

文章编号: 1000-8152(2010)03-0373-04

无监督Eidos表相盒中脑状态人工神经元网络模型参数优化选取

王旭东, 宋茂忠

(南京航空航天大学 信息科学与技术学院, 江苏 南京 210016)

摘要: 本文研究了无监督表相盒中脑状态(Eidos BSB)人工神经元网络模型的参数优化选取问题。通过对模型连接矩阵的特征值进行深入分析, 发现网络分类能力取决于有效特征值的平稳性和区别性。提出采用有效特征值均值与其他特征值均值的比, 作为参数优化选取的依据, 给出了选取最优参数的具体方法。仿真结果表明, 经参数优化选取后的Eidos BSB模型与原始Eidos BSB模型相比, 能够获得更强的噪声适应能力, 更好的分类性能。参数优化后的网络对噪声污染率为100%的输入样本的平均识别概率达94%以上。

关键词: 盒中脑; 无监督表相盒中脑状态; 参数优化

中图分类号: TN052 **文献标识码:** A

Parameter optimization in Eidos brain-state-in-a-box artificial neural network model

WANG Xu-dong, SONG Mao-zhong

(College of Information Science and Technology, Nanjing University of Aeronautics & Astronautics, Nanjing Jiangsu 210016, China)

Abstract: The parameter optimization for the Eidos brain-state-in-a-box(Eidos BSB) artificial neural network model is considered. By an in-depth analysis to the eigenvalues of the model-connected matrix, it can be found that the network's classification ability relies on the stability and distinction of the valid eigenvalues. Thereby, a novel parameter optimization technique is proposed, which is based on the ratio of the valid eigenvalues' mean to the others. Then, the details of this parameter optimization method are presented. According to the simulation results, this optimized Eidos BSB model is immune to noise and provides better classification results. More than 94% correct classification rate can be attained for the samples with 100% noise contamination rate by employing this optimized neural network.

Key words: brain-state-in-a-box; Eidos BSB; parameter optimization

1 引言(Introduction)

BSB(brain-state-in-a-box, 盒中脑)神经元网络模型是Anderson于1977年提出的^[1], 该模型是一种典型的无导师自联想神经网络模型。随后国内外学者对BSB模型进行了深化扩展, Hui^[2], Lillo^[3], Qiao^[4]等人对其动态过程和网络吸引子的稳定性等做了详细的分析; 文[5]通过将Hebbian和Anti-Hebbian学习规则应用于BSB网络, 给出了Eidos BSB模型。该模型具有更强的分类能力, 能够对相关性很高的模式进行区分。但是, Eidos BSB模型的分类能力与网络参数选取有关, 文[5]并未给出具体的参数选取方法。本文在研究了网络分类能力与连接矩阵特征值分布关系的基础上, 给出了Eidos BSB模型参数优化选取的具体方法, 提高了模型的分类能力。

2 BSB模型(BSB model)

BSB模型同其他的神经元网络模型一样, 包括学习和联想两个过程^[6]。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。通过对大量样本的学习, 当 ΔA 趋向于0时, 学习过程结束, 网络完成对输入模式的记忆过程。其联想过程的表达式为

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

其中: α, γ, δ 都是 $[0, 1]$ 区间的常数, 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*步的联想结果, 当 $f(i+1) = f(i)$ 时联想结束; L 代表如式(3)所示的限制函数:

收稿日期: 2008-04-30; 收修改稿日期: 2009-05-22。

基金项目: 国家自然科学基金资助项目(60572108); 南京航空航天大学青年教师基金资助项目(Y0618-041)。

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

其中: V_T 为门限值, 代表 n 维超立方体的顶点。经过若干次迭代运算后, 不同样本(初始点), 会被“吸引”到 n 维超立方体的不同顶点(记忆模式), 从而实现分类功能。

3 Eidos BSB模型(Eidos BSB model)

3.1 原始Eidos BSB模型(Original Eidos BSB model)

基于Widrow-Hoff学习规则的BSB模型, 当输入模式相关性较大时, 其分类能力将明显下降。为此, Begin^[5]对其进行改进, 并将改进后的模型称之为Eidos BSB模型。该模型的学习规则如式(4):

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

其中: α, β 是[0, 1]区间的常数, 且 $\alpha > \beta$; $f(p), f(n)$ 分别代表网络对 $f(0)$ 迭代 p, n 次的结果, $p < n$ 。这种学习规则是基于Hebbian和Anti-Hebbian的, 具有更强的分类能力, 能够对相关性很高的模式进行区分。Eidos BSB模型的联想规则如式(5):

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

其中: L 为限制函数, 其定义如式(3), ξ, φ 为[0, 1]区间的常数, 分别代表遗忘因子和限制因子。

3.2 Eidos BSB模型参数优化选取(Parameter optimization of Eidos BSB model)

由于Eidos BSB模型学习和联想过程中的参数相互影响, 这就为参数选择带来了困难。Boukadoum^[7]通过仿真的方法对参数 α 和 β 做了优化选取; Chartier^[8]对Eidos BSB模型进行了简化, 使得可变参数只有一个。上述参数选取方法都只针对学习向量没有受到噪声污染的情况, 而在实际应用中, 特别是在模式识别中, 类别属性预先并不知道, 需要网络通过对大量接收样本的学习来获得。因此, 用于学习的向量也含有噪声。

通过分析和仿真发现, Eidos BSB网络对模式记忆的准确程度, 可通过网络对不同污染程度输入样本的回忆准确率来衡量, 分类效果与下列因素有关:

1) 能否进行分类取决于连接矩阵A的特征值的分布情况, 如果有效特征值(与输入模式相对应的特征值)明显大于其余的特征值, 则网络能够进行分类。

2) 分类正确率取决于3个因素: A) 有效特征值大于其他特征值的程度, 越大越有利于分类。B) 有效特征值的平稳程度, 如果各特征值大小比较一致, 则各模式的分类正确率类似相等。否则, 与小特征值对应的模式, 分类正确率较低。C) 其余特征值的绝

对大小, 越小越有利于分类。

3) 当学习样本相同时, 遗忘因子(ξ)越小越不利于特征值的平稳, 此时有效特征值的幅度较大, 分类的平均正确率较高, 但相关性较高的两个类别的识别概率较低; ξ 值越大则有效特征值越平稳, 但其绝对值较小, 与其他特征值的差别也较小, 正确分类的平均概率较低, 但各类别的错误概率比较一致(平稳)。不同 ξ 值对连接矩阵特征值的影响如图1所示, 系统总类别为36个, 输入样本中含有9种模式。

由图1可见, ξ 值的大小决定了有效特征值的大小和平稳程度。连接矩阵有效特征值的这两个特性决定了Eidos BSB模型的分类效果。因此, 如何选择合适的 ξ 参数是Eidos BSB模型实际应用中的关键所在。Begin针对字母分类问题, 在用50%噪声污染样本训练网络时, 指出 $\xi = 0.999$ 为较佳的一个值, 但并没有给出选择最佳 ξ 值的具体方法。

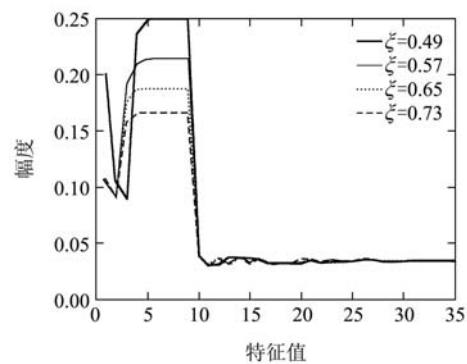


图1 ξ 值对特征值的影响

Fig. 1 Eigenvalues spectra under various ξ

综合考虑有效特征值的平稳性及其与其他特征值的区别性, 本文采用有效特征值的均值与其他特征值的均值比, 作为优化 ξ 值的依据, 其定义如下。

$$q = \frac{1}{9} \sum_{i=1}^9 \lambda(i) / \left[\frac{1}{26} \sum_{i=10}^{35} \lambda(j) \right]. \quad (6)$$

q 值随 ξ 的变化曲线如图2所示。

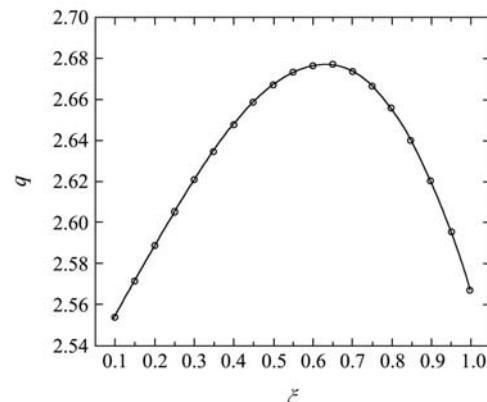


图2 q 随 ξ 值变化曲线

Fig. 2 q value versus ξ value

从图2中可以看出, 当 $\xi = 0.65$ 时, q 值最大, 能够较好的满足模型对有效特征值平稳性和区别性的要求。

3.3 参数优化后的Eidos BSB模型仿真(Simulation of parameter optimized Eidos BSB model)

本文对参数优化后的Eidos BSB模型做了大量仿真, 并与原始模型输出结果做了比较。网络要记忆的模式为A, E, H, I, N, O, R, S, T, 9个 7×5 象素的大写字母, 每一象素的灰度值为 $-1/\sqrt{35}$ (黑)或 $1/\sqrt{35}$ (白)。各字母之间的相关程度从0.03(R-S或R-T)到0.77(H-N或I-T)不等, 平均相关程度为0.3。通过给原始图像随机加入均值为零, 方差为 σ 的高斯噪声, 构成了不同信噪比的输入样本。方差的表达式为: $\sigma = \frac{\rho}{\sqrt{35}}$ 其中 ρ 为噪声比率。学习样本个数为10000个, 测试样本个数为900个(每个字母100个)。学习过程为: 1) 随机选取一个学习样本; 2) 按照式(5)计算 $f(p), f(n)$; 3) 按照式(4)计算 ΔA , 并调整连接矩阵 A ; 4) 重复1)~3)步, 直至 ΔA 趋向于0。模型中各参数的取值为: $\alpha = 0.05, \beta = -0.0025, \varphi = 0.95, p = 5, n = 10, V_T = 2$, 以上参数与原始模型相同, 参数 ξ 本文取优化值 $\xi = 0.65$, 原始模型取 $\xi = 0.999$ 。学习样本噪声比率分别为50%和100%, 测试样本噪声比率在0~100%之间, 仿真结果如表1、表2所示。

表1 学习50%带噪样本后的识别结果

Table 1 Recognize results of the network after studying samples with 50% noise rate

| 样本噪声比率/% | 参数优化前 | | 参数优化后 | |
|----------|-------|------|-------|------|
| | 错误率/% | 迭代次数 | 错误率/% | 迭代次数 |
| 0 | 0 | 73 | 0 | 63 |
| 25 | 0.7 | 77 | 0.1 | 67 |
| 50 | 1.5 | 79 | 0.3 | 72 |
| 100 | 8.6 | 88 | 2.1 | 81 |

表2 学习100%带噪样本后的识别结果

Table 2 Recognize results of the network after studying samples with 100% noise rate

| 样本噪声比率/% | 参数优化前 | | 参数优化后 | |
|----------|-------|------|-------|------|
| | 错误率/% | 迭代次数 | 错误率/% | 迭代次数 |
| 0 | 14.6 | 89 | 0 | 69 |
| 25 | 16.7 | 96 | 0.5 | 77 |
| 50 | 20.3 | 105 | 2.7 | 86 |
| 100 | 45.1 | 204 | 5.1 | 106 |

当 ξ 取其他值时, 网络分类性能介于两者之间, 当 ξ 接近0.65时性能差别不大, 如图3~6所示。

仿真结果验证了2.2节所做的理论分析, 利用这种参数优化选取方法, 能够取得更好的识别效果。当

学习样本的噪声比率较高时, 优势更明显; 当学习样本的噪声比率达到100%时, 未经参数优化的网络识别错误率在45%以上, 而经过参数优化后的网络, 其识别错误率可控制在6%以内。网络对某一样本的迭代过程如图7所示(学习样本和测试样本的噪声比率均为100%)。为显示方便, 作图时对灰度范围做了 $[-1/3, 1/3]$ 的限制。图片上方的数字, 代表迭代次数。

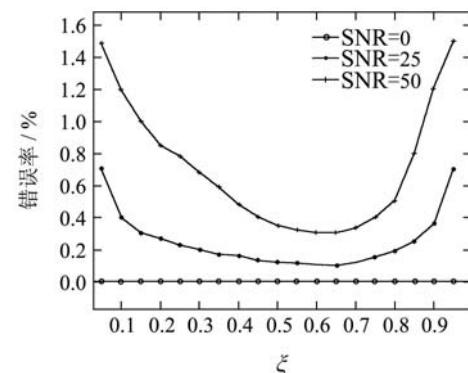


图3 学习50%带噪样本网络分类错误率

Fig. 3 Error category percentage of the network after studying samples with 50% noise rate

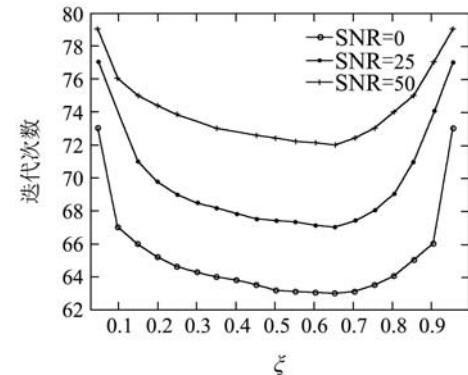


图4 学习50%带噪样本网络迭代次数

Fig. 4 Iteration numbers of the network when studying samples with 50% noise rate

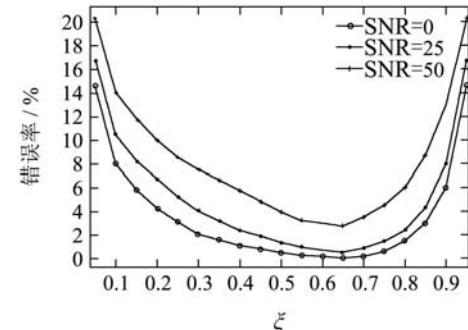


图5 学习100%带噪样本网络分类错误率

Fig. 5 Error category percentage of the network after studying samples with 100% noise rate

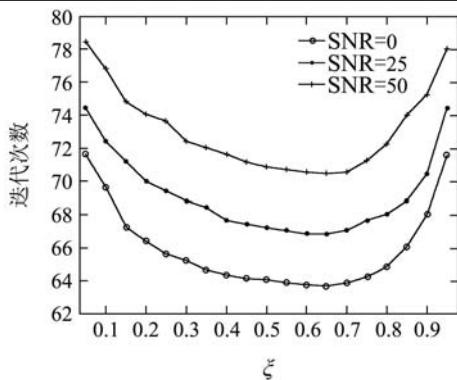


图 6 学习100%带噪样本网络迭代次数

Fig. 6 Iteration numbers of the network when studying samples with 100% noise rate

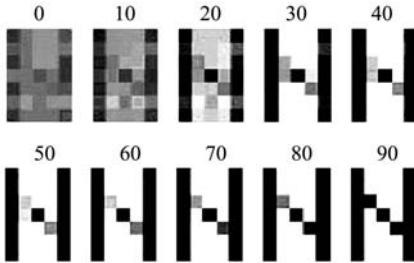


图 7 参数优化的Eidos BSB模型联想过程

Fig. 7 Recall procedure of the parameter optimized Eidos BSB model

4 结论(Conclusions)

本文通过研究Eidos BSB人工神经元网络模型连接矩阵的特征值与学习参数 ξ 的关系,发现连接矩阵有效特征值的平稳性与区别性是一对矛盾。提出将有效特征值的均值与其它特征值的均值之比 q 作为优化参数,取 q 最大值处的 ξ 值作为网络学习时的遗忘因子,实现了对Eidos BSB模型的参数优化选取。与原始Eidos BSB模型相比,经参数优化选取的网络自联想学习后,具有更高的分类精度,更强的噪声适应能力。当学习样本的噪声比率为100%时,未经参

数优化的网络识别错误率在45%以上,而经过参数优化后的网络,其识别错误率可控制在6%以内。但是,对于Eidos BSB人工神经元网络模型,多参数优化选取机理的理论分析还有待进一步深入研究。

参考文献(References):

- [1] 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]. MA: MIT Press, 1988.
- [2] HUI S, ZAK S H. Dynamical analysis of the brain-state-in-a-box (BSB) neural models[J]. *IEEE Transactions on Neural Networks*, 1992, 3(1): 86 – 94.
- [3] LILLO W E, MILLER D C, HUI S, et al. Synthesis of Brain-State-in-a-Box (BSB) based associative memories[J]. *IEEE Transactions on Neural Networks*, 1994, 5(5): 730 – 737.
- [4] QIAO H, PENG J Q, XU Z B, et al. A reference model approach to stability analysis of neural networks[J]. *IEEE Transactions on Systems, Man and Cybernetics, Part B*, 2003, 33(6): 925 – 936.
- [5] BEGIN J, PROULX R. Categorization in unsupervised neural networks: the Eidos model[J]. *IEEE Transactions on Neural Networks*, 1996, 7(1): 147 – 154.
- [6] 魏海坤, 李奇, 宋文忠. 梯度算法下RBF网的参数变化动态[J]. 控制理论与应用, 2007, 24(3): 356 – 360.
(WEI Haikun, LI Qi, SONG Wenzhong. Gradient learning dynamics of radial basis function networks[J]. *Control Theory & Applications*, 2007, 24(3): 356 – 360.)
- [7] DOGRUEL M, LAMRANI J. Performance improvement of the BSB-Eidos neural network[C] // *IEEE Canadian Conference on Electrical and Computer Engineering*. Halifax, Canada: [s.n.], 1994, 2: 718 – 721.
- [8] CHARTIER S, PROULX R. A new online unsupervised learning rule for the BSB model[C] // *IEEE International Joint Conference on Neural Networks*. Washington, DC: [s.n.], 2001, 1: 448 – 453.

作者简介:

王旭东 (1978-), 男, 博士, 讲师, 研究方向为电子智能技术, E-mail: xudong@nuaa.edu.cn;

宋茂忠 (1965-), 教授, 博士生导师, 研究方向为时空调制技术、电子智能等, E-mail: smz@nuaa.edu.cn.