自组装神经形态硬件的安全性

Can Rager*
Clipco Ltd.

Kyle Webster，博士
Clipco Ltd.

摘要

现代计算硬件的可扩展性受物理瓶颈和高能耗限制。受人脑启发的神经形态硬件（NMH）有望解决这些限制。NMH 能够在硬件层级实现物理内置的信息处理能力。换言之，类脑特征使硬件在规模扩大时更趋于智能。在表1中，我们根据计算设备的扩展能力（可扩展性特征）和对脑启发概念的采用程度（神经形态特征）进行比较。神经形态计算范式要求采用全新的方法来实现安全、可解释的人工智能。为了有效应对目标错位的人工智能带来的风险，安全研究可能需要拓展范围，将神经形态硬件纳入其中。支持目前从事神经形态硬件能力研究的人员开展安全及相关领域的工作，或许是实现这一目标的最佳方式。

表1：**计算硬件的比较**。人脑 [1]–[5] 与神经形态硬件（原子开关网络） [6]–[9] 以及现代图形处理器（NVIDIA A100 PCIe 80GB） [10]的比较。神经形态硬件的能效高于现代图形处理器，同时也具备受大脑启发的特性。请注意，目前控制纳米线网络方面的挑战限制了其应用场景 [11]。正如第3节和第7节所述，克服这些挑战可能会加剧我们的担忧。

	人脑	**神经形态硬件**	**GPU**
可扩展性特征			
节点密度	2.3×10^5 /mm^3	10^7 /mm^2	6.6×10^7 /mm^2
信号速率（最大值）	338(10) 赫兹	10^9 赫兹	1.6×10^9 赫兹
节点数量	$8.6(8) \times 10^{10}$	1.6×10^8	5.42×10^{10}
每个节点的连接数	7×10^3（每个神经元）	4	4（每个逻辑门）
计算活动	7.7 × 10^8 赫兹 / mm^3	10^{16} 赫兹/ mm^2	1.1×10^{17}赫兹/ 毫米^2
能耗	10^{-13} 焦耳/浮点运算	10^{-14} 焦耳/浮点运算	10^{-12} 焦耳/浮点运算
神经形态特征			
自组装	yes	yes	no
可塑性	yes	开发中	no
基于脉冲的计算	yes	开发中	no
临界性	yes	yes	no
忆阻行为	yes	yes	no
存内计算	yes	开发中	no

* 通信请联系 can.rager@gmail.com

1. 纳米线网络简介

生物脑具有空间结构复杂的特点（图1a）。这一结构启发了由高度互连的纳米线构成的计算硬件设计（图1b）。导线的非确定性排列通过自组装形成：网络完全由单根纳米线之间的微观相互作用塑造 [12]。

纳米线之间的交叉点结使电信号能够在网络中传播。图1c展示了放置在带有多个读出端口的芯片上的纳米线网络。通过网络输入和测量电信号，即可实现信息处理。此外，纳米线的动态特性使硬件层级能够实现短期存储。网络可塑性（通过经验在结构和功能上重组网络的能力）由两种机制决定 [9]:

1. 通过操纵结点的电导率进行重新加权（图1d、1e）。2. 通过迫使单根纳米线断裂或重新连接进行重新布线（图1f、1g）。

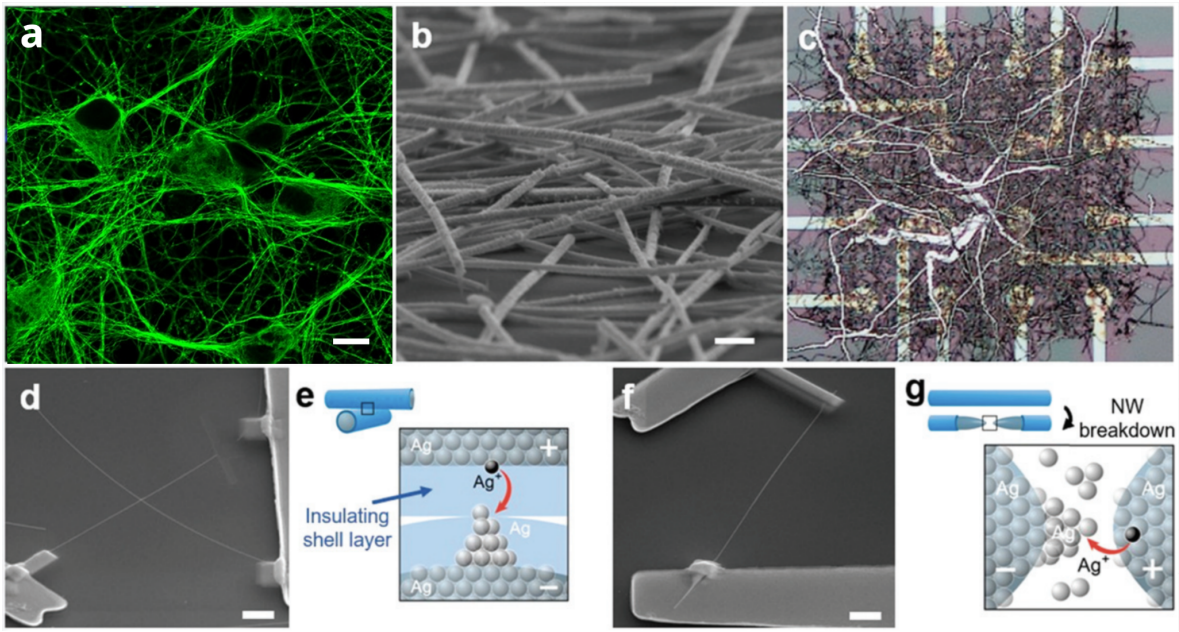


图1：**大脑结构与纳米线网络**。（**a**）生物神经网络：培养6天后经β-III-微管蛋白染色的小鼠海马体神经元（比例尺， 10 μm）。改编自 [13], [14]。（**b**）受生物启发的忆阻纳米线网络（比例尺，500 nm）。根据知识共享署名4.0国际许可协议改编自 [9] ，版权所有 © 2020 Wiley-VCH。（**c**）放置在带有多个读出端口的芯片上的银线原子开关网络。改编自 [6], ，版权所有 © 2013 IOP出版社。（**d**）和（**e**）单个纳米线结器件，其忆阻机制依赖于在外加电场作用下，于相交纳米线的金属芯之间形成/断裂金属导电细丝；以及（**f**）和（**g**）单个纳米线器件，其开关机制是在纳米线沿线发生电击穿并形成纳米间隙后，由金属离子穿过该间隙的电迁移所致。图像和说明根据知识共享署名4.0国际许可协议改编自 [9], [11] ，版权所有 © 2022 IOP出版社。

据我们所知，目前还不存在完全依赖重新加权 和重新布线 的训练算法。在第3节中，我们将论证，对可塑性的控制是纳米线人工智能应用的主要瓶颈。对可塑性进行系统优化需要取得以下进展：

列表 1：控制纳米线可塑性的当前挑战 [6]。

- 增加纳米线器件中功能性输入/输出端口的数量
- 设计接口（例如，将图像转换为随时间变化的电输入信号）
- 选择具备短期和长期记忆能力的最佳材料
- 对不同尺度下的结点电导率和开关行为进行建模
- 了解尺度不变性和临界性对涌现智能的影响

1.1 潜在应用场景：利用纳米线器件实现高效推理 s

纳米线有望成为推理设备的新标准。我们首先介绍一种现有的训练框架，它可能适用于纳米线。随后，我们重点说明纳米线为何可能在制造成本、能效和计算速度方面优于常见硬件。

训练框架。 反向传播已成功应用于人们充分了解的物理系统：物理感知训练（PAT）使晶体和麦克风能够完成音频和图像分类任务 [15]。在此，外部数字设备将可训练参数作为单独的输入馈入系统。参数通过反向传播进行优化。确定最优参数后，便不再需要外部数字设备。此时，物理系统便能独立执行推理。由于训练过程由单独的设备负责，物理系统本身可以针对推理进行优化。事实上，经过 PAT 训练的物理系统在能效和执行时间方面优于现代图形处理器上的推理[15]。

一旦清单1中的问题得到更深入的理解，纳米线网络将成为物理感知训练的合适候选方案。事实证明，在一项类似的应用中，纳米线的表现优于静态系统（基于储备池计算的图像分类基准测试 [7]；更多储备池计算的详细信息见第7节）。因此，纳米线可能成为物理感知训练应用的主要候选方案。

制造成本。图形处理器等常见硬件需要采用精确的交叉阵列结构才能正常运行。这种特定设计要求达到较高的制造标准，例如具备洁净室设施和高精度纳米光刻技术 [16]。相比之下，纳米线网络等自组装硬件不需要预先明确规定的架构 [9]。纳米线网络通过将悬浮液中的一滴纳米线浇铸到绝缘表面上制成。这种技术会为每个新器件形成独特的单根纳米线排列。以多种不同形态作为网络训练的起点，都能实现计算能力。这表明该技术能够适应不纯净的制造环境。因此，与常见图形处理器相比，自组装有望降低硬件的生产成本。低成本制造的这一潜力也进一步支持了在物理感知训练应用中采用纳米线技术。

能效与计算速度。纳米线网络中的基于脉冲的计算模拟了时变信号在人脑中的传播 [17]。在这里，部分

输入通过信号时序编码。与深度神经网络相比，这使输入信号总量得以减少 [18]–[20]。总信号量的减少带来了能耗的降低。每个节点拥有更多连接，还能进一步加快推理速度。规模化的基于脉冲的网络已在非自组装神经形态硬件中实现 [21], [22]。其应用达到了最先进水平，同时将能耗降低了两个数量级 [23]。这与安全研究的现状可能存在重要联系，因为据我们所知，目前还没有专注于基于脉冲的计算的可解释性研究。不过，具备适当条件的能力研究人员可以着手研究这一问题，这或许能补充由专注于算法的研究人员在基于脉冲的系统方面开展的工作。据我们所知，目前没有工作专注于这两个特定领域中的任何一个。

其次，存内计算是神经形态硬件的一项关键特征。在现代硬件设计中，存储器与处理单元相分离是一种标准做法 [24]。这种架构要求在两个单元之间传输数据，从而限制了整体执行速度（也称为冯·诺依曼瓶颈）。受人脑启发，存内计算克服了这一瓶颈。理想的存内处理器利用模拟存储单元，以 [25] 为代价实现 $\mathcal{O}(1)$时间复杂度的矩阵向量乘法（相比之下，常见处理器的时间复杂度为 $\mathcal{O}(N^2)$）。这种范式有望将能效和计算速度提高两个数量级 [26], [27]。有限的实验进展已证明存内处理器切实可行，并指明了改进方向[28], [29]。

2. 将映射问题置于当前技术现状之中

先进的神经形态硬件带来了一系列值得关注的问题。在本节中，我们将以削弱人类自主性的人工智能为例，讨论可解释性和能力。

可解释性。 可解释性能够显著提高人工智能系统造福所有利益相关者的可能性，尤其是在复杂应用中。不可解释模型会使审计流程更加困难，并可能导致非预期且削弱人类自主性的决策。

进一步研究神经形态硬件的物理动力学，在我们看来有助于提升其可解释性。理解模拟存储单元的大尺度动力学，是实现模型可解释性的必要步骤。纳米线网络尤其适合用于研究：其自组装结构有助于深入了解尺度支配的动力学——哺乳动物大脑中也观察到了这种动力学 [30]。

关于大语言模型涌现行为的人工智能研究明确提出了缩放定律[31]–[33]。这些定律或许能为神经形态硬件的大尺度开关动力学提供有价值的见解。我们建议神经形态硬件研究与可解释性工作更加紧密地结合（例如 Anthropic 和 Redwood Research 开展的相关工作）。

目标不一致的通用人工智能。根据缩放假说 [34], , 将基础的、能力狭窄的 AI 模型扩展后，会涌现出泛化能力和复杂行为。越来越多的研究人员担忧通用人工智能（AGI）可能会涌现 [35]。AGI 能够设定并执行工具性子任务，以实现目标。默认情况下，AGI 可能会将寻求权力作为工具性子任务，以实现人类设定的几乎任何总体目标。这种行为可能导致人类丧失自主权，并对人类构成生存风险 [36]。

当前的纳米线网络表现出明显的短期记忆 [7]。这降低了其具备长期自优化能力的可能性。然而，研究人员应根据能力跟踪这一风险

，因为硬件的进步既在预期之中，也已逐步实现。要有效应对新兴风险，可能需要在新技术实现之前采取行动，即使是在相对受控的研究环境中。

神经形态特征是否会使先进人工智能倾向于**意识** 仍是一个悬而未决的问题。有意识系统的泛化能力可能会增加目标错位的通用人工智能带来的风险。我们认为，进一步探究这些主张是一个有效的研究领域，但已将其排除在本文讨论范围之外。

3. 可能加剧或减轻安全担忧的发展

本节将介绍可能加剧第2节所述担忧的发展。

纳米线网络中**长期记忆** 的发展，有望支持训练过程中的反馈回路。这可能会增加目标错位的人工智能带来的风险。此外，**控制纳米线可塑性** 的能力对于实现人工智能应用至关重要。如表1所示，神经形态硬件的物理可扩展性已可与现代图形处理器相媲美。一旦能够进行可塑性训练，纳米线网络就有望成为可轻易扩展的人工智能应用硬件。在相关挑战（列表1）上取得进展，将提高实现可控纳米线网络的可能性。

我们预计，纳米线器件将如第1.2节所述，借助外部数字设备进行训练（物理感知训练）。这一外部训练设备可作为有用的参照，帮助进一步了解纳米线动力学。因此，**利用纳米线进行物理感知训练** 的实现情况，以及此类系统的性能和其他属性，将为通用人工智能风险评估提供额外的数据来源。

自组装网络所需的制造标准可能低于传统计算机芯片 [9]。向研究人员（最初）以及业余爱好者（之后）提供用于生产自组装纳米线介质硬件的台式**制造设备或“套件”**，将加剧人们对先进人工智能的担忧。较低的生产门槛将使更广泛的人群能够参与自组装纳米线介质硬件的实验性开发。易于获取的制造设备可能会增加双重用途风险，因为这会加快神经形态硬件的发展，并增加单方面行动的风险。此外，这种易得性可能会加剧先进人工智能领域的竞赛动态。这种情况将使政府机构或第三方更难监控人工智能的进展。目前，在生物安全和3D打印武器领域也能看到类似的担忧。

临界性可能是纳米线网络中智能的一种指标。“临界性这一概念指系统处于有序态与无序态之间的临界点，类似于相变。” [30]。多项研究表明，临界动力学可能在生物系统的信息处理和任务表现中发挥作用 [37]–[39]。然而，临界性与智能之间的关系尚不明确。临界性适用于纳米线网络的电阻。若电阻过高，电信号释放后很快就会消失。同样，若电阻过低，单个信号就可能引发信号雪崩，并在整个网络中传播。网络的临界状态介于这两种极端情况之间。纳米线网络的临界电阻最适合进行信息处理[7]。深入了解临界系统将有助于监测神经形态硬件的能力。

4. 将 AI 对齐工作映射到神经形态网络 s

近期发表的研究中，最成功的人工智能模型是大规模扩展的软件架构 [40]–[42]。自然，AI对齐工作也聚焦于大型软件架构。然而，计算硬件向神经形态硬件转变的范式转移，可能以意想不到的方式重塑人工智能格局。随着现代计算硬件遭遇物理瓶颈，而利用物理系统进行计算可能在执行时间、能量和数据方面实现更高效率（第3节），这一转变将会加速。这种转变要求AI安全研究拓宽其以软件为中心的范围，将硬件可预测性纳入其中。

在近期的一篇综述 [11]，中，工业界和学术界的研究者介绍了神经形态计算的最新进展。他们在长达97页的内容中，仅用一个段落讨论了目标错位的人工智能所带来的担忧。这表明，神经形态计算研究仍然忽视 AI安全。

我们认为，对神经形态硬件的投资很可能源于其提升能效、加快计算速度和降低制造成本的前景。如果工业界的资金投入增加，我们预计利润最大化激励将使能力优先于安全 [43]。鉴于第2节所述的担忧，我们建议资助现有的能力研究人员开展神经形态硬件安全研究，并在有益时与现有的安全研究群体合作。这样可以确保硬件可解释性等领域的研究得到相关系统深厚技术知识基础的支持，同时让当前的安全研究人员在相对成熟的人工智能软件领域中，仅需对紧迫工作作出有限取舍。

5. 反驳观点

1. 神经形态硬件的发展速度太慢，不足以产生影响。在神经形态硬件能够应用于现实世界任务之前，其他进展就会决定通用人工智能的发展方向。

   简短回应： 我们欢迎技术预测专家评估：在与通用人工智能相关的时间范围内，神经形态硬件的能力达到可与传统方法竞争的水平，其可能性有多大，以及可能造成多大影响。据我们所知，此类评估尚未发表。

2. 我们或许能够使用经典硬件模拟神经形态硬件。因此，针对神经形态硬件的安全研究可直接映射到经典硬件已有的安全研究上。神经形态硬件安全无需专门关注。

   简短回应： 大规模模拟物理系统往往不可行。此外，PAT训练框架无法直接映射到深度神经网络[15]。即使能够理想地模拟神经形态硬件，也仍需要新的可解释性方法。

3. 我们将能够实时重组网络的自组装机制列为通用人工智能安全领域的一项关键关注。不过，自适应可塑性尚未得到实验

结果的支持。在这种情况出现之前，将研究精力投入神经形态硬件并不值得为此付出机会成本。

简短回应：与我们对反驳论点 1 的回应一致，我们欢迎对这一领域进一步研究的成本效益进行评估。我们预计，此处所述网络重组开发的进展速度存在很大的不确定性。

4. 迄今为止，大多数神经形态网络都只在专业实验室中制造。在进一步研究中，我们可能会发现制造方面的重大要求，这些要求会使自组装神经形态计算芯片难以实现低成本、便捷的生产。

简短回答：如果创建网络严格依赖昂贵的设备或技术（例如电子显微镜或光刻），情况很可能就是如此。不过，在分子生物学领域，过去只有能力最强、资源最充足的实验室才能实现的技术，正逐渐走向普及化。这个过程可以从“产品化”技术开始，借助相对易用的开源软件和湿实验室套件，帮助其他科学家复现实验结果。随后，实用研究技术可能会走向商业化，最终通过向业余爱好者公开销售套件，实现全面普及。如果纳米线在开发达到实用或有趣的阶段时，无需昂贵的制造设备，那么也可能出现类似的过程。

6. 附录

每个节点的连接数。 对于大脑，我们使用每个神经元的平均突触连接数。对于原子开关网络，我们使用每个结点直接连接的结点数。对于图形处理器，我们使用每个逻辑门的扇出值。

硬件之间能耗的可比性。人脑的能耗是按平均大脑20瓦的功耗计算得出的 $\frac{power\ consumption}{synaptic\ firing\ frequency * \#FLOP\ per\ synaptic\ operation}$ 。对于互连纳
的单次输入脉冲（而非重复尖峰）的数值。每次操作的能耗按以下方式计算：。我们预计，一旦获得纳米线网
得到更 $\frac{total\ energy\ per\ input\ pulse}{\#junctions}$ 可比的数值。人工突触的一次独立突触操作每次需要10^{-15} 焦耳 [44]。这表明
升的潜力。现代图形处理器每次浮点运算（FLOP）消耗10^{-12} 焦耳。神经形态硬件与现代计算硬件所采用的算法
因此，只有针对特定任务，神经形态硬件与图形处理器的基本操作能耗才具有可比性。我们针对图像分类任务
[45] 确定了对MNIST数据集中的手写数字进行分类所需的基本操作次数。他们对脉冲神经网络（SNN，即神经
经网络（CNN）都进行了基准测试。我们得出的换算率为1次突触操作对应≈ 10 次浮点运算。请注意，对于其
我们选择纳米线来代表表1中的神经形态硬件，因为它们具备多种神经形态特征 [11]。

储备池计算 在预测算法中将随机网络结构用作黑箱 [46]。纳米线网络通过储备池计算成功实现了图像识别 [7]。纳米线与浅层交叉阵列芯片相结合，成功完成了图像识别 [7], 、语音识别 [47] 及其他任务 [6], [48]。我们认为，纳米线很可能会发展成为独立的推理设备，初期由外部数字训练器进行训练（见下文的物理感知训练）。将未知的网络结构嵌入人工智能，会给模型可解释性带来重大挑战。

物理感知训练。 智能系统不受特定设计硬件的限制。Wright等人 [15] 提出了一种适用于**任意物理系统**的通用训练算法，称为物理感知训练（PAT）。其应用包括模拟麦克风和光学元件。尽管该算法在训练时使用数字模型，但应用物理系统的主要优势体现在推理过程中：与现代基于晶体管的硬件相比，执行时间和能耗可降低多个数量级，同时仍能达到有竞争力的准确率。

表征学习有望在算法层面提升神经形态硬件的数据处理能力和计算效率。单个数据点会映射为神经形态硬件中的一种特定表征。可能的表征数量会随着硬件节点数量的增加而呈指数级增长。旨在实现高效信息表征的研究计划有望降低对数据和计算的需求（即每个数据样本带来的性能增益更高）。与此同时，表征学习研究也推动了硬件可解释性的发展。此外，表征学习可能会影响传感器设计。它将规定传感器数据输出的格式要求，以实现

在神经形态硬件中进行高效处理，并缩短传感器与计算硬件之间的反馈回路。据我们所知，目前尚无针对神经形态硬件的表征学习研究。

7. 参考文献

[1] J. Kelly 和 M. Hawken，《利用共聚焦图像堆栈的自动三维分析量化皮层深度方向的神经元密度》，《脑结构与功能》，第 222 卷，2017 年 9 月，doi：10.1007/s00429-017-1382-6。[2] B. Wang 等人，《人类、猴和小鼠新皮层快速放电神经元的放电频率峰值》，《细胞神经科学前沿》，第 10 卷，239 页，2016 年 10 月，doi：10.3389/fncel.2016.00239。[3] F. A. C. Azevedo 等人，《数量相同的神经元细胞和非神经元细胞使人脑成为等比例放大的灵长类脑》，《比较神经学杂志》，第 513 卷，第 5 期，第 532–541 页，2009 年 4 月，doi：10.1002/cne.21974。[4] D. A. Drachman，《我们的大脑是否有富余？》，《神经病学》，第 64 卷，第 12 期，第 2004–2005 页，2005 年 6 月，doi：10.1212/01.WNL.0000166914.38327.BB。[5] V. Balasubramanian，《脑力》，《美国国家科学院院刊》，第 118 卷，第 32 期，文章 e2107022118，2021 年 8 月，doi：10.1073/pnas.2107022118。[6] H. Sillin 等人，《用于储备池计算的神经形态原子开关网络理论与实验研究》，《纳米技术》，第 24 卷，384004 页，2013 年 9 月，doi：10.1088/0957-4484/24/38/384004。[7] G. Milano 等人，《基于自组织纳米线网络的全忆阻架构材料内储备池计算》，《自然·材料》，第 21 卷，第 2 期，第 195–202 页，2022 年 2 月，doi：10.1038/s41563-021-01099-9。[8] A. Diaz-Alvarez 等人，《神经形态纳米线网络的涌现动力学》，《科学报告》，第 9 卷，第 1 期，文章 14920，2019 年 12 月，doi：10.1038/s41598-019-51330-6。[9] G. Milano 等人，《通过多端自组织忆阻纳米线网络中的重新加权与重新布线实现脑启发结构可塑性》，《先进智能系统》，第 2 卷，第 8 期，文章 2000096，2020 年 8 月，doi：10.1002/aisy.202000096。[10]《NVIDIA A100 PCIe 80 GB 规格》，TechPowerUp。https://www.techpowerup.com/gpu-specs/a100-pcie-80-gb.c3821（访问于2022年12月23日）。[11] D. V. Christensen 等人，《2022年神经形态计算与工程路线图》，《神经形态计算与工程》，第 2 卷，第 2 期，文章 022501，2022 年 5 月，doi：10.1088/2634-4386/ac4a83。[12] G. Milano、S. Porro、I. Valov 和 C. Ricciardi，《基于金属氧化物纳米线的忆阻器件：最新进展与展望》，《先进电子材料》，第 5 卷，第 9 期，文章 1800909，2019 年，doi：10.1002/aelm.201800909。[13] F. Tomassoni-Ardori、Z. Hong、G. Fulgenzi 和 L. Tessarollo，《功能性小鼠海马神经元的生成》，《生物实验方案》，第 10 卷，第 15 期，第 e3702–e3702 页，2020 年 8 月，访问于：2022年10月7日。

[ ] 3702 在线 . 可用：
[14] 1
https://bio-protocol.org/e F. Tomassoni-Ardori 等人，《Rbfox 上调通过扰乱 TrkB异构体表达水平损害 BDNF依赖性海马长时程增强》，《eLife》，第 8 卷，文章 e49673，2019 年 8 月，doi：10.7554/eLife.49673。[15] L. G. Wright 等人，《通过反向传播训练的深度物理神经网络》，《自然》，第 601 卷，第 7894 期，文章编号 7894，2022 年 1 月，doi：10.1038/s41586-021-04223-6。[16]《微芯片是如何制造的 | ASML》。
https://www.asml.com/en/technology/all-about-microchips/how-microchips-are-made（访问于2022年10月9日）。[17] M. Pfeiffer 和 T. Pfeil，《脉冲神经元深度学习：机遇与挑战》，《神经科学前沿》，第 12 卷，2018 年，访问于：2022年10月10日。[在线]。可用：
https://www.frontiersin.org/articles/
10 3389 2018 00774 。/fnins。 . C. Lee、S. S. Sarwar、
[18]
P. Panda、G. Srinivasan 和 K. Roy，《实现基于脉冲的

用于训练深度神经网络架构的反向传播》，《神经科学前沿》，第 14, 2020, 10, 2022 [ ] 访问于：10 月。在线 . 可用：https://www.frontiersin.org/articles/ 10 3389 2020 00119 。/fnins。 . T. C. Wunderlich 和 C. [19] Pehle，《基于事件的反向传播能够为脉冲神经网络计算精确梯度》，《科学报告》，第 11 卷，第 1 期，文章编号 1，2021 年 6 月，doi：10.1038/s41598-021-91786-z。[20] K. Roy、A. Jaiswal 和 P. Panda，《通过神经形态计算迈向基于脉冲的机器智能》，《自然》，第 575 卷，第 7784 期，文章编号 7784，2019 年 11 月，doi：10.1038/s41586-019-1677-2。[21] N. Imam 和 T. A. Cleland，《神经形态嗅觉电路中的快速在线学习与稳健回忆》，《自然·机器智能》，第 2 卷，第 3 期，文章编号 3，2020 年 3 月，doi：10.1038/s42256-020-0159-4。[22] P. Zuliani、A. Conte 和 P. Cappelletti，《用于嵌入式非易失性存储器应用的相变存储器方案》，2019 年 VLSI 技术研讨会，第 T192–T193 页，2019 年，doi：10.23919/VLSIT.2019.8776502。[23] 《LaneSNNs：用于 Loihi 神经形态处理器车道检测的脉冲神经网络》，DeepAI，2022 年 8 月 3 日。htt ps://deepai.org/publication/lanesnns-spiking-neural-networks-for-lane-detection-on-the-loihi-neuromorphic-processor（访问于2022年10月10日）。[24] 《冯·诺依曼架构》，维基百科。2022 年 9 月 16 日。访问于：2022年10月10日。[在线]。可用：https://en.wikipedia.org/w/index.php?title=Von_Neumann_architecture&oldid=1110615949# 冯·诺依曼瓶颈[25] Z. Sun 和 R. Huang，《存内矩阵向量乘法的时间复杂度》，《IEEE 电路与系统汇刊 II：简报》，第 68 卷，第 8 期，第 2785–2789 页，2021 年 8 月，doi：10.1109/TCSII.2021.3068764。[26] A. Sebastian、M. Le Gallo、R. Khaddam-Aljameh 和 E. Eleftheriou，《存内计算的存储器件与应用》，《自然·纳米技术》，第 15 卷，第 7 期，文章编号 7，2020 年 7 月，doi：10.1038/s41565-020-0655-z。[27] S. Ambrogio 等人，《利用模拟存储器实现等精度加速神经网络训练》，《自然》，第 558 卷，第 7708 期，文章编号 7708，2018 年 6 月，doi：10.1038/s41586-018-0180-5。[28] M. Dazzi、A. Sebastian、L. Benini 和 E. Eleftheriou，《利用存内计算加速卷积神经网络推理》，《计算神经科学前沿》，第 15 卷，2021 年，访问于：2022年12月17日。 [在线]。可用：https://www.frontiersin.org/articles/ 10 3389 2021 674154 。/fncom。 . A. Boroumand 等人，[29] 《面向消费设备的 Google 工作负载：缓解数据移动瓶颈》，《ACM SIGPLAN 通知》，第 53 卷，第 316–331 页，2018 年 3 月，doi：10.1145/3296957.3173177。[30] C. S. Dunhamet 等人，《纳米尺度神经形态网络与临界性：观点》，《物理复杂性杂志》，第 2 卷，第 4 期，文章 042001，2021 年 12 月，doi：10.1088/2632-072X/ac3ad3。[31] J. Wei 等人，《大语言模型的涌现能力》。arXiv，2022 年 10 月 26 日。doi：10.48550/arXiv.2206.07682。[32] T. Henighan 等人，《自回归生成建模的缩放定律》。arXiv，2020 年 11 月 5 日 10 48550 2010 14701。doi：。/arXiv。。.[33] J. Kaplan 等人，《神经语言模型的缩放定律》。arXiv，2020 年 1 月 22 日。doi：10.48550/arXiv.2001.08361。[34] G. Branwen，《缩放假说》，2020 年 5 月，访问于：2022年10月8日。[在线]。可用：https://www.gwern.net/Scaling-hypothesis [35] 《奇点何时会到来? 995 位专家对通用人工智能的看法》。https://research.aimultiple.com/artificial-general-intelligence-singularity-timing/（访问于2022年12月18日）。[36] S. Russell，《人工智能与控制问题》，《数字人文主义展望》，第 19 页，2022 年。

[37] L. Cocchi、L. L. Gollo、A. Zalesky 和 M. Breakspear，《大脑临界性：神经生物学、模型与认知的综合》，《神经生物学进展》，第 158 卷，第 132–152 页，2017 年 11 月，doi：10.1016/j.pneurobio.2017.07.002。[38] R. V. Solé 等，《进化生态学中的临界性与标度》，《生态学与进化趋势》，第 14 卷，第 4 期，第 156–160 页，1999 年 4 月，doi：10.1016/S0169-5347(98)01518-3。[39] S. Shirai 等，《无标度神经形态网络中的长程时间相关性》，《网络神经科学》，第 4 卷，第 2 期，第 432–447 页，2020 年 4 月，doi：10.1162/netn_a_00128。[40] A. Ramesh、P. Dhariwal、A. Nichol、C. Chu 和 M. Chen，《基于 CLIP 潜变量的层次化文本条件图像生成》。arXiv，2022 年 4 月 12 日。doi：10.48550/arXiv.2204.06125。[41] J. Devlin、M.-W. Chang、K. Lee 和 K. Toutanova，《BERT：面向语言理解的深度双向变换器预训练》。arXiv，2019 年 5 月 24 日。doi：10.48550/arXiv.1810.04805。[42] J. Jumper 等，《利用 AlphaFold 实现高精度蛋白质结构预测》，《自然》，第 596 卷，第 7873 期，文章编号 7873，2021 年 8 月，doi：10.1038/s41586-021-03819-2。[43] S. Russell，《如果我们成功》，《代达罗斯》，第 151 卷，第 2 期，第 43–57 页，2022 年 5 月，doi：10.1162/daed a 01899。

[44] W. Xu、S.-Y. Min、H. Hwang 和 T.-W. Lee，《具有飞焦耳能耗的有机核壳纳米线人工突触》，《科学进展》，第 2 卷，第 6 期，文章编号 e1501326，2016 年 6 月，doi：10.1126/sciadv.1501326。[45] J. López-Randulfe、N. Reeb 和 A. Knoll，《将卷积神经网络转换为脉冲神经网络：每个神经元的脉冲数少于一个》，载于*2022*年认知计算神经科学会议，旧金山，2022 年。doi：10.32470/CCN.2022.1081-0。[46] G. Tanaka 等，《物理储层计算的最新进展：综述》，《神经网络》，第 115 卷，第 100–123 页，2019 年 7 月，doi：10.1016/j.neunet.2019.03.005。[47] S. Lilak 等，《利用神经形态原子开关网络进行材料内储层计算，实现口语数字分类》，《纳米技术前沿》，第 3 卷，2021 年，访问日期：2022 年 11 月 18 日。[在线]。可访问：https://www.frontiersin.org/articles/10 3389 2021 675792 。/fnano. 。

[48] E. C. Demis、R. Aguilera、K. Scharnhorst、M. Aono、A. Z. Stieg 和 J. K. Gimzewski，《用于非常规计算的纳米架构原子开关网络》，《日本应用物理学杂志》，第 55 卷，第 11 期，文章编号 1102B2，2016 年 9 月，doi：10.7567/JJAP.55.1102B2。