

过程神经网络及其在时变信息处理中的应用

何新贵, 许少华

(北京大学 视觉听觉智能信息处理国家实验室, 北京 100871)

摘 要:针对时变信息处理和动态系统建模等类问题,建立了输入输出均为时变函数的过程神经网络和有理式过程神经网络 2 种网络模型. 在输入输出为时变函数的过程神经网络中,过程神经元的时间累积算子取为对时间的积分或其他代数运算,它的时空聚合机制和激励能同时反映外部时变输入信号对输出结果的空间聚合作用和时间累积效应,可实现非线性系统输入、输出之间的复杂映射关系. 在有理式过程神经网络中,其基本信息处理单元为由 2 个成对偶出现的过程神经元组成,逻辑上分为分子和分母 2 部分,通过有理式整合后输出,可有效提高过程神经网络对带有奇异值过程函数的柔韧逼近性和在奇异值点附近反应的灵敏性. 分析了 2 种过程神经网络模型的性质,给出了具体学习算法,并以油田开发过程模拟和旋转机械故障诊断问题为例,验证了这 2 种网络模型在时变信息处理中的有效性.

关键词:过程神经网络;时变系统;信息处理;学习算法;仿真试验

中图分类号: TP18 **文献标识码:** A **文章编号:** 1673-4785 (2006) 01-0001-08

Process neural networks and its applications in
time-varying information processing

HE Xin-gui, XU Shao-hua

(National Laboratory on Machine Perception, Peking University, Beijing 100871, China)

Abstract: Aimed at the problems of the time-varying information processing and the dynamic system modeling, two kinds of process neural network models, including the rational formula process neural networks and the process neural networks with time-varying inputs and outputs function, were built in this paper. In the process neural networks with time-varying inputs and outputs function, the time accumulation operator of process neuron was adopted as the integral to time or other algebra operations, its space-time aggregation mechanism and incitation could synchronously reflect the space aggregation and stage time accumulation effect of exterior time-varying input signals to the output results, so as to complete the complex mapping relationship between the inputs and outputs of non-linear system. In the rational formula process neural networks, its basic information processing unit was made up of two process neurons which appear dually, and logically divided into numerator and denominator, then output after rational formula combining, it can effectively advance the flexile approximation of process neural networks to the process functions which have singular values and the facility of reaction nearby the singular value point. The characteristics of these two kinds of process neural networks models were analyzed in this paper, the concrete learning algorithms were given, the effectiveness of these two kinds of network modes in time-varying information processing was proved by the cases of the process simulation and fault diagnosis of rotating machinery in the oil filed exploitation.

Key words: process neural networks; time-varying system; information processing; learning algorithm; simulation experiment

随着现代科学技术研究领域的不断扩大, 针对复杂非线性系统建模、时变过程信号处理、智能过程控制等问题的研究已成为智能科学理论与应用领域非常活跃的一个前沿方向. 目前, 应用于时变信号处理和非线性系统建模的智能方法和技术主要包括人

收稿日期: 2006-02-23.
基金项目: 国家自然科学基金资助项目 (60373102, 60473051); 教育部博士点基金资助项目 (20030001701).

工神经网络、模糊计算、进化计算、协同计算、信息融合、分形理论、粗糙集理论等^[1],其中模仿和延伸人脑认知功能的人工神经网络由于具有并行性、高度的非线性、容错性以及结构可变性等特点而被广泛采用。

人工神经网络是一种新型的智能系统,它是由大量的简单处理单元(人工神经元)互联而成的一个具有自学习、自适应和自组织性的非线性动力系统,也是一个具有全新计算结构模型的智能信息处理系统。目前具有实用价值的人工神经网络模型大多是基于 MP 神经元模型^[2]构建的,系统的输入为与时间无关的常量,即网络的输入、输出是几何点式的瞬时对应关系。对于时变信号和动态系统的信息处理问题,一些学者已提出了若干动态神经网络模型,例如,延时单元网络^[3]、时空神经元模型^[4]、递归网络^[5]、部分反馈网络^[6]等,这些网络模型在解决系统过程式输入和时间顺序依赖性问题时,通常是将时间关系转化为空间关系(时间序列)后,再以外延环节实现输入输出之间的动态映射,即构成一个时间离散化的循环网络。但这些模型的本质还都是基于传统神经元,并未改变传统神经元本身的信息处理机制。

生物学研究结果表明^[7-8]:在生物神经元中,突触的输出变化与输入脉冲的相对定时有关,即依赖于持续一定时间的输入过程;生物神经系统的输出不仅与输入信号的空间聚合作用有关,而且也依赖于时间过程的累积效应。在一些实际问题中,许多系统的输入也往往是一个过程,或依赖于时间变化的函数,系统的输出不仅与系统当前的输入和状态有关,而且也与过去一段时间内输入时间效应的累积相关。笔者根据生物神经系统的信息处理特性和实际应用问题需求,将传统人工神经元的聚合运算机制和激励方式向时间域扩展,建立了过程神经元和过程神经网络模型^[9]。过程神经元与传统神经元 MP 模型的结构相类似,不同之处在于过程神经元的输入和连接权都可以是时变函数,并在传统神经元空间加权聚合运算的基础上增加了一个对于时间的累积算子,使过程神经元的聚合运算和激励能同时反映时变输入信号的空间加权聚合和时间累积效应,并证明了过程神经网络的连续性、泛函数逼近能力、计算能力、传统神经网络是过程神经网络的一个特例等理论问题^[10]。在此基础上,根据过程神经元的信息处理机制和实际问题需求,构建了反馈过程神经网络^[11]、自组织过程神经网络^[12]、径向基函数过程神经网络^[13]等网络模型。过程神

经元网络把传统人工神经网络输入输出间的映像关系从函数映像推广为泛函数映像,极大地扩大了人工神经网络的表达能力。

针对时变信息处理问题,文中在过程神经网络基本模型的基础上,建立了输入输出均为时变函数的过程神经网络和有理式过程神经网络模型。给出输入输出均为时变函数,过程神经网络和有理式过程神经网络 2 种模型具体的学习算法,并以旋转机械故障诊断和油田开发采油过程动态模拟问题为例,验证模型和算法的有效性。

1 过程神经网络

1.1 过程神经元

1.1.1 过程神经元基本模型

过程神经元是由时变输入信号加权,时间、空间二维聚合和阈值激励输出等运算组成,其结构如图 1 所示。




图 1 过程神经元

Fig. 1 Process neuron

图 1 中, $x_1(t), x_2(t), \dots, x_n(t)$ 为过程神经元的时变输入函数; $w_1(t), w_2(t), \dots, w_n(t)$ 为相应的连接权函数;“ \oplus ”为过程神经元的空间聚合算子,“ \otimes ”为时间累积算子,“ \oplus ”和“ \otimes ”构成了过程神经元时空二维聚合运算对; $K(t)$ 为过程神经元的时间聚合核函数, $f(\cdot)$ 为激励函数。

过程神经元输入与输出之间的映射关系为

$$y = f((W(t) \oplus X(t)) \otimes K(\cdot)). \quad (1)$$

在式(1)中,如果“ \oplus ”取为空间加权和,“ \otimes ”取对时间的积分,且 $K(\cdot) = 1$,则式(1)可写为

$$y = f\left(\sum_{i=1}^n w_i(t) x_i(t)\right). \quad (2)$$

1.1.2 输入输出均为时变函数的过程神经元

这类过程神经元的输入输出均可为时变函数,其空间聚合算子取为多输入信号加权和,时间累积算子取为对时间的积分,结构如图 2 所示。

图 2 中,“ \oplus ”为过程神经元的空间聚合算子,

“ ”为过程神经元的时间累积算子, $y(t)$ 为过程神经元的输出.




图 2 输入输出均为时变函数过程神经元
Fig. 2 Process neuron with time-varying inputs/outputs

由图 2,输入输出均为时变函数,过程神经元输入与输出之间的映射关系为

$$y(t) = f\left(\int_0^t \sum_{i=1}^n w_{ij}(\tau) x_i(\tau) d\tau - \theta(t)\right). \quad (3)$$

式中: $\theta(t)$ 为过程神经元的激励阈值,也为时间函数.

式(3)中的时空聚合算子还可以取其他形式的运算,例如对应输入时间点 t ,空间加权聚合运算可取 \max 或 \min , S —算子或 T —算子;时间聚合算子可为 $[0, t]$ 区间上的褶积、取大或取小运算等.

由式(3)知,这类过程神经元模型同时表示了时变输入信号的空间加权聚合以及在时刻 t 对已输入时变信号的阶段时间效应累积,可实现输入、输出之间的同步映射关系.

1. 1. 3 有理式过程神经元

有理式过程神经元由 2 个成对偶出现的过程神经元组成,逻辑上分为分子和分母 2 部分,通过有理式整合后输出,其结构如图 3 所示.




图 3 有理式过程神经元
Fig. 3 Rational formula process neuron

图 3 中, $x_1(t), x_2(t), \dots, x_n(t)$ 为有理式过程神经元的时变输入函数; $w_1(t), w_2(t), \dots, w_n(t)$ 为对应于分子部分相应的连接权函数(图中实线连接部分), $v_1(t), v_2(t), \dots, v_n(t)$ 为对应于分母部分的连接权函数(图中虚线连接部分);“ Σ_1, \int_1, f_1 ”为有理式过程神经元分子部分的时、空聚合算子和激励

函数,“ Σ_2, \int_2, f_2 ”为分母部分的时、空聚合算子和激励函数, y 为有理式过程神经元的输出.

若 Σ_1, Σ_2 均取为空间加权求和运算, \int_1, \int_2 均取为过程积分算子,则

$$y = \frac{f_1\left(\int_0^T \sum_{i=1}^n w_i(t) x_i(t) dt - \theta^{(u)}\right)}{f_2\left(\int_0^T \sum_{i=1}^n v_i(t) x_i(t) dt - \theta^{(d)}\right)}. \quad (4)$$

式中: $\theta^{(u)}, \theta^{(d)}$ 分别为有理式过程神经元分子部分和分母部分的阈值.

1. 2 过程神经网络

1. 2. 1 基本模型

由若干过程神经元和其他类型的神经元按照一定拓扑结构可构成过程神经网络. 含一个过程神经元隐层的多输入单输出系统(容易推广到多输入多输出情况)结构如图 4.




图 4 过程神经网络
Fig. 4 Process neural networks

由图 4,网络输入输出之间的映射关系为

$$y = g\left(\sum_{j=1}^m v_j f\left(\int_0^T \sum_{i=1}^n w_{ij}(t) x_i(t) dt - \theta_j^{(1)}\right)\right). \quad (5)$$

式中: $w_{ij}(t)$ ($i = 1, 2, \dots, n; j = 1, 2, \dots, m$) 为输入层节点与隐层节点的连接权函数; v_j ($j = 1, 2, \dots, m$) 为隐层节点到输出节点的连接权; $[0, T]$ 为时变信号输入过程区间, f 为过程神经元激励函数, $\theta_j^{(1)}$ 为隐层节点的激励阈值, g 为输出神经元激励函数, $\theta^{(1)}$ 为输出神经元阈值.

1. 2. 2 输入输出均为时变函数的过程神经网络

若干由式(3)定义的过程神经元和其他类型的神经元按照一定的结构关系可构成输入输出均为时变函数的过程神经网络. 在网络中,相同类型的神经元具有相同的结构,共享理论和学习算法,执行相同的聚合运算;同时,各神经元隐层之间的信息传递

应满足网络模型中各类神经元输入输出信号类型的定义. 为讨论问题简单, 考虑仅含一个由式(3)定义的过程神经元隐层、线性输出的前馈过程神经网络模型, 网络拓扑结构如图5所示.




图5 输入输出均为时变函数的过程神经网络

Fig. 5 PNN with time-varying inputs/outputs

图5中, $v_j(t)$ ($j = 1, 2, \dots, m$) 为隐层节点到输出节点的连接权函数; $y(t)$ 为网络输出函数.

由图5, 网络输入输出之间的映射关系为

$$y(t) = \sum_{j=1}^m v_j(t) f\left(\int_0^t \sum_{i=1}^n w_{ij}(\tau) x_i(\tau) d\tau - j(t)\right), t \in [0, T]. \quad (6)$$

式中: $[0, T]$ 为时变信号输入过程区间, f 为过程神经元激励函数, $j(t)$ 为隐层过程神经元节点 j 的阈值函数.

1.2.3 有理式过程神经网络模型

有理式过程神经网络是以有理式过程神经元为基本信息处理单元的过程神经网络模型. 其思想来源于函数逼近论中有理函数的逼近性质以及过程神经网络具有的对时变信号的非线性变换能力, 利用所构建的类似于有理式函数形式的过程神经元信息处理单元之间的逻辑运算关系, 来提高过程神经网络对带有奇异值过程函数的柔韧逼近性和在奇异值点附近反应的灵敏性. 网络拓扑结构如图6所示.




图6 有理式过程神经网络

Fig. 6 Rational formula PNN

图6中, 实线表示输入层各节点与有理式过程神经元分子部分的连接, 权函数为 $w_{ij}(t)$ ($i = 1, 2, \dots, n; j = 1, 2, \dots, m$); 虚线表示与各分母部分的连接, 权函数为 $v_{ij}(t)$. 输入层有 n 个节点, 完成时变函数 $x_1(t), x_2(t), \dots, x_n(t)$ 的输入; 隐层有 m 个有理式过程神经元, 分别完成分子、分母过程神经元的时空聚合运算以及它们输出的有理式整合; 输出层为一个一般非时变神经元, 隐层到输出层的连接权为 u_j ($j = 1, 2, \dots, m$), 网络输出为 y .

由图6, 有理式过程神经网络的输出为

$$y = g\left(\sum_{j=1}^m u_j \cdot \frac{f_1\left(\int_0^T \sum_{i=1}^n w_{ij}(\tau) x_i(\tau) d\tau - j^{(u)}\right)}{f_2\left(\int_0^T \sum_{i=1}^n v_{ij}(\tau) x_i(\tau) d\tau - j^{(d)}\right)}\right). \quad (7)$$

2 过程神经网络性质分析

对于输入输出均为时变函数的过程神经网络, 由式(6)知, 该模型中的时、空聚合算子都是连续的, 因此, 若网络输入/输出函数、连接权函数和激励函数均连续, 则网络满足连续性.

关于泛函数逼近性质, 由文献[10]中的定理3, 对任意的连续泛函数 $G(x(t)): U \subset C(R^n) \rightarrow V \subset R$ 和 $\epsilon > 0$, 存在输入为时变函数向量, 输出为一个非时变值的过程神经网络 P , 使得 $|G(x(t)) - P(x(t))| < \epsilon$. 对于输入输出均为时变函数的过程神经网络, 当输出函数连续且满足 Lipschitz 条件时, 由于式(6)中的时空聚合算子分别为加权求和及含参变的积分, 故可采用分时间粒度逼近的方法, 证明对任意的连续泛函数 $G(x(t)): U \subset (C[0, T])^n \rightarrow Z \subset C[0, T]$ 和 $\epsilon > 0$, 若 Z 中的函数 $y(t)$ 满足 Lipschitz 条件, 即 $|y(t_1) - y(t_2)| \leq L_y |t_1 - t_2|$ (式中: $L_y > 0$ 为 Lipschitz 常数), 则存在由式(6)定义的过程神经网络 P , 使得 $|G(x(t)) - P(x(t))| < \epsilon$.

关于有理式过程神经网络, 在图6中, 若 $v_{ij}(t) = 0$, 则有理式过程神经网络简化为一个单隐层的过程神经网络. 文献[10]中已经证明了通过线性加权和实现空间聚合的过程神经网络的连续性, 对连续泛函数的可逼近性以及图灵机等价的计算能力等性质定理. 有理式过程神经网络是上述过程神经网络的一种扩展形式, 因此, 其泛函逼近能力和计算能力不会小于过程神经网络. 另一方面, 有理式过程神经网络与单隐层过程神经网络相比只增加了1个有理式整合层, 而有理式运算

可用图灵机实现,故有理式过程神经网络也具有对任意连续泛函的逼近能力和与图灵机等价的计算能力.同时,通过线性加权和实现空间聚合的过程神经网络是连续的,而且有理数式函数具有连续性,因此,当激励函数 f_1, f_2, g 连续时,有理式过程神经网络也具有连续性.

3 学习算法

在网络输入输出函数空间中引入一组适当的基函数系,将输入、输出函数在给定的拟合精度下表示为该组基函数的有限项展开形式,同时,将权函数也表示为该组基函数的有限项级数形式.权函数基展开的作用是在权函数形式未知的情况下,给出权函数一种公共的函数类型.这样,在网络训练中可不必特别考虑权函数的具体函数形式,只需根据实际系统的统计特征选择适当的基函数系.采用这种方法,就将输入输出均为时变函数过程神经网络和有理式过程神经网络根据学习样本集进行的关于网络连接权函数的训练问题,转化为对权函数基展开式中非时变系数的学习问题,从而可借助已有的学习算法或构造新的算法进行过程神经网络的训练.

3.1 输入输出均为时变函数过程神经网络的学习算法

设过程神经网络的输入函数空间为 $(C[0, T])^n$, $b_1(t), b_2(t), \dots, b_L(t)$ 为 $C[0, T]$ 中一组满足输入函数拟合精度要求的基函数(例如,三角函数系、Walsh 函数系、多项式函数等), $X(t) = (x_1(t), x_2(t), \dots, x_n(t))$ 为网络输入空间中的任意函数,则 $x_i(t)$ 的基函数展开形式可表示为

$$x_i(t) = \sum_{l=1}^L a_{il} b_l(t), i = 1, 2, \dots, n. \tag{8}$$

式中 L 为满足基函数展开拟合精度要求的基函数项数.

将式(6)中的权函数 $w_{ij}(t), v_j(t)$ 和阈值函数 $j(t)$ 也用基函数 $b_1(t), b_2(t), \dots, b_L(t)$ 的展开形式表示,

$$w_{ij}(t) = \sum_{l=1}^L w_{ij}^{(l)} b_l(t),$$

$$i = 1, 2, \dots, n; j = 1, 2, \dots, m, \tag{9}$$

$$v_j(t) = \sum_{l=1}^L v_j^{(l)} b_l(t), j = 1, 2, \dots, m, \tag{10}$$

$$j(t) = \sum_{l=1}^L j^{(l)} b_l(t), j = 1, 2, \dots, m. \tag{11}$$

式中 $w_{ij}^{(l)}, v_j^{(l)}, j^{(l)}$ 分别为 $w_{ij}(t), v_j(t), j(t)$ 相对于 $b_l(t)$ 的基展开系数,为可调非时变参数.

将式(8)~(11)代入式(6),并整理得

$$y(t) = g\left(\sum_{j=1}^m \left(\sum_{l=1}^L v_j^{(l)} b_l(t)\right) f\left(\sum_{i=1}^n \sum_{l=1}^L a_{il} w_{ij}^{(l)} \cdot \int_0^t b_l(\tau) b_s(\tau) d\tau - \sum_{l=1}^L j^{(l)} b_l(t)\right)\right). \tag{12}$$

给定 K 个学习样本: $(x_{k1}(t), x_{k2}(t), \dots, x_{kn}(t), d_k(t)), k = 1, 2, \dots, K$; 式中 $d_k(t)$ 为对应输入 $x_{k1}(t), x_{k2}(t), \dots, x_{kn}(t)$ 网络的期望输出函数. 设对应第 k 个样本输入网络的实际输出为 $y_k(t)$, 记 $B_{ks}(t) = \int_0^t b_l(\tau) b_s(\tau) d\tau$, 则网络误差函数可定义为

$$E = \sum_{k=1}^K \int_0^T \left(y_k(t) - d_k(t) \right)^2 dt = \sum_{k=1}^K \int_0^T \left(g\left(\sum_{j=1}^m \left(\sum_{l=1}^L v_j^{(l)} b_l(t)\right) f\left(\sum_{i=1}^n \sum_{l=1}^L a_{il} w_{ij}^{(l)} B_{ks}(t) - \sum_{l=1}^L j^{(l)} b_l(t)\right) \right) - d_k(t) \right)^2 dt \tag{13}$$

式中 $a_{il}^{(k)}$ 为 $x_{ki}(t)$ 在基函数展开式中对应于 $b_l(t)$ 的系数.

将过程区间 $[0, T]$ 进行适当的 P 等分(时间粒度),记区间分割点为 t_0, t_1, \dots, t_P . 将式(8)~(11)另写为

$$x_i(t_p) = \sum_{l=1}^L a_{il}^{(k)} b_l(t_p), \tag{14}$$

$$w_{ij}(t_p) = \sum_{l=1}^L w_{ij}^{(l)} b_l(t_p), \tag{15}$$

$$v_j(t_p) = \sum_{l=1}^L v_j^{(l)} b_l(t_p), \tag{16}$$

$$j(t_p) = \sum_{l=1}^L j^{(l)} b_l(t_p). \tag{17}$$

将式(14)~(17)带入式(13),有

$$E = \sum_{k=1}^K \sum_{p=1}^P \left(g\left(\sum_{j=1}^m \left(\sum_{l=1}^L v_j^{(l)} b_l(t_p)\right) f\left(\sum_{i=1}^n \sum_{l=1}^L a_{il} w_{ij}^{(l)} B_{ks}(t_p) - \sum_{l=1}^L j^{(l)} b_l(t_p)\right) \right) - d_k(t_p) \right)^2. \tag{18}$$

由于基函数 $b_l(t)$ 在过程区间 $[0, T]$ 上为已知函数,因此,可用积分或数值计算的方法求出 $B_{ks}(t)$ 在 $[0, T]$ 中每个分割点处的值,即当过程区间各分割点确定后, $b_l(t_p)$ 和 $B_{ks}(t_p)$ 均可在网络训练前通

过预处理程序计算确定. 因此, 采用供传统神经网络学习的梯度下降等学习算法, 即可确定出网络连接权函数.

3.2 有理式过程神经网络的学习算法

将式(6)中的 $v_{ij}(t)$ 用基函数 $b_1(t), b_2(t), \dots, b_L(t)$ 的展开形式表示

$$v_{ij}(t) = \sum_{l=1}^L v_{ij}^{(l)} b_l(t). \tag{19}$$

把式(8), (9), (19)代入式(7), 整理得

$$y = g\left(\sum_{j=1}^m u_j \cdot \frac{f_1\left(\sum_{i=1}^n \sum_{l=1}^L \sum_{s=1}^L a_{il} w_{ij}^{(l)} \int_0^T b_l(t) b_s(t) dt - \sum_{j=1}^{(w)} \right)}{f_2\left(\sum_{i=1}^n \sum_{l=1}^L \sum_{s=1}^L a_{il} v_{ij}^{(l)} \int_0^T b_l(t) b_s(t) dt - \sum_{j=1}^{(d)} \right)}\right). \tag{20}$$

记: $B_{ls} = \int_0^T b_l(t) b_s(t) dt$. 由于 $b_l(t)$ 在区间 $[0, T]$ 上为已知函数, 因此, B_{ls} 为一确定数值. 给定 K 个学习样本: $(x_{k1}(t), x_{k2}(t), \dots, x_{kn}(t), d_k), k = 1, 2, \dots, K$; 式中: d_k 为对应输入 $x_{k1}(t), x_{k2}(t), \dots, x_{kn}(t)$ 网络的期望输出. 定义网络训练误差函数

$$E = \sum_{k=1}^K \left(g\left(\sum_{j=1}^m u_j \cdot \frac{f_1\left(\sum_{i=1}^n \sum_{l=1}^L \sum_{s=1}^L a_{il}^{(k)} w_{ij}^{(l)} B_{ls} - \sum_{j=1}^{(w)} \right)}{f_2\left(\sum_{i=1}^n \sum_{l=1}^L \sum_{s=1}^L a_{il}^{(k)} v_{ij}^{(l)} B_{ls} - \sum_{j=1}^{(d)} \right)}\right) - d_k \right)^2. \tag{21}$$

式(21)仅含 $u_j, w_{ij}^{(l)}, v_{ij}^{(l)}, \sum_{j=1}^{(w)}, \sum_{j=1}^{(d)}$, 等非时参变数, 上述网络的训练问题就化成了传统神经网络的训练, 采用诸如梯度下降等学习算法, 即可完成网络的训练.

4 应用实例

例 1 油田开发采油过程动态模拟

油田开发中油气开采主要分成 3 个阶段进行, 即依据原始地层能量的自然开采、注水驱油开采、注聚合物开采. 油藏采收率(采出程度)是衡量一个油田开发水平的重要指标, 开发方式不同, 所获得的最终采收率也不同. 实验室模拟地层条件下进行的驱替采油实验是合理制定油田采油开发方案的重要依据. 实验过程分为 3 个阶段: 原始含油饱和度下的注水驱油、注水驱油不见效后的注聚合物驱油和后续阶段的注水驱油. 注采系统输入变量有 2 个: 驱替物(水或聚合物)注入体积和注入压力增量, 这 2 个变量都是随时间变化的函数, 系统输出为随时间变化

的采收率. 因此, 采用输入输出均为时变函数的过程神经网络进行实验室岩心驱替采油过程模拟具有较好的适应性.

选取 11 块体积尺寸、岩性、物性、含油性十分接近的人造岩心样品, 在不同的注入速度、注入压力增量(即不同的开发方式)下进行实验, 采样间隔为 30 min, 整个实验共得到 11 组记录. 其中一块岩心样品实验数据见表 1.

表 1 一个岩心样品实验记录
Table 1 The experimental record of a core sample

序号	时间 / h	注入体积 / PV	注入压力增量 / MPa	采出程度 / %
1	0.5	0.15	0.015	19.75(水驱开始)
2	1.0	0.30	0.035	26.30
3	1.5	0.45	0.065	30.61
4	2.0	0.86	0.115	36.00
5	2.5	1.20	0.065	37.88
6	3.0	1.86	0.030	37.88
7	3.5	1.93	0.015	37.88(水驱结束, 聚驱开始)
8	4.0	1.99	0.055	38.42
9	4.5	2.06	0.090	41.02
10	5.0	2.12	0.140	45.77
11	5.5	2.16	0.185	48.91
12	6.0	2.25	0.230	52.77(聚驱结束, 后续水驱开始)
13	6.5	2.36	0.165	57.25
14	7.0	2.43	0.095	57.79
15	7.5	2.50	0.035	57.88
16	8.0	2.57	0.025	57.88
17	8.5	2.63	0.025	57.88(后续水驱结束)

以 1~8 号岩心样品实验结果组成网络训练样本集, 9~11 号岩心样品组成测试集. 选择 Walsh 函数系作为输入、输出函数和权函数基展开的基函数系. 将获得的 11 组实验数据在精度 0.05 下分别进行 Walsh 基函数拟合^[14], 当基函数个数为 16 时, 满足各组实验数据的拟合精度要求. 过程神经网络结构选择为 2-8-1, 即 2 个输入节点, 8 个输入输出为时变函数的过程神经元隐层节点, 1 个输出节点. 学习效率均取 0.50, 激励函数 f, g 取为 Sigmoid 函数, 最大学习次数设定为 3 000, 学习精度为 0.01. 网络实际学习 1 326 次后收敛. 对测试集的 3 个岩心样本进行采出程度过程预测, 在采样点处最大误差

为 3.18, 平均绝对误差 1.56, 平均相对误差为 3.87%, 预测结果能够满足实际问题分析需要. 可将经训练的过程神经网络模型实际应用于同类型的油田, 预测出各种不同开发方式下采收率的变化情况.

例 2 在旋转机械故障诊断中的应用

旋转机械是以转子及其他回转部件作为工作主体的机械设备. 对于旋转机械故障诊断问题, 不同故障类型对应不同的时域波形信号, 因此可通过对采样区间内连续信号波形的识别, 实现故障诊断. 旋转机械运动呈周期性, 故可把机械的 1 个旋转周期作为采样区间, 把 1 个周期内的信号连续变化过程作为 1 个样本. 旋转机械的典型故障主要分为偏心、不同轴、磨损以及正常共 4 种情况. 典型信号曲线如图 7 所示.




图 7 旋转机械运动 4 种典型曲线

Fig. 7 Four kinds of typical curves of rotating mechanical movement

采用有理式过程神经网络进行旋转机械故障自动诊断, 以一个周期内的连续变化信号作为网络输入, 输出为机械工作状态 (故障类型). 针对上述 4 种情况, 在实际测量信号中, 分别选取 5 条不同轴、6 条偏心、7 条磨损和 4 条正常共 22 条曲线组成学习样本集, 另外 8 个样本作为测试集. 有理式过程神经网络结构参数选择如下: 1 个输入节点, 5 个有理式过程神经网络隐层节点, 1 个输出节点, 激励函数采用 Sigmoid 函数. 由于网络输入信号呈周期性, 故基函数选用三角函数系, 基函数个数为 50 (由 22 个学习样本和 8 个测试样本在拟合误差精度 0.001 下实验确定). 学习效率均取 0.45; 最大学习次数 $N = 3\,000$, 学习精度 $= 0.05$.

采用不同的初值, 对网络进行了 20 次训练, 获得 20 个故障检测模型. 各次训练平均迭代 312 次后收敛. 用 20 个故障检测模型分别对测试集样本进行判别检测, 其中 4 个模型全部判对, 11 个模型各有 1

个判错, 5 个模型各有 2 个判错, 平均可正确检测率为 90.5%. 这与已有的一些旋转机械故障自动诊断方法比较, 效果较好.

5 结束语

本文针对非线性系统动态过程模拟和复杂时变信号模式分类问题, 建立了 2 种过程神经网络模型. 在输入输出均为时变函数过程神经网络中, 时空聚合运算和激励能同时反映外部时变输入信号对输出结果的空间聚合作用和时间累积效应, 在机制上对于建立非线性系统输入/输出之间的复杂映射关系具有较好的适应性. 在有理式过程神经网络中, 结合了有理函数逼近的良好性质和过程神经网络对时变信息的非线性变换机制, 可有效提高过程神经网络对带有奇异值过程函数的柔韧逼近性和在奇异值点附近反应的灵敏性. 由于 2 种过程神经网络模型都具有连续性和对连续泛函的可逼近性, 因此, 在复杂动态系统建模和时变信号模式识别等方面具有广泛的适应性.

参考文献:

- [1] 高 隼. 智能信息处理方法导论 [M]. 北京: 机械工业出版社, 2004.
GAO Jun. The introduction of intelligence information processing technology [M]. Beijing: China Machine Press, 2004.
- [2] MCCULLOCH W S, PITTS W H. A logical calculus of the ideas immanent in neuron activity [J]. Bulletin Mathematical Biophysics, 1943, 5(1): 115 - 133.
- [3] WABER A. Phoneme recognition using time delay NN [J]. IEEE Trans ASSP, 1989, 37(2): 328 - 339.
- [4] TSOI A C. Locally recurrent globally feedforward networks [J]. IEEE Transactions on Neural Networks, 1994(5): 229 - 239.
- [5] DRA YE J S. Dynamic recurrent NN: A dynamical analysis [J]. IEEE Trans SMC(B), 1996, 26(2): 692 - 706.
- [6] HERTS J. Introduction to the Theory of Neural Computation [M]. Boston: Addison Wesley, 1991.
- [7] 欧阳楷, 刘卫芳. 基于生物的神经网络的理论框架——神经元模型 [J]. 北京生物医学工程, 1997, 16(2): 93 - 101.
OU YANG Kai, LIU Weifang. The biology-based theoretical frame for the neural network—neuron model [J]. Beijing Biomedical Engineering, 1997, 16(2): 93 - 101.
- [8] ZHANG Li, TAO Huizhong, HOLTC E, et al. A critical window for cooperation and competition among developing retinotectal synapses [J]. Nature, 1998, 395: 37 - 44.

- [9] HE Xingui, LIANG Jiuzhen. Process Neural Networks [A]. Proceedings of Conference on Intelligent Information Processing[C]. Beijing, 2000.
- [10] 何新贵, 梁久祯. 过程神经网络的若干理论问题[J]. 中国工程科学, 2000, 2(12): 40 - 44.
- HE Xingui, LIANG Jiuzhen. Some theory issues of process neural networks [J]. Engineering Science, 2000, 2(12): 40 - 44.
- [11] 何新贵, 许少华. 一类反馈过程神经网络模型及其学习算法[J]. 自动化学报, 2004, 30(6): 801 - 806.
- HE Xingui, XU Shaohua. A feedback process neuron network model and its learning algorithm[J]. Acta Automatica Sinica, 2004, 30(6): 801 - 806.
- [12] 许少华, 何新贵. 自组织过程神经网络及其应用研究[J]. 计算机研究与发展, 2003, 40(11): 1612 - 1615.
- XU Shaohua, HE Xingui. Research and applications of self-organization process neural networks[J]. Journal of Computer and Development, 2003, 40(11): 1612 - 1615.
- [13] 许少华, 何新贵. 径向基过程神经网络及其应用研究[J]. 北京航空航天大学学报, 2004, 30(1): 14 - 17.

XU Shaohua, HE Xingui. Research and applications of radial basis process neural networks[J]. Journal of Beijing University of Aeronautics and Astronautics, 2004, 30(1): 14 - 17.

- [14] 王能超. 同步并行算法设计[M]. 北京: 科学出版社, 1996.


WANG Nengchao. The design of synchronous parallel algorithm[M]. Beijing: Science Press, 1996.

作者简介:



何新贵, 男, 1938 年生, 北京大学教授, 博士生导师, 中国工程院院士, 北京计算机学会理事长. 《计算机学报》副主编. 主要研究方向为模糊逻辑、神经网络、进化计算、数据库理论, 发表论文 130 余篇, 其中多篇被 SCI、EI 检索.

E-mail: hexg @cae. cn.



许少华, 男, 1962 年生, 博士后, 教授, 博士生导师. 研究方向为模式识别、神经网络、智能信息处理. 在国内外学术期刊发表论文 50 余篇, 其中 20 多篇被 SCI、EI 检索.

E-mail: xush62 @163. com

2006 国际计算智能与信息安全会议征文

国际计算智能与信息安全会议(CIS)是一个重要的国际性会议, 每年召开一次, 会议聚集了学术界和工作在计算智能与信息安全边缘学科领域的研究人员、工程师、开发商及专业人员, 分享经验, 交流思想, 相得益彰。2006 国际计算智能与信息安全会议由(香港)电气和电子工程师学会计算智能分会和广东工业大学共同组织, 主办单位有香港浸会大学计算机科学系、西安电子科技大学和济南大学。此次会议论文集将正式出版, SCI 检索, 会议召开时间为 2006. 11. 3 - 2006. 11. 6, 征文截稿日期为 2006. 6. 15。征文范围涉及: 人工免疫系统、面向自主的计算、生物计算、共同进化算法、进化计算、模糊系统、智能主体与系统、机器学习、分子计算、神经计算学、概率推理、强化学习、群体智能、支持向量机、无监督学习密码系统与编码、密码协议、异常检测、电子商务安全、侵入窃密检测、信息隐蔽、信息安全管理、信息存贮与检索系统、移动编码与主体安全、媒体数据验证、安全模式与体系结构、安全分析方法论、隐写术与水印、网络与无线安全生物信息学与医疗诊断系统、版权保护、密码系统及其应用、数据挖掘、数据保密、隐蔽通信信道检测、数字签名、电子商务安全、身份识别、图像与信号处理、智能信息检索、模式识别、网络应用信息、数据与系统集成等。

会议联系人: 蹇柯, 联系电话: 020 - 31687290, 传真: 020 - 39322319, E-mail: cis2006 @gdut. edu. cn, 通讯地址: 广东工业大学应用数学学院, 邮政编码: 510006。恭请全国各位人工智能研究领域广大科技工作者尽快登录网站 <http://cis2006.gdut.edu.cn> 查阅征文通知并积极投稿。