

一种基于人工神经网络的连续吸引子神经动力学表征学习方法

莫凌飞, 葛张宇

(东南大学仪器科学与工程学院, 南京 210096)

摘要: 连续吸引子网络 (Continuous Attractor Networks, CAN) 是为数不多的、经过神经科学检验的神经动力学计算模型, 其计算方法创新与工程应用转化是类脑计算领域的重要研究方向。然而, 传统 CAN 依赖于微分方程建模, 其神经动力学迭代更新过程与解码过程效率较低, 制约了其在工程应用转化过程中的实用性。针对这一问题, 本文提出了一种基于人工神经网络 (Artificial Attractor Networks, ANN) 的 CAN 神经动力学表征学习方法。为验证该方法的有效性, 本文设计了两个应用案例, 通过拟合 CAN 的动力学特性, 分别重建了两类常见的空间细胞编码功能。根据实验结果, 本工作不仅能够精确复现 CAN 建模的空间细胞的神经动力学模式, 并且拥有着极高的运行效率。在建模两种空间细胞的总运行时间上, 对比原生模型, 重构后的算法在通用设备上实现了约 94.5% 的效率提升, 在边缘设备上则达到了 69.2% 的效率提升。

关键词: 人工神经网络; 连续吸引子网络; 神经动力学; 边缘计算

中图分类号: Q811.2; TP18

A Representation Learning Method for Continuous Attractor Network Neurodynamics Based on Artificial Neural Networks

Lingfei Mo, Zhangyu Ge

(School of Instrument Science and Engineering, Southeast University, Nanjing 210096)

Abstract: Continuous Attractor Networks (CAN) are among the few neurodynamic models validated by neuroscience, making their methodological innovation and engineering application a significant research direction in brain-inspired computing. However, conventional CAN relies on differential equation modeling, where the iterative neurodynamics update and decoding processes suffer from low efficiency, constraining their practical utility in engineering applications. To address this, this paper proposes a representation learning method based on Artificial Neural Networks (ANN) to replicate CAN's neurodynamics. To validate its effectiveness, this paper designed two application cases, reconstructing two common types of spatial cell encoding functions by fitting the neurodynamics of CANs. Experimental results demonstrate that this work not only accurately reproduces the neurodynamics of CAN-modeled spatial cells, but also

achieves substantially higher operational efficiency. In terms of total runtime for modeling both spatial cell types, the reconstructed algorithm achieves approximately 94.5% efficiency improvement on general-purpose devices and 69.2% on edge devices compared to the native model.

Key words: Artificial Neural Network; Continuous Attractor Network; Neurodynamics; Edge Computing

长期以来，大脑的连接组学结构和神经功能常被借鉴以开发智能算法和设计计算模型，这一思路最终成为人工智能（Artificial Intelligence, AI）领域的核心方法论^[1]。连续吸引子神经网络早在四十年前便形成了成熟的理论框架，作为少数经过神经科学实验验证的神经动力学计算模型，常被作为大脑中具备独特发放模式的空间细胞的解释模型^[2]。连续吸引子网络（Continuous Attractor Networks, CAN）的数学基础由吴思等^[3]在早期的研究中确立，并被证明在处理外界噪声时具备良好的鲁棒性，故而被转化应用于目标追踪、定位建图等工程领域并取得了一定的成功。然而，关于 CAN 的工程实践均使用微分方程进行描述并在近二十年来基本未发生改变，由此产生了一定的局限性。

独特的编解码能力和良好的神经动力学模式，使得 CAN 在工程领域中得以应用转化。如，2004 年，Milford 等所开发的初代 RatSLAM 系统成功的将 CAN 应用于 SLAM 系统^[4]。后续衍生出的大量脑启发 SLAM 系统也延续了初代 RatSLAM 的思路^{[5]-[7]}，利用 CAN 建模构建其核心的功能模块。然而，由于传统 CAN 使用微分方程作为建模方法，并且在工程实践中依旧保留了局部兴奋、全局抑制、状态更新、遍历解码等高冗余的神经动力学过程，CAN 的计算复杂度与建模维度呈现的正相关性最终成为了高精度算法下的严重掣肘。由于基于 CAN 的工程应用往往集中在导航定位、目标追踪等具备高计算维度和高精度需求的领域，这种掣肘以及长期实践过程中所形成的路径依赖导致 CAN 在实际部署中面临着显著瓶颈：神经动力学的迭代更新过程计算开销大、动力学状态更新效率不足，并且难以适配通用计算平台的边缘部署需求。因此，CAN 在工程应用转化过程中的实用性正面临着一些限制。

上述观察构成了本研究的核心动机。因此，本文提出一种基于轻量化人工神经网络（Artificial Neural Network, ANN）的 CAN 神经动力学复刻方法，通过数据驱动的特征学习方式完整拟合原生 CAN 的动力学特性，实现从连续微分方程迭代向高效前向推理计算的范式转换。该方法在兼顾 CAN 模型生物学合理性和计算功能的前提下，充分发挥轻量化神经网络相较于微分模型在边缘侧计算时具备的效率优势，能够有效规避 CAN 因大量微分方程

迭代和遍历式解码过程所带来的计算瓶颈。本文将该方法简称为“CAN2ANN”以方便表述，其整体框架如图 1 所示。

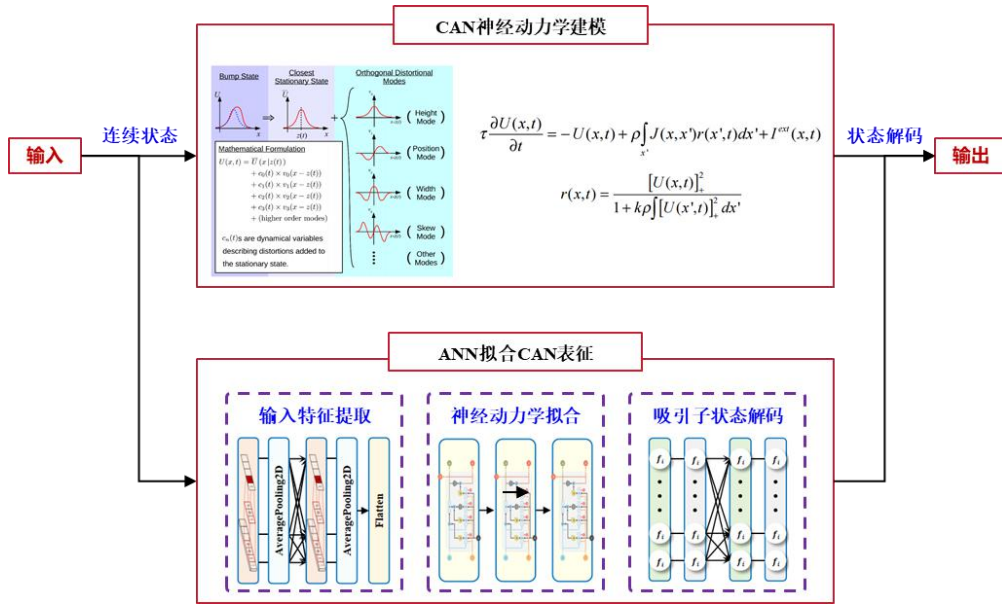


图 1 本文所提出的 CAN2ANN 方法示意图

Fig. 1 Schematic of the proposed CAN2ANN method in this paper

本文使用随机过程合成输入序列，并结合吴思模型和 BrainPy 框架^[9]进行动力学计算的同时记录迭代过程中的中间量，以获取拟合 ANN 模型的数据样本。原始 CAN 的连续输入序列经过预编码后将作为 ANN 模型的输入特征，并使用 CAN 的动态解码值构成标签，通过有监督的表征学习方法达成轻量化 AI 模型关于 CAN 编解码功能的端到端拟合。同时 ANN 的构建思路在针对不同维度的 CAN 也有所调整，以应对高维 CAN 的计算复杂度问题。

为验证 CAN2ANN 方法的有效性与实用价值，本文选择 CAN 在工程领域中的一个常见应用进行验证，即建模关键的空间细胞功能。具体而言，基于 CAN2ANN 分别构建了二维头朝向细胞（Head Direction Cell, HDC）与三维网格细胞（Grid Cell, GC），并与体心堆叠式原生 CAN 模型的实现进行了功能对照。结果表明，CAN2ANN 在精度层面几乎完美复现了原生 CAN 的神经动力学特性，可有效替代原生 CAN 建模的 HDC 与 GC 模型。值得一提的是，该方法面向利用轻量化 ANN 拟合 CAN 的通用思路，旨在工程应用中实现 CAN 的功能平替，并且在边缘计算的效率方面具有优势，充分证明了其在通用计算平台部署中的实践价值。为了验证 CAN2ANN 方法的有效性与实用价值，本文针对性选择 CAN 在工程领域中的常见应用，即建模大脑位置细胞、网格细胞和头朝向细胞等空间细胞^[10-12]。其中，三维 GC 和多层 HDC 功能建模涵盖工程领域常见的 CAN 计算维度（一维到三维），因此被本文选择用于测试 CAN2ANN 方法的有效性。

具体而言，基于 CAN2ANN 分别构建了 HDC 与 GC，并与原生 CAN 模型的实现进行了功能对照。其中 HDC 通过解耦思路由一个一维 CAN2ANN 分别维护两个中间状态实现，GC 则由三维 CAN2ANN 实现。结果表明，CAN2ANN 在精度层面上几乎完美复现了原生 CAN 的神经动力学特性，可以有效替代通过以原生 CAN 建模的 HDC 和 GC 模型。值得一提的是，该方法面向利用轻量化 ANN 拟合 CAN 的通用思路，核心是为了在工程实践中实现 CAN 的功能平替并且保留了一定的可扩展性，轻量化的设计也使得模型优势在边缘端设备上得到进一步放大。

1 CAN2ANN 算法设计

CAN2ANN 方法的路线是利用高效的前向推理替代复杂的微分计算，即通过端到端的 ANN 直接拟合 CAN 的编解码特性，最终形成计算范式的区分。该方法的成功实践建立在明确的拟合对象以及良好的输入-输出特性以保证 ANN 的最终性能，基于这一考虑，本文选择了吴思等^[3]提出的经典 CAN 模型作为拟合对象。该模型核心为局部兴奋-全局抑制的连接机制，数学形式简洁保证了制作数据集的效率，明确的神经动力学特性便于对照分析，抗噪性能优良确立工程实践的可行性，因此成为了本文 CAN2ANN 方法的理想基准。

1.1 吴思 CAN 模型概述

吴思等提出的经典 CAN 模型使用微分方程描述神经元群体的动力学演化，主要过程包含内部权重初始化，输入编码，神经元状态更新，以及归一化输出四个环节。该模型具备以下优势：其一，利用高斯函数和空间距离创建初始权重，保证网络能够形成稳定的激活波包且具有平移不变性；其二，使用除法归一化机制替代显示抑制连接，避免神经元发放的指数级增长的同时减少计算压力；其三，针对输入噪声具备内在的鲁棒性，成为工程实践的理想模型。以上特性使其成为类脑导航领域广泛采用的建模基础，也为 ANN 拟合提供了清晰的输入-输出映射关系。

1.2 输入序列生成与数据准备

如图 1 所示，为拟合 CAN 的神经动力学表征特性，需首先构建多样化的输入序列以覆盖 CAN 的神经动力学响应空间。本文采用随机过程生成关于待编码状态（如角度或空间坐标）的时序序列，随机对象包括序列长度、状态变化模式、各模式持续时间占比及静止状态的常数值。训练集与验证集按 4:1 划分，序列长度固定为 500 帧；测试集序列长度为训练集的 7-10 倍（不低于 3750 帧），以验证模型的长期稳定性。输入数值在 $[-\pi, \pi]$ 范围内线性变化或保持恒定，确保网络学习不同变化速度下的波包活动模式。

在输入 CAN 前，采用独热编码加线性插值的方式将标量输入转换为向量形式，使网络

预先捕捉输入空间中的邻近关系。具体而言，对于 N 个神经元的一维 CAN，构建 N 维向量 r ，其第 i 个元素 r_i 对应第 i 个神经元的偏好位置。任意输入 x 经映射后表示为相邻偏好位置的加权组合，从而降低后续拟合难度。

1.3 CAN 模型构建与解码标签

为获取 ANN 训练的监督信号，需按以下步骤构建待拟合的 CAN 模型并实现解码。以一维 CAN 为例，其建模过程描述如下：

$$I_{ext}^i = a_{ext} \exp[-b_{ext} \|p_{ext} - p_i\|^2] \quad (1)$$

其中， I_{ext}^i 表示外部输入对第 i 个神经元的刺激， a_{ext} 和 b_{ext} 都是大于 0 的常数， p_{ext} 和 p_i 分别为外部输入和第 i 个神经元的偏好，神经元的偏好都取自信息状态集合。而神经元状态更新方程和内部权重的连接，则根据吴思的模型可以描述为：

$$\tau \frac{dU^i(t)}{dt} = -U^i(t) + \rho \sum_j J_{ij} r^j(t) + I_{ext}^i(t) \quad (2)$$

其中， τ 代表突触时间常数， ρ 表示神经元密度， J_{ij} 指代第 i 个神经元和第 j 个神经元之间的连接权重， $r^j(t)$ 表示神经元的发放频率，通过公式(2)可以计算出任意神经元的突触输入 $U(t)$ 。

$$J_{ij} = \frac{J_0}{\sqrt{2\pi a}} \exp\left[-\frac{\|p_i - p_j\|^2}{2a^2}\right] \quad (3)$$

神经元之间的连接权重则通过公式(3)中的高斯函数进行初始化，利用参数 a 控制神经元的连接范围。连接权重只与两个神经元偏好的状态距离有关，因此当神经元偏好线性分布时 CAN 将保持平移不变性。

$$r^i(t) = \frac{r_0^i(t)}{1 + k \rho \sum_j r^j(t)} \quad (4)$$

其中 $0 < k < k_c = \rho J_0^2 / (8\sqrt{2\pi a})$, $[U]_+ = \max(U, 0)$ 。吴思的模型并不存在神经元之间的显示抑制关系,而是通过公式(4)的除法归一化限制神经元发放频率的强度,进而避免神经元的突触输入 $U(t)$ 呈现爆炸性增长的趋势。通过公式(2-4)就实现了 CAN 接受外部输入到波包状态更新的所有过程。在实际类脑导航应用中，不同模块之间的信息传递无法通过抽象化的神经元状态信息进行直接传递，而是依赖于属数学计算的范式。因此，需要对 CAN 的波包状态进行解码以获取具象化的信息。对于一维的 CAN 波包，其解码公式被写成下式：

$$\theta(t) = \arctan 2 \frac{U^i(t) \sin(th \frac{p_i}{2})}{U^i(t) \cos(th \frac{p_i}{2})} \quad (5)$$

$$y(t) = (\theta(t)/th) \bmod(Z) \quad (6)$$

其中, $th = 2\pi/N$, Z 是 CAN 中神经元的个数, y 代表当前波包的解码结果。

CAN2ANN 采用监督学习方式训练,其输入数据为头朝向细胞活动模式的生成序列信息,输出为头朝向细胞模型的状态解码值。在输入序列输入到网络前,会使用独热编码加插值的方式来获取网络的输入向量,该操作可以让网络预先捕捉不同输入之间的空间邻近关系,降低网络的拟合难度。在此案例中,本文定义一个 37 维的向量 $x \in \{0,1\}^{37}$ 用来对应 ANN 网络的实际输入,并规定 HDC 偏好对应的向量为:

$$V_i = OHE(i) \quad (7)$$

其中, i 对应神经元的索引,基于该操作我们可以通过插值的方式将任意输入进行线性映射后转变为一个向量,如公式(2)所示:

$$V_{I_{ext}} = (1 - C_{frac}) OHE(C) + C_{frac} OHE(C + 1) \quad (8)$$

其中 $C = I_{ext} / 2\pi * N_p$, C_{frac} 指的是 C 的小数部分, N_p 表示一维 CAN 神经元之间的间隔数,外部输入会预先取模到 $[0, 2\pi)$ 之间。在 CAN 解码过程中,需要对神经元状态进行加权计算并使用反正切以获得最终的解码值,可见公式(5)和公式(6)。出于浅层时间分布层难以直接拟合反正切函数的考量,CAN2ANN 将加权计算的求和值作为 ANN 的最终输出并进行相关的标签设计。

1.4 CAN2ANN 拟合模型结构设计

如图 2 所示, CAN2ANN 模型采用编码器-动力学拟合器-解码器的三级架构:




图 2 CAN2ANN 框架设计

Fig. 2 Design of the CAN2ANN framework.

模型架构设计遵循原生 CAN 模型的动力学过程选择对应的网络模型,故而划分为特征

提取层、LSTM 动力学拟合层和时间步解码层。首先是特征提取层，这一层对应于 CAN 模型中的高斯编码步骤，由于高斯编码并未引入时间要素，因此选择构建通过 ReLU 激活函数引入非线性的全连接层，该层的主要作用是将输入序列提取为高维抽象表征。特征提取层的神经元数目可以灵活变化，这取决于所平替的 CAN 的分辨率，基于吴思模型构建的 CAN 其首尾神经元完全等价而部分 CAN 模型中则不包含这一特点，导致相同分辨率的情况下二维 CAN2ANN 特征提取层的输入维度可能会比部分 CAN 模型的神经元个数多 1。

三维 CAN2ANN 特征提取层的输入维度为同分辨率下一维 CAN2ANN 的三倍。紧接特征提取层的是 LSTM 动力学拟合层，该层对应于 CAN 模型中的神经元动力学演化过程，替代原模型的状态迭代过程，利用多层 LSTM 拟合 CAN 的时序变化，其神经元个数设置原则同特征提取层。最后是时间步解码层，其对应于 CAN 模型的解码步，由于解码过程同样未引入时序信息，因此只需要两个时间分布全连接层即可，将 LSTM 隐藏状态映射解码中间量，即反正切运算前的分子分母，最终通过反正切运算完成整个编解码流程。时间步解码层的隐藏层神经元个数设置上没有限制，但输出层神经元数目需为原生 CAN 维度的两倍。CAN2ANN 的具体实践案例需见下一章关于 HDC 和 GC 的编码-解码特性建模。

2 案例与分析

本工作的核心是利用 ANN 拟合 CAN 的神经动力学过程，而该过程理应以什么模式进行并无限制，抗噪性和鲁棒性在不同模型不同参数下都有所变化，并不存在一个绝对完美的能够应用于各种实践工程场景的模型，因此本工作拟合的 CAN 模型参数有所调整以使其更契合于工程领域应用。在早期的研究中，CAN 就被多次运用于空间细胞神经编解码功能的建模，也是 CAN 的主要功能之一^[13-14]。鉴于以上原因，本文选择围绕空间细胞的编解码能力设置两个案例对 CAN2ANN 进行功能验证和评估分析。

2.1 案例一：基于 CAN2ANN 实现多层 HDC 编码-解码功能

本文中 ANN 重构的 HDC 的网络设计遵循轻量化原则并延续吴思模型的结构，包括一个输入层、两个 ReLU 激活的全连接层、两个 LSTM 层和两个用于时间步状态解码的时间分布层，如图 2 所示。两个全连接层用于提取输入序列的抽象表征。在以往研究中，多层 HDC 的实现是通过堆叠多层一维 CAN 构建而成二维 CAN。由于高度和角度信息实际上并无关联，可以考虑解耦，因此本文在利用 CAN2ANN 构建 HDC 的过程中并没有选择使用 ANN 去拟合二维 CAN，而是直接通过一维的 ANN2CAN 去分别维护不同信息的神经元状态。在本案例中，编码分辨率被统一为 10° ，故 CAN2ANN 的输入层及部分隐藏层神经元

个数被设置为 37，时间解码层中隐藏层神经元个数被设置为 12。训练细节描述如下，训练过程中，本文采用了 Adam 优化器和均方根误差（Mean Square Error, MSE）损失函数，共训练了 200 epoch，每轮输入 12 条序列信息。

本文采用合成数据本质上是为了通过随机过程是样本尽可能的多样化，以保证最终拟合成功的 ANN 可以复刻 CAN 的动力学特性。考虑到瞬时加速度可能带来的影响，因此也在数据集中引入了一些突变情况，但并不作为主要部分，这是为了更好的去模拟 CAN2ANN 在工程实践中应用时可能面临的潜在问题。图 1 对比了 ANN 拟合的一维 CAN 和原始模型在合成数据集上的表现。

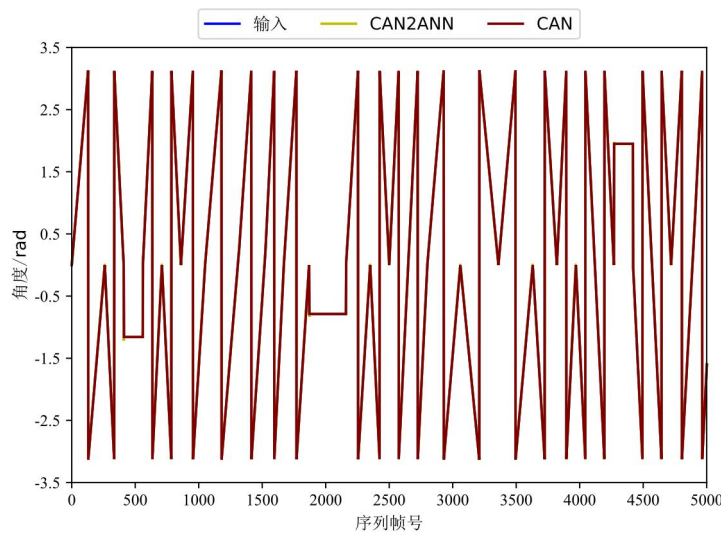


图 3 输入与两种模型解码值对比

Fig. 3 Comparison between inputs and decoded values from two models

根据图 1 可以看到，输入具备一定的动态性和非线性，存在多次突变和停顿，并且变化的速率在不同时刻也不完全一致。就图 1 的解码效果来看，在 4000 帧以上的长期运行中，ANN 拟合的解码效果并没有因为几次突变与 CANN 的解码效果产生较大出入。因此可以认为 ANN 拟合的 CANN 对于瞬时变化具备足够的抗性并且能够较为精准的跟随输入变化。此外，本文使用了均方误差评估重构前后的模型解码值与输入之间的差异性，并使用不包含训练集以及验证的多条序列作为样本以避免离群值的影响。重构前的均方误差在 10^{-8} 量级，重构后的均方误差在 10^{-5} 量级，虽然误差有一定增加，但是该量级的误差在实践中并不会产生影响。

2.2 案例二：基于 CAN2ANN 实现三维 GC 编码-解码功能

同样的，为实现三维 GC 的功能模拟，验证 CAN2ANN 方法可以实现 CAN 的效果平替。

本文需将此前以一维 CAN2ANN 为例的通用描述方法应用至三维空间。由于数学模型下的三维 GC 通过构建三维 CAN 实现对三维坐标的表达，空间细胞状态更新过程中所产生的波包也过渡到了空间中的球形结构，对该球形波包解码就可获得三维 GC 所表达的空间坐标信息，实现对三维坐标编解码。三维 CAN 的数学模型可直接在一维模型上进行拓展，但是对于 K 维且单维度 N 个神经元的 CAN，根据其数学模型构建的时间复杂度和空间复杂度均为 $O(N^K)$ ，这使得构建和拟合三维 CAN 的动力学过程的复杂度明显高于一维 CAN。以下是实现三维 CAN2ANN 的必要改造说明：

三维 CAN 的建模过程与一维 CAN 相近，区别在于神经元的偏好从高度和角度这样的一维数据转变为了坐标相关的三维向量，神经元活动主要过程如公式(9)和(10)所示：

$$\tau \frac{\partial U^i(t)}{\partial t} = -U^i(t) + \rho \sum_{x,y,z} J_{x,y,z}^i r^{x,y,z}(t) + I_{ext}^i(t) \quad (9)$$

$$J_{x,y,z}^i = \frac{J_0}{\sqrt{2\pi a}} \exp\left[-\frac{\|p_{x_i,y_i,z_i} - p_{x,y,z}\|^2}{2a^2}\right] \quad (10)$$

其中 $J_{x,y,z}^i$ 表示神经元 i 与空间坐标 (x,y,z) 处神经元之间的连接权重， (x_i,y_i,z_i) 表示神经元 i 的空间坐标， $p_{x,y,z}$ 为空间坐标 (x,y,z) 处神经元的偏好。输入编码与归一化过程则与公式(1)以及公式(4)保持一致。在对三维 GC 的波包解码时需要预先对空间细胞活动数组按照维度求和，以分别获得在 X, Y 和 Z 维度上的一维神经元信息表征，如公式(11)所示：

$$\begin{aligned} SX(x) &= \sum_z U^{x,y,z} \\ SY(y) &= \sum_x \sum_z U^{x,y,z} \\ SZ(z) &= \sum_x \sum_y U^{x,y,z} \end{aligned} \quad (11)$$

SX, SY, SZ 分别表示降维至 x, y, z 三个维度上的 1 维向量，之后计算各自维度的解码值，以获得空间信息。此处 SX, SY, SZ 拼接后的结果就是三维 ANN2CAN 的 LSTM 层的拟合目标。在完成 CAN2ANN 的三维空间升维适配后，后续基于 CAN2ANN 方法的三维 GC 功能建模则与多层 HDC 的功能建模类似。

实现该案例的 CAN2ANN 架构与案例一所使用的架构相同，包括一个 Input 层、两个 ReLU 激活的全连接层、两个 LSTM 层和两个用于时间步状态解码的时间分布层。由于前文所提到的复杂度问题，对于多维 CAN 网络我们并不直接拟合其神经元的活动状态，而是拟合解码过程中降维拼接后的向量，降维方式将在后续介绍。这种策略使得时间复杂度和空间复杂度均变为 $O(NK)$ ，也是重构后算法运行速率提升的关键所在，并可以通过逆变换近似

获取降维前的波包状态。为了保证 GC 的分辨率与 HDC 一致以观察同分辨率下高维 CAN2ANN 与一维 CAN2ANN 的表现差异，GC 的特征输入层和 LSTM 层的神经元个数都为 111，用于近似拟合 GC 的动力学过程。两个时间分布层分别具有 37 个神经元和 6 个神经元，每两个输出神经元对应 1 个维度。

监督训练所使用的数据同样通过随机过程生成，随机过程与拟合 HDC 时生成输入数据的随机过程完全一致，在制作数据集时会预先生成三条 1D 的随机序列再进行拼接以模拟坐标的变化，输入数值的范围依旧在 $[-\pi, \pi]$ 之间，对于不同尺度的网格细胞都可以通过线性映射的方式将数值限制在这个范围内。为了契合 CAN2ANN 的升维策略，输入预处理时会将三维坐标分维度根据公式(8)计算各自的输入向量再进行拼接，如公式(12)所示。

$$V_l^T = \begin{bmatrix} V_{x_l}^T \\ V_{y_l}^T \\ V_{z_l}^T \end{bmatrix} \quad (12)$$

训练细节描述如下，在三维 CAN2ANN 训练过程中，本文采用了 Adam 优化器和 MSE 损失函数，共训练了 200 epoch，每轮输入 12 条序列信息。

图 2 对比了 ANN 拟合的三维 CANN 和原始模型在合成数据集上的表现。由于不同维度的编解码在 ANN 中进行了解耦，因此三个维度的解码表现不会出现较大差异，这里只展示 X 维度的解码值对比结果，以避免重复论证。

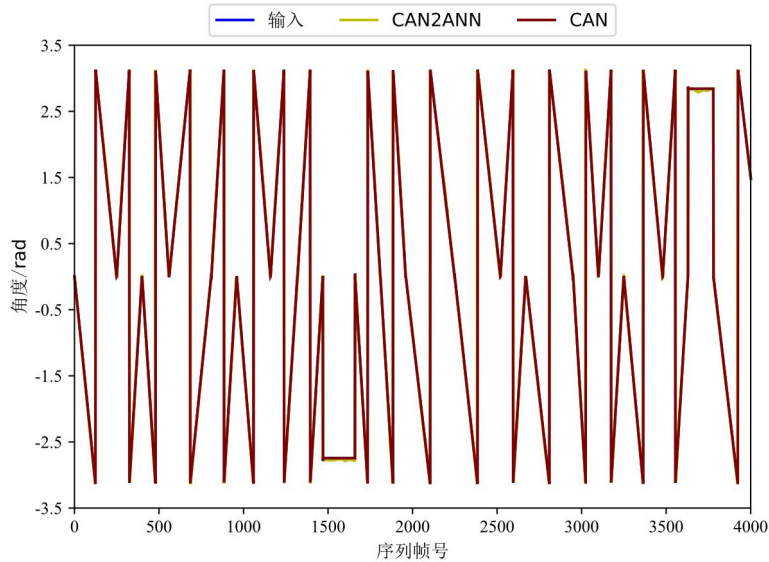


图 4 X 维度上输入与两种模型解码值对比

Fig. 4 X-dimensional comparison between inputs and decoded values from two models

从图 2 解码对比的效果可以看出，ANN 重构的三维 CAN 模型基本保证了解码值与输入基本一致。使用多条测试序列的均方误差计算偏差情况，重构前的误差量级在 10^{-9} 等级，重构后的误差量级在 10^{-4} 等级，可以认为 ANN 重构的三维 CAN 基本继承了原始模型的功能。

虽然使用升维策略导致三维 CAN2ANN 的误差量级相较于一维 CAN2ANN 有所上升，但尚在接受范围之内。

2.3 综合讨论与结果分析

为了进一步论证 ANN 重构模型的有效性并展现计算复杂度降低对算法耗时的影响。本文将 CAN2ANN 模型封装为 HDC 和 GC，直接与工程实践中常用的 CAN 离散模型进行对比，关于该离散模型的详细信息可见[6]此外，为了确认 CAN2ANN 和离散模型在不同算力设备上的表现，分别使用了工作站和边缘设备作为硬件基础。该工作站包含一块 NVIDIA RTX4060 GPU (8GB RAM)以及一块 Intel core i7-12650H 的 CPU (2.7GHz)，边缘端设备为树莓派 4B 且系统环境为 Raspbian GNU/Linux。

表 1 相同序列长度下空间细胞使用不同建模方法在不同设备上的耗时表现

Table 1 Execution time performance of spatial cells using different modeling methods across various devices with identical sequence lengths.

序列长度	模拟案例	建模方法	工作站运行耗时	树莓派运行耗时
1000 帧	HDC	CAN	1.82s	24.53s
		CAN2ANN	1.12s	87.71s
	GC	CAN	36.43s	476.83s
		CAN2ANN	0.97s	66.46s

表 1 统计了固定序列长度下使用 CAN 和 CAN2ANN 建模空间细胞的运行耗时。需要注意的是，由于 HDC 需要同时编码高度和角度，因此使用 CAN2ANN 方法建模 HDC 的 ANN 等效跑了两千帧，这也可以解释为什么使用 CAN2ANN 建模 GC 的运行耗时会比 HDC 更短，此外所有的 ANN 都未使用 GPU 加速运行。由于 HDC 本身的算力需求较小且未经过加速，在工作站这种算力支撑和内存都十分充足的设备上，拟合前后的运行耗时表现较为接近，CAN2ANN 方法的运行耗时相较于 CAN 方法提升了约 38%左右。相对的，当使用 CAN 方法建模 GC 时，由于算力和内存都有了较高的要求，此时运行耗时来到了 36.43s。而使用 CAN2ANN 方法建模的 GC 相较于 HDC 不增反降，运行耗时为 0.975s，拟合前后的运行耗时等效提升了约 97.3%。不过在树莓派上的表现略有不同，使用 CAN 建模的 HDC 相较于 CAN2ANN 方法建模的 HDC 会更快，这是由于 CAN 方法经过合理优化后在建模 HDC 时所需的空间更小，可以依赖树莓派的极速缓存加速计算。

不过，使用 CAN2ANN 方法由于权重和隐藏状态的存在，导致无法完全依靠树莓派的极速缓存进行存储并运算，在数据传输过程中添加了额外的耗时开销，致使 CAN2ANN 建模的 HDC 表现较差。这一点可以在未来借助计算量化和微机器学习 (Tiny Machine Learning, TinyML) 直接转换为二进制矩阵计算，降低内存基础开销来避免这一问题。当树莓派的缓存不足以支撑 CAN 建模 GC 的计算压力时，这就导致 GC 的运行时间猛涨至 476.83s。而树莓派上使用 CAN2ANN 建模 GC 的运行耗时仅为 66.46s，运行耗时等效提升了 86%。在工程实践中，GC 和 HDC 一般同时出现，CAN2ANN 建模方法的总体提升在工作站上有 94.5%，在树莓派上有 69.2%，都有较为可观的表现。

图 5 和图 6 是运行过程中记录的空间细胞神经元活动变化图。图 5 展示了 HDC 的神经动力学变化，当系统的角度状态发生变化时，如(a-1)至(a-3)所示，从 HDC 计算得到的波包状态会沿神经元环发生相应的平滑移动。当波包超出边界范围时，HDC 能够激发对侧的邻近神经元，使波包穿越边界实现连续平滑的过渡，完整复现了 CAN 的连续性特征。当系统高度发生变化时，如(b-1)至(b-3)组所示，从 HDC 解码得到的波包状态在高度上的投影表现出了类似的动力学特性。

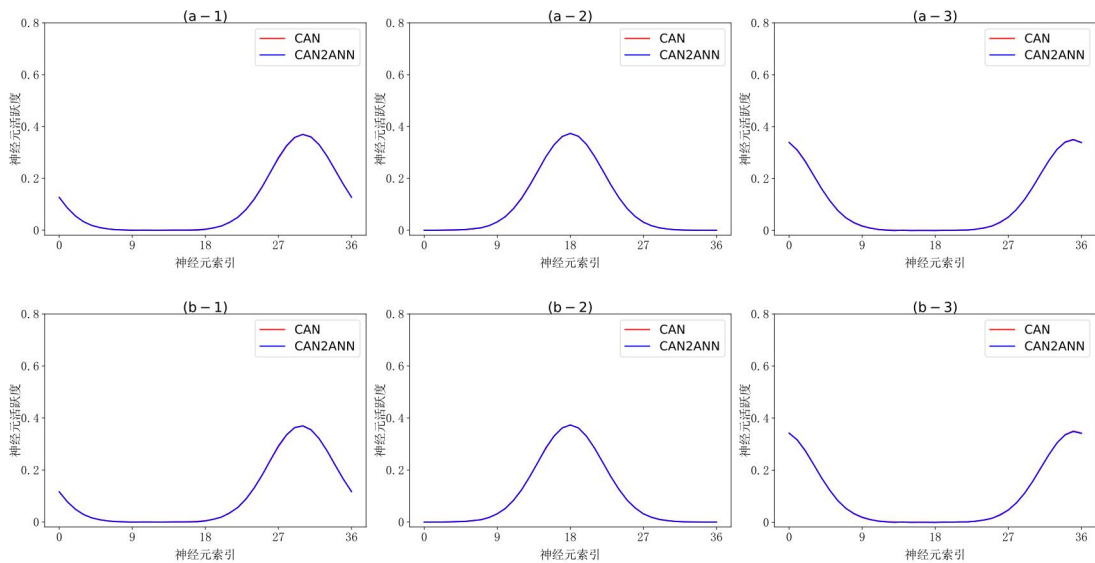


图 5 多层 HDC 神经元活动变化图。(a-1) 至 (a-3): 角度维度投影。(b-1) 至 (b-3): 高度维度投影。

Fig. 5 Firing activity variations of multi-layer HDC. (a-1)–(a-3): Projections of the angular dimension. (b-1)–(b-3): Projections of the height dimension.

此外，图 5 还同时记录了位于同一时刻的 CAN 产生的波包，其结果与 CAN2ANN 建模产生的波包基本重合，说明 CAN2ANN 不仅仅是拟合了最终的解码结果，而是拟合了完整

的动力学过程。图 6 展示了在不同投影模式下从 GC 解码得到的波包激活模式，随着系统坐标的变化，投影到二维平面上的波包会进行相应的转移，以实现对空间位置的表征。以上 ANN 重构的导航细胞所表现出的神经元活动模式与基于 CAN 构建的导航细胞的活动模式相同，都展现出了连续性和平移不变性的特点，这也表明 ANN 拟合后的 CAN 与原生模型有着高度一致的神经动力学特性。




图 6 三维 GC 神经元活动变化图。(a-1) 至 (a-3): X-Y 维度上投影。(b-1) 至 (b-3): Y-Z 维度上投影。(c-1) 至 (c-3): Y-Z 维度上投影。

Fig. 6 Firing activity variations of 3D GC. (a-1)–(a-3): Projections on the X-Y plane. (b-1)–(b-3): Projections on the Y-Z plane. (c-1)–(c-3): Projections on the Y-Z plane.

4 结论

本文提出了一种基于 ANN 的 CAN 神经动力学表征学习方法，通过使用轻量级 ANN 拟合 CAN 的神经动力学表征，以便于其在基于 CAN 的工程应用中实现功能平替。该方法避

免了以往基于高维微分方程的 CAN 建模过程中的计算冗余，提升了计算效率并压缩了神经元状态，顺应 AI 时代对于边缘应用的计算效率与可部署性需求。本文以空间细胞的神经编码-解码功能模拟为应用案例，充分展示了如何实践本文所提出的多维 CAN2ANN 方法，这种设计对于将 CAN2ANN 的通用思路进行其适配的工程领域应用具有参考价值。与原生 CAN 相比，基于 CAN2ANN 方法的多维空间细胞模型在编码-解码精度一致且保留了 CAN 的神经动力学特性的情况下，运行效率在通用设备上建模低维空间细胞时实现了约 38% 的效率提升，在建模高维空间细胞时效率提升达到了 97.3%。在边缘设备上也有亮眼的表现，虽然低维空间细胞由于硬件和固定内存开销导致比原生模型更慢，但是在建模 GC 时运行速度仍有超过 86% 的提升，综合来看也有 69.2% 的提升。综上，本工作带来的计算效率提升彰显了其价值并且同样适用于边缘设备应用，符合 AI 时代下所追求的智能算法可部署化需求，并且我们计划将于未来的研究中探索 CAN2ANN 这一通用策略的具象化工程应用方案，以配合 AI 量化加速方法形成高度实用化的创新实践。

参考文献 (References)

- [1] HE X, MENG X, MO L, et al. A comprehensive review of brain-inspired navigation [J]. *ACM Computing Surveys*, 2026, 58(8): 200.
- [2] AMARI S. Dynamics of pattern formation in lateral-inhibition type neural fields [J]. *Biological Cybernetics*, 1977, 27(2): 77-87.
- [3] WU S, WONG K Y M, FUNG C C A, et al. Continuous attractor neural networks: candidate of a canonical model for neural information representation [J]. *F1000Research*, 2016, 5: 151.
- [4] MILFORD M J, WYETH G F, PRASSER D. RatSLAM: a hippocampal model for simultaneous localization and mapping [C]// *IEEE International Conference on Robotics and Automation*. New Orleans, LA, USA, 2004: 403-408.
- [5] BALL D, HEATH S, WYETH G F, et al. OpenRatSLAM: an open source brain-based SLAM system [J]. *Autonomous Robots*, 2013, 34(3): 149-176
- [6] YU F, SHANG J, HU Y, et al. NeuroSLAM: a brain-inspired SLAM system for 3D environments [J]. *Biological Cybernetics*, 2019, 113(5-6): 515-545.
- [7] SHEN D, LIU G, LI T C, et al. ORB-NeuroSLAM: a brain-inspired 3-D SLAM system based on ORB features [J]. *IEEE Internet of Things Journal*, 2024, 11(7): 12408-12418.
- [8] CHEN Y, XIONG Z, XIAO K, et al. Brain-inspired multisensor navigation information

fusion model based on spatial representation cells [J]. *IEEE Sensors Journal*, 2024, 24(11): 18122-18132.

- [9] WANG C, ZHANG T, YI X, et al. BrainPy: a flexible, integrative, efficient, and extensible framework for general-purpose brain dynamics programming [J]. *eLife*, 2023, 12: e86365.
- [10] BATTAGLIA F P, TREVES A. Attractor neural networks storing multiple space representations: a model for hippocampal place fields [J]. *Physical Review E*, 1998, 58(6): 7738-7753.
- [11] BEN-YISHAI R, BAR-OR R L, SOMPOLINSKY H, et al. Theory of orientation tuning in visual cortex [J]. *Proceedings of the National Academy of Sciences of the United States of America*, 1995, 92(9): 3844-3848.
- [12] WANG Y, XU X, PAN X, et al. Grid cell activity and path integration on 2-D manifolds in 3-D space [J]. *Nonlinear Dynamics*, 2021, 104(2): 1767-1780.
- [13] GOODRIDGE J P, TOURETZKY D S. Modeling attractor deformation in the rodent head-direction system [J]. *Journal of Neurophysiology*, 2000, 83(6): 3402-3410.
- [14] ZHANG K. Representation of spatial orientation by the intrinsic dynamics of the head-direction cell ensemble: a theory [J]. *Journal of Neuroscience*, 1996, 16(6): 2112-2126.