



基于支持向量机的认知无线电频谱预测方法^{*}

徐元, 鲁华祥, 陈旭

(中国科学院半导体研究所 北京 100083)

摘要: 频谱预测是认知无线电系统中的关键技术之一, 利用该技术可以显著减少认知用户的能量损耗, 同时提高系统的频谱利用率。针对现有基于 BP 神经网络的频谱预测方法预测精度低及失效率高等问题, 将建立在统计学习理论和结构风险最小原则上的支持向量机引入认知无线电频谱预测中, 利用其对小样本及非线性数据优越的预测性能对信道进行预测。实验结果表明, 该方法通过避免无效检测, 提高了频谱感知系统的性能, 并且比基于 BP 神经网络算法的模型的预测精度更高, 具有良好的实用性与灵活性。

关键词: 认知无线电; 频谱预测; 支持向量机

doi: 10.3969/j.issn.1000-0801.2014.11.015

A SVM Based Spectrum Prediction Scheme for Cognitive Radio

Xu Yuan, Lu Huaxiang, Chen Xu

(Institute of Semiconductor, Chinese Academy of Science, Beijing 100083, China)

Abstract: Spectrum prediction is one of the key technologies in cognitive radio (CR) systems. This technology can reduce considerable energy consumed by spectrum sensing, and improve the overall system's spectrum utilization. Aiming at the low accuracy and invalid prediction problems of spectrum prediction in cognitive radio, a new prediction method was proposed by integrating support vector machine (SVM) which was based on statistical learning theory (SLT) and structural risk minimization principle (SRM). The channel status is forecasted by utilizing the excellent forecasting performance of the model in small sample and nonlinear data of SVM. The results show that by avoiding invalid prediction, the spectrum utilization can also be improved, and the forecasting accuracy is better than model based on back propagation (BP), thus the proposed algorithm is practicable and flexible for spectrum prediction in cognitive radio.

Key words: cognitive radio, spectrum prediction, support vector machine

1 引言

认知无线电作为一种解决当前无线通信中频谱利用率低下问题的重要技术, 通过检测未被授权用户占用的频谱空穴, 使得认知用户能够在不干扰授权用户正常通信的前提下使用空闲频段, 以提高频谱利用率。

在实际应用中, 认知用户将授权频谱划分为时隙结

构, 并在每个时隙内感知信道状态, 如果感知结果为空闲状态则认知用户可在不对授权用户造成干扰的前提下接入该频段进行数据传输。然而由于硬件条件限制, 认知用户在单个时隙内通常只能检测部分频谱, 而且为保证检测精度, 检测时间可能很长, 这将导致利用频谱空穴的机会减少。另外, 在大部分应用场合中, 认知用户的功耗也是设计者需要重点考虑的问题。因此, 频谱预测技术正在成为

^{*} 中国科学院战略性先导专项基金资助项目 (No.XDA06020700)



认知无线电领域的研究热点。

目前常用的频谱预测方法可归结为基于神经网络的预测方法^[1-3]、基于回归分析的预测方法^[4]、基于马尔科夫链的预测方法^[5,6]和数据挖掘方法^[7]。其中,神经网络方法由于其强大的非线性映射能力已经被应用于认知无线电频谱预测领域,并取得了一定效果。但是神经网络的方法存在预测失效的问题,这是由于网络拓扑结构和初始权值的选取存在不确定性,导致训练可能达不到预期效果。与建立在经验风险最小化原则上的 BP 神经网络相比,建立在统计学习理论和结构风险最小化原则上的支持向量机(SVM)具有更强的泛化能力^[8],它克服了神经网络方法收敛速度慢、结构和类型的选择过分依赖经验等缺点,被广泛应用于非线性预测领域^[9-11]。参考文献[1~3]提出了基于 BP 神经网络的频谱预测方法,可达到一定的预测精度。但是这种方法由于神经网络初始权值的选取存在不确定性,容易使训练达不到预期效果,导致预测失效;参考文献[12,13]针对基于 BP 神经网络方法的频谱预测方法的不足,分别提出了基于差分进化算法和 Levenberg-Marquardt (LM)算法改进的 BP 神经网络算法,预测精度得到了一定的改善;参考文献[14,15]提出了基于支持向量机的频谱预测方法。参考文献[14]中作者定性说明了在理想信道(历史信道占用状态信息已知)和非理想信道(历史信道占用信息通过频谱检测获得)两种状态下的预测性能,并与 BP 神经网络方法进行了比较,但并未定量给出具体预测精度。参考文献[15]着力于研究利用 SVM 对授权用户信号类型进行分类识别,同时给出了基于概率密度估计的频谱接入算法。参考文献[4]利用线性自回归预测方法对信道状态进行了预测,该方法在迭代求解过程中会出现 Hessian 矩阵不正定的情况,导致函数无法收敛,并且求解时间较长。参考文献[5,6]利用马尔科夫模型进行了信道状态预测,仿真结果表明该方法可有效预测频谱空洞。参考文献[7]提出了一种数据挖掘方法,通过大数据训练建立信道数据库,认知用户可以按查表匹配的方式对信道状态进行预测,该方法的不足之处在于需要存储大量数据,且训练时间过长。

本文通过在固定信道及时变信道下的仿真实验定量地给出了基于 SVM 方法的频谱预测方法与 BP 神经网络方法的预测精度对比,并对认知用户进行频谱预测时的能耗改善率和 SVM 方法的参数选取进行了详尽的分析研究。

2 基于支持向量机的频谱预测

2.1 支持向量机回归理论^[8-11]

假设给定训练样本集 $\{(x_i, y_i)\}_{i=1}^n$,其中, $x_i \in R^d$ 为输入变量, $y_i \in R$ 为对应的输出值。支持向量机的回归理论的基本思想是通过一个非线性映射 ϕ 将数据投影到高维特征空间 F 进行线性回归。根据统计学习理论确定如下回归函数:

$$f(x) = w\phi(x_i) + b \quad (1)$$

其中, $\phi(x)$ 是将样本点映射到高维空间的非线性变换, $w \in R^d$ 为权值矢量, $b \in R$ 为阈值。

根据结构风险最小化原则,原问题可转化为对如下优化目标函数求极值:

$$Q(w) = \frac{1}{2} \|w\|^2 + \frac{c}{n} \sum_{i=1}^n |f(x_i) - y_i|_\varepsilon \quad (2)$$

其中,第一项 $\|w\|^2$ 反映 $f(x)$ 在高维空间的复杂性;第二项表示训练集上的平均损失;惩罚因子 c 控制着模型复杂度和逼近误差的能力; ε 为不敏感损失函数:

$$|f(x_i) - y_i|_\varepsilon = \max\{0, |f(x_i) - y_i| - \varepsilon\} \quad (3)$$

不敏感损失函数控制着支持向量的个数及模型泛化能力。最小化式(2)等价于最小化泛函:

$$\min \left\{ \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n (\xi_i^* + \xi_i) \right\} \quad (4)$$

$$\text{s.t.} \begin{cases} f(x_i) - w\phi(x_i) - b \leq \xi_i + \varepsilon \\ w\phi(x_i) + b - f(x_i) \leq \xi_i^* + \varepsilon \\ \xi_i^* \geq 0, \xi_i \geq 0 \end{cases} \quad (5)$$

式(5)中的 ξ_i 和 ξ_i^* ($i=1,2,\dots,n$)为考虑到约束条件不能充分满足而引入的非负松弛变量。对于上述二次优化问题求解最优 w ,利用拉格朗日算子将其转化为其对偶形式求解:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (6)$$

其中, n 为支持向量的个数, α_i 和 α_i^* 为拉格朗日乘子, b 为阈值, $K(x_i, x)$ 为满足 Mercer 条件的核函数,它的作用是可以直接使用低维空间的输入变量求解高维特征空间中的线性问题,而无需知道式(1)中的映射函数 $\phi(x)$ 。

2.2 基于支持向量机的频谱预测模型

通常可以把信道状态预测问题看作一个二值的时间序列预测问题。通过对信道持续时间 T 的观测和感知,记录下每个时隙的信道状态,从而得到序列 $X^T = \{x_1, x_2, \dots, x_T\}$,其中信道被占用和空闲状态可分别由1和-1表示。在

SVM 的预测模型训练中,将整个序列分解为 $T-\tau$ 个长度为 τ 的向量作为输入向量,即 $x_{t-\tau+1}^T = [x_t, x_{t-1}, \dots, x_{t-\tau+1}]$,表示当前时刻 t 之前 τ 个时刻的信道状态;相应的输出向量 y_{t+1} 即为预测的下一时刻的信道状态,通过与实际的信道状态 x_{t+1} 进行对比得出预测准确率。根据上述思想形成训练样本集:

$$X = \begin{bmatrix} x_1 & \cdots & x_{t-\tau+1} & \cdots & x_{T-\tau} \\ x_2 & \cdots & x_{t-\tau+2} & \cdots & x_{T-\tau+1} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_\tau & \cdots & x_t & \cdots & x_{T-1} \end{bmatrix},$$

$$Y = [y_{\tau+1}, \dots, y_{t+1}, \dots, y_T] \quad (7)$$

利用式(6)、式(7)建立时间序列预测模型:

$$y_t = \sum_{i=t-\tau}^{t-1} (\alpha_i - \alpha_i^*) K(x_t, x_i) + b, t = \tau+1, \dots, T \quad (8)$$

将 X 的每一列作为输入向量依次输入预测器,从而得到预测输出集合 Y 。

支持向量机不需要像神经网络预测器一样选择隐层节点数和初始权值,在确定输入节点后,预测器的网络结构由算法自动最优化生成,因此选择合适的参数,对预测器的性能有着重要影响。尽管支持向量机在理论上很完善,但在具体使用中尚无统一的参数选取标准和理论,故本文在第 3.2.4 节中对不同参数下的预测精度进行了分析。

3 频谱预测仿真实验

离散时间的排队理论在通信中有着广泛的应用,故本文采用 M/G/1 排队模型^[2]作为频谱模型,它假设系统的授权用户到达间隔服从泊松分布,用户占用频谱的时间服从几何分布^[16]。实验通过改变通信强度和授权用户平均到达间隔时间 t_{inter} 来测试不同通信场景下的预测性能。通信强度被定义为:

$$\rho = \frac{\text{mean ON time}}{\text{mean ON+OFF time}} = \frac{t_{\text{serv}}}{t_{\text{inter}}} \quad (9)$$

其中, t_{serv} 为授权用户占用信道的平均时间, t_{inter} 为授权用户到达的平均时间间隔。在本文所进行的仿真中,通信强度至少保持在 50% 以上,即信道被授权用户占用的平均时间大于信道空闲的平均时间。

在实验中采用错误预测概率,即频谱预测结果与实际信道状态不相等的概率来反映预测器的性能。错误概率定义如下:

$$P_p^e(\text{Overall}) = (T - \tau)^{-1} \left[\sum_{t=\tau}^{T-1} (y_{t+1} = -1 | x_{t+1} = 1) + \sum_{t=\tau}^{T-1} (y_{t+1} = 1 | x_{t+1} = -1) \right] \quad (10)$$

对授权用户和认知用户双方来说,这都是一项非常重要的性能指标,它确保认知用户能够最大限度地利用空闲频谱,而不对授权用户造成干扰。

如无特别说明,实验中的 SVM 模型均选取径向基核

$$\text{函数 } K(x_i, x_j) = \exp \left[-\frac{(x_i - x_j)^2}{2\sigma^2} \right], \text{核函数参数 } \sigma = \frac{1}{\tau} = 0.25,$$

嵌入维数 $\tau=4$,惩罚因子 $c=1$,损失函数 $\varepsilon=0.1$ 。

3.1 BP 神经网络方法预测失效实验

本实验对 BP 神经网络方法的预测失效情况进行了仿真,并与 SVM 方法做出比较。BP 网络采用参考文献[2]中的结构,为 4-15-20-1,即输入层 4 个神经元表示预测时间点前 4 个时隙的状态,隐含层为两层,分别含有 15 个和 20 个神经元,输出层为 1 个神经元,为预测的当前时刻信道状态。每层的传输函数均为 tansig 函数,权值学习规则采用梯度下降法,学习率设为 0.2,动量因子为 0.9。实验采用排队模型生成信道数据,固定通信强度为 $\rho=50\%$,平均到达间隔 $t_{\text{inter}}=10$ slot,前 1 000 个数据作为训练样本,后 10 000 个数据作为测试样本。两种方法采用相同的训练及测试样本,独立实验 50 次,BP 方法每次随机选取初始权值和阈值。

本文定义错误率高于 25% 的预测为无效预测。如图 1 所示,BP 神经网络方法的预测失效率达到 46%,这是由于初始权值和阈值选取的不确定性,导致模型在训练时没有达到预期的效果,而且 BP 神经网络算法本身也存在易陷入局部极小的问题。在实际应用中,过高的错误概率将使得频谱预测失去意义。而 SVM 方法在输入节点确定后,连接权值由算法最优生成,因此具有很好的稳定性。可以看到,在相同的样本条件下,SVM 方法的预测精度达到 14.85%,高于 BP 方法的有效预测的平均值为 20.24%。




图 1 BP 神经网络预测方法失效实验



3.2 SVM 方法预测性能仿真

本实验从 4 个方面说明基于 SVM 方法的频谱预测的性能,并与参考文献[2]中基于 BP 神经网络的方法进行比较。

3.2.1 固定通信条件下的预测仿真

固定通信条件是指信道模型的参数,即通信强度 ρ 和授权用户平均到达间隔时间 t_{inter} 保持不变。图 2 给出了固定平均到达间隔时间 $t_{\text{inter}}=10$ slot 和 $t_{\text{inter}}=20$ slot 时,不同通信强度下的错误预测概率。可以看到随着通信强度的增加,两种方法的预测准确率都在逐渐提高。




图 2 固定通信条件下的 SVM 方法与 BP 神经网络方法的预测性能对比

表 1 反映了在通信强度 $\rho=50\%$ 时的不同信道占用时间下的预测性能。可以看到 SVM 方法的预测精度要明显高于 BP 神经网络方法,并且随着 t_{serv} 从 5 slot 变化到 11 slot, SVM 方法的预测错误率从 16.37% 下降到 8.38%,这是由于平均占用时间的提高导致信道状态跳变次数减少。

表 1 不同信道占用时间下的 SVM 方法与 BP 神经网络方法的预测性能对比

$t_{\text{serv}}/\text{slot}$	$P_p^e(\text{overall})\text{-BP}$	$P_p^e(\text{overall})\text{-SVM}$
5	24.65%	16.37%
8	18.57%	10.79%
9	16.43%	9.84%
10	15.27%	9.03%
11	14.56%	8.38%

3.2.2 不固定通信条件下的预测仿真

不固定通信条件是指授权信道在不同时段的通信强度 ρ 和授权用户平均到达间隔时间 t_{inter} 不同。本实验通过计算整个时段 $[t_0, t_6]$ 内的预测错误概率来检验预测性能。信道状态的统计特性变化见表 2。

表 2 不固定通信条件下的信道状态

时间间隔	$t_{\text{inter}}/\text{slot}$	ρ
$[t_0, t_1]$	20	0.7
$[t_1, t_2]$	10	0.5
$[t_2, t_3]$	18	0.667
$[t_3, t_4]$	16	0.625
$[t_4, t_5]$	22	0.3
$[t_5, t_6]$	18	0.5

实验表明,在每个时段为 6 000 slot 的情况下,如果采用 $[t_0, t_6]$ 内的前 1 000 个 slot 数据作为训练样本进行一次性训练,则 SVM 方法和 BP 神经网络方法的错误概率分别为 10.46% 和 17.64%;如果采用每个时段内的前 1 000 个数据作为训练样本重复训练,则两种方法的错误概率分别下降为 10.04% 和 13.94%。可以看到 SVM 方法在两种训练方式下的预测精度差别不大,这意味着 SVM 方法在实际应用中无需分时段反复训练,而只需根据历史数据训练一次,就能够达到很高的预测精度。

3.2.3 基于频谱预测的频谱感知能耗仿真^[2]

本文考虑两种设备类型的未授权用户: CR_{sense} 设备和 CR_{predict} 设备。在频谱感知中, CR_{sense} 设备需要感知观测周期内的所有 N_{total} 个时隙,而 CR_{predict} 设备只需感知预测结果为空闲的时隙。假设进行 1 次频谱感知需要 1 个能量单元 U_{energy} ,而由于硬件条件所限每次只能对 1 个时隙做出感知,则 CR_{sense} 设备在有限时间段内的总感知能量为:

$$SE_{\text{sense}} = N_{\text{total}} \times U_{\text{energy}} \quad (11)$$

与此同时, CR_{predict} 设备的总感知能量为:

$$SE_{\text{predict}} = SE_{\text{sense}} - P_{\text{busy}} \times U_{\text{energy}} \quad (12)$$

其中, P_{busy} 为感知结果为占用的时隙,从而得出感知能耗的改善率为:

$$SE_{\text{red}}(\%) = \frac{SE_{\text{sense}} - SE_{\text{predict}}}{SE_{\text{sense}}} = \frac{P_{\text{idle}}}{N_{\text{total}}} \quad (13)$$

其中, P_{idle} 为预测结果为空闲的时隙数。

表 3 给出了在通信强度 $\rho=50\%$ 时的不同信道占用时间下采用 SVM 频谱预测方法 CR_{predict} 的设备的能量改善率 $SE_{\text{red}}(\%)$, 时隙总数 $N_{\text{total}}=10\ 000$ slot, N_{idle} 为实际空闲时隙数。

通过表 3 可以看到,能耗的改善率取决于对空闲时隙的准确估计。实验结果表明,采用 BP 神经网络方法预测出的空闲时隙数往往要大于真实的时隙数。以 $t_{\text{inter}}=16$ 时为例, BP 方法预测出的空闲信道数为 $B_{\text{idle}}=4\ 813$, 这意味着有一部分处于占用状态的时隙被误判,认知用户实际上无

法在这些时隙占用信道,却损耗了对这些时隙进行频谱感知时的能量。SVM 方法估计出的空闲时隙数非常接近真实情况,在尽可能增加接入机会的前提下最大限度地降低了感知能耗。

表 3 不同用户到达间隔下的能耗改善率

t_{inter}	N_{idle}	P_{idle}	SE_{red}
10	4 991	4 975	49.75%
16	4 692	4 692	46.92%
18	4 724	4 725	47.25%
20	4 877	4 877	48.77%
22	4 973	4 952	49.52%

3.2.4 SVM 参数仿真

为说明基于支持向量机的频谱预测精度与模型参数及核函数间的关系,实验选取通信强度 $\rho=50\%$,平均到达间隔 $t_{inter}=10$ slot 的条件下的 10 组样本对各项参数进行仿真实验。默认参数值为嵌入维数 $\tau=4$,惩罚因子 $c=0.1$,损失函数参数 $\varepsilon=0.1$,当改变其中一个参数时,其余两个参数保持不变。结果见表 4~表 6,其中的预测精度为 10 组样本的平均值,最后一列为 10 组样本预测精度的方差。

表 4 嵌入维数 τ 对预测精度的影响

τ	c	ε	$P_p^*(overall)$	Var
2	0.1	0.1	15.28%	1.57×10^{-5}
4	0.1	0.1	15.28%	1.55×10^{-5}
10	0.1	0.1	15.28%	1.59×10^{-5}
16	0.1	0.1	15.28%	1.53×10^{-5}
32	0.1	0.1	17.09%	1.45×10^{-5}

表 5 惩罚因子 c 对预测精度的影响

τ	c	ε	$P_p^*(overall)$	Var
4	0.1	0.1	15.28%	1.55×10^{-5}
4	1	0.1	15.30%	1.68×10^{-5}
4	10	0.1	15.32%	1.77×10^{-5}
4	100	0.1	15.32%	1.77×10^{-5}
4	200	0.1	15.32%	1.77×10^{-5}

表 6 损失函数 ε 对预测精度的影响

τ	c	ε	$P_p^*(overall)$	Var
4	0.1	0.01	15.28%	1.55×10^{-5}
4	0.1	0.1	15.28%	1.55×10^{-5}
4	0.1	0.2	15.28%	1.55×10^{-5}
4	0.1	0.8	15.28%	1.55×10^{-5}
4	0.1	0.9	15.30%	1.68×10^{-5}

结果表明,基于 SVM 的预测方法对参数的变化具有顽健性。同时也可以看到,嵌入维数对于预测精度有着重要影响。这是因为在对预测模型进行相空间重构时,嵌入

维数反映了一维时间序列转化成矩阵形式后获得的数据间的关联性和信息量。

对于核函数的选择,目前还缺乏理论指导,应结合具体应用场景进行测试。实验证明,针对本文中预测数据的二值特性,选取线性核函数、多项式核函数及径向基核函数的预测结果并无差别,在相同的样本下错误预测率均为 15.28%,而选取 sigmoid 函数的错误概率为 19.59%,不适合本文的应用。

4 结束语

本文提出了一种基于 SVM 的认知无线电频谱预测方法。理论上,基于统计学习理论和结构风险最小化原则的支持向量机泛化能力更强,并且不存在 BP 神经网络局部极小、初始权值选取不确定及收敛速度慢等问题。实验证明,基于 SVM 的频谱预测方法相比基于 BP 神经网络的预测方法具有如下优势。

- 预测精度更高,并且有效避免了 BP 神经网络预测的失效问题。
- 无需针对不同的信道状态反复训练,只需训练一次便可达到较好的效果。
- 网络结构由算法自动最优确定,避免了 BP 神经网络算法结构设计过于依赖经验的问题。
- 该方法对参数变化具有顽健性。

综上所述,本文所提基于支持向量机的频谱预测方法显著降低了频谱感知的能耗,提高了频谱利用率,在认知无线电预测中具有很好的应用前景。

参考文献

1 Tumuluru V K , Wang P, Niyato D. Channel status prediction for cognitive radio networks. *Wireless Communications and Mobile Computing*, 2010, 12(10): 862~74

2 Tumuluru V K, Wang P, Niyato D. A neural network based spectrum prediction scheme for cognitive radio. *Proceedings of 2010 IEEE International Conference on Communications (ICC2010)*, Piscataway, 2010

3 Yin L, Yin S X, Hong W J, *et al.* Spectrum behavior learning in cognitive radio based on artificial neural network. *Proceedings of 2011 Military Communications Conference*, Baltimore, MD, USA, 2011

4 Gorcin A, Celebi H, Qaraqe K A. An autoregressive approach for spectrum occupancy modeling and prediction based on synchronous measurements. *Proceedings of IEEE Symposium on Personal Indoor and Mobile Radio Communications (PIMRC 2011)*, Toronto, Canada, September, 2011:705~709



- 5 Black T, Kerans B, Kerans A. Implementation of Hidden Markov model spectrum prediction algorithm. Proceedings of IEEE Symposium on Communications and Information Technologies (ISCIT 2012), Queensland, Australia, August, 2012:280~283
- 6 Chen Z, Qiu R C. Prediction of channel state for cognitive radio using higher-order hidden Markov model. Proceedings of IEEE SoutheastCon 2010 (SoutheastCon), Concord, NC, USA, March, 2010: 276~282
- 7 Yin S X, Chen D W, Zhang Q, *et al.* Mining spectrum usage data: a large-scale spectrum measurement study. IEEE Transactions on Mobile Computing, 2012, 11(6):1033~1046
- 8 李国正, 王猛, 曾华军. 支持向量机导论. 北京: 电子工业出版社, 2004
- 9 尉询楷, 李应红, 张朴等. 基于支持向量机的时间序列预测模型分析与应用. 系统工程与电子技术, 2005, 27(3):530~532
- 10 陈果. 基于遗传算法的支持向量机时间序列预测模型优化. 仪器仪表学报, 2006, 27(9):1081~1084
- 11 孙煦, 陆化普, 吴娟. 基于蚁群优化支持向量机模型的公路客运量预测. 合肥工业大学学报, 2012, 35(1):125~29
- 12 李书荣. 基于 DE-BP 神经网络认知无线电频谱预测研究. 西南交通大学硕士学位论文, 2013
- 13 陈斌华. 认知无线电系统中的频谱预测算法研究. 北京邮电大学硕士学位论文, 2011
- 14 高翔, 任国春, 陈瑾等. 快变信道环境下基于支持向量回归的频谱预测. 信号处理, 2014, 30(3):289~297

- 15 贺新颖. 基于支持向量机的认知无线电若干关键技术研究. 北京邮电大学硕士学位论文, 2009
- 16 Cooper B R. Introduction to Queueing Theory. New York: Elsevier North Holland Inc, 1981

[作者简介]



徐元, 男, 中国科学院半导体研究所助理工程师, 主要研究方向为神经网络的硬件化实现等。



鲁华祥, 男, 博士, 中国科学院半导体研究所研究员, 主要研究方向为智能信息处理、神经网络技术及其应用等。

陈旭, 女, 博士, 中国科学院半导体研究所副研究员, 主要研究方向为模式识别、智能信息处理。

(收稿日期: 2014-06-19)

· 简讯 ·

勘误说明

本刊 2014 年第 8 期《基于过采样的六二阶归一化累积量盲均衡算法》的图 5(第 91 页)有误。应更正为:




图 5 4 种算法的误码率曲线

对此, 我们向作者及读者深表歉意。

《电信科学》编辑部

2014 年 10 月