arXiv:2603.18066v1 [cs.NE] 18 Mar 2026

预测编码网络的可综合RTL实现

Timothy Oh加州大学河滨分校

摘要

反向传播推动了现代深度学习的发展，但由于全局误差传播、阶段分离以及对集中式存储器的严重依赖，要将其实现为在线、完全分布式的硬件学习系统并非易事。预测编码提供了一种替代方案，其中推理和学习源自相邻层之间的局部预测误差动态。本文提出一种数字架构，可直接在硬件中实现离散时间预测编码更新。每个神经核心都维护自身的活动值、预测误差和突触权重，并仅通过硬连线连接与相邻层通信。通过统一的逐神经元钳位原语，系统支持监督学习和推理；该原语在施加边界条件的同时，不改变内部更新时序。该设计是一种确定性的可综合RTL基底，以时序乘加数据通路和固定的有限状态调度为核心。该系统并非在学习基底中执行特定任务的指令序列，而是在固定的局部更新规则下演化，并通过连接结构、参数和边界条件施加任务结构。本文的贡献并非提出一种新的学习规则，而是构建了一个完整的可综合数字基底，可直接在硬件中执行预测编码学习动态。

制品可用性。本文所述架构的完整参考实现已作为开源寄存器传输级代码提供，并附有仿真测试平台和可复现性脚本，地址为

`https://github.com/alskaf1293/neuralcomputer`

代码仓库包含可综合的 SystemVerilog 实现，涵盖神经核心、层组合模块和多层网络构建，还提供基于 Verilator 的测试平台，可复现第 8 节报告的实验。每项实验都会生成 CSV 格式的学习曲线，可直接绘图以重新生成本文中的图表。

1 引言

现代机器学习系统通常采用反向传播进行训练，通过结合全局损失信息与紧密协调的前向/反向计算调度来计算梯度。尽管这一范式非常有效，但要在硬件中将其实现为完全分布式的学习基底并不容易。反向传播过程需要有组织的全局误差传播、中间激活存储，以及通过存储器和互连进行大量数据传输。

预测编码提供了一种替代性表述：通过最小化层级中的预测误差来实现推理和学习 [10, 2]。在标准的预测编码

预印本。正在评审中。

网络（PCN）中，每一层都预测其下方的层；每个单元仅利用局部可用的信息更新自身的状态和突触权重：自身的活动值、自身的预测误差、来自上方相邻层的突触前活动，以及来自下方相邻层的预测误差。这种局部性使预测编码成为物理嵌入式学习系统的一种颇具吸引力的候选算法基底。
本文提出了一种数字微架构，可在单个神经元层面直接实现预测编码方程。每个神经核心对应一个标量单元，并在每个时钟周期执行固定的有限状态调度。通信严格限定于通过硬连线连接在相邻层之间进行。无需共享参数存储器，也无需全局学习阶段控制器。本工作的目标并非提出新的学习规则，而是展示如何将预测编码式局部学习具体映射到结构化、可综合的数字基底上。

贡献。

- 一种可组合的神经核心架构，使用顺序 MAC 数据通路实现离散时间预测编码更新。
- 一种统一的逐神经元钳位接口，通过边界条件支持监督训练和推理。
- 一种基于 IEEE-754 算术的确定性、可综合 RTL 组织结构。
- 预测编码计算与硬件有限状态机阶段之间的直接对应关系。

2 相关工作

神经形态与局部学习硬件。 大量研究致力于开发受大脑启发的脉冲神经网络（SNN）硬件。英特尔 Loihi、IBM TrueNorth、SpiNNaker 和 BrainScaleS 等平台通过脉冲时序依赖可塑性（STDP）及相关赫布规则实现片上局部学习 [1, 4, 13]。这些系统利用事件驱动的异步计算和稀疏二进制脉冲通信，取得了出色的能效。

本研究沿三个维度处于这一设计空间中的不同位置。首先，神经表征采用连续值，而非基于脉冲：每个核心都维护一个标量浮点状态，该状态在局部梯度动力学作用下连续演化，而不是由离散事件驱动的积分发放膜电位。其次，学习规则是由二次能量函数推导出的赫布式预测误差更新，而非 STDP；权重更新取决于突触后预测误差和突触前活动值，而非脉冲时序重合。第三，所用基底是面向标准数字综合流程的同步确定性寄存器传输级设计，而非异步网格或模拟混合信号架构。这些选择优先确保预测编码更新方程与硬件数据通路之间具有直接且可验证的对应关系，但代价是无法获得事件驱动脉冲系统所带来的能效提升。预测编码动力学与脉冲事件驱动计算能否有效结合，仍是有待未来研究的问题。

作为层级推断的预测编码。 预测编码已发展成为一种皮层计算的功能性解释：在该解释中，感知和学习源于在层级生成模型中最小化预测误差 [10, 2]。自由能原理提供了一个更广泛的解释框架，在这一框架中，系统通过最小化变分自由能来维持自身，并由此促使预测编码成为一种具体的算法实例化 [3]。

与反向传播的关系。在特定建模假设下，预测编码已被分析为一种实现类似反向传播学习规则的潜在途径。具体而言，Whittington 和 Bogacz 表明，在采用局部赫布可塑性的预测编码网络中，钳制输出下的收敛推断会产生近似于

反向传播梯度 [14] 的误差信号。这种关联使预测编码实现成为局部学习基底的候选方案，同时也阐明了预期其与反向传播等价的条件。

增量预测编码与稳定性。 当前架构采用基于时钟周期的增量机制，而不假设参数更新之间的推理已完全收敛。Salvatori 等人提出了一种适用于预测编码网络的稳定且全自动的学习算法，并分析了增量预测编码变体 [12]。相关分析将增量变体与增量期望最大化（EM）的观点联系起来 [9] ，并给出了适当条件下增量式期望最大化程序的收敛结果[6]。这些研究为增量调度提供了依据，但并未直接保证特定离散化方案和有限精度硬件数据通路的稳定性。

反向传播与生物学及硬件之间的不匹配。 Lillicrap 等人总结了关于反向传播的生物学合理性，以及其与神经系统之间机制不匹配的担忧 [7], ；他们的工作建立在 Rumelhart 等人提出的经典反向传播形式之上 [11]。这些批评促使研究者探索能够减少全局协调并确保局部性的替代方案。

3 反向传播及其局限

反向传播需要全局协调，这难以与分布式生物学习以及某些类型的嵌入式硬件系统相协调 [7]。首先，标准的梯度计算要求误差信息在整个网络中反向传播，从而形成并非纯粹局部的依赖结构。其次，训练通常分为不同阶段（前向、反向、更新），需要进行同步并存储中间激活。第三，反向传播假设计算图具有可微性，而生物系统涉及不连续随机信号传递 [11]。这些问题虽不妨碍在传统加速器上实现反向传播，却促使研究者探索能够实现局部更新结构、适用于嵌入式在线适应的替代学习形式。

4 预测编码

预测编码将推理和学习表述为在层级网络中最小化预测误差 [10, 2]。令 $x^{(\ell)} \in \mathbb{R}^{n_\ell}$ 表示第 ℓ 层的活动向量，令 $\Theta^{(\ell)} \in \mathbb{R}^{n_\ell \times n_{\ell+1}}$ 表示从第 $\ell+1$ 层投射到第 ℓ 层的突触权重矩阵。由第 ℓ 层生成的自上而下的预测为

$$\mu^{(\ell)} = \Theta^{(\ell)} f\left(x^{(\ell+1)}\right),$$

其中， $f(\cdot)$ 是逐元素激活函数。预测误差为

$$\varepsilon^{(\ell)} = x^{(\ell)} - \mu^{(\ell)}.$$

常用的二次预测误差目标函数为

$$E = \sum_{\ell} \left\| \varepsilon^{(\ell)} \right\|^2 = \sum_{\ell} \left\| x^{(\ell)} - \Theta^{(\ell)} f\left(x^{(\ell+1)}\right) \right\|^2.$$

尽管 E 是全局的，其梯度可分解为严格局部的项。

4.1 活动值动力学与突触更新

推理对应于相对于活动值对 E 进行梯度下降。对于内部层 ℓ,

$$\Delta x^{(\ell)} = \gamma \left(-\varepsilon^{(\ell)} + f'\left(x^{(\ell)}\right) \odot \left(\Theta^{(\ell-1)}\right)^\top \varepsilon^{(\ell-1)} \right),$$

其中， $\odot$ 表示逐元素乘法， γ 表示活动步长。突触权重可以使用局部赫布式规则进行更新，

$$\Delta\Theta^{(\ell)} = \alpha\, \varepsilon^{(\ell)} \left(f\left(x^{(\ell+1)}\right)\right)^{\top},$$

学习率尺度为 α。每个突触仅取决于其关联的突触前活动和突触后误差。

4.2 逐分量形式

对于层 ℓ 中的神经元 i，

$$\mu_i^{(\ell)} = \sum_j \Theta_{ij}^{(\ell)} f\left(x_j^{(\ell+1)}\right), \quad \varepsilon_i^{(\ell)} = x_i^{(\ell)} - \mu_i^{(\ell)},$$

$$b_i^{(\ell)} = \sum_k \Theta_{ki}^{(\ell-1)}\, \varepsilon_k^{(\ell-1)},$$

$$\Delta x_i^{(\ell)} = \gamma \left(-\varepsilon_i^{(\ell)} + f'\left(x_i^{(\ell)}\right) b_i^{(\ell)} \right),$$

$$\Delta\Theta_{ij}^{(\ell)} = \alpha\, \varepsilon_i^{(\ell)}\, f\left(x_j^{(\ell+1)}\right).$$

这些方程明确体现了局部性：每个神经元仅取决于自身的标量状态、自身的局部预测误差、来自上方相邻层的突触前状态，以及来自下方相邻层的反向传播误差乘积。

在 RTL实现中，各层之间传递的是原始状态值 x_j 。当接收神经元使用突触前输入进行预测和权重更新时，会在本地应用激活函数 $f(\cdot)$。

4.3 硬件中实现的离散时间更新

该架构实现了一种基于时钟周期的离散时间变体。对于层 ℓ 中的神经元 i ，其突触前索引为 $j \in \{0, \ldots, N-1\}$，并设有一个显式偏置通道 $j = N$，其特征值为 1；定义当前时钟周期内使用的有效局部状态如下：

$$x_{i,\mathrm{eff}}^{(\ell)} = \begin{cases} x_{\mathrm{obs},i}^{(\ell)} & \text{if external clamping is asserted for neuron } i, \\ x_i^{(\ell)} & \text{otherwise.} \end{cases}$$

随后，硬件执行

$$\mu_i^{(\ell)} = \sum_{j=0}^{N} \theta_{ij}^{(\ell)}\, f\left(x_j^{(\ell+1)}\right), \tag{1}$$

$$\varepsilon_i^{(\ell)} = x_{i,\mathrm{eff}}^{(\ell)} - \mu_i^{(\ell)}, \tag{2}$$

$$b_i^{(\ell)} = \sum_k \theta_{ki}^{(\ell-1)}\, \varepsilon_k^{(\ell-1)}, \tag{3}$$

$$x_i^{(\ell)} \leftarrow x_i^{(\ell)} + \gamma \left(f'\left(x_{i,\mathrm{eff}}^{(\ell)}\right) b_i^{(\ell)} - \varepsilon_i^{(\ell)} \right), \tag{4}$$

$$\theta_{ij}^{(\ell)} \leftarrow \theta_{ij}^{(\ell)} + \alpha \varepsilon_i^{(\ell)} f\left(x_j^{(\ell+1)}\right). \tag{5}$$

每个时钟周期都会执行一次显式欧拉式状态更新和一次局部突触更新。在实现中，突触前非线性是在使用从相邻上层接收到的状态时应用的，而不是将其存储为层间传递的量。

5 数字预测编码基底

系统的核心是一个名为 神经核心 的硬件单元，用于执行预测编码所需的局部计算。每个核心对应一个带索引的单元（$i,\ \ell$），维护其局部状态和参数，并且仅通过硬连线信号与相邻层通信。

5.1 神经核心示意图

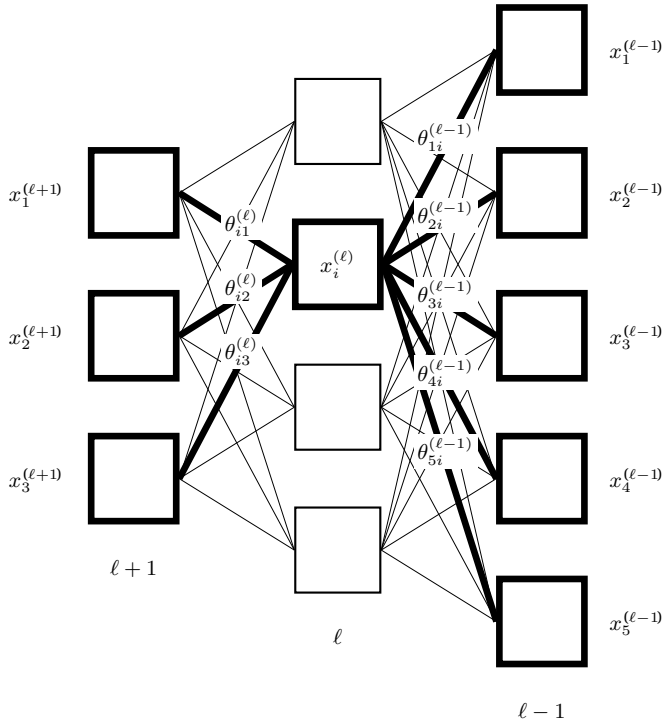

5.2 神经核心微架构

每个神经核心包含:

1. **本地状态与参数存储**。 核心存储其标量状态 $x_i^{(\ell)}$ 、预测误差 $\varepsilon_i^{(\ell)}$ 以及本地突触权重向量 $\theta_{ij}^{(\ell)}$ ，其中包括一个作为额外固定突触前通道实现的显式偏置通道。学习率 α 和活动步长 γ 由外部提供，但在本地应用，不使用共享参数存储器。

2. **突触前激活与门控逻辑**。 突触前输入以原始状态值 $x_j^{(\ell+1)}$ 的形式在各层之间传递。在接收神经元内部，这些值会经过按层选择的激活函数 $f(\cdot)$变换，用于生成预测和权重更新。导数 $f'(x)$根据当前时钟周期中神经元所使用的有效状态在本地计算，并在状态更新期间对自下而上项进行门控。偏置通道被视为常量单位特征。

3. **顺序式 DSP 数据通路**。 单个乘累加数据通路通过按索引迭代来执行预测累加、权重更新并构造反向传播乘积，以吞吐量换取更小的面积。

4. **局部有限状态机调度器**。 每个核心通过以下方式依次执行计算

$$\text{PRED} \to \text{ERR} \to \text{BACKSUM} \to \text{BACKVEC} \to \text{WUP} \to \text{STATE}.$$

推理和学习期间的调度完全相同；权重是否更新以及状态值是否钳制，均由外部控制。

5. **硬连线邻居接口**。每个核心仅与以下对象通信：
   - 其当前状态 $x_{(\ell)\ i}$ 向下传至第 $\ell-1$ 层，
   - 用于形成自下而上项的乘积向上传至第 $\ell+1$ 层。通信采用点对点方式，不进行全局仲裁。

5.3 有限状态机阶段

每个时钟周期执行一次完整更新：

- **预测阶段**：计算
$$\mu_i^{(\ell)} = \sum_j \theta_{ij}^{(\ell)} f(x_j^{(\ell+1)}),$$
包括显式偏置通道。
- **误差阶段**：计算并存储
$$\varepsilon_i^{(\ell)} = x_{i,\text{eff}}^{(\ell)} - \mu_i^{(\ell)}.$$
- **反向求和阶段**：累加
$$b_i^{(\ell)} = \sum_k \theta_{ki}^{(\ell-1)} \varepsilon_k^{(\ell-1)}$$
来自低层信号的值。
- **反向向量阶段**：输出乘积
$$\theta_{ij}^{(\ell)} \varepsilon_i^{(\ell)}$$
针对所有非偏置突触前索引 j，以便相邻上层能够构成其自下而上项。

- **权重更新阶段**：更新权重
$$\theta_{ij}^{(\ell)} \leftarrow \theta_{ij}^{(\ell)} + \alpha \varepsilon_i^{(\ell)} f(x_j^{(\ell+1)}).$$
在仅推理运行中，这一阶段在结构上仍会执行，但当 $\alpha = 0$ 时，其数值运算将不起作用。

- **状态**：使用以下内容更新状态
$$x_i^{(\ell)} \leftarrow x_i^{(\ell)} + \gamma \left(f'\left(x_{i,\text{eff}}^{(\ell)}\right) b_i^{(\ell)} - \varepsilon_i^{(\ell)} \right),$$
除非硬钳制在时钟周期结束时覆盖已存储的状态。

5.4 用于监督学习和推理的网络级钳制

每个核心都提供：

- `x_set_en`：启用当前时钟周期的外部观测，
- `x obs`：观测到的状态值。_

寄存器传输级定义了一个有效状态
$$x_{i,\text{eff}}^{(\ell)} = \begin{cases} x_{\text{obs},i}^{(\ell)} & \text{if } \texttt{x\_set\_en}_i = 1, \\ x_i^{(\ell)} & \text{otherwise,} \end{cases}$$
该状态用于时钟周期内计算局部预测误差和局部导数门控。随后，在时钟周期结束时更新存储状态寄存器，更新方式如下：
$$x_i^{(\ell)} \leftarrow \begin{cases} x_{\text{obs},i}^{(\ell)} & \text{if } \texttt{CLAMP\_HARD} = 1 \ \wedge \ \texttt{x\_set\_en}_i = 1, \\ x_i^{(\ell)} + \gamma \left(f'\left(x_{i,\text{eff}}^{(\ell)}\right) b_i^{(\ell)} - \varepsilon_i^{(\ell)} \right) & \text{otherwise.} \end{cases}$$
因此，只要存在外部观测，钳位不仅会影响最终存储的状态，还会影响时钟周期内执行的计算。

监督学习会钳制输入层和目标输出层等边界层，而推理只钳制输入，并在固定的时钟周期预算后读取自由输出。

5.5 基于时钟周期的执行模型

计算由外部时钟控制，以离散时钟周期推进。每个时钟周期都会触发神经核心有限状态调度的完整执行。在网络级，全局`start_tick` 请求会在网络空闲时转换为内部启动脉冲，随后该脉冲会广播至所有层模块和神经核心。

每个核心在完成其局部更新后会发出一个 `done` 信号。层模块会锁存每个核心的完成状态，并在该层的所有神经元均完成后发出一个单次层级完成脉冲。网络模块在各层之间采用相同的聚合策略，并在所有层均完成当前时钟周期后发出一个单次网络级 `done` 脉冲。

这种组织方式能够实现确定性的时钟周期调度，而无需在神经核心内部进行任何异步协调。

从动力系统视角来看，每个时钟周期对应于第 4.3 节所述预测编码动力学的一次显式欧拉式步进。

6 实现细节

6.1 算术格式

所有算术运算均采用 IEEE-754 单精度，并使用 HardFloat 重编码格式（recFN）。舍入模式固定为舍入至最近偶数。乘法、加法和融合乘加单元会在各个索引之间按顺序复用。

6.2 顺序数据通路

每个核心在预测阶段和权重更新阶段都会遍历突触前索引。因此，每个时钟周期的周期数随扇入线性增长。这种设计选择以降低吞吐量为代价，换取更小的面积和统一的每核心实现。

6.3 偏置通道

偏置通道实现为一个值恒为 1 的额外突触前特征。偏置权重可以选择使用独立的学习率尺度，也可以被冻结。

6.4 硬件成本模型

由于每个神经核心都会复用串行乘累加数据通路，因此每个时钟周期的周期数会随扇入线性增长。

设 N 表示真实突触前输入的数量， M 表示反向传播误差输入的数量。所实现的有限状态机执行以下操作：

- $N+1$ 个周期用于预测累加，包括显式偏置通道，
- 1 个周期用于误差生成，
- M 个周期用于累加下层反向输入，
- N 个周期用于输出向上传递的反向向量，
- $N+1$ 个用于权重更新的周期数，同样包括偏置通道，
- 1个用于状态更新的周期。

因此，每个时钟周期的周期数约为

$$C_{\text{tick}} = (N+1) + 1 + M + N + (N+1) + 1 = 3N + M + 4.$$

因此，该设计在突触前扇入和传入反向误差扇入方面都具有线性时钟周期延迟。这种顺序结构降低了每个神经元的面积，但增加了每个时钟周期的延迟。更高吞吐量的实现可以引入并行乘累加单元或向量化数据通路。

7 稳定性与收敛性考量

预测编码通常被描述为在连续时间内对预测误差能量进行梯度下降 [2]。本文所述硬件实现了一种离散时间变体，采用有限精度、固定的逐时钟周期计算调度、可选的钳位，以及活动值和权重的同步更新。这些差异十分重要：理想化连续时间动力学的稳定性性质，并不会自动适用于基于时钟周期、采用浮点运算的显式欧拉离散化。

因此，在本工作中，我们将稳定性视为一项经验属性，并根据步长、初始化、激活函数选择和时钟周期预算对其进行表征。

7.1 与反向传播和增量预测编码的关系

在推理收敛且满足标准建模假设的情况下，预测编码可以近似反向传播式的误差信号 [14]。本系统不假设参数更新之间推理已收敛，而是采用增量式机制，每个样例执行固定数量的时钟周期。近期对增量预测编码的分析为此类调度提供了依据，并将其与增量式期望最大化视角联系起来 [12, 9, 6]，但并未直接保证特定硬件离散化方案的稳定性。

8 实验

实验采用 Verilator 仿真实现，使用公共代码仓库中提供的参考寄存器传输级实现。学习和推理完全通过钳位和学习率参数进行控制，不改变内部神经核心调度。所有图表均采用对数纵轴。

8.1 教师–学生回归

一个带有 ReLU隐藏层 的三层网络（$2 \to 4 \to 3$）经过训练，以匹配固定的教师网络 $y = A_{\mathrm{gt}}\,\mathrm{ReLU}(B_{\mathrm{gt}}x)$。输入层和输出层被钳制，隐藏层则不受约束。均方误差从 0.341207 开始，在训练轮次 1 短暂升至 0.369199，随后迅速下降，到训练轮次 7 时降至 0.004784，并在训练轮次 25 时稳定在 0.005935（图1）。这种两阶段曲线——先急剧初始下降，随后缓慢进入平台期——符合增量式时钟周期机制；在该机制中，各次权重更新之间的推理不会完全收敛。

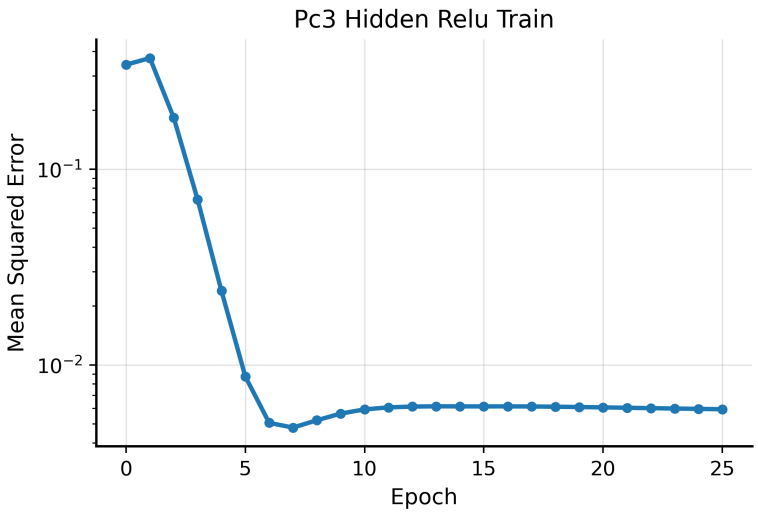

图 1： $2 \to 4 \to 3$ ReLU 网络的训练曲线。在第 1 个训练轮次经历短暂的过渡后，均方误差迅速下降，随后进入缓慢改善的平台期。

8.2 使用隐藏 tanh 层进行非线性回归

一个带有 tanh隐藏层 的较小网络（$2 \to 2 \to 1$）以目标 $y = A_{\text{gt}}\tanh(B_{\text{gt}}x + b_1) + b_2$ 进行训练。均方误差从 1.106512 开始，在训练轮次 1 升至 1.986610，随后急剧下降，到训练轮次 3 时降至 0.004725——两个训练轮次内降低了两个数量级以上。此后的改善缓慢且单调，到训练轮次 25 时达到 0.004382（图2）。

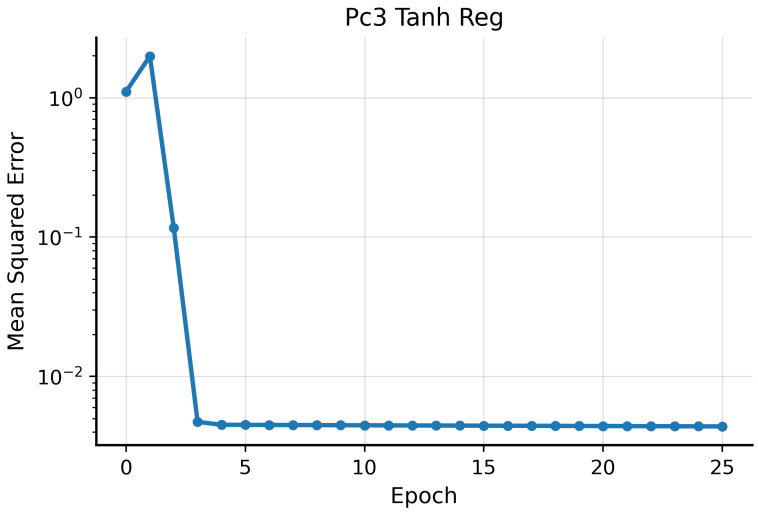

图2： $2 \to 2 \to 1$ tanh 网络的训练曲线。均方误差在第 3 个训练轮次时下降了两个数量级以上，此后缓慢改善，最终趋于较小的残差。

8.3 架构扩展

为测试局部更新动态能否适用于不同网络规模，使用单个参数化测试平台（`tb_scale_function.sv`），对三种架构应用相同的时钟周期调度、钳位接口和训练协议：

$$2 \to 4 \to 3, \quad 4 \to 8 \to 4, \quad 8 \to 16 \to 8.$$

神经核心有限状态机和钳位逻辑均未作任何改动；只有编译时维度参数不同。三个网络都呈现出快速的初始下降（到第 1 个训练轮次时，均方误差分别降低了 74%、67% 和 88%），随后达到稳定的残差下限，且该下限随维度增大而略有上升（图3）。较大的网络最终残差较高，这与增量式机制相符：较宽的隐藏层需要为每个样本运行更多时钟周期，才能达到相当的推理均衡。

关键结果是，跨不同规模均无需进行 RTL 修改。架构维度是网络实例化的结构参数；逐神经元有限状态机和学习规则保持不变。较大的网络通过实例化更多神经核心来实现，而无需重新设计基底。

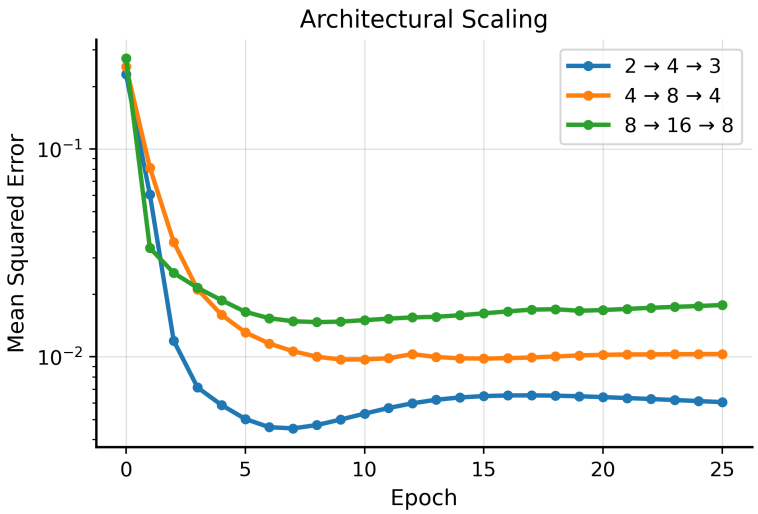

Fig图 3：三种维度递增的架构的训练曲线。所有架构均呈现出快速 d
init下降，随后趋于稳定的残差下限，并且该下限随网络规模略有上升。

8.4 定量总结

实验	架构	初始均方误差	最终均方误差
教师–学生（ReLU）	$2 \to 4 \to 3$	0.341207	0.005935
隐藏层 tanh	$2 \to 2 \to 1$	1.106512	0.004382
缩放：小	$2 \to 4 \to 3$	0.229206	0.006053
缩放：中	$4 \to 8 \to 4$	0.248934	0.010317
缩放：大	$8 \to 16 \to 8$	0.273252	0.017752

表 1：第 25 个训练轮次报告的最终均方误差值。前两行是基准回归实验；后三行是架构扩展扫描。

在全部五次运行中，端到端监督学习仅依靠局部状态变量、局部预测误差以及固定有限状态机调度下的相邻层通信来进行。所有运行中均存在非零残差下限，这促使我们进一步研究时钟周期预算和步长调优。

8.5 评估方案

学习分为交替进行的两个阶段：**推理阶段** ($\alpha = 0,\ \gamma > 0$)中，网络状态在钳制边界条件下趋于稳定；**学习阶段** ($\alpha > 0$,$\gamma > 0$)中，在状态持续演化的同时更新权重。这一区分完全通过边界条件和学习率参数实现，内部硬件调度不作任何改变。

9 讨论：迈向嵌入式自适应计算

本系统的提出源于一个实际的硬件问题：如果将学习实现为局部动力学过程，而不是一种在前向计算、反向梯度传播和存储于集中式存储器中的参数更新之间交替进行的流程，会有什么变化？在这一背景下，预测编码颇具吸引力，因为其更新规则可分解为严格的局部项，使每个单元仅凭相邻层信号就能更新自身状态和突触。由此形成的基底更像一种分布式物理过程，而非由集中式控制器执行的传统程序。

这种视角改变了任务结构在系统中的表达位置。在传统的冯·诺依曼架构中，任务行为通常主要通过外部编写、并在固定基底上执行的软件来规定。而在当前架构中，行为更多地由输入、局部状态动力学、局部可塑性以及外部施加的边界条件之间的相互作用直接塑造。

9.1 与致死计算的关系

Hinton 引入了致死计算这一概念，用以描述算法与硬件不可分割的系统：由于每个物理实例都存在未知的模拟变化，训练得到的参数只对特定硬件个体有用，并会随其一同消亡[5]。与传统的不朽计算相比，本研究更接近这一设计空间的端点。预测编码更新规则并非运行在通用基底上的软件，而是直接作为硬件数据通路本身实现。有限状态机调度、乘累加、局部状态寄存器和权重更新逻辑共同构成了整个过程；硬件与软件之间并无界限。这种表述旨在描述，而非奠定理论基础。其价值在于凸显：固定的局部动态基底如何在无需单独编程学习阶段的情况下，同时支持推理和适应——这是它与致死计算观点共有的结构特性，尽管本设计采用的是同步数字逻辑，而非模拟电路。未来值得探讨的问题是：进一步向真正的模拟致死计算迈进，以硬件特定的参数保真度换取能效，是否有益于预测编码基底。

9.2 与莫拉维克悖论的关系

莫拉维克悖论揭示了两者之间的不对称性：符号操作能够顺畅地映射到时序数字计算，而感觉运动推理在生物系统中表现稳健，却对传统架构构成挑战 [8]。本文并不声称能够解决这一悖论，而是提供了一个具体的基底，用于检验一个相关假设：感知和控制的某些方面，或许更适合通过分布式动力系统中的快速局部推理来实现，而非依赖全局存储器进行显式符号计算。

由于所提出的架构按照固定的更新规则持续进行局部误差最小化，因此它可能特别适合那些自然可表述为受约束推理的任务，尤其是在噪声较大、数据流式输入或部分可观测的环境中。要证实这一假设，还需在计算量和能耗预算相同的条件下，与传统数字基线进行实证比较。

9.3 局限性与未来方向

当前设计存在若干局限。首先，该架构复用一个按突触前索引迭代的时序浮点数据通路，虽然降低了每个神经元的面积，但随着扇入增大，时钟周期延迟也会增加。其次，非线性激活函数及其导数的可综合实现需要谨慎进行数值设计。第三，连续时间分析并不能保证耦合的离散时间、有限精度钳位系统能够收敛并保持稳定；应通过实证绘制其稳定区域，并在可能的情况下进行理论分析。

这些局限性促使未来开展以下研究：架构扩展（并行性与面积/功耗之间的权衡）、适用于综合的激活函数近似，以及能够确定局部在线推理有益场景的任务驱动基准测试。

复现实验

A本文中描述的所有实验都可以使用公共代码仓库复现。

```
git clone https://github.com/alskaf1293/neuralcomputer
cd neuralcomputer
```

```
./scripts/test_all.sh
```

运行该脚本即可执行完整的仿真实验套件。

Out输出以 CSV 文件的形式写入 `runs/` 目录。该代码仓库还提供了 Python 脚本，可根据这些输出生成论文中展示的图表。

致谢

我尤其感谢 Greg Ver Steeg 的鼓励，以及他与我进行的许多交谈，这些都帮助我将这个项目从头到尾坚持下来。

参考文献

[1] Mike Davies、Narayan Srinivasa、Tsung-Han Lin、Gautham N. Chinya、Yongqiang Cao、Sri Harsha Choday、Georgios Dimou、Prasad Joshi、Nabil I mam、Shweta Jain、Yuyun Liao、Chit-Kwan Lin、Andrew Lines、Ruokun Liu、Deepak Mathaikutty、Steven McCoy、Arnab Paul、Jonathan Tse、Guruguhanathan Venkataramanan、Yi-Hsin Weng、Andreas Wild、Yoonseok Yang 和 Hong Wang。Loihi：一种具备片上学习能力的神经形态众核处理器。*IEEE Micro*，38(1):82–99，2018。[2] Karl Friston。皮层反应理论。英国皇家学会哲学汇刊 *B*：生物科学，360(1456):815–836，2005。[3] Karl Friston。自由能原理：大脑的粗略指南？认知科学趋势，13(7):293–301，2009。[4] Stephen B. Furber、Francesco Galluppi、Steve Temple 和 Luis A. Plana。SpiNNaker 项目。*IEEE* 学报，102(5):652–665，2014。[5] Geoffrey Hinton。前向-前向算法：一些初步研究。*arXiv* 预印本 *arXiv:2212.13345*，2022。[6] Belhal Karimi、Hoi-To Wai、Eric Moulines 和 Marc Lavielle。论（快速）增量期望最大化方法的全局收敛性。*arXiv* 预印本 *arXiv:1910.12521*，2019。[7] Timothy P Lillicrap、Adam Santoro、Luke Marris、Colin J Akerman 和 Geoffrey E Hinton。反向传播与大脑。自然综述：神经科学，21(6):335–346，2020。[8] Hans P. Moravec。《心智儿童：机器人与人类智能的未来》。哈佛大学出版社，马萨诸塞州剑桥，1988。[9] Radford M Neal 和 Geoffrey E Hinton。对 EM 算法的一种观点：为增量、稀疏及其他变体提供理论依据。图模型中的学习，第 355–368 页，1998。[10] Rajesh PN Rao 和 Dana H Ballard。视觉皮层中的预测编码：对某些非经典感受野效应的功能性解释。自然神经科学，2(1):79–87，1999。[11] David E Rumelhart、Geoffrey E Hinton 和 Ronald J Williams。通过反向传播误差进行表示学习。自然，323(6088):533–536，1986。[12] Tommaso Salvatori、Yuhang Song、Yordan Yordanov、Beren Millidge、Zhenghua Xu、Lei Sha、Cornelius Emde、Rafal Bogacz 和 Thomas Lukasiewicz。一种稳定、快速且全自动的预测编码网络学习算法。*arXiv* 预印本 *arXiv:2212.00720*，2023。

[13] Sebastian Schmitt、Johann Klähn、Guillaume Bellec、Andreas Grübl、Maurice Guettler、Andreas Hartel、Stephan Hartmann、Dan Husmann de Oliveira、Kai Husmann、Vitali Karasenko、Mitja Kleider、Christoph Koke、Christian Mauch、Eric Müller、Paul Müller、Johannes Partzsch、Mihai A. Petrovici、Stefan Schiefer、Stefan Scholze、Bernhard Vogginger、Robert Legenstein、Wolfgang Maass、Christian Mayr、Johannes Schemmel 和 Karlheinz Meier。神经形态硬件闭环：在 BrainScaleS 晶圆级系统上训练深度脉冲网络。第 2227–2234 页，2017。

[14] James C. R. Whittington 和 Rafal Bogacz。在具有局部赫布突触可塑性的预测编码网络中对误差反向传播算法的近似。*Neural Computation*，29(6):1229–1262，2017。