

合作是你所需要的全部

Ahsan Adeel^{*†} Junaid Muzaffar^{*} Fahad Zia^{*} Khubaib Ahmed^{*} Mohsin Raza^{*}
Eamin Chaudary^{*} Talha Bin Riaz^{*} Ahmed Saeed^{*}

Abstract

超越“树突民主”，我们引入了“局部处理器的民主”，称为合作者。这里我们将它们在用于强化学习 (RL) 的置换不变神经网络中的能力进行了比较，与基于 Transformer 等机器学习算法（如 ChatGPT）进行了对比。Transformer 基于长期存在的整合和发射“点”神经元的概念，而合作者则受到最近神经生物学突破的启发，表明心智生活的细胞基础依赖于新皮层中对上下文敏感的锥体神经元，这些神经元具有两个功能上不同的点。我们展示了用于 RL 时，基于合作者的算法比基于 Transformer 的算法学习速度更快，即使它们拥有相同数量的参数。

介绍传递相关信息，但不传递无关信息，是生物神经元 [1] 的基本能力：但是神经元如何知道什么是相关的，什么不是？文献 [2] 表明唤醒和注意力的功能之一是增加信噪比 (SNR)，然而，确定什么是相关的（信号）以及什么是不相关的（噪声）是一个难题。例如，对一个大脑区域而言相关的信息可能对其他区域来说无关紧要 [2]。

在文献中，科学家们为人工神经网络 (ANNs) 提出了几种受生物启发的注意力机制 [3]，其中最受欢迎的是 Transformer [4]—ChatGPT 的基础架构。然而，现有的注意力机制基于整合和放电“点”神经元的概念 [5,6]，这些神经元以相同的方式整合所有传入的突触输入来计算细胞激活水平，也被称为“树突民主 (DD)”。

尽管 DD 允许深度网络学习具有多级抽象的信息表示，但它忽视了神经元之间合作的重要性，即单个神经元




图 1. 排列不变 RL 代理 (PyBullet 蚂蚁) 适应感觉替代：合作者与变压器 [4,9]。在一个公平的比较中，拥有相同数量参数的情况下，合作者学习速度远快于变压器。参见演示：将在双盲评审后披露。

无论其对邻近神经元的相关性如何都会传递信息。这导致了前馈 (FF) 传输的矛盾信息，使学习变得困难并增加了能量消耗 [7,8]。

最近的神经生物学突破 [2,10,11] 已经揭示了哺乳动物新皮层中的两点第 5 层锥体细胞 (L5PCs) 利用其顶树突输入作为背景来调节向基树突传输的一致前馈 (FF) 输入。这些研究，包括 [1,12–22]，还设计了针对一致信息传输的背景敏感神经调制转移函数。然而，将感受野 (RF) (或 FF 输入) 必然作为驱动因素的做法，在解决复杂现实世界问题方面未能取得令人满意的结果。尽管单个具有顶树突的两点神经元可以解决仅能通过多层常规人工点神经元解决的异或 (XOR) 问题 [18]，但它们在大规模上如何施展魔力，直到现在仍然是一个谜。

超越 DD，我们通过引入“局部处理器民主 (DoLP)”来解决这个长期存在的问题。被称为合作者的 DoLP 允许局部处理器否决 RF 的主导地位，并赋予来自相邻神经元的背景信息更多权限 [7,8]。在两点神经元中，这

^{*}CMI Lab, University of Stirling, Stirling, UK.

[†]deepCI.org, Parkside Terrace, Edinburgh, UK.

Email: ahsan.adeel@deepci.org

种背景敏感性会根据上下文的相关或不相关放大或抑制 FF 信息的传输。请参见我们的依赖于突发的突触可塑性的尖峰背景敏感两点神经元模拟 [23]：将在双盲评审后披露。

在更细微的层面上，背景敏感处理器利用上下文来估计其对 RF 的看法是否与大多数相邻处理器一致；如果是一致的，则放大 RF 的传输，否则抑制。这种背景敏感神经信息处理是合作性的，它旨在最大化活跃神经元之间的协议，从而减少矛盾信息的传输。

DoLP 可能包含高度影响力的“偏倚竞争”理论的某些方面，该理论是关于注意力和标准化 [24]，以及其生物物理和细胞基础在 [1] 中概述的递归放大 [25]。

在 [7,8] 中，研究人员表明这种上下文敏感的神经信息处理可以比最先进的受点状神经元启发的深度网络更有效地处理大规模复杂的真实世界数据。在这里我们展示了这种方法在用于 RL 的排列不变神经网络中学习速度极快（图 1）[9]。

变压器 vs. 合作者

图 2(A) 展示了最先进的 Transformer 的缩放点积注意力或多重头部注意力，它通过线性变换 (LT) 或非线性变换 (NLT) 使用 RF 的三种不同表示形式来表示查询 (Q)、键 (K) 和值 (V) 矩阵，表达式为 [4]：

$$Attention(Q, K, V) = f(QK^T V) \quad (1)$$

等效点神经元表示的 Transformer 用于排列不变 RL 代理 (PyBullet Ant) 适应感觉替代如图 2(B) [9] 所示。这些点神经元以相同的方式整合所有传入的感觉流，即简单地将所有输入相加，并假设它们对神经元输出的影响机会相同 [5]。

相比之下，提出的合作者网络（图 2(C)）使用一种合作的上下文敏感神经信息处理机制 [7]，其中合作的上下文敏感神经处理器（图 2(D)）接收两组功能上不同的输入。一组提供关于神经元传递的信息：RF。另一组提供邻近神经元对 RF 作为上下文的意见。这些处理器使用上下文来放大或抑制相关或不相关信息的传输，分别地。具体来说，这里对传感器 1 敏感的神经元从同一神经网络 (NN) 中的相邻神经元接收近端上下文 (P)，从距离较远网络部分中对传感器 2-N 敏感的远端神经元作为远端上下文 (D) 接收信息，并将所有可能的输入对作为普遍上下文 (U)。该神经元通过异步调节

传输函数等式 (2) [7] 使用整合的上下文 (C)，选择性地放大和抑制相关的传感器 1 信息以及不相关信息的前馈传输。其他所有神经元同样适用。

这个新的异步调制传输函数 (AMTF)，称为“合作方程”，可以定义为：

$$Cooperation(R, C) = f(R^2 + 2R + 2C(1 + |R|)) \quad (2)$$

该合作方程强制执行局部处理器的‘民主’，能够否决异常值。在这个方程中，C 是决定是否放大或抑制信息传输的动力 [7]。具体来说，单个神经元将 C 用作一种“调制力”，如果 R 相关，则推动神经元输出朝激活函数的正侧（例如整流线性单元 (ReLU)），否则朝负侧。本质上，如果 R 强或弱，C 可以抑制或鼓励神经活动的放大 [7]。该机制增强了合作，并力求最大化活跃神经元之间的协议。

以下是其他人提出的替代的成熟 AMTFs [1,20]。在这些 AMTFs (T_{Ms}) 方程 (3-6) 中，R 是驱动力，即如果 R 不存在或很强，C 就不起作用。

$$T_{M1}(R, C) = \frac{1}{2}R(1 + \exp(RC)) \quad (3)$$

$$T_{M2}(R, C) = R + RC \quad (4)$$

$$T_{M3}(R, C) = R(1 + \tanh(RC)) \quad (5)$$

$$T_{M4}(R, C) = R(2^{RC}) \quad (6)$$

在本例中使用的多感官 RL 情况下，R、P 和 D 是传感器 1-N 的函数，即输入 $x \in R^N$ （例如，任何 LT 或 NLT），U 是与 R、P 和 D 维度相匹配的位置编码 [4] 的输出。对于置换不变性 (PI)，U 独立于输入 x ，使得仅置换 x 只影响 P 和 D 但不影响 U，这使输出具有置换不变性 [9]。如 [9] 中全面解释的那样，个体感觉输入 1-N 或观察值 O_t^i ， $i=1, 2, \dots, N$ 以及之前的动作 a_{t-1} 以任意顺序通过一个神经网络模块，使得每个神经网络只能部分访问代理在时间 t 的观察结果，并且 i^{th} 神经元




图 2. (A) 点神经元基础的 Transformer。缩放点积注意力或多重头注意力 [4] 用于建模置换不变的 RL 代理 [9]。(B) 点神经元基础的置换不变 PyBullet Ant RL 代理的简单表示。这些点神经元仅仅是将所有输入相加，假设它们对神经元输出的影响概率相同。(C) 上下文敏感神经元基础的合作者用于建模置换不变的 RL。(D) 一个上下文敏感神经元的功能描绘，它具有两个整合点，其上下文整合区接收来自邻近感觉 1 神经元的近距离上下文 (P)，来自网络更远部分的感觉 2-N 神经元的远距离上下文 (D) 以及代表 Q 的普遍上下文 (U)。整合后的上下文 (C) 用作邻居神经元的平均意见，以决定是否传递信息。 C 值越高，传输信息的概率就越大。更多详情，请参见 [7, 15]。

只能看到观察值 $O_t[i]$ 的 i^{th} 组件，计算 $f_R(O_t[i], a_{t-1})$ 和 $f_D(O_t[i])$ 。整个操作可以使用式 (7-10) 来描述：

$$m_t = ReLU(R(O_t, a_{t-1})^2 + 2R(O_t, a_{t-1}) + 2C(1 + |R(O_t, a_{t-1})|)) \quad (9)$$

$$R(O_t, a_{t-1}) = \begin{bmatrix} f_R(O_t[1], a_{t-1}) \\ \dots \\ f_R(O_t[N], a_{t-1}) \end{bmatrix} \in \mathbb{R}^{N \times d_{f_R}} \quad (7)$$

$$C = P + D + U \quad (10)$$

其中 $P = f_P(R)$ ， U 是位置编码的函数。

结果

由于处理能力有限，我们方便地在两个不同的 RL 环境中进行了实验，分别是 Cart-pole swing up 和 PyBullet Ant 环境，分别进行了 1 万次和 1 千次迭代。所有代理




图 3. 训练结果：在 Cart-Pole 和 PyBullet 问题中，具有相同架构和参数数量的合作者学习速度远快于 Transformer 和先前提出的神经调节功能。在 [9] 中，作者仅展示了测试结果，在这里我们同时展示训练和测试结果。参见演示：将在双盲评审后公开。

的策略网络架构、训练方法、AttentionNeuron 层以及超参数与 [9] 中使用的一样。这里呈现的结果是使用 [9] 提供的代码生成的，这也是基线。

图 3 显示了 Cart-pole 和 PyBullet Ant 场景的结果。观察到上下文敏感神经元驱动的代理比基于 Transformer 的 PI 代理（基线）学习任务的速度快得多。此外，之前提出的上下文敏感神经调节转移函数（3-6）的表现与基线 Transformer 模型相当。具体来说，在 Cart-pole 问题中，合作者在少于 23 个回合内收敛到最高的适应度得分，超过了 600 分。相比之下，基线学习速度较慢，在 23 个回合内达到 100 的适应度分数，并在 1 千个回合后仍低于 500 分。在 PyBullet Ant 问题中，合作者学习速度更快，并在 1 千个回合内超过 500 分。相比之下，基线和其他 TFs 从未超过 100 的适应度得分。表 1 中的 CartPole 测试结果显示，在 1k-10K 回合训练下，合作者实现了显著更高的适应度分数，并且标准偏差远低于基线，无论是在打乱还是未打乱的情况下。虽然对于打乱输入的情况，合作者在 1 千个回合内与基线表现相当，但在 5 千个回合后快速跳到了更高的适应度得分，并且标准偏差更小。然而，在 PyBullet Ant

情况下，合作者在打乱和未打乱场景中都表现出色。我们现在正在训练这些模型进行 2 万次迭代，并将在未来报告比较结果。

表 1. 卡车杆测试（在 1K、5K 和 10K 次迭代上训练）。对于每个实验，我们报告了来自 1K 个测试集的平均分数和标准差。

	Iterations		
	1K	5K	10K
Transformer	279±272	340±308	340±310
Transformer (Shuffled)	279±274	339±308	340±309
Cooperator	428±293	524±408	538±419
Cooperator (Shuffled)	267±248	508±408	536±417

表 2. PyBullet 蚂蚁测试（经过 1000 个回合训练）。对于每个实验，我们报告来自 1000 个测试回合的平均得分和标准差。

	ES	ES (shuffled)
Transformer	121±53	30±241
Cooperator	1170±35	280±124

讨论

与在 [7] 中呈现的音频视觉语音处理结果类似，这里提出的 RL 结果支持我们的假设，即最先进的深度学习的基本弱点在于其依赖于点状神经元，这些神经元会无条件地最大化信息传输，而不考虑当前上下文的相关性。相比之下，在所提出的合作上下文敏感神经信息处理机制中，神经元时刻与邻近的神经元合作，分别放大和抑制相关和不相关信息的前馈传播。这一机制确保了局部处理器之间的民主性得以维持。

虽然在 [7,8] 中呈现的令人信服的证据显示了上下文敏感神经元如何迅速进化为对特定类型的高级信息高度敏感，并且仅当接收到的相关信号与当前上下文相关时才“开启”，从而导致更快的信息互估，减少神经活动，降低能耗并增强韧性，这里的结果进一步支持了我们的激进观点。在本研究中，合作者模型仅由一层两点神经元和一个简单的策略网络组成。此外，包括参数数量在内的架构与 [9] 中相同。关于 CartPole 和 PyAnt 模拟，请参见：将在双盲审后披露。我们目前正在训练包含多层两点神经元的更深模型用于语言模型。然而，应用于音频视觉语音处理的更深层网络的结果在 [7,8] 中展示。对于 50 层的深度网络，请参见：将在双盲审稿后披露。

感官替代的证据是假设上下文敏感处理是皮质计算中心的一个众多理由之一，如在 [26] 中所论证的，并且最近在 [27] 中得到了支持。这些结果强烈支持新皮层功能的合作上下文敏感观点。值得一提的是，我们的算法不是神经模型，而是证明合作上下文敏感计算风格具有卓越的大数据信息处理能力，这可以在硅基或神经组织中实现。

致谢 本研究得到了英国工程与物理科学研究委员会 (EPSRC) 资助，项目编号为 EP/T021063/1。我们感谢斯特灵大学的比尔·菲利普斯教授和莱斯利·史密斯教授、奥登布勒克大学的彼得·科尼格教授、牛津计算神经科学的牛顿·霍华德教授以及伦敦国王学院的迈克尔·斯普拉廷博士和伦敦大学学院的迈克尔·豪瑟教授，他们以多种方式帮助和支持了我们，包括评审我们的工作、给予赞赏和鼓励。

贡献 AA 构思并发展了最初的想法，撰写了手稿，并分析了结果。AA、JM、KA、MR、FZ、EC、TBR 和

AS 进行了模拟。

竞争利益 AA 拥有本论文中使用算法的临时专利申请。其他作者声明不存在利益冲突。

数据可用性 支持本研究发现的数据可在请求后获取。

参考文献

- [1] W. A. Phillips, *The Cooperative Neuron: Cellular Foundations of Mental Life*. Oxford University Press, 2023.
- [2] —, “Cognitive functions of intracellular mechanisms for contextual amplification,” *Brain and Cognition*, vol. 112, pp. 39–53, 2017.
- [3] M.-H. Guo, T.-X. Xu, J.-J. Liu, Z.-N. Liu, P.-T. Jiang, T.-J. Mu, S.-H. Zhang, R. R. Martin, M.-M. Cheng, and S.-M. Hu, “Attention mechanisms in computer vision: A survey,” *Computational Visual Media*, vol. 8, no. 3, pp. 331–368, 2022.
- [4] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, “Attention is all you need,” *Advances in neural information processing systems*, vol. 30, 2017.
- [5] M. Häusser, “Synaptic function: Dendritic democracy,” *Current Biology*, vol. 11, no. 1, pp. R10–R12, 2001.
- [6] A. Burkitt, “A review of the integrate-and-fire neuron model: I. homogeneous synaptic input,” *Biological cybernetics*, vol. 95, pp. 1–19, 08 2006.
- [7] A. Adeel, M. Franco, M. Raza, and K. Ahmed, “Context-sensitive neocortical neurons transform the effectiveness and efficiency of neural information processing,” *arXiv preprint arXiv:2207.07338*, 2022.
- [8] A. Adeel, A. Adetomi, K. Ahmed, A. Hussain, T. Arslan, and W. Phillips, “Unlocking the poten-

- tial of two-point cells for energy-efficient training of deep nets,” *The IEEE Transactions on Emerging Topics in Computational Intelligence* (in press); <https://arxiv.org/abs/2211.01950>, 2022.
- [9] Y. Tang and D. Ha, “The sensory neuron as a transformer: Permutation-invariant neural networks for reinforcement learning,” *Advances in Neural Information Processing Systems*, vol. 34, pp. 22 574–22 587, 2021.
- [10] M. E. Larkum, J. J. Zhu, and B. Sakmann, “A new cellular mechanism for coupling inputs arriving at different cortical layers,” *Nature*, vol. 398, no. 6725, pp. 338–341, 1999.
- [11] M. Larkum, “A cellular mechanism for cortical associations: an organizing principle for the cerebral cortex,” *Trends in neurosciences*, vol. 36, no. 3, pp. 141–151, 2013.
- [12] G. Major, M. E. Larkum, and J. Schiller, “Active properties of neocortical pyramidal neuron dendrites,” *Annual review of neuroscience*, vol. 36, pp. 1–24, 2013.
- [13] S. Ramaswamy and H. Markram, “Anatomy and physiology of the thick-tufted layer 5 pyramidal neuron,” *Frontiers in cellular neuroscience*, vol. 9, p. 233, 2015.
- [14] M. E. Larkum, “Are dendrites conceptually useful?” *Neuroscience*, vol. 489, pp. 4–14, 2022.
- [15] A. Adeel, “Conscious multisensory integration: Introducing a universal contextual field in biological and deep artificial neural networks,” *Frontiers in Computational Neuroscience*, vol. 14, 05 2020.
- [16] K. P. Körding and P. König, “Learning with two sites of synaptic integration,” *Network: Computation in neural systems*, vol. 11, no. 1, pp. 25–39, 2000.
- [17] B. Schuman, S. Dellal, A. Prönneke, R. Machold, and B. Rudy, “Neocortical layer 1: An elegant solution to top-down and bottom-up integration,” *Annual Review of Neuroscience*, vol. 44, no. 1, pp. 221–252, 2021, PMID: 33730511.
- [18] P. Poirazi and A. Papoutsi, “Illuminating dendritic function with computational models,” *Nature Reviews Neuroscience*, vol. 21, pp. 1–19, 05 2020.
- [19] M. E. Larkum, L. S. Petro, R. N. Sachdev, and L. Muckli, “A perspective on cortical layering and layer-spanning neuronal elements,” *Frontiers in neuroanatomy*, vol. 12, p. 56, 2018.
- [20] J. Kay, D. Floreano, and W. A. Phillips, “Contextually guided unsupervised learning using local multivariate binary processors,” *Neural Networks*, vol. 11, no. 1, pp. 117–140, 1998.
- [21] J. W. Kay and W. A. Phillips, “Contextual modulation in mammalian neocortex is asymmetric,” *Symmetry*, vol. 12, no. 5, p. 815, 2020.
- [22] J. W. Kay, J. M. Schulz, and W. A. Phillips, “A comparison of partial information decompositions using data from real and simulated layer 5b pyramidal cells,” *Entropy*, vol. 24, no. 8, p. 1021, 2022.
- [23] A. Payeur, J. Guerguiev, F. Zenke, B. A. Richards, and R. Naud, “Burst-dependent synaptic plasticity can coordinate learning in hierarchical circuits,” *Nature neuroscience*, vol. 24, no. 7, pp. 1010–1019, 2021.
- [24] J. H. Reynolds and D. J. Heeger, “The normalization model of attention,” *Neuron*, vol. 61, no. 2, pp. 168–185, 2009.
- [25] M. Carandini and D. J. Heeger, “Normalization as a canonical neural computation,” *Nature Reviews Neuroscience*, vol. 13, no. 1, pp. 51–62, 2012.

- [26] W. A. Phillips and W. Singer, “In search of common foundations for cortical computation,” *Behavioral and brain Sciences*, vol. 20, no. 4, pp. 657–683, 1997.
- [27] K. D. Harris and G. M. Shepherd, “The neocortical circuit: themes and variations,” *Nature neuroscience*, vol. 18, no. 2, pp. 170–181, 2015.