D_j(k)$ 分别为近似信号和细节信号。

第三阶段,流量预测。本阶段使用的是两种模型的组合:使用 ARIMA 模型,对平稳的小波尺度系数序列预测;使用 Elman 网络模型,利用公式(2)对高频的小波系数序列预测。

$$\begin{cases} \mathbf{y}(k) = g(w_3 \mathbf{x}(k)) \\ \mathbf{x}(k) = f(w_1 \mathbf{x}_c(k) + w_2(\mathbf{u}(k-1))) \\ \mathbf{x}_c(k) = \mathbf{x}(k-1) \end{cases} \quad (2)$$

其中, y 为 m 维输出结点向量; x 为 n 维中间层结点单元向量; u 为 r 维输入向量; x_c 为 n 维反馈状态向量; w_1 为承接层到中间层的连接权值; w_2 为输入层到中间层的连接权值; w_3 为中间层到输出层的连接权值; $g(x)$ 为输出神经元的传递函数, 是中间层输出的线性组合; $f(x)$ 为中间层神经元的传递函数, 常采用 s 函数。

第四阶段, 减小误差整合. 使用 BP2 网络对第三阶段两个单个模型预测的输出数据进行整合, 这个阶段的主要任务是利用 BP 网络强大的函数逼近功能拟合数据, 减小由于单个模型预测造成的误差, 输出最后的预测结果。

3.3 蚁群算法训练 BP 网络权值

蚁群算法参照文献[13]. 表 1 所示是蚂蚁在第 n 条路径时携带的信息表, 记为 PTB_n , τ_{ni} 为携带的信息素值 ($i = 1, 2, \dots, p$); c_{ni} 表示 BP 网络的两节点之间是否连通, 即是否存在路径, 当 $c_{ni} = 0$ 时, 表示不连通, 此时权值 $w_{ni} = 0$; 当 $c_{ni} = 1$ 时, 表示连通, 此时权值为任意 $[-1, 1]$ 的随机数. p 表示网络中待估权值参数的总数。

表 1 蚂蚁携带的信息表 PTB_n

参数序号	信息素	路径连通情况	权值
Pa_{n1}	τ_{n1}	c_{n1}	w_{n1}
.....
Pa_{np}	τ_{np}	c_{np}	w_{np}

算法具体的步骤如下:

①初始化参数. 初始化表 1 中的所有参数, 其中 $\tau_{ni} = \tau_0$, 其余参数按规则取随机值. 以 $2 \times 2 \times 1$ 的 BP 网络为例, 第 1 只蚂蚁初始化的参数值如图 2 所示。

②蚂蚁路径遍历. 蚂蚁 k 从任意路径出发, 按式 (3) 和式 (4) 选择下一个节点, 直到遍历网络的所有路径. 图 3 为第 k 只蚂蚁遍历所有路径后的参数. 则训练后的网络结构即如图 4 所示. 同时, 计算 MSE 。

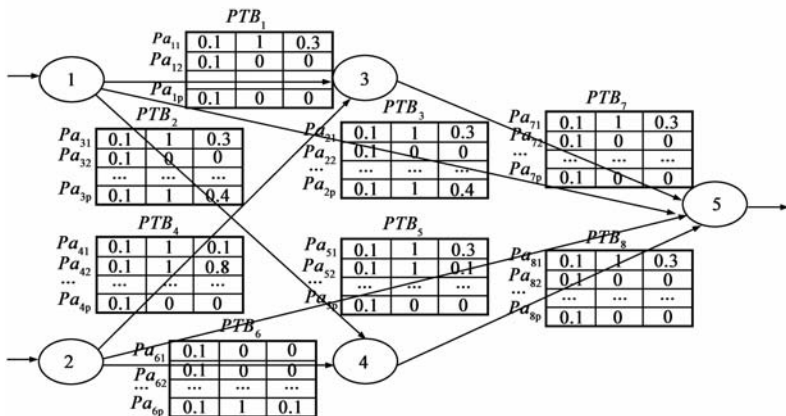


图 2 每条路径上的初始化参数值 PTB_n

$$i = \begin{cases} \operatorname{argmax}_{1 < i < p} \{ \tau_{ni} \}, & q \leq q_0 \\ p_{ni}, & \text{else} \end{cases} \quad (3)$$

$$p_{ni} = \tau_{ni} / \sum_{j=1}^p \tau_{nj} \quad (4)$$

其中, q 与 q_0 为随机数, τ 表示信息素的强度。




图 3 第 k 只蚂蚁遍历后参数




图 4 第 k 只蚂蚁遍历后网络结构即其权值

③更新局部信息素. 蚂蚁 k 遍历结束后, 按式 (5) 更新其所经历路径的信息素。

$$\tau_{ni} = (1 - \varphi) \tau_{ni} + \varphi \tau_0 \quad (5)$$

其中, 初始时刻各条路径上的信息量相等, 设 $\tau_{ni}(0) = c$; $\varphi \in (0, 1]$ 表示挥发系数。

④重复步骤 ②、③, 直到所有的蚂蚁都完成一次遍历。

⑤更新全局信息素. 按式 (6)、(7) 更新所有路径的信息素。

$$\tau_{ni} = \begin{cases} (1 - \rho) \tau_{ni} + \rho \Delta \tau_{ni}, & i \in \text{MSE}_{best} \\ \tau_{ni}, & \text{otherwise} \end{cases} \quad (6)$$

$$\Delta \tau_{ni} = 1 / \text{MSE}_{best} \quad (7)$$

其中, $\rho \in (0, 1)$ 为信息素残留系数; $\Delta \tau_{ni}$ 为在当前循环中的信息素增量;

⑥判断结束条件, 如果达到最大迭代次数或者到达预先指定的误差精度, 即转 ⑦; 否则转 ②。

⑦网络结构和权值的确定. 网络结构的确定使用 c_{ni} 的值, 去除 $c_{ni} = 0$ 的连接, 保留 $c_{ni} = 1$ 的连接即得到最后 BP 网络的结构. 权值即为蚁群算法最后收敛得到的一组权值。

⑧算法结束。

由上述整个算法可看到, 使用蚁群算法训练神经网络的权值完全脱离了对原始数据的依赖, 并且使得整个模型具有更好的自学习、自组织能力, 充分体现了算法的认知特性。

4 仿真分析

本节使用 MATLAB 对 Ant Double-BP 模型进行仿真分析, BP1 网络是 $9 \times 10 \times 1$ 的三层结构, BP2 网络参照文[11]为 $9 \times 10 \times 2$ 的三层结构. 随机数选择的步长定义为 0.01, 蚂蚁数量 30 只, 最大迭代次数为 100 次, $p = 60, q_0 = 0.9, \rho = 0.9$.

用于仿真的网络流量数据是来自于间隔时间 1 小时、某主干网核心路由器上的历史数据. 数据信号共 1040 个, 用于检测拟合效果的为其中的最后 140 个数据.

图 5 为网络流量数据曲线图, 横轴表示时间(小时), 纵轴表示流量数据(kb/sec), 收集到的数据信号范围为 $[0, 1816.73]$.




图5 原始数据信号曲线图

4.1 BP1 网络剔除异常数据

原始数据中存在由于网络设备或人为原因而出现的一些异常数据, 如流量为 0kb/sec 的时刻等.

图 6 为使用 BP1 网络剔除异常数据后的流量曲线图, 横轴表示时间(小时), 纵轴表示流量数据(kb/sec). 经过 BP1 网络即第一阶段后, 数据信号数量为 1001 个, 范围为 $[159.79, 1765.24]$.




图6 剔除异常数据后的流量曲线图

4.2 小波分解

对于图 6 的流量数据信号, 利用公式(1)进行小波分解. 取 $L = 5$, 即分解后的小波系数序列为 $\{D1(k), D2(k), D3(k), D4(k), D5(k), A5(k)\}$ 原始信号 $t = d1 + d2 + d3 + d4 + d5 + a5$, 结果如图 7 所示.

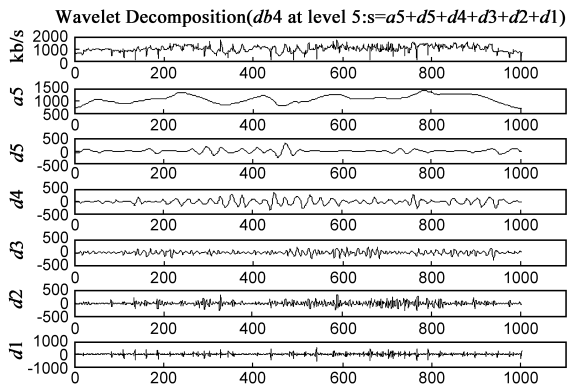


图7 数据信号的小波分解结果

图 7 中第一个图为第一阶段得到的原始信号, 第二个图 $a5$ 为分解后的低频信号, 第三个到第七个为分解后的高频信号 $d1, d2, d3, d4, d5$.

4.3 流量预测

将 $a5$ 输入到模型 ARIMA, $d1, d2, d3, d4, d5$ 输入到 Elman 神经网络, 再将两个模型的输出结果叠加作为输入, 输入到 BP2 网络进行流量的预测.

图 8 是 Ant Double-BP 模型对后 140 个数据预测的拟合结果, 预测时间为提前 1 小时的短期预测.




图8 新模型1小时短期预测拟合图

图 9 是 Ant Double-BP 模型对后 140 个数据预测的拟合结果, 预测时间为提前 2 小时的短期预测.




图9 新模型2小时短期预测拟合图

图 10 是 Ant Double-BP 模型对后 140 个数据预测的拟合结果, 预测时间为提前 24 小时的短期预测.




图10 新模型24小时短期预测拟合图

WNN 模型是本文所提出模型的基础, 并且其应用广泛, 具有代表性. 图 11 是 Ant Double-BP 模型与 WNN 模型预测的比较图.

从图 8 和图 9 可以看出, Ant Double-BP 模型在短期预测中的拟合程度很好, 预测精度较高. 虽然图 10 的




图11 新模型与WNN预测拟合比较图

24 小时预测曲线的拟合不如图 8 和图 9 好,但是误差较小,波动不明显,影响不大.图 11 与 WNN 模型的比较也表现出明显的优势.

为了清晰说明 Ant Double-BP 模型的性能,将该模型与 WNN 模型性能参数计算结果的列出,如表 2 所示.其中, SSE 为误差平方和, MRE 为相对误差, MAE 为绝对误差.

表 2 Ant Double-BP 模型性能参数

模型名称		$MSE/\%$	$SSE/\%$	$MRE/\%$	$MAE/\%$
WNN		1.74	10.57	21.14	7.57
Ant Double-BP (时间)	24h	1.90	8.26	22.79	7.97
	1h	1.09	4.59	14.38	3.52
	2h	1.25	6.21	17.56	16.74

5 结论

本文提出了具有很好的自组织和自学习能力的 Ant Double-BP 模型.通过 MATLAB 仿真分析并与 WNN 模型比较得出,该模型的预测精度高于以往的流量预测模型,主要体现在:

- (1) 使用蚁群算法训练 BP 网络的权值,解决了模型对训练样本的依赖问题;
- (2) 使用 BP 网络剔除了原始数据中的异常数据信号,提高预测精度;
- (3) 使用小波分解和组合模型,对不稳定的变化较大的网络流量也能提供高精度的预测.

但是, Ant Double-BP 模型本身比较复杂,预测所需的计算开销较大,使得模型的效率较低;同时,蚁群算法本身也存在一定的收敛等问题,所以,改进蚁群算法,再将其应用到训练 BP 网络,并且在保证模型高精度的同时进一步提高效率是本文以后的研究方向.

参考文献

[1] Thomas R W, DaSilva L A, Mackenzie A B. Cognitive networks[A]. Proc of IEEE DySPAN 2005[C]. Maryland, USA, 2005. 352 - 360.
 [2] 王兆霞,孙雨耕,陈增强,袁著祉.基于模糊神经网络的网

络业务流量预测研究[J].通信学报,2005,3(26):136 - 140.
 Wang Zhao-xia, Sun Yu-geng, Chen Zeng-qiang, Yuan Zhu-zhi. Study of predicting network traffic using fuzzy neural networks[J]. Journal on Communication, 2005, 3(26): 136 - 140. (in Chinese)
 [3] Sang Ai-min, Li San-qi. A predictability analysis of network traffic[A]. INFOCOM 2000, Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies [C]. Tel Aviv, Israel, 2000. 1. 342 - 351.
 [4] Yu Guo-qiang, Zhang Chang-shui. Switching ARIMA model based forecasting for traffic flow [A]. ICASSP' 04 [C]. Canana, 2004. 2. 429 - 432.
 [5] 姜明,吴春明,张旻,胡大民.网络流量预测中的时间序列模型比较研究[J].电子学报,2009,37(11):2353 - 2358.
 Jing Ming, Wu Chunming, Zhang Min, Hu Damin. Research on the comparison of time series models for network traffic prediction[J]. Acta Electronica Sinica, 2009, 37(11): 2353 - 2358. (in Chinese)
 [6] 丁世飞,贾伟宽,许新征,苏春阳.基于 PLS 的 Elman 神经网络算法研究[J].电子学报,2010,38(2A):71 - 75.
 Ding Shifei, Jia Weikuan, Xu Xinzhen, Su Chunyang. Elman neural network algorithm based on PLS[J]. Acta Electronica Sinica, 2010, 38(2A): 71 - 75. (in Chinese)
 [7] 徐晓霞,陈涛,王晓升.基于正交最小二乘法的小波神经网络[J].电子学报,1998,26(10):115 - 117, 137.
 Xu Xiaoxia, Chen Tao, Wang Xiaosheng. Wavelet neural network based on the algorithm of orthogonal least square[J]. Acta Electronica Sinica, 1998, 26(10): 115 - 117, 137. (in Chinese)
 [8] Wang Peng, Liu Yuan. Network traffic prediction based on improved BP wavelet neural network[A]. Wireless Communications, Networking and Mobile Computing [C]. Dalian, China, 2008. 1 - 5.
 [9] Zhao Qi-gang, Fang Xu-ming, Li Qun-zhan. WNN - based NGN traffic prediction[A]. Proc ISADS 2005[C]. Chengdu, China, 2005. 230 - 234.
 [10] 黄国锐,曹先彬,王煦法.基于信息素扩散的蚁群算法[J].电子学报,2004,32(5):865 - 868.
 Huang Guorui, Cao Xianbin, Wang Xufa. An ANT colony optimization algorithm based on pheromone diffusion[J]. Acta Electronica Sinica, 2004, 32(5): 865 - 868. (in Chinese)
 [11] 洪炳熔,金飞虎,高庆吉.基于蚁群算法的多层前馈神经网络[J].哈尔滨工业大学学报,2003,35(7):823 - 825.
 Hong Bing-rong, Jin Fei-hu, Gao Qing-ji. Multi-layer feedforward neural network based on ant colony system[J]. Journal of Harbin Institute of Technology, 2003, 35(7): 823 - 825. (in Chinese)
 [12] Gao Wei. Evolutionary neural network based on new ant colony algorithm[A]. IEEE/2008 International Symposium

on Computational Intelligence and Design[C]. IEEE, 2008. 318 – 321.

[13] Nikorn Pokudom. Determine of appropriate neural networks

structure using ant colony system[A]. ICROS-SICE International Joint Conference 2009 August 18 – 21[C]. Fukuoka International Congress Center, Japan, 2009. 4523 – 4525.

作者简介



李丹丹 女, 1982 年出生, 现为北京交通大学信息管理专业博士研究生, 研究方向为认知网络的 QoS 技术.

E-mail: lidandanhdj@163.com



王传臣 男, 1965 年出生, 现为北京交通大学信息管理专业博士研究生, 研究方向为互联网中的流量预测、流媒体业务的 QoS 技术.



张润彤 男, 1963 年出生, 博士, 教授、博士生导师, 目前研究方向包括下一代互联网的流量工程、移动通讯技术与应用.

E-mail: rtzhang@bjtu.edu.cn



肖东坡 男, 1969 年出生, 现为北京交通大学信息管理专业博士研究生, 研究方向为下一代互联网的智能技术应用.

(上接第 2239 页)

[8] X Zhang, Z Lv, W Wang. Performance analysis of multiuser diversity in MIMO systems with antenna selection[J]. IEEE Transactions on Wireless Communication, 2009, 7(1): 15 – 21.

[9] M O Hasna, M S Alouini. Harmonic mean and end-to-end performance of transmission systems with relays[J]. IEEE Transactions on Communication, 2004, 52(1): 130 – 135.

[10] 赵睿, 李春国, 王海荣, 杨绿溪. “Nakagami- m 衰落信道下固定增益中继系统性能分析[J]. 电子学报, 2011, 39(1): 162 – 167.

R Zhao, C G Li, H R Wang, L X Yang. Performance Analysis of Fixed Gain Relaying Systems in Nakagami- m Fading Channels[J]. Acta Electronica Sinica, 2011, 39(1): 162 – 167. (in Chinese)

[11] K S Ahn. Performance analysis of MIMO-MRC systems with

channel estimation error in the presence of cochannel interferences[J]. IEEE Signal Processing Letters, 2008, 15: 445 – 448.

[12] I S Gradshteyn, I M Ryzhik. Table of Integrals, Series, and Products, 6th ed[M]. San Diego, CA: Academic, 2000.

[13] M K Simon, M S Alouini. Digital Communication Over Fading Channels[M]. New York: Wiley, 2000.

[14] A Papoulis. Probability, Random Variables, and Stochastic Processes, 3rd ed[M]. New York: McGraw-Hill, 1991.

[15] M R McKay, A Grant, I B Collings. Performance analysis of MIMO-MRC in double-correlated Rayleigh environments[J]. IEEE Transactions on Communication, 2007, 55(5): 497 – 507.