物理学报 Acta Physica Sinica



基于大脑情感学习模型和自适应遗传算法的混沌时间序列预测 梅英 谭冠政 刘振焘 武鹤 Chaotic time series prediction based on brain emotional learning model and self-adaptive genetic algorithm Mei Ying Tan Guan-Zheng Liu Zhen-Tao Wu He

引用信息 Citation: Acta Physica Sinica, 67, 080502 (2018) DOI: 10.7498/aps.67.20172104 在线阅读 View online: http://dx.doi.org/10.7498/aps.67.20172104 当期内容 View table of contents: http://wulixb.iphy.ac.cn/CN/Y2018/V67/I8

您可能感兴趣的其他文章

Articles you may be interested in

结合可视图的多状态交通流时间序列特性分析

Analysis of multi-state traffic flow time series properties using visibility graph 物理学报.2017, 66(23): 230501 http://dx.doi.org/10.7498/aps.66.230501

基于时间序列符号化模式表征的有向加权复杂网络

Directed weighted complex networks based on time series symbolic pattern representation 物理学报.2017, 66(21): 210502 http://dx.doi.org/10.7498/aps.66.210502

基于有限穿越水平可视图的短时睡眠心率变异性研究

Research of short-term heart rate variability during sleep based on limited penetrable horizontal visibility graph

物理学报.2017, 66(16): 160502 http://dx.doi.org/10.7498/aps.66.160502

基于蝙蝠算法的粒子滤波法研究

Intelligent particle filter based on bat algorithm 物理学报.2017, 66(5): 050502 http://dx.doi.org/10.7498/aps.66.050502

基于分段信号相关累加的变速度多站联合直接定位方法

An improved direct position determination method based on correlation accumulation of short-time signals with variable velocity receivers 物理学报.2017, 66(2): 020503 http://dx.doi.org/10.7498/aps.66.020503

基于大脑情感学习模型和自适应遗传算法 的混沌时间序列预测*

梅英¹⁾²⁾ 谭冠政^{1)†} 刘振焘³⁾ 武鹤²⁾

(中南大学信息科学与工程学院,长沙 410083)
 (湖南文理学院电气与信息工程学院,常德 415000)
 3)(中国地质大学自动化学院,武汉 430074)

(2017年9月22日收到;2018年2月8日收到修改稿)

针对传统神经网络预测精度不高、收敛速度慢的问题,提出一种基于大脑情感学习模型和自适应遗传算法的混沌时间序列预测方法.大脑情感学习模型模拟了哺乳动物大脑中杏仁体和眶额皮质之间的情感学习机制,具有计算复杂度低、运算速度快的特点,因此可以大大提高混沌预测的快速性.为了进一步提高大脑情感学习模型的预测精度,采用自适应遗传算法优化其参数,将待优化的权值与阈值分布在染色体基因序列上,用适应度函数选出最佳参数,从而增强了模型的逼近能力.基于 Lorenz 混沌时间序列和实际地磁 Dst 指数序列的预测结果表明,本文方法较其他传统方法在预测精度、运算速度和稳定性上均具有明显优势.

关键词: 混沌时间序列, 预测, 大脑情感学习, 自适应遗传算法
 PACS: 05.45.Tp, 05.45.Gg
 DOI: 10.7498/aps.67.20172104

1引言

混沌时间序列预测在地磁活动预测^[1]、天气预 测^[2]、太阳黑子数预测^[3]等方面应用广泛.近年来, 国内外学者提出了多种混沌预测模型,如:人工神 经网络(回声状态网络^[4,5]、极限学习机^[6]和递归 神经网络^[7])等、局部多项式模型^[8]、自回归模型^[9] 和支持向量机^[10]等.混沌系统往往具有高度的非 线性特性,而神经网络由于具有良好的非线性运算 能力已成为混沌预测的有力工具.然而,随着系统 复杂度的不断增加,传统神经网络在混沌预测中的 运算速度与准确性难以满足要求.因此,需要借助 神经科学上的新发现,发展准确高效的神经网络新 模型,为系统的下一步决策提供科学指导.

神经心理学研究表明[11],情感是人类智能的

重要组成部分.目前,情感智能为新一代人工智能的发展提供了新思路.根据神经生理学上的研究发现^[12],大脑中的杏仁体能根据感官刺激信息产生情感并巩固记忆,避免重复学习.2001年,Balkenius和Morén^[13]提出了大脑情感学习(brain emotional learning,BEL)模型,该模型根据哺乳动物大脑边缘系统的结构,模拟了杏仁体和眶额皮质之间的情感学习机制,具有结构简单、计算复杂度低和运算速度快的优点.近年来,BEL模型在混沌时间序列预测领域取得了广泛的应用.Babaie和Karimizandi^[14]设计了基于BEL模型的地磁风暴预警系统.Abdi等^[15]将BEL模型用于短时交通预测.Sharafi等^[16]和Milad等^[17]将BEL模型用于短时交通预测.Sharafi等^[16]和Milad等^[17]将BEL模型用

* 国家自然科学基金(批准号: 61403422, 61703156)、湖南省教育厅科研基金(批准号: 17C1084) 和湖南文理学院重点科研项目(批 准号: 17ZD02)资助的课题.

†通信作者. E-mail: <u>63641214@qq.com</u>

© 2018 中国物理学会 Chinese Physical Society

奖励信号的强化学习方法调节模型参数,使得 BEL 模型的输出对奖励信号有明显的依赖性,而关于奖 励信号的设定方法,目前尚没有统一的规定.以上 研究者只是根据不同的应用提出了不同的奖励信 号设定方法,而这些方法缺乏通用性.

为了增强BEL模型的通用性,提高模型精度,研究者们提出采用智能算法优化其参数. Dorrah^[18]采用粒子群算法优化BEL控制器参数,实验结果表明优化后的BEL控制器在鲁棒性和响应时间方面优于传统比例-积分-微分(proportion integration differentiation, PID)控制器,但当待优化参数过多时算法容易陷入局部最优. Mei 等^[19]采用遗传算法优化BEL模型参数,优化后的BEL模型在分类正确率方面明显提高,但在处理高维多分类数据时收敛速度变慢. Lotfi和Akbarzadeh^[20]设计了竞争型BEL模型并采用遗传算法优化其参数,增强了BEL模型处理高维多分类数据的能力, 但当优化目标模型较复杂时,遗传算法容易出现局部收敛.遗传算法由于交叉与变异概率固定,其灵活度不高,搜索能力受限.

为了克服遗传算法的缺点,本文提出采用 自适应遗传算法(self-adaptive genetic algorithm, AGA)优化BEL模型,即自适应遗传算法和大脑情 感学习模型结合形成AGA-BEL模型用于混沌时 间序列预测. 在自适应遗传算法中, 通过设计合理 的自适应交叉概率和变异概率,让染色体能够根据 适应度值自适应地进行交叉与变异操作,优化调节 BEL模型中杏仁体和眶额皮质的权值和阈值. 该 方法可以提高算法的灵活性, 增强算法的全局和局 部搜索能力.因此,AGA-BEL模型一方面可以充 分利用自适应遗传算法在广域空间中的寻优功能, 另一方面又能利用BEL算法的快速学习能力引导 自适应遗传算法向最优解快速逼近,从而获得最佳 的模型参数. 将AGA-BEL模型用于Lorenz混沌 时间序列和实际地磁Dst指数序列的仿真预测,实 验结果表明, AGA-BEL模型的预测结果能有效地 反映混沌时间序列的变化趋势, 预测精度高, 且计 算速度和稳定性明显优于传统神经网络.

2 大脑情感学习模型

大脑中的边缘系统是负责调节情感的主要部 位^[12],边缘系统中控制情感反应的一个重要组织 叫杏仁体,它可以接收来自不同感觉联合区的信息,负责产生情感并巩固记忆.感官刺激可以通过两条长短不同的反射通路到达杏仁体,在长反射通路中,感官刺激经过丘脑到达视觉皮层,被深度加工处理后到达杏仁体;在短反射通路中,感官刺激到达丘脑后直接送往杏仁体.

受神经生理学研究的启发, Balkenius和 Morén^[13]提出了大脑情感学习模型,该模型主要 由丘脑、感官皮质、眶额皮质和杏仁体四大部分组 成,如图1所示.杏仁体和眶额皮质是两个主要组 成部分.情感学习主要发生在杏仁体内,杏仁体负 责根据刺激产生情感输出并促进情感记忆,避免重 复学习;眶额皮质主要对杏仁体的学习起辅助调节 作用,避免出现过学习和欠学习现象.





由图1可知, 杏仁体接收丘脑信号 $A_{\rm th}$ 、感官 输入信号 $S_{\rm I}$ (sensor inputs) 及奖励信号 $R_{\rm ew}$ (reward); 眶额皮质接收奖励信号 $R_{\rm ew}$ 及感官输入信 号 $S_{\rm I}$. 大脑情感学习模型的输出是对感官输入信号 的响应, 情感学习的过程即为大脑情感学习模型的 权值调节过程. 根据大脑情感学习模型的定义^[13], 杏仁体和眶额皮质的权值调节规律分别为

$$\Delta v = \alpha \left[S_{\rm I} \cdot \max\left(0, R_{\rm ew} - \sum_i A_i\right) \right], \quad (1)$$

$$\Delta w = \beta \left[S_{\rm I} \cdot \sum_{i} (O_i - R_{\rm ew}) \right], \tag{2}$$

式中 Δv 表示杏仁体权值变化率; Δw 表示眶额皮 质权值变化率; *i*是表示感官输入信号个数的变量; $A_i 和 O_i 分别表示杏仁体和眶额皮质的输出节点;$ $<math>\alpha 和 \beta 表示学习率, 分别控制杏仁体和眶额皮质的$ 学习速度.

从(1)式和(2)式可以看出,奖励信号 R_{ew} 对杏 仁体和眶额皮质的权值调整起重要作用.因此,大 脑情感学习的效果对奖励信号有明显的依赖性,而 关于奖励信号的设定方法,目前尚没有统一的规 定.为了增强大脑情感学习模型的通用性,提高模型精度,本文采用自适应遗传算法优化调节其权值,具体方法见下一节.

3 AGA-BEL 实现方法

3.1 大脑情感学习算法

采用基于自适应遗传算法的监督学习代替基 于奖励信号的强化学习,能优化调节大脑情感学习 模型中杏仁体和眶额皮质的权值,因此需要对基本 大脑情感学习模型进行改进,去掉奖励信号.此外, 为了防止神经元在学习过程中出现饱和状态,可以 根据大脑中杏仁体和眶额皮质间的交互机制,在杏 仁体和眶额皮质神经元中添加阈值,分别为b_a和 b_o.杏仁体和眶额皮质是负责情感学习的主要组成 部分,对于任意输入模式,都是在二者的共同学习 作用下形成输出模式.基于大脑情感学习模型的改 进网络如图2所示.

在图2所示的网络中,代表情感刺激的所有感 官输入信号 S_I表示为

$$S_{\rm I} = [S_1, S_2, \cdots, S_m],$$
 (3)

其中m表示感官输入信号数目.

根据大脑中的情感信息处理机制,在短反射通路中,感官输入信号 *S*_I中的最大值通过丘脑传递给杏仁体,表示为

$$A_{\rm th} = \max(S_{\rm I}).\tag{4}$$

对于每个感官输入信号 S_i, 杏仁体中总存在相 应节点 A_i 接受信号, 表示为

$$\begin{cases}
A_i = S_i \cdot v_i, & i = 1, 2, \cdots, m, \\
A_{m+1} = A_{\text{th}} \cdot v_{m+1},
\end{cases}$$
(5)

其中 v_i 表示杏仁体各节点间的权值, $A_{\rm th}$ 表示丘脑 信号.

杏仁体接收每个感官输入信号*S_i*、丘脑信号 *A*_{th} 及阈值*b*_a,则杏仁体的内部输出表示为

$$E_{\rm a} = \sum_{i=1}^{m} S_i \cdot v_i + A_{\rm th} v_{m+1} + b_{\rm a}.$$
 (6)

在眶额皮质单元中,也存在相应节点O_i接受 每个感官输入信号S_i,表示为

$$O_i = S_i \cdot w_i, \quad i = 1, 2, \cdots, m, \tag{7}$$

其中wi表示眶额皮质各节点间的权值.

眶额皮质接收每个感官输入信号 S_i 和阈值 b_o,则眶额皮质的内部输出 E_o表示为

$$E_{\rm o} = \sum_{i=1}^{m} S_i \cdot w_i + b_{\rm o}.$$
 (8)

在杏仁体和眶额皮质的相互学习下,产生大脑 情感学习模型的总体输出 E,表示为

$$E = E_{\rm a} - E_{\rm o}.\tag{9}$$

根据以上描述,大脑情感学习主要包括杏仁体 和眶额皮质的学习,学习过程即为二者权值和阈值 的调节过程,其协同工作的结果决定大脑情感学习 模型的总体输出.采用不同的方法调整权值和阈 值,将会使大脑情感学习的效果产生很大的差别. 本文将自适应遗传算法引入改进后的大脑情感学 习网络,实现了杏仁体和眶额皮质权值与阈值的 优化调整.



图 2 改进大脑情感学习网络

Fig. 2. Improved brain emotional learning network.

080502-3

3.2 自适应遗传算法

为了使遗传算法具有更强的自适应性能,需要 对遗传参数动态化以提高算法的灵活性,这样改进 的遗传算法称为自适应遗传算法^[21].本文根据染 色体的适应度值设计自适应交叉概率和变异概率, 具体遗传操作见以下描述.

3.2.1 染色体编码

在自适应遗传算法中,将待优化的参数编码 形成的字符串称为染色体.由于BEL网络中的每 个权值与阈值为实数,本文采用实数编码方式以 提高参数的提取精度.将BEL网络中待优化的参 数按顺序排列在染色体基因序列上,以第3.1节中 图2所示的BEL网络为例,染色体编码格式为

$$Ch = [v_1, \cdots, v_{m+1}, b_a, w_1, \cdots, w_m, b_o], \quad (10)$$

其中 v₁,..., v_{m+1} 表示杏仁体各节点间的权值; b_a 为杏仁体神经元阈值; w₁,..., w_m 表示眶额皮质各 节点间的权值; b_o为眶额皮质神经元阈值; m表示 感官信号数目, 每条染色体包含的基因数为2m+3.

3.2.2 适应度函数

适应度函数 (fitness function) 用于指导自适应 遗传算法的搜索进程, 该函数的设计关系到算法的 收敛速度和预测精度. 一般而言, 适应度函数由目 标函数转换而成. 本文AGA-BEL 模型的预测误差 越小表明染色体分配的参数越优, 而求目标函数问 题是最小值问题. 因此, 定义适应度函数为

$$F(Ch) = \frac{1}{n} \sum_{l=1}^{n} (\hat{y}_l - y_l)^2, \qquad (11)$$

式中*n*表示样本数量; *y*_l表示第*l*种输入模式下模型的预测值; *ŷ*_l表示第*l*种输入模式下模型的输出期望值; *F*(*Ch*)表示以染色体*Ch*为网络参数时的平均预测误差.根据适应度函数选出的最优染色体,即为杏仁体和眶额皮质权值与阈值的最佳组合.

3.2.3 遗传算子

在选择操作中,采用轮盘赌和最优个体保留 策略选择交配组^[19]. 在轮盘赌方法中,每条染色 体被选择的概率与其适应度值成正比. 设第*j*条染 色体的适应度值为*f_j*,则该个体被选择的概率*p_j* 表示为

$$\begin{cases} f_j = k/F(Ch_j), \\ p_j = f_j / \sum_{j=1}^M f_j, \end{cases}$$
(12)

式中*M*表示种群大小;*k*表示相关系数;*F*(*Ch_j*)可以根据适应度函数计算出来.由于概率选择存在随机性误差,为了提高遗传算法的收敛性,采用最优个体保留策略,其思想是让适应度最高的个体直接参与下一步遗传操作.

在自适应交叉操作中,交叉概率pc计算公式为

$$p_{\rm c} = \begin{cases} p_{\rm c\,max} - \frac{p_{\rm c\,min}(f - f_{\rm avg})}{f_{\rm max} - f_{\rm avg}}, & f \ge f_{\rm avg}, \\ p_{\rm c\,max}, & f < f_{\rm avg}, \end{cases}$$
(13)

式中 $p_{c max}$ 和 $p_{c min}$ 分别为预先设定的最大交叉概 率和最小交叉概率; f_{max} 和 f_{avg} 分别为群体最大适 应度值及平均适应度值; f 为当前父代双亲中适应 度值较大者.

在交叉操作中,采用算术交叉方式,表示为

$$\begin{cases} Ch_1' = rCh_1 + (1-r)Ch_2, \\ Ch_2' = rCh_2 + (1-r)Ch_1, \end{cases}$$
(14)

式中*Ch*₁和*Ch*₂代表两个父个体; *Ch*₁[']和*Ch*₂代表 两个子个体; *r*为随机数, 取值范围为[0, 1].

在自适应变异操作中,首先判断每条染色体是 否需要变异,如果需要,则根据父个体的适应度值 确定变异概率 *p*_m,表示为

$$p_m = \begin{cases} p_{\max} - \frac{p_{\min}(f' - f_{avg})}{f_{\max} - f_{avg}}, & f' \ge f_{avg}, \\ p_{\max}, & f' < f_{avg}, \end{cases}$$
(15)

式中 $p_{\text{max}} 和 p_{\text{min}} 分别为预先设定的最大变异概率$ $和最小变异概率; <math>f_{\text{max}} 和 f_{\text{avg}} 分别为群体最大适应$ 度值与平均适应度值; <math>f'为需要变异个体的适应 度值.

在上述遗传操作中,交叉和变异过程随着个体的适应度值动态改变,从而增强了算法的灵活性,加快了算法的收敛速度与精度.经过自适应遗传操作选出的最优染色体,代表了BEL网络中杏仁体和眶额皮质最佳权值与阈值的组合,将其更新至BEL网络中,通过网络训练,即能得到预测结果.

3.3 AGA-BEL 算法步骤

AGA-BEL 算法的伪代码如下.

输入: 混沌时间序列数据集, 种群大小 M, 最大进化代数 G_{max} 等. 输出: BEL 网络最优权值与阈值.

Begin

```
g ← 0; /*g 代表当前进化代数, 从第0 代开始*/
初始化遗传参数, 如: p_{c \max}, p_{c \min}, p_{\max}, p_{\min}, M, G_{\max}等;
根据(10)式初始化种群中染色体;
根据 (3) 式 ---(9) 式训练 BEL 网络;
根据(11)式评价每个染色体的适应度;
保存最优染色体进入下一代;
While (g \leq G_{\text{max}}) /* 当没有达到最大进化代数 G_{\text{max}} 时*/
For j = 1 to M/*j表示种群变量, 种群大小为 M */
根据(12)式选择染色体组成下一代种群;
根据(13)式计算交叉概率,进行染色体交叉操作;
根据(15)式计算变异概率,进行染色体变异操作;
更新 BEL 网络权值与阈值;
根据 (3) 式 ---(9) 式训练 BEL 网络;
根据(11)式评价每个染色体适应度;
保存最优染色体进入下一代;
End for
g \leftarrow g + 1;
End while
输出最优染色体. /* 代表 BEL 网络最优权值和阈值的组合*/
End
```

4 仿真预测实验

实验中采用 Intel CPU Core i7-3770 处理器, 主频 3.4 GHz, 8 GB内存, 64位 Windows 7 操作系 统, Matlab 2014b编程环境.

4.1 数据处理

采用神经网络进行混沌时间序列预测时,为 了获得更好的预测效果,需要对预测数据进行归 一化和反归一化处理^[22].设一时间序列原始数 据 $X = (x_1, x_2, \dots, x_N), X \in R^N$,进行归一化的 方法为

$$x(t)' = \frac{x(t) - x_{\min}}{x_{\max} - x_{\min}}, \quad t = 1, 2, \cdots, N,$$
 (16)

式中 N 为时间序列的总长; x(t) 表示原始值; x(t)' 表示归一化后的值, $x(t)' \in [0,1]$; x_{\min} 表示原始数 据序列中的最小值; x_{\max} 表示最大值. 设神经网络的仿真输出为 $Y = (y_1, y_2, \cdots, y_N), Y \in [0, 1],$ 进行反归一化的方法为

$$y(t)' = y(t)(y_{\max} - y_{\min}) + y_{\min},$$

 $t = 1, 2, \cdots, N,$ (17)

式中y(t)表示仿真输出值;y(t)'表示反归一化后的 值, $y(t)' \in \mathbb{R}^N$; y_{\min} 表示仿真输出数据中的最小 值; y_{\max} 表示最大值.

相空间重构即通过一维时间序列反向构造出 原系统的相空间结构. Takens 定理^[23]中说明了系 统中任一分量的演化都是由与之相关的其他分量 决定的. 设*x* 为观测到的分量, x(t), t = 1, 2, ..., N为要研究的混沌时间序列, 其重构的相空间表示 为: $X(t) = \{x(t), x(t-\tau), ..., x[t-(m-1)\tau]\}, t = (m-1)\tau + 1, ..., N$, 选择合适的延迟时间 τ 和嵌 入维数*m*, 可以预测未来 $t + \eta$ 时刻的值 $x(t + \eta)$, 其中, η 为预测步长, 当 $\eta = 1$ 时, 为单步预测; 当 $\eta > 1$ 时, 为多步预测. 本文对混沌时间序列开展单 步预测的仿真实验研究.

4.2 预测器性能评价

本文主要验证 AGA-BEL 模型在预测精度、运 算速度和稳定性方面的性能.预测精度采用平均 绝对误差 (mean absolute deviation, M_{ad})^[24]、均方 误差 (mean square error, M_{se})^[25]、平均绝对百分 比误差 (mean absolute percentage error, M_{ape})^[24] 和相关系数 (correlation coefficient, C_{or})^[25]4个指 标来衡量.设y(t)为模型的预测值, $\hat{y}(t)$ 为混沌时 间序列的实际观测值,n为样本数量,4个指标计算 如下:

1) 平均绝对误差 Mad

$$M_{\rm ad} = \frac{1}{n} \sum_{t=1}^{n} |y(t) - \hat{y}(t)|; \qquad (18)$$

2) 均方误差 M_{se}

$$M_{\rm se} = \frac{1}{n} \sum_{t=1}^{n} [y(t) - \hat{y}(t)]^2;$$
(19)

3) 平均绝对百分比误差 Mape

$$M_{\rm ape} = \frac{1}{n} \sum_{t=1}^{n} \left| \frac{\hat{y}(t) - y(t)}{\hat{y}(t)} \right|;$$
(20)

080502-5

4) 相关系数 Cor

$$C_{\rm or} = \frac{\sum_{t=1}^{n} [\hat{y}(t) - \bar{y}] \cdot [y(t) - \bar{y}]}{n \cdot \sigma(\hat{y}) \cdot \sigma(y)}, \qquad (21)$$

式中 \bar{y} 表示y的算术平均值; $\sigma(y)$ 表示y的标准差; \bar{y} 表示 \hat{y} 的算术平均值; $\sigma(\hat{y})$ 表示 \hat{y} 的标准差.

关于模型的运行效率,可以采用在相同的计算 环境下,执行同样任务所需的时间来评价;关于模 型的稳定性,可以采用在相同的计算环境下重复性 实验结果的统计方差来评价^[24].

4.3 Lorenz 混沌时间序列预测

Lorenz 系统可以作为许多混沌系统的精确模型,此模型的动力学方程式为一组三元常微分方程^[3],表示为

$$\begin{cases} \frac{\mathrm{d}x}{\mathrm{d}t} = -a(x-y),\\ \frac{\mathrm{d}y}{\mathrm{d}t} = -xz + cx - y,\\ \frac{\mathrm{d}z}{\mathrm{d}t} = xy - bz. \end{cases}$$
(22)

当选取参数a = 10, b = 8/3, c = 28, x(0) = -1, y(0) = 0, z(0) = 1时, (22)式具有 混沌特性.取采样时间为0.05,采用四阶 Runge-Kutta法迭代产生 6000 组混沌时间序列.本文使用 前 4000 组数据作为训练样本,后 2000 组数据作为 测试样本,验证 AGA-BEL 模型对 Lorenz-x(t) 的单 步预测效果.

4.3.1 参数设置

首先对 Lorenz 混沌时间序列进行归一化处理 和相空间重构. 根据饱和关联维数法和互信息函数 法^[24]分别确定嵌入维数m = 4, 延迟时间 $\tau = 1$. 采用单步预测方式, 设置预测步长 $\eta = 1$. 构造一个 输入数据形式为 [$\mathbf{x}(t), \mathbf{x}(t-1), \mathbf{x}(t-2), \mathbf{x}(t-3)$] 的四维向量作为 AGA-BEL 预测模型的输入信号, 模型输出用一维向量表示为 $\mathbf{x}(t+1)$.

AGA-BEL模型参数设计包括BEL网络参数设计与AGA遗传参数设计两部分.采用十折交叉验证法得到模型的最佳参数.在BEL神经网络设计中,输入层和输出层的节点数分别由输入和输出数据的维度确定,因此设置输入节点数为4,输出节点数为1,隐含层节点数由经验公式和交叉验证确定为9,网络初始权值和阈值的取值范围为[-1,1].在自适应遗传算法设计中,取种群大小为

100,最大进化代数为100,染色体长度为11,设定 最大交叉概率和最小交叉概率分别为 $p_{cmax} = 0.8$ 和 $p_{cmin} = 0.3$,最大变异概率和最小变异概率分别 为 $p_{max} = 0.1 和 p_{min} = 0.001$.经过网络训练,将 仿真数据进行反归一化处理,最后得到Lorenz-x(t)的预测值.

4.3.2 Lorenz 序列预测结果

在 Lorenz-x(t) 混沌预测中,图3(a) 代表 4000 个训练数据的 Lorenz-x(t) 预测曲线,从图中可以 看出,绿色的预测曲线可以很好地拟合蓝色的实际 曲线,均方误差 M_{se}为0.0001537.对应地,图3(b) 代表 4000 个训练数据的预测误差曲线,从图中可 以看出,各点预测误差均在零点附近的较小范围内 波动,说明 AGA-BEL 模型的预测误差小.

图 4 (a) 代表 2000 个测试数据的 Lorenz-x(t) 预测曲线,从图中可以看出,绿色的预测曲线可 以很好地拟合红色的实际曲线,均方误差 M_{se}为 0.0001336.对应地,图 4 (b) 代表 2000 个测试数据 的预测误差曲线,从图中可以看出,各点预测误差 均在零点附近的较小范围内波动,说明 AGA-BEL 模型对 Lorenz-x(t) 预测的有效性.

从图 3 和图 4 所示的 Lorenz-*x*(*t*) 预测曲线和 误差曲线可以看出,无论对训练数据还是测试数 据,预测曲线都可以很好地拟合实际曲线,说明 AGA-BEL 模型的预测结果能有效地反映混沌时间 序列的变化趋势,预测精度高,鲁棒性好.

图 5 表示 AGA-BEL 模型对 Lorenz-x(t) 混沌时间序列数据的拟合性能, Cor 值表示模型预测值与观测值之间的相关系数.从图 5 (a) 和图 5 (b)中可以看出,在训练集与测试集上的相关系数分别为0.9989和0.9999,说明 AGA-BEL 模型对 Lorenz-x(t) 混沌时间序列数据具有很好的拟合性能.

4.3.3 与其他方法比较

为了在预测精度、速度和稳定性上对比验证 AGA-BEL模型的性能,在相同的实验条件下,分别 采用 MLP-BP^[26], LM-BP^[27]和基本 BEL模型^[13] 对 Lorenz 时间序列进行单步预测.每种模型独立 运行 50次,统计得到平均绝对误差 *M*_{ad},均方误差 *M*_{se},平均绝对百分比误差 *M*_{ape},线性相关度 *C*_{or} 及 计算时间的平均值.其中,*M*_{ape} 是反映预测值与 实际值之间偏离程度的重要指标,模型的稳定性采 用 *M*_{ape} 的方差来评价^[24].表1给出了不同模型对 Lorenz 时间序列的预测结果.



图 5 LOICHZ-2(1)时内/17/前环末19/网站本(a) 19/网回34,(b)以至回34

Fig. 3. Result of Lorenz-x(t) prediction on training datas: (a) Prediction curve; (b) error curve.



Fig. 4. Result of Lorenz-x(t) prediction on testing datas: (a) Prediction curve; (b) error curve.



图 5 Lorenz 时间序列预测线性相关性 (a) 训练集; (b) 测试集

Fig. 5. Linear correlation of Lorenz time series prediction: (a) Training datas; (b) testing datas.

模型		精度指标	<i>M</i> 的方兰	计質时间/。		
	$M_{\rm ad}$	$M_{ m se}$	$M_{\rm ape}$	$C_{ m or}$	Mape 的刀左	и уг ијнј/ 5
MLP-BP	6.3715	13.6758	0.6338	0.8918	0.5721	269.5378
LM-BP	2.2126	4.5672	0.5326	0.9467	0.3462	112.9753
BEL	1.0607	0.2136	0.1427	0.9601	0.0158	25.6321
IGA-LSSVM ^[3]	0.1338		3.1000	—	—	—
BEL-IK ^[16]		2.3333×10^{-4}		—	—	—
AGA-BEL	0.1201	1.4365×10^{-4}	0.0126	0.9994	0.0011	31.7628

表 1 不同模型对 Lorenz-x(t) 单步预测的结果比较 Table 1. Lorenz-x(t) prediction comparisons of different models (1-step).

从表1中可以看出,相对于其他方法,在预 测精度方面,AGA-BEL预测模型的 M_{ad} , M_{se} 及 M_{ape} 均最小, C_{or} 最高,说明AGA-BEL在混沌时 间序列的预测精度上具有明显的优势.在预测稳定 性方面,AGA-BEL的平均绝对百分比误差 M_{ape} 的 方差最小,说明其预测的稳定性最好.在计算时间 方面,BEL模型与AGA-BEL模型所用的计算时间 远远少于传统的BP网络,由于AGA-BEL中执行 了遗传算法的迭代运算,所以计算时间较基本BEL 模型长.总体看来,在Lorenz 混沌时间序列预测中, 较其他传统方法,AGA-BEL模型在预测精度、运行 速度和稳定性上均具有明显优势.

4.4 磁暴环电流 Dst 指数预测

磁暴环电流 (disturbance storm time, Dst) 指数^[1] 作为一种通用表征磁暴强度的地磁指数,在地磁扰动研究中具有重要作用,对防御空间天气灾害方面具有重要价值.本文的Dst指数数据集来自于世界地磁数据中心(http://wdc.kugi.kyoto-

u.ac.jp). 选取发生在2000年间的1000个磁暴环电流指数Dst数据序列作为测试数据,时间间隔为1h,这是一个典型的混沌时间序列.本文通过研究Dst指数的变化规律,建立提前1h预报Dst指数的方法.

4.4.1 参数设置

采用 AGA-BEL 模型对 Dst 指数时间序列进行 单步预测. 首先按上个实验的方法对 Dst 数据进行 归一化处理和相空间重构. 根据饱和关联维数法和 互信息函数法^[24]确定嵌入维数m = 4和延迟时间 $\tau = 1$. 采用单步预测方式,设置预测步数 $\eta = 1$. 采用代表 Dst 指数的时间序列: Dst(t), Dst(t-1), Dst(t-2), Dst(t-3),预测t+1时刻的 Dst 指数值 Dst(t+1). 在构造 BEL 网络时,设置网络输入层的 神经元为4个,输出神经元为1个. 构造一个输入数 据形式为 [Dst(t), Dst(t-1), Dst(t-2), Dst(t-3)] 的四维向量作为感官输入信号,预测模型输出用一 维向量 Dst(t+1) 表示. 基于 AGA-BEL 的 Dst 指 数预测网络简化表示如图 6 所示.



图 6 基于 AGA-BEL 的 Dst 指数预测模型 Fig. 6. AGA-BEL prediction model for Dst index.

设置输入节点数为4,输出节点数为1,隐含层 节点数由经验公式和交叉验证确定为10,网络初始 权值的取值范围为[-1,1].在自适应遗传算法设计 中,取种群大小为100,最大进化代数为50,染色体 长度为11,设定最大交叉概率和最小交叉概率分别 为 $p_{cmax} = 0.6 \ p_{cmin} = 0.1, 最大变异概率和最$ $小变异概率分别为<math>p_{max} = 0.1 \ n_{pmin} = 0.003.$ 经 过网络训练,将仿真数据进行反归一化处理,得到 Dst 指数序列的预测结果.

4.4.2 Dst 指数预测结果

根据磁暴的4个级别: $-50 < Dst \leq 30$ nT 为小磁暴; $-100 < Dst \leq -50$ nT为中等磁暴; -200 < Dst ≤ -100 nT 为大磁暴; Dst ≤ -200 nT 为特大磁暴^[28].因此,准确预测 Dst 指数的最小值 对避免空间灾难具有重要意义.图7所示为磁暴环 电流 Dst 指数的预测结果,从图中可以看出,绿色 的预测曲线很好地拟合了蓝色的实际曲线,说明 AGA-BEL 模型能够很好地描述磁暴期间 Dst 指数 的变化趋势,特别是 Dst 指数达到最小值时,即磁 暴最强点.

由图 8 所示的误差曲线可以看出, 各点的预测 误差在零点附近的较小范围内波动, 说明预测误差 小, 从而验证了 AGA-BEL 模型在磁暴事件预测问 题上的有效性.

为了进一步量化评估 AGA-BEL 模型的预测 性能,计算了预测模型的均方误差 *M*_{se} 以及预测值 与实际值的相关系数 *C*_{or}.图9代表均方误差曲线, 当算法进化到第50代时网络完全收敛,均方误差 *M*_{se}为0.0011859.

图 10 表示在 Dst 指数预测中的线性相关性, 其中, Y 表示模型预测值, T 表示 Dst 指数的实际 值, C_{or} 表示二者之间的相关系数. 从图 10 (a) 和 图 10 (b) 中可以看出, 在训练集与测试集上的相关 系数分别为0.9555 和0.9697, 说明 AGA-BEL 模型 对于 Dst 指数数据集具有很好的拟合性能.



图 8 Dst 指数预测误差曲线 Fig. 8. Error curve of Dst index prediction.

080502-9



Fig. 9. $M_{\rm se}$ of Dst index prediction.

4.4.3 与其他方法比较

为了在精度、速度和稳定性上对比验证 AGA-BEL的性能,在相同的实验条件下,分别采 用 MLP-BP^[26], LM-BP^[27]和基本 BEL 模型^[13] 对 Dst 指数进行单步预测.每种模型独立运行 50次,统计得到 *M*_{ad}, *M*_{se}, *M*_{ape}, *C*_{or} 及计算时间的平均 值.根据文献 [24],模型的稳定性采用 *M*_{ape}的方 差来评价.表2给出了不同模型对 Dst 指数的预测 结果.

从表2可以看出,相对于其他方法,AGA-BEL 预测模型的 M_{ad}, M_{se} 及 M_{ape} 均最小, C_{or} 最大,说 明 AGA-BEL 模型的预测精度最高.在预测稳定 性方面,AGA-BEL 模型 M_{ape} 的方差最小,说明其 预测的稳定性最好.在计算时间方面,BEL 模型 与 AGA-BEL 模型所用时间远远少于传统的 BP 网 络.AGA-BEL 模型中因执行了遗传算法的迭代 运算,所以计算时间比基本 BEL 模型稍长.总体 看来,AGA-BEL 模型在地磁 Dst 指数预测问题上 的准确性、稳定性和速度均优于传统模型.因此, AGA-BEL 模型在空间灾害的预警系统中具有巨大 的潜力和广阔的应用前景.



图 10 Dst 指数预测线性相关性 (a) 训练集; (b) 测试集

Fig. 10. Linear correlation of Dst index prediction: (a) Training datas; (b) testing datas.

					<pre></pre>		
模型 —		精度	M _{ape} 的方差	计算时间/s			
	$M_{\rm ad}$	$M_{\rm se}$	$M_{\rm ape}$	C_{or}			
MLP-BP	17.2465	16.1075	0.8373	0.7584	0.7426	27.6741	
LM-BP	12.3433	7.0643	0.6378	0.9237	0.5253	12.6425	
BEL	3.1268	0.2086	0.1165	0.9446	0.0287	1.5643	
SVM ^[28]	17.35	—	—	0.8900		—	
AD-BEL ^[1]	—	_		0.9532	_		
AGA-BEL	1.5367	0.0012	0.0631	0.9626	0.0023	2.6551	

表 2 不同模型对 Dst 指数单步预测的结果比较 Table 2. Dst index prediction performance comparisons of different models (1-step).

5 结 论

结合大脑情感学习模型和自适应遗传算法,提 出了一种混沌时间序列预测的新模型.利用大脑情 感学习模型模拟大脑边缘系统中的情感学习机制, 有效地克服了传统神经网络收敛速度慢的缺点.进 一步,采用基于自适应遗传算法的监督学习代替基 于奖励信号的强化学习,使预测模型能根据实际输 出和期望输出的差值来优化调节杏仁体和眶额皮 质的权值与阈值,增强了大脑情感学习模型的通用 性,提高了模型精度.在Lorenz标杆问题和实际地 磁Dst指数的预测中,实验结果表明了本文所提出 的AGA-BEL预测模型具有预测精度高、收敛速度 快和稳定性强的优点,而且模型结构简单,计算复 杂度低,便于用于实际的预测系统,如地下水位预 测系统、天气预测系统等.

参考文献

- [1] Lotfi E, Akbarzadeh T M R 2014 Neurocomputing 126 188
- [2] Singh S, Gill J 2014 Int. J. Intell. Syst. Appl. 6 55
- [3] Tian Z D, Gao X W, Shi T 2014 Acta Phys. Sin. 63 160508 (in Chinese) [田中大, 高宪文, 石形. 2014 物理学 报 63 160508]
- [4] Li D, Han M, Wang J 2012 IEEE Trans. Neural Netw. Learn. Syst. 23 787
- [5] Shi Z W, Han M 2007 IEEE Trans. Neural Netw. 18 359
- [6] Wang X Y, Han M 2015 Acta Phys. Sin. 64 070504 (in Chinese) [王新迎, 韩敏 2015 物理学报 64 070504]

- [7] Han M, Xi J H, Xu S G 2004 IEEE Trans. Signal Process. 52 3409
- [8] Su L Y 2010 Comput. Math. Appl. 59 737
- [9] Su L Y, Li C L 2015 Discrete. Dyn. Nat. Soc. 2015 329487
- [10] Tian Z D, Li S J, Wang Y H, Gao X W 2015 Acta Phys. Sin. 64 030506 (in Chinese) [田中大, 李树江, 王艳红, 高 宪文 2015 物理学报 64 030506]
- [11] Mayer J D, Roberts R D, Barsade S G 2008 Annu. Rev. Psych. 59 507
- [12] Ledoux J E 1991 Concepts Neurosci. 2 169
- [13] Balkenius C, Morén J 2001 Cybern. Syst. 32 611
- [14] Babaie T, Karimizandi L 2008 Soft. Comput. 12 857
- [15] Abdi J, Moshiri B, Abdulhai B 2012 Eng. Appl. Arti. Intell. 25 1022
- [16] Sharafi Y, Setayeshi S, Falahiazar A 2015 J. Math. Comput. Sci. 14 42
- [17] Milad H S A, Farooq U, Hawary M, Asad M U 2016 IEEE Access 23 569
- [18] Dorrah H T 2011 J. Adv. Res. 2 73
- [19] Mei Y, Tan G Z, Liu Z T 2017 Algorithms 10 70
- [20] Lotfi E, Akbarzadeh T M R 2016 Inf. Sci. 3 369
- [21] Srinivas M, Patnaik L M 2002 IEEE Trans. Syst. M. Cyber. 24 656
- [22] Guo Y Y 2013 M. S. Thesis (Harbin: Harbin Institute of Technology) (in Chinese) [郭圆圆 2013 硕士学位论文 (哈尔滨:哈尔滨工业大学)]
- [23] Takens F 1981 Lecture Notes in Mathematics (Berlin: Springer-Verlag) p366
- [24] Yang F 2012 Ph. D. Dissertation (Beijing: Beijing University of Posts and Telecommunications) (in Chinese) [杨飞 2012 博士学位论文 (北京:北京邮电大学)]
- [25] Lotfi E, Akbarzadeh T 2013 Cybernet. Syst. 44 402
- [26] Amani J, Moeini R 2012 Sci. Iran. 19 242
- [27] Li J, Feng J, Wang W 2016 Sci. Geog. Sin. **36** 780
- [28] Peng Y X, Lü J Y, Gu S J 2016 Chin. J. Space Sci. 36
 866 (in Chinese) [彭宇翔, 吕建永, 顾赛菊 2016 空间科学
 学报 36 866]

Chaotic time series prediction based on brain emotional learning model and self-adaptive genetic algorithm^{*}

Mei Ying¹⁾²⁾ Tan Guan-Zheng^{1)†} Liu Zhen-Tao³⁾ Wu $He^{2)}$

1) (School of Information Science and Engineering, Central South University, Changsha 410083, China)

2) (Information and Electric Engineering College, Hunan University of Arts and Science, Changde 415000, China)

3) (School of Automation, China University of Geosciences, Wuhan 430074, China)

(Received 22 September 2017; revised manuscript received 8 February 2018)

Abstract

Chaos phenomenon is one of the most important physical phenomena, which has significant effects on one's production and life. Therefore, it is indispensable to find out the regularity of chaotic time series from a chaotic system for weather forecasting, space missions, alarm systems, etc. Although various models and learning algorithms have been developed to predict chaotic time series, many traditional methods suffer drawbacks of high computational complexity, slow convergence speed, and low prediction accuracy, due to extremely complex dynamic characteristics of chaotic systems. In this paper, a brain-inspired prediction model, i.e., brain emotional learning (BEL) model combined with self-adaptive genetic algorithm (AGA) is proposed.

The establishment of BEL model is inspired by the neurobiology research, which has been put forward by mimicking the high-speed emotional learning mechanism between amygdala and orbitofrontal cortex in mammalian brain, it has advantages of lowcomputational complexity and fast learning. The BEL model employs reward-based reinforcement learning to adjust the weights of amygdala and orbitofrontal cortex. However, the reward-based method is modelsensitive and hard to generalize to other issues. To improve the performance of BEL model, AGA-BEL is proposed for chaotic prediction, in which the AGA is employed for parameter optimization. Firstly, weights and biases of orbitofrontal cortex and amygdala in BEL model are distributed to chromosomal gene sequence for optimization. Secondly, fitness function is employed to adjust the weights of amygdale and orbitofrontal cortex by self-adaptive crossover and mutation operations. Therefore, the parameter optimization problem is transformed into a function optimization problem in the search space. Finally, the best chromosome that represents the best combination of weights and biases for BEL model is chosen, which is used for chaotic prediction.

Prediction experiments on the benchmark Lorenz chaotic time series and a real-world chaotic time series of geomagnetic activity Dst index are performed. The experimental results and numerical analysis show that the proposed AGA-BEL prediction model achieves lower mean absolute deviation, mean square error, mean absolute percentage error, and higher correlation coefficient than the original BEL, levenberg marquardt-back propagation (LM-BP) and multilayer perceptron-back propagation (MLP-BP). Meanwhile, the BEL-based models take less computational time than the traditional BP-based models. Therefore, the proposed AGA-BEL model possesses the advantages of fast learning and low computational complexity of BEL model as well as the global optimum solution of AGA. It is superior to other traditional methods in terms of prediction precision, execution speed, and stability, and it is suited for online prediction in fast-varying environments.

Keywords: chaotic time series, prediction, brain emotional learning, self-adaptive genetic algorithmPACS: 05.45.Tp, 05.45.GgDOI: 10.7498/aps.67.20172104

^{*} Project supported by the National Natural Science Foundation of China (Grant Nos. 61403422, 61703156), the Hunan Education Department Science Research Foundation, China (Grant No. 17C1084), and the Science Research Project of Hunan University of Arts and Science, China (Grant No. 17ZD02).

[†] Corresponding author. E-mail: 63641214@qq.com