

液态神经网络研究综述^①

殷瑞刚¹, 王偲柠², 魏 帅³

¹(中国人民解放军联勤保障部队第九二四医院, 桂林 541002)

²(嵩山实验室, 郑州 450018)

³(信息工程大学, 郑州 450002)

通信作者: 魏 帅, E-mail: weis0906@163.com



摘 要: 2018 年, 麻省理工学院的研究人员从秀丽隐杆线虫的神经网络中得到启发, 提出了液态神经网络 (liquid neural network, LNN), 这种神经网络更接近于人类大脑的思维模式, 可以更高效地处理时序任务. 本文对液态神经网络相关研究进行了介绍和分析, 首先总结了液态神经网络的原理模型及其与简单循环神经网络 (Simple RNN)、长短时记忆 (LSTM) 网络和时间常数循环神经网络 (TC-RNN) 的区别与联系, 以及其相对于时间常数循环神经网络所具有的优势. 接着介绍了液态神经网络在汽车自动驾驶、无人机导航以及股票预测中的应用, 分析了其中采用的液态神经网络模型. 最后对其面临的问题和挑战进行了总结和展望.

关键词: 液态神经网络 (LNN); 秀丽隐杆线虫; 长短时记忆网络; 时间常数循环神经网络

引用格式: 殷瑞刚, 王偲柠, 魏帅. 液态神经网络研究综述. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10090.html>

Survey on Liquid Neural Networks Research

YIN Rui-Gang¹, WANG Cai-Ning², WEI Shuai³

¹(No. 924 Hospital of the Joint Logistics Support Force of the People's Liberation Army of China, Guilin 541002, China)

²(Songshan Laboratory, Zhengzhou 450018, China)

³(Information Engineering University, Zhengzhou 450002, China)

Abstract: In 2018, the researchers from the Massachusetts Institute of Technology, inspired by the neural network of *Caenorhabditis elegans*, proposed the liquid neural network (LNN). This type of neural network more closely resembles the thinking patterns of the human brain and can process sequential tasks more efficiently. This study introduces and analyzes research related to LNN. It primarily summarizes the principal models of LNN, highlighting their distinctions from and connections to simple recurrent neural network (Simple RNN), long short-term memory (LSTM) network, and time-constant recurrent neural network (TC-RNN), as well as the advantages that LNN possesses over TC-RNN. Furthermore, it details the applications of LNN in autonomous driving, drone navigation, and stock prediction, analyzing the specific LNN models employed in these areas. Finally, the study summarizes the challenges faced and discusses the prospects for future development.

Key words: liquid neural network (LNN); *Caenorhabditis elegans* (*C. elegans*); long short-term memory (LSTM) network; time-constant recurrent neural network (TC-RNN)

2018 年, 麻省理工学院研究人员 Hasani 等人^[1,2]提出了一种基于现实生活中的自然智能而非人工智能的

新型神经网络, 即液态神经网络. 他们从微小的秀丽隐杆线虫^[3]中汲取灵感, 尽管这种微生物的体长仅 1 mm、

① 基金项目: 嵩山实验室自立项目 (221100211100)

殷瑞刚与王偲柠为共同第一作者

收稿时间: 2025-09-01; 修改时间: 2025-09-22; 采用时间: 2025-10-09; csa 在线出版时间: 2026-01-19

只有 302 个神经元、96 块肌肉,但却具备感知、逃逸、觅食、交配等复杂智能行为.秀丽隐杆线虫是最简单的生命智能体,也是通过生物神经机理模拟实现通用人工智能的最小载体.液态神经网络有效借鉴了秀丽隐杆线虫的神经行为特征,打造了更接近人类大脑思维模式的智能模型,因此在处理带有时序因素的任务时,展现出卓越性能,能够像人类大脑一样,依据时间序列信息动态调整处理策略,在语音识别、动作识别、运动控制、序列预测等领域具有极高的应用潜力.

当前液态神经网络在动态系统建模和时序数据处理中展现出独特优势,并且在可解释性方面相较于传统深度学习网络也有明显进步.与传统简单循环神经网络和长短时记忆网络相比,液态神经网络通过连续时间激活和动态连接权重实现自适应计算,液态架构的生物启发性使其能够以更少的神经元实现复杂时空模式的表达,这种高效性已在机器人控制、自动驾驶等领域得到验证.理解液态神经网络的原理和机制,不仅有助于解释液态网络在低功耗边缘计算中的卓越表现,也可为开发新一代类脑计算架构提供理论基石.

本文第 1 节介绍与液态神经网络密切相关的简单循环神经网络、长短时记忆网络.第 2 节介绍时间常数循环神经网络和液态神经网络,说明了两种神经网络之间的区别和联系,以及液态神经网络相对于时间常数循环神经网络所具有的优势.第 3 节介绍液态神经网络在汽车自动驾驶、无人机导航以及股票预测中的应用,分析了其中采用的液态神经网络模型及取得的效果.最后,对全文进行了总结和展望.

1 离散循环神经网络

1.1 简单循环神经网络

简单循环神经网络 (Simple RNN)^[4,5]是一种专为处理序列数据设计的神经网络架构,其核心在于通过隐藏状态的循环传递实现对时间依赖关系的建模.在每个时间步 t , Simple RNN 接收当前输入 x_t 和上一时刻隐藏状态 h_{t-1} ,通过非线性变换(通常为 \tanh 函数)生成当前状态 h_t ,最终输出 y_t .数学表达为:

$$h_t = \tanh(w_h \times h_{t-1} + w_x \times x_t) + b_h \quad (1)$$

$$y_t = w_y \times h_t + b_y \quad (2)$$

如图 1 所示,这种结构使得 Simple RNN 能够处理变长序列,如自然语言和时间序列数据.以自然语言中

的自动翻译为例,每个单词都要结合上下文语境才能正确翻译,所以需要结合前面的信息确定单词的含义,比如“The negotiation broke down. All our efforts were now down the drain.”中,“down the drain”的字面意思是流进了下水道,但是这里是形象的比喻,结合上面的语句,应该翻译为付诸东流,如果神经网络只是进行逐词翻译,就不可能得到正确的结果,而循环神经网络结合了前文的信息,则有可能得到正确的结果.

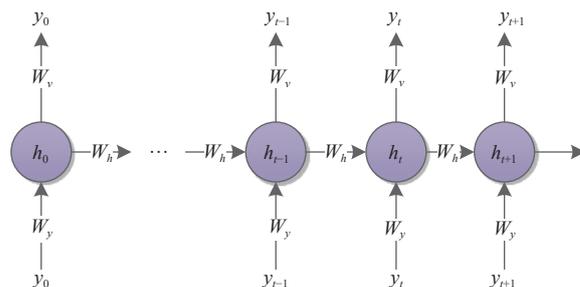


图 1 Simple RNN 网络示意图

Simple RNN 面临两大核心问题,一个是梯度消失/爆炸问题:当反向传播时,梯度需沿时间步连续相乘,导致长距离依赖的梯度指数级衰减或膨胀.例如,在文本生成任务中,Simple RNN 难以关联相隔超过 10 个词的信息.另外一个问题是短期记忆瓶颈问题:隐藏状态的简单非线性变换无法选择性地保留关键历史信息,使得模型对长期模式捕捉能力不足^[6].

1.2 LSTM 网络

为了解决传统 RNN 所面临的梯度消失/爆炸问题以及短期记忆瓶颈,1997 年, Hochreiter 等人^[7]提出 LSTM,通过引入门控机制和细胞状态解决 RNN 的缺陷.其核心创新是引入了长短时记忆,整个系统除了隐藏状态外,还引入了细胞状态 C_t 作为“记忆通道”,允许梯度无损传递,缓解梯度消失,如图 2 中虚线框所示,主要承载记忆信息.

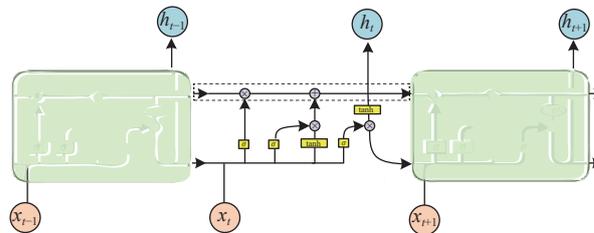


图 2 LSTM 网络示意图

记忆通道的输出更新主要依赖于上一阶段的隐藏状态 h_{t-1} 、当前的输入 x_t 以及上一阶段的记忆 C_{t-1} ,主

要通过遗忘门和输入门来实现。

遗忘门 (f_t): 决定上一状态 C_{t-1} 中哪些信息需丢弃。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

输入门 (i_t): 当前输入 x_t 以及上一阶段隐藏状态 h_{t-1} 的值信息。

$$i_t = \sigma(W_C \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (5)$$

通过遗忘门和输入门, 即可更新当前的记忆状态

$$C_t = f_t \times C_t + i_t \times \tilde{C}_t \quad (6)$$

输出门 (o_t): 控制细胞状态对当前输出的贡献。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

隐藏状态可以由输出门和当前状态共同决定:

$$h_t = o_t \times \tanh(C_t) \quad (8)$$

门控计算均采用 Sigmoid 函数 $\sigma(\cdot)$ (输出 $[0, 1]$), 或 \tanh 函数 (输出 $[-1, 1]$) 实现软选择, 公式如下:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (10)$$

LSTM 的结构^[7,8]设计借鉴了人脑记忆机制、选择性遗忘以及信息分层处理; 选择性遗忘类似突触可塑性, 遗忘门模拟神经元的长期抑制; 信息分层处理将细胞状态与隐藏状态分离, 对应大脑工作记忆与长期记忆的协同^[9], 并可在 TensorFlow^[10]等工具中快速实现。

2 连续循环神经网络

2.1 时间常数循环神经网络

在序列建模领域, 简单循环神经网络 (Simple RNN) 及其门控架构 (典型代表为 LSTM) 通常采用离散时间步长的计算范式, 即通过固定时间间隔的离散化处理来模拟序列数据的时序特性。然而, 近年研究表明, 这种离散化处理在建模连续动态系统时存在固有局限, 而通过常微分方程 (ODE) 描述的连续时间动态系统^[11]能更有效地刻画隐藏状态的演化规律。这种连续化建模方法将隐藏状态视为随时间连续变化的变量, 其动态特性可由微分方程精确描述:

$$\dot{x} = f(I, x(t), \theta) \quad (11)$$

其中, 连续变量 $x(t)$ 表征时变隐藏状态, 其导数表示状态随时间的变化率; 非线性函数 f 作为一个参数化的转

换函数, 整合了当前时刻的输入信号 I 、系统当前状态 $x(t)$ 以及可学习的网络参数 θ 。这种连续动力学系统相比传统离散 RNN 具有显著的理论优势和实践价值^[12], 主要体现在以下 3 个方面。

(1) 计算效能提升: 支持自适应步长控制, 可根据系统的动态复杂度自动调整计算粒度, 在平稳区域采用大步长提高效率, 在快速变化区域采用小步长保证精度^[13]。

(2) 时序适应性: 通过数值积分器灵活处理非均匀采样序列^[14,15], 有效解决了传统 RNN 在处理不规则间隔时序数据时的插值难题。

(3) 参数经济性: 在实验中展现出更优的连续信号建模能力^[16,17], 其连续状态空间表示可以更紧凑地编码时序信息, 减少了对大量离散时间步参数的需求。

虽然用微分方程具有很多优点, 但是却并不适用于深度神经网络, 这是由于 f 函数通常会比较复杂, 往往需要多层感知机才能实现。与之相反, 一种较老的神经网络变体, 称为时间常数循环神经网络 (TC-RNN), 对其神经状态的定义就大大简化, 适用于用集成电路实现^[18]。其输出的神经状态 $x_i(t)$ 被描述为如式 (12) 的动力学方程的解:

$$\dot{X}_i(t) = -\frac{x_i(t)}{\tau_i} + \sum_{j=1}^m W_{i,j} \sigma(A_{i,j} X_j(t) + B_j) \quad (12)$$

其中, τ_i 是隐藏节点的时间常数 (相当于自连接矩阵或自耦合); $A_{i,j}$ 和 B_j 分别是权重和偏置。TC-RNN 可以以 τ_i 为节拍对隐藏状态进行更新^[18], 并具有较好的稳态收敛特征^[19,20], 但是由于耦合常数为固定值, 限制了其表达能力^[21,22]。

2.2 液态神经网络 (LNN)

液态神经网络利用非线性门控的一阶常微分方程作为其动力学基础^[23], 替代了传统神经网络的激活函数。ODE 能表达更复杂的行为, 提升节点对输入细微变化的捕捉能力, 但也增加了复杂性。类似于生物神经网络的神经元和突触^[24,25], 液态神经网络也由神经元和突触组成^[26]。

● 神经元: 第 i 个神经元的状态 $x_i(t)$ 可建模为膜积分器, 其常微分方程表达形式及各个参数的含义如式 (13)^[27-29]所示, 其状态如图 3 所示。

$$C_{m_i} \dot{X}_i = -g_l \sigma(x_{\text{leak}_i} - x_i(t)) + \sum_{j=1}^n I_{\text{in}}^{i,j} \quad (13)$$

其中, 主要参数的含义如下所示。

$x_i(t)$: 第 i 个神经元的膜电压 (电位)

$I_{in}^{i,j}$: 代表输入神经元的外部电流。

C_{m_i} : 膜电容, 生物学中指细胞膜储存电荷的能力, 是细胞膜的一个基本电学特性, 它反映了细胞膜作为绝缘体分隔细胞内、外带电溶液时所表现出的类似于电容器的性质。

x_{leak_i} : 漏反转电位 (通常记为漏电流的平衡电位), 生物学中指维持细胞静息电位的基准电压, 当膜电位等于该值时, 漏电流为 0。

g_{l_i} : 生物学中描述细胞膜上离子通道的“泄漏”特性, 即离子被动通过膜的能力, 漏电导越大, 细胞膜对离子的通透性越高, 电流越容易“泄漏”。

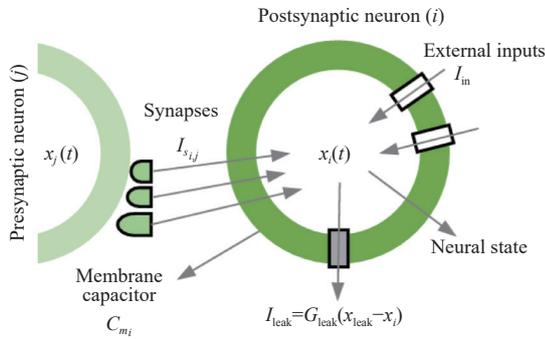


图3 液态神经单元原理图^[30]

● 突触: 从神经元 j 到 i 的突触传递, 通过 S 型非线性函数建模, 该函数是突触前节点状态 $x_j(t)$ 的函数。

$$I_{s_{i,j}} = \frac{W_{i,j}(E_{i,j} - x_i(t))}{1 + e^{-r_{i,j}(x_j(t) + \mu_{i,j})}} \quad (14)$$

其中, 参数含义如下所示:

$I_{s_{i,j}}$: 从神经元 j 到神经元 i 的突触电流。

$W_{i,j}$: 突触权重 (连接强度)。

$E_{i,j}$: 该突触的反转电位。

$x_i(t)$: 突触后神经元膜电位。

$r_{i,j}, \mu_{i,j}$: Sigmoid 非线性参数。

● 突触后神经元状态动态: 接收来自神经元 j 的一个突触的神经元 i 的状态动态 $x_i(t)$ 可以表示为某个数学公式值决定了突触电流的符号, 若为正则使突触表现为兴奋性, 若为负则表现为抑制性。这种机制允许突触后神经元根据更复杂的内在动力学来调节状态, 而非仅基于突触权重的简单标量值。

将式 (14) 代入式 (13) 中进行替换, 得到:

$$\dot{X}_i = \frac{g_{l_i}(x_{leak_i} - x_i(t))}{C_{m_i}} + \frac{-w_{i,j}\sigma_i(x_j(t))(E_{i,j} - x_i(t))}{C_{m_i}} \quad (15)$$

其中, $\sigma_i(x_j(t)) = \frac{1}{1 + e^{-r_{i,j}(x_j(t) + \mu_{i,j})}}$, 将包含 x_i 的项进行归并, 便可得到:

$$\dot{X}_i = -\left(\frac{1}{\tau_i} + \frac{W_{i,j}}{C_{m_i}}\sigma_i(x_j(t))\right)x_i + \left(\frac{x_{leak_j}}{\tau_i} + \frac{W_{i,j}}{C_{m_i}}\sigma_i(x_j(t))E_{i,j}\right) \quad (16)$$

其中, $\tau_i = \frac{g_{l_i}}{C_{m_i}}$, 式 (16) 将常微分方程表述为一个具有非线性时变特性 (耦合敏感度) 的系统, 其时变常数定义如式 (17) 所示, 因此该模型被命名为液态时间常数 (liquid time-constant, LTC) 循环神经网络。

$$\tau_{system} = \frac{1}{\tau_i} + \frac{W_{i,j}}{C_{m_i}}\sigma_i(x_j(t)) \quad (17)$$

液态神经网络的核心动力来源于一组由非线性门控机制调控的 ODE。这与依赖激活函数引入隐式非线性的传统神经网络有本质区别。ODE 模型能够表达比标准激活函数更复杂、更精细的系统动态行为, 显著增强了每个节点的表达能力, 使其能精确捕捉输入数据的细微变化。但这种强大的表达力是以模型复杂性的增加为代价的。

液态时间常数 (LTC) 是实现网络动态适应性的核心参数, 它直接关联于输入数据、动态调节 ODE 方程的速度和节点间耦合的灵敏度, 赋予网络“弹性”。LTC 在每个时间步会根据当前输入和网络输出进行更新。这使得 LTC 能持续响应输入变化, 动态重塑网络自身的行为。网络的运行依赖于求解其核心的 ODE 方程。使用专门的 ODE 求解器, 网络能够逐步、迭代地计算出序列中下一个隐藏状态。这个过程使网络能够持续依据最新输入优化其内部状态。这种基于 ODE 和动态 LTC 的机制, 使得液态神经网络在处理复杂、变化的输入序列时, 能够保持高效响应和精确处理的能力。

2.3 液态神经网络的独特优势

LTC 模型相对于 TC-RNN 的优势可以用一个简单的实验进行验证: 一个单个的 TC-RNN 神经元的实验进行验证: 一个单个的 TC-RNN 神经元和一个 LTC 神经元被一个余弦输入信号 $I(t)$ 所激励, 其公式是由式 (12) 和式 (16) 推导而来, 因为其外部输入只有一个余弦信号, 所以比较课题大大简化, 如图 4(a) 和 (b) 所示, 通过改变它们的等效参数 (通过颜色表示), 可以比较它们生成的输出状态。对于两个系统, 可以通过它们的时间常数随时间的变化说明它们的差异。图 5 (c)-(f) 展示了在不同参数下 TC-RNN 神经元 ((c)、(d)) 和 LTC 神经元 ((e)、(f)) 的不同表现, 它们处于可比较的参数化设置下, 且都受到输入信号 $I(t)$ 的激励。图 5

(c)–(f) 展示了神经元输出响应(上图)及其耦合灵敏度(时间常数)(下图) 随时间变化的投影。这些实验旨在展示当两种架构中设置等效参数时, LTC 的动态特性相较于 TC-RNN 具有更强的表达能力。图 5(c) 中参数 w 设置为较低值, 对于 TC-RNN 神经元, 绘制了对应于 10 个在指定范围内变化的输入耦合参数 λ 的 10 条输出轨迹。图 5(d) 中 w 设置为较高值, 并绘制了相同的 10 条轨迹。与图 5(c) 相比, TC-RNN 的输出响应中唯一可观察到的变化是信号的放大。图 5(e) 中当为 LTC 神经元等效地设置低 w 值时, 观察到与 TC-RNN 相似的动态特性, 因为低 w 值削弱了耦合灵敏度的影响。图 5(f) 中当 w 值较大时, LTC 的动态特性发生显著变化。LTC 的动态特性直接由其变化的耦合灵敏度(时

间常数 τ) 引起, 而对于 TC-RNN 神经元(图 5(d)), 信号的形状保持不变, 只是输出被放大。

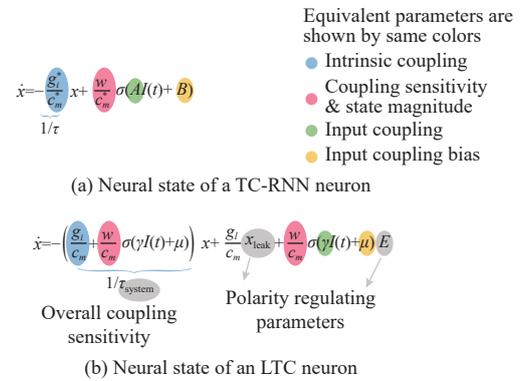
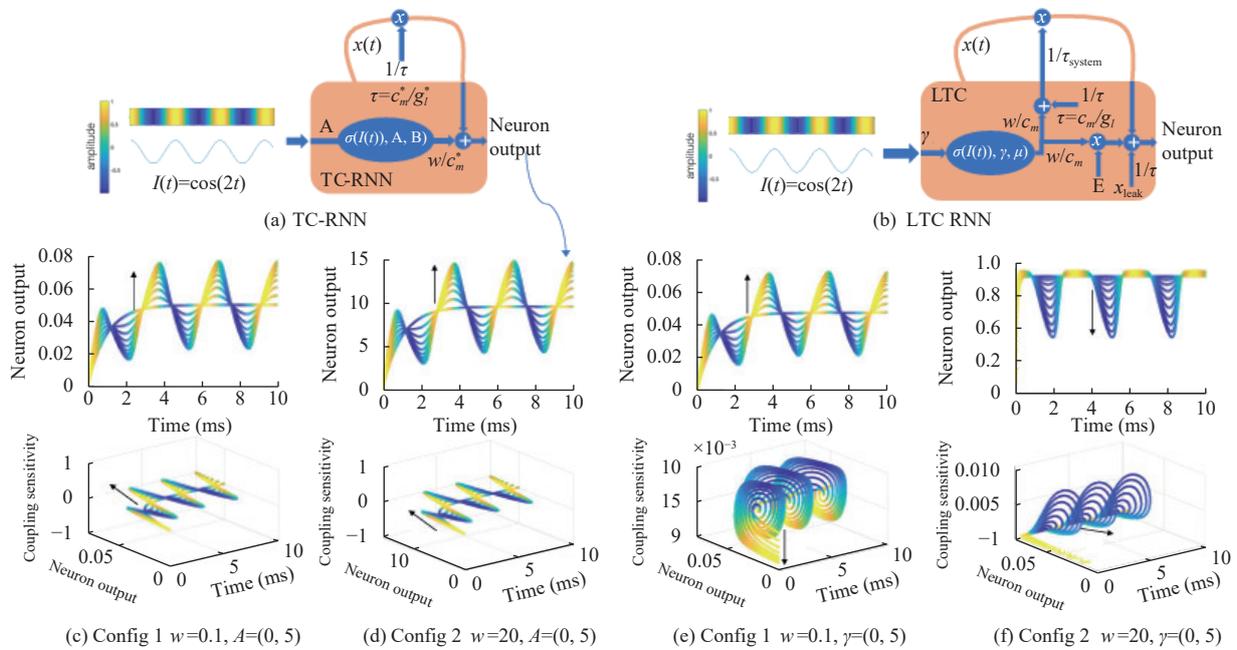
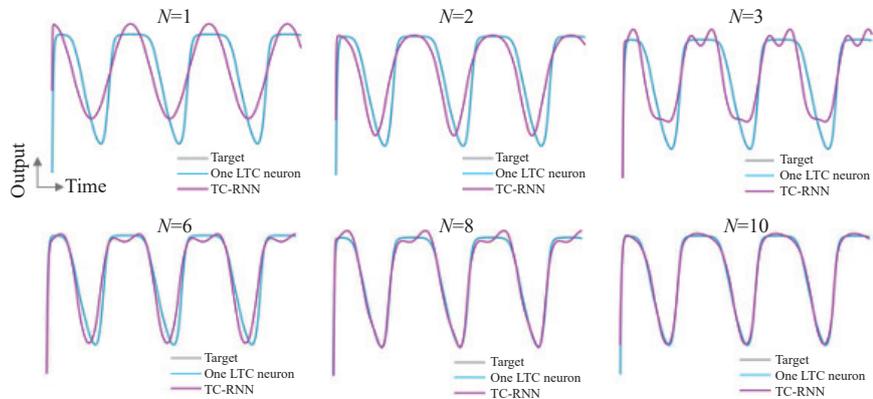


图 4 LTC 和 TC-RNN 神经元简化原理图^[26]



1. Input $I(t)$:
2. Train nets of size N :
3. To generate: Target is a single LTC neuron's output

Network	Loss (MSE)
LTC ($N=1$)	0
TC-RNN ($N=1$)	0.010 2
TC-RNN ($N=2$)	0.009 0
TC-RNN ($N=3$)	0.006 7
TC-RNN ($N=6$)	0.003 5
TC-RNN ($N=8$)	5.80×10^{-4}
TC-RNN ($N=10$)	2.55×10^{-4}



(g) TC-RNN和LTC的参数配置及对比

图 5 液态神经网络与 TC-RNN 对比图^[26]

在图 5 所示的实验中可以看出, 改变耦合灵敏度参数 w 会导致 LTC 神经元的输出信号发生剧烈变化, 而对于 TC-RNN 神经元仅小幅地改变了放大后输出信号的形状. 原因在于, LTC 中的参数 w 同时显式地影响系统的时间常数 (耦合灵敏度) 以及神经元的状态, 从而在神经元的输入、液态时间常数以及其输出状态之间建立了一种固有的因果结构. 当神经元参数 (LTC 中的 c_m/g_l 以及 TC-RNN 中的 τ) 发生变化, 而 w 保持固定时, 这种因果效应可以得到进一步体现, 如图 5(e) 和 (f) 所示, 随着其固有神经时间常数的增加, LTC 神经元实现了一系列非线性特性. 这种变化的效果通过神经元整体的时变常数 (耦合灵敏度) 来体现. 对于 TC-RNN, 这个属性是静态的, 这限制了神经元所能实现的动态范围. 为了进一步阐述这个特性, 可以将 1 个 LTC 神经元的输出做为目标, 训练不同神经元规模的 TC-RNN 网络, 观察多少个 TC-RNN 神经元可以达到相近的效果. 从图 5(g) 左半部分可以看出 1 个 LTC 神经元的输出信号具有高度非线性, 它存在相移, 在上行部分包含余弦波失真, 并且是不对称的. 由图 5(g) 右半部分可见, TC-RNN 网络至少需要 10 个神经元才能学习单个 LTC 神经元生成的目标输出. 因此, 尽管 TC-RNN 具有普适性, 但为了产生复杂动态, 在神经元数量上需要付出高昂代价.

液态神经网络以其独特的设计理念, 在人工智能领域展现出显著优势, 为应对复杂现实挑战提供了新方案. 其核心优势体现在以下 3 个方面.

- 卓越的动态适应能力: 不同于训练后参数即固化的传统神经网络, 液态神经网络具备持续进化的特性. 它能在部署后实时响应新的输入数据, 动态调整内部连接权重. 这种“活”的特性使其能像智能体一样, 在数据分布不断变化的环境中 (如自动驾驶中瞬息万变的路况、天气和突发状况)^[31,32], 迅速适应新情境, 保持高效运作.

- 强大的环境抗扰性: 面对现实世界普遍存在的数据噪声、数据干扰或数据缺失问题, 液态神经网络展现出非凡的稳定性. 其特殊架构赋予其有效过滤噪声、从残缺信息中提取关键特征的能力, 从而保障决策的准确性. 这使得它在数据质量不佳的场景 (如工业传感器监测中受设备老化、环境干扰影响的含噪数据) 下^[33-35], 依然能可靠识别设备状态、预警故障, 确保系统稳定运行^[36].

- 清晰的决策透明度: 克服了传统大型神经网络“黑匣子”的困境, 液态神经网络通过精简模型规模 (减少神经元数量), 显著提升了决策过程的可理解性. 其节点和权重在特定任务中的角色更易于解读, 使研究者能追溯推理逻辑, 不仅了解“是什么”决策, 更能理解“为什么”如此决策. 这种透明度在要求高可信度的领域 (如医疗诊断、金融风控)^[37-39]中至关重要, 例如能为医生提供清晰的诊断依据, 增强人机协作信任, 推动 AI 在关键领域的深度应用.

综上所述, 液态神经网络具有卓越的动态适应能力、强大的环境抗扰性以及清晰的决策透明度, 使得其在汽车自动驾驶、无人机导航以及股票预测等复杂时序处理任务中有着广泛的应用.

3 液态神经网络的应用

LNN 首先成功应用于汽车驾驶领域, 在第 2 节描述的神经元模型基础上, 参照秀丽隐杆线虫神经元类型, 构建了 4 层神经电路策略网络, 相较于传统的 RNN 和 LSTM 等取得了更好的结果. 但是这种神经网络求解比较复杂, 为此, Chahine 等人^[32]改进了 LNN 模型, 提出了闭合形式的 LNN 网络, 并在无人导航系统中验证其仍具有较好的效果. 除了交通领域, LNN 结合特征提取技术在股票预测领域也取得了较好的效果.

3.1 LNN 在汽车自动驾驶中的应用

液态神经网络驱动的自动驾驶系统能够依据实时采集的数据, 快速适应这些变化, 做出合理的驾驶决策, 保障行车安全. Lechner 等人^[30]在 2020 年提出了一个仅包含 19 个神经元和 253 个突触的液态神经网络来实现自动驾驶控制. 相比传统深度学习模型构造的自动驾驶系统, 网络结构要简单得多, 仅使用了 75 000 个参数. 在该自动驾驶系统中, 为了应对表示学习的挑战和自主车道保持的复杂性, 设计了一种新的端到端学习系统. 该系统通过一系列卷积层感知输入以捕捉图像结构, 并通过一种名为神经电路策略 (neural circuit policy, NCP) 的新型 RNN 结构执行控制.

具体原理由图 6(a) 所示, 突触后 LTC 神经元 i 的神经状态用 $x_i(t)$ 表示, 该神经元接收来自突触前神经元 j 的输入电流, 具体公式可参考第 2.2 节. 架构如图 6(b) 所示, NCP 中的神经动力学由 LTC 神经元表示, 共包含 4 层: 感觉神经元、中间神经元、命令神经元和运动神经元, 分别如图中的紫色、蓝色、绿色和

褐色节点所示, 命令神经元之间相互形成递归突触连接, 而其他层则采用前向连接图, 这种特定的网络拓扑结构与线虫的连接图相似. 整个系统通过卷积层处理

摄像头输入, 将潜在表示传递至设计的感受神经元, 经过中间神经元、命令神经元和运动神经元转化最终输出控制指令.

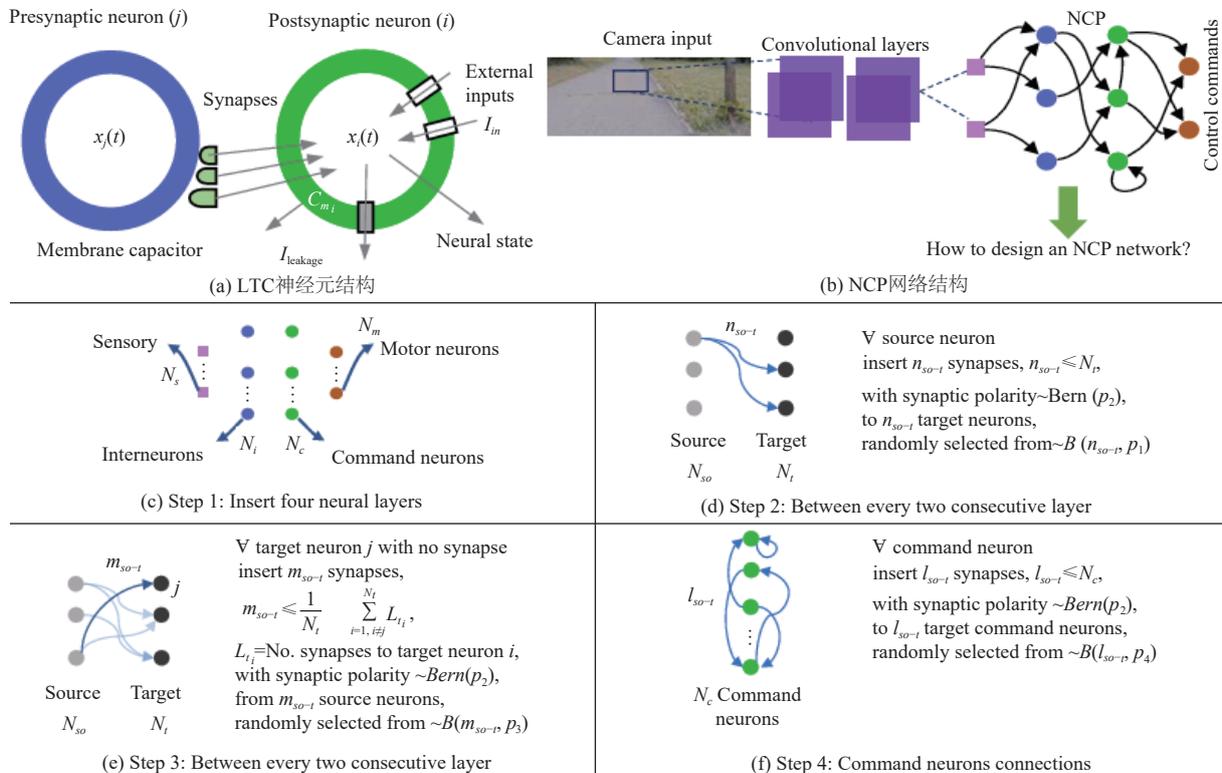


图6 面向自动驾驶的液态神经网络组成图^[30]

NCP 设计原则可生成高度紧凑且极稀疏的液态时间常数神经元 (LTC) 网络. 整个学习系统由卷积层与 NCP 网络堆叠构成, 并通过端到端监督学习进行训练. 针对设计完成的 NCP 网络, 采用半隐式 ODE 求解器以获得系统数值可计算且稳定的表示形式. 随后将 ODE 求解器递归展开为 RNN 单元, 并构建系统的训练流程.

为了形象地表达液态神经网络的有效性和鲁棒性^[40-43], Lechner 等人^[30]模拟了一系列故障场景, 与所有测试学习系统相比, NCP 网络对像素级输入扰动展现出显著更强的鲁棒性^[44], 其在噪声增强时偏离道路导致事故的概率最低. 图 7(a) 显示了在不同输入噪声方差下 4 种 RNN 的事故数统计 (主动驾驶测试, $n=3$), 其中事故定义为导致车辆偏离道路的转向指令; 图 7(b) 显示了显著图结构相似性指数 (SSIM) 变化 (输入噪声方差递增, $n=3$), 结构相似性指数 (SSIM) 可以量化输入扰动对注意力图的影响^[45], SSIM 值越高表明注意力机制越稳定, 从图 7(b) 中可以看出 NCP 在噪声干扰下

仍能保持接近 1 的 SSIM 值, 证明了 NCP 在维护习得因果结构的完整性上显著优于其他网络; 图 7(c) 展示神经元活动最大李普希茨常数分布 (按常数幅值排序, $n=5$), 其值越低表征动力学特性越平滑稳定; 图 7(d) 为 LSTM/CNN 事故案例的显著图对比 (输入扰动下); 图 7(e) 展示了当网络输入受强噪声干扰时, 事故发生在图中标定位置的典型案例.

3.2 闭合形式 LNN 及其在无人机导航中的应用

第 3.1 节中所述的 NCP 网络在自动驾驶中取得了较好的效果, 但是其运行速度很慢. 这主要是由于 LNN 的神经元和突触模型均是非线性方程, 无法快速地进行并行计算, 而需要迭代收敛, 通常需要通过求解器进行处理. 为了解决这个问题, Liquid AI 团队提出了闭合形式液态网络^[46], 并通过专业无人机飞行员收集的数据对闭合形式的液态神经网络进行了训练, 并在户外环境中测试了该算法应用于无人机导航的可行性. 结果显示液态神经网络能够在未探索的空间中做出决策, 甚至在干扰很大的空间环境下也可以使无人机做出正

确的决策^[47,48].

图8展示了其采用的液态神经网络示意图,其中图8(a)展示了全连接LTC层的示意图,单个神经元*i*的动力学由图中公式给出,和第2.2节描述的神经网络模型基本一致.图8(b)展示了闭合形式液态网络及其状态方程的示意图,这种连续时间表示由两个Sigmoid门机制 σ 和 $1-\sigma$ 组成,它们的活动由非线性神

经层*f*调节,这些门控制另外两个非线性层*g*和*h*,以创建系统的状态.图8(c)展示了NCP的示意图,网络架构受到线虫*C. elegans*神经回路的启发,由4个稀疏连接的LTC层构建,称为感觉神经元、中间神经元、命令神经元和机械神经元,这与第3.1节中NCP模型基本一致.图8(d)展示了CFC网络结构,这是一个具有与NCP相同架构特征的稀疏神经回路^[49].

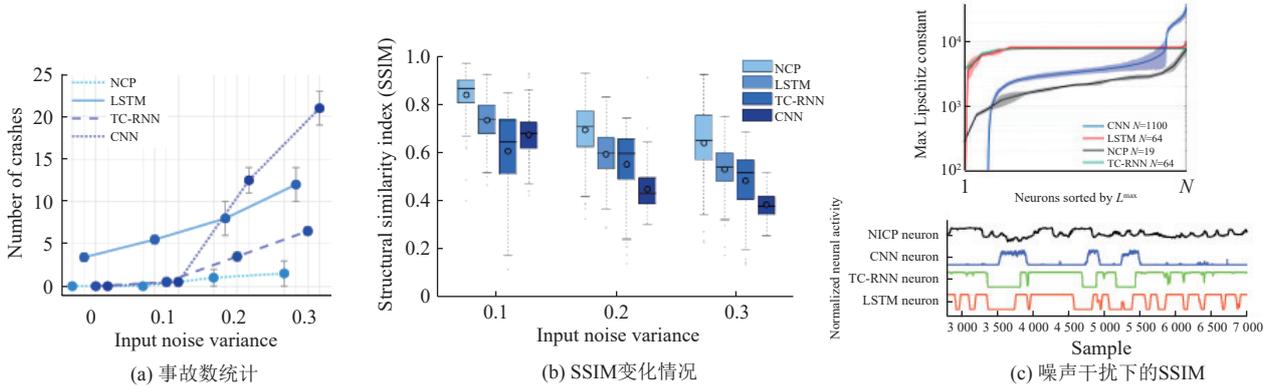


图7 面向自动驾驶的液态神经网络测试结果^[30]

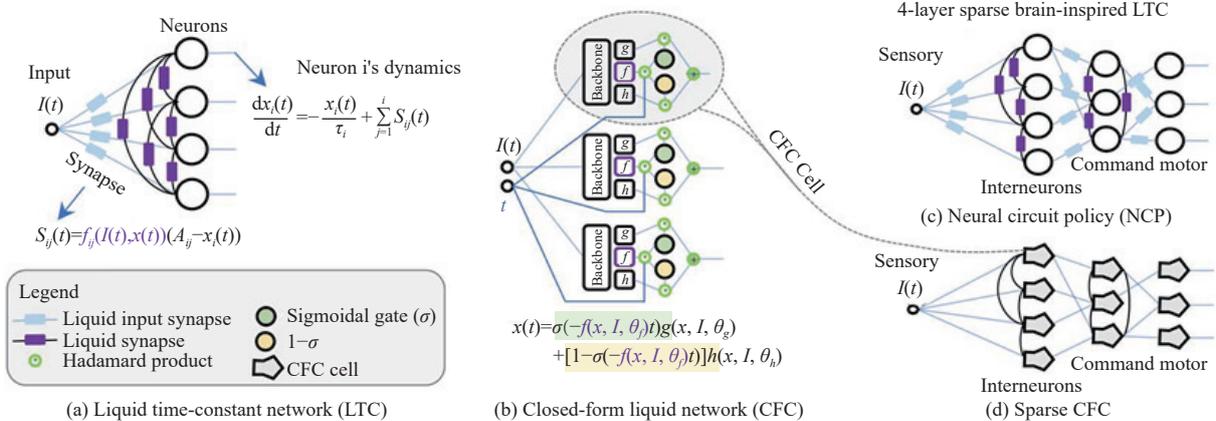


图8 闭合形态液态神经网络原理图^[32]

和第 3.1 节进行的实验类似,同时运行无人机收集的原始图像序列和一个扰动版本通过一个网络,积分输出速度指令,并记录序列之间的最终位移(值越低越好),

图 9 中的条形图显示 10 次运行的标准差. NCP、LSTM 和 CFC 的趋势线分别用棕色、橙色和灰色的阴影线表示 ($n=10$),在这些测试中,CFC 网络均取得了较好的结果.

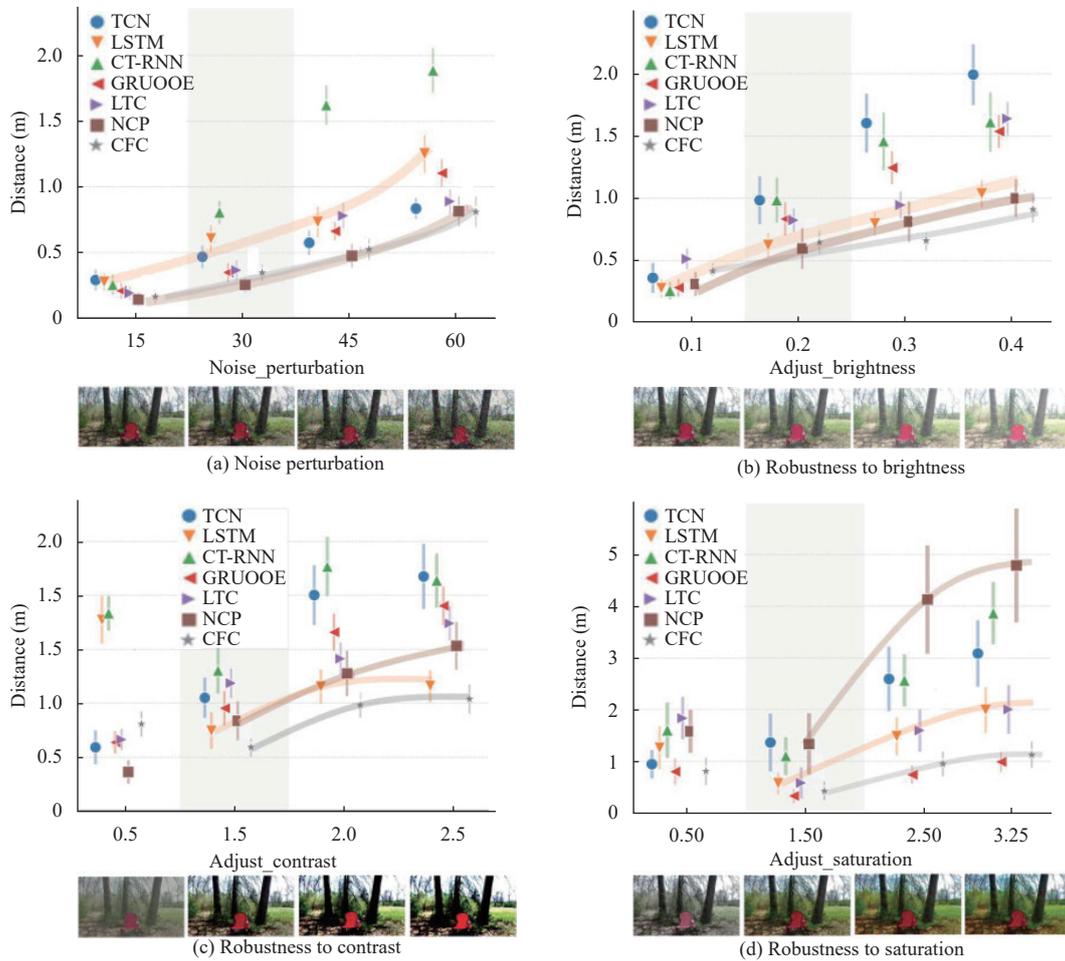


图 9 闭合形态 LNN 在无人导航应用中的测试结果^[32]

3.3 利用神经网络进行股票预测

在全球金融体系中,时间序列数据分析已成为股票市场预测的核心技术支撑.这一领域的研究面临三重显著挑战:高频数据复杂性:现代股票市场以毫秒级甚至微秒级生成海量数据(如逐笔交易、盘口变化),每个数据点的噪声干扰和瞬时性使得传统统计方法难以捕捉有效信号;非平稳性特征:股价波动受宏观经济政策、突发事件等多维度因素影响,呈现显著的非线性、非高斯分布特性;预测时效要求:量化交易场景下,模型需在极短时间窗口内完成从数据输入到决策输出的闭环.传统的股票预测一般都采用 RNN^[50]或者 LSTM^[51]进行拟合和预测,为了更加有效地解决股票预

测问题,Reddy 等人^[39]提出了一种新颖的基于液态神经网络的预测方法.整体结构如图所示,主要由 3 个主要部分组成:输入层、液态层和读出层.

输入层接受外部输入信号 u_t ,例如历史股票价格、交易量和和其他金融指标,这些指标经过标准化和分类后形成特征数据输入液态层中,液态层是由具有递归连接的相互连接的神经元组成的集合.液态层的状态定义为:

$$\tau \dot{X}_i(t) = -X_i(t) + W_{in}u_t + W_{rec}\sigma(x(t)) \quad (18)$$

其中, W_{in} 是输入权重矩阵, W_{rec} 是递归权重矩阵,而 σ 表示非线性激活函数,如 Sigmoid 或 tanh.状态包含液态层对输入信号及其自身过去状态的动态响应.这

个微分方程可以使用欧拉方法离散化进行数值模拟。对于小时间步长,离散时间更新规则为:

$$X_i(t + \Delta t) = -X_i(t) + \frac{\Delta t}{\tau} (-X_i(t) + W_{in}u_t + W_{rec}\sigma(x(t))) \quad (19)$$

读出层将液态层的动态状态映射到所需的输出,计算公式为:

$$y(t) = W_{out}\sigma(x(t)) \quad (20)$$

其中, W_{out} 是读出权重矩阵。更一般地,参数 W_{in} 、 W_{rec} 和 W_{out} 从数据中学习。在训练过程中,模型通过最小化损失函数来学习参数,以使预测值与真实值之间的差异最小化。读出层通常以监督方式训练,以最小化损失函数,例如回归任务中的相似度均方误差 (MSE) 或类别任务中的交叉熵损失。

这种架构非常适合时间序列预测,液态层的动态状态捕捉了输入数据中的复杂时间依赖关系,这对于准确的股市预测至关重要。此外,液态层和读出层的分离简化了训练过程。液态层作为动态特征提取器,而读出层由于是线性的,可以使用标准优化算法高效地训练。图 10 为两阶段的液态神经网络算法,在预测股票未来价格时,输入层接收历史价格和交易量的时间序列,液态层处理这些输入,捕获隐藏的时间模式。然后读出层利用这些模式预测未来的股票价格。

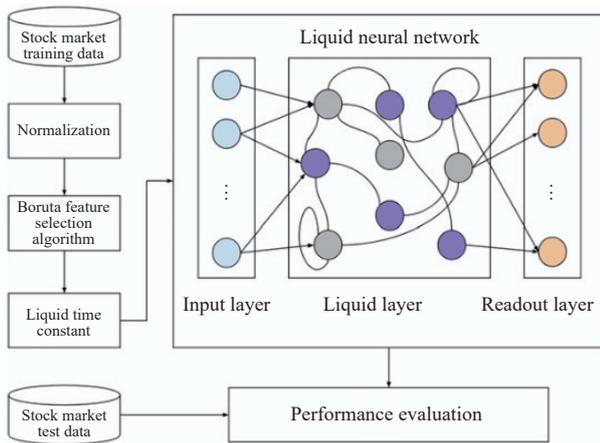


图 10 面向股票预测的液态神经网络^[39]

为了验证液态神经网络的有效性,以 LSTM 和 RNN 为比较对象,以 Alphabet、Apple、Blackrock、JP Morgan 以及 IBM 近 10 年的股票数据为训练集,观察 LNN、RNN 和 LSTM 的表现,发现 LNN 在所有数据集类型中均表现最优,具体数据如表 1 所示。

表 1 3 种方法预测效果对比^[39]

方法	R^2	MSE	MAE
LSTM	0.1947	0.3075	0.3986
RNN	1.301	0.9211	1.127
LNN with feature selection	0.0526	0.1724	0.2292

4 总结和展望

受秀丽隐杆线虫神经系统启发的液态神经网络,通过模拟生物神经元动态连接机制,展现出传统人工神经网络难以企及的环境适应性。其核心优势在于实时拓扑重构能力,可依据输入数据流动态调整网络参数,以及时间连续性建模优势,特别适用于自动驾驶、无人机导航等需要持续环境交互的场景;这些优势使得液态神经网络在电力负荷预测、高频金融数据分析、气象模式识别等时序敏感领域表现突出。虽然液态神经网络存在很多优点,但当前仍存在静态数据处理效率低、长期依赖建模梯度消失、超参数优化复杂度高等技术瓶颈。并且由于现有的高性能计算处理器(如 GPU 等)大多数都是基于数字计算,LNN 在其上的部署效率不高,但是 LNN 在英特尔的神经拟态芯片 Loihi 2 上就展现出较高的效能优势^[52],相信随着神经形态计算硬件的成熟,LNN 有望成为实现通用人工智能的关键技术路径之一。

参考文献

- Hasani RM, Lechner M, Amini A, *et al.* Liquid time-constant recurrent neural networks as universal approximators. arXiv:1811.00321, 2018.
- Hasani RM, Lechner M, Amini A, *et al.* Liquid time-constant networks. Proceedings of the 35th AAAI Conference on Artificial Intelligence. AAAI Press, 2021. 7657–7666.
- Kato S, Kaplan HS, Schrödel T, *et al.* Global brain dynamics embed the motor command sequence of *Caenorhabditis elegans*. Cell, 2015, 163(3): 656–669. [doi: 10.1016/j.cell.2015.09.034]
- Schafer AM, Zimmermann HG. Recurrent neural networks are universal approximators. Proceedings of the 16th International Conference on Artificial Neural Networks. Athens: Springer, 2006. 632–640.
- Pascanu R, Mikolov T, Bengio Y. On the difficulty of training recurrent neural networks. Proceedings of the 2013 International Conference on Machine Learning. Atlanta: JMLR, 2013. 1310–1318.
- Gers FA, Schmidhuber J, Cummins F. Learning to forget:

- Continual prediction with LSTM. *Neural Computation*, 2000, 12(10): 2451–2471. [doi: [10.1162/089976600300015015](https://doi.org/10.1162/089976600300015015)]
- 7 Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, 9(8): 1735–1780. [doi: [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735)]
- 8 Chung J, Gulcehre C, Cho K, Bengio Y. Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv:1412.3555, 2014.
- 9 Hasani RM, Amini A, Lechner M, *et al.* Response characterization for auditing cell dynamics in long short-term memory networks. *Proceedings of the 2019 International Joint Conference on Neural Networks*. Budapest: IEEE, 2019. 1–8.
- 10 Abadi M, Barham P, Chen JM, *et al.* TensorFlow: A system for large-scale machine learning. *Proceedings of the 12th USENIX Conference on Operating Systems Design and Implementation*. Savannah: USENIX Association, 2016. 265–283.
- 11 Chen RTQ, Rubanova Y, Bettencourt J, *et al.* Neural ordinary differential equations. *Proceedings of the 32nd International Conference on Neural Information Processing Systems*. Montréal: Curran Associates Inc., 2018. 6572–6583.
- 12 Mozer MC, Kazakov D, Lindsey RV. Discrete event, continuous time RNNs. arXiv:1710.04110, 2017.
- 13 Rubanova Y, Chen TQ, Duvenaud DK. Latent ordinary differential equations for irregularly-sampled time series. *Proceedings of the 33rd International Conference on Neural Information Processing Systems*. Vancouver: Curran Associates Inc., 2019. 5321–5331.
- 14 Yan HS, Du JW, Tan VYF, *et al.* On robustness of neural ordinary differential equations. *Proceedings of the 8th International Conference on Learning Representations*. Addis Ababa: OpenReview.net, 2019.
- 15 Richards SM, Berkenkamp F, Krause A. The Lyapunov neural network: Adaptive stability certification for safe learning of dynamical systems. arXiv:1808.00924, 2018.
- 16 Hasani RM, Lechner M, Amini A, *et al.* Re-purposing compact neuronal circuit policies to govern reinforcement learning tasks. arXiv:1809.04423, 2018.
- 17 Folgheraiter M, Gini G, Nava A, *et al.* A BioInspired neural controller for a mobile robot. *Proceedings of the 2006 IEEE International Conference on Robotics and Biomimetics*. Kunming: IEEE, 2006. 1646–1651.
- 18 Hung WNN, Song XY, Tan JD, *et al.* Motion planning with satisfiability modulo theories. *Proceedings of the 2014 IEEE International Conference on Robotics and Automation (ICRA)*. Hong Kong: IEEE, 2014. 113–118.
- 19 Zhang HG, Wang ZS, Liu DR. A comprehensive review of stability analysis of continuous-time recurrent neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, 2014, 25(7): 1229–1262. [doi: [10.1109/TNNLS.2014.2317880](https://doi.org/10.1109/TNNLS.2014.2317880)]
- 20 Zhang K, Fan W. Forecasting skewed biased stochastic ozone days: Analyses, solutions and beyond. *Knowledge and Information Systems*, 2008, 14(3): 299–326. [doi: [10.1007/s10115-007-0095-1](https://doi.org/10.1007/s10115-007-0095-1)]
- 21 Zhang M, Geng XY, Bruce J, *et al.* Deep reinforcement learning for tensegrity robot locomotion. *Proceedings of the 2017 IEEE International Conference on Robotics and Automation (ICRA)*. Singapore: IEEE, 2017. 634–641.
- 22 Zhang M, McCarthy Z, Finn C, *et al.* Learning deep neural network policies with continuous memory states. *Proceedings of the 2016 IEEE International Conference on Robotics and Automation (ICRA)*. Stockholm: IEEE, 2016. 520–527.
- 23 Gleeson P, Lung D, Grosu R, *et al.* c302: A multiscale framework for modelling the nervous system of *Caenorhabditis elegans*. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2018, 373(1758): 20170379. [doi: [10.1098/rstb.2017.0379](https://doi.org/10.1098/rstb.2017.0379)]
- 24 Lee C, Park Y, Yoon S, *et al.* Brain-inspired learning rules for spiking neural network-based control: A tutorial. *Biomedical Engineering Letters*, 2025, 15(1): 37–55. [doi: [10.1007/s13534-024-00436-6](https://doi.org/10.1007/s13534-024-00436-6)]
- 25 Quintana FM, Perez-Peña F, Galindo PL. Bio-plausible digital implementation of a reward modulated STDP synapse. *Neural Computing and Applications*, 2022, 34(18): 15649–15660. [doi: [10.1007/s00521-022-07220-6](https://doi.org/10.1007/s00521-022-07220-6)]
- 26 Hasani RM. Interpretable recurrent neural networks in continuous-time control environments [Ph.D. Thesis]. Vienna: Technische Universität Wien, 2020.
- 27 Hasani RM, Haerle D, Grosu R. Efficient modeling of complex analog integrated circuits using neural networks. *Proceedings of the 12th Conference on Ph.D. Research in Microelectronics and Electronics (PRIME)*. Lisbon: IEEE, 2016. 1–4.
- 28 Wang GD, Ledwoch A, Hasani RM, *et al.* A generative neural network model for the quality prediction of work in progress products. *Applied Soft Computing*, 2019, 85: 105683. [doi: [10.1016/j.asoc.2019.105683](https://doi.org/10.1016/j.asoc.2019.105683)]
- 29 DelPreto J, Salazar-Gomez A, Gil S, *et al.* Plug-and-play supervisory control using muscle and brain signals for real-

- time gesture and error detection. *Autonomous Robots*, 2020, 44(7): 1303–1322. [doi: [10.1007/s10514-020-09916-x](https://doi.org/10.1007/s10514-020-09916-x)]
- 30 Lechner M, Hasani RM, Amini A, *et al.* Neural circuit policies enabling auditable autonomy. *Nature Machine Intelligence*, 2020, 2(10): 642–652. [doi: [10.1038/s42256-020-00237-3](https://doi.org/10.1038/s42256-020-00237-3)]
- 31 Wang XQ, Zhu FH, Huang CW, *et al.* Robust beamforming with gradient-based liquid neural network. *IEEE Wireless Communications Letters*, 2024, 13(11): 3020–3024. [doi: [10.1109/LWC.2024.3436576](https://doi.org/10.1109/LWC.2024.3436576)]
- 32 Chahine M, Hasani RM, Kao P, *et al.* Robust flight navigation out of distribution with liquid neural networks. *Science Robotics*, 2023, 8(77): eadc8892. [doi: [10.1126/scirobotics.adc8892](https://doi.org/10.1126/scirobotics.adc8892)]
- 33 Vorbach C, Hasani RM, Amini A, *et al.* Causal navigation by continuous-time neural networks. *Proceedings of the 35th International Conference on Neural Information Processing Systems*. Curran Associates Inc., 2021. 951.
- 34 Zong S, Bierly A, Boker A, *et al.* Accuracy, memory efficiency and generalization: A comparative study on liquid neural networks and recurrent neural networks. arXiv:2510.07578, 2025.
- 35 Amini A, Wang TH, Gilitschenski I, *et al.* VISTA 2.0: An open, data-driven simulator for multimodal sensing and policy learning for autonomous vehicles. *Proceedings of the 2022 International Conference on Robotics and Automation*. Philadelphia: IEEE, 2022. 2419–2426.
- 36 Amini A, Gilitschenski I, Phillips J, *et al.* Learning robust control policies for end-to-end autonomous driving from data-driven simulation. *IEEE Robotics and Automation Letters*, 2020, 5(2): 1143–1150. [doi: [10.1109/LRA.2020.2966414](https://doi.org/10.1109/LRA.2020.2966414)]
- 37 Le AT, Shakiba M, Ardekani I, *et al.* Optimizing plant disease classification with hybrid convolutional neural network—Recurrent neural network and liquid time-constant network. *Applied Sciences*, 2024, 14(19): 9118. [doi: [10.3390/app14199118](https://doi.org/10.3390/app14199118)]
- 38 Shaheema SB, K SD, Muppalaneni NB. An explainable Liquid Neural Network combined with path aggregation residual network for an accurate brain tumor diagnosis. *Computers and Electrical Engineering*, 2025, 122: 109999. [doi: [10.1016/j.compeleceng.2024.109999](https://doi.org/10.1016/j.compeleceng.2024.109999)]
- 39 Reddy GJ, Sahani RK, Raja SP. Stock market prediction using a hybrid approach with Boruta and liquid neural network. *IEEE Transactions on Computational Social Systems*, 2025, 12(5): 2833–2847. [doi: [10.1109/TCSS.2025.3540035](https://doi.org/10.1109/TCSS.2025.3540035)]
- 40 Zeiler MD, Fergus R. Visualizing and understanding convolutional networks. *Proceedings of the 13th European Conference on Computer Vision*. Zurich: Springer, 2014. 818–833.
- 41 Yosinski J, Clune J, Nguyen A, *et al.* Understanding neural networks through deep visualization. arXiv:1506.06579, 2015.
- 42 Karpathy A, Johnson J, Li FF. Visualizing and understanding recurrent networks. arXiv:1506.02078, 2015.
- 43 Strobel H, Gehrmann S, Pfister H, *et al.* LSTMVis: A tool for visual analysis of hidden state dynamics in recurrent neural networks. *IEEE Transactions on Visualization and Computer Graphics*, 2018, 24(1): 667–676. [doi: [10.1109/TVCG.2017.2744158](https://doi.org/10.1109/TVCG.2017.2744158)]
- 44 Bilal A, Jourabloo A, Ye M, *et al.* Do convolutional neural networks learn class hierarchy? *IEEE Transactions on Visualization and Computer Graphics*, 2018, 24(1): 152–162.
- 45 Wang Z, Bovik AC, Sheikh HR, *et al.* Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 2004, 13(4): 600–612. [doi: [10.1109/TIP.2003.819861](https://doi.org/10.1109/TIP.2003.819861)]
- 46 Hasani RM, Lechner M, Amini A, *et al.* Closed-form continuous-time neural networks. *Nature Machine Intelligence*, 2022, 4(11): 992–1003. [doi: [10.1038/s42256-022-00556-7](https://doi.org/10.1038/s42256-022-00556-7)]
- 47 Grunbacher S, Hasani RM, Lechner M, *et al.* On the verification of neural odes with stochastic guarantees. *Proceedings of the 35th AAAI Conference on Artificial Intelligence*. AAAI, 2021. 11525–11535.
- 48 Lechner M, Hasani RM, Grosu R, *et al.* Adversarial training is not ready for robot learning. *Proceedings of the 2021 IEEE International Conference on Robotics and Automation*. Xi'an: IEEE, 2021. 4140–4147.
- 49 Brunnbauer A, Berducci L, Brandstätter A, *et al.* Model-based versus model-free deep reinforcement learning for autonomous racing cars. arXiv:2103.04909, 2021.
- 50 Pramod BS, Mallikarjuna SPM. Stock price prediction using LSTM. *Test Engineering and Management*, 2021, 83: 5246–5251.
- 51 Wu ST, Liu YL, Zou ZR, *et al.* S_I_LSTM: Stock price prediction based on multiple data sources and sentiment analysis. *Connection Science*, 2022, 34(1): 44–62. [doi: [10.1080/09540091.2021.1940101](https://doi.org/10.1080/09540091.2021.1940101)]
- 52 Pawlak WA, Isik M, Le D, *et al.* Exploring liquid neural networks on Loihi-2. arXiv:2407.20590, 2024.

(校对责编: 张重毅)