

基于相应簇回声状态网络静态分类方法

郭 嘉,雷 苗,彭喜元

(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)

摘 要: 借鉴模仿哺乳动物大脑皮层分簇结构的复杂网络拓扑结构,提出一种基于相应簇储备池回声状态网络的分类方法.将时间窗函数机制引入到回声状态网络储备池的构建中,利用具体问题中需分类数据的类别数量,生成具有对应分簇数目的储备池,以期提高分类精度.基于标准数据集和模拟电路故障诊断的实验验证结果表明,本文方法与标准回声状态网络等方法相比具有更高的分类精度.

关键词: 回声状态网络; 时间窗; 模拟电路故障诊断

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2011) 3A-014-05

Echo State Networks for Static Classification with Corresponding Clusters

GUO Jia, LEI Miao, PENG Xi-yuan

(Automatic Test and Control Institute, Harbin Institute of Technology, Harbin, Heilongjiang 150080, China)

Abstract: A classification method using echo state networks (ESNs) with corresponding clusters is proposed, which is inspired by complex network topologies imitating cortical networks of the mammalian brain. The time windows functions are adopted to construct multiple-cluster reservoir. The number of clusters corresponds with the number of classes in specific classification problems to improve the classification accuracy. Experimental results based on the standard datasets and analog circuit fault diagnosis show that the proposed method outperforms the original echo state networks.

Key words: echo state networks; time windows; analog circuit fault diagnosis

1 引言

回声状态网络(Echo State Networks, ESNs)是对传统递归神经网络训练算法的改进,由 H. Jaeger 于 2001 年提出^[1]. ESNs 的特点是采用由随机稀疏连接的神经元组成的储备池(Dynamical Reservoir, DR)作为隐层,用以对输入进行高维、非线性的表示,并且只需训练储备池至输出层的权值,使网络的训练过程得以简化,决了传统递归神经网络存在的训练算法复杂、网络结构难以确定等问题.借助于上述优势,ESNs 在时间序列预测^[2]、语音识别^[3]、异常检测^[4]等领域取得了良好的效果,有较好的应用价值.

回声状态网络一般用于解决时序相关问题,但也有学者提出面向静态模式分类的回声状态网络方法^[5],取得了较好的性能表现.然而,稀疏连接的回声状态网络储备池本身并不具有分簇结构,且其随机特性难以保证对不同数据的分类需求.

近年来,复杂网络理论继承和发展了规则网络和随机网络理论,并揭示了在互联网、科研合作网、细胞网

络、社会关系网等实际网络中,具有小世界、无尺度等特性.如何利用简单有效的生长规则,建立与现实世界聚类系数、度分布、平均路径等网络特性相吻合的复杂网络成为其中的一个热点研究问题.其中,有的网络自身还具有层级或分簇结构,例如, Kaiser 等人在研究了哺乳动物大脑皮层分簇结构后,揭示出了分簇的本质原因是类似于细胞新陈代谢的时间机制,并用时间窗函数成功地模仿了大脑皮层分簇结构,且生成的网络被验证具有复杂网络的典型性质,是一种高聚类的小世界网络.

本文针对分类需求,尝试借鉴复杂网络理论,替代标准回声状态网络中的随机稀疏连接机制,建立一种自身分簇的分类器,以期提高分类效果.

本文在 Kaiser 等^[6]提出的基于时间窗机制结合空间位置的分簇网络生长算法基础上,结合需分类数据类别数量已知但不尽相同这一先决条件,提出一种基于相应簇储备池回声状态网络的分类方法,以期建立储备池子簇与需分类数据类别数量的对应关系,满足对不同数据有针对性的分类需求.

2 回声状态网络方法分析

2.1 回声状态网络基本原理

ESNs 随机地布置稀疏连接的神经元构成网络结构——“储备池”. ESNs 是储备池计算(Reservoir Computing)的一种主要类型. 储备池计算的另一种主要类型——流体状态机(Liquid State Machines, LSMs)由 W. Maass 于 2002 年提出.

ESNs 的典型结构如图 1 所示,由输入层、储备池和输出层组成. 对于由 K 个输入单元、 N 个储备池处理单元、和 L 个输出单元组成的 ESNs 网络,其基本方程如下:

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

$$\mathbf{y}(n+1) = \mathbf{f}^{\text{out}}(\mathbf{W}^{\text{out}}(\mathbf{u}(n+1), \mathbf{x}(n+1), \mathbf{y}(n))) \quad (2)$$

其中, $\mathbf{x}(n) = (x_1(n), \dots, x_N(n))^T$, $\mathbf{y}(n) = (y_1(n), \dots, y_L(n))^T$, $\mathbf{u}(n) = (u_1(n), \dots, u_K(n))^T$ 分别表示回声状态网络的状态变量、输出变量和输入变量. $\mathbf{f} = (f_1, \dots, f_N)$ 和 $\mathbf{f}^{\text{out}} = (f_1^{\text{out}}, \dots, f_L^{\text{out}})$ 分别为储备池处理单元和输出单元的激活函数向量. 输入单元通过 $\mathbf{W}^{\text{in}} = (w_{ij}^{\text{in}}) \in \mathbb{R}^{N \times K}$ 与储备池处理单元连接, $\mathbf{W} = (w_{ij}) \in \mathbb{R}^{N \times N}$ 为储备池处理单元间的连接权值, $\mathbf{W}^{\text{back}} = (w_{ij}^{\text{back}}) \in \mathbb{R}^{N \times L}$ 为输出层到储备池的连接权值, 储备池通过 $\mathbf{W}^{\text{out}} = (w_{ij}^{\text{out}}) \in \mathbb{R}^{L \times (K+N+L)}$ 与输出单元连接. 其中, \mathbf{W}^{in} 、 \mathbf{W} 和 \mathbf{W}^{back} 无需训练, 经初始给定后保持不变. 图 1 中虚线部分分别为输入层到输出层的连接、输出层到储备池的连接、输出层到输出层的连接, 为可选部分.

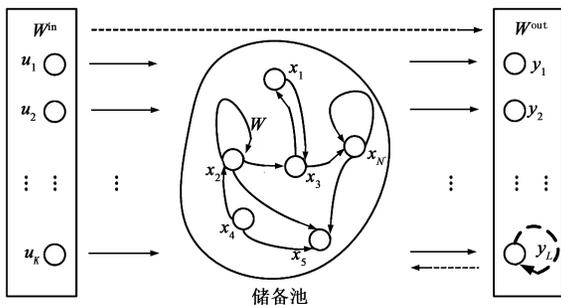


图1 典型的ESN网络结构

回声状态网络训练的基本思想是:输入输出训练样本数据通过随机生成的权值矩阵 \mathbf{W}^{in} 和 \mathbf{W}^{back} 激励储备池处理单元, 储备池处理单元间的稀疏连接权值矩阵 \mathbf{W} 也是随机生成的, 采用线性回归使训练均方误差最小化的方法即得到 \mathbf{W}^{out} . 具体实现方法可参考文献 [1, 7], 本文限于篇幅不予赘述.

2.2 面向静态模式分类的回声状态网络

回声状态网络一般用于解决时序相关问题.

Alexandre 等提出面向静态模式分类的回声状态网络方法^[5], 去除了传统回声状态网络中状态变量间的依赖关系, 使其更适于解决静态模式分类问题. 回声状态网络静态分类方法的基本思想如式(3), 始终保持输入样本不变, 直至储备池状态变量趋于稳定, 即前后两次迭代结果的变化不明显. 在这里, n 仅用于区分不同的样本, 并非表示时间.

$$\mathbf{x}(n+1)^{(i)} = \mathbf{W}^{\text{in}}\mathbf{u}(n+1) + \mathbf{W}\mathbf{x}(n+1)^{(i-1)} \quad (3)$$

其中, $\mathbf{x}(n+1)^{(0)} = \mathbf{0}$.

这种方法的特点在于使用储备池处理单元激活函数对状态变量处理之前使其趋于稳定, 而其仍然具有回声状态网络训练过程简捷的特点, 且取得了优秀的性能表现, 但是, 其储备池完全随机生成, 在生成过程中, 没有利用需分类数据类别数量已知这一条件, 其随机稀疏连接并不具有分簇结构, 难以保证对不同数据的分类需求.

3 基于相应簇的回声状态网络静态分类方法

3.1 基于相应簇的回声状态网络静态分类方法

本文针对分类需求, 尝试借鉴复杂网络理论, 替代标准回声状态网络中的随机稀疏连接机制, 建立一种自身分簇的分类器, 以期提高分类效果. 其中, 一个简单且有效的分簇小世界网络结构是 Kaiser 等基于时间窗机制生成的.

Kaiser 等受到自然界中哺乳动物大脑皮层结构的启发^[8], 提出基于时间窗机制结合空间位置的分簇网络生长算法^[6], 以生成具有分簇结构及小世界特性的网络. 在网络中存在若干簇结构即簇内高度连接的节点集合, 用于模拟真实大脑皮层中的特定功能区, 其簇结构数量由网络生成初始化阶段设置的前驱节点数量决定. 借鉴文献^[6]中的基于时间窗机制结合空间位置的分簇网络生长算法以生成储备池处理单元间的连接结构, 本文提出一种基于相应簇储备池回声状态网络的静态分类方法, 建立储备池子簇与需分类数据类别数量的对应关系, 满足对不同数据有针对性的分类需求.

基于时间窗机制结合空间位置的分簇网络生长算法中, 决定两个节点之间是否存在连接关系的概率由式(4)描述:

$$P = P_{\text{dist}}(d(U, V)) \cdot P_{\text{time}}^{(w(V))}(t) \cdot P_{\text{time}}^{(w(U))}(t) \quad (4)$$

其中, $P_{\text{dist}}(d(U, V)) = \beta e^{-\gamma \cdot d(U, V)}$ 为距离相关概率.

$P_{\text{time}}^{(i)}(t) = P(t, \mu^{(i)}, \sigma(\alpha))$, ($i = 1, \dots, k$), 为时间窗相关概率. 图 2 中的时间窗函数模拟具有 3 个簇 ($k = 3$) 大脑皮层结构的储备池内部处理单元时间相关概率, 积分参数 α 控制时间窗面积. 关键参数 k 为网络中

簇结构的数量亦即先驱节点数量,代表大脑皮层的功能单元数目.而在本文中,则为具体分类问题中分类数据的类别数,如图3所示,以某具体分类问题需分3类为例,则可设 $k=3$,于是储备池内部将相应地产生3个子簇.其它参数和设置方法可参考文献[6].

在本文中,为了生成储备池处理单元间的连接结构,分簇网络生长算法的实现步骤如下:

(1)设置网络生成算法的各个参数,包括网络最终节点数量亦即储备池处理单元个数 N 、时间窗积分参数 α 、距离相关参数 β 、 γ .根据待分类数据的类别数量设置网络簇结构数量 k ;

(2)将 k 个先驱节点随机散布于长、宽均为1的二维区域中并记录其空间位置.在这里,由于网络生成的目的并非用于模拟真实的大脑皮层结构,因此与文献[6]对称散布先驱节点的方式有所不同^[9];

(3)在区域内随机生成新节点 U 的空间位置,并将 U 归属于与其空间距离最近的先驱节点,从而可计算其时间窗相关概率 $P_{\text{time}}^{(w(U))}(t)$;

(4)计算新节点 U 与网络中已布置的节点 V 之间的距离相关概率 $P_{\text{dist}}(d(U, V))$ 及时间窗相关概率 $P_{\text{time}}^{(w(V))}(t)$.利用式(4)得到新节点与已布置节点之间的连接概率,若其不小于一个(0,1)区间内均匀分布的随机数,则新节点 U 与已布置的节点 V 之间存在连接关系;

(5)执行步骤(4)直至与所有已布置节点的连接概率计算并比较完毕,若与所有已布置节点之间均不存在连接关系,则转至步骤(3)重复执行,直至网络中已布置节点数量达到设置的参数 N .

3.2 回声状态网络训练过程

本文方法中,ESNs储备池处理单元采用的激活函数为双曲正切函数,输出单元采用的激活函数为恒等函数,没有采用输入层到输出层的连接、输出层到储备池的连接、输出层到输出层的连接.

从而,ESNs的训练过程如下:

(1)设置ESNs各个参数,包括储备池处理单元数目 N 、内部连接权谱半径 R ,输入、输出单元数目等;

(2)初始化输入连接权矩阵 W^m ,根据数据对象按照3.1所述方法生成内部连接权矩阵 W ;

(3)将训练样本输入已初始化的ESNs中,利用式(3)收集状态变量,并输入至储备池处理单元激活函数中处理得到最终的状态变量;

(4)采用伪逆算法求解输出权矩阵 W^{out} ,得到训练完毕的ESNs网络结构.

4 实验验证与结果分析

4.1 实验设计

本文一方面采用标准数据集来验证方法对于静态模式分类问题的有效性,另一方面将方法应用于模拟电路故障诊断中,验证方法对于模拟电路故障诊断的适用性.

本文实验采用2折交叉验证进行,分类错误率为10次实验的平均值.当输入样本的类别为 m 时,ESNs的第 m 个输出单元输出+1,其他输出单元输出-1.

在4.2中,本文将基于标准数据集进行静态模式分类实验,并给出与标准ESNs的实验结果对比.在4.3中,基于典型模拟电路进行模拟电路故障诊断实验,并给出实验结果对比.

4.2 静态模式分类实验分析

为验证本文提出的基于相应簇的回声状态网络静态分类方法,本文从UCI机器学习知识库中选取了三个数据集进行实验.在实验用数据集的选择过程中,力求选取具有不同特点的模式分类问题,其基本属性对比参见表1.对于每一个数据集,分别采用一致的ESNs储备池参数(储备池处理单元个数 N 、内部连接权谱半径 R 、储备池稀疏程度 D)生成标准ESNs储备池及相应簇储备池,进行实验对比分析.

表1 数据属性对比

数据	Iris	Wine	Sonar
类别数量	3	3	2
样本维数	4	13	60
样本总量	150	178	208

以数据集Wine为例,本文在生成回声状态网络相应簇储备池的过程中,将先驱节点数量 k 设置为类别数量,即 $k=3$.其他参数设置分别为 $N=20$, $R=0.2$, $\gamma=4$, $\beta=0.1$, $\alpha=0.5$.取10次实验的平均值,得到相应簇储备池稀疏程度为 $D=0.089$.在采用标准ESNs方法进行实验时,采用与本文方法相同的储备池参数设置,以对比储备池生成方法的性能差异性,验证本文方法构建的分簇结构对静态模式分类问题的适应性和优越性.

表2给出了本文方法与标准ESNs的分类错误率对比结果.本文方法在Iris、Wine和Sonar等三个数据集上

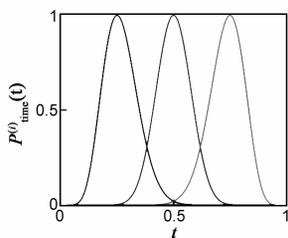


图2 时间窗函数曲线图
($k=3, \alpha=0.2$)

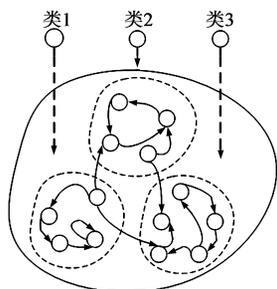


图3 相应簇储备池示意图
($k=3$)

均取得了比标准 ESNs 方法更低的分类错误率.其中,在数据集 Wine 上,本文方法的分类错误率降低了 23.6%,相对降低幅度最大;在数据集 Sonar 上,相对降低幅度最小,分类错误率降低了 4.15%,从数据属性特点来看,这一数据集的样本特征维数较高,其分类难度也较大.在数据集 Iris 上,分类错误率降低了 14.7%.

表 2 分类方法性能对比

数据	Iris	Wine	Sonar
标准 ESNs	3.13%	3.60%	24.33%
本文方法	2.67%	2.75%	23.32%

实验结果表明,结合需分类数据类别数量确定簇结构数量,采用基于时间窗机制结合空间位置的分簇网络生长算法生成 ESNs 储备池,有助于获得与数据适应性更好的储备池,提高分类性能,与标准 ESNs 方法相比,分类错误率更低.

4.3 模拟电路故障诊断实验分析

本文采用四运放双二次高通滤波电路进行模拟电路故障诊断实验,具体电路构造及参数如图 4.其中,共设置 13 种工作状态,每种工作状态采集 50 个样本,详细的故障设置参见文献[10],本文限于篇幅不予赘述.

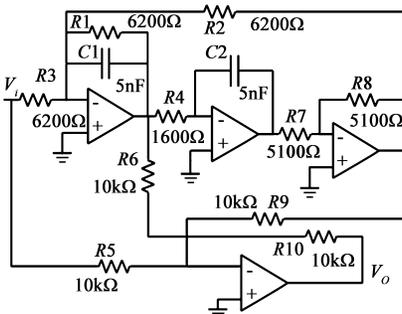


图 4 模拟电路故障诊断实例

本文中,模拟电路故障诊断分为学习和诊断两个阶段.在学习阶段,采集电路的单位脉冲响应输出信号并采用 Haar 小波变换进行处理,提取 1~5 层的第 1 个低频概貌成分作为故障特征,输入 ESNs 中进行训练,以获取诊断模型.需要说明的是,特征提取并非本文的讨论重点,实际上,采用特征选择有望改进本文方法的性能表现.在诊断阶段,生成故障测试样本,输入至诊断模型中进行故障分类,从而得到故障诊断结果.

为对比起见,本文引入常用的神经网络方法:采用反向传播算法训练的多层感知器(BPNN)进行实验对比分析.表 3 给出了 BP 神经网络、标准 ESNs 方法以及本文方法的性能对比结果.此外,为验证方法的时间消耗表现,随机选取样本的 90% 作为训练数据集,其余 10% 作为测试数据集,将各种方法在固定参数下分别连续运行 100 次,其训练时间和测试时间的平均值如表 3 所示,单位为秒.

表 3 诊断方法性能对比

方法	BPNN	标准 ESNs	本文方法
诊断错误率	17.88%	8.91%	8.37%
训练时间	8.031	0.197	0.117
测试时间	0.010	0.017	0.010
储备池生成时间	—	0.134	0.717

实验结果表明,本文提出的方法取得了更为准确的表现,诊断错误率较低.BP 神经网络的诊断错误率较高.其中,与 BP 神经网络相比,本文方法的诊断错误率降低了 53.2%.与标准 ESNs 方法相比,本文方法的诊断错误率也有所降低,证明了相应簇储备池的适应性.

在训练时间消耗上,本文方法相对于 BP 神经网络方法有明显的降低,与标准 ESNs 相比也较低.此外,在测试时间消耗上,本文方法也优于标准 ESNs 方法.在储备池生成时间消耗上,本文方法高于标准 ESNs,这是由于分簇网络生长算法相对于随机生成方法带来的额外时间消耗,但是需要注意的是,储备池的生成可以在训练之前独立完成,因此,这部分时间消耗对于实际应用的影响很小.

基于典型模拟电路的故障诊断实验结果表明:(1)基于回声状态网络的方法相对于 BP 神经网络方法,诊断错误率较低,本文提出的相应簇储备池方法有利于提高诊断性能;(2)本文方法在时间消耗等性能指标上同样取得了较好的表现,从而,能够为模拟电路故障诊断的准确性和效率提供保障.

5 结论

在保持回声状态网络储备池内部权值矩阵数值随机,不参与训练的基础上,本文借鉴模仿哺乳动物大脑皮层分簇结构的复杂网络拓扑结构,提出了一种基于相应簇储备池回声状态网络的分类方法——分类器内部结构自分簇.利用具体分类问题中类别数量已知这一先决条件,本文将时间窗函数机制引入到回声状态网络储备池的构建中.基于标准数据集和模拟电路故障诊断的实验验证结果表明,本文方法与标准回声状态网络、BP 神经网络等方法相比,子簇物理意义明晰且具有更高的分类精度.

值得注意的是,本文提出的自身分簇的分类器虽然提高了分类效果,物理意义明晰,但并未给出理论证明.同时,分类器子簇和需分类问题的对应关系以及提高了分类数据表达能力的原因还有待进一步研究.

参考文献

- [1] Jaeger H. The "Echo State" Approach to Analysing and Training Recurrent Neural Networks[R]. Bremen: German National Research Center for Information Technology, 2001.

- [2] Jaeger H, Haas H. Harnessing nonlinearity: Predicting chaotic system and saving energy in wireless communication[J]. Science, 2004, 304(5667): 78 – 80.
- [3] Skowronski M D, Harris J G. Automatic speech recognition using a predictive echo state network classifier[J]. Neural Networks, 2007, 20(3): 414 – 423.
- [4] Ding Hai-yan, Pei Wenjiang, He Zhen-ya. A multiple objective optimization based echo state network tree and application to intrusion detection[A]. Proceedings of 2005 IEEE International Workshop on VLSI Design and Video Technology[C]. Piscataway: Institute of Electrical and Electronics Engineers Inc, 2005. 443 – 446.
- [5] Alexandre L A, Embrechts M J, Linton J. Benchmarking reservoir computing on time independent classification tasks[A]. Proceedings of the International Joint Conference on Neural Networks[C]. Piscataway: Institute of Electrical and Electronics Engineers Inc, 2009. 89 – 93.
- [6] Nisbach F, Kaiser M. Developmental time windows for spatial growth generate multiple-cluster small-world networks[J]. European Physical Journal B, 2007, 58(2): 185 – 191.
- [7] Jaeger H. Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the "echo state network" approach[R]. Bremen: German National Research Center for Information Technology, 2002.
- [8] Kaiser M, Hilgetag C C. Development of multi-cluster cortical networks by time windows for spatial growth[J]. Neurocomputing, 2007, 70(10 – 12): 1829 – 1832.
- [9] Song Qingsong, Feng Zuren. 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.
- [10] Aminian F, Aminian M, Collins H W. Analog fault diagnosis of actual circuits using neural networks[J]. IEEE Transactions on Instrumentation and Measurement, 2002, 51(3): 544 – 550.

作者简介



郭嘉男, 1982年4月生于黑龙江哈尔滨, 现为哈尔滨工业大学自动化测试与控制系博士研究生, 主要研究方向为回声状态网络、时间序列数据挖掘等。

E-mail: guojia. gm@gmail. com



雷苗男, 1985年8月生于重庆, 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小波分析、复杂网络等。

E-mail: leimiao_ hit@126. com