arXiv:2302.01302v1 [cs.NE] 2 Feb 2023

利用纳米级器件随机性的二元脉冲网络贝叶斯推断

Prabodh Katti、Nicolas Skatchkovsky、Osvaldo Simeone、Bipin Rajendran、Bashir M. Al-Hashimi 伦敦国王学院工程系，英国伦敦 电子邮箱：bipin.rajendran@kcl.ac.uk

摘要——**贝叶斯神经网络（BNN）能够克服传统频率学派深度神经网络普遍存在的过度自信问题，因此被视为构建可靠人工智能系统的关键推动因素。然而，传统的 BNN 硬件实现需要大量资源，必须实现随机数生成器以进行突触采样。纳米级忆阻器件在编程和读取操作过程中具有固有的随机性，因此可以直接用于采样，无需额外的硬件资源。本文介绍了一种新型的基于相变存储器（PCM）的 BNN 硬件实现方案，采用二值突触。所提出的架构由独立的权重平面和噪声平面组成，其中相变存储器单元分别经过配置和操作，以表示权重的标称值并生成采样所需的噪声。利用实验观测到的 PCM 噪声特性，在乳腺癌数据集分类这一示例问题中，我们实现了与 8 位定点（FxP8）实现相当的硬件准确率和期望校准误差，同时预计核心面积晶体管数量可减少超过 9×。**

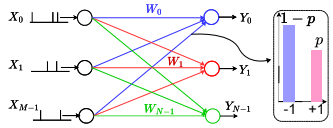
索引词—**贝叶斯推断、相变存储器、脉冲神经网络、器件噪声、随机性。**

I. 引言

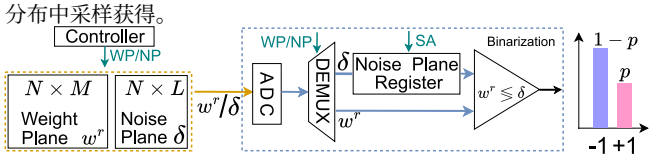
现代神经网络往往会做出过度自信的决策，无法准确反映因可用数据有限而产生的固有认知不确定性 [1]。相比之下，关键应用需要对预测置信度进行良好校准，以支持风险感知决策 [2], [3]。贝叶斯神经网络（BNN）通过在模型参数空间上以概率分布的形式编码认知不确定性，并实现集成预测器，为这一问题提供了有原则的解决方案 [4], [5]。通过 BNN 实现推理需要随机性来源，即随机数生成器，以便从模型参数的概率分布中采样。本文探讨利用纳米尺度器件级编程噪声作为

贝叶斯推断中采样的来源。

相关工作：所提出的方法不同于大多数现有的二值脉冲神经网络（BNN）实现方案；这些方案依赖伪随机数生成器（PRNG），导致系统资源开销较大 [6]。例如， [2], [7] 提出的基于互补金属氧化物半导体（CMOS）的实现方案需要静态随机存取存储器（SRAM）单元、乘法器和模数转换器（ADC），因而占用较大的芯片面积。此外，这些方案依赖传统的冯·诺依曼架构，其中存储器与处理单元在物理上彼此分离。



（a）贝叶斯脉冲神经网络，其二值权重通过在推理过程中从伯努利分布中采样获得。



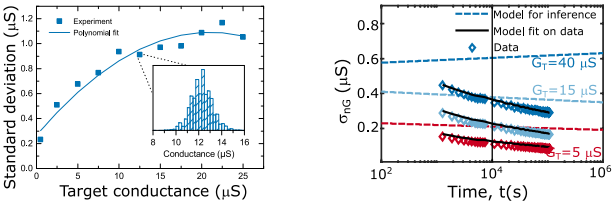
（b）所提出的硬件架构由一个 $N \times M$ 差分相变存储器（DPCM）单元 w^r交叉开关阵列组成，该阵列称为权重平面（WP），用于存储标称权重；此外还包括一个由 $N \times L$ DPCM 单元构成的噪声平面（NP），用于为突触采样生成随机性。我们选择 $L < M$，并通过随机仲裁（SA）复用存储在寄存器中的噪声平面 L 行的电导值，从而在优化面积的同时降低采样相关性。

图1：贝叶斯二值脉冲神经网络（BSNN）的示意图及其采用 PCM 交叉开关阵列的实现。

人们正在探索采用非易失性存储器（NVM）器件（如电阻式随机存取存储器（RRAM）、相变存储器（PCM）和自旋转移力矩随机存取存储器（STTRAM））实现存内计算（IMC）架构，以绕过冯·诺依曼瓶颈 [8]。这些纳米级器件通过调节有效电导，在更小的占用面积内存储信息，从而支持多级计算乃至模拟计算 [9], [10]。然而，众所周知，这些器件具有显著的编程噪声和读取噪声 [9]。

通过存内计算（IMC）实现贝叶斯神经网络（BNN）的方法包括 [11], ，该方法使用电阻式随机存取存储器（RRAM）阵列，并通过马尔可夫链蒙特卡罗（MCMC）实现训练，因而耗时且资源消耗大 [12]。 [6] 的作者提出利用自旋转移力矩随机存取存储器（STT-RAM）的伯努利分布噪声来生成高斯随机变量。通常，这种方法需要大量器件，以确保其贡献之和能够通过平均趋近于高斯密度，这正如中心极限定理所规定的那样。

脉冲神经网络（SNNs） [13]因其能效而受到广泛研究，相关硬件实现涵盖数字平台和混合信号存内计算平台，包括由业界制造的 TrueNorth 和 Loihi 芯片[14]–[16]。针对脉冲神经网络的贝叶斯学习算法已被提



(a) 编程噪声 (b) 读取噪声

图 2：PCM 的噪声特性，改编自 [9]。

出 [17] （另请参阅其中的参考文献），但迄今为止尚未涉及其硬件实现。

本文的主要贡献如下：

- 我们提出了一种二值贝叶斯脉冲神经网络（BSNN，见图 1(a)）的新型硬件实现方案，该方案采用存内计算架构，利用相变存储器器件固有的编程随机性进行突触采样。如图 1(b) 所示，所提出的架构和设计能够将经过软件训练的网络权重直接传输至硬件，同时最大限度地减少为采样而引入的额外硬件资源。

- 利用实验观测到的 PCM 噪声特性，在示例性乳腺癌数据集分类任务中，我们获得了与 8位定点实现相匹配的硬件准确率和期望校准误差，同时预计核心面积晶体管数量可节省超过9× 。

II. 背景

本节回顾相变存储器器件和二值脉冲神经网络的基础知识。

相变存储器件： 相变存储器（PCM）器件由硫属化物材料（如 $Ge_2Sb_2Te_5$ ）构成，该材料夹在两个金属电极之间。通过施加一系列电脉冲，可将器件电导编程至预先设定目标范围内的指定状态；这些电脉冲的数量、幅度和宽度各不相同，并会改变两个电极之间材料中晶态和非晶态的比例及构型 [10], [18], ，从而实现模拟存内计算 [9], [19]。随后，这类器件会被配置为差分对，以便在交叉阵列中存储正权重值和负权重值，进而表示突触网络。

相变存储器器件在编程和读取操作期间会表现出噪声。参见图 2，我们注意到，对在 [9] 中采用 90纳米互补金属氧化物半导体工艺制造的 10,000 多个器件进行测量后，得到的器件固有噪声具有以下关键特征：（i）编程噪声 $\sigma_p(G)$ 近似服从高斯分布，其标准差取决于平均电导的平方 G；（ii）读取噪声噪声 $\sigma_r(G)$ 随时间变化，且幅度小于编程噪声。

具有二值突触的贝叶斯脉冲神经网络： 在本研究中，我们考虑具有二值突触的贝叶斯二值脉冲神经网络。其运行特性由突触权重 w 决定，这些权重只能取 $\{-1,+1\}$状态。因此，突触权重由向量 $w \in \{-1,+1\}^{|w|}$表示，其中 $|w|$ 表示该向量的大小。在训练过程中，通过在线推广 [5]中引入的贝叶斯学习规则 [20]，对描述相互独立的伯努利随机变量分布的平均场分布$q(w)$进行优化。

此优化的结果是一个实值向量$w^{\mathrm{r}} \in \mathbb{R}^{|w|}$，它决定了分布 $q(w)$。具体而言，随机向量 $w \sim q(w)$由相互独立的随机变量组成，其中每个第 i个分量 w_i 以概率 $p_i = \mathrm{sigmoid}(2w_i^r)$取值$+1$ ，或者等价地取值$w_i^r = \frac{1}{2}\log\left(p_i/(1-p_i)\right)$，其中 p_i和 w_i^r分别是向量 p 和 w的第 i个分量。

给定向量 w^r，可以通过 Gumbel-Softmax 技巧 21]近似生成一个样本 $w \sim q(w)$

$$w = \tanh\left(\frac{w^r + \delta}{\tau}\right), \tag{1}$$

其中函数 s 逐元素应用,li向量 δ 的每个分量均独立生成为 $\frac{1}{2}\log(\epsilon/(1-\epsilon))$，其中$\epsilon \sim \mathcal{U}(0,1)$是一个 Gumbel 分布随机变量。当 $\tau \to 0$时，样本 w 服从分布 $q(w)$。

在推理过程中，会生成多个样本 $w \sim q$（w），以获得预测器集成，并对它们的决策取平均，从而产生最终决策。神经元动力学采用带泄漏积分发放（LIF）实现，并使用离散脉冲响应模型（例如参见 [22]）。

III. 基于 PCM 的硬件架构

本节将介绍所提出的基于 PCM 的硬件架构，该架构通过具有二值突触的贝叶斯二值脉冲神经网络实现集成预测器。

架构概述： 如图 1(b) 和图 3 所示，所提出的架构由两个平面组成：权重平面和噪声平面。权重平面由差分相变存储器（DPCM）器件的 $N \times M$ 交叉阵列实现，噪声平面则由 DPCM 器件的 $N \times L$ 交叉阵列构成。权重平面实现标称权重 w^r，而噪声平面用于生成采样步骤 (1) 所需的随机向量 δ。其核心思想是利用相变存储器器件的编程噪声来实现噪声平面。为此，主要挑战在于设计噪声平面，使其能够利用上一节介绍的相变存储器器件特性来近似执行采样步骤 (1)。

将噪声平面的尺寸设置为与权重平面相同，即设置 $L = M$，即可使噪声平面按照式 (1) 生成相互独立的随机权重。为提高整体面积效率，本文提出采用尺寸较小的噪声平面，设置为 $L < M$ ，并通过多次复用噪声平面的值（通过随机仲裁方案选取）进行二值化。但这会导致权重之间产生相关性，与式 (1) 相比引入近似误差。所提出的架构支持灵活选择参数 L，我们通过仿真研究 L 对性能和效率的影响。

为确保在呈现输入信号的所有脉冲期间应用相同的采样权重，我们对噪声平面寄存器组（图 1b）中器件的电导值进行采样并保持。此外，这使得

可以实现随机仲裁方案，从该寄存器组存储的L 列 N 电导中随机选择一列，对权重平面中的权重进行二值化，从而降低相关性的影响（见第 IV 节）。

利用 *PCM* 噪声：如 [9]，所示，PCM 编程噪声服从高斯分布，其均值和标准差取决于状态（见图 2(a)）。我们提出利用这种随机性，为采样步骤 (1) 生成所需的向量 δ。为此，我们用零均值、标准差为 $\sigma_\delta \approx 0.8$ 的高斯分布近似 Gumbel 分布。如下文所述，通过对相变存储器器件的电导进行适当缩放和组合，即可从该分布中获得一个样本。

权重平面与噪声平面：为了说明将权重平面与噪声平面分离这一设计选择的动机，首先考虑一种更简单的方案：使用单个 DPCM 器件，其电导水平为 G^+ 和 G^-，以表示均值等于标称权重 w^r 、方差为 σ_δ^2 的目标高斯分布。稍作符号滥用，此处用 w^r 表示向量 w^r 的任意元素。为此，这两个相变存储器件必须满足以下约束

$$w^r = G^+ - G^-, \tag{2}$$

$$\sigma_\delta^2 = \sigma_p^2(G^+) + \sigma_p^2(G^-) + \sigma_r^2(G^+) + \sigma_r^2(G^-), \tag{3}$$

其中，编程和读出噪声的标准差 σ_p 和 σ_r 如上一节所述（见图 2），而电导水平 G^+ 和 G^- 位于相变存储器件 0-25 μS 的动态范围内。我们通过实验观察到，在一系列有实际意义的权重 w^r取值范围内，这一可行空间无法满足条件（2）和（3）。

为了解决这个问题，我们提出在权重平面中使用差分对（$G^+_{w^r}$，$G^-_{w^r}$）来实现权重的标称值 w^r ；而采样噪声则通过在噪声平面中从由 L 个 DPCM 单元（G^+_{ni}，G^-_{ni}）组成的集合中任意选取一个单元来获得，其中 $i = 1, 2, \ldots L$。PCM 核心上的实现细节将在下一小节介绍。权重平面和噪声平面中的器件配置为满足以下条件

$$w^r = G^+_{ni} - G^-_{ni} + \kappa^{-1}\left(G^+_{w^r} - G^-_{w^r}\right), \tag{4}$$

$$\begin{aligned}\sigma_\delta^2 &= \sigma_p^2(G^+_{ni}) + \sigma_p^2(G^-_{ni}) + \sigma_r^2(G^+_{ni}) + \sigma_r^2(G^-_{ni}) + \\ &\quad \kappa^{-2}\left(\sigma_p^2(G^+_{w^r}) + \sigma_p^2(G^-_{w^r}) + \sigma_r^2(G^+_{w^r}) + \sigma_r^2(G^-_{w^r})\right) \\ &\approx \sigma_p^2(G^+_{ni}) + \sigma_p^2(G^-_{ni}) + \sigma_r^2(G^+_{ni}) + \sigma_r^2(G^-_{ni}),\end{aligned} \tag{5}$$

其中 $\kappa > 1$ 是一个缩放参数，其值应足够大，以便合理采用近似式 (5)。通过编程$G^+_{ni} \approx G^-_{ni}$ 时，我们确保噪声平面器件的电导不会影响权重的整体标称值，仅产生采样噪声。

作为一种实现细节，满足不等式 $|w^r| > 2$ 的标称权重被设为固定的高值，对通过式 (1) 进行二元采样的影响极小。此外，根据器件电导的可用范围，我们在式 (4)-(5) 中选择 $\kappa = 8$ ，并将标称权重的最大值映射到权重平面电导

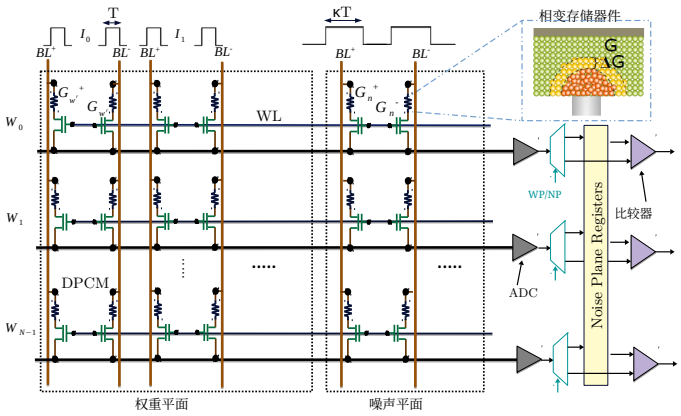


图 3：所提出的突触核心架构，其中 DPCM 单元被配置为在权重平面中表示标称权重值（w^r），并在噪声平面中生成贝叶斯采样所需的噪声变量（δ）。

值为 16 μS，向上取整后的权重则映射到 24 μS。在 *PCM* 核心上的实现：如图 3 所示，在所提出的交叉阵列架构中，通过分配 L 额外的列来配置噪声平面所需的器件。为实现式 (1)，我们将 tanh(·) 函数替换为近似且硬件效率更高的 sign(·) 函数。对于每批输入，首先读取噪声平面中 DPCM 单元所有 L 列的模拟电导，然后将其离散化并存储在噪声平面寄存器中。由于权重与输入脉冲的乘积需要在输出神经元中累加之前通过 sign(·) 函数进行二值化，因此权重平面的各列逐列激活，然后与噪声平面寄存器中存储的噪声值列之一进行比较；该列通过随机仲裁选出。

为实现权重平面中标称权重值与编程电导之间的 $\kappa = 8$ 缩放因子，我们沿位线采用脉宽调制，将噪声平面的读取脉冲持续时间缩放 κ 倍，相较于权重平面器件的读取持续时间（见图 3）。

要在具有 N列的交叉阵列中实现前向传播，需要 N 个读取时钟周期。首先，通过使能字线（WL）来导通权重平面中的访问晶体管；然后，根据前神经元是否产生脉冲，在位线（BL）上施加适当宽度的读取脉冲。我们假设使用 8 位模数转换器读取两个平面中的电导值。

置信度分数通过对输出脉冲信号的速率进行时间平均，以及对从分布 $q(w)$中抽取的预测器集成进行平均而得到，详见 [5]。通过对置信度分数应用阈值来作出分类决策，并将决策与真实标签进行比较以确定准确率。

IV. 实验与结论

在本节中，我们首先按照 [5] 中介绍的方法，在软件中训练神经网络，以评估所提出的架构。随后将软件训练的权重映射

到一款定制的 PCM 交叉开关阵列硬件仿真器上。该仿真器支持 PCM 的迭代编程 [9]，具体采用上一节介绍的方法。

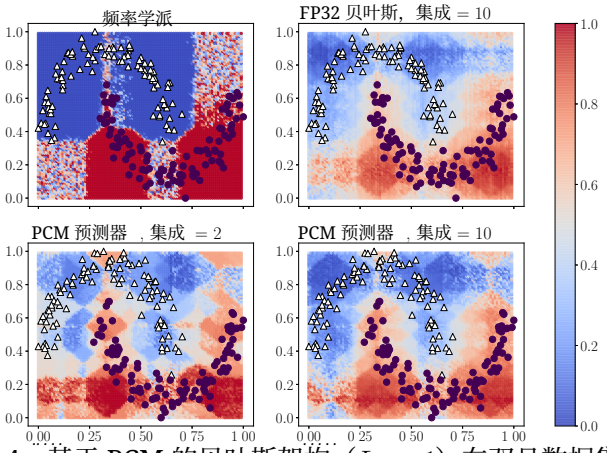


图 4：基于 PCM 的贝叶斯架构（$L = 1$）在双月数据集上的分类概率，与 FP32 贝叶斯软件基线相匹配。

我们首先考虑双月分类问题，并采用与 [5] 中相同的具有两个隐藏层的全连接网络。在图 4 中，我们比较了 FP32 实现（右上）和基于 PCM 的实现（下方）对“圆形”类别所分配的置信度分数；集成中包含不同数量的模型，这些模型根据（1）绘制而成。这些图中颜色的深浅表示某个点属于“圆形”类别的预测概率。顶部的两个面板表明，贝叶斯模型的校准效果优于频率学派实现（按照 [5] 中的方法进行优化）。在频率学派情况下，大多数分布外样本都被错误地赋予了属于某一类别的较高概率和较强置信度，忽略了认知不确定性。FP32 贝叶斯实现通过为这些点分配梯度化的概率，提供了更可靠的不确定性量化，这一点可以从颜色的色调中看出。值得注意的是，即使仅使用 $L = 1$，PCM 实现（底部面板）也能与包含 10 个集成的 FP32基线实现良好匹配；即使只有两个集成，也能取得合理的性能。

现在我们转向一个更复杂的真实世界数据集，即威斯康星州乳腺癌数据集（诊断）。我们采用与 [5]，相同的网络架构，但输入神经元数量为 30。输入采用 [5]，中的群体编码方式；此外，我们增加了一个预处理步骤，以提高输入数据的稀疏性，使每个神经元在每个时间步的平均脉冲发放率为 0.04 个脉冲。图 5 展示了准确率和期望校准误差（ECE）随集成规模变化的情况，其定义与 [1]，中相同。ECE 衡量模型所赋予的置信度与真实值之间的平均差异。对于基准频率学派实现，我们采用了委员会机器（CM）架构，将多个神经网络的输出取平均，以消除...
...的影响。这些神经网络均具有相同的标称权重，并使用标准频率学派学习进行训练。

器件随机性 [23]。ECE 和准确率指标
针对 L 的不同取值所示，这些取值决定了噪声平面的大小。图中的主要观察结果是，设置 $L = 16$ 后，在准确率和校准误差两方面都与 8 位定点（FxP8）软件基准相当。相比之下，使用 $L = 1$ 时，由于噪声相关性（见第 III 节），期望校准误差（ECE）出现了显著的性能损失。

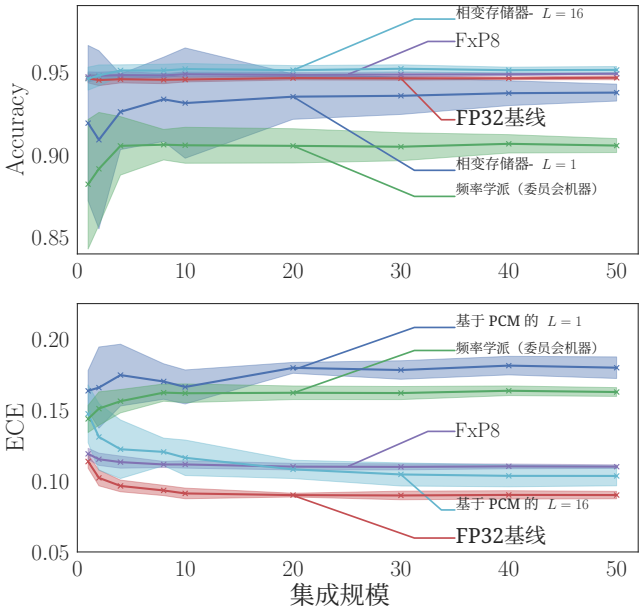


图 5：基于 PCM 的贝叶斯架构在威斯康星乳腺癌数据集上获得的准确率和期望校准误差（ECE），其结果与 8 位定点仿真相当，并优于频率学派（委员会机器）实现。

基于这一观察，我们最终通过比较突触核心的晶体管数量，估算基于 PCM 的架构相较于传统静态随机存取存储器（SRAM）FxP8 实现的面积效率。我们假设权重平面包含 256×256 个权重，噪声平面包含 256×16 个权重。对于互补金属氧化物半导体（CMOS）实现，我们假设采用基于线性反馈移位寄存器（LFSR）的伪随机数生成器（PRNG），其周期足够长，可用于生成伪随机样本。D 触发器的晶体管数量根据文献 [24] 中的方法计算。为此，我们考虑两种实现：第一种由一个 36 位 PRNG 为整个噪声平面提供服务；另一种则在每一行配置一个 22 位 PRNG，类似于所提出的 PCM 设计。对于前一种情况，我们估算基于 PCM 的架构相较于 CMOS 定点设计可减少 9.3× 的面积；对于后一种情况，我们估算晶体管数量可减少 11×。

未来的工作可以探索硬件感知训练，使网络性能能够抵御非理想效应，例如纳米级忆阻器件的有限耐久性和良率。

参考文献

[1] C. Guo, G. Pleiss, Y. Sun, and K. Q. Weinberger, “现代神经网络的校准”，载于机器学习国际会议。PMLR，2017年，页码 1321–1330。[2] P. Shukla, A. Shylendra, T. Tulabandhula, and A. R. Trivedi, “Mc^{2}ram：用于快速贝叶斯推理的静态随机存取存储器中的马尔可夫链蒙特卡罗采样”，载于2020年IEEE国际电路与系统研讨会（ISCAS）。IEEE，2020年，页码 1–5。[3] C. Blundell, J. Cornebise, K. Kavukcuoglu, and D. Wierstra，“神经网络中的权重不确定性”，载于机器学习国际会议。PMLR，2015年，页码 1613–1622。[4] A. G. Wilson，“支持贝叶斯深度学习的理由”，arXiv 预印本 arXiv:2001.10995，2020年。[5] H. Jang, N. Skatchkovsky, and O. Simeone，“BiSNN：通过贝叶斯学习训练具有二值权重的脉冲神经网络”，载于2021年IEEE数据科学与学习研讨会（DSLW）。IEEE，2021年，页码 1–6。[6] K. Yang, A. Malhotra, S. Lu, and A. Sengupta，“全自旋贝叶斯神经网络”，IEEE电子器件汇刊，第67卷，第3期，页码 1340–1347，2020年。[7] R. Cai, A. Ren, N. Liu, C. Ding, L. Wang, X. Qian, M. Pedram, and Y. Wang，“VIBNN：贝叶斯神经网络的硬件加速”，ACM SIGPLAN 通知，第53卷，第2期，页码 476–488，2018年。[8] B. Li, B. Yan, and H. Li，“面向数据密集型应用的新兴非易失性存储器存内处理概述”，载于2019年大湖区超大规模集成电路研讨会论文集，2019年，页码 381–386。[9] V. Joshi, M. Le Gallo, S. Haefeli, I. Boybat, S. R. Nandakumar, C. Piveteau, M. Dazzi, B. Rajendran, A. Sebastian, and E. Eleftheriou，“利用计算型相变存储器实现准确的深度神经网络推理”，《自然·通讯》，第11卷，第1期，页码 1–13，2020年。[10] S. R. Nandakumar, M. Le Gallo, I. Boybat, B. Rajendran, A. Sebastian, and E. Eleftheriou，“用于神经形态计算的相变存储器模型”，《应用物理学杂志》，第 124，15，152135, 卷。期。2018 [ ] 10 1063 1 页码。在线。可访问：https://doi.org/。/。5042408 [11] T. Dalgaty, N. Castellani, C. Turck, K.-E. Harabi, D. Querlioz, and E. Vianello，“利用忆阻器固有变异性通过马尔可夫链蒙特卡罗采样进行原位学习”，《自然·电子学》，第4卷，第2期，页码 151–161，2021年。[12] T. Salimans, D. Kingma, and M. Welling，“马尔可夫链蒙特卡罗与变分推断：弥合差距”，载于机器学习国际会议。PMLR，2015年，页码 1218–1226。[13] H. Jang, O. Simeone, B. Gardner, and A. Gruning，“概率脉冲神经网络简介：概率模型、学习规则与应用”，《IEEE信号处理杂志》，第36卷，第6期，页码 64–77，2019年。[14] M. Davies, A. Wild, G. Orchard, Y. Sandamirskaya, G. A. F. Guerra, P. Joshi, P. Plank, and S. R. Risbud，“借助 Loihi 推进神经形态计算：成果综述与展望”，《IEEE会刊》，第109卷，第5期，页码 911–934，2021年。[15] B. Rajendran, A. Sebastian, M. Schmuker, N. Srinivasa, and E. Eleftheriou，“用于信号处理应用的低功耗神经形态硬件：架构与系统级设计方法综述”，《IEEE信号处理杂志》，第36卷，第6期，页码 97–110，2019年。[16] P. A. Merolla, J. V. Arthur, R. Alvarez-Icaza, A. S. Cassidy, J. Sawada, F. Akopyan, B. L. Jackson, N. Imam, C. Guo, Y. Nakamura, B. Brezzo, I. Vo, S. K. Esser, R. Appuswamy, B. Taba, A. Amir, M. D. Flickner, W. P. Risk, R. Manohar, and D. S. Modha，“具有可扩展通信网络和接口的百万脉冲神经元集成电路”，《科学》，第345卷，第6197期，页码 668–673，2014年。[17] N. Skatchkovsky, H. Jang, and O. Simeone，“通过脉冲神经网络实现贝叶斯持续学习”，《神经科学前沿》，即将发表，2022年。[18] B. Rajendran, A. Sebastian, and E. Eleftheriou，“构建新一代人工智能系统：算法、架构与纳米级忆阻器件的协同优化”，载于2019年IEEE第11届国际存储器研讨会（IMW）。IEEE，2019年，页码 1–4。[19] N. Papandreou, H. Pozidis, A. Pantazi, A. Sebastian, M. Breitwisch, C. Lam, and E. Eleftheriou，“多级相变存储器的编程算法”，载于2011年IEEE国际电路与系统研讨会（ISCAS）。IEEE，2011年，页码 329–332。[20] M. E. Khan and H. Rue，“贝叶斯学习规则”，arXiv 预印本 arXiv:2107.04562，2021年。

[21]E. Jang、S. Gu 和 B. Poole，《使用 Gumbel-softmax 的分类重参数化》，载于国际学习表征会议，2017年。 [在线]。可访问：https://openreview.net/ forum?id=rkE3y85ee [22] J. Kaiser、H. Mostafa 和 E. Neftci，《用于深度连续局部学习（DECOLLE）的突触可塑性动力学》，《神经科学前沿》，第14卷，第424页，2020年。[23] D. Joksas、P. Freitas、Z. Chai、W. H. Ng、M. Buckwell、C. Li、W. Zhang、Q. Xia、A. Kenyon 和 A. Mehonic，《委员会机器——处理基于忆阻器的神经网络中非理想性的一种通用方法》，《自然·通讯》，第11卷，第1期，第1–10页，2020年。[24] E. L˚ate、A. A. Vatanjou、T. Ytterdal 和 S. Aunet，《28 20、2017 48、11 nm FDSOI 亚阈值应用中触发器架构的扩展比较分析》，《微处理器与微系统》，第 卷，第 – 页。