

储备池计算概述

彭 宇¹, 王建民^{1,2}, 彭喜元¹

(1. 哈尔滨工业大学自动化测试与控制研究所, 黑龙江哈尔滨 150080;

2. 哈尔滨理工大学电子科学与技术系, 黑龙江哈尔滨 150001)

摘 要: 针对传统递归神经网络存在训练困难的问题, 一种新的递归神经网络的训练方法——储备池计算被提出, 这种方法的核心思想是只训练网络部分连接权, 其余连接权一经产生就不再改变, 网络的训练一般只需要通过求解线性回归问题. 广义地说, 储备池可以作为一种时序相关的核函数使用, 从而完全拓展了其应用领域, 使之不再仅仅是递归神经网络训练算法的一种改进. 本文在介绍储备池计算基本数学模型的基础上, 从储备池计算研究的热点问题——储备池适应性问题的角度, 全面地分析了目前储备池计算的研究现状、热点及应用等方面的问题.

关键词: 机器学习; 递归神经网络; 储备池计算; 回声状态网络

中图分类号: TP183 **文献标识码:** A **文章编号:** 0372-2112 (2011) 10-2387-10

Survey on Reservoir Computing

PENG Yu¹, WANG Jian-min^{1,2}, PENG Xi-yuan¹

(1. Automatic Test and Control Institute, Harbin Institute of Technology, Harbin, Heilongjiang 150080, China;

2. Department of Electronics Science & Technology, Harbin University of Science and Technology, Harbin, Heilongjiang 150001, China)

Abstract: A novel training method for recurrent neural networks, which is called reservoir computing, was proposed with the purpose of dealing with difficulties in the training of the traditional recurrent neural networks. The main idea of the reservoir computing is training only parts of the connection weights of the networks, and generating the rest parts randomly. The connection weights generated randomly remain unchanged during the training process. Then training process of the network can be carried out by solving a linear regression problem. The reservoir can be considered as a temporal kernel function which extends the applications of the reservoir computing. In fact, the reservoir computing is not only a modification of the training algorithm to recurrent neural networks. In this paper, we firstly introduce the mathematical model of the reservoir computing and analyze the current related researches and applications in detail in the view of reservoir adaption which has attracted much interest of the researchers recently.

Key words: machine learning; recurrent neural network; reservoir computing; echo state networks

1 引言

神经网络因具有良好的非线性映射能力、自学习适应能力和并行信息处理能力在机器学习领域得到了广泛而深入的研究, 并取得大量成功的应用. 但是, 神经网络方法在具体应用过程中也存在一些局限性. 比如前向结构的神经网络一般不适合处理与时序相关的机器学习问题, 而在实际应用中出现的问题往往与时间相关, 比如预测、系统辨识、自适应滤波等等. 递归神经网络虽然可以用于解决时序相关问题, 但递归神经网络在实际应用中存在训练算法过于复杂、计算量大、收敛速度慢以及网络结构难以确定等问题. 另外, 还存在记忆渐消 (Fading Memory) 问题, 随时间步骤的加长, 误差梯度可

能消失或者产生畸变, 所以递归神经网络一般只适合处理短时时序问题. 这些问题都严重阻碍了递归神经网络在实际问题中的应用.

为了减少训练过程的计算负担以及克服记忆渐消等问题, Jaeger 于 2001 年提出回声状态网络 (Echo State Networks, ESNs)^[1], Maass 于 2002 年提出流体状态机 (Liquid State Machines, LSMs)^[2]. 这两种方法虽然提出的角度不同, 但其本质都可以认为是对传统的递归神经网络训练算法的改进. D Verstraeten 等在文献[3]中以实验的方式证明了 ESNs 和 LSMs 在本质上是一致的, 并将其统一命名为“储备池计算” (Reservoir Computing).

ESNs 通过随机地布置大规模稀疏连接的模拟神经元构成随机网络结构, 这个用于处理时序输入信号的随

机的稀疏连接的大规模递归网络,被称为“储备池”(Reservoirs),其结构如图1所示.神经元(储备池内部单元)输出 $x(n)$ 的线性组合形成系统的输出信号 $y(n)$. 储备池中神经元之间的连接权 W 、以及输入信号对于储备池中神经元的连接权 W^{in} 全部随机产生,而且产生后即保持不变,不需要训练.需要训练的连接权只有储备池到系统输出的连接权 W^{out} ,训练过程一般只需要求解一个线性回归问题.与传统的递归神经网络相比,ESNs 最大的优势是简化了网络的训练过程,解决了传统递归神经网络结构难以确定、训练算法过于复杂的问题,同时也克服了递归网络存在的记忆渐消问题(ESNs 的训练方法与传统的递归神经网络有本质不同).




图1 回声状态网络的网络结构

流体状态机(Liquid State Machines, LSMs)由 Wolfgang Maass 首先提出^[2]. LSMs 提出的动机是解决时序信号的实时计算问题,应用的目标是神经微电路(Neural Micro-circuit)领域.虽然 LSMs 和 ESNs 应用的领域以及提出的动机都有所不同,但是二者却具有相同的解决问题的思想,即使用大规模随机稀疏网络(储备池)作为信息处理媒介,网络的训练过程只对部分神经元连接权进行,而其他连接权随机产生,并在网络训练过程中保持不变.这种思想在 Steil 关于传统递归神经网络的经典训练算法(Atiya-Parlos)的研究中也得到了验证:递归神经网络输出连接权改变迅速,而内部连接权则只以高度耦合的方式缓慢改变.也就是说,如果递归神经网络内部连接权选择合适,在对网络进行训练时可以忽略内部连接权的改变.除了以上提到的 ESNs 和 LSMs 两种主要的方法,随着研究的深入,研究人员将另外两种不同的方法也划归为储备池计算的研究范畴^[5], Backpropagation—Decorrelation 方法^[6]、时序递归神经网络(Temporal Recurrent Neural Network)^[7].

从解决问题的思想角度考虑,储备池计算与以支持向量机为代表的核方法是相一致的^[8],其最基本的思想都是将输入从低维空间映射到高维空间.在高维空间,利用处理线性问题的方法和理论去处理问题.二者

的区别在于,储备池计算中,从低维输入空间到高维状态空间的映射是通过储备池完成的,状态空间的完备性、以及基向量的丰富程度通过稀疏连接矩阵以及神经元的不同形式体现.核方法中,从低维输入空间到高维特征空间的映射通过核函数隐式地完成,核函数的性质决定了映射的性质,从而最终决定系统的性能.二者的另外一个区别是储备池计算适合处理时序相关的动态系统建模问题,而核方法一般适合处理静态函数逼近问题^[9].原因在于核方法本质上是前馈结构,不存在反馈连接.

由于具有上述优点,储备池计算方法一经提出,就在不同的领域取得了广泛的应用,比如时间序列预测^[10~17]、模式分类^[18~21]、语音识别^[22]、事件检测^[23]、机器臂控制^[24]、图像处理^[25]、飞行器控制^[26]等等.

综上所述,储备池计算方法在工程应用中有现实的需求,同时在理论上 also 具有重要意义.因此,一经提出就到了学术界和工程应用领域研究人员的广泛关注,并正在逐渐成为机器学习领域的一个研究热点.研究人员从不同的角度,对储备池计算的基本理论、算法以及应用展开了全面的研究.其中,关于如何克服储备池产生时存在的随机性,产生一个与具体问题相关的最优的储备池,即储备池的适应性问题,是储备池研究的根本性问题,存在着巨大的挑战^[8].鉴于此,本文从储备池计算中储备池适应性问题,对储备池计算的基本原理、研究的热点以及应用等问题进行阐述,尝试对储备池计算方法给出一个全面的分析.

储备池计算方法中最具代表性的就是回声状态网络和流体状态机,其中结构最为简单,最具代表性,同时也是最基本的方法当属回声状态网络,因此本文后续对储备池计算方法的介绍以 ESNs 方法为代表展开.

2 回声状态网络的数学模型

本节介绍储备池计算的基本数学模型、储备池的产生方法、训练算法以及关于储备池计算的一些基本理论结果.对数学模型的介绍以经典*的 ESNs 模型为代表,区别于其他的 ESNs 的推广和改进模型.

2.1 经典 ESNs 的数学模型

本小节进一步分析 ESNs 的结构以及数学模型.考虑如图1所示^[28]的 ESNs 的网络结构.假设系统具有 M 个输入单元, N 个内部处理单元(Processing Elements, PEs),即 N 个内部神经元,同时具有 L 个输出单元.时刻 n 输入单元、内部状态以及输出单元的取值分别为:

* 这里指的是 Jaeger 在文献[1]中提出的方法.

$$\mathbf{u}(n) = [u_1(n), u_2(n), \dots, u_M(n)]^T,$$

$$\mathbf{x}(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T,$$

$$\mathbf{y}(n) = [y_1(n), y_2(n), \dots, y_L(n)]^T.$$

从结构上讲, ESNs 是一种特殊类型的递归神经网络, 其基本思想是使用大规模随机连接的递归网络, 取代经典神经网络中的中间层, 从而简化网络的训练过程. 回声状态网络的状态方程和输出方程^[28]可以由式(1)给出:

$$\begin{cases} x(t+1) = f(\mathbf{W}x(t) + \mathbf{W}^{in}u(t) + \mathbf{W}^{back}y(t)) \\ \hat{y}(t+1) = f_{out}(\mathbf{W}^{out}[x(t+1), u(t+1), y(t)] + \mathbf{W}^{out}_{bias}) \end{cases} \quad (1)$$

其中 \mathbf{W} , \mathbf{W}^{in} , \mathbf{W}^{back} 分别表示状态变量、输入和输出对状态变量的连接权矩阵; \mathbf{W}^{out} 表示储备池、输入和输出对于输出的连接权矩阵, \mathbf{W}^{out}_{bias} 表示输出的偏置项或者可以代表噪声. $f = [f_1, f_2, \dots, f_N]$ 表示内部神经元激活函数, 通常情况下, $f_i (i = 1, 2, \dots, N)$ 取做双曲正切函数. $f_{out} = [f^1_{out}, f^2_{out}, \dots, f^L_{out}]$ 表示输出函数, 一般情况下, 输出层是线性的, 即 $f^i_{out} (i = 1, 2, \dots, L)$ 取恒等函数. 在以上的各种连接权矩阵中, 连接到储备池的连接权矩阵 \mathbf{W}^{in} , \mathbf{W} , \mathbf{W}^{back} 随机产生, 一经产生就固定不变. 而连接到输出的各连接权矩阵 \mathbf{W}^{out} 需要根据系统的输入、输出数据训练得到, 因为状态变量与输出之间是线性关系, 所以通常这些连接权只需通过求解线性回归问题得到.

2.2 回声状态网络的训练

回声状态网络的训练过程就是根据给定的训练样本 $(\mathbf{u}(n), \mathbf{y}(n), n = 1, 2, \dots, M)$, 确定系统中的输出连接权矩阵 \mathbf{W}^{out} 的过程. 为了简单起见, 这里假定 $\mathbf{W}^{back} = 0$, 同时输入到输出连接权也假定为 0, 样本数据 $(\mathbf{u}(n), \mathbf{y}(n), n = 1, 2, \dots, M)$ 有时也被称为教师数据. 回声状态网络的训练过程可以分为两个阶段: 采样 (Sampling) 阶段和权值计算 (Weight Computation) 阶段^[19].

2.2.1 采样

采样阶段首先任意选定网络的初始状态, 但是通常情况下选取网络的初始状态为 0, 即 $x(0) = 0$. 训练样本 $(\mathbf{u}(n), n = 1, 2, \dots, M)$ 经过输入连接权 \mathbf{W}^{in} , 样本数据 $y(n)$ 经过反馈连接权 \mathbf{W}^{back} 分别被加到储备池, 按照系统(1), 依次完成系统状态的计算和相应输出 $\hat{y}(n)$ 的计算与收集. 注意每一时刻系统状态 $\mathbf{x}(n)$ 的计算, 都需要将样本数据 $\mathbf{y}(n)$ 写入到输出单元. 为了计算输出连接权矩阵, 需要从某一时刻开始收集 (采样) 内部状态变量. 这里假定从 m 时刻开始收集系统状态, 并以向量 $(x_1(i), x_2(i), \dots, x_N(i)) (i = m, m+1, \dots, M)$ 为行构成矩阵 $\mathbf{B} (M-m+1, N)$, 同时相应的样本数据 $\mathbf{y}(n)$

也被收集, 并构成一个列向量 $\mathbf{T} (M-m+1, 1)$. 这里需要说明的是:

(1) 如果系统包含有输入到输出、输出到输出的连接权, 那么在收集系统的状态矩阵 \mathbf{B} 时, 还需要收集相应的输入和输出部分;

(2) 为了消除任意初始状态对系统动态特性的影响, 总是从某一时刻后才开始收集系统的状态. 从该时刻开始, 可以认为系统反映的是输入、输出样本数据之间的映射关系.

2.2.2 权值计算

为了实现权值的计算, 需要根据在采样阶段收集到系统状态矩阵和样本数据, 计算输出连接权 \mathbf{W}^{out} . 因为状态变量 $\mathbf{x}(n)$ 和系统输出 $\hat{y}(n)$ 之间是线性关系, 而需要实现的目标是利用网络实际输出 $\hat{y}(n)$ 逼近期望输出 $\mathbf{y}(n)$, 即

$$\mathbf{y}(n) \approx \hat{\mathbf{y}}(n) = \sum_{i=1}^L w_i^{out} x_i(n)$$

也就是希望计算权值 w_i^{out} (w_i^{out} 为矩阵 \mathbf{W}^{out} 的元素), 满足系统的均方误差最小, 即需要求解如下的优化问题:

$$\min_{w_i^{out}} \frac{1}{M-m+1} \sum_{n=m}^M \left(d(n) - \sum_{i=1}^L w_i^{out} x_i(n) \right)^2 \quad (2)$$

从数学的观点看, 这是一个线性回归问题, 问题可以归结为求矩阵 \mathbf{B} 的逆矩阵问题, 实际应用中矩阵 \mathbf{B} 可能是病态的, 在计算上该问题可以进一步处理为矩阵 \mathbf{B} 的伪逆问题, 即

$$(\mathbf{W}^{out})^T = \mathbf{B}^{-1} \mathbf{T}$$

至此, ESNs 网络训练已经完成.

以上介绍的训练算法是基本的离线训练算法, 或者叫做批量算法, 一般情况下, 由于矩阵 \mathbf{B} 可能是奇异的, 矩阵 \mathbf{B} 的逆矩阵计算可以采用伪逆 (Pseudoinverse) 算法或者正则化技术 (Regularization Techniques), 其中比较常用的是岭回归 (ridge regression) 算法^[12]. 为了解决实时性要求较高的在线 (Online) 问题, 文献[31]提出了基于递归最小二乘算法的在线训练算法; 为了利用支持向量机的优点, 文献[10]提出将使用 ϵ -不敏感损失函数取代均方误差最小损失函数, 从而得到了一个比式(2)更为广泛的优化问题, 进而提出了无核支持向量机的概念.

2.2.3 稳定性: 回声状态属性

以上介绍了回声状态网络一般结构和训练算法, 使我们对 ESNs 有了初步认识. 下面从理论层面对回声状态网络做深入介绍.

理解 ESNs 训练过程的关键是理解“回声状态” (echo state) 的概念. 所谓回声状态是网络具备的一种性

质,由于回声状态网络由输入连接权矩阵 \mathbf{W}^{in} 、内部连接权矩阵 \mathbf{W} 和反馈连接权矩阵 \mathbf{W}^{back} 描述,因此网络应该具备的一种性质,在数学上可以理解为以上几个矩阵所应该具备的某种性质.需要注意的是“回声状态”除了与网络本身有关外,与训练样本的性质也有关系,也就是说,同样的网络对某些训练样本可能具有回声状态属性,但对于另外的样本可能就不具备回声状态属性.因此,在“回声状态”严格的数学定义中,要求训练样本输入向量和输出向量都属于某一个紧集.以下给出回声状态的定义^[1].

定义 1 未训练网络具有连接权矩阵 \mathbf{W}^{in} , \mathbf{W} , \mathbf{W}^{back} , 网络的输入样本数据 $\mathbf{u}(n)$ 和输出样本数据 $\mathbf{y}(n)$ 分别来自紧集 U 和 D , 称网络 $(\mathbf{W}^{in}, \mathbf{W}, \mathbf{W}^{back})$ 关于紧集 U 和 D 具备回声状态属性,如果对于每一个左边输入/输出序列:

$$(\mathbf{u}(n), \mathbf{y}(n), n = \cdots, -2, -1, 0)$$

和所有的状态序列 $\mathbf{x}(n)$, $\mathbf{x}'(n)$ 满足: 如果:

$$\mathbf{x}(n+1) = f(\mathbf{W}\mathbf{x}(n) + \mathbf{W}^{in}\mathbf{u}(n) + \mathbf{W}^{back}\mathbf{y}(n))$$

$$\mathbf{x}'(n+1) = f(\mathbf{W}\mathbf{x}'(n) + \mathbf{W}^{in}\mathbf{u}(n) + \mathbf{W}^{back}\mathbf{y}(n))$$

则 $\mathbf{x}(n) = \mathbf{x}'(n)$, 对于所有的 $n \leq 0$ 成立.

通过以上定义,可以发现“回声状态”属性的含义: 如果网络已经运行足够长时间,网络的当前状态只由网络的输入和输出决定.

回声状态属性与权重矩阵 \mathbf{W} 的数学性质紧密相关,但到目前为止对于给定的网络 $(\mathbf{W}^{in}, \mathbf{W}, \mathbf{W}^{back})$ 还不能给出确定该网络是否具有回声状态属性的充要条件.

只有网络具有回声状态属性时,对网络的训练才是有意义的,因此网络的训练算法应该保证网络具有回声状态属性;经典的储备池产生方法^[1],通过对随机产生的内部连接权矩阵进行整体的“尺度 (scaling)”运算保证储备池的回声状态属性,即保证网络的稳定性.实际应用中保证 ESNs 稳定的最基本方法是保证内部连接权矩阵的谱半径小于 1,具体实现方法参见文献 [1, 30];在实际 ESNs 实现过程中回声状态属性容易得到保证,从而确保 ESNs 网络具有局部渐进稳定的特性.但是,从另一方面看,这在一定程度上又限制了 ESNs 网络设计的灵活性,而且不能对网络的设计提供实质性的帮助.也就是说,该条件过于宽泛,实际应用中能够满足该条件的 ESNs 网络未必最优,甚至未必能够满足网络的实际需求.文献 [30] 在状态回声属性的基础上,提出了一个更为严格的网络稳定性条件,这种条件可以保证网络全局渐进稳定.在某些情况下,虽然储备池不满足全局稳定性条件,但 ESNs 网络也可以很好地工作^[31],函数逼近仿真实验表明,ESNs 可以工作在“暂时稳定”状态^[31].

3 储备池适应性问题

虽然储备池计算引起了研究人员的广泛关注,研究人员从不同角度对其开展研究,而且在很多领域都取得了成功的应用,但是必须承认,储备池计算的研究仍然处于起步阶段^[8],仍然有大量的理论和实际问题亟待解决.

目前,关于储备池计算的研究工作主要可以分为两类,一类是针对储备池计算方法本身的改进与扩展;另一类主要是储备池计算方法的应用.两类研究中都无法回避的核心问题是储备池的适应性问题.

“储备池”的性质对于系统最终的性能至关重要,也就是说储备池的产生方法对整个问题的解决起着决定性的作用.在经典储备池计算方法中,储备池随机产生,而且神经元一般选择为普通的模拟神经元 (Analog Neuron).这种储备池的产生方法从本质上讲是一种“问题”无关的方法.无论从理论上讲(“没有免费午餐”理论),还是从直觉上讲,如能够采用某种方法或者手段,使储备池的产生过程与具体问题相关,那么对储备池计算性能的提高将是革命性的.在目前的研究中,最优的储备池就是希望能够产生一个与具体问题相关的储备池.为此,研究人员从不同的角度提出不同的思路.应该讲这其中的一些改进方法仅仅是对获得最佳的储备池做出的一种尝试.目前开展的研究工作包括,尝试不同类型的神经元、储备池的网络拓扑结构修正以及储备池的参数优化等.本节将针对以上三个方面展开具体分析.储备池计算的应用分析将在第 4 节进行.

3.1 神经元类型

前面已经提到,一般 ESNs 网络采用的是普通模拟神经元,而 LSMs 中采用的神经元则是 Spiking 神经元.经典神经网络研究已经表明,神经元类型对于网络的性能起到关键作用.因此,不断有研究去探讨储备池中采用的神经元类型与具体问题的关系,比如神经元类型与网络记忆能力^[32]、逼近能力^[2, 17, 33~35]的关系等等.

目前文献报道已经有许多不同类型的神经元被应用到储备池计算方法中,包括 Spiking 神经元^[2, 36], 阈值逻辑神经元^[37], S 型模拟神经元^[1, 10, 13, 16], 线性神经元^[32, 38], leaky integrator 神经元^[17], Stochastic Bitstream Neurons^[39], 小波神经元^[33] 和滤波器神经元^[34, 35] 等.在典型的 ESNs 中,一般采用普通的模拟神经元类型,比如双曲正切函数 \tanh .而在 LSMs 中一般采用 Spiking 神经元.但是在具体实际问题中采用哪种类型的神经元更好,目前还没有定论.文献 [32] 提出具有线性神经元^{*} 的 ESNs 网络具有最好的记忆能力但是在其他很

* 记忆能力的度量方法可以参见文献 [32].

多方面这种网络并不是最优的,比如逼近能力等.文献[3]通过数值仿真实验证明对于某些任务具有 Spiking 神经元的网络要比具有普通的模拟神经元的网络更有优势,比如其逼近能力,以及计算的一致性等等.

由 Leaky Integrator 神经元构成的 ESNs 是由普通模拟神经元所构造网络的一种推广^[17],而由普通模拟神经元构成的 ESNs 只是其在某种参数取值下的特例,因此只要参数选取合适,理论上讲,具有 Leaky Integrator 神经元的储备池网络一定比普通 ESNs 具有更好的性能.

前面提到的神经元一般需要计算输入信号的加权和,然后经过一个非线性函数映射为输出.这种类型的神经元采用硬件实现的效率是非常低的,因为需要执行大量的乘法运算.文献[39]采用一种叫做 Stochastic Bitstream 的神经元,这种神经元之间采用随机位流进行通信,而不需要进行定点数的计算,这大大简化了储备池计算的硬件实现.该文采用这种类型的神经元并在 FPGA 芯片上实现了一个储备池系统.

为了提高储备池神经元的激活程度,文献[33]提出采用小波神经元和普通模拟神经元构成混合结构的储备池构建储备池计算系统.此外,为了学习输入信号中的不同时间尺度动态特性,文献[34,35]提出采用滤波器神经元构造储备池计算系统,所谓滤波器神经元其实就是在普通模拟神经元基础上首先加入积分环节,再加入一个无限冲击响应滤波器,以提高系统处理不同时间尺度动态特性的能力.

这里需要指出的是,前面提到这些关于神经元类型与网络性能之间的关系,都是从实验的角度提出.目前在这方面从理论角度开展的探讨还比较少,这也从另一个角度说明了储备池计算研究领域仍然存在大量理论问题需要解决.

3.2 网络的拓扑结构

储备池适应性研究的第二个重要方面就是对储备池网络拓扑结构的改进.目前已经有许多尝试,采用新的网络拓扑结构取代目前随机稀疏的网络结构.这其中有些方法是对目前的 ESNs 网络结构的完全颠覆^[40],当然也存在一些研究是针对 ESNs 拓扑结构的修改^[38,40~49],以适应不同的应用目标.

文献[40]采用著名的小世界网络、无尺度网络拓扑结构构建储备池计算系统,以均方误差以及状态矩阵特征值的 spread 为衡量目标,以仿真实验比较了不同网络拓扑结构和经典 ESNs 网络储备池的优劣.实验采用的数据集是合成的 NARMA(Nonlinear Autoregressive Moving Average)时间序列和 Mackey-Glass 混沌时间序列.文献最后给出的结论是这两种拓扑结构与随机产生的网络拓扑结构相比,并无明显优势.但是,这并不意味着

该工作方向存在问题.因为文献[43]只是针对具体数据和具体衡量目标展开,应该说该方向还有大量工作可以深入,比如可以从理论层面探讨采用其它形式网络拓扑结构构建储备池的可行性以及应用等问题,类似采用复杂网络思想构造储备池的工作还包括文献[41,42,47~49].

文献[38]提出一种简单的前向结构 ESNs,仿真实验表明,如果前向结构 ESNs 提供的存储窗口对于其解决的问题来说足够的话,那么前向结构的 ESNs 依然可以取得理想的结果.文献[43]研究了一种退化形式的 ESNs 网络的短时记忆能力,该网络具有线性神经元,对角化的内部链接区矩阵,以及统一的输入矩阵.

除了上述 3 种典型的拓扑结构设计思路外,为了解决不同性质的问题,还有不同结构的 ESNs 网络被提出.比如为了解决多尺度动态系统的建模问题,文献[42]受大脑皮层生长发育过程启发,提出一种类皮层网络的复杂回声状态网络的构建方法.

3.3 储备池的优化

经典 ESNs 方法中储备池是随机产生的,随机产生的储备池是通用的,与具体问题无关,也就是说,对于每一个具体问题,其储备池的产生方式相同.根据机器学习领域的“没有免费午餐”原理,最优的储备池应该是与具体问题相关的,应该是由具体问题决定的.针对储备池对具体问题的适应性问题,研究者提出了许多与储备池参数优化相关的方法,利用训练的样本数据,获得一个与具体问题相关的最优的储备池.

3.3.1 基于 GA 等传统方法的优化

Kazuo Ishii 等首次在文献[50]中提出采用进化算法对储备池的某些参数进行优化进而找到最优的储备池.文献[51]提出的寻优参数包括:储备池规模 N_x ,内部连接权矩阵的谱半径 $\rho(\mathbf{W})$,以及内部连接权矩阵的稀疏度三个参数.针对文献[51]中的水下机器人运动建模问题,给出的最优储备池包含神经元数目为 5 个.由于包含较少的神经元,使优化过程中的计算量不至于过大,所以使得针对其他参数的寻优过程可以继续运行.文献[54]提出另外一种基于进化算法的优化储备池的方法.该方法首先将内部连接权矩阵分解为两个矩阵的乘积,并只针对其中的一个稀疏矩阵进行搜索,从而大大降低了运算量.

尽管采用进化计算等优化算法进行储备池参数的优化是一种最为直观的方法,并在某些情况下取得了一定效果,但遗传算法本身的搜索盲目性导致计算量过大,以及容易陷入局部最优的问题还是限制了其在储备池参数优化上的应用.另外,其计算量过大的问题与储备池计算的简化计算过程的思想也是背道而驰的.

3.3.2 基于随机梯度下降法的储备池参数优化

Herbert 在文献[17]中,通过引入 Leaky Integrator 神经元,对经典的 ESNs 网络做出了一定的推广,给出一个比经典 ESNs 更为一般的形式:

$$\mathbf{x}(n+1) = (1 - \alpha \Delta t) \mathbf{x}(n) + \Delta t f(\mathbf{W}^{\text{in}} \mathbf{u}(n+1) + \mathbf{W} \mathbf{x}(n))$$

同时也引入了两个全局参数 Δt 和 α ,其中 Δt 是离散化时间间隔与系统时间常数的比值, α 叫做 decay rate^[55].进而建立了针对全局参数 Δt 和 α 的随机梯度下降优化算法.针对变化较慢的并且含有噪声的标准数据集(日文原音数据集)进行时间序列分类问题试验证明了该方法的有效性(分类的错误率为 0)^[17].

3.3.3 Intrinsic Plasticity 方法

最近,受到绝大多数生物神经元都具有各种塑性(plasticity)的启发,一类通过优化塑性参数(Plasticity Parameters)从而达到提高储备池适应性的方法得到了广泛研究^[9,36,51~54].

文献[9,51,52]提出的思想方法是一致的,首先需要在普通的神经元中引入 IP(Intrinsic Plasticity)参数,然后对 IP 参数进行优化,优化的目标是储备池中神经元的输出符合最大熵分布,从而实现捕捉和携带最多的输入信息的目的.不同的是文献[51]针对的是 Fermi 型神经元,优化的目标是使神经元输出服从指数分布,建立了针对 IP 参数的随机梯度下降优化方法.文献[9]与文献[52]的思想一致,只是文献[9]针对双曲正切激活函数 \tanh ,使神经元输出服从高斯分布,同样建立梯度下降优化方法.同时还对神经元输出的有界性对于高斯分布和最大熵分布的差别进行了讨论.

针对标准数据集,分别考察网络的记忆能力、非线性逼近能力,证明了 IP 优化方法较经典 ESNs 都有不同程度的提高^[9].语音识别数值仿真实验从另一个角度显示出该方法的优越性^[9].但同时该方法也存在一些问题,如该方法只针对高斯分布和指数分布,而对实际中出现更多的稀疏分布却无能为力.另外,该方法只能针对引入的 IP 参数进行优化,而对储备池其他参数没能提出相应的随机梯度下降算法.这也为研究人员提出了进一步的研究方向.

4 应用方法研究

作为经典神经网络训练算法的改进,储备池计算除了在其经典的应用领域时间序列预测问题得到应用外,还推广到了时间序列分类、维数约简、动态系统尺度发现、飞行器控制、自适应滤波、图像边缘检测等应用领域中.

文献[13]针对混沌时间序列预测问题,采用经典的 ESNs 方法,在对 Mackey-Glass 标准数据集的预测上,其准确程度较以前其他方法提高了 2400 倍.类似地,将

ESNs 应用于时间序列预测的文献还有文献[1,10~15]等.

文献[26]针对具有外部干扰力矩和模型不确定性的多体航天器快速跟踪控制问题,基于逆系统方法和回声状态网络,设计鲁棒控制器.采用“meta-learning”策略离线训练 ESN 网络,并用遗传算法优化其主要参数,解决了动态递归神经网络训练困难以及网络参数不易确定的问题.其他类似利用储备池计算解决的控制问题还有机器臂控制^[24].

文献[43]讨论了回声状态网络的短时记忆能力问题,并利用网络的短时记忆能力解决动态模式识别问题.类似还有文献[32].文献[44]针对网络输入一般具有多尺度特性,提出层次化的回声状态网络,用于解决动态系统中多时间尺度问题.文献[25]将经典的回声状态网络方法用于图像边缘检测,取得了良好的效果,其利用 ESNs 的目的主要是克服传统递归神经网络隐层结构难以确定的问题.

储备池计算方法的软件实现也有多种形式.其中比较著名的是比利时根特大学储备池计算实验室的开源 Matlab 工具箱^[61],该工具箱包括储备池计算方法的基本实现,支持数据集的设定、储备池拓扑结构的设置、实验参数的交叉验证功能;支持的神经元类型包括模拟神经元(线性、双曲正切)和 Spiking 神经元.另外,Jaeger 也实现了基本 ESNs 功能,并提供开源的 Matlab 工具箱^[62].其他采用 C++ 实现的软件工具可以参考文献[63].

目前,关于储备池计算方法的硬件实现也已经出现.文献[64]针对语音信号识别中计算量较大,对计算速度要求较高的特点,提出一种流体状态机硬件实现方法.与传统的 Spiking 递归神经网络硬件实现方式相比,这种 LSMs 的实现方式结构更为紧凑,采用串行方式,而且计算字宽是可调的.其设计实现在满足语音识别实时计算要求的同时,可以节省更多的硬件资源.但是,采用经典模拟神经元构造实现储备池网络,每个神经元的输出都需要计算其输入信号的一个加权和,从而引进了大量的加法和乘法计算,这在硬件实现上是不利的.文献[39]针对该问题,提出了基于随机位流神经元(Stochastic Bitstream Neurons)构造储备池系统,从而大大简化了储备池计算的硬件实现过程.

上述的应用研究仅仅是储备池计算方法应用的一部分,凭借其良好的网络记忆能力和逼近能力以及训练方法简单等特点,储备池计算方法正在不断地被应用到不同的技术研究领域.可以断定传统的神经网络的应用领域都将会成为储备池计算方法潜在的拓展空间.

5 结论和展望

储备池计算方法一经提出就在许多领域得到广泛应用,并取得了巨大成功.但随之发展也不断面临着新的研究挑战.

储备池计算方法是作为 RNNs 改进算法而被引入的,但是实际上目前关于储备池计算的概念已经远远超出其当初被提出时的想法,几乎在所有与时序相关的机器学习领域都得到了应用,且应用领域不断扩大.理论层面上,关于储备池计算的稳定性、网络拓扑结构的改进、算法改进的研究也赋予了储备池计算方更广泛的含义,比如储备池可以被理解为广义的时序相关的核函数,用来处理将系统输入映射到高维空间问题.但与此同时,目前关于储备池适应性问题的研究也处于一个瓶颈,需要有新的理论和方法的支撑.

储备池计算方法的研究应该说还是一个比较新的研究领域,虽然取得了一定的成果,但在理论层面上,对网络稳定性和储备池适应性问题还需进一步研究,在应用方法研究方面也需要进一步拓展,因此还是存在很多需要解决的问题:

(1)储备池适应性问题.该问题同经典递归网络结构确定问题类似.储备池计算采用随机的方式产生储备池,在一定程度上解决了网络结构问题,但是如何根据具体问题确定储备池的一系列的参数,仍然是不可回避的问题.

(2)网络的稳定性分析、网络逼近能力的理论研究还需要进一步开展.从理论层面上讲,Jaeger 给出了 ESNs 稳定的一般充分性条件,但该条件还是显得比较宽泛,对网络设计的实际意义并不大.后续网络稳定性分析理论和方法研究中,应该尝试给出对网络设计更具指导意义的稳定性条件.

(3)储备池理论的发展和创新.储备池产生方法还需要有进一步突破,因为储备池产生问题,与传统神经网络的网络结构确定问题很相似,如果不能很好从根本上进行解决,将会严重限制储备池计算方法的实际应用.因此,需要一套完整的、甚至全新的储备池产生方法,这样的方法可以完全对立于现有的储备池产生方法.比如引入小世界网络和无尺度网络方法,对储备池网络拓扑结构进行修改.虽然目前还没有取得实质性的进展,但确实是一种有益的尝试.

(4)硬件实现方法研究.随着储备池计算应用领域变得越来越复杂,以及应用的实时性要求不断提高,储备池计算方法的硬件实现也会受到越来越多地关注.从硬件实现的角度看,需要能够产生一种具有固定拓扑结构的回声状态网络(区别于随机网络),如文献[8].这也从另一个角度重新强调了关于采用不同的优

化算法对储备池参数进行优化,提高储备池性能方法的重要性.即需要首先产生固定的拓扑结构,然后再采用优化算法进行参数优化.优点是既能保证网络结构固定,方便硬件实现,同时又能保证网络的性能.

在开展上述理论方法研究的同时,应更加积极地探索储备池计算的应用方法研究,为其理论提升提供充分的实践基础.从储备池计算方法应用的趋势看,储备池计算方法应用领域正在被不断地拓展.随着对储备池计算方法认识的不断深入,储备池方法的应用领域势必会继续被拓展.

参考文献

- [1] Herbert Jaeger. The "Echo State" Approach to Analyzing and Training Recurrent Neural Network[R]. Bremen: GMD Report 148, GMD-German National Research Institute for Computer Science, 2001.
- [2] Wolfgang Maass, T Natschlager, M H. Real-time computing without stable states: A new framework for neural computation based on perturbations[J]. Neural Computation, 2002, 14(11): 2531 - 2560.
- [3] D Verstraeten, B Schrauwen, M D'Haene, D Stroobandt. An experimental unification of reservoir computing methods[J]. Neural Networks, 2007, 20(3): 391 - 403.
- [4] U D Schiller, J J Steil. Analyzing the weight dynamics of recurrent learning algorithm[J]. Neurocomputing, 2005, 63(1): 5 - 23.
- [5] Jaeger H. Reservoir Computing: Shaping Dynamics into Information [DB/OL] <http://reservoir-computing.org/>, 2009-03-03.
- [6] Jochen J Steil. Backpropagation-decorrelation: online recurrent learning with $O(N)$ complexity[A]. International Joint Conference on Neural Networks-IJCNN 2009[C]. Piscataway, NJ 08855-1331, 2004. 843 - 848.
- [7] Dominey P F. Complex sensory-motor sequence learning based on recurrent state representation and reinforcement learning[J]. Biological Cybernetics, 1995, 73(3): 265 - 274.
- [8] Mantas Lukosevicius, Herbert Jaeger. Reservoir computing approaches to recurrent neural network training[J]. Computer Science Review, 2009, 3(3): 127 - 149.
- [9] Benjamin Schrauwen, Marion Wardermann, David Verstraeten, Jochen J Steil. Improving reservoirs using intrinsic plasticity[J]. Neurocomputing, 2007, 71(7-9): 1159 - 1171.
- [10] Zhiwei Shi, Min Han. Support vector echo-state machine for chaotic time series prediction[J]. IEEE Transactions on Neural Networks, 2007, 18(2): 359 - 372.
- [11] 史志伟, 韩敏. ESN 岭回归学习算法及混沌时间序列预测[J]. 控制与决策, 2007, 22(3): 258 - 267.

Shi Zhi-wei, Han Min. Ridge regression learning in ESN for

- chaotic time series prediction[J]. Control and Decision, 2007, 22(3): 258 – 267. (in Chinese)
- [12] 韩敏, 王亚楠. 基于 Kalman 滤波的储备池多元时间序列在线预报器[J]. 自动化学报, 2010, 36(1): 169 – 173.
Han Min, Wang Ya-Nan. Multivariate time series online predictor with kalman filter trained reservoir[J]. Acta Automatica Sinica, 2010, 36(1): 169 – 173. (in Chinese)
- [13] Herbert Jaeger, Harald Haas. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless telecommunication[J]. Science, 2004, 304(5667): 78 – 80.
- [14] 彭宇, 王建民, 彭喜元. 基于回声状态网络的时间序列预测方法研究[J]. 电子学报, 2010, 38(2A): 148 – 154.
Peng Yu, Wang Jian-min, Peng Xi-yuan. Researches on time series prediction with echo state networks[J]. Acta Electronica Sinica, 2010, 38(2A): 148 – 154. (in Chinese)
- [15] Peng Yu, Wang Jian-min, Peng Xi-yuan. Traffic prediction with reservoir computing for mobile networks[A]. The 5th International Conference on Neural Computation, ICNC2009 [C]. Piscataway, NJ 08855-1331, 2009. 464 – 468.
- [16] Herbert Jaeger. Tutorial on Training Recurrent Neural Networks, Covering BPTT, RTRL, EKF, and the “Echo State Network” Approach [R]. Bremen: Technical Report GMD Report 159, German National Research Center for Information Technology, 2002.
- [17] Herbert Jaeger, Mantas Lukosevicius, Dan Popovici, Udo Siewert. Optimization and applications of echo state networks with leaky integrator neurons[J]. Neural Networks, 2007, 20(3): 335 – 352.
- [18] Embrechts M, Alexandre L, Linton J. Reservoir computing for static pattern recognition[A]. 17th European Symposium on Artificial Neural Network, ESANN 2009 [C]. Amsterdam, 1000 AE, Netherlands, 2009. 1. 245 – 250.
- [19] Alexandre L, Embrechts M, Linton J. Benchmarking reservoir computing on time independent classification tasks[A]. International Joint Conference on Neural Networks IJCNN 2009 [C]. Piscataway, NJ 08855-1331, 2009. 89 – 93.
- [20] M D Skowronski, J G Harris. Minimum mean squared error time series classification using echo state network prediction model[A]. IEEE International Symposium on Circuits and System [C]. Piscataway, NJ 08855-1331, 2006. 3153 – 3156.
- [21] M D Skowronski, J G Harris. Automatic speech recognition using a predictive echo state network classifier[J]. Neural Networks, 2007, 20(3): 414 – 423.
- [22] D Verstraeten, B Schrauwen, D Stroobandt, J Van Campenhout. Isolated word recognition with the liquid state machine: A case study[J]. Information Process Letters, 2005, 95(6): 521 – 528.
- [23] DING Hai-yan, PEI Wenjiang, HE Zhen-ya. A multiple objective optimization based echo state network tree and application to intrusion detection[A]. IEEE International Workshop on VLSI Design & Video Technology [C]. Piscataway, NJ 08855-1331, 2005. 443 – 446.
- [24] P Joshi, W Maass. Movement generation and control with generic neural microcircuits[A]. Proceedings of BIO-AUDIT [C]. Springer, Berlin, 2004. 16 – 31.
- [25] 裴承丹. 回声状态网络及其在图像边缘检测中的应用[J]. 计算机工程与应用, 2008, 44(19): 172 – 174.
Pei Cheng-dan. Echo state networks and its applications on image edge detection[J]. Computer Engineering and Applications, 2008, 44(19): 172 – 174. (in Chinese)
- [26] 袁长清, 李俊峰, 邓志东, 宝音贺西. 基于 ESN 网络的航天器姿态跟踪鲁棒控制[J]. 清华大学学报(自然科学版), 2008, 48(8): 1362 – 1367.
Yuan Changqing, Li Junfeng, Deng Zhidong, Baoyin Hexi. ESN neural networks robust attribute tracking control for multi-body spacecraft[J]. Journal of Tsinghua University (Science and Technology), 2008, 48(8): 1362 – 1367. (in Chinese)
- [27] Mustafa C Ozturk, Dongming Xu, Jose C. Principe. analysis and design of echo state networks[J]. Neural Computation, 2007, 19: 111 – 138.
- [28] Benjamin Schrauwen, David Verstraeten, Jan Van Campenhout. An overview of reservoir computing: Theory, applications and implementations[A]. 15th European Symposium on Artificial Neural Networks, ESANN 2007 [C]. Amsterdam, 1000 AE, Netherlands, 2007. 471 – 482.
- [29] Herbert Jaeger. Adaptive nonlinear system identification with echo state network[A]. Advances in Neural Information Processing Systems (NIPS) [C]. MIT Press, 2003. 593 – 600.
- [30] Michael Buehner, Peter Young. A tighter bound for the echo state property[J]. IEEE Transactions on Neural Networks, 2006, 17(2): 820 – 824.
- [31] Mustafa C Ozturk, Jose C Principe. Computing with transiently stable states[A]. International Joint Conference on Neural Networks, IJCNN 2005 [C]. Piscataway, NJ 08855-1331, 2005. 3. 1467 – 1472.
- [32] Herbert Jaeger. Short Term Memory in Echo State Networks [R]. Bremen: Technical report, German National Research Center for Information Technology, 2001.
- [33] Se Wang, Xiao-jiao Yang, Cheng-Jian Wei. Harnessing nonlinearity by sigmoid-wavelet hybrid echo state networks[A]. The 6th World Congress on Intelligent Control and Automation, 2006, WCICA 2006 [C]. Piscataway, NJ 08855-1331, 2006. 1. 3041 – 3018.
- [34] Wyffels F, Schrauwen B, Verstraeten D, Stroobandt D. Band-pass reservoir computing[A]. International Joint Conference on Neural Networks, IJCNN 2008 [C]. Piscataway, NJ 08855-1331, 2008. 3204 – 3209.

- [35] Georg Holzmann, Helmut Hauser. Echo state networks with filter neurons and delay&sum readout[J]. *Neural Networks*, 2010, 23(2): 244 – 256.
- [36] Helene Paugam-Moisy, Regis Martinez, Samy Bengio. Delay learning and polychronization for reservoir computing[J]. *Neurocomputing*, 2008, 71(7-9): 1143 – 1158.
- [37] R Legenstein, W Maass. New Directions in Statistical Signal Processing: From Systems to Brain[A]. Chapter: What Makes a Dynamical System Computationally Powerful[M]. MIT Press, 2005.
- [38] Michal Cernansky, Matej Makula. Feed-forward echo state networks[A]. *International Joint Conference on Neural Networks, IJCNN 2005*[C]. Piscataway, NJ 08855-1331, 2005. 1479 – 1482.
- [39] David Verstraeten, Benjamin Schrauwen, Dirk Stroobandt. Reservoir computing with stochastic bitstream neurons[A]. *Proceedings of the 16th Annual ProRISC WorkShop*[C]. BMJ Publishing Group Ltd, 2005. 454 – 459.
- [40] Lukosevicius M, Jaeger H. Reservoir Computing Approaches to Recurrent Neural Network Training[DB/OL]. <http://www.eecs.jacobs-university.de/archive/bsc-2004/liebald.pdf>, 2004-05-10.
- [41] 宋青松, 冯祖仁, 李人厚. 用于混沌时间序列预测的多簇回响状态网络[J]. *物理学报*, 2009, 58(7): 5057 – 5064.
Song Qingsong, Feng Zuren, Li Ren-Hou. Multiple clusters echo state network for chaotic time series prediction[J]. *Acta Physica Sinica*, 2009, 58(7): 5057 – 5064. (in Chinese)
- [42] 宋青松, 冯祖仁. 构建复杂回响状态网络的新方法[J]. *西安交通大学学报*, 2009, 43(4): 1 – 4.
Song Qingsong, Feng Zuren. A new method to construct complex echo state networks[J]. *Journal of Xi'an Jiao Tong University*, 2009, 43(4): 1 – 4. (in Chinese)
- [43] Georg Fette, Julian Eggert. Short term memory and pattern matching with simple echo state networks[A]. *International Conferences on Artificial Neural Networks, ICANN 2005*[C]. Springer, Berlin, 2005. 13 – 18.
- [44] Herbert Jaeger. Discovering Multiscale Dynamical Features with Hierarchical Echo State Networks[R]. Bremen: Technical Report No. 9, Jacobs University Bremen, 2007.
- [45] Yanbo Xue, Le Yang, Simon Haykin. Decoupled state networks with lateral inhibition[J]. *Neural Networks*, 2007, 20(3): 365 – 376.
- [46] Mantas Lukosevicius. Echo State Networks with Trained Feedbacks[R]. Bremen: Technical Report No. 4, International University Bremen, 2007.
- [47] Qingsong Song, Zuren Feng. Effects of connectivity structure of complex echo state network on its prediction performance for nonlinear time series[J]. *Neurocomputing*, 2010, 73(10 – 12): 2177 – 2185.
- [48] Zhidong Deng, Yi Zhang. Complex systems modeling using scale-free highly-clustered echo state network[A]. *International Joint Conference on Neural Networks, IJCNN 2006*[C]. Piscataway, NJ 08855-1331, 2006. 3128 – 3135.
- [49] Zhidong Deng, Yi Zhang. Collective behavior of a small-world recurrent neural system with scale-free distribution[J]. *IEEE Transactions on Neural Networks*, 2007, 18(5): 1364 – 1475.
- [50] Kazuo Ishii, Tijn van der Zant, Vlatko Becanovic, Paul Ploger. Identification of motion with echo state network[A]. *OCEAN' S04 MTS/IEEE – TECHNO – OCEAN' 04*[C]. Piscataway, NJ 08855-1331, 2004. 3. 1205 – 1210.
- [51] Keith Bush, Batsukh Tsendjav. Improving the richness of echo state features using next ascent local search[A]. *Artificial Neural Networks in Engineering Conferences*[C]. ASME Press, 2005. 227 – 232.
- [52] J Triesch. A gradient rule for the plasticity of a neuron's intrinsic excitability[A]. *International Conference on Artificial Neural Networks (ICANN)*[C]. Springer, Berlin, 2005. 65 – 70.
- [53] Jochen J Steil. Online reservoir adaptation by intrinsic plasticity for backpropagation-decorrelation and echo state learning[J]. *Neural Networks*, 2007, 20(3): 353 – 364.
- [54] Joschka Boedecker, Oliver Obst, Norbert Michael Mayer, Minoru Asada. Studies on reservoir initialization and dynamics shaping in echo state networks[A]. *The 17th European Symposium on Artificial Neural Networks, ESANN 2009*[C]. Amsterdam, 1000 AE, Netherlands, 2009. 227 – 232.
- [55] Mantas Lukosevicius, Dan Popovici, Herbert Jaeger, Udo Siewert. Time Warping Invariant Echo State Networks[R]. Bremen: Technical Report No. 2, International University Bremen, 2006.
- [56] Jurgen Schmidhuber, Daan Wierstra, Matteo Gagliolo, Faustino J Gomez. Training recurrent networks by Evolino[J]. *Neural Computation*, 2007, 19(3): 757 – 779.
- [57] T Natschlager, N Bertschinger, R Legenstein. At the edge of chaos: Real-time computations and self-organized criticality in recurrent neural network[A]. *Advances in Neural Information Processing Systems (NIPS)*[C]. MIT Press, 2004. 145 – 152.
- [58] M Salmen, P G Ploger. Echo state networks used for motor control[A]. *Proceedings of the 2005 IEEE International Conference on Robotics and Automation*[C]. Piscataway, NJ 08855-1331, 2005. 1953 – 1958.
- [59] Francis wyffels, Benjamin Schrauwen. Design of a central pattern generator using reservoir computing for learning human motion[A]. *Symposium on Learning and Adaptive Behavior in Robotic Systems*[C]. Piscataway, NJ 08855-1331, 2009. 118 – 122.
- [60] Eric Aislan Antonelo, Benjamin Schrauwen. Unsupervised Learning in Reservoir Computing: Modeling Hippocampal

- Place Cells for Small Mobile Robots[A]. International Conference on Artificial Neural Networks (ICANN) [C]. Springer, Berlin, 2009. 747 – 756.
- [61] Machine Learning Group at Ghent University, Reservoir Computing Toolbox [DB/OL]. <http://snn.elis.ugent.be/node/59>, 2007-10-09.
- [62] Jaeger H. A Simple Toolbox of Echo State Networks[DB/OL]. http://www.faculty.jacobs-university.de/hjaeger/esn_research.html, 2007-06-10.
- [63] Georg Holzmann. Efficient C++ library for analog reservoir computing neural networks(Echo State Networks)[DB/OL]. <http://aureservoir.sourceforge.net/>, 2007-10-07.
- [64] Benjamin Schrauwen, Michel D'Haene, David Verstraeten, Jan Van Campenhout. Compact hardware liquid state machine on FPGA for real-time speech recognition[J]. Neural Networks, 2008, 21(2–3): 511 – 523.
- [65] H Jaeger. Reservoir riddles: Suggestions for echo state network research[A]. International Joint Conference on Neural Networks, IJCNN 2005 [C]. Piscataway, NJ 08855-1331, 2005. 1460 – 1462.
- [66] J Hertzberg, H Jaeger. Learning to ground fact symbols in behavior-based robots[A]. Proceedings of the 15th European Conference on Artificial Intelligence [C]. Amsterdam, 1000 AE, Netherlands, 2002. 708 – 712.
- [67] W Maass, T Natschlager, H Markram. A model for real-time computation in generic neural microcircuits[A]. Advances in Neural Information Processing Systems (NIPS) [C]. MIT Press, 2003. 15. 229 – 236.
- [68] Michal Cernansky. Novel recurrent connectionist approaches – echo state networks[J]. ICIC Express Letters, 2008, 2(3): 219 – 224.
- [69] Georg Holzmann. Reservoir computing: A powerful black-box framework for nonlinear audio processing[A]. Proceedings of the 12th International Conference on Digital Audio Effects [C]. Kluwer Academic Publishers, 2009. 1 – 8.
- [70] David Reid, Mark Barrett-Baxendale. Glial reservoir computing, second UKSIM european symposium on computer modeling and simulation[A]. Computer Modeling and Simulation, 2008, EMS '08 [C]. Piscataway, NJ 08855-1331, 2008. 81 – 86.

作者简介



彭宇男, 教授, 博士生导师, 1973年6月生于陕西西安, 哈尔滨工业大学自动化测试与控制研究所副所长, 主要研究方向为测试诊断技术、无线传感器网络技术和数据挖掘技术等。
E-mail: pengyu@hit.edu.cn



王建民男, 1976年生于吉林长春, 现为哈尔滨工业大学自动化测试与控制系博士研究生, 主要研究方向为时间序列分析、数据挖掘、故障诊断。
E-mail: wjmuzzy@126.com

(上接第 2352 页)

- [5] Q Yang, C Ling, X Chai, et al. Test-cost sensitive classification on data with missing values[J]. IEEE Transactions on Knowledge and Data Engineering, 2006, 18[5]: 626 – 638
- [6] P D Turney. Cost-sensitive classification: empirical evaluation of a hybrid genetic decision tree induction algorithm[J]. Journal of Artificial Intelligence Research, 1995, 2: 369 – 409
- [7] J V Davis, J Ha, C J Rossbach, et al. Cost-sensitive decision tree learning for forensic classification[A]. Proc of 17th European Conference on Machine Learning [A]. Berlin GERMANY, SEP 18 – 22, 2006: 622 – 629
- [8] X Liu. Cost-sensitive decision tree with missing values and multiple cost scales[A]. Proc of the first IITA International Joint Conference on Artificial Intelligence [C]. Hainan, CHINA, APR 25-MAY 26, 2009: 294 – 297
- [9] M Gong, L Jiao, H Du, et al. Multiobjective immune algorithm with nondominated neighbor-based selection. Evolutionary Computation[J]. 2008, 16[2]: 225 – 255
- [10] A Asuncion, D J Newman, UCI machine learning repository [http://www.ics.uci.edu/~mllearn/MLRepository.html]. Irvine, CA: University of California, School of Information and Computer Science, 2007.
- [11] R Quinlan. C4. 5: programs for machine learning. Morgan Kaufmann Publishers, 1992.
- [12] F Min, Q Liu. A hierarchical model for test-cost-sensitive decision systems[J]. Information Sciences, 2007, 179: 2442 – 2452.
- [13] D Kim. Structural risk minimization on decision trees using an evolutionary multiobjective optimization[A]. Proc of the 7th European Conference on Genetic Programming [C]. University Coimbra, Coimbra, PORTUGAL, APR 05 – 07, 2004. 338 – 348.