arXiv:2601.02253v1 [cs.LG] 5 Jan 2026

# 神经通道网络：基于生物信号传输的无乘法架构

**Emrah Mete** 计算机工程系
**Yeditepe大学** 伊斯坦布尔，土耳其
**emrah.mete@std.yeditepe.edu.tr**

**Emin Erkan Korkmaz** 计算机工程系 **Yeditepe大学** 伊斯坦布尔，土耳其
**ekorkmaz@cse.yeditepe.edu.tr**

2026年1月6日

**摘要**

深度学习的迅速普及正日益受到其对高性能硬件，尤其是图形处理器（GPU）的严重依赖所制约。这些专用加速器不仅价格高昂、能耗巨大，还面临严重的供应短缺，从而限制了人工智能（AI）在边缘设备上的普及。这种低效率的核心源于标准人工感知器对密集矩阵乘法的依赖。然而，生物神经系统无需如此高强度的算术运算便能实现无与伦比的效率；突触信号传递受物理离子通道限制和化学神经递质水平调节，而不是通过类似算术乘法的过程。受这一生物机制启发，我们提出了**神经通道网络（NCN）**，这是一种新型无乘法架构，旨在使人工智能摆脱对昂贵硬件的依赖。在我们的模型中，权重被“通道宽度”所取代，由通道宽度从物理上限制信号幅度；同时，另一个参数作为“神经递质”，根据符号逻辑调节**信号传输**。前向传播完全依赖加法、减法和位运算（最小值、符号），从而彻底消除浮点乘法。在这项概念验证研究中，我们证明了神经通道网络能够利用标准反向传播，以100%的准确率解决异或和多数函数等非线性可分问题，证明其无需乘法权重也能构建复杂决策边界。该架构为下一代神经形态硬件提供了一种高效替代方案，有望在无需依赖昂贵GPU集群的情况下，借助商用CPU或超低功耗芯片运行复杂模型。

## 1 引言

深度神经网络（DNN）在从计算机视觉到自然语言处理的各种任务中取得了显著成功。然而，这种性能需要付出巨大的计算代价。几乎所有现代 DNN 的基础运算都是矩阵乘法。尽管浮点乘法有效，但其计算开销和能耗都很高，成为在边缘设备、物联网传感器以及功耗约束严格的神经形态硬件上部署先进人工智能应用的一大瓶颈 [1]。

为了解决这一“乘法瓶颈”，研究人员探索了多种替代方案。二值神经网络（BNN）将权重限制为 $\{-1, +1\}$，以便用位运算替代乘法 [2],，但通常会牺牲准确率。近年来，AdderNets [5] 提出以 L1 范数（曼哈顿）距离取代点积，并证明仅通过加法也能构建可在非线性问题上实现收敛的模型。然而，与高度依赖矩阵乘法的 DNN 模型相比，所提出方法的性能仍然有限。

尽管这些方法成功降低了计算复杂度，但它们主要是数学近似，而非生物学上合理的机制。在生物神经系统中，没有与.....类似的过程

在突触中观察不到浮点运算乘法。相反，信号传输受到物理限制和化学调节剂的调控。离子通道充当门控机制，从物理上限制信号流的幅度（通道饱和），而神经递质水平决定突触效能 [7]。

受这种生物学效率的启发，我们提出了一种新颖的架构：**神经通道网络（NCN）**。NCN 是一种完全无需乘法的架构，仅使用加法、减法和按位逻辑运算（例如最小值、符号和多路复用）来解决非线性问题。与依赖距离度量的 AdderNets [5] 不同，NCN 的灵感源自**生物信号传输** 机制。在我们的模型中，权重被物理**通道宽度** 取代，用于钳制输入信号；而另一个作为**神经递质**的参数则创建一条可学习的旁路，以调节信号流和梯度传播。

在这项工作中，我们展示了 NCN 的概念验证。我们的贡献如下：

1. 我们提出了**神经通道层**，这是一种处理单元，通过结合通道限制逻辑与基于符号的传输机制，在前向传播中消除乘法。2. 我们引入一种基于输入维度的信号缩放因子，无需复杂的初始化方案即可保持方差稳定性 [9]。3. 我们证明，尽管不使用乘法，NCN 仍能通过标准反向传播 [8], 以 100% 的准确率解决非线性可分问题（例如异或门、多数函数），从而证明其能够在没有乘法权重的情况下形成复杂的决策边界。

这种架构为极端边缘人工智能硬件开辟了一个前景广阔的新方向，可大幅减少硅面积和能耗。

## 2 相关工作

为了减轻深度神经网络（DNN）的计算负担，相关架构经历了按时间顺序不断演进的过程，从低精度近似逐渐转向算术运算替代策略。早期以提升效率为目标的研究主要聚焦于权重量化。Courbariaux 等人 [2] 率先提出了二**值神经网络（BNNs）**，将权重和激活值都限制为 $\{-1, +1\}$。这种激进的量化方式以位级 XNOR运算和人口计数（popcount）取代了开销巨大的浮点乘法，理论上可将内存用量减少 $32\times$，并使 CPU 上的运算量减少 $58\times$。随后，Rastegari 等人提出了**XNOR-Net** [3],，通过引入缩放因子，弥补二值化造成的部分精度损失。然而，尽管这些方法能带来极高的加速效果，却往往会因符号函数不连续而造成显著的信息损失和训练不稳定，从而限制其在复杂数据集上的表达能力。

作为严格二值化与全精度之间的中间方案，研究人员探索了用位移运算替代乘法。**DeepShift** [4] 等架构将权重限制为 2 的幂（例如，$2^p$）。由于二进制移位的计算成本低于乘法，这类网络在两者之间提供了一种折中方案，其准确率高于二值神经网络。不过，它们本质上仍是通过近似标准神经元的乘法特性来实现计算，而非重新定义累加机制本身；此外，要充分发挥其理论效率，通常还需要专用硬件移位器。

Chen 等人提出的**AdderNets** [5]带来了一次重大的范式转变。AdderNets 对点积的必要性提出质疑，并以基于 $L_1$范数（曼哈顿距离）的相似度度量取代卷积运算，通过加法运算而非乘法来计算特征响应。这种方法表明，仅使用加法和减法进行特征提取也能取得显著成效，在 ResNet-50 基准测试中，其性能可与标准卷积神经网络相媲美。从生物学角度看，依赖基于距离的相似度度量，与通常和突触相互作用相关联的信号传递机制有所不同。此外，$L_1$ 距离的梯度特性并不平滑，因此需要专门的自适应学习率策略，以确保稳定且高效地收敛。

与这些结构优化并行，**脉冲神经网络（SNNs）** [6]等生物学上合理的模型尝试依靠离散的脉冲事件来消除连续乘法。尽管脉冲神经网络在神经形态硬件上能效极高，但由于脉冲生成具有不可微的特性，其训练一直以难度极高而闻名。

我们提出的 **神经通道网络（NCN）**在这一领域中占据着独特的位置。与二值神经网络不同，神经通道网络不会遭受 1 位量化造成的严重信息损失。与 AdderNets 不同，我们的架构不依赖数学距离度量；相反，它将突触建模为一种由物理通道限制和神经递质门控控制的流量控制机制。这种方法使数学运算符合生物学上的合理性

并模拟离子通道饱和，同时保持梯度流的稳定性，从而有效弥合生物保真度与深度学习效率之间的差距。

## 3 方法论

本节将正式介绍**Neuro-Channel Network (NCN)** 架构。我们的主要目标是构建一种神经网络模型，使其前向传播阶段完全不涉及浮点乘法运算，仅依靠加法、减法和位逻辑。

### 3.1 Neuro-Channel 感知器

标准人工感知器通过点积运算计算输入的加权和，从而得到某个感知机 $in_j$ 的总和 $j$： $in_j = \sum_i (w_i \cdot x_i) + b$ [15] 其中 $x_i$ 是单元 $i$的输入， $w_i$ 是对应的权重，而$b$ 是偏置输入。这种乘法运算表示输入向量在权重向量上的投影。相比之下，我们提出的感知机将突触传递建模为受通道约束调节的物理流动过程。我们将 Neuro-Channel 感知器的输出定义为两种并行机制的聚合：通道宽度（物理限制）和**神经递质旁路**（化学调节）。图 1 展示了该突触处理单元的结构概览。

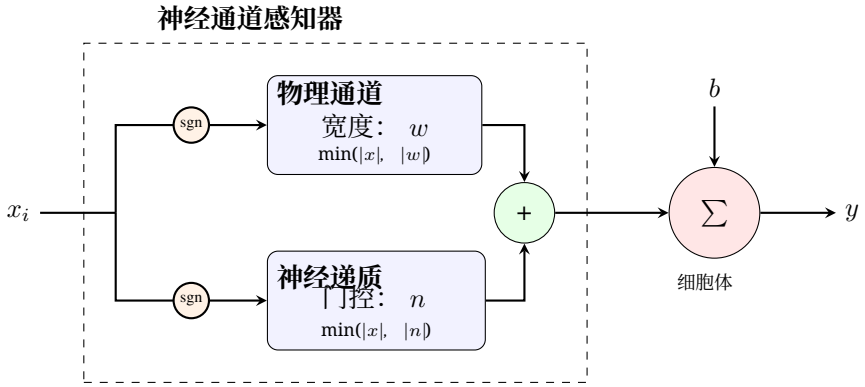


图 1：单个 **Neuro-Channel 感知器** 的结构。输入信号 $x_i$ 经过两条并行路径处理：一条受权重宽度 $|w|$限制的**物理通道**路径，以及一条由神经递质水平 $|n|$进行门控的**化学旁路**路径。两条路径均保留输入的原始符号。

#### 3.1.1 通道宽度（物理限制）

设 $x \in \mathbb{R}^d$ 为输入向量， $w \in \mathbb{R}^d$ 为权重向量。在标准神经网络中，权重充当乘法缩放因子（$w \cdot x$）。然而，在我们的架构中， $w$ 表示通道的物理**宽度**或**容量**。

通道宽度会产生一种非线性的门控机制，根据通道宽度 $|w|$限制输入信号的幅度，同时严格保留输入的方向（符号）。不同于将输入投影到权重向量上的矩阵乘法，该操作充当**动态信号限幅器**。其数学定义如下：

$$C(x, w) = \text{sgn}(x) \odot \min(|x|, |w|) \tag{1}$$

其中， $\odot$表示逐元素应用。

**物理解释：** 该机制反映了生物突触的饱和行为。正如通道无论浓度梯度如何，都只能允许由其孔径决定的最大离子流速一样，神经通道神经元也只允许信号 $x$ 通过，且不超过由 $|w|$定义的上限。如果输入信号较弱（$|x| < |w|$），它可以自由流动；如果输入信号较强（$|x| > |w|$），则会在通道上限处达到饱和。

在硬件实现中，这种逻辑不需要进行浮点运算，而是通过条件选择（多路复用器）高效执行：如果 $x$ 的符号位为正，电路就传输 $\min(|x|, |w|)$；否则，就传输 $-\min(|x|, |w|)$。

### 3.1.2 神经递质旁路

在生物突触中，信号传输并不完全取决于离子通道的物理孔径。神经递质（化学信使）通过缓慢的传递通路主动调节突触效能，即使物理通道暂时受限，信号也能继续传播 [12]。

我们对这一现象进行建模，以应对一个称为“梯度死亡”问题的关键优化挑战。在我们的通道模型中，如果宽度参数变得非常小（$|w| \approx 0$），或明显小于输入（$|w| \ll |x|$），通道就会有效饱和或关闭。在标准的硬裁剪情形下，这将阻断梯度流，使该神经元的学习过程停止。

为防止这种情况，我们引入一个额外的可学习参数向量 $n \in \mathbb{R}^d$，用于表示**神经递质水平**。这会创建一条与物理通道并行运行的化学调控通路：

$$B(x, n) = \text{sgn}(x) \odot \min(|x|, |n|) \tag{2}$$

**功能作用：** 该机制充当可学习泄漏，或作为残差连接的生物学等价物 [13]。即使物理通道（$w$）完全饱和或关闭，信号仍可通过神经递质通路（$n$）绕过这一限制。这确保：

- **In信息流：** 前向传播即使经过狭窄通道，也能保持信号方差。
- **梯度传播：** 反向传播始终存在一条有效路径，供误差导数流动，从而确保权重持续更新并高效地逃离局部极小值。

### 3.1.3 总输出与缩放

通过物理通道模型（算法1中的步骤 2）和神经递质旁路（步骤 3）的并行机制处理输入信号后，必须聚合得到的信号分量，以形成感知机的最终激活值。此阶段模拟了**胞体整合**（具体来说是空间总和）这一生物过程：兴奋性和抑制性突触后电位在细胞体（胞体）中整合 [7]。

总输出 $y_j$ 通过对所有输入连接 $i = 1 \dots d$ 上的通道输出 $C(x_i, w_{ji})$ 和神经递质输出 $B(x_i, n_{ji})$ 求和得出。然而，在深度网络中，直接对 $d$ 输入求和通常会导致信号方差随输入维度线性增长，从而引发众所周知的“梯度爆炸”问题。在生物系统中，神经元会通过**稳态可塑性**机制（例如突触缩放）防止过度兴奋，从而使放电率不受输入驱动力剧烈变化的影响 [11]。
为确保信号稳定，并在不依赖复杂权重初始化方案的情况下模拟这种生物调节，我们应用一个根据输入维度 $d$ 得出的静态缩放因子。此归一化步骤对应于我们算法中的**第 5 阶段**：

$$y_j = \left( \frac{\sum_{i=1}^{d} (C(x_i, w_{ji}) + B(x_i, n_{ji}))}{\sqrt{d}} \right) + b_j \tag{3}$$

$\sqrt{d}$ 项充当归一化因子，类似于生物稳态缩放，在数学上用作方差保持因子 [10], ，与 LeCun 等人提出的缩放原则一致 [9]。**需要注意计算复杂度上的区别：** 不同于标准人工神经元，其乘法运算次数会随输入维度 $O$ 线性增长（$d$）（每个突触连接处都会发生），这种缩放是静态标量运算，在胞体整合期间每个神经元仅应用一次（$O(1)$）。因此，大量的突触处理完全无需乘法，而这单个全局缩放步骤的计算成本，与深度神经网络所需的稠密矩阵乘法相比微不足道。

将这些物理和化学机制与最终输出联系起来的完整计算流程，详见算法 1。

**算法 1**神经通道层的前向传播

**要求：** 输入向量 $\mathbf{x}$，权重 $\mathbf{W}$，神经递质 $\mathbf{N}$，偏置 $\mathbf{b}$
**确保：** 输出向量$\mathbf{y}$

**初始化：** $\mathbf{y} \leftarrow \mathbf{0}$，$d \leftarrow$ 长度$(\mathbf{x})$
**对**每个神经元 $j$ 在层**执行**
  $sum_val \leftarrow 0$
  **对于**每个输入特征 $i$ **执行**
    **// 1. 计算幅值（无需乘法）**
    $abs_x \leftarrow |x_i|$
    $abs_w \leftarrow |W_{ji}|$
    $abs_n \leftarrow |N_{ji}|$
    **// 2. 物理通道模型（门控）**
    $limit_c \leftarrow \min(abs_x, abs_w)$
    **如果** $\text{sgn}(x_i) == \text{sgn}(W_{ji})$**则**
      $channel_out \leftarrow \text{sgn}(x_i) \cdot limit_c$ ▷ 信号自由流动
    **else**
      $channel_out \leftarrow -limit_c$ ▷ 信号反转（抑制性）
    **结束 if**
    **// 3. 神经递质旁路（泄漏）**
    $limit_n \leftarrow \min(abs_x, abs_n)$
    $neuro_out \leftarrow \text{sgn}(x_i) \cdot limit_n$ ▷ 旁路遵循输入符号
    **// 4. 累积信号**
    $sum_val \leftarrow sum_val + (channel_out + neuro_out)$
  **结束循环**
  **// 5. 胞体整合与归一化**
  $y_j \leftarrow (sum_val/\sqrt{d}) + b_j$ ▷ 用于保持方差的缩放
**结束循环**
**返回 y**

### 3.2 计算复杂度分析

为准确评估效率提升，我们比较标准前馈神经网络（FFNN）感知机与 Neuro-Channel 感知器在输入维度为 $d$的输入向量上的理论运算次数。我们将运算分为两个不同阶段：**突触运算**，其数量随输入维度线性增长（$O(d)$）；以及**胞体运算**，每个神经元只执行一次（$O(1)$）。

如表1所示，标准感知机高度依赖于突触循环中的 $d$ 乘法运算，这构成了深度网络的主要能耗瓶颈。相比之下，神经通道网络（NCN）完全消除了突触层面的乘法运算。尽管我们的架构引入了缩放运算，但必须注意它在计算图中的位置：这是一个**胞体运算**，复杂度为 $O(1)$。

对于一个典型的层，其中 $d$ 可能为 1024 或 2048，用加法逻辑替代 $d$ 次乘法可显著节省能耗，因为单次胞体缩放步骤（1 次操作）的成本，与被消除的突触工作负载（$d$次操作）相比微不足道。此外，如第 3.1 节所述，这个单次缩放步骤可简化为硬件友好的位移，从而确保整个流水线保持高效。

表1：每个感知机的基本运算对比（输入维度： $d$）

| 范围 | 运算类型 | 标准前馈神经网络 | NCN（我们的模型） |
|---|---|---|---|
| 突触运算 （规模： $O$（$d$）） - 高容量 | | | |
| | **浮点乘法** | **d** | **0** |
| | 浮点加法 | $d$ | $2d$ |
| | 比较运算 / 符号检查 | 0 | $2d$ |
| | 多路复用（Mux） | 0 | $2d$ |
| 胞体运算（缩放： $O$（1）） - 常数时间 | | | |
| | 偏置加法 | 1 | 1 |
| | **缩放 / 归一化** | 0 | **1** |

# 4 实验

为验证神经通道网络（NCN）的理论能力，我们聚焦于基础的非线性逻辑问题。所有实验均使用 Python 实现的自定义框架进行。

## 4.1 实验设置

在所有实验中，我们都使用了框架中定义的相同网络结构。该网络架构由全连接NCN层和用于分类的标准Softmax层组成。

- **初始化：** 权重 $w \sim \mathcal{N}(0,\ 1)$，神经递质 $n \sim \mathcal{N}(0,\ 0。5)$。
- **优化器：** 标准带动量的随机梯度下降 (0。9)。
- **损失函数：**交叉熵损失。

### 4.1.1 异或问题

异或（Exclusive OR）问题是神经网络文献中的经典基准问题。它要求模型在输入不同时输出 1 （0，1 或 1，0），而在输入相同时输出 0 （0，0 或 1，1）。这个问题在历史上意义重大，因为它证明了单层感知机（线性分类器）无法解决非线性可分问题。在本实验中，尽管前向传播不涉及乘法，我们仍使用了**标准反向传播** [8] 来更新通道宽度、神经递质和偏置。

表 2：异或问题的真值表

| 输入A | 输入B | 输出（目标） |
|---|---|---|
| 0 | 0 | 0 |
| 0 | 1 | 1 |
| 1 | 0 | 1 |
| 1 | 1 | 0 |

**网络拓扑结构和参数：**

- **训练方法：**标准反向传播（随机梯度下降）。
- **拓扑结构：** $2 \to 4 \to 2$ （2 个输入神经元、4 个隐藏神经元、2 个输出神经元）。如图 2 所示。
- **学习率：**0.001.
- **动量：**0.9.
- **训练轮次：**1000。

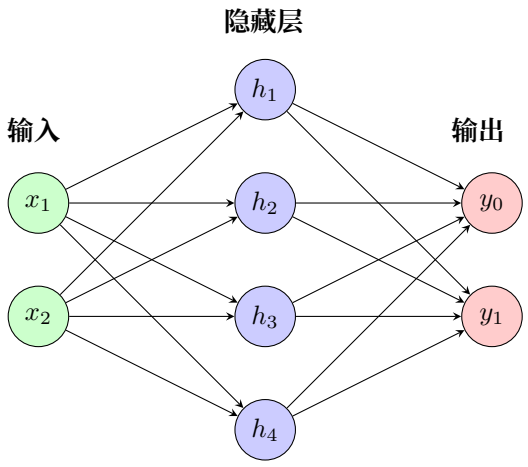


图 2：用于异或问题的 NCN 架构（2-4-2 拓扑结构）。

**结果：** NCN 使用标准反向传播成功收敛，达到了**100% 的准确率**。该任务所使用的网络拓扑如图2所示。图3展示了网络学习到的决策边界。如图所示，网络成功实现了非线性分离，将 (0,0) 和 (1,1) 区域与 (0,1) 和 (1,0) 区域隔离开来。这证实了所采用的通道模型与神经递质旁路之间的相互作用能够在无需乘法权重的情况下实现有效的非线性变换。

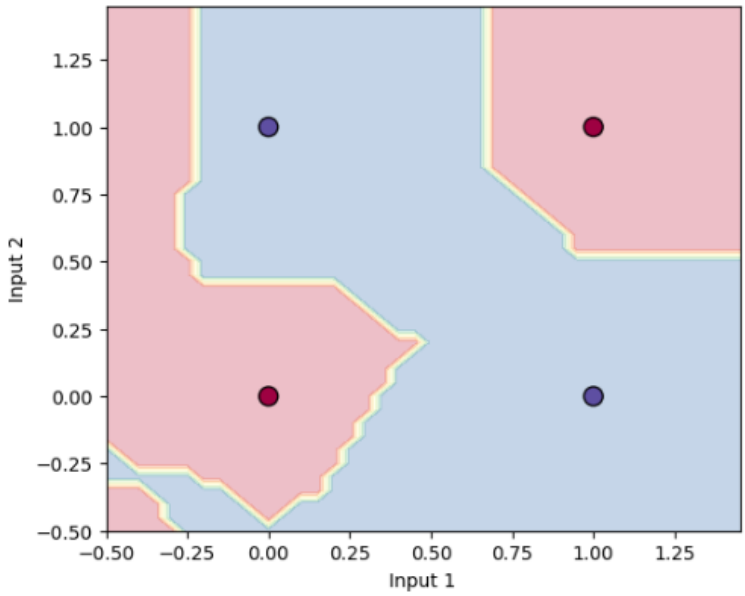


图3：NCN 通过标准反向传播学习到的异或函数决策边界。该模型仅使用加法运算，便成功区分了非线性类别。

### 4.1.2 多数函数

我们进一步在 $3-bit$ 多数函数上测试了该网络。该函数在输入位中占多数的位（例如，1 ）为2 个（总共3个）时输出1；否则输出0。这项测试检验了网络执行基于阈值的逻辑推理并汇总多个来源信息的能力。在此实验中，我们再次采用**标准反向传播** [8] 来更新通道宽度、神经递质和偏置。

表3：3位多数函数的真值表

| 输入A | 输入B | 输入C | 输出（目标） |
|---|---|---|---|
| 0 | 0 | 0 | 0 |
| 0 | 0 | 1 | 0 |
| 0 | 1 | 0 | 0 |
| 0 | 1 | 1 | 1 |
| 1 | 0 | 0 | 0 |
| 1 | 0 | 1 | 1 |
| 1 | 1 | 0 | 1 |
| 1 | 1 | 1 | 1 |

**网络拓扑结构和参数：**

- **拓扑结构：** $3 \to 8 \to 2$ （3个输入神经元、8个隐藏神经元、2个输出神经元）。如图4所示。
- **学习率：** 0.001.
- **动量：** 0.9.
- **训练轮次：** 200。

**结果：**该网络成功学习了所有 $2^3 = 8$ 可能输入组合的完整真值表，准确率达到**100%**。这一结果表明，神经通道网络能够有效汇总多个输入信号，并进行稳健的决策。

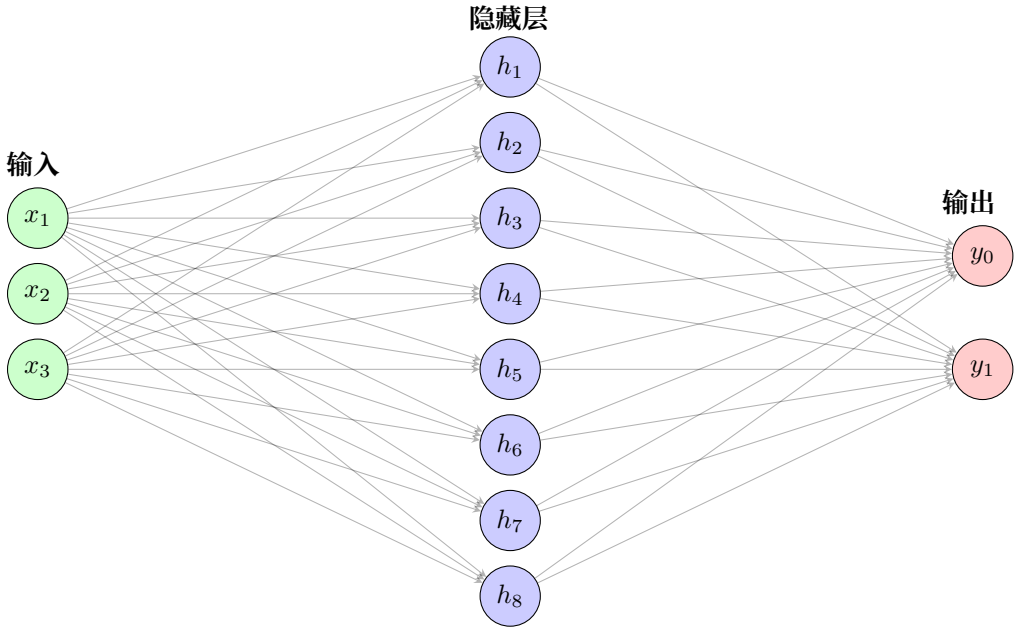


图4：用于实现3位多数函数的NCN架构（3-8-2拓扑）。

## 5 讨论

上一节展示的结果表明，所提出的神经通道网络（NCN）能够在前向传播中不依赖矩阵乘法来学习非线性表示。这一发现对神经形态计算和硬件高效人工智能都具有重要意义。

## 6 结论与未来方向

本文介绍了一种受生物突触离子通道门控机制启发的新型神经架构 **神经通道网络（NCN）**。NCN 以加法和按位逻辑运算取代计算开销高昂的浮点乘法，挑战了深度学习中占主导地位的重算术范式。我们在多数函数和异或函数等基础非线性问题上取得的实证结果，验证了所提出的 **信号传输** 机制在结构上的有效性。我们证明，仅利用物理通道限制和基于神经递质的门控，无需在前向传播中使用乘法，就能有效构建复杂的非线性决策边界。

基于这一概念验证，未来的研究将聚焦于三大战略支柱，以弥合理论效率与实际部署之间的差距：

1. **完全无乘法训练的实现：**虽然本研究验证了前向传播的效率，但训练阶段采用了标准反向传播 [8]。为了实现真正的端到端效率，我们近期的工作将重点放在将无乘法范式扩展到训练阶段。我们旨在开发优化策略，以加法更新或基于符号的更新取代标准梯度下降中的乘法运算 [14] (符号随机梯度下降)，使该架构能够仅使用位运算和加法进行推理和训练。

2. **可扩展性与深层表示学习：**我们计划将 NCN 架构扩展至更深层的拓扑结构，并评估其在 MNIST 和 CIFAR-10 等高维数据集上进行层次化特征提取的能力。一个关键目标是探究通道机制能否在显著降低能耗的同时，在计算机视觉任务中达到与卷积神经网络（CNNs）相近的性能

在计算机视觉任务中，卷积神经网络的同时保持显著更低的能耗。

3. **神经形态硬件协同设计：**理论复杂度分析表明，这种方法有望大幅节省能耗。为量化这一点，我们计划将 NCN 逻辑综合到现场可编程门阵列（现场可编程门阵列）上，并设计定制的专用集成电路（专用集成电路）。这样我们就能测量每次推理的精确功耗。

我们认为，神经通道网络是迈向生物学上合理的人工智能的重要一步。通过使数学运算符合突触的生理约束，NCN 提供了一条可扩展的途径，有望克服现代硅技术的能耗瓶颈，为下一代高效且无处不在的人工智能铺平道路。

## 参考文献

[1] Horowitz, M. (2014). “1.1 计算的能耗问题（以及我们能采取的措施）。” *IEEE*国际固态电路会议技术论文摘要集 *(ISSCC)*, 10-14.[2] Courbariaux, M., Hubara, I., Soudry, D., El-Yaniv, R., & Bengio, Y. (2016). “二值化神经网络：将深度神经网络的权重和激活值限制为 +1或 -1 的训练方法。” *arXiv* 预印本 *arXiv:1602.02830*.[3] Rastegari, M., Ordonez, V., Redmon, J., & Farhadi, A. (2016). “XNOR-Net：使用二值卷积神经网络进行 ImageNet 分类。”欧洲计算机视觉会议 *(ECCV)*, 525-542. 施普林格.[4] Elhoushi, M., Chen, Z., Shafiq, F., Ye, Y. H., & Zhang, Z. (2021). “DeepShift：迈向采用二次幂权重的无乘法神经网络。” *arXiv* 预印本 *arXiv:1905.13298*.[5] Chen, H., Wang, Y., Xu, C., Shi, B., Xu, C., Tian, Q., & Xu, C. (2020). “AdderNet：深度学习真的需要乘法吗？” *IEEE/CVF*计算机视觉与模式识别会议 *(CVPR)* 论文集, 1468-1477.[6] Maass, W. (1997). “脉冲神经元网络：第三代神经网络模型。”《神经网络》, 10(9), 1659-1671.[7] Kandel, E. R., Schwartz, J. H., & Jessell, T. M. (2000).《神经科学原理》（第4版）。纽约：麦格劳-希尔。[8] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). “通过误差反向传播学习表征。”《自然》, 323(6088), 533-536[9] LeCun, Y., Bottou, L., Orr, G. B., & Müller, K. R. (2012). “高效反向传播。”《神经网络：行业诀窍》 (pp. 9-48). 施普林格，柏林，海德堡。[10] Glorot, X., & Bengio, Y. (2010). “ 理解深度前馈神经网络训练的难点。”第十三届国际人工智能与统计会议论文集, 249-256.[11] Turrigiano, G. G., Leslie, K. R., Desai, N. S., Rutherford, L. C., & Nelson, S. B. (1998). “新皮层神经元中量子幅度的活动依赖性缩放。”《自然》, 391(6670), 892-896.[12] Greengard, P. (2001). “慢速突触传递的神经生物学。”《科学》, 294(5544), 1024-1030.[13] He, K., Zhang, X., Ren, S., & Sun, J. (2016). “用于图像识别的深度残差学习。” *IEEE*计算机视觉与模式识别会议论文集 *(CVPR)*, 770-778.[14] Bernstein, J., Wang, Y. X., Azizzadenesheli, K., & Anandkumar, A. (2018). “signSGD：非凸问题的压缩优化。”国际机器学习会议 *(ICML)*, 560-569. 机器学习研究论文集.[15] Rosenblatt, F. (1958). “感知机：一种用于大脑信息存储与组织的概率模型。”《心理学评论》, 65(6), 386.