

Adaptive Radar Pulse Deinterleaving Method Base on Auto-associative Artificial Neural Network

Xudong Wang, Maozhong Song

College of Information Science and Technology, Nanjing University of Aeronautics & Astronautics, Nanjing 210016,

Email: xudong@nuaa.edu.cn

Abstract: An adaptive radar pulse deinterleaving method is proposed in this paper. This deinterleaving method is based on parameter optimized BSB artificial neural network. After learning a mass of radar pulse samples with measure errors, the input radar pulse patterns can be stored and deinterleaved by this unsupervised auto-associative neural network. Comparing with other radar pulse deinterleaving methods, this method can adapt more measure errors and give better deinterleaving precision

Keywords: radar pulse deinterleaving; auto-associative; artificial neural network

一种基于自联想人工神经网络的雷达脉冲信号自适应分选方法

王旭东, 宋茂忠

南京航空航天大学信息科学与技术学院, 南京, 中国, 210016

Email: xudong@nuaa.edu.cn

摘 要: 提出了一种具有自联想功能的雷达脉冲信号自适应分选方法, 该算法基于参数优化选取后的盒中脑人工神经网络, 具有极强的自联想能力。能够通过对大量带有测量误差的雷达脉冲样本进行自联想学习, 完成对脉冲模式的记忆, 进而实现自适应分选功能。与其他雷达脉冲分选方法相比, 本文给出的方法具有更好的参数测量误差适应能力, 更高的分选精度。

关键词: 雷达脉冲分选; 自联想; 人工神经网络模板

1. 引言

电子战(EW, Electronic War)中, 信号环境十分复杂, 信号密度达百万脉冲/秒^[1,2]。来自不同雷达的脉冲信号会源源不断涌入电子侦察接收机, 要实现正确截获, 必须对信号进行分选。

现有雷达脉冲分选方法主要包括: 参数比对法^[3]、直方图法^[4]和基于智能信号处理的方法^[2]。参数比对法将接收到的雷达脉冲参数与数据库中预先存储的雷达参数进行比较, 来确定所截获雷达类型。该方法要求接收机能够准确测量信号脉内参数。受噪声及多径效应等影响, 接收机对信号脉内参数的测量精度往往不高, 因此参数比对法的分选效果不佳。直方图法通过

检测脉冲到达时间, 得到脉冲重复频率(PRF, Pulse Repeat Frequency), 将其变换成直方图, 进而实现脉冲分选。该方法结构简单、运算量小, 是一种经典的雷达脉冲分选方法。但是, 当脉冲流中含有三部以上雷达时, PRF 变化模式会显著增多, 分选性能急剧下降。本文提出将 Eidos BSB 神经网络用于雷达脉冲信号分选, 利用 Eidos 学习规则记忆接收脉冲中蕴含的雷达模式信息, 再将其应用到分选中, 取得了良好效果。

2. Eidos BSB 模型分析

2.1 原始 BSB 模型

Anderson 于 1977 年提出的 BSB 神经网络模型^[5], 是一种典型的无导师自联想人工神经网络。BSB 模型基本思想是先应用 Widrow-Hoff 学习规则对样本或原型模式进行学习记忆, 然后将学习好的网络应用于模式分类。随后国内外学者对 BSB 模型进行了深化

基金项目: 国家自然科学基金(60572108); 南京航空航天大学基本科研业务费专项科研项目(NS2010109); 南京航空航天大学青年创新基金(Y0618-041)

扩展, Hui^[6]、Lillo^[7]、Hong Qiao^[8]等人对其动态过程和神经网络模型的稳定性做了详细分析。BSB 模型同其他神经网络模型一样, 包括学习和联想两个过程。其学习过程的表达式为:

$$\Delta A = \eta(f_k - Af_k)f_k^T \quad (1)$$

ΔA 为 BSB 模型连接矩阵的增量, f_k 为输入向量, η 为学习步长。通过对大量样本学习, 当 ΔA 趋向于 0 时, 学习过程结束, 网络完成对输入模式记忆过程。其联想过程表达式为:

$$f(i+1) = L(\alpha Af(i) + \gamma f(i) + \delta f(0)) \quad (2)$$

其中, α , γ , δ 都是[0,1]区间常数, 分别代表遗忘、限制和保留因子; $f(0)$ 代表原始输入样本, $f(i+1)$ 和 $f(i)$ 分别代表第 $i+1$ 和第 i 步联想结果, 当 $f(i+1) = f(i)$ 时联想结束; L 代表限制函数, 如(3)式:

$$L(x) = \begin{cases} V_T & x \geq V_T \\ x & -V_T < x < V_T \\ -V_T & x \leq -V_T \end{cases} \quad (3)$$

其中 V_T 为一门限值, 代表 n 维超立方体顶点值。经过若干次迭代运算后, 不同样本(初始点)会被“吸引”到正方形(n 维超立方体)不同顶点(记忆模式), 从而实现分类功能。

2.2 Eidos BSB 模型

基于 Widrow-Hoff 学习规则的原始 BSB 模型, 对于输入模式相关性比较大的情况, 其分类能力明显下降。为此 Begin 对其进行了改进, 并将改进后的模型称之为 Eidos BSB 模型^[1]。该模型的学习规则为:

$$\Delta A = \alpha f(p)f^T(p) + \beta f(n)f^T(n) \quad (4)$$

其中 α 、 β 是[0,1]区间常数($\alpha > \beta$), $f(p)$ 、 $f(n)$ 分别代表网络对 $f(0)$ 迭代 p 、 n 次的结果。这种学习规则是基于 Hebbian 和 anti-Hebbian 的, 具有更强的分类能力, 能够对相关性的模式进行区分。Eidos BSB 模型联想规则为:

$$f(i+1) = L(\xi Af(i) + \varphi f(i)) \quad (5)$$

其中 L 为限制函数, 其定义如(3)式, ξ 、 φ 为[0,1]区间常数, 分别代表遗忘、限制因子。

由于 Eidos BSB 模型学习和联想过程中的参数相互影响, 这就给参数选择带来了困难。Boukadoum 通过仿真方法对参数 α 和 β 做了优化选取^[9]; Chartier 对 Eidos BSB 模型进行了简化^[10], 使得可变参数只有一个。上述参数选取方法只针对学习向量未受噪声污染情况, 而在雷达脉冲分选时, 接收脉冲的类别属性

事先并不知道, 需要网络通过对大量接收脉冲的学习来获取, 因此用于学习的向量也含有噪声。

文献[11]对 Eidos BSB 参数进行了优化选取, 给出了如下参数值:

$$\alpha = 0.05, \beta = -0.0025,$$

$$\varphi = 0.95, p = 5, n = 10,$$

$$V_T = 2, \xi = 0.65。$$

本文将采用这种参数优化选取后的模型进行雷达脉冲信号分选。

3 基于 Eidos BSB 的脉冲分选算法

3.1 雷达脉冲信号参数表示

设信号环境中含 10 部雷达辐射源, 各辐射源信号参数如表 1 所示。

表 1 十部雷达辐射源信号参数表

辐射源	方位角 (度)	俯仰角 (度)	载频 (GHz)	脉宽 (us)	调制方式
1	108	36	0.3	0.52	脉压
2	216	63	1.4	0.69	跳频
3	108	36	0.5	0.48	常规
4	280	72	1.5	0.58	脉压
5	144	45	0.6	0.74	跳频
6	252	63	0.6	0.44	常规
7	180	45	1.6	0.56	脉压
8	180	36	0.8	0.67	跳频
9	180	45	0.5	0.77	常规
10	280	63	0.9	0.47	脉压

表中前四个参数的范围: $[0^\circ, 359^\circ]$ 、 $[0^\circ, 90^\circ]$ 、 $[0\text{GHz}, 1\text{GHz}]$ 、 $[0\mu\text{s}, 1\mu\text{s}]$, 表中五个参数分别用 10、10、18、10、12 字长的杠码表示, 总码长为 60, 如图 1 所示。每个“=”或“.”用它们的 8 位 ASCII 码表示, 则网络共有 480 个神经元。每个参数的编码相互独立, 杠码向左移动代表数值减小, 向右移动代表数值增大。其中, 调制方式用三种汉明距离较远的码表示。

3.2 Eidos BSB 模型脉冲分选

首先研究原始 BSB 模型的分选效果。用不带测量误差的脉冲参数作为学习向量, 每个辐射源取 51 个样本, 共 510 个学习样本, 按照公式(1)对网络连接矩阵进行学习, $\eta=1/480$, A 的初始值为 0, 学习 2000 次后(平均每个样本学习 4 次), 所得连接矩阵 A 的

特征值分布如图 2 所示。




图 1 十辐射源参数编码




图 2 连接矩阵特征值(学习样本无测量误差)

前十个特征值相等且为 1, 其他特征值都为 0, 十部雷达参数被网络准确记忆。用学习好的网络, 按照 (2) 式对有测量误差的样本进行分类, 设方位角、俯仰角、载频、脉宽的测量误差在下列区间均匀分布: $[-18^\circ, +18^\circ]$ 、 $[-4.5^\circ, +4.5^\circ]$ 、 $[-0.05\text{GHz}, +0.05\text{GHz}]$ 、 $[-0.05\mu\text{s}, +0.05\mu\text{s}]$ 。在 (2) 式中, 参数取值为: $\alpha = 0.5$, $\gamma = 0.9$, $\delta = 0$, $V_T = 2$ 。每个辐射源选取 10 个带有测量误差的样本, 共 100 个测试样本, 仿真所得分类正确率为 100%。可见, 当辐射源参数已知时, BSB 模型处在有导师、异联想的工作状态, 网络能够对输入脉冲进行非常好的分选作用。然而在电子侦察中, 雷达辐射源参数事先并不知道, 网络必须能够通过对带有测量误差的样本进行学习, 提取辐射源模式 (类别), 进而实现分选。

当采用带测量误差样本对模型进行训练后, 所得连接矩阵 A 的特征值分布如图 3 所示。

可见连接矩阵中较大特征值的个数远远大于输入向量中实际模式的个数 (10 个), 网络产生了“伪特征值”, 此时网络已经失去了分类能力。因此, 原始 BSB 模型的自联想记忆能力不理想, 不能实现对有测量误差雷达脉冲信号的分选功能。

下面研究 Eidos BSB 模型的脉冲分选能力。网络

参数按 1.2 节中优化后的设置。参数测量误差及学习向量于用 BSB 模型进行分选时的相同。




图 3 连接矩阵特征值(学习样本有测量误差)




图 4 Eidos BSB 连接矩阵特征值(学习样本有测量误差)

学习后的网络连接矩阵特征值分布如图 4 所示。与图 3 相比, 消除了伪特征值。将学习好的网络再应用于雷达脉冲分选, 测试样本与用 BSB 模型进行分选时的相同。针对辐射源 4 的网络输入、输出结果如图 5 所示。其他测试样本的网络输出结果与此类似。可见带有测量误差的输入向量, 经网络迭代联想后能收敛到真实值。对输出向量以汉明距离为标准进行分类, 并认为汉明距离小于等于 6 的为同一类, 即可实现对输入雷达脉冲信号的分选。大量仿真实例证明, 在上述测量误差范围内, 网络分选正确率不低于 95%。这种参数优化的 Eidos BSB 模型脉冲分选方法, 对脉冲参数的测量误差不敏感, 较好解决了带有测量误差雷达脉冲信号的分选问题。

4. 结论

本文将参数优化选取后的 Eidos BSB 人工神经元

网络用于解决带有测量误差雷达脉冲信号的分选问题。网络能够对带有测量误差的样本进行自联想学习,提取雷达脉冲信号的模式信息,达到了良好分选效果。




图5 Eidos BSB 模型输入、输出向量比较

通过对输入雷达脉冲信号参数的符号化处理,对所提分选方法进行了计算机仿真,结果表明,该模型在输入脉冲参数测量误差较大时,仍能从中提取雷达类别信息,分选正确率可达 95%以上。与其他雷达脉冲信号分选算法相比,具有更强的适应能力。

致 谢

感谢评审专家的评阅。

References (参考文献)

- [1] Begin, J.; Proulx, R.; Categorization in unsupervised neural networks: the Eidos model[J], IEEE Transactions on Neural Networks, Vol.7, No.1, Jan. 1996 Page(s): 147-154
- [2] Anderson, J. A.; Gately, M. T.; Penz, P. A.; Collins, D. R.; Radar signal categorization using a neural network[C], Proceedings of the IEEE, Vol.78, No.10, Oct. 1990 Page(s):1646-1657
- [3] Mardia H K, et al. New techniques for the deinterleaving of repetitive sequences[J]. IEEE proceedings Pt. F, 1989, 136(4):149-154.
- [4] Milojevic D. J.; Improved algorithm for the deinterleaving of radar pulses[J], IEEE proceedings Pt. F, 1992, 139(1): 98-104.
- [5] Anderson J A, Silverstein J W, Ritz S A, et al; Distinctive features, categorical perception and probability learning: Some applications of a neural model, in Neurocomputing: Foundations of Research[M], Anderson J A and Rosenfeld E. Eds. Cambridge, MA: MIT Press, 1988, Ch.2-Ch.4
- [6] Hui, S.; Zak, S.H.; Dynamical analysis of the brain-state-in-a-box(BSB) neural models[J], IEEE Transactions on Neural Networks, Vol.3, No.1, Jan. 1992 Page(s): 86-94
- [7] Lillo, W. E.; Miller, D. C.; Hui, S.; Zak, S. H.; Synthesis of Brain-State-in-a-Box (BSB) based associative memories[J], IEEE Transactions on Neural Networks, Vol.5, No.5, Sept. 1994, Page(s):730-737
- [8] Hong Qiao; Jigen Peng; Xu, Z.-B.; Bo Zhang; A reference model approach to stability analysis of neural networks[J], IEEE Transactions on Systems, Man and Cybernetics, Part B, Vol.33, No.6, Dec. 2003, Page(s):925-936
- [9] Boukadoum, A.M.; Lamrani, J.; Performance improvement of the BSB-Eidos neural network[C], Canadian Conference on Electrical and Computer Engineering, Vol.2, Sept. 1994, Page(s):718-721
- [10] Chartier, S.; Proulx, R.; A new online unsupervised learning rule for the BSB model[C], International Joint Conference on Neural Networks, Vol.1, July 2001, Page(s):448-453
- [11] Wang Xudong, Song Maozhong. Parameter optimization in Eidos brain state in a box artificial neural network model[J], Control Theory & Application, Vol.27, No.3, Mar. 2010, Page(s):373-376.
王旭东, 宋茂忠. Eidos BSB 人工神经网络模型参数优化选取[J], 控制理论与应用, Vol.27, No.3, Mar. 2010, Page(s): 373-376.