生物学上合理的神经网络研究：脑启发机制在持续学习中的作用与相互作用

Fahad Sarfraz*、**Elahe Arani***、**Bahram Zonooz**
fahad.sarfraz@navinfo.eu，{e.arani, bahram.zonooz}@gmail.com[1]*NavInfo Europe* 高级研究实验室，荷兰埃因霍温[2]埃因霍温理工大学数学与计算机科学系，荷兰*贡献相同。

arXiv:2304.06738v1 [cs.NE] 13 Apr 2023

在 OpenReview 上评审： *https://openreview.net/forum?id=DJr6zorJM2*

摘要

人类擅长从不断变化的环境中持续获取、巩固并保留信息，而人工神经网络（ANN）则会出现灾难性遗忘。生物神经网络及其人工对应物在突触复杂性、信息处理方式和学习机制方面存在显著差异，这或许可以解释二者性能上的差距。我们探讨了一种生物学上合理的框架，该框架由两个独立的神经元群体构成，分别仅包含兴奋性神经元和抑制性神经元，并遵循戴尔定律；此外，还为兴奋性锥体神经元添加了树突样结构，以便依赖上下文处理刺激。随后，我们全面研究了大脑启发的多种机制的作用及其相互作用，包括稀疏非重叠表征、赫布学习、突触巩固，以及对伴随学习事件发生的过往激活进行重放。我们的研究表明，在类似大脑的生物学上合理的架构中采用多种互补机制，或许能有效实现人工神经网络的持续学习。 [1]

1 引言

人脑擅长从不断变化的环境中持续学习，而标准人工神经网络（ANN）本质上是为使用平稳的独立同分布（i.i.d.）数据进行训练而设计的。在持续学习（CL）中按顺序学习任务，违背了这一强假设，导致灾难性遗忘。尽管人工神经网络受到生物神经元的启发（Fukushima，1980），但它们忽略了大脑设计原则和学习机制中的许多细节。这些根本差异或许可以解释性能和行为上的不匹配。

生物神经网络的突触复杂得多，信息处理也具有动态的、依赖上下文的特性。此外，每个神经元都发挥着特定作用。根据戴尔定律（Strata 等，1999），每个突触前神经元对其突触后神经元都具有独有的兴奋性或抑制性作用。此外，锥体神经元中的远端树突段——它们构成了新皮层中大多数兴奋性细胞——会接收额外的上下文信息，从而实现依赖上下文的信息处理。结合抑制作用，这使网络能够学习任务特定模式并避免灾难性遗忘（Yang 等人，2014；Iyer 等，2022；Barron 等人，2017）。此外，人们认为，在新皮层和海马体中重放以往经历所对应的非重叠、稀疏神经活动，对记忆形成、巩固和提取发挥着关键作用（Walker与Stickgold，2004年；McClelland等，1995年）。为保护信息不被抹除，

[1]我们的代码已公开发布于 https://github.com/NeurAI-Lab/Bio-ANN。

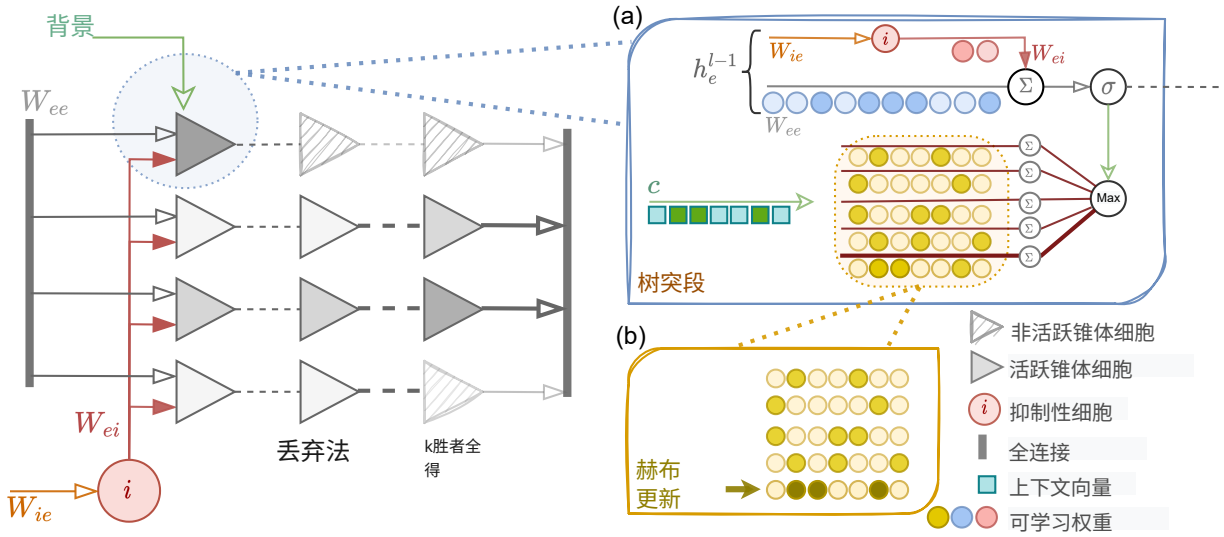

图 1：生物学上合理的框架中一个隐藏层的架构。每一层都由彼此分离的、完全由兴奋性锥体细胞和抑制性神经元组成的群体构成，并遵循戴尔定律。阴影表示权重或激活的强度，颜色越深表示数值越高。（a）锥体细胞配备了树突段，这些树突段接收额外的上下文信号 c；与上下文向量最为匹配的树突段（底行）会被选中，以调节前馈神经元的输出活动，从而对信息进行依赖上下文的处理。（b）赫布更新步骤进一步增强上下文与绝对值最大的获胜树突段之间的关联（底行中以较深阴影表示）。最后，异质性丢弃保留每个锥体细胞的激活计数（以灰色阴影表示），并丢弃在先前任务中最活跃的神经元（以最深阴影表示被丢弃的神经元），以强制形成非重叠表征。剩余细胞中排名前 k 的细胞随后投射到下一层（阴影加深）。这为我们提供了一个更具生物学合理性的框架，使我们能够研究不同脑启发机制的作用，并为设计新的持续学习方法提供洞见。

大脑采用突触巩固机制，其中可塑性速率会按比例选择性降低，以强化突触（Cichon 和 Gan，2015）。

因此，我们在持续学习设置中，基于一个生物学上合理的框架，研究受大脑启发的不同机制的作用及其相互作用。底层模型在每一层都包含彼此独立的兴奋性神经元群和抑制性神经元群，遵循戴尔定律（Cornford 等，2020）；此外，兴奋性神经元（模拟锥体细胞）还配备了类树突结构，用于处理依赖上下文的信息（Iyer 等，2022）。树突段处理额外的上下文信号，该信号编码任务信息，随后调节兴奋性神经元的前馈活动（图 1）。接着，我们系统地研究控制表征重叠的效果，并采用“共同放电，连接增强”的学习范式，同时结合经验回放和突触巩固。我们的研究表明：

i. 采用树突对信息进行依赖上下文的处理并遵循戴尔定律的人工神经网络架构，能够在持续学习设置中有效学习。重要的是，考虑到权重变化对兴奋性和抑制性神经元的影响差异，能够进一步减少持续学习中的遗忘。 ii. 在隐藏层中使用 k胜者全得激活来施加不同程度的激活稀疏性，并采用互补的丢弃机制（异质性丢弃），鼓励模型为每个任务使用不同的一组活跃神经元，从而有效控制表征重叠，减少干扰，同时保留可复用性。

iii. 在实施此类约束时，需要考虑任务相似性，以平衡前向迁移与干扰。iv. 通过对上下文信号与树突段之间的连接执行赫布更新步骤，模仿大脑中普遍存在的“共同激活，连接增强”学习规则，进一步强化上下文门控，并促进任务特定子网络的形成。v. 我们表明，采用重要性度量并对其进行调整以考虑权重变化影响的差异，同时以特定上下文的方式使用重放机制，对于巩固不同任务之间的信息至关重要，尤其是在具有挑战性的持续学习设置中。

我们的研究表明，在生物学上合理的架构中采用多种互补机制，类似于人们认为大脑中存在的机制，有助于在人工神经网络中实现持续学习。据我们所知，我们首次在持续学习场景下，对生物学上合理的架构中不同脑启发机制的整合进行了全面研究。

2 持续学习的生物学上合理框架

我们提供了我们开展研究所依据的生物学上合理框架的详细信息 y.

2.1 戴尔定律

生物神经网络与其人工对应物在突触的复杂性和单个单元的作用方面存在差异。具体而言，大脑中的大多数神经元都遵循戴尔定律，该定律认为，突触前神经元对其突触后神经元只能产生单一的兴奋性或抑制性作用（Strata 等人，1999）。多项研究表明，兴奋性和抑制性神经元群体的平衡动力学（Murphy & Miller，2009；Van Vreeswijk & Sompolinsky，1996）具有功能优势，包括高效的预测编码（Boerlin 等人，2013）和模式学习（Ingrosso & Abbott，2019）。此外，研究假设抑制有助于减轻灾难性遗忘（Barron 等人，2017）。然而，标准人工神经网络并不遵循戴尔定律，因为神经元同时具有正、负输出权重，且权重符号会在学习过程中发生变化。

Cornford 等人（2020）将戴尔定律引入人工神经网络（称为 DANN），纳入兴奋性神经元与抑制性神经元各自不同的连接模式（Tremblay 等人，2016），并在基准物体识别任务中的表现与标准人工神经网络相当。每个层 l 由独立的兴奋性神经元群体 $h_e^l \in \mathbb{R}_+^{n_e}$ 和抑制性神经元群体 $h_i^l \in \mathbb{R}_+^{n_i}$ 构成，其中 $n_e \gg n_i$，且突触权重严格非负。与生物网络类似，两个群体都接收来自前一层的兴奋性投射（h_e^{l-1}），但只有兴奋性神经元会向其他层投射，而抑制性神经元则抑制同一层中兴奋性单元的活动。Cornford 等人（2020）用三组严格为正的权重刻画了这些特性：层间兴奋性连接 $W_{ee}^l \in \mathbb{R}_+^{n_e \times n_e}$、向抑制性单元的兴奋性投射 $W_{ie}^l \in \mathbb{R}_+^{n_i \times n_e}$，以及层内抑制性投射 $W_{ei}^l \in \mathbb{R}_+^{n_e \times n_i}$。兴奋性单元的输出会受到抑制性单元所产生的减性抑制影响：

$$z^l = (W_{ee}^l - W_{ei}^l W_{ie}^l) h_e^{l-1} + b^l \tag{1}$$

其中，$b^l \in \mathbb{R}^{n_e}$ 是偏置项。图 1 展示了兴奋性锥体细胞（三角形符号）与抑制性神经元（以 i表示）之间的相互作用和连接性。

我们旨在将 DANN 用作前馈神经元，以证明它们也能在具有挑战性的持续学习场景中进行学习，且性能可与标准人工神经网络相媲美，并为进一步研究抑制在缓解灾难性遗忘中的作用提供一个生物学上合理的框架。

2.2 主动树突

大脑采用特定的结构和机制来进行依赖上下文的处理和信息路由。前额叶皮层在认知控制中发挥重要作用（Miller & Cohen,

2001），它接收感觉输入以及上下文信息，从而能够为当前任务选择最相关的感觉特征，以引导行动（Mante等人，2013；Fuster，2015；Siegel等人，2015；Zeng等人，2019）。尤其值得关注的是锥体细胞，它们是大脑中数量最多的兴奋性神经元家族成员（Bekkers，2011）。锥体细胞中的树突棘具有高度非线性的整合特性，这被认为对学习任务特定模式至关重要（Yang等人，2014）。锥体细胞将多种不同输入整合到多个相互独立的树突段中，使主动树突中的上下文输入能够调节神经元的响应，从而提高其放电的可能性。然而，标准人工神经网络基于点神经元模型（Lapique，1907），这是一种过度简化的生物计算模型，缺乏锥体细胞复杂的非线性和依赖上下文的行为。

Iyer 等人（2022）通过为每个神经元增添一组树突段，对树突的这些整合特性进行建模。多个树突段接收额外的上下文信息，并使用单独的一组权重对其进行处理。由此得到的树突输出会调节前馈激活，而前馈激活则通过对前馈输入进行线性加权求和来计算。这种计算方式使神经元对给定刺激的响应幅度高度依赖于上下文。为实现针对特定任务的信息处理，任务 τ 的原型向量通过对任务样本逐元素取均值来计算，$\mathcal{D}_\tau$ 在任务开始时计算，随后在训练期间作为上下文提供。

$$c_\tau = \frac{1}{|\mathcal{D}_\tau|} \sum_{x \in \mathcal{D}_\tau} x \tag{2}$$

在推理过程中，使用存储在记忆中的所有任务原型 $\boldsymbol{C}$ 之间的欧几里得距离，选取与每个测试样本 x' 最接近的原型向量作为上下文。

$$c' = \arg\min_{c_\tau} \|\boldsymbol{x}' - \boldsymbol{C}_\tau\|_2 \tag{3}$$

遵循 Iyer 等人（2022），我们为每个层中的兴奋性单元添加树突段（图 1 (a)）。兴奋性单元的前馈活动受树突段调制，树突段接收一个上下文向量。给定上下文向量，每个树突段 j 计算 $u_j^T c$，给定权重 $u_j \in \mathbb{R}^d$和上下文向量 $c \in \mathbb{R}^d$，其中 d 是输入图像的维度。对于兴奋性神经元，选择对上下文响应最高的树突段（保留符号的最大绝对值），以调制输出活动。

$$h_e^l = k\text{-}WTA(z_l \times \sigma(u_\kappa^T c)), \qquad \text{where } \kappa = \arg\max_j |u_j^T c| \tag{4}$$

其中，σ 是 Sigmoid函数（Han & Moraga, 1995），$k\text{-}WTA$(.) 是 k赢家通吃激活函数（Ahmad & Scheinkman, 2019），它只传递排名前 k 的神经元，并将其余神经元置为零。这为我们提供了一个生物学上合理的框架：与生物网络类似，前馈神经元遵循戴尔定律，而兴奋性神经元则模拟活跃树突的整合特性，以便依赖上下文地处理刺激。

3 持续学习设置

为了研究受大脑启发的不同组件在适用于持续学习的生物学上合理的神经网络中的作用，并评估它们对模型性能和特性的影响，我们在统一的设置下开展所有实验。实现细节和实验设置见附录。我们在两种持续学习场景下评估模型。**领域增量学习（领域增量学习）**指的是这样一种持续学习场景：后续任务中的类别保持不变，但输入分布发生变化。我们考虑 Rot-MNIST 和 Perm-MNIST：Rot-MNIST 涉及在每个任务中对 10 个数字进行分类，每个数字旋转的角度介于 0 到 180 度之间；Perm-MNIST 则对每个任务中的像素应用固定随机置换。值得注意的是，Rot-MNIST 有多种难度各异的变体。我们将数字逐步旋转至固定角度，即任务 {$\tau_1, \tau_2, .., \tau_N$} 对应的角度为 {0, 8, ..., (N-1)*8}，这比随机抽样旋转具有更大的挑战性。值得注意的是，Rot-MNIST 数据集捕捉了以下概念：

表1：在任务数量各不相同的情况下，生物学上合理的框架中各组件对不同数据集的影响。我们首先展示采用遵循戴尔定律的前馈神经元，并结合主动树突 构建框架的效果；在此框架中，我们评估各项脑启发机制（赫布更新、异质性丢弃（HD）、突触巩固（SC）、经验回放（ER）和一致性正则化（CR））各自的影响，然后将它们组合起来构建 Bio-ANN。所有实验中，我们将活跃神经元的比例设为 5%。我们报告五次运行的平均任务表现及 1 个标准差。此外，我们还在附录的表 6 中展示了在标准人工神经网络基础上加入脑启发机制后所获得的性能提升。

方法	Rot-MNIST			Perm-MNIST			Seq-MNIST
	5 任务	10 个任务	20 个任务	5 个任务	10 个任务	20 项任务	
联合	98.27±0.07	98.25±0.06	98.17±0.11	97.64±0.19	97.61±0.15	97.59±0.08	94.53±0.50
SGD	93.79±0.32	74.13±0.36	51.89±0.36	77.96±8.34	76.42±2.54	65.18±2.12	19.83±0.04
主动树突	92.58±0.26	71.06±0.52	48.18±0.52	95.71±0.27	94.41±0.21	91.74±0.34	19.97±0.29
+戴尔定律	92.28±0.27	70.78±0.23	48.79±0.27	96.18±0.14	95.20±0.11	92.44±0.20	19.79±0.08
+赫布更新	92.58±0.35	71.22±0.86	48.88±0.90	95.90±0.24	94.72±0.29	92.55±0.47	19.88±0.02
+ HD	93.24±0.25	75.50±0.74	51.11±0.76	96.58±0.17	95.94±0.24	93.20±0.32	38.45±2.71
+ SC	93.34±0.57	75.94±1.15	64.99±2.19	96.54±0.29	96.14±0.47	95.43±0.49	27.31±2.20
+ ER	95.21±0.28	90.99±0.51	83.45±0.44	96.72±0.13	96.04±0.17	94.26±0.78	86.93±0.82
+经验回放 +CR	96.48±0.55	93.87±0.25	89.39±0.23	97.23±0.30	96.93±0.31	96.13±0.05	89.60±0.73
Bio-ANN	**96.82**±0.14	**94.64**±0.23	**91.32**±0.26	**97.33**±0.04	**97.07**±0.05	**96.51**±0.03	**89.90**±0.24

在后续任务中具有相似性，其中两个任务之间的相似性由其旋转角度的差异定义，而 Perm-MNIST 中的每个任务则相互独立。我们还考虑了具有挑战性的**类别增量学习（Class-IL）**场景，在该场景中，每个后续任务都会引入新的类别，智能体必须学会区分当前任务中的各个类别，以及所有已学习任务中的类别。Seq-MNIST 将 MNIST 分类任务划分为 5 个任务，每个任务包含 2 个类别。

4 实证评估

为了探究受大脑启发的不同组件所产生的影响，我们采用上述生物学上合理的框架，并研究其对模型性能和特性的影响。

4.1 抑制性神经元的影响

我们首先研究具有独立的兴奋性单元和抑制性单元群体的前馈网络是否能够在持续学习环境中良好运行。重要的是，我们注意到，在使用抑制性神经元学习一系列任务时，考虑不同参数的更新对层输出分布产生影响的程度差异（Cornford 等，2020），从而考虑其对遗忘的影响，是有益的。具体而言，由于 W_{ie}^{l} 和 W_{ei}^{l} 对输出分布的影响程度高于 W_{ee}^{l}，因此我们在第一个任务之后降低这些权重的学习率（参见附录）。

表1显示，遵循戴尔定律的前馈神经元模型，其性能与采用标准神经元的模型相当；当上下文信号的质量较高时（以置换 MNIST 为例），结合主动树突还能进一步缓解遗忘。值得注意的是，这种性能提升伴随着参数数量的大幅减少和依赖上下文的处理能力的增强，因为我们保持每一层中的神经元数量不变，仅对兴奋性神经元（∼90%）增加树突段。对于20个任务，结合戴尔定律的主动树突将参数数量从 ∼70M减少至不到 ∼64M。我们推测，在同一层内设置不同的神经元群体，使它们能够发挥专门的作用。具体而言，抑制性神经元可以根据刺激选择性地抑制某些兴奋性神经元，从而进一步促进任务特定子网络的形成，并补充树突段对信息进行的依赖上下文的处理。

表 2：激活中不同稀疏性水平对模型性能的影响。列表示活跃神经元的比例（k 在 k-WTA 激活中），行表示任务数量。

#任务 \ k	Rot-MNIST				Perm-MNIST			
	0.05	0.10	0.20	0.50	0.05	0.10	0.20	0.50
5	92.28±0.27	92.26±0.31	**92.79**±0.44	92.26±0.65	95.77±0.33	**96.32**±0.20	90.29±6.07	74.51±13.55
10	70.78±0.23	71.95±1.54	**73.32**±0.69	71.61±0.76	**95.06**±0.29	93.45±0.92	72.68±12.83	41.33±6.72
20	**48.79**±0.27	47.96±1.84	48.65±0.91	47.71±0.91	**92.40**±0.38	84.28±1.35	63.84±3.45	20.80±0.99

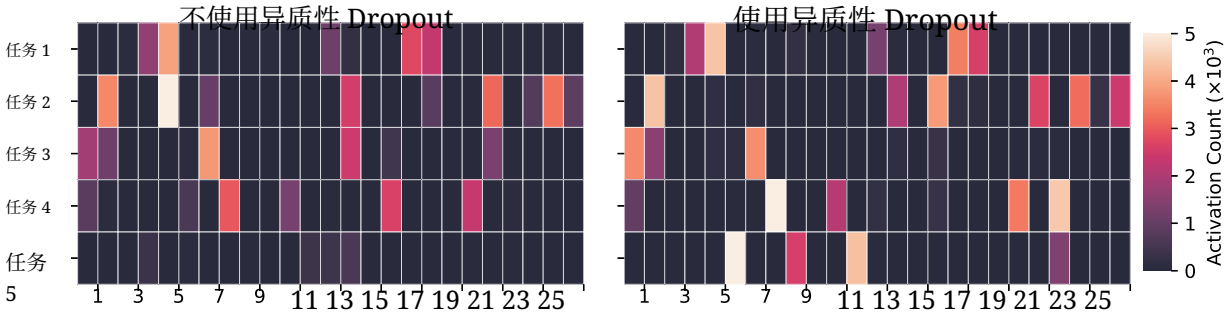

图 2：模型第二个隐藏层中随机抽取的 25 个单元在各任务测试集上的激活总计数（纵轴）。异质性丢弃减少了激活的重叠，并促进任务特定子网络的形成。

4.2 稀疏激活促进子网络的形成

新皮层回路的特点是神经激活具有高度稀疏性（Barth & Poulet, 2012; Graham & Field, 2006）。进一步的证据表明，自然感觉刺激的神经元编码应当是稀疏的（Barth & Poulet, 2012; Tolhurst 等人，2009）。这与标准人工神经网络中稠密且高度纠缠的连接性形成了鲜明对比。尤其对于持续学习而言，稀疏性具有多项优势：稀疏非重叠表征可以减少任务之间的干扰（Abbasi 等人，2022; Iyer 等，2022; Aljundi 等人，2019），并能够促使任务特定模块自然涌现（Hadsell等，2020年）。

我们通过改变 k 胜者全得（k-WTA）激活中活跃神经元的比例，研究不同激活稀疏性水平的影响（Ahmad & Scheinkman, 2019）。模型的每个隐藏层在连接上都具有恒定稀疏性（初始化时随机将 50% 的权重设为 0），且只传递前 k 个激活（图 1 中的 k-WTA 层）。表 2 显示，稀疏性对于实现深度神经网络中的持续学习至关重要。激活稀疏性通过减少表征重叠，有效降低了干扰。有趣的是，不同激活稀疏性水平对 Rot-MNIST 和 Perm-MNIST 的影响差异显著，这凸显了在设计持续学习方法时考虑任务相似性的重要性。由于 Perm-MNIST 中的任务彼此独立，较少的活跃神经元（5%）使网络能够为每项任务学习非重叠表征；而 Rot-MNIST 中较高的任务相似性则可以从重叠表征中受益，从而能够在各项任务间重复利用特征。智能体需要学习的任务数量也会影响最优稀疏性水平。在附录中，我们展示了在不同层中采用不同稀疏性水平可以进一步提升性能。由于较早层学习的是通用特征，较高比例的活跃神经元有助于提高特征重复利用率和前向迁移。对于较后层，较低比例的活跃神经元则可以减少任务特定特征之间的干扰。

4.3 面向非重叠激活和子网络的异质性丢弃法

大脑中的信息通过相对少量神经元的强激活进行编码，从而形成稀疏编码。不同类型的刺激由不同的神经元子集进行表征。Graham

表 3：异质性丢弃在不同数据集上，随着 ρ 值增加且任务数量不同的影响。

数据集	任务数	w/o 丢弃法	丢弃法参数（ρ）				
			0.1	0.3	0.5	0.7	1.0
Rot-MNIST	5	92.28±0.20	91.79±0.53	92.53±0.11	92.74±0.38	93.19±0.32	**93.42**±0.25
	10	70.78±0.23	71.53±1.07	72.38±1.44	73.63±1.00	74.20±0.78	**75.50**±0.74
	20	48.79±0.27	48.57±0.90	48.91±0.65	49.84±0.59	51.03±0.31	**51.11**±0.76
Perm-MNIST	5	95.77±0.33	95.70±0.29	95.97±0.44	96.40±0.28	**96.58**±0.17	96.48±0.26
	10	95.06±0.29	95.23±0.04	95.65±0.20	95.54±0.26	95.74±0.22	**95.94**±0.24
	20	92.40±0.38	92.83±0.42	**93.20**±0.32	92.82±0.06	93.09±0.47	91.77±0.30

& Field（2006）。此外，有证据表明，大脑中存在非重叠表征。为了模拟这一现象，我们采用异质性丢弃（Abbasi 等人，2022），该方法与信息的依赖上下文的处理相结合，能够有效减少表征之间的重叠，从而降低任务之间的干扰，进而减少遗忘。在训练过程中，我们跟踪给定任务下某一层中每个神经元的激活频率；在后续任务中，神经元被丢弃的概率与其激活计数成反比。这促使模型利用先前任务中激活程度较低的神经元来学习新任务。图 1 显示，在应用 k胜者全得之前，激活程度较高（颜色较深）的神经元更有可能被丢弃。具体而言，设 $[a_t^l]_j$ 表示在学习了 t 个任务后，层 l 中神经元 j 的激活计数。对于学习任务 $t+1$，该神经元被保留的概率为：

$$[p_{t+1}^l]_j = exp(\frac{-[a_t^l]_j}{\max_j [a_t^l]_j}\rho) \tag{5}$$

其中，ρ 控制非重叠表征的约束强度，值越大，重叠程度越低。这为我们提供了一种高效机制，可根据任务相似性控制不同任务表征之间的重叠程度，进而控制前向迁移和干扰的程度。

表 3 显示，采用异质性丢弃法可以进一步提升模型的性能。我们还分析了 ρ 参数对激活计数和表征重叠的影响。图 2 显示，异质性丢弃法有助于形成任务特定子网络；图 3 显示了在 Perm-MNIST 的两个任务上，使用不同的 ρ 值训练的模型在任务 1 和任务 2 测试集上的激活计数分布之间的对称 KL 散度。随着 ρ 参数增大，各层中的激活变得越来越不相似。异质性丢弃法提供了一种简单机制，可根据任务相似性平衡特征的可复用性与干扰。

4.4 逐层异质性丢弃与任务相似性

对于有效的持续学习智能体而言，在不同任务之间保持前向迁移与干扰的平衡至关重要。较早层学习通用特征，因此可以重用更多特征来学习新任务，从而促进前向迁移；而较后层学习更多任务特定特征，这可能引发干扰。异质性丢弃为我们提供了一种高效机制，用于控制每一层激活的重叠程度，从而控制各层特征的重叠程度。本文将探究在不同层中采用不同的稀疏性水平（通过 ρ 参数控制）能否进一步提升性能。由于较早层学习通用特征，增大活跃神经元集合之间的重叠程度（减小ρ）有助于提高可重用性和前向迁移。对于较后层，减小激活之间的重叠程度（增大 ρ）则可以减少任务特定特征之间的干扰。

为了研究异质性丢弃与任务相似性之间的关系，我们在包含 5 个任务的 Rot-MNIST 设置中，改变后续每个任务的增量旋转量 θ_{inc}。任务 τ 的旋转角度为（$\tau -$

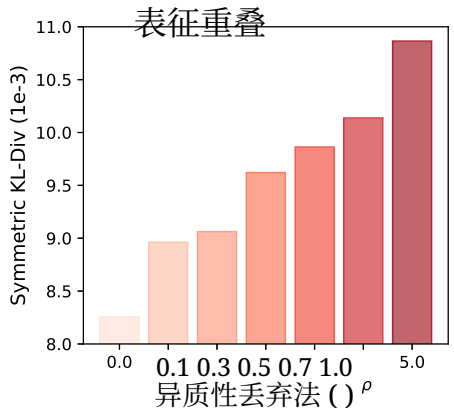

图 3：丢弃法 ρ 对 Perm-MNIST 中 2 个任务的第二层激活计数分布重叠的影响。较高的 ρ会降低重叠。

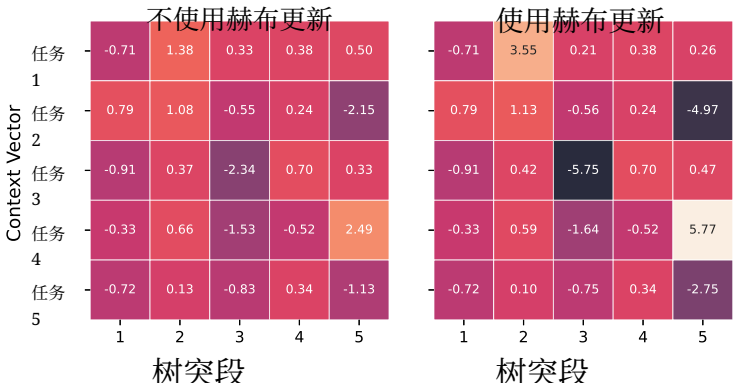

图4：在使用 5 个任务训练的 Perm-MNIST 模型中，第1层一个单元针对各任务上下文向量的树突段激活。赫布更新会增强上下文与树突段之间的关联，从而增强调制信号的幅度。

表4：逐层随机失活 ρ 对包含 5 个任务的 Rot-MNIST 的影响，其中后续每个任务的增量旋转程度各不相同（θ_{inc}）。第 0 行显示（ρ^{l_1}, ρ^{l_2}）第一和第二隐藏层的 ρ 值。

ρ^{l_1}, ρ^{l_2}	任务相似性（θ_{inc}）					
	2	4	8	16	24	32
0.1, 0.1	97.60±0.12	96.74±0.16	91.79±0.53	74.99±1.16	63.33±1.15	57.39±2.36
0.1, 0.5	97.77±0.08	97.02±0.11	92.39±0.39	75.56±1.46	64.18±1.79	57.05±2.13
0.5, 0.5	97.88±0.12	97.22±0.11	92.74±0.38	76.73±1.01	64.18±1.42	58.35±0.73
0.5, 1.0	97.88±0.04	**97.25**±0.11	92.87±0.39	76.87±0.39	64.84±0.65	59.40±2.31
1.0, 1.0	**97.89**±0.09	97.19±0.09	93.42±0.25	77.48±0.94	66.33±1.62	61.35±1.90
1.0, 2.0	97.68±0.09	97.00±0.23	93.46±0.78	79.07±0.67	68.20±2.34	63.08±0.86
2.0, 2.0	97.42±0.17	97.00±0.11	**93.53**±0.53	80.03±0.62	69.99±1.97	65.74±1.21
2.0, 5.0	97.39±0.03	96.54±0.15	92.95±0.01	**80.55**±0.89	**73.74**±0.21	69.46±2.66
5.0, 5.0	96.86±0.11	96.12±0.08	92.33±0.18	79.53±0.42	72.47±1.23	**70.77**±2.11
不使用丢弃法	97.72±0.29	96.93±0.40	92.31±0.56	75.67±1.40	63.68±1.36	56.49±2.86

1）θ_{inc}。表4展示了模型在不同逐层 ρ 值下的性能。总体而言，异质性丢弃始终能提升模型性能，尤其是在任务相似性较低时。对于$\theta_{inc} = 32$，性能提升了 ∼25%。随着任务相似性降低（θ_{inc} 增大），较大的 ρ 值更有效。此外，我们发现，为每个层设置不同的 ρ 值还能进一步提升性能。

4.5 赫布学习强化上下文门控

对于生物学上合理的人工神经网络而言，不仅要融入生物神经元的设计要素，还要纳入其所采用的学习机制，这一点同样十分重要。大脑中的终身可塑性通常遵循赫布原则：持续促成另一个神经元放电的神经元，会与该神经元建立更强的连接（Hebb，2005）。

因此，我们采用 Flesch 等人（2023）的方法，通过赫布更新补充基于误差的学习，以增强上下文信息与树突段之间的连接（图 1(b)）。

每次通过反向传播进行监督参数更新后，都会在树突段上执行一次赫布更新步骤，以增强上下文输入与相应被激活的树突段之间的连接。为了约束参数，我们采用 Oja规则，该规则在赫布学习中引入了权重衰减（Oja，1982年），

$$u_\kappa \leftarrow u_\kappa + \eta_h d(c - d u_\kappa) \tag{6}$$

其中，η_h 是学习率，κ 是权重为 u_κ 的获胜树突索引，$d = u_\kappa^T c$ 是针对上下文信号 c的调制信号。图4显示，赫布更新步骤会增大树突调制信号在前馈活动上的幅度，从而进一步强化依赖上下文的门控，并促进任务特定子网络的形成。表1显示，这进而可以带来结果改善。尽管在这些设置中的增益并不显著，但表5显示，在任务和数据集复杂度更高、更具挑战性的持续学习设置中，赫布学习带来的增益更加明显。

4.6 突触巩固进一步缓解遗忘

除了整合特性外，树突在保留信息和防止信息被抹除方面也发挥着关键作用（Cichon与Gan，2015年；Yang等，2009年）。在学习不同任务时，响应学习而在不同树突分支组上形成的新棘突，会通过突触可塑性以及在学习新任务时仍持续存在的结构变化的调节，受到保护而不被消除（Yang等，2009年）。

我们通过纳入突触智能 （Zenke等，2017年）（详情见附录）来实现突触巩固。该方法会在训练过程中以在线方式维护每个突触的重要性估计，随后降低那些被认为对已学习任务很重要的突触的可塑性。具体而言，考虑到 DANN层中的抑制性中间神经元架构会导致不同参数的更新对层输出的影响程度各异，我们对重要性估计进行了调整（Cornford 等，2020）。此外，我们还提高了通向抑制性单元的兴奋性连接以及层内抑制性连接的重要性估计，以进一步惩罚这些权重的变化。表1显示，以这种方式运用突触智能（+SC）能够进一步减轻遗忘。特别是在包含20个任务的 Rot-MNIST 中，该方法显著提升了性能。

4.7 经验回放对于在具有挑战性的场景中实现持续学习至关重要

大脑中过去神经激活模式的重放被认为在记忆形成、巩固和提取中发挥着关键作用（Walker与Stickgold，2004年；McClelland等，1995年）。海马体中的重放机制（Kumaran等，2016年）启发了一系列基于复习的方法（Li与Hoiem，2017年；Chaudhry等，2019年；Lopez-Paz与Ranzato，2017年；Arani等，2022年），这些方法已被证明在具有挑战性的持续学习场景中有效（Farquhar与Gal，2018年；Hadsell等，2020年）。因此，为了重放先前任务中的样本，我们利用一个通过蓄水池抽样 （Vitter，1985年）维护的小型情景记忆缓冲区。它通过为每个新样本分配相等的概率，使其能够在缓冲区中得到表示，从而近似匹配输入流的分布。在训练期间，当前任务中的样本（x_b，y_b）$\sim \mathcal{D}_\tau$与记忆缓冲区样本（x_m，y_m）$\sim \mathcal{M}$ 交错使用，以近似截至目前所见任务的联合分布。此外，为了模拟大脑中伴随学习事件的激活模式重放，我们还沿着训练轨迹保存输出逻辑值 z_m，并在重放情景记忆中的样本时施加一致性损失。具体而言，损失为：

$$\mathcal{L} = \mathcal{L}_{cls}(f(x_b;\theta), y_b) + \alpha \mathcal{L}_{cls}(f(x_m;\theta), y_m) + \beta (f(x_m;\theta) - z_m)^2 \tag{7}$$

其中，$f(.;\theta)$ 是由 θ 参数化的模型，$\mathcal{L}_{cls}$ 是标准交叉熵损失，而 α 和 β 分别控制交错训练和一致性约束的强度。

表1显示，经验回放（+ER）与依赖上下文的信息处理相辅相成，使模型能够在各种具有挑战性的设置中很好地学习联合分布。具体而言，在类别增量学习设置（Seq-MNIST）中，如果没有经验回放，模型无法避免遗忘。

这表明，仅依赖上下文的信息处理并不足够，经验回放可能至关重要。添加一致性正则化（+CR）可进一步提升性能，因为模型能够获取有关类别结构相似性的额外关系信息，从而促进信息整合。

表5：生物学上合理的框架中各组件在不同领域增量学习和类别增量学习设置下的效果。所有实验均使用500个样本的内存预算。我们报告5次运行的平均任务表现及1个标准差。

方法	领域增量学习	类别增量学习		
	Rot-FMNIST	Seq-FMNIST	Seq-MNIST	Seq-GCIFAR10
联合	98.15±0.09	94.33±0.51	94.53±0.53	36.10±0.86
SGD	51.89±0.27	19.83±0.04	19.83±0.04	14.86±1.06
ActiveDANN	49.42±0.83	21.46±1.95	19.97±0.29	16.12±0.31
ActiveDANN + 经验回放	80.99±0.53	77.56±0.27	86.88±0.83	28.74±0.42
+ 赫布更新	82.16±0.26	78.02±0.38	88.39±0.78	30.12±0.49
+ SC	82.55±0.37	78.05±0.61	88.79±0.49	30.45±0.61
+ HD	83.97±0.46	78.74±0.38	89.60±0.73	30.29±0.51
Bio-ANN	**89.22**±0.21	**79.28**±0.42	**89.90**±0.24	**30.95**±0.17

4.8 组合各个组件

在展示了生物学上合理的框架中各个脑启发组件的单独作用后，我们在此考察它们的组合效果。由此得到的模型称为 Bio-ANN。表1显示，不同组件彼此互补，并持续提升模型的性能。我们的实证结果表明，采用多个互补组件和学习机制（类似于大脑中的机制），可能是使人工神经网络实现持续学习的有效方法。

4.9 ChallengingCL 设置下的补充结果

为了进一步评估生物组件在更具挑战性的设置下的适用性，我们在 Fashion-MNIST 和灰度版 CIFAR10 上进行了实验。我们同时考察了类别增量学习和领域增量学习设置。Seq-FMNIST、Seq-MNIST 和 Seq-GCIFAR10 将分类任务划分为 5 个任务，每个任务包含 2 个类别；Rot-FMNIST 则包含 20 个任务，每个任务都对 10 个类别进行分类，并将样本按 8 度的增量旋转。

为简洁起见，我们将主动树突与戴尔定律的组合称为 ActiveDANN。为了更好地展示不同组件的作用（在类别增量学习设置下，不带 ER 的 ActiveDANN 会失效），我们以 ActiveDANN 与 ER 的组合作为基线，并在此基础上添加其他组件。表5中的实证结果表明，针对 MNIST 设置得出的发现同样适用于更具挑战性的数据集，而且每个组件都能提升性能。特别是，我们观察到，对于更复杂的数据集，赫布学习能显著提升性能。初步结果表明，在更复杂的数据集和持续学习设置中，生物学机制和架构的作用可能更加显著。

5 讨论

持续学习是智能的标志，而人脑是能够进行持续学习的最高效学习主体。因此，将大脑所采用的不同组件和机制纳入研究，并探究它们之间的相互作用，能够为设计适用于持续学习的人工神经网络提供宝贵见解。尽管已有若干受大脑启发的研究，但它们主要聚焦于某一个方面。既然大脑会同时运用这些不同的组件，那么有理由认为，正是这些组件之间的相互作用或互补性，而非单一组件，使有效学习成为可能。此外，这些组件所依托的底层框架以及学习机制可能……

也可能至关重要。我们对大脑的理解不断加深，并将类似机制融入人工神经网络，这有助于缩小当前人工智能与人类智能之间的差距。这正是我们旨在研究并提请整个研究界关注的根本问题。

我们研究了在持续学习设置下，生物学上合理的框架中不同脑启发机制的影响。底层模型融入了大脑中设计原则和学习机制的若干关键组件：每一层都由相互分离、仅包含兴奋性单元或抑制性单元的群体构成，这符合戴尔定律；同时，为兴奋性锥体神经元增添树突段，以便依赖上下文地处理信息。我们首先表明，具备树突整合特性的、遵循戴尔定律的前馈网络，其表现可与标准人工神经网络相媲美；并且在上下文信号质量较高时，能带来显著的性能提升。随后，我们研究了不同组件各自的作用。我们表明，利用 k-WTA 激活控制激活的稀疏性，并采用鼓励模型为每项任务使用不同神经元集合的异质性丢弃机制，是在特征可复用性与干扰之间维持平衡的有效方法，而这对实现持续学习至关重要。我们还表明，在基于误差的学习之外，加入“共同激发，连接增强”的学习范式，能够进一步强化上下文信号与处理该信号的树突段之间的关联，并促进依赖上下文的门控。为进一步减轻遗忘，我们结合使用突触巩固与经验回放，并证明了它们在具有挑战性的持续学习设置中的有效性。最后，这些组件的综合作用表明，与大脑类似，在生物学上合理的架构中采用多种互补机制，是实现人工神经网络持续学习的有效方法。这也为进一步研究抑制在减轻灾难性遗忘中的作用提供了一个框架。

然而，仍有若干局限性，也存在一些值得未来研究探索的方向。具体而言，树突段为研究在上下文信号中编码不同信息所产生的影响提供了有效机制，因此，哪些信息有助于任务的序列学习，以及不同上下文信号会产生什么影响，都是颇具意义的研究方向。神经科学研究表明，多个大脑区域参与刺激处理；尽管有证据显示，主动树突段接收的上下文信息不同于近端分段接收的输入，但目前尚不清楚上下文信息中编码了什么信息，以及这些信息是如何提取的。本文采用了 Iyer 等（2022）提出的上下文信号，其目的是通过计算任务中所有样本的平均输入图像来编码任务身份。尽管这一方法在 Perm-MNIST 设置中经验证效果良好，但仍有必要考察它在不同持续学习设置下的实用性与局限性。鉴于 Perm-MNIST 的具体设计——数字以二值为中心，且各任务中的排列彼此独立——平均输入图像可以较好地近似所施加的排列，从而有效编码任务身份。然而，对于 Rot-MNIST，这种做法并不简单，因为其任务相似性更高；对于自然图像而言，挑战更大，因为对输入图像取平均无法提供有意义的信号。更重要的是，仅将任务信息编码为上下文信号，而忽视不同任务中出现的类别之间的相似性，似乎并不符合生物学实际。例如，相较于通过不同子网络处理同一数字的轻微旋转版本，以相似方式处理它们（如 Rot-MNIST 中的情况）似乎更为合理。主动树突在旋转版 MNIST 设置下的性能低于标准人工神经网络，也支持了这一观点。理想情况下，同一数字不同旋转版本的上下文信号应高度相似。然而，要设计出能够捕捉任务序列学习中广泛复杂性的上下文信号，颇具挑战。此外，与其手工设计上下文信号，使学习偏向某些类型的任务，不如在端到端训练框架中有效地学习上下文信号；这也是未来研究的一个有趣方向。我们框架的另一项局限是采用了反向传播。反向传播因其缺乏生物学 plausibility 而广受批评，因为它要求前馈和反馈通路使用对称权重矩阵（Xiao 等人），并要求每个神经元都能访问并参与优化单一的全局目标函数。相比之下，大脑中的突触是单向的，前馈连接和反馈连接在物理上彼此分离。此外，人们认为大脑采用局部学习。未来一个有趣的研究方向是，使用更符合生物学实际的学习规则扩展我们的框架，并研究学习规则如何影响这些符合生物学实际的机制之间的相互作用

。未来研究还可以探讨采用比全连接更符合实际的神经元组织方式的作用，例如引入群体编码。

总的来说，我们的研究有力地说明了将大脑的设计原则和学习机制融入人工神经网络的必要性，也支持这样一种观点：提炼大脑学习机制的细节，能够使我们更接近人类智能（Hassabis 等人，2017；Hayes 等人，2021）。此外，深度学习正日益用于神经科学研究，以建模和分析脑数据（Richards 等人，2019）。模型在此类研究中的实用性取决于两个关键方面：模型的性能，以及其架构与大脑的相似程度（Cornford 等，2020；Schrimpf 等人，2020）。我们研究中的生物学上合理的框架融合了大脑的多个设计组件和学习机制，并且在更接近人类学习的（持续学习）任务中表现良好。因此，我们认为，这项工作也可能对神经科学界评估和指导计算神经科学有所帮助。研究与大脑具有更高相似性的人工神经网络的特性，可能有助于我们深入了解大脑功能的机制。我们相信，人工智能与神经科学领域紧密交织，其中一个领域的进步也能够推动另一个领域的发展。

参考文献

Ali Abbasi、Parsa Nooralinejad、Vladimir Braverman、Hamed Pirsiavash 和 Soheil Kolouri。《神经激活零空间中的稀疏性与异质性丢弃法：持续学习方法》。载于终身学习智能体会议，第 617–628 页。机器学习研究论文集，2022 年。

Subutai Ahmad 和 Luiz Scheinkman。我们怎么会如此稠密？使用高度稀疏表示的益处。*arXiv* 预印本 *arXiv:1903.11257*，2019。Rahaf Aljundi、Marcus Rohrbach 和 Tinne Tuytelaars。无私序列学习。载于国际学习表征会议，2019。网址 https://openreview.net/forum?id=Bkxbrn0cYX。Elahe Arani、Fahad Sarfraz 和 Bahram Zonooz。快学，慢学：一种基于互补学习系统的通用持续学习方法。载于国际学习表征会议，2022。网址 https://openreview.net/forum?id=uxxFrDwrE7Y。Helen C Barron、Tim P Vogels、Timothy E Behrens 和 Mani Ramaswami。知觉与记忆中的抑制性记忆印迹。《美国国家科学院院刊》，114(26):6666–6674，2017。Alison L Barth 和 James FA Poulet。新皮层稀疏放电的实验证据。神经科学趋势，35(6):345–355，2012。John M Bekkers。锥体神经元。当代生物学，21(24):R975，2011。Marcus K Benna 和 Stefano Fusi。突触记忆巩固的计算原理。《自然-神经科学》，19(12):1697–1706，2016。Martin Boerlin、Christian K Machens 和 Sophie Denève。平衡脉冲网络中动态变量的预测编码。*PLOS*计算生物学，9(11):e1003258，2013。Arslan Chaudhry、Puneet K Dokania、Thalaiyasingam Ajanthan 和 Philip HS Torr。用于增量学习的黎曼行走：理解遗忘与固执性。载于欧洲计算机视觉会议（*ECCV*）论文集，第532–547页，2018。Arslan Chaudhry、Marc'Aurelio Ranzato、Marcus Rohrbach 和 Mohamed Elhoseiny。利用 a-GEM 实现高效的终身学习。载于国际学习表征会议，2019。网址 https://openreview.net/forum?id=Hkf2_sC5FX。Joseph Cichon 和 Wen-Biao Gan。分支特异性树突钙 2+尖峰引发持久的突触可塑性。《自然》，520(7546):180–185，2015。Jonathan Cornford、Damjan Kalajdzievski、Marco Leite、Amélie Lamarquette、Dimitri Michael Kullmann 和 Blake Aaron Richards。学习与戴尔定律共存：具有独立兴奋性和抑制性单元的人工神经网络。载于国际学习表征会议，2020。

Sebastian Farquhar 和 Yarin Gal。迈向对持续学习的稳健评估。*arXiv* 预印本 *arXiv:1805.09733*，2018。

Timo Flesch、David G Nagy、Andrew Saxe 和 Christopher Summerfield。利用赫布式情境门控和指数衰减的任务信号对人类持续学习进行建模。*PLOS*计算生物学，19(1):e1010808，2023。Peter Foldiak。灵长类皮层中的稀疏编码。《脑理论与神经网络手册》，2003。Kunihiko Fukushima。一种用于模式识别机制的自组织神经网络模型，不受位置变化的影响。生物控制论，36:193–202，1980。Joaquin Fuster。前额叶皮层。学术出版社，2015。Daniel J Graham 和 David J Field。新皮层中的稀疏编码。《神经系统的进化》，3:181–187，2006。Raia Hadsell、Dushyant Rao、Andrei A Rusu 和 Razvan Pascanu。拥抱变化：深度神经网络中的持续学习。认知科学趋势，24(12):1028–1040，2020。Jun Han 和 Claudio Moraga。Sigmoid函数参数对反向传播学习速度的影响。载于国际人工神经网络研讨会，第195–201页。施普林格，1995。Demis Hassabis、Dharshan Kumaran、Christopher Su mmerfield 和 Matthew Botvinick。受神经科学启发的人工智能。神经元，95(2):245–258，2017。Tyler L Hayes、Giri P Krishnan、Maxim Bazhenov、Hava T Siegelmann、Terrence J Sejnowski 和 Christopher Kanan。深度学习中的重放：当前方法与缺失的生物学要素。《神经计算》，33(11):2908–2950，2021。Donald Olding Hebb。《行为的组织：一种神经心理学理论》。心理学出版社，2005。Carl Holmgren、Tibor Harkany、Björn Svennenfors 和 Yuri Zilberter。大鼠新皮层第2/3层局部网络中的锥体细胞通信。《生理学杂志》，551(1):139–153，2003。Kevin Lee Hunter、Lawrence Spracklen 和 Subutai Ahmad。两种稀疏性胜过一种：释放稀疏-稀疏网络的性能优势。*arXiv*预印本 *arXiv:2112.13896*，2021。Alessandro Ingrosso 和 LF Abbott。训练动态平衡的兴奋-抑制网络。*PLOS ONE*，14(8):e0220547，2019。Abhiram Iyer、Karan Grewal、Akash Velu、Lucas Oliveira Souza、Jeremy Forest 和 Subutai Ahmad。避免灾难：主动树突使动态环境中的多任务学习成为可能。神经机器人学前沿，16，2022。James Kirkpatrick、Razvan Pascanu、Neil Rabinowitz、Joel Veness、Guillaume Desjardins、Andrei A Rusu、Kieran Milan、John Quan、Tiago Ramalho、Agnieszka Grabska-Barwinska 等。克服神经网络中的灾难性遗忘。《美国国家科学院院刊》，114(13):3521–3526，2017。Dhireesha Kudithipudi、Mario Aguilar-Simon、Jonathan Babb、Maxim Bazhenov、Douglas Blackiston、Josh Bongard、Andrew P Brna、Suraj Chakravarthi Raja、Nick Cheney、Jeff Clune 等。终身学习机器的生物学基础。《自然·机器智能》，4(3):196–210，2022。Dharshan Kumaran、Demis Hassabis 和 James L McClelland。智能体需要什么样的学习系统？互补学习系统理论的最新进展。认知科学趋势，20(7):512–534，2016。Louis Lapique。关于神经电刺激的定量研究：将其视为极化现象。生理学与病理学杂志，9:620–635，1907。Zhizhong Li 和 Derek Hoiem。无遗忘学习。《*IEEE*模式分析与机器智能汇刊》，40(12):2935–2947，2017。

David Lopez-Paz 和 Marc'Aurelio Ranzato。用于持续学习的梯度情景记忆。载于神经信息处理系统进展，第6467–6476页，2017。Arun Mallya、Dillon Davis 和 Svetlana Lazebnik。Piggyback：通过学习屏蔽权重，使单个网络适应多个任务。载于欧洲计算机视觉会议（*ECCV*）论文集，第67–82页，2018。Valerio Mante、David Sussillo、Krishna V Shenoy 和 William T Newsome。前额叶皮层中由循环动力学实现的上下文依赖计算。自然，503(7474):78–84，2013。James L McClelland、Bruce L McNaughton 和 Randall C O'Reilly。为什么海马体和新皮层中存在互补学习系统：从连接主义学习与记忆模型的成功和失败中得到的启示。心理学评论，102(3):419，1995。Earl K Miller 和 Jonathan D Cohen。前额叶皮层功能的整合理论。神经科学年度评论，24(1):167–202，2001。Brendan K Murphy 和 Kenneth D Miller。平衡放大：一种选择性放大神经活动模式的新机制。神经元，61(4):635–648，2009。Erkki Oja。作为主成分分析器的简化神经元模型。数学生物学杂志，15(3):267–273，1982。Blake A Richards、Timothy P Lillicrap、Philippe Beaudoin、Yoshua Bengio、Rafal Bogacz、Amelia Christensen、Claudia Clopath、Rui Ponte Costa、Archy de Berker、Surya Ganguli 等。神经科学的深度学习框架。《自然-神经科学》，22(11):1761–1770，2019。Martin Schrimpf、Jonas Kubilius、Ha Hong、Najib J Majaj、Rishi Rajalingham、Elias B Issa、Kohitij Kar、Pouya Bashivan、Jonathan Prescott-Roy、Franziska Geiger 等。Brain-Score：哪种人工神经网络在物体识别方面最接近大脑？*bioRxiv*，第407007页，2020。Markus Siegel、Timothy J Buschman 和 Earl K Miller。灵活感觉运动决策过程中的皮层信息流。《科学》，348(6241):1352–1355，2015。Piergiorgio Strata、Robin Harvey 等。戴尔定律。《脑研究通报》，50(5):349–350，1999。David J Tolhurst、Darragh Smyth 和 Ian D Thompson。雪貂初级视觉皮层中神经元反应的稀疏性。《神经科学杂志》，29(8):2355–2370，2009。Robin Tremblay、Soohyun Lee 和 Bernardo Rudy。新皮层中的GABA能中间神经元：从细胞特性到神经回路。神经元，91(2):260–292，2016。Carl Van Vreeswijk 和 Haim Sompolinsky。具有平衡的兴奋与抑制活动的神经元网络中的混沌。《科学》，274(5293):1724–1726，1996。Jeffrey S Vitter。使用蓄水池进行随机抽样。《*ACM*数学软件汇刊》（*TOMS*），11(1):37–57，1985。Matthew P Walker 和 Robert Stickgold。睡眠依赖性学习与记忆巩固。神经元，44(1):121–133，2004。Will Xiao、Honglin Chen、Qianli Liao 和 Tomaso Poggio。生物学上合理的学习算法能够扩展至大型数据集。载于国际学习表征会议。Guang Yang、Feng Pan 和 Wen-Biao Gan。稳定维持的树突棘与终身记忆相关。自然，462(7275):920–924，2009。Guang Yang、Cora Sau Wan Lai、Joseph Cichon、Lei Ma、Wei Li 和 Wen-Biao Gan。睡眠促进学习后树突棘的分支特异性形成。《科学》，344(6188):1173–1178，2014。

Guanxiong Zeng、Yang Chen、Bo Cui 和 Shan Yu。《神经网络中依赖上下文的处理的持续学习》。《自然·机器智能》，1(8):364–372，2019。

Friedemann Zenke、Ben Poole 和 Surya Ganguli。通过突触智能实现持续学习。载于国际机器学习大会，第3987–3995 页。机器学习研究论文集，2017 年。

A 附录

A.1 相关工作——受生物启发的人工智能

长期以来，人脑一直是人工神经网络设计的灵感来源（Hassabis et al., 2017；Kudithipudi et al., 2022）。然而，我们未能充分利用对大脑不断加深的认识，而且大脑与人工神经网络所采用的设计原则和学习机制存在根本差异。这些差异或许可以解释二者在性能和行为上的巨大差距。

从架构设计的角度来看，标准人工神经网络主要基于点神经元模型（Lapique，1907）。这种模型已经过时，且对生物计算的描述过于简化，无法体现大脑中复杂且依赖上下文的处理过程。此外，标准人工神经网络中的神经元不遵循戴尔定律（Strata 等，1999），而大脑中的大多数神经元都遵循这一原则。与大脑不同，在大脑中，突触前神经元对其突触后神经元的作用要么完全是兴奋性的，要么完全是抑制性的；标准人工神经网络中的神经元则同时具有正、负输出权重，且权重符号会在学习过程中发生变化。这是人工神经网络与大脑在底层设计原则上的两个主要差异。

近期有两项研究试图弥补这一空白。Cornford 等人（2020）以更符合生物学合理性的方式将戴尔定律融入人工神经网络（DANN），并表明在考虑某些初始化和正则化因素后，DANN 在物体识别任务上的表现可与标准人工神经网络相当，而早期尝试未能做到这一点。我们的研究将 DANN 扩展到更具挑战性的持续学习设置，并表明，考虑兴奋性神经元和抑制性神经元中权重变化所产生影响的差异，可以进一步减少持续学习中的遗忘。Iyer 等人（2022）提出了一种替代点神经元模型的方法，并对新皮层中的锥体神经元进行了算法抽象。每个神经元都增设了树突段，用于接收额外的上下文信号；树突段的输出会调节神经元的活动，从而实现依赖上下文的信息处理。我们的研究基于他们的工作，提出了一种生物学上合理的架构，该架构既遵循戴尔定律，也具备锥体神经元的依赖上下文的处理特性。这为我们研究脑启发机制的作用提供了一个框架，也使我们能够在更接近人类学习的、更具挑战性的持续学习设置中研究抑制的作用。

从学习的角度来看，已有多种方法受到大脑的启发，尤其是在持续学习领域（Kudithipudi等，2022年）。海马体中的重放机制（Kumaran等，2016年）启发了一系列基于复习的方法（Hayes等，2021年；Hadsell等，2020年），这些方法已被证明在具有挑战性的持续学习场景中有效（Farquhar与Gal，2018年）。另一种广受欢迎的持续学习方法——基于正则化的方法（Zenke等人，2017年；Kirkpatrick等人，2017年）——则受到神经生物学模型的启发。这些模型认为，新皮层中的持续学习基于任务特定的突触巩固过程，该过程会降低一定比例突触的可塑性，使其能在长时间尺度上保持稳定（Benna与Fusi，2016年；Yang等，2009年）。尽管这两种方法都受到大脑的启发，研究人员大多忽视了这样一个事实：大脑会结合使用这两种机制来巩固信息，而非孤立地使用其中一种。因此，针对这两种方法的研究彼此独立。此外，这些方法都应用于标准人工神经网络之上，而标准人工神经网络并不能体现大脑中神经元的复杂性。我们的研究在一种生物学上更合理的架构中结合使用重放与突触巩固，并表明二者能够相辅相成，提升性能。

此外，我们的框架采用了多种技术来模拟大脑中激活的特征。新皮层中的锥体神经元彼此之间具有高度稀疏的连接性（Hunter 等人，2021；Holmgren 等人，2003），且对于给定刺激，只有一小部分（$<2\%$）神经元处于活跃状态（Barth & Poulet，2012）。因此，我们采用 k胜者全得（k-WTA）激活（Ahmad & Scheinkman，2019）来模拟激活稀疏性。多项研究表明，稀疏性有利于持续学习（Abbasi 等人，2022；Mallya 等人，2018；Aljundi 等人，2019），但这些研究没有考虑到，大脑不仅利用稀疏性，还以高效的方式利用它来编码信息。大脑通过一组相对较少的神经元产生强激活来编码信息，从而形成稀疏编码。不同类型的刺激由不同的神经元子集表示（Foldiak，2003），而语义相似的刺激会激活一组相似的

神经元。异质性丢弃（Abbasi 等人，2022）与 k-WTA 激活相结合，旨在通过促使新任务利用一组新的神经元进行学习，来模拟这些特征。最后，我们认为，不仅要纳入生物神经元的设计要素，还要纳入它们所采用的学习机制，这一点同样重要。大脑中的终身可塑性通常遵循赫布原则（Hebb，2005）。因此，我们采用 Flesch 等人（2023）的方法，以赫布更新补充基于误差的学习，从而增强上下文信息与树突段之间的连接，并表明这会强化上下文门控。

我们的研究提出了一种生物学上合理的框架，其底层架构能够根据上下文处理信息，并遵循戴尔定律。此外，该框架还采用了大脑的学习机制（经验回放、突触巩固和赫布更新）及其特征（稀疏非重叠激活和任务特定子网络）。据我们所知，我们首次全面研究了持续学习场景中，在生物学上合理的架构内整合不同脑启发机制这一问题。

A.2 训练复杂度

此处讨论框架中不同组件的训练复杂度。虽然 Dale 原则会增加额外的学习参数，但减性抑制可以高效实现，因为有效权重可表示为 $W^l = W^l_{ee} - W^l_{ei}W^l_{ie}$。此外，抑制性神经元的数量远少于兴奋性神经元，因此额外参数数量不多。主动树突的计算成本包括两部分：为任务创建上下文信号的成本，以及随后在树突段中计算调制信号的成本。这两部分都很大程度上取决于评估上下文信号的具体方法，以及上下文向量的维度。所实现的方法采用任务所有训练样本的平均输入图像，因此需要额外遍历训练样本一次，并且上下文向量的维度与输入图像的维度相同。更高效地创建上下文向量的方法将显著降低主动树突的计算成本。另一方面，激活稀疏性可大幅减少前向传播和反向传播所需的计算量（例如，前向传播中只有 5% 的单元处于激活状态，因此只有这些单元会参与训练）；如果编译器和硬件支持稀疏计算，这一优势尤为明显。异质性丢弃不会显著增加计算开销，因为它只涉及跟踪模型的激活计数，并在训练期间应用掩码操作。突触智能无需额外的前向传播即可在线估计参数重要性。不过，它会保留模型先前权重的检查点，以便对权重变化施加惩罚。

我们想强调，大脑能够高效地运用一系列复杂机制。随着我们越来越关注在人工神经网络中采用类似机制及其互补交互作用，沿着这一前景广阔的方向开展研究，必将带来更高效、更有效的学习。

A.3 标准人工神经网络上的生物学组件

为进一步评估生物学机制在我们框架中的适用性，以及底层生物学上合理的架构所发挥的作用，我们在标准人工神经网络的基础上进行了一项消融研究。表 6 展示了在标准人工神经网络中使用 k胜者全得引入激活稀疏性后的效果，随后依次加入异质性丢弃（HD）、突触巩固（SC）和经验回放（ER），最后组合所有组件（标准生物学人工神经网络）。结果表明，激活稀疏性显著提升了在 Perm-MNIST 上的性能。然而，它降低了在 Rot-MNIST 上的性能，这可能归因于活跃神经元数量较少，或缺乏前向迁移，因为任务相似性较高。加入生物学组件后，性能得到了一致的提升，与原始设置中的结果相似。其结果低于 ActiveDA NN 实验的结果，这进一步支持了这样的观点：在生物学上合理的架构基础上加入生物学机制，能够带来更好的效果。

表 6：在不同任务数量下，生物学上合理的框架中各组件对标准人工神经网络在不同数据集上的影响。我们给出五次运行的平均任务表现和 1 个标准差。

方法	Rot-MNIST			Perm-MNIST			Seq-MNIST
	5	10	20	5	10	20	
联合	98.27±0.07	98.25±0.06	98.17±0.11	97.64±0.19	97.61±0.15	97.59±0.08	94.53±0.50
标准人工神经网络	93.79±0.32	74.13±0.36	51.89±0.36	77.96±8.34	76.42±2.54	65.18±2.12	19.83±0.04
+ 激活稀疏性	92.36±0.30	70.61±0.51	48.04±0.32	93.14±0.32	87.01±0.80	72.22±0.92	19.85±0.02
+ HD	92.72±0.36	72.97±0.55	49.54±0.69	93.80±0.31	89.07±0.82	74.38±0.59	24.28±8.28
+ SC	93.77±0.28	74.68±0.48	51.45±1.01	96.07±0.11	95.30±0.19	92.86±0.43	20.19±0.25
+ ER	94.81±0.21	87.84±0.37	76.09±0.51	95.52±0.08	93.11±0.17	86.34±0.27	81.44±0.72
标准生物人工神经网络	**96.66**±0.09	**93.32**±0.28	**88.57**±0.50	**96.72**±0.04	**96.27**±0.05	**95.35**±0.10	**89.67**±0.46

表7：在 Rot-MNIST 上进行 5 个任务的实验，每个后续任务的增量旋转程度各不相同（θ_{inc}），比较不同丢弃强度（ρ）下的前向迁移。报告 5 次运行的平均值和标准差。

ρ^{l_1}, ρ^{l_2}	任务相似性 (θ_{inc})					
	2	4	8	16	24	32
无丢弃法	88.78±0.90	88.10±0.98	86.52±0.47	82.35±0.75	73.94±0.82	60.37±0.87
0.1, 0.1	88.85±0.75	88.05±0.81	86.99±0.78	82.45±0.88	73.30±0.34	60.03±1.35
0.5, 0.5	88.96±0.76	88.31±0.91	87.11±0.80	82.33±0.82	73.66±0.54	59.94±1.64
1.0, 1.0	88.92±0.83	88.10±0.86	86.89±0.75	81.97±0.89	72.80±0.52	59.54±0.96
5.0, 5.0	88.38±0.83	87.62±0.92	85.73±0.96	78.76±0.93	67.75±1.16	53.65±1.07

A.4 前向与后向迁移

为了进一步理解模块化对模型稳定性和可塑性的影响，我们根据任务相似性以及通过不同强度的异质性丢弃所施加的模块化程度，评估模型的前向迁移和遗忘程度（Chaudhry 等人，2018）。前向迁移用于评估模型相对于随机猜测而言，是否能够在未见过的任务上取得更好的表现，而遗忘则用于衡量模型在后续任务中出现的性能下降。我们将遗忘定义为模型在某项任务上的最大性能（即该任务学习完成时的性能）与所有任务训练结束时的最终准确率之间的平均差值。在包含 5 个任务的 Rot-MNIST 设置中，我们改变每个后续任务的增量旋转角度 θ_{inc}，以模拟不同程度的任务相似性，其中较大的 θ_{inc} 对应于差异更大的任务。通过设置不同强度的异质性丢弃（ρ 参数）来控制模块化程度，其中较高的 ρ 值对应于较低的表征重叠程度，因而具有较高的模块化程度。

表7展示了前向迁移，表8展示了后向迁移。我们观察到，通常任务之间越不相似，前向迁移就越少，遗忘也越严重。此外，提高模块化程度（更高的 ρ 值）通常会减少前向迁移，同时减轻遗忘。异质性丢弃为我们提供了一种有效机制，用于控制模型的可塑性和稳定性；在稳定性与可塑性之间实现最佳平衡，可以带来最佳性能。有趣的是，我们观察到，在某些相似度较高的情形下，适度的模块化有时会增加前向迁移。

A.5 实验设置

为了研究生物学上合理的神经网络中受大脑启发的不同组件在持续学习中的作用，并衡量它们对模型性能和特性的影响，我们进行了所有实验。

表 8：在 Rot-MNIST 上，针对每个后续任务采用不同程度增量旋转的 5 个任务，使用不同丢弃强度（ρ）时的遗忘程度（θ_{inc}）。报告 5 次运行的平均值和标准差。

ρ^{l_1}, ρ^{l_2}	任务相似性（θ_{inc}）					
	2	4	8	16	24	32
不使用丢弃法	$0.47_{\pm 0.16}$	$1.30_{\pm 0.25}$	$7.10_{\pm 0.60}$	$29.96_{\pm 3.04}$	$43.06_{\pm 2.61}$	$50.96_{\pm 1.96}$
0.1, 0.1	$0.38_{\pm 0.14}$	$1.19_{\pm 0.29}$	$6.50_{\pm 1.55}$	$26.87_{\pm 1.58}$	$42.03_{\pm 0.46}$	$50.45_{\pm 1.07}$
0.5, 0.5	$0.13_{\pm 0.14}$	$0.81_{\pm 0.31}$	$6.12_{\pm 1.28}$	$25.93_{\pm 2.00}$	$41.63_{\pm 1.71}$	$46.78_{\pm 2.08}$
1.0, 1.0	$0.12_{\pm 0.10}$	$0.61_{\pm 0.19}$	$5.52_{\pm 1.04}$	$23.77_{\pm 0.71}$	$38.29_{\pm 1.39}$	$44.36_{\pm 2.43}$
5.0, 5.0	$0.61_{\pm 0.25}$	$1.46_{\pm 0.22}$	$5.81_{\pm 0.06}$	$21.82_{\pm 1.37}$	$27.39_{\pm 1.11}$	$30.95_{\pm 1.83}$

表 9：展示各组件独立作用的实验所选用的超参数（表1）。所有实验的基础学习率为 0.3，各组件对 W_{ie} 和 W_{ei} 使用相同的学习率（+ 戴尔定律）。对于 + SC 实验，我们使用 $\lambda_{W_{ie}}$=10 和 $\lambda_{W_{ei}}$=10。对于经验回放实验，我们使用 500 个样本的内存预算。

数据集	#任务	+ 戴尔定律	+ 赫布更新	+ SC	+ ER	+ 经验回放 +CR
Rot-MNIST	5	$\eta_{W_{ie}}$=3e-2, $\eta_{W_{ei}}$=3e-3	n_h=3e-10	λ=0.25	α=1, β=0	α=1, β=0.50
	10	$\eta_{W_{ie}}$=3e-2, $\eta_{W_{ei}}$=3e-3	n_h=3e-08	λ=0.25	α=1, β=0	α=1, β=0.50
	20	$\eta_{W_{ie}}$=3e-3, $\eta_{W_{ei}}$=3e-4	n_h=3e-10	λ=1.00	α=1, β=0	α=1, β=0.50
Perm-MNIST	5	$\eta_{W_{ie}}$=3e-2, $\eta_{W_{ei}}$=3e-2	n_h=3e-09	λ=0.10	α=1, β=0	α=1, β=0.50
	10	$\eta_{W_{ie}}$=3e-2, $\eta_{W_{ei}}$=3e-2	n_h=3e-06	λ=0.25	α=1, β=0	α=1, β=0.50
	20	$\eta_{W_{ie}}$=3e-2, $\eta_{W_{ei}}$=3e-3	n_h=3e-09	λ=0.10	α=1, β=0	α=1, β=0.50
Seq-MNIST	5	$\eta_{W_{ie}}$=3e-2, $\eta_{W_{ei}}$=3e-3	n_h=3e-07	λ=0.25	α=1, β=0	α=1, β=0.25

在统一设置下。除非另有说明，我们使用一个包含两个隐藏层的多层感知机（MLP），每个隐藏层包含 2048 个单元，并采用 k-WTA 激活。每个神经元都增设 N 个树突段，其中 N 对应任务数量，而维度对应上下文向量的维度，该向量对应输入图像的大小（所有基于 MNIST 的设置均为 784）。模型在每个任务上训练 3 个训练轮次，使用随机梯度下降优化器，学习率为 0.3，批量大小为 128。我们将权重稀疏度设为 0，并将活跃神经元的比例设为 5%。对于涉及戴尔定律的实验，我们保持每层单元总数不变，并将其分为 1844 个兴奋性单元和 204 个抑制性单元。只有兴奋性单元会增设树突段。重要的是，我们采用 Cornford 等人（2020）提出的初始化策略和随机梯度下降更新校正，以考虑对不同参数的更新影响层输出分布的程度存在差异这一问题。与兴奋性参数的更新相比，抑制性单元参数的更新会按比例缩小。具体而言，对 W_{ie} 的梯度更新按 $\sqrt{n_e}^{-1}$ 缩放，对 W_{ei} 则按 d^{-1} 缩放，其中n_e 是该层中的兴奋性神经元数量，d 是该层的输入维度。此外，为不同设置选择超参数时，我们使用一个小型验证集。请注意，我们的目标并非获得尽可能高的准确率，而是展示各个组件的作用，因此没有进行大规模超参数搜索。表 9 列出了表 1 中单个组件实验所选用的超参数，表 10 列出了 Bio-ANN 实验所选用的超参数。我们报告所有任务的平均准确率，以及在三个不同随机种子下的 1 个标准差。

A.6 调整抑制性权重的影响

DANN层的抑制性中间神经元架构导致不同参数更新对层输出分布的影响程度存在差异。例如，若更新 W_{ie} 中的单个元素，

表 10：表1中 Bio-ANN 实验所选用的超参数。对于每种设置，我们均采用与 + 戴尔定律（表 9）相同的学习率。

数据集	#任务	n_h	λ	ρ	α	β
Rot-MNIST	5	3e-8	0.25	0.1	1	0.5
	10	3e-8	0.1	0.3	1	0.5
	20	3e-8	0.1	0.3	1	0.5
Perm-MNIST	5	3e-6	0.1	0.1	1	0.5
	10	3e-8	0.1	0.3	1	0.5
	20	3e-8	0.1	0.3	1	0.5
Seq-MNIST	5	3e-6	0.1	0.1	1	0.25

表11：在不同任务数量下的不同数据集上，第一个任务结束时调整 W_{ie} 和 W_{ei} 的学习率的效果。

η_{Wie}	η_{Wei}	Rot-MNIST			Perm-MNIST		
		5	10	20	5	10	20
3e-1	3e-1	92.12$_{\pm 0.34}$	70.86$_{\pm 0.44}$	46.30$_{\pm 1.03}$	95.78$_{\pm 0.19}$	94.73$_{\pm 0.36}$	**92.67**$_{\pm 0.61}$
3e-2	3e-2	92.23$_{\pm 0.53}$	70.23$_{\pm 1.12}$	47.53$_{\pm 1.79}$	95.77$_{\pm 0.33}$	**95.06**$_{\pm 0.29}$	91.63$_{\pm 0.39}$
3e-2	3e-3	92.28$_{\pm 0.27}$	70.78$_{\pm 0.23}$	47.32$_{\pm 1.43}$	95.68$_{\pm 0.14}$	94.96$_{\pm 0.49}$	92.40$_{\pm 0.38}$
3e-3	3e-3	**92.34**$_{\pm 0.51}$	**71.27**$_{\pm 1.69}$	47.81$_{\pm 1.10}$	95.70$_{\pm 0.29}$	94.44$_{\pm 0.70}$	92.02$_{\pm 0.19}$
3e-3	3e-4	92.03$_{\pm 0.09}$	70.79$_{\pm 1.75}$	**48.79**$_{\pm 0.27}$	**95.90**$_{\pm 0.13}$	94.19$_{\pm 0.47}$	91.04$_{\pm 0.34}$

则会影响该层输出的每个元素。将 δ 更新为 W_{ie} 的抑制性权重更新，对模型分布造成的影响约为将 δ 更新为 W_{ee} 的兴奋性权重更新的 n_e 倍（Cornford 等，2020）。在持续学习（CL）情境下，这种差异的影响会更加显著，因为学习新任务时输出分布发生较大变化，可能导致对先前任务的遗忘加剧。为应对这些差异，我们在学习完第一个任务后进一步降低 W_ie 和 W_ei 的学习率。表11显示，在大多数设置中，考虑到抑制性神经元的影响更大，可以进一步提升模型性能。未来值得探索更适用于持续学习、并考虑其对遗忘影响的更优方法，以应对上述差异。

A.7 调整抑制性权重重要性估计缩放的效果

与调整抑制性权重的学习率类似，我们检验了放大抑制性神经元的重要性估计，是否能进一步提高突触巩固减少遗忘的效果。表12显示，根据抑制性权重对输出分布及遗忘的影响程度来缩放重要性估计，在大多数情况下都能进一步提升性能，尤其是在任务数量较少时。这表明，专门针对含抑制性神经元的网络设计正则化方法，是一个很有前景的研究方向。

A.8 稀疏性的影响

为进一步研究激活和连接中不同稀疏程度的影响，我们改变初始化时随机设为零的权重数量（$S_W \in \{0，0。25，0。50\}$）以及每个隐藏层中活跃神经元的比例（k^{l1}，k^{l2}）。表13显示，激活稀疏性在使人工神经网络实现持续学习方面发挥着关键作用。有趣的是，在活跃神经元比例较高时（≥ 0.2），连接稀疏性对 Perm-MNIST 有相当大的作用。此外，进一步探索不同层激活稀疏性的细微差异，或许能够提升性能。与异质性丢弃类似，我们在表14中展示了激活稀疏性与任务相似性之间的关系。相似任务（较低的 θ_{inc}）会受益于更多活跃

表12：缩放 W_{ie} 和 W_{ei} 的抑制性权重重要性估计，以减少参数偏移，在任务数量不同的 Rot-MNIST 和 Perm-MNIST 数据集上的效果。

λ	$\lambda_{W_{ie}}$	$\lambda_{W_{ei}}$	Rot-MNIST			Perm-MNIST		
			5	10	20	5	10	20
0.1	1	1	92.92±0.22	75.53±1.46	52.16±1.17	96.59±0.17	96.20±0.13	**95.69**±0.10
	10	10	92.77±0.27	74.70±1.05	51.94±1.05	96.57±0.34	96.18±0.18	95.64±0.15
	10	100	92.50±0.65	74.67±1.27	52.55±1.12	**96.67**±0.23	96.26±0.26	95.61±0.10
0.25	1	1	92.77±0.69	**76.30**±0.77	55.05±2.47	96.62±0.28	96.07±0.02	95.36±0.24
	10	10	**93.54**±0.79	75.44±0.81	54.93±2.35	96.54±0.22	96.23±0.16	95.03±0.13
	10	100	93.40±0.86	75.87±1.35	55.06±1.77	96.65±0.25	**96.36**±0.10	95.18±0.29
0.5	1	1	93.23±0.71	75.24±0.62	**60.24**±2.02	96.22±0.37	95.97±0.06	92.94±0.85
	10	10	93.13±0.24	75.95±0.38	59.35±1.53	96.24±0.51	95.81±0.10	92.86±0.87
	10	100	92.85±0.42	75.85±1.18	58.94±2.15	96.36±0.42	96.02±0.27	93.48±0.57
无 SC			92.28±0.27	70.78±0.23	48.79±0.27	95.77±0.33	95.06±0.29	92.40±0.38

表13：在任务数量逐渐增加时，激活稀疏性（活跃神经元比例，(k^{l1}，k^{l2})，分别对应 1st 和 2nd 隐藏层）以及连接稀疏性（零权重比例，S_W）对 Rot-MNIST 和 Perm-MNNIST 的影响。每项任务在不同稀疏性水平下的最佳表现以粗体标出。

	#任务	S_W	激活稀疏性 (k^{l1}, k^{l2})						
			(0.05, 0.05)	(0.1, 0.05)	(0.1, 0.1)	(0.2, 0.1)	(0.2, 0.2)	(0.5, 0.2)	(0.5, 0.5)
Rot-MNIST	5	0.00	92.28±0.27	92.63±0.46	92.26±0.31	92.25±0.71	**92.79**±0.44	92.51±0.50	92.26±0.65
		0.25	91.22±0.58	91.50±0.36	92.33±0.26	91.75±0.30	92.60±0.19	91.23±1.63	91.66±0.46
		0.50	90.78±0.11	91.15±0.34	91.25±0.14	91.25±0.92	90.67±0.73	90.75±0.86	90.41±1.48
	10	0.00	70.78±0.23	71.16±0.51	71.95±1.54	72.22±0.63	**73.32**±0.69	71.89±0.62	71.61±0.76
		0.25	70.23±0.76	71.42±0.98	71.84±0.72	73.22±1.34	72.58±0.64	72.23±0.71	71.23±0.84
		0.50	69.61±0.50	70.59±0.62	70.94±0.71	72.05±0.34	72.25±1.40	71.37±0.65	70.85±0.67
	20	0.00	**48.79**±0.27	48.01±0.58	47.96±1.84	48.33±1.23	48.65±0.91	48.19±0.14	47.71±0.91
		0.25	47.72±0.83	48.61±0.30	48.41±0.84	48.53±1.77	48.30±0.87	48.29±1.59	47.11±0.44
		0.50	46.20±0.26	47.15±1.37	48.02±1.10	48.17±1.42	48.30±1.41	47.66±1.53	47.73±0.51
Perm-MNIST	5	0.00	95.77±0.33	95.55±0.27	**96.43**±0.10	95.85±0.29	90.29±6.07	88.18±8.86	74.51±13.55
		0.25	95.45±0.25	95.14±0.27	95.65±0.22	95.75±0.32	93.73±1.29	87.49±2.33	75.97±5.61
		0.50	93.95±0.65	94.19±0.41	94.90±0.22	94.22±1.19	94.05±0.81	91.02±3.71	83.94±9.58
	10	0.00	**95.06**±0.29	94.08±0.95	94.38±0.73	89.54±2.27	78.91±5.26	76.44±7.93	35.86±2.04
		0.25	94.51±0.12	93.52±0.01	93.62±0.64	88.58±2.17	84.94±3.58	69.32±6.24	59.53±9.57
		0.50	92.12±0.62	90.31±2.01	92.29±0.73	88.48±0.22	82.57±2.40	74.42±2.84	69.31±5.66
	20	0.00	**92.40**±0.38	89.41±1.73	84.28±1.35	73.29±2.60	63.84±3.45	58.85±5.00	20.80±0.99
		0.25	90.75±0.63	89.22±0.94	84.29±2.17	75.82±6.68	67.26±1.22	63.96±1.19	41.60±2.64
		0.50	87.31±0.82	84.90±1.99	83.72±0.63	69.62±5.98	66.27±2.74	64.42±2.33	51.92±3.79

能够增加前向迁移的神经元；而对于不相似的任务（较高的 θ_{inc}），提高激活稀疏性、减少表征重叠则能带来更好的效果。

表14：在包含 5 个任务的 Rot-MNIST 上，不同激活稀疏性水平的影响；每个后续任务的增量旋转程度各不相同（θ_{inc}）。第 0 行显示了 1st 和 2nd 隐藏层中活跃神经元的比例（k^{l_1}、 k^{l_2}）。

(k^{l_1}, k^{l_2})	任务相似性（θ_{inc}）					
	2	4	8	16	24	32
0.05, 0.05	97.54±0.06	96.56±0.14	91.95±0.54	75.13±0.83	63.14±0.52	57.01±0.89
0.1, 0.05	97.57±0.32	96.84±0.18	92.49±0.59	76.15±1.28	64.03±1.12	58.56±1.17
0.1, 0.1	97.81±0.08	96.84±0.30	92.28±0.31	**76.80**±1.20	**64.91**±1.17	**58.62**±1.70
0.2, 0.1	97.44±0.74	96.88±0.45	92.47±0.69	75.79±1.26	64.38±1.58	58.34±1.54
0.2, 0.2	**97.88**±0.11	**97.27**±0.15	**92.79**±0.50	76.22±1.46	64.30±1.38	57.22±1.06
0.5, 0.2	97.67±0.64	96.92±0.78	92.61±0.65	75.66±0.95	63.86±0.61	56.11±1.20
0.5, 0.5	97.67±0.55	97.03±0.53	92.29±0.58	74.55±1.01	62.37±0.62	53.13±3.62

算法 1 Bio-ANN：一种适用于持续学习的生物学上合理的框架。

输入： 数据流 $\mathcal{D}$；学习率 η, $\eta_{W_{ie}}$, $\eta_{W_{ei}}$；赫布学习率 η_h；异质性丢弃 ρ；突触巩固权重 λ, $\lambda_{W_{ie}}$, $\lambda_{W_{ei}}$, γ；经验回放权重 α, β

初始化：

模型权重 θ，参考权重 $\theta_c = \{\}$,任务原型 $C_\tau = \{\}$

异质性丢弃：总体激活计数 $A_\tau = 0$，保留概率 $P_\tau = 1$

内存缓冲区 $\mathcal{M} \leftarrow \{\}$

突触智能：$\omega = 0$，$\Omega = 0$

▷ 从数据流中采样任务

对于 $D_\tau \in \{D_1, D_2, .., D_T\}$ **执行**

▷ 任务上下文

评估上下文向量（公式 2）：

$c_\tau = \frac{1}{|D_\tau|} \sum_{x \in \mathcal{D}_\tau} x$

更新原型集合：

$C_\tau \leftarrow \{C_\tau, c_\tau\}$

▷ 在任务 τ 上训练

当训练 **执行**

样本数据：$(x_b, y_b) \sim \mathcal{D}_\tau$ 和 $(x_m, y_m, z_m) \sim \mathcal{M}$

。任务特定损失

获取当前任务批次的模型输出和激活计数：

$z_b, a_b = F(x_b, c_\tau;\ \theta, P_\tau)$ # 应用异质性丢弃

计算任务损失：

$L_\tau = L_{cls}(z_b, y_b)$

更新总体激活计数：

$A_\tau \leftarrow$更新激活计数(a_t)

▷经验回放

推断缓冲区样本的上下文（公式 3）：

$c_m = \arg\min_{c_\tau} \|x' - C_\tau\|_2$

获取缓冲区样本的模型输出：

$z = F(x_m, c_m;\ \theta)$ # 禁用异质性丢弃

计算重放损失：

$\mathcal{L}_{er} = \alpha \mathcal{L}_{cls}(z, y_m) + \beta(z - z_m)^2$

▷ 突触正则化

计算 SI 损失：

$\mathcal{L}_{sc} = \Omega^{adj}(\theta - \theta_c)^2$

计算总体损失，并将梯度裁剪至 0 到 1 之间：

$L = L_\tau + L_{er} + L_{sc}$

$\nabla_\theta \mathcal{L} = \text{Clip}(\nabla_\theta \mathcal{L}, 0, 1)$

▷ 更新模型

随机梯度下降更新：$\theta =$ 更新模型$(\nabla_\theta \mathcal{L}, \eta, \eta_{W_{ie}}, \eta_{W_{ei}})$

树突段上的赫布更新：$U =$赫布式步骤$(\{c_\tau, c_m\}, U)$

更新小 ω：$\omega = \omega + \eta \nabla^2_\theta \mathcal{L})$ ▷ 更新 SI 参数

$\mathcal{M} \leftarrow Reservoir(\mathcal{M}, (x_b, y_b, z_b))$ ▷ 更新内存缓冲区（算法 2）

▷ 任务边界

更新保留概率（公式 5）：$P_\tau = exp(\frac{-A_\tau}{\text{最大值}\ A_\tau} \rho)$

更新 SI Omega 和参考权重，并重置小 omega：

$\Omega = \Omega + \frac{\omega}{(\theta - \theta_c)^2 + \gamma}$

$\omega = 0$

$\theta_c = \theta$

提高抑制性权重的重要性

$\Omega^{adj} =$ScaleUpInhib$(\Omega, \lambda_{W_{ie}}, \lambda_{W_{ei}})$

return θ

算法 2 蓄水池抽样

输入： 内存缓冲区 $\mathcal{M}$，缓冲区大小 $\mathcal{B}$，迄今为止见过的样本数 N，数据点 (x, y, z)

如果 $\mathcal{B} > N$ **则** ▷ 检查记忆是否已满
    $\mathcal{M}[N] \leftarrow (x, \ y, \ z)$
否则
    $n =$ 随机整数抽样(min=0, 最大值=N) ▷ 选择要替换的样本
    若 $n < \mathcal{B}$ **则**
        $\mathcal{M}[n] \leftarrow (x, \ y, \ z)$
return $\mathcal{M}$