

引用格式:魏海文,郭业才.门控递归单元神经网络坐标变换盲均衡算法[J].微电子学与计算机,2019,36(9):89-93.[WEI H W, GUO Y C. Coordinate transformation blind equalization algorithm based on gated recurrent unit neural network[J]. Microelectronics & Computer, 2019, 36(9): 89-93.]

门控递归单元神经网络坐标变换盲均衡算法

魏海文¹, 郭业才^{1,2}

(1 南京信息工程大学 江苏省气象探测与信息处理重点实验室, 江苏 南京 211800;
2 江苏省大气环境与装备技术协同创新中心, 江苏 南京 211800)

摘 要: 针对数字信号传输过程中的码间干扰问题, 提出了门控递归单元神经网络坐标变换盲均衡算法 (GRUNN-CT-CMA)。首先, 在递归神经网络基础上加入门控结构, 使门控递归单元神经网络 (GRUNN) 对长时间跨度信息的感知能力更强、记忆力更持久。其次, 在 GRUNN 中引入坐标变换得到的盲均衡算法, 进一步降低了稳态误差、加快了代价函数收敛速度。结果表明, 与常模盲均衡算法 (CMA) 和延迟单元递归神经网络盲均衡算法 (BRNN-CMA) 相比, GRUNN-CT-CMA 在均衡高阶多模信号时, 稳态误差最小、收敛速度最快、输出信号星座图最清晰。

关键词: 盲均衡; 门控递归单元; 神经网络; 代价函数; 坐标变换; 码间干扰

中图分类号: TN911.7 **文献标识码:** A **文章编号:** 1000-7180(2019)09-0089-05

Coordinate transformation blind equalization algorithm based on gated recurrent unit neural network

WEI Hai-wen¹, GUO Ye-cai^{1,2}

(1 Jiangsu Key Laboratory of Meteorological Observation and Information Processing,
Nanjing University of Information Science & Technology, Nanjing 211800, China;
2 Jiangsu Collaborative Innovation Center on Atmospheric Environment and
Equipment Technolog, Nanjing 211800, China)

Abstract: In order to solve the problem of inter symbol interference in the process of digital signal transmission, a coordinate transformation constant modulus blind equalization algorithm based on gated recurrent unit neural network (GRUNN-CT-CMA) is proposed. Firstly, based on the recurrent neural network, the gated recurrent unit neural network (GRUNN) with a gate structure was added, which has stronger perception and longer-lasting memory of long-span information. Secondly, the coordinate transformation blind equalization algorithm was introduced in GRUNN, which further reduced the residual error and corrected the phase offset. The simulation results show that comparing with the constant modulus blind equalization algorithm (CMA) and the bias-unit recurrent neural networkconstant modulus blind equalization algorithm (BRNN-CMA), when GRUNN-CT-CMA equalizing high order multi-mode signals, the steady-state error is minimal, the speed of convergence is the fastest and the constellation of the output signal is the clearest.

Key words: blind equalization; gated recurrent unit; neural network; cost function; coordinate transformation; inter-symbolinterference

1 引言

在现代数字通讯技术中,信道多径效应与环境噪声产生的码间干扰(Inter-Symbol Interference, ISI)导致通信系统接收端产生高误码率.降低码间干扰的有效方法是不需训练序列的盲均衡技术,其本质是通过性能优异的算法来实时调整均衡器权向量,降低通信系统误码率^[1].

传统前馈神经网络盲均衡算法对非常模信号均衡能力差^[2],递归类神经网络盲均衡算法虽隐藏层单元有信息内循环,但结构简单,不能充分提取序列特征,稳态误差大^[3].门控递归单元神经网络(Gated Recurrent Unit Neural Network, GRUNN)将递归结构与门控结构结合起来,使 GRUNN 对长时间跨度序列特征感知能力更强^[4].将 GRUNN 作为横向均衡器,输入层单元个数为均衡器长度,非常模信号序列输入 GRUNN 时,隐藏层中每一个网络单元不仅接收当前时刻输入层的输入信息还接收前一时刻隐藏层单元自身的输出信息,序列特征信息保存在门控参数中,具有良好的自适应与容错能力.神经网络均衡器中广泛应用的常模盲均衡算法(Contant Modulus Algorithm, CMA)代价函数,由于星座坐标与模值位置不匹配,对非常模信号均衡效果不明显.坐标变换算法(Coordinate Transformationbased CMA, CT-CMA)把非常模信号星座坐标变换到常模位置,使信号星座坐标与统计模值匹配.因此,GRUNN 与 CT-CMA 相结合将是有意义的研究课题.

本文在充分发挥 GRUNN 与 CT-CMA 优点的基础上,提出了一种门控递归单元神经网络坐标变换盲均衡算法(GRUNN based CT-CMA, GRUNN-CT-CMA).该算法用 GRUNN 加快了代价函数收敛速度,降低了稳态误差,用 CT-CMA 实现了对 GRUNN 门控参数的调整,优化了网络对序列信息特征的学习能力.仿真结果验证了 GRUNN-CT-CMA 的有效性.

2 前馈神经网络盲均衡算法基本结构

前馈神经网络盲均衡算法原理,如图 1 所示.

图 1 中, $a(k)$ 是输入端接收到的未知信号序列, $h(k)$ 是信道的冲激响应序列, $x(k)$ 是信道的输出序列, $w(k)$ 是高斯白噪声, $y(k)$ 是前馈神经网络均衡器的输入序列, $f(k)$ 为神经网络均衡器等价的卷积权向量, $z(k)$ 是前馈神经网络均衡器恢复的输




图 1 前馈神经网络盲均衡算法结构图

出信号序列, $\hat{a}(k)$ 是判决输出信号序列.均衡器的输出 $z(k)$ 为

$$x(k) = a(k) \otimes h(k) \tag{1}$$

$$y(k) = x(k) + w(k) \tag{2}$$

$$z(k) = f(k) \otimes y(k) \tag{3}$$

式中, $\otimes$ 表示卷积运算,如果不考虑噪声的影响, $z(k)$ 可由式(1)与式(2)推导得出,即

$$z(k) = h(k) \otimes f(k) \otimes a(k) \tag{4}$$

将信道的冲激响应与神经网络均衡器卷积权向量相结合,可以得到式(4)的可行性条件如下

$$h(k) \otimes f(k) = [0, \cdots, 0, e^{j\varphi}, 0, \cdots, 0]^T \tag{5}$$

式中, φ 表示相移量,可由判决器去除.

针对不同的问题,前馈神经网络的目标函数有不同的选择.前馈神经网络盲均衡算法的网络权向量通过特定的算法更新,使信道冲击响应与均衡器权向量符合式(5),进而使网络代价函数收敛到最小值^[5].

3 门控递归单元神经网络盲均衡算法

门控递归单元神经网络盲均衡算法(GRUNN based CMA, GRUNN-CMA)将 GRUNN 作为横向滤波器处理输入信号,在网络隐藏层单元之间建立全连接,能更好地追踪序列信号特征,对输入突变有迅速的反应能力^[6].门控递归单元神经网络隐藏层单元内部结构图,如图 2 所示.




图 2 门控递归单元神经网络隐藏层单元内部结构图

图 2 中, $c_{t-1}(k)$ 表示 $t-1$ 时刻第 k 个隐藏层单元激活值, $s_t(k)$ 表示 t 时刻第 k 个隐藏层单元的输入, $r_t(k)$ 表示 t 时刻第 k 个隐藏层单元重置门值, $n_t(k)$ 表示 t 时刻第 k 个隐藏层单元更新门值, $\tilde{c}_t(k)$

表示 t 时刻第 k 个隐藏层单元更新门激活值, $c_t(k)$ 表示 t 时刻第 k 个隐藏层单元输出值. 隐藏层单元内信息流为

$$r_t(k) = \text{sigmoid}(W_{rs}(k) \cdot s_t(k) + W_{re}(k) \cdot c_{t-1}(k)) \quad (6)$$

$$n_t(k) = \text{sigmoid}(W_{ns}(k) \cdot s_t(k) + W_{ne}(k) \cdot c_{t-1}(k)) \quad (7)$$

$$\tilde{c}_t(k) = \tanh(W_{\alpha s}(k) \cdot s_t(k) + r_t(k) \cdot W_{\alpha e}(k) \cdot c_{t-1}(k)) \quad (8)$$

$$c_t(k) = (1 - n_t(k)) \cdot c_{t-1}(k) + n_t(k) \cdot \tilde{c}_t(k) \quad (9)$$

式中, $W_{rs}(k)$ 、 $W_{re}(k)$ 为第 k 个隐藏层单元重置门权向量, $W_{ns}(k)$ 、 $W_{ne}(k)$ 为第 k 个隐藏层单元更新门权向量, $W_{\alpha s}(k)$ 、 $W_{\alpha e}(k)$ 为第 k 个隐藏层单元更新门激活值权向量. 由上式知, sigmoid 函数将重置门向量 $r_t(k)$ 的元素控制在 0 到 1 之间, 当 $r_t(k)$ 的元素值接近 1 时, $t-1$ 时刻隐藏层节点激活值充分保留, 反之则丢弃, 同时充分保留新输入隐藏层单元的 t 时刻第 k 个隐藏层单元输入值 $s_t(k)$. 同理, 更新门 $n_t(k)$ 通过控制 $c_{t-1}(k)$ 与 $\tilde{c}_t(k)$ 两个量来更新 t 时刻第 k 个隐藏层单元状态值 $c_t(k)$.

整个网络在 t 时刻的输出为

$$o_t = f(W_o \cdot c_t) \quad (10)$$

式中, W_o 为隐藏层与输出层的连接权向量; c_t 为隐藏层输出. 门控递归单元神经网络最后的传递函数定义为

$$f(x) = x + \beta \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (11)$$

导数为

$$f'(x) = 1 + 4\beta \frac{1}{(e^x + e^{-x})^2} \quad (12)$$

为了保证传递函数的单调性, 传递函数导数值必须大于零. 因此, 传递常数 β 取大于零的值. β 值的选取取决于信号振幅大小. 信号从神经网络输出层输出后, 结合 CMA 代价函数:

$$J(n) = \frac{1}{2} [|\tilde{y}(k)|^2 - R_2]^2 \quad (13)$$

得网络中各个权重的误差更新量, 其中

$$R_2 = \frac{E[|a(k)|^4]}{E[|a(k)|^2]} \quad (14)$$

式中, $a(k)$ 为系统的发送序列.

4 门控递归单元神经网络坐标变换盲均衡算法

盲均衡算法代价函数通常由均衡器输入序列与

输出序列的统计信息组成, 通过随机梯度下降算法进行权值更新, 输入信号统计模值由信号星座图决定. 对于非常模信号, 由于统计模值与输入信号星座图不符, 同时进一步降低算法收敛后稳态误差, 提出了 GRUNN-CT-CMA. 在信号序列进入 GRUNN 之前, 通过坐标变换将非常模信号坐标位置变换到常模信号坐标位置, 均衡器输出信号经变换后与新统计模值组成新代价函数.

坐标变换盲均衡算法种类多样, 文献[7-8]通过坐标变换实现了非常模信号与统计模值的匹配, 但只能应用于 16QAM 信号. 文献[9]在文献[7-8]的基础上进行了改进, 实现了 16QAM, 4-PAM, 2-PAM, BPSK 信号的盲均衡, 本文提出了一种坐标变换新算法, 可以实现对 MQAM 和 MPAM 信号的均衡. 通过式(15)与式(16)进行坐标变换, 重构 GRUNN 的代价函数, 将 MQAM 和 MPAM 信号的星座图坐标实部与虚部分开, 即

$$Y_r = X_r - 2\text{sign}(X_r) \quad (15)$$

$$Y_i = X_i - 2\text{sign}(X_i) - \text{sign}[X_i - 2\text{sign}(X_i)] \quad (16)$$

变换后得新坐标 $\{\pm 1 \pm 0i\} = \{\pm 1\}$, 变换后信号星座图的统计模值 $R = 1$. 结合 CMA 的代价函数, GRUNN 输出的实部与虚部分别为 $\tilde{o}_r(k)$ 与 $\tilde{o}_i(k)$, 则定义新的代价函数为

$$J(k) = \frac{1}{2} [|\tilde{o}_r(k) - 2\text{sign}(\tilde{o}_r(k)) + i(\tilde{o}_i(k) - 2\text{sign}(\tilde{o}_i(k)) - \text{sign}(\tilde{o}_i(k) - 2\text{sign}(\tilde{o}_i(k))))|^2 - R]^2 \quad (17)$$

根据瞬时梯度下降算法, 有

$$f(k+1) = f(k) - \mu \frac{\partial J}{\partial f(k)} \quad (18)$$

式中, f 代表权向量; μ 为迭代步长; 由式(17)与式(18)得输出权向量更新公式, 即

$$\begin{aligned} \frac{\partial J(k)}{\partial W_o(k)} = & 2[|\tilde{o}_r(k) - 2\text{sign}(\tilde{o}_r(k)) + i(\tilde{o}_i(k) - 2\text{sign}(\tilde{o}_i(k)) - \text{sign}(\tilde{o}_i(k) - 2\text{sign}(\tilde{o}_i(k))))|^2 - R] \cdot \\ & [\tilde{o}_r(k) - 2\text{sign}(\tilde{o}_r(k)) + i(\tilde{o}_i(k) - 2\text{sign}(\tilde{o}_i(k)) - \text{sign}(\tilde{o}_i(k) - 2\text{sign}(\tilde{o}_i(k))))] \cdot f'(o_t(k)) \cdot c_t(k) \end{aligned} \quad (19)$$

$$W_o(k+1) = W_o(k) - \mu \frac{\partial J(k)}{\partial W_o(k)} \quad (20)$$

定义 $\mathbf{H}(k)$ 为

$$\mathbf{H}(k) = \frac{\partial J(k)}{\partial \mathbf{W}_o(k)} \cdot \mathbf{W}_o(k) + \mathbf{N}(k-1) \cdot \mathbf{W}_n(k) + \mathbf{P}(k-1) \cdot \mathbf{W}_\alpha(k) \cdot \mathbf{r}(k-1) + \mathbf{R}(k-1) \cdot \mathbf{W}_\pi(k) + \mathbf{H}(k-1) \cdot (1 - n(k-1)) \quad (21)$$

式中, $\mathbf{N}(k-1)$ 为更新门权向量 $\mathbf{W}_{ns}(k)$ 与 $\mathbf{W}_{ne}(k)$ 前一次迭代的偏导数更新量; $\mathbf{P}(k-1)$ 为更新门激活权向量 $\mathbf{W}_\alpha(k)$ 与 $\mathbf{W}_\pi(k)$ 前一次迭代的偏导数更新量; $\mathbf{R}(k-1)$ 为重置门权向量 $\mathbf{W}_{rs}(k)$ 与 $\mathbf{W}_{re}(k)$ 前一次迭代的偏导数更新量. $\mathbf{r}(k-1)$ 与 $\mathbf{n}(k-1)$ 分别为前一次迭代重置门值与更新门值.

由式(21)得更新门权向量更新公式为

$$\mathbf{N}(k) = \mathbf{H}(k) \cdot (\tilde{c}(k) - c(k-1)) \cdot \text{sigmoid}'(\mathbf{W}_{ns}(k) \cdot \mathbf{s}_t(k) + \mathbf{W}_{ne}(k) \cdot c(k-1)) \quad (22)$$

$$\mathbf{W}_{ns}(k+1) = \mathbf{W}_{ns}(k) - \mu \cdot \mathbf{s}(k) \cdot \mathbf{N}(k) \quad (23)$$

$$\mathbf{W}_{ne}(k+1) = \mathbf{W}_{ne}(k) - \mu \cdot c(k-1) \cdot \mathbf{N}(k) \quad (24)$$

更新门激活值权向量更新公式为

$$\mathbf{P}(k) = \mathbf{H}(k) \cdot \mathbf{n}(k) \cdot \tanh'(\tilde{c}(k)) \quad (25)$$

$$\mathbf{W}_\alpha(k+1) = \mathbf{W}_\alpha(k) - \mu \cdot \mathbf{r}(k) \cdot c(k-1) \cdot \mathbf{P}(k) \quad (26)$$

$$\mathbf{W}_\pi(k+1) = \mathbf{W}_\pi(k) - \mu \cdot \mathbf{s}(k) \cdot \mathbf{P}(k) \quad (27)$$

重置门权向量更新公式为

$$\mathbf{R}(k) = c(k-1) \cdot (\mathbf{H}(k) \cdot \mathbf{n}(k) \cdot \tanh'(\tilde{c}(k)) \cdot \mathbf{W}_\alpha(k)) \cdot \text{sigmoid}'(\mathbf{W}_{rs}(k) \cdot \mathbf{s}_t(k) + \mathbf{W}_{re}(k) \cdot c_{t-1}(k)) \quad (28)$$

$$\mathbf{W}_{rs}(k+1) = \mathbf{W}_{rs}(k) - \mu \cdot \mathbf{s}(k) \cdot \mathbf{R}(k) \quad (29)$$

$$\mathbf{W}_{re}(k+1) = \mathbf{W}_{re}(k) - \mu \cdot c(k-1) \cdot \mathbf{R}(k) \quad (30)$$

5 仿真及结果

通过计算机仿真,验证 GRUNN-CT-CMA 在数字通讯盲均衡领域中的有效性,系统环境为 Windows8,硬件环境为 Intel(R) Core(TM) i5-430M CPU@2.26 GHz,在 Matlab2016a 编程环境中运行. 分别对 32QAM、64QAM 的发射信号依次进行均衡,且均发射 30 000 个字符,信道为典型的无线通讯信道 $h = [0.005, 0.009, -0.024, 0.854, -0.218, 0.049, -0.016]$, 高斯白噪声信噪比 15 dB. 以 CMA 和 BRNN-CMA^[5] 为比较对象,进行 MATLAB 仿真.

5.1 32QAM 信号

当发射信号为 32QAM 调制信号时, CMA 均衡器抽头个数为 15, 迭代步长 $\mu_{\text{CMA}} = 0.000\ 005$; BRNN-CMA 的网络结构为 (25, 17, 1), 延迟单元为 1, 传递常数 $\beta_{\text{BRNN-CMA}} = 8$, 迭代步长 $\mu_{\text{BRNN-CMA}} = 0.000\ 008$; GRUNN-CT-CMA 的网络结构为 (3, 40, 1), 隐藏层权向量 $\mathbf{W}_c$ 、 $\mathbf{W}_\pi$ 与 $\mathbf{W}_{ne}$ 维度为 40×40 , $\mathbf{W}_s$ 、 $\mathbf{W}_{rs}$ 和 $\mathbf{W}_{re}$ 的维度为 3×40 , $\mathbf{W}_o$ 维度为 40×1 , 传递常数 $\beta_{\text{GRUNN-CT-CMA}} = 8$, 迭代步长 $\mu_{\text{GRUNN-CT-CMA}} = 0.000\ 07$. 300 次蒙特卡洛仿真结果, 如图 3、4 所示.




图 3 32QAM 仿真实验输出星座图




图 4 32QAM 仿真实验均方误差曲线

图 3 与图 4 分别比较了 CMA、BRNN-CMA 与 GRUNN-CT-CMA. 可以看出, 在收敛速度上, GRUNN-CT-CMA 比 BRNN-CMA 快大约 1 500 步, 比 CMA 快大约 1 200 步; 在稳态误差上,

GRUNN-CT-CMA 比 BRNN-CMA 降低了大约 2.5 dB,比 CMA 降低了大约 6.5 dB,且 GRUNN-CT-CMA 的输出星座图比 BRNN-CMA 和 CMA 更加紧凑、清晰.

5.2 64QAM 信号

当发射信号为 64QAM 调制信号时. CMA 均衡器抽头个数为 17, 迭代步长 $\mu_{\text{CMA}} = 0.000\ 002$; BRNN-CMA 的网络结构为 (27, 20, 1), 延迟单元为 1, 传递常数 $\beta_{\text{BRNN-CMA}} = 12$, 迭代步长 $\mu_{\text{BRNN-CMA}} = 0.000\ 002$; GRUNN-CT-CMA 的网络结构为 (3, 50, 1), 隐藏层权向量 $\mathbf{W}_c, \mathbf{W}_{rc}$ 与 $\mathbf{W}_{rk}$ 维度为 50×50 , $\mathbf{W}_s, \mathbf{W}_{rs}$ 和 $\mathbf{W}_{rs}$ 的维度为 3×50 , $\mathbf{W}_o$ 维度为 50×1 , 传递常数 $\beta_{\text{GRUNN-CT-CMA}} = 12$, 迭代步长 $\mu_{\text{GRUNN-CT-CMA}} = 0.000\ 03$. 300 次蒙特卡洛仿真结果, 如图 5, 6 所示.




图 5 64QAM 仿真实验输出星座图




图 6 64QAM 仿真实验均方误差曲线

图 5 与图 6 分别比较了 CMA, BRNN-CMA 与 GRUNN-CT-CMA. 可以看出, 在收敛速度上, GRUNN-CT-CMA 比 BRNN-CMA 快大约 1 600 步, 比 CMA 快大约 1 000 步; 在稳态误差上, GRUNN-CT-CMA 比 BRNN-CMA 降低了大约 2.5 dB, 比 CMA 降低了大约 4 dB, 且 GRUNN-CT-CMA 的输出星座图比 BRNN-CMA 和 CMA 更加紧凑、清晰.

6 结束语

本文将 GRUNN 与坐标变换算法相结合, 提出了 GRUNN-CT-CMA. 该算法融合了递归神经网络良好的记忆能力、门控结构突出的识别能力与坐标变换算法对高阶信号的适应能力, 加快了收敛速度、降低了稳态误差. 仿真实验证明, 新算法的性能与多种算法相比均具有显著的提升.

参考文献:

[1] 樊康, 郭业才. 基于小生境遗传优化的正交小波变换盲均衡算法[J]. 微电子学与计算机, 2011, 28(7): 50-53.

[2] GIACOMIDIS E, MATIN A, WEI JINLONG, et al. Blind nonlinearity equalization by machine learning based clustering for single- and multi-channel coherent optical OFDM[J]. Journal of Lightwave Technology, 2018, 36(3): 721-727.

[3] YU CHENGPU, XIELIHUA. On Recursive blind equalization in sensor networks[J]. IEEE Transactions on Signal Processing, 2015, 63(3): 662-672.

[4] CASCIANELLI S, COSTANTE G, CIARFUGLIA T, et al. Full-GRU natural language video description for service robotics applications[J]. Robotics & Automation Letters, 2018, 3(2): 841-848.

[5] YING XIAO, DONG YUHUA, LI ZHENXING. Blind equalization in underwater acoustic communication by recurrent neural network with bias unit[C]// 2008 7th World Congress on Intelligent Control and Automation. Chongqing: IEEE, 2008: 25-27.

[6] RAVANELLI M, BRAKEL P, OMOLOGO M, et al. Light gated recurrent units for speech recognition[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2018, 2(2): 92-102.

[7] RAO WEI, YUAN KUNMING, GUO YECAI, et al. A simple constant modulus algorithm for blind equalization suitable for 16-QAM signal[C]// 2008 9th International Conference on Signal Processing. Beijing: IEEE, 2008: 1963-1966.

5 结束语

随着半导体工艺的发展,WAT 在半导体生产良率控制中扮演的角色也愈发重要.可寻址测试芯片的应用大幅提升了 WAT 的测试效率,满足了日益复杂的测试需求.但与此同时,如何从海量测试数据中高效地进行良率诊断,成为了亟待解决的问题.

本文提出的基于随机森林的可寻址 WAT 良率诊断方法,使用随机森林算法在测试数据上建立分类模型,并从中提取关键规则,得到的规则集合可以帮助分析人员快速定位缺陷,进而完成良率诊断.在真实可寻址 WAT 数据集上进行验证,结果表明本文提出的方法,相较于基于决策树的规则提取方法,在提取出的规则集合的查准率与查全率上均有着更好的表现.

参考文献:

[1] CHIEN C F, CHEN Y J, WU J Z. Big data analytics for modeling WAT parameter variation induced by process tool in semiconductor manufacturing and empirical study [C] // Winter Simulation Conference (WSC), 2016. IEEE, Hyderabad, India, 2016: 2512-2522.

[2] ZHANG B, PAN W, ZHENG Y, et al. A fully automated large-scale addressable test chip design with high reliability[J]. european conference on circuit theory and design, 2011: 61-64. DOI: 10.1109/ECCTD.2011.6043609.

[3] LEE F. Advanced yield enhancement: integrated yield analysis[C] // Advanced Semiconductor Manufacturing Conference and Workshop, 1997. Cambridge, MA, USA, IEEE/SEMI. IEEE, 1997: 67-75.

[4] CHIEN C, HSU C, CHEN P, et al. Semiconductor fault detection and classification for yield enhancement and manufacturing intelligence[J]. Flexible Services and Manufacturing Journal, 2013, 25(3): 367-388.

[5] CHIEN C, WANG W, CHENG J, et al. Data mining for yield enhancement in semiconductor manufacturing and an empirical study[J]. Expert Systems With Applications, 2007, 33(1): 192-198.

[6] WEISS S M, BASEMAN R J, TIPU F, et al. Rule-based data mining for yield improvement in semiconductor manufacturing[J]. Applied Intelligence, 2010, 33(3): 318-329.

[7] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1):5-32.

[8] BREIMAN L. Bagging predictors[J]. Machine Learning, 1996, 24(2):123-140.

作者简介:

刘元修 男,(1994-),硕士研究生.研究方向为集成电路测试数据分析.

史 峰(通讯作者) 男,(1967-),副教授,硕士生导师.研究方向为集成电路 DFM 及 EDA.

E-mail:shiz@vlsi.zju.edu.cn.

张培勇 男,(1977-),副教授.研究方向为集成电路设计.

(上接第 93 页)

[8] GUOYE CAI, ZHAO XUEQING, LIU ZHENXING, et al. A modified T/2 fractionally spaced coordinate transformation blind equalization algorithm[J]. International Journal of Communications Network & System Sciences, 2010, 3(2): 183-189.

[9] 饶伟,郭业才,汪胜前,等.基于坐标变换的常数模盲均衡新算法[J].电子学报,2011,39(1):7-12.

作者简介:

魏海文 男,(1993-),硕士研究生.研究方向为自适应盲均衡技术. E-mail: CJwei haiwen@163.com.

郭业才 男,(1962-),博士,教授.研究方向为通信信号处理、自适应盲均衡技术.