

液体状态机研究进展

张永强^{1,2}, 倪珊珊², 宋美霖², 满梦华¹

(1.陆军工程大学石家庄校区, 河北 石家庄 050003;

2.河北科技大学信息科学与工程学院, 河北 石家庄 050018)

✉ zyzq@hebust.edu.cn; nss_work@163.com; songmeilin1997@qq.com; manmenghua@126.com



摘要:液体状态机(Liquid State Machine, LSM)具有实时计算和仿生的特点,在处理时间序列数据上具有巨大潜力。为了研究如何提高神经网络模型训练性能,降低计算复杂度,文章首先梳理和回顾了近几年相关研究文献,其次提出硬件实现和软件模型两个优化思路,并总结了不同优化方法的优势与不足,硬件和软件上的优化可以提高神经网络模型学习性能和训练速度,但依然存在可控性差、算法最优解未知等问题,最后针对以上问题对未来的研究方向进行了展望,可为时间序列数据处理和模式识别领域提供优化思路。

关键词:脉冲神经网络;储备池层;液体状态机;遗传算法

中图分类号:TP183 **文献标志码:**A

Research Advances in Liquid State Machine

ZHANG Yongqiang^{1,2}, NI Shanshan², SONG Meilin², MAN Menghua¹

(1.Shijiazhuang Campus of Army Engineering University of PLA, Shijiazhuang 050003, China;

2.School of Information Science and Engineering, Hebei University of Science and Technology, Shijiazhuang 050018, China)

✉ zyzq@hebust.edu.cn; nss_work@163.com; songmeilin1997@qq.com; manmenghua@126.com

Abstract: Liquid State Machine (LSM), characterized by real-time computation and biomimetics, has great potential in processing time series data. In order to study how to improve the training performance of neural network models and reduce computational complexity, relevant research literature in recent years is firstly reviewed in this paper. Then, two optimization ideas, hardware implementation and software model, are proposed, and the advantages and disadvantages of different optimization methods are summarized. Hardware and software optimization can improve the learning performance and training speed of neural network models, but there are still problems such as poor controllability and unknown algorithm optimal solutions. Finally, the future research direction is prospected for the above problems, which can provide optimization ideas for the field of time series data processing and pattern recognition.

Key words: spiking neural network; reserve pool layer; Liquid State Machine; genetic algorithm

0 引言(Introduction)

受神经生物学基础短脉冲的启发,研究者通过改变深度神经网络的神经元,仿照大脑工作机制研究提出脉冲神经网络(Spiking Neural Network, SNN)^[1-2]。SNN的拓扑结构有前

馈型脉冲神经网络、递归型脉冲神经网络和混合型脉冲神经网络。2002年,MAASS等^[3]和NATSCHLÄGER等^[4]首次提出液体状态机,该方法是混合型脉冲神经网络的一种,它不需要将信息存储在计算系统的某些稳定状态中,训练速度较快。

2004年,WOJCIK等^[5]首次使用LSM模拟类生物视觉系统,验证了其分类有效性。后续研究逐渐拓展到生物^[6]、图像预测^[7]、模式分类^[8]等领域。

目前,液体状态机的硬件实现方式有超大规模集成电路、现场可编程逻辑门阵列和忆阻器。液体状态机软件模型的优化工作主要包括算法优化、突触可塑性改进以及储备池层的增加。在对液体状态机的基本结构进行详细介绍的前提下,本文对硬件实现和软件模型两个优化方向的研究进展进行了总结,列举了一些LSM编程平台,可供学者参考。

1 液体状态机(Liquid State Machines)

1.1 基本结构

液体状态机是一种脉冲神经网络,也是一种递归神经网络。液体状态机主要分为三个部分,即输入层、储备池层和输出层。从输入层到储备池层的连接是随机确定的,一个输入神经元可与储备池层神经元进行任意连接。液体状态机的基本模型结构如图1所示。

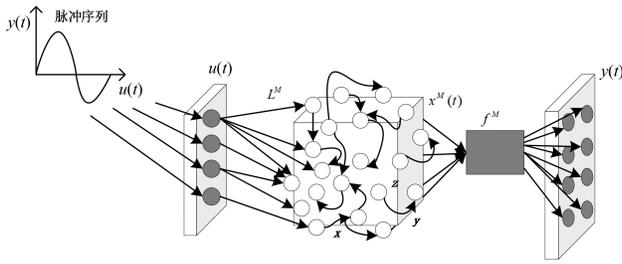


图1 液体状态机的基本模型结构图

Fig.1 Structure diagram of LSM

LSM模型结构的第一部分是输入神经元,主要是通过外部刺激,引入输入序列 $u(t)$ 。

第二部分是储备池层,主要进行神经计算,即将引入的信号进行特定的数学运算。在数学表达中,液体状态可称为液体滤波器 L^M , M 表示滤波器。储备池层所有神经元的放电输出向量 $x^M(t)$,使用数学计算将输入序列映射到高维中间状态,即

$$x^M(t) = (L^M u)(t) \quad (1)$$

因为储备池层是递归连接的网络,储备池层接收一个连续的输入序列 $u(s)$,在之后的时间 $s < t$ 的情况下,当前中间内部状态 $x^M(t)$ 保存了关于最近输入 $u(s)$ 的大量信息,所以中间内部状态不仅与当前的输入有关,而且与前一段时间的输入有关,具有一定的记忆能力,就像石头投入水中会产生波纹,不断投入石头,水中会不断地产生波纹,波纹延迟一段时间消失,一定时间内的波纹与波纹之间会相互影响。

第三部分是输出层,储备池层具有一定的记忆功能,输出层则不需要处理 t 时间之前的信息,通过学习算法 f^M 连接中间内部状态与目标输出 $y(t)$,即

$$y(t) = f^M(x^M(t)) \quad (2)$$

为了获得与输入相对应的输出,必须对液体状态机进行训练。在训练阶段,液体神经元之间的连接权重不发生变化,只调节从液体神经元到输出单元的连接权重。训练或调整一个输出映射函数 f^M ,使得液态 $x^M(t)$ 映射到所需的输出 $y(t)$,同时保持液体滤波器 L^M 不变。在这个过程中,网络层权值通

常随机选取,之后保持不变,大大降低了训练的复杂度。从液体神经元到输出单元的训练方法只需选择简单的分类器,如线性回归等。因此,液体状态机对不同的任务具有普适性。

1.2 LSM 属性

液体状态机是有效的分类器,同时具有通用的实时计算时间序列能力,这是因为它有两个抽象但概念简单的属性——分离属性 (Separation Property) 和接近属性 (Approximation Property)。分离属性是指不同的输入 $u(t)$ 与 $v(t)$,产生的中间状态 $x_u^M(t)$ 与 $x_v^M(t)$ 反映了两个不同输入之间的全部差异。研究表明,分离特性把很小的输入差异都反映在中间状态中,保证了网络对于复杂输入的处理能力。不同输入储备池层之间的距离可以使用欧式距离对中间状态的差异进行计算,即

$$D(u, v) = \|x_u^M(t) - x_v^M(t)\| \quad (3)$$

其中, $\|\cdot\|$ 表示欧几里得范数。

接近属性是表征输出神经元能够区分中间状态对自己的影响,将需要的状态转化为特定的输出能力。分离属性依赖储备池层的复杂程度,接近属性主要依赖输出层对于目标任务的适应能力。

1.3 与其他神经网络的对比

目前,神经网络连接方式大部分为线性的全连接,输出也为连续的值。根据归纳算法的基本结构和特征可以发现,LSM使用具有固定权重的互联神经元库,将时空输入信号投射到高维空间,高度模拟生物神经元机制,通过学习网络中的连接权重实现输出,大大降低了训练的复杂度,并且可以识别标签,编码成具有时序性的脉冲序列,对时序信号的计算能力具有实时性,对分类任务具有普适性。几种具有代表性的神经网络算法特性如表1所示。

表1 经典神经网络算法

Tab.1 Classical neural network algorithms

| 神经网络 | 基本结构 | 主要特征 | 缺点 |
|--------------------------|------------------------------------|-----------------------|-------------------------------------|
| 感知机 | 以神经元为最小单位,输入进入网络后,经过加权求和,比较数学操作后输出 | 有监督线性二分类模型 | 处理高维数据具有一定的局限性 |
| BP(Back Propagation)神经网络 | 基于神经元按误差逆传播算法训练的多层前馈网络 | 适合解决内部机制复杂的问题,自学能力比较强 | 由于其目标函数的复杂性,训练与预测次数过于频繁,所以容易出现过拟合现象 |
| 深度神经网络 | 感知机的一种延展,内部连接方式为全连接 | 擅长处理局部相关性比较大的问题 | 训练数据与测试数据分布拥有较大差异时,会导致网络的泛化能力降低 |

2 LSM模型的硬件实现(The hardware realization of LSM model)

硬件模型的设计出发点是满足高性能和低能耗等需求,但是硬件模型很难控制网络模型参数的最优范围,导致优化工作

很难开展;而液体状态机不需要设置过多的参数,更符合生物神经网络的特性,有助于实现硬件计算模块。液体状态机的硬件主要有三种实现方式:超大规模集成电路(Very Large Scale Integration Circuit, VLSI)、现场可编程逻辑门阵列(Field Programmable Gate Array, FPGA)和忆阻器。

2.1 VLSI

2014年,ROY等^[9]针对液体状态机的读出阶段提出了一种新的树状增强的结构(LSM-DER)作为读出方式的液体状态机和一种有效学习规则网络(NRW)重新布线。研究发现,LSM-DER和NRW能够以更少的突触数量获得比目前最先进的平行感知器读出的液体状态机(LSM-PPR)更好的性能。2015年,ZHANG等^[10]提出了仿生数字液体状态机技术。利用VLSI技术可以将一个电子子系统乃至整个电子系统集成在一块芯片上,完成信息采集、处理、存储等多种功能,但存在不能重复编程的缺点。

2.2 FPGA

2016年,LSM模型的硬件实现使用了FPGA技术,它可以进行重复编程,既解决了定制电路的设计复杂度,又克服了原有可编程器件门电路数有限的缺点。SCHRAUWEN等^[11]提出了一种基于FPGA的液体状态机串行体系硬件设计方案,该体系结构紧凑地实现了尖峰神经网络,能实时处理数据信息,在不影响识别精度的前提下,降低语音识别基准的能耗。FPGA与液体状态机在很好的组合状态下,可以高效地进行储层调整,大大提高学习性能和能量效率;但是,在处理大量数据时的表现差强人意。

2.3 忆阻器

忆阻器最早于2008年提出,它两端是由纳米电子器件构成的,既可以保持用过去历史电导状态表示突触权重,又可以在输入的电压或电流信号作用下调制到新的状态^[12]。忆阻器阵列可以将计算与存储高效地结合,省去数据调用,加快了矩阵计算的速度,满足对大量数据信息的实时处理要求。基于忆阻器的SNN硬件电路研究得到迅速发展^[13]。但是,忆阻器内部存在阵列的漏电与可控性问题,因此目前集成大规模的忆阻器阵列比较困难。市面上的忆阻器神经形态计算平台以仿真为主,未来的发展方向应将仿真实验与实际相结合,构建合理的忆阻器模型。

3 LSM软件模型优化进展(LSM software model optimization progress)

液体状态机结构简单,训练速度快,处理具有时序特性的问题时,能够快速获取信息并处理,具有实时性和普适性,但是计算精度低、无法捕获多个时间尺度上的动态信息的缺点依然存在。分析原因主要如下:(1)评估算法的性能需要大量的时间,加重了液体状态机的计算压力。(2)液体状态机虽然只需要训练储备池层到读出层之间的连接矩阵,但是只有矩阵为全连接方式时,才能保证具有良好的性能。(3)单个液体状态机处理复杂的现实任务存在一定的难度,无法兼顾不同时间尺度上的时间信息。针对以上问题,研究者在液体状态机的软件模型上找到了优化方向。第一,通过其他算法评估LSM网络模型性能,改进时间库,优化模型。第二,通过改变突触的可塑性可以稀疏储备池层和读出层之间的连通性,防止权重饱和,提高LSM网络模型的学习性能。第三,利用LSM固有的随机投影以及局部塑性机制优化顺序层之间的数据传输,增强其在复

杂时空任务中的性能。与传统神经网络一样,可以增加储备池层的层数,增加训练次数,优化输出结果。

3.1 算法优化

在优化算法上,使用遗传算法进行调整最为常见。遗传算法更符合生物特性,适合液体状态机这类具有生物特性的网络,提高液体状态机训练效率。

目前,已有研究者使用遗传算法去掉自连接的神经元和对结果产生不好效果的神经元,再通过强化学习的方法改变储备池层的连接方式,从而优化了液体状态机的内部结构。为了使遗传算法更加精确,JU等^[14]将液体过滤器从一个没有连接的最小结构演化为一个具有最小突触数和高分类精度的优化核,简化了最优线性模型的设计,降低了计算复杂度。此外,通过改变液体状态机本身的参数和输入方式达到优化目的,也是一种常用的优化方法。ZHOU等^[15]使用协方差矩阵自适应进化策略(Covariance Matrix Adaptation Evolution Strategy, CMA-ES)的同时,采用连接概率和尖峰神经元模型中的超参数对其结构进行编码,采用高斯过程作为替代对CMA-ES实现辅助,缩小搜索空间,提高了计算效率。

优化算法使得液体状态机训练能力有所提高,训练时间比人工调优的时间短,改进方案更具优势,简化了繁重的手动调参和调试网络结构的过程。但是,此方法的选择过程是在类似黑匣子中进行,只能知道结果,不能对其过程进行改进,优化结果的不确定性大。

3.2 突触可塑性改进

突触可塑性(Synaptic Plasticity)通过积极神经元与消极神经元相互配合达到更好的效果。突触可塑性在生物体内是指神经细胞间的连接,会随自身活动的激励与抑制发生相应的变化。在人工神经网络中,突触可塑性是指利用生物中的数学模型构造神经元之间的关系。

频率上,突触可塑性可以分为短时程突触可塑性与长时程突触可塑性。思想上,突触可塑性又可分为Hebbian可塑性与脉冲时间依赖可塑性(Spike Time Dependent Plasticity, STDP)。目前,研究者对液体状态机突触的改进,主要有改变突触的构造或者构造不同类型的突触。基于短时程可塑性的液体状态机改进,通过使用神经形态硬件即可实现^[16]。基于混合可塑性的液体状态机改进,是一种通过将两种类型的可塑性结合开发液体状态机储备池层的新方法,它是由不同行为和不同兴奋程度的异质神经元组成的自组织网络,通过皮层编码的两种生物学习规则——细化突触连通性和神经元内源性构建子神经元^[17]。神经元之间的连接则在考虑了两种不同的STDP(兴奋性突触的e-STDP和抑制性突触的i-STDP)的前提下,通过脉冲时间依赖的可塑性学习实现的,擅长完成时间模式分类任务。

STDP规则不仅提高了网络学习效率,而且在液体层中诱导了自组织行为,从而自然地形成一个更稀疏的递归网络。2013年,XUE等^[18]提出了基于时间依赖可塑性的改进液体状态机,可以有效地对液体池进行优化。研究发现,具有STDP学习性能的液体状态机可以高精度地执行同类型生物相关的实时计算任务。2017年,LIU等^[19]利用生物合理的尖峰时间依赖可塑性机制,训练了液体状态机的监督性。利用STDP自然诱发的自组织行为,提高学习能力的同时,液体状态机的高

效性也得到了有效实现。2017年,LI等^[20]还提出了一种具有多聚类 and 主动-神经元-主导结构的脉冲神经网络液体计算模型,取代了传统的随机结构,改善了活动同步性和网络敏感性,同时提高了信息处理能力,并且具有较高的拓扑复杂度和动态多样性,大大提高了信号传输效率。2021年,TIAN等^[21]提出了一个基于神经结构搜索的框架,探索面向数据集的自动LSM模型的结构和参数设计空间,优化了指数级增长的参数设计空间,提高了计算精度,降低了计算复杂度。

3.3 深度液体状态机

深度液体状态机是一种通过加入其他层或者加入多层实现液体状态机模型的一种方式。2017年,SOURES等^[22]提出一种深度液体状态机模型,将神经可塑性和注意力嵌入拓扑结构中,增强了其对复杂网络的性能,训练时间与传统液体状态机相比有所缩短。深度LSM的基本模型结构如图2所示。

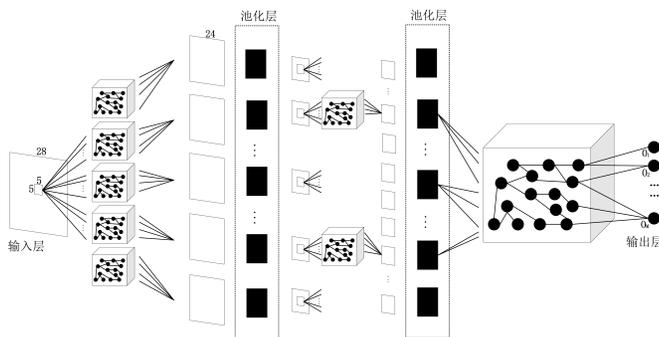


图2 深度LSM的基本模型结构

Fig. 2 Basic model structure of deep LSM

深度液体状态机结构的深度与广度使其比较擅长处理分层时态问题。这是因为深度液体状态机自身液体层的随机性,并且能够使用多个局部塑性规则构造编码层,从而降低其训练复杂度,提高训练速度;但是,深度液体状态机存在不可扩展和可伸缩性差的缺点。

4 LSM编程平台(Programming platform of LSM)

使用液体状态机编程工具可以快速地建模、训练以及搭建软件平台。根据面向的研究目标以及使用的方式不同,现存 Gensis、Neuron、Nengo、BindsNet、SpyKetorch、Nest、Brian、Synaptics 等液体状态机编程平台;各平台的具体特点如表2所示。

表2 液体状态机编程平台
Tab.2 Programming platform of LSM

| 平台 | 编程语言 | 功能 | 特点 |
|--------|-----------------------|----------|---|
| Gensis | C | 神经元仿生 | 可以模拟多个同类型的神经元 |
| Neuron | C,C++, Python, Fortan | 神经元仿生 | 仿真单个神经元,拥有良好的图形界面和丰富的功能 |
| Nengo | Python | 神经元及网络仿生 | 直接从硬件获取输入,可自定义神经元类型以及学习规则,拥有高度的可扩展性和灵活性 |

续表

| 平台 | 编程语言 | 功能 | 特点 |
|------------|------------|----------|--|
| BindsNet | Python | 网络学习 | Python库,使用Tensor功能在CPU或GPU上模拟脉冲神经网络,可与机器学习结合 |
| SpyKetorch | Python | 网络学习 | 基于张量计算的PyTorch框架,提高了CPU、GPU或多GPU平台上运行的实时优化能力 |
| Nest | Python | 神经元及网络仿生 | 强化神经网络模型的模拟器,适合任何大小的脉冲神经网络 |
| Brain | Python | 神经元及网络仿生 | 面向SNN的开源模拟器,简单易学,可扩展,降低了编程时间和计算机的模拟时间 |
| Synaptics | JavaScript | 神经元及网络仿生 | 为Node.js和浏览器环境打造的JavaScript神经网络库,可训练高阶网络 |

5 结论(Conclusion)

本文围绕LSM的基本结构和软硬件优化方式,梳理相关领域的研究进展,总结LSM实现的编程平台,为相关领域的学者优化LSM提供了参考。液体状态机作为一种典型的脉冲神经网络,结构简单,拥有极高的生物相似性,与传统神经网络相比,计算复杂度大大降低,训练速度也大大提高。由于本身需要设置一定的参数,对储备池层约束较少,因此还有很大的发展空间。未来的研究方向如下:第一,探索液体状态机的每一层,寻找层与层之间的算法最优解;第二,在单个突触或者不同类型之间构造的研究有所进展,突触的触发机制有待深入研究;第三,在模型实现上的时间集成能力不够精准和拓扑结构如何影响计算的问题尚未解决。

参考文献(References)

- [1] 王秀青,曾慧,韩东梅,等. 基于脉冲神经网络的类脑计算[J]. 北京工业大学学报,2019,45(12):1277-1286.
- [2] 蔺想红,王向文,张宁,等. 脉冲神经网络的监督学习算法研究综述[J]. 电子学报,2015,43(3):577-586.
- [3] MAASS W, NATSCHLÄGER T, MARKRAM H. Real-time computing without stable states: a new framework for neural computation based on perturbations [J]. Neural Computation, 2002, 14(11): 2531-2560.
- [4] NATSCHLÄGER T, MAASS W, MARKRAM H. The "Liquid Computer": a novel strategy for real-time computing on time series [J]. Special Issue on Foundations of Information Processing of Telematik, 2002, 8(1): 39-43.

(下转第38页)