神经元负载均衡：放电率控制维持持续学习中的可塑性

Jan Robine *jan.robine@tu-dortmund.de*
计算机科学系 多特蒙德工业大学 *Lamarr* 机器学习与人工智能研究所

Marc Höftmann *marc.hoeftmann@tu-dortmund.de*
Computer 科学系 多特蒙德工业大学 *Lamarr* 机器学习与人工智能研究所

Stefan Harmeling *stefan.harmeling@tu-dortmund.de*
Computer 科学系 多特蒙德工业大学 *Lamarr* 机器学习与人工智能研究所

arXiv:2611.32691v1 [cs.LG] 24 Nov 2026

摘要

持续学习中的神经网络往往会失去可塑性：一些神经元变得不活跃，而另一些神经元几乎持续放电。这限制了网络对变化数据的适应能力，也浪费了容量。以往工作通过定期重新初始化低效用单元来缓解这一问题，但这种重置可能会破坏此前已学习的特征，并且无法主动防止低效用的产生。我们研究了一种简单的诊断指标：ReLU 单元的放电率，即正预激活值所占的比例。较低的放电率可识别死亡单元，而极高的放电率则表明单元已线性化、始终处于开启状态。基于这一观点，我们提出了一种轻量级负载均衡机制，通过调整逐神经元阈值，使放电率保持在目标范围内。在持续学习 ImageNet 和类别增量 CIFAR-100 上，放电率分布解释了多种方法之间的可塑性差异，其中包括 L2 正则化和非仿射归一化等知名技术；在两个基准测试中，负载均衡的效果均达到或超过基于重置的方法。同一机制还可迁移至强化学习，在以层归一化为基线的情况下提升 Atari 上 Rainbow DQN 的表现。

1 引言

深度学习模型在固定数据集上进行训练时，已在广泛的任务中取得最先进的性能（He 等人，2016年；Liu 等人，2022年）。然而，在持续学习场景中，性能往往会下降，因为数据分布会随时间不断变化（Khetarpal 等人，2022年；Lee 等人，2023年；Abbas 等人，2023年）。仅在新数据上继续训练通常会导致优化不稳定性和灾难性遗忘，而这些失败背后的机制尚未得到充分理解（Lyle 等人，2025年）。一种常见的补救方法是从头开始重新训练一个新模型，这可以恢复准确率，但由于计算成本，通常并不实际到计算成本。

理想情况下，持续学习系统应在可塑性与稳定性之间取得平衡：前者是适应新数据的能力，后者是保留已学知识的能力（Carpenter，1987年；Elsayed & Mahmood，2024年）。稳定性下降被称为灾难性遗忘（McCloskey & Cohen，1989年），而可塑性下降通常称为可塑性丧失。克服这些挑战将使模型能够随着数据随时间变化而不断演进，仿照人类和动物持续学习的方式，而无需从头开始重新训练。

在单个单元层面，可塑性丧失具有一个简单的特征。在 ReLU 网络中，已经停止放电的单元既不产生激活，也不产生梯度；而几乎对每个输入都放电的单元则已变成仿射直通；在这两种情况下，其阈值都不再具有区分作用。我们通过跟踪每个单元的一个数值——其放电率，即处于激活状态的输入所占的比例——使这一现象变得可观测，并发现这些放电率的分布能够反映不同方法、基准测试和架构中的可塑性。它还可以被直接控制：通过控制器而非梯度下降更新的逐神经元偏移量，可将放电率维持在目标范围内；与基于重置的方法相比，该方法在监督学习基准上提升了准确率，相较于 Atari 上的层归一化基线也同样如此。同一视角还解释了若干彼此无关的已知补救方法为何有效，并表明某些架构变更无需任何显式控制即可诱导出均衡的放电率。

贡献：

- 我们将放电率分析引入为一种简单、直观的诊断指标，用于评估持续学习中的神经元利用率和可塑性丧失，并为不同任务和架构提供统一的视角。
- 我们分析并比较了现有方法（包括 L2 正则化和非仿射归一化）的放电率分布，并展示这些模式与可塑性丧失之间的联系。
- 我们提出了一种负载均衡机制，通过转移激活输入动态调整神经元活动。该机制能够保持放电率均衡，且性能优于以往的基线方法。

2 背景

可塑性丧失。在监督学习（Ash & Adams，2020；Berariu 等人，2021；Dohare 等，2024）和强化学习（Lyle 等人，2022；Nikishin 等人，2022；Dohare 等，2024）中，都观察到了可塑性丧失现象。人们提出了多种方法来改善可塑性。例如，在训练过程中注入噪声（Ash 与 Adams，2020）、定期重置末层（Nikishin 等人，2022）、在训练过程中扩展网络（Nikishin 等人，2023）、使用串联 ReLU 激活函数（Abbas 等人，2023）、重新初始化低效用神经元（Sokar 等人，2023；Dohare 等，2024）、根据非活动统计量进行自归一化神经元重置（Farias & Jozefiak，2025）、扰动低效用神经元的梯度（Elsayed & Mahmood，2024），以及将权重正则化至其初始值附近（Kumar 等，2024）。一些研究结合了多种技术，例如 Lee 等人（2023）结合了层重置、串联 ReLU、层归一化（Ba 等人，2016）和尖锐度感知最小化（Foret 等人，2021）。

许多此类干预措施以破坏已学习信息为代价来恢复可塑性：它们重置神经元或整个层，而不是从一开始就防止塌缩。相比之下，我们探讨如何通过最小限度的架构变更来主动维持可塑性。

衡量神经元效用。上述许多方法都依赖于神经元效用的衡量指标。例如，Dohare 等人（2024）将神经元的贡献效用定义为其激活幅值与所有出射权重幅值的乘积，并在训练过程中以移动平均的方式进行跟踪。Sokar 等人（2023）将休眠分数定义为神经元的激活幅值相对于同一层其他神经元激活幅值的归一化值，并在整个数据集上取平均；若休眠分数低于阈值，则认为该神经元处于休眠状态。Elsayed & Mahmood（2024）将权重效用定义为将某个权重置零后损失的变化，由此得到所有权重的全局排名，但计算成本更高。自归一化重置则对脉冲间隔时间采用自归一化百分位检验，依据非活动统计量而非幅值来判断何时进行重置（Farias & Jozefiak，2025）。

相比之下，我们引入了一种放电率诊断，用于揭示神经元利用率在不同层及随时间变化的分布，而不是将活动压缩为单一的汇总统计量。

持续学习基准。人们提出了许多基准来评估持续学习，但目前尚无统一标准，而且经常引入新的变体，因此难以进行比较。在本研究中，我们采用 Dohare 等人（2024）的基准测试设置来评估我们的方法。因此，我们重点关注他们用于评估持续反向传播（CBP）的持续学习 *ImageNet* 和类别增量 *CIFAR-100*基准。

3 通过放电率的视角理解可塑性

可塑性丧失通常反映了 ReLU 网络中的神经元级塌缩：一些神经元停止放电，而另一些则始终处于激活状态。反过来，神经元的可塑性取决于它是否有时间处于阈值两侧。因此，我们使用放电率作为诊断神经元使用情况的工具，即神经元处于激活状态的预激活值所占的比例。跟踪放电率分布可以揭示训练异常；正如我们将在实验部分展示的那样，将其维持在均衡范围内与分布偏移下适应能力的提升相关。

3.1 将可塑性视为激活区域的有效数量

为了使这一直觉更加精确，我们现在从网络的分段仿射结构及其二元激活模式的角度来审视网络。许多标准网络设计，例如使用 ReLU 或类似函数的多层感知机和卷积网络，都实现了连续分段仿射映射，将输入空间划分为若干区域，使得网络在每个区域上都是仿射的（Montúfar 等人，2014 年；Serra 等人，2018年；Goujon 等人，2024年）。每个这样的区域由哪些隐藏单元处于激活状态或非激活状态所决定，并且这些激活模式与网络诱导的仿射区域之间存在一一对应关系（Zhang 和 Wu，2020 年）。这一视角使我们能够根据这些区域对输入空间进行划分的精细程度，来刻画网络的函数复杂度（Montúfar 等人，2014 年；Serra 等人，2018年；Zhang 和 Wu，2020 年）；关于非 CPWA 架构的扩展将在 B 节中讨论。

考虑一个参数为 θ、总计包含 M 个隐藏单元的网络。对于任意输入 $x \in \mathcal{X}$，令 $z_i(x)$ 表示单元 $i \in \{1, \dots, M\}$ 的预激活。我们定义相应的二元门控

$$S_i(x) \coloneqq [z_i(x) \geq 0], \tag{1}$$

它表示单元 i 是否处于激活状态。**全局激活模式** 是所有门控组成的向量：

$$S(x) \coloneqq \big(S_1(x), \dots, S_M(x)\big) \in \{0,1\}^M. \tag{2}$$

每个独特的模式 $s \in \{0,1\}^M$ 定义了一个区域 $\mathcal{R}(s) \coloneqq \{x \mid S(x) = s\}$，网络在该区域内是仿射的。所有非空区域共同构成输入空间的一个划分 $\mathcal{P}$。

有效容量与可塑性。 CPWA 网络的表达能力从根本上取决于其划分 $\mathcal{P}$（Montúfar 等人，2014 年；Serra 等人，2018年；Takai 等人，2021 年）。由于网络在每个区域 $R \in \mathcal{P}$ 上都是仿射映射，因此无法捕捉单个区域内的非仿射变化。因此，要表示非线性目标函数，划分必须将那些无法由同一个仿射函数良好近似的输入分隔到不同区域中。

一种朴素的容量量化方法是计算区域总数 $|\mathcal{P}|$，但这种方法将所有区域一视同仁，不考虑数据访问这些区域的频率。为了得到一种依赖数据的概念，令 $\mathbf{x} \sim P_{\mathbf{x}}$，并令 $\mathbf{s} \coloneqq S(\mathbf{x})$ 表示随机激活模式（$\mathbf{x}$和$\mathbf{s}$ 是随机变量；x、s 是它们的取值）。然后，我们用激活模式的**困惑度** $2^{H(\mathbf{s})}$ 来衡量有效区域数。标准熵界给出 $2^{H(\mathbf{s})} \leq |\mathrm{supp}(\mathbf{s})| \leq |\mathcal{P}|$，其中 $\mathrm{supp}(\mathbf{s})$ 是$\mathbf{s}$的支撑集，因此，困惑度提供了一个平滑且依赖数据的下界，表示在 $P_{\mathbf{x}}$ 下具有非忽略概率质量的区域数量。相关研究曾使用激活模式的熵和困惑度，量化网络区分输入或类别的丰富程度（Davel 等人，2020 年；Hartmann 等人，2021 年）。

由于映射 $x \mapsto S(x)$ 是确定性的，$H(\mathbf{s} \mid \mathbf{x}) = 0$，因此 $I(\mathbf{x};\mathbf{s}) = H(\mathbf{s}) - H(\mathbf{s} \mid \mathbf{x}) = H(\mathbf{s})$。因此，最大化该下界等价于最大化输入与其激活模式之间的互信息，从而迫使离散编码保留关于输入的最大信息（**信息最大化原理**；Linsker，1988年）。与此密切相关的是，激活编码与输入之间的互信息目标已被用于显式增强编码器的非线性表达能力（Park等人，2021 年）。在具有时变分布 $P_{\mathbf{x}_t}$ 的持续学习环境中，最大化 $2^{H(\mathbf{s}_t)}$ 会持续提高 $|\mathcal{P}|$ 的下界。这是在促进**可塑性**，因为它促使网络持续积极使用许多不同的仿射区域，从而能够继续区分新的和不断变化的输入模式。

3.2 易处理的代理指标：神经元级放电率

全局熵 $H(\mathbf{s})$ 的上界是各个单元熵之和。两者之间的差距就是总相关（*TC*）（Watanabe，1960年），它衡量单元之间的冗余（统计依赖）：

$$H(\mathbf{s}) = \sum_{i=1}^{M} H(\mathbf{s}_i) - TC(\mathbf{s}). \tag{3}$$

直接优化联合熵 H（$\mathbf{s}$）在计算上颇具挑战，因为高维依赖关系（ TC 项）难以估计。然而，公式（3）中的第一项 $\sum_{i=1}^{M} H$（$\mathbf{s}_i$）仅取决于边缘概率，计算起来十分高效。由于每个门控 $\mathbf{s}_i$ 都是一个伯努利变量，其熵 H（$\mathbf{s}_i$）会在其处于激活状态的概率恰好为 0.5 时达到最大值。二值化激活熵正则项也采用了类似的观察：它们鼓励单个单元约有一半时间处于激活状态，同时保持单元之间的弱相关性，从而增加其激活模式的联合熵（Cao 等人，2018）。因此，最大化边缘熵之和会鼓励每个单元对一半的输入进行放电，避免“死单元”问题，并最大化单个神经元的信息容量。

我们提出将这一总和最大化，作为全局可塑性的一个简单且易处理的替代指标。原则上，这一目标仍可能导致单元之间存在冗余（即当 TC（$\mathbf{s}$）非零时），但我们观察到，让每个单元约有一半时间处于激活状态，通常也会增加联合熵：在第4节中，我们通过实证检验这一假设，发现总相关性保持在可控范围内，而边缘熵不断增加，因此额外的逐单元容量对应于有效仿射区域数的实际增加。另一种互补的视角是考察激活编码之间的平均汉明距离，我们将在 B 节中进一步讨论这一点。

放电率。 放电率视角为监测和控制门控的边缘熵提供了一种实用方法 $\mathbf{s}_i$。对于每个单元 i，在 $\mathbf{x} \sim P_{\mathbf{x}}$条件下，门控 $\mathbf{s}_i$ 是一个伯努利随机变量，其激活概率为 $\Pr(\mathbf{s}_i = 1) = \Pr(z_i(\mathbf{x}) \geq 0)$。实践中，我们通过小批量 $x_1, \ldots, x_n$ 中的瞬时放电率来估计这一概率

$$\rho_i \coloneqq \frac{1}{n} \sum_{j=1}^{n} [z_i(x_j) \geq 0], \tag{4}$$

该值是门控 $\mathbf{s}_i$ 在整个小批量上的经验均值。为平滑小批量噪声，同时对不断变化的数据分布保持响应，我们以衰减率 $\tau \in [0, 1]$跟踪指数平均放电率，记为 $\bar{\rho}_i$，以捕捉更长期的趋势：

$$\bar{\rho}_i \leftarrow \tau \bar{\rho}_i + (1 - \tau)\rho_i. \tag{5}$$

对于 ReLU 单元，预激活 z_i 会产生两种状态：关闭 状态 $z_i < 0$（输出为零且斜率为零）和开启 状态 $z_i \geq 0$（输出为正且斜率为单位值）。因此，放电率 $\bar{\rho}_i$ 直接反映单元 i 处于每种状态的频率。当接近 $\bar{\rho}_i = 0$ 时，神经元处于死亡 或休眠 状态，既不产生激活，也不产生梯度。当接近 $\bar{\rho}_i = 1$ 时，它表现得近似线性直通，梯度仍可流动，但不会增加曲率。在这两种极端情况下，门控 $\mathbf{s}_i$ 的熵都接近于零，并且该单元对全局熵 $H(\mathbf{s})$的贡献很小，从而降低有效容量和可塑性。这一观点促使我们既将放电率用作可塑性的诊断指标，也将其用作后文引入的负载均衡机制的控制信号。

3.3 持续学习基准中的放电率动态

在本小节中，我们研究持续学习 ImageNet 和类别增量 CIFAR-100 基准中的放电率行为。这些设置基于广泛使用的数据集，针对卷积神经网络和 ResNet 架构进行设计；与更简单的多层感知机模型相比，它们能够更有力地检验可塑性，同时也便于解释。总体而言，这些设置为考察神经元放电率如何在分布偏移下演变提供了一个有用的测试平台。

持续学习 ImageNet：放电率与准确率。 在持续学习 ImageNet 基准测试中（Dohare 等人，2024），模型在一系列二分类任务上进行训练。对于每个任务，模型需要学会区分

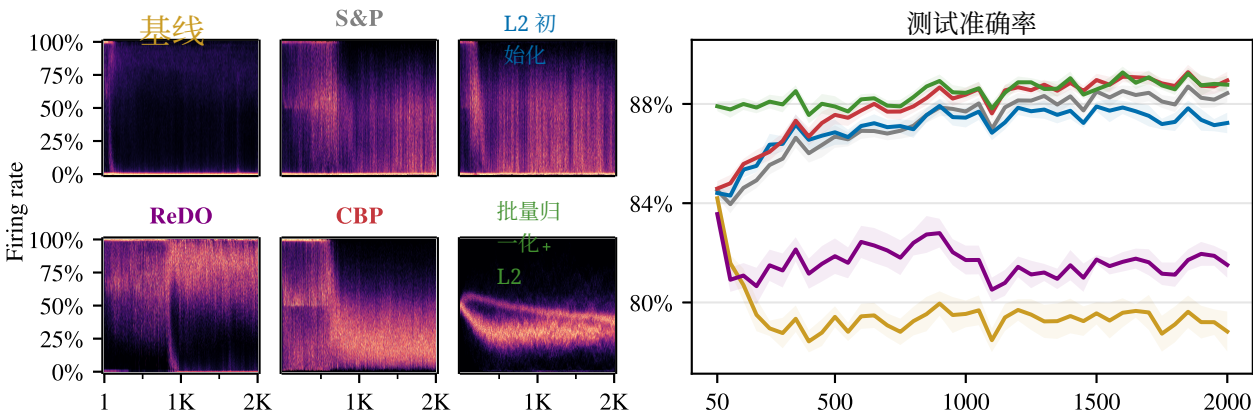

图1：**持续学习 ImageNet：**放电率分布的演变（左）以及带误差带的测试准确率（右），均为 10 次运行的平均值。标准训练会使神经元活动塌缩至 0%，而批归一化、L2 正则化和 CBP 则能维持更均衡的放电。均衡放电率与准确率上升在时间上的对应关系正是两者之间的联系；各方法的发现详见正文。

从 ImageNet（Deng 等，2009）中随机抽取的两个类别，然后再转向新的一对类别。由于所有任务的难度相当，跨任务的准确率下降表明可塑性降低（Dohare 等人，2024）。遵循 Dohare 等人（2024）的方法，图像被下采样至 32×32 分辨率，这在保留 ImageNet 类别多样性的同时，使数千个任务的长序列运行在计算上变得可行。该设置的要求显著高于 MNIST 规模的基准测试。我们使用带有 ReLU 激活的紧凑型卷积神经网络（训练详情见 C 节）。

图1展示了几种基线方法的放电率分布和测试准确率。超参数详情见 C 节。准确率曲线报告 10 次运行的均值，阴影带表示±1 均值标准误。由于每个任务都是从类别中随机抽取一对，因此任务难度差异很大，这种任务采样方差是任一方法不同运行之间结果差异的主要来源。不过，这种差异是共有的：每种方法都在相同的 10 个任务序列上进行评估，因此逐次比较方法时，这种差异会相互抵消。因此，我们以逐运行配对差值的形式报告方法间差异（表3）；与单独考察任一方法的均值相比，这种方式能更精确地进行比较。所有基线方法和任务的绝对准确率列于 D 节。

本文始终使用二维热力图展示放电率分布：横轴表示训练进度（任务数量），纵轴表示从 0 到 100% 的放电率范围，每一列展示网络中所有神经元的直方图。较亮的区域表示具有该放电率的神经元较多，较暗的区域则表示较少。这些图揭示了活动模式如何随时间演变。

主要发现：

1. **基线**。 准确率会随着任务推进而迅速下降。大多数神经元的放电率塌缩至接近 $\approx 0\%$，与准确率下降相一致。2. **S&P**。 收缩与扰动将 L2 正则化与小幅参数噪声相结合（Ash 与 Adams，2020）。它提高了活跃神经元的比例（最高达 $\approx 75\%$），并显著提升准确率，不过仍有许多神经元接近 $\approx 0\%$。3. **L2 初始化**。 L2 初始化通过正则化权重，使其趋向初始化值（Kumar 等，2024）。与 S&P 类似，它带来了更高的神经元活跃度（最高达 $\approx 80\%$）和更高的准确率，但仍有一部分神经元塌缩至接近 $\approx 0\%$。4. **ReDO**。 回收休眠神经元会重置低于休眠阈值的神经元（Sokar 等人，2023）。它基本消除了 $\approx 0\%$ 的状态，但在早期导致广泛饱和（$\approx 100\%$）和持续的高放电率（$\approx 75{-}95\%$），这与 ReLU 线性化的情况相符；其准确率也低于其他干预方法。

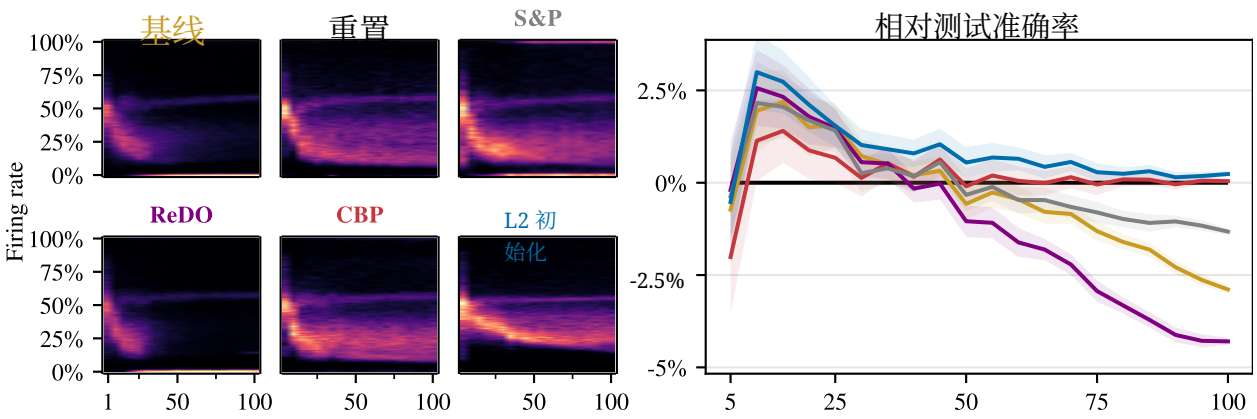

图 2：**类别增量 CIFAR-100：** 放电率分布（左）和带误差带的测试准确率（右），为 15 次运行的平均值。准确率相对于从头开始训练的 重置 基线计算，该基线对应零线。持续训练会使神经元逐渐不活跃，而重置和 CBP 可防止放电模式崩溃，准确率也呈现相同趋势；各方法的具体结果见正文。

5. **CBP**。 持续反向传播使用激活幅值标准重置“利用不足”的神经元（Dohare 等，2024）。它基本避免了塌缩至 $\approx 0\%$，但早期在接近$\approx 100\%$处出现的饱和再次表明 ReLU 发生了线性化。经过 ≈ 500 个任务后，分布重新居中并变宽，同时准确率有所提升。

6. **批归一化 +L2**。 将批归一化（Ioffe 与 Szegedy，2015年）与 L2 正则化相结合，已经能够防止放电率出现极端值。准确率和可塑性均保持较高水平。我们在图和表格中将此配置缩写为 BN +L2，同样将层归一化记作 LN。

类别增量 CIFAR-100：放电率和准确率。 在类别增量 CIFAR-100 基准中，模型首先学习对从 CIFAR-100 中随机抽取的一小组类别进行分类（Krizhevsky 等人，2009年）。随后逐步引入其他类别，模型必须对截至当前遇到的所有类别进行分类，直到包含完整的 100 个类别。由于随着类别不断累积，分类问题变得更加困难，即使没有可塑性丧失，性能也可能下降（Dohare 等，2024年）。为区分这一影响，我们将持续训练与在相同子集上从头训练的模型进行比较。如果持续训练的模型表现不如从头训练的模型，则表明存在可塑性丧失；而更优的表现则说明发生了知识迁移（Dohare 等，2024年）。我们使用带有 ReLU 激活的 ResNet-18（训练细节见附录 C）。

图 2 展示了若干基线方法的放电率分布和测试准确率。结果取 15 次运行的均值，阴影带表示 ± 1 均值标准误。

本文始终按照 Dohare 等人（2024）的做法，以从头训练的相对于 重置基线的差值绘制类别增量 CIFAR-100 准确率。因此，重置 在每个右侧面板中都是零线，本身不对应任何曲线：高于零的曲线表示存在知识迁移，低于零的曲线则表示发生了可塑性丧失。所有方法的绝对准确率列于 D 节。

主要发现：

1. **基线**。 神经元逐渐变得不活跃，但程度不如持续学习 ImageNet 严重。许多单元的放电率达到 $\approx 0\%$，限制了网络学习新任务的能力。2. **重置**。 每个任务结束后重新初始化完整网络，可避免塌缩并保留适应性。随着任务难度增加，放电率分布也会相应偏移。3. **S&P**。 放电率分布逐渐趋近于重置 状态，但许多神经元仍聚集在$\approx 0\%$（死亡）和 $\approx 100\%$（实际上已线性化）附近。这种失衡对应的准确率低于重置。

4. **ReDO**。与基线方法类似，大多数神经元变得不活跃；其准确率甚至低于基线方法。5. **CBP**。 放电率分布与重置非常接近，测试准确率也相当。大多数单元位于 10–30% 区间，部分高达 $\approx 60\%$，表明可塑性得以持续。6. **L2 初始化**。 与 CBP 相比，放电率更集中于 $\approx 50\%$ 附近。它在这些基线方法中取得了最高准确率。

研究结果总结。 总之，放电率分析为理解持续学习中的可塑性提供了一个直观的视角。在两个基准测试中，常规训练都会迅速导致神经元变为非活跃状态，而 CBP 和 L2 初始化则能维持均衡的放电率分布，与完全重置网络的分布非常相似。

4 负载均衡：控制放电率

第 3 节确立了两点：可塑性丧失表现为放电率向 0% 塌缩或在接近 100% 时饱和，而边际熵论证则指出中间放电率才是目标。无需等到塌缩发生，这两点才会显现。放电率可通过激活已接收的同一张量来测量，也可以通过平移该张量来调整——因此，训练过程中可以持续将放电率保持在目标范围内，成本几乎为零，也无需改动权重。

本节将探究，对放电率进行显式控制能否实现超越任务间完全重置网络的性能。我们提出一种轻量机制，**负载均衡 (LB)**，通过平移每个神经元的预激活，使其长期放电率保持在目标范围内。具体而言，在 ReLU 之前，我们将预激活 x替换为一个平移后的值

$$\tilde{x} = x + \mathrm{sg}(\beta), \tag{6}$$

其中， $\beta \in \mathbb{R}$ 是每个神经元各自的偏移量，初始化为零；sg(·)表示停止梯度（即，反向传播时将 β 视为常量）。我们不通过梯度下降更新 β ，而是在每个批次后，根据指数平均放电率 $\bar{\rho}$使用一个简单的控制器对其进行调整：

$$\beta \leftarrow \begin{cases} \beta + \alpha & \text{if } \bar{\rho} < \rho_{\min} \\ \beta - \alpha & \text{if } \bar{\rho} > \rho_{\max} \\ \beta & \text{otherwise,} \end{cases} \tag{7}$$

其中， $\alpha > 0$ 是一个较小的步长（我们使用 $\alpha = 0.001$）， $[\rho_{\min}, \rho_{\max}] \subset [0, 1]$ 指定了目标范围。全文中，我们用 LB a–b% 表示目标范围 $[a\%\ b\%]$, ，用 LB 50% 表示单一放电率目标；我们将其实现为较窄的 49–51% 范围。我们在偏移后的预激活值 $\tilde{x}$ 上测量放电率，而不是在 x上测量，因为 $\tilde{x}$ 才是 ReLU 实际接收的信号；因此，控制器会针对其所调节的量形成闭环。推理期间， β 保持固定。直观而言，这会使有效激活阈值水平移动，从而让处于激活状态的时间过少（或过多）的神经元逐渐趋向目标范围。

实践考量。 实际上，偏移量 β 可能会与前一层学到的偏置竞争。我们通过在偏移量之前紧邻放置一个批归一化层并使用 L2 正则化来缓解这一问题。类别增量 CIFAR-100 设置中已采用此配置；对于持续学习 ImageNet，我们采用批量归一化 + L2 配置。

实现。 我们将负载均衡实现为一个插入到每个激活之前的小型层，用于测量放电率并调整偏移量。算法 1 给出了适用于一维输入的层，例如位于具有 d特征的全连接层之后。

对于三维输入，即位于卷积层之后时，算法 1 中有两行需要更改：

```
x = x + self.offset.reshape(1, -1, 1, 1)
rate = (x > 0).float().mean(dim=[0, 2, 3])
```

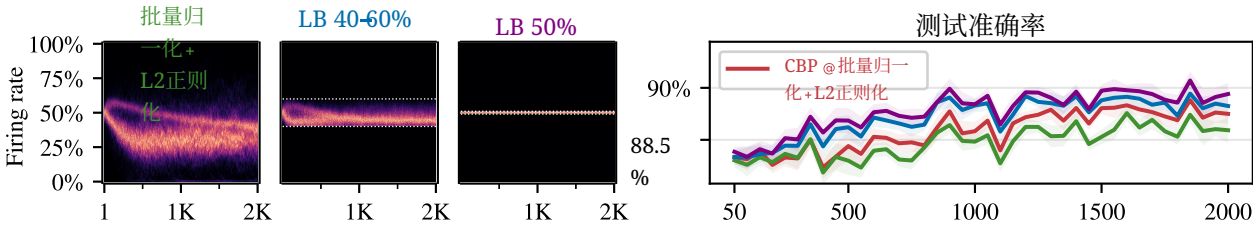

图 3：**持续学习 ImageNet：** 在有无负载均衡的情况下，采用 BN + L2 时的放电率分布（左）和测试准确率（右）；结果为 10 次运行的平均值，带有 ± 1 标准误差带。将神经元限制在中间区间（40–60% 或 50%）可提高准确率，优于无约束基线和 CBP。

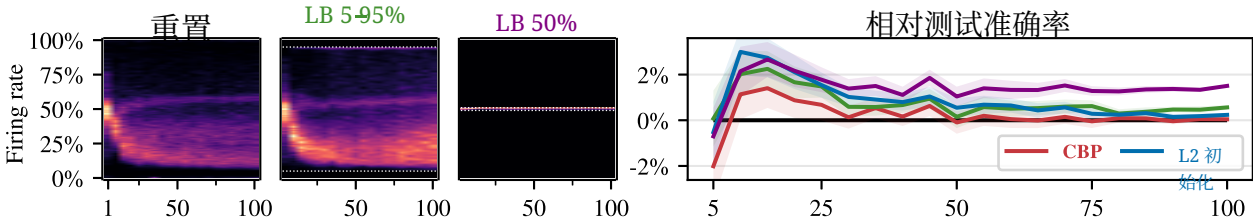

图 4：**类别增量 CIFAR-100：** 不同负载均衡范围下的放电率分布（左）和测试准确率（右），为 15 次运行的平均值，带有 ± 1 标准误差带；准确率以重置为基准。较宽松的边界（5–95%）呈现出类似重置的行为，同时准确率有所提升；而在 50% 附近进行控制则能带来进一步提升，表现超过重置和先前的方法。LB 50% 面板中几乎所有神经元都集中在同一个区间，因此除 50% 处的线条外，面板几乎一片暗色。

最佳实践。 在我们的实验中，EMA 衰减 $\tau = 0.99$ 和步长 $\alpha = 0.001$ 在各种设置下都表现稳健。在主要实验所使用的骨干网络上，随着目标范围收紧，准确率单调提升（第 C 节）；而我们尝试过的最宽范围相比不受约束的参考设置基本没有任何收益。因此，我们建议从 50% 的目标开始（我们将其实现为 49–51%），只有在训练变得不稳定时才放宽范围。如上所述，我们还建议将负载均衡与置于其前方的归一化层结合使用。我们始终将负载均衡层直接插入激活函数之前；当存在归一化层时，这意味着将负载均衡置于归一化层与激活函数之间。

算法 1 PyTorch 中用于带有 d 特征的一维输入的负载均衡层。 `offset` 是 β， `avg_rate`是 $\bar{\rho}$。

```
class LoadBalancer(nn.Module):
```

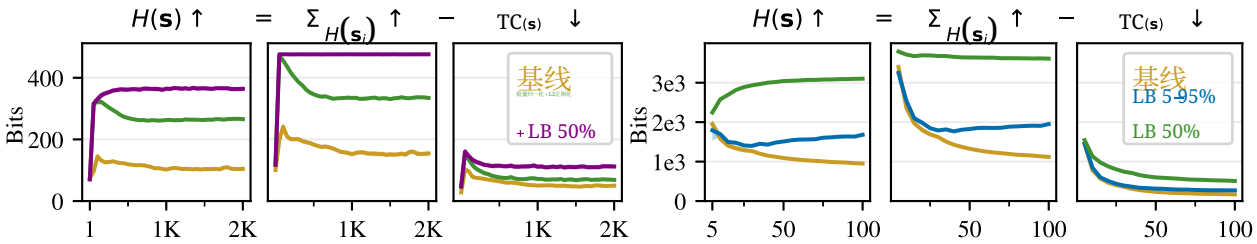

图 5：**熵：** 持续学习 ImageNet（左）和类别增量 CIFAR-100（右）中，在测试集上计算的 $H(\mathbf{s})$、$\sum_i H(\mathbf{s}_i)$ 和 $TC(\mathbf{s})$，结果取 3 个随机种子的平均值。在持续学习 ImageNet 中，三种配置分别为基线、BN + L2正则化，以及采用 50% 负载均衡的 BN + L2正则化（“+ LB 50%”）；在类别增量 CIFAR-100 中，三种配置分别为基线、5–95% 负载均衡和 50% 负载均衡。

持续学习 ImageNet 中的负载均衡。 我们使用 BN + L2 作为基础配置，因为在存在归一化的情况下，负载均衡更加稳定。为确保可比性，我们在相同设置下重新调整所有基线方法；结果见图15，超参数详情和完整表格见 C 节和 D 节。全文中，我们使用“方法 @ 参考配置”表示在指定参考配置下实例化的方法，例如此处的 CBP @ BN + L2，以及第 5.2 节中的 CBP @ LN。

在持续学习 ImageNet 上，我们评估了不同放电率界限下的负载均衡（图 3）。将放电率限制在中间区间（40–60%）时，其准确率高于未加约束的 BN + L2正则化和 CBP @ BN + L2正则化，而将所有神经元固定在 50% 时表现更好。

类别增量 CIFAR-100 中的负载均衡。 在类别增量 CIFAR-100 基准中，我们评估了两种负载均衡配置，并将其性能与重置基线进行比较；在重置基线中，网络会在每个任务之后重新初始化。结果如图 4 所示。使用 5–95% 的宽松边界，可以复现出与基于重置的基线相似的放电率模式。该配置已经取得了高于重置方案和 CBP 的准确率。将边界进一步积极地推至 50% 后，性能还能得到提升。

测量熵。 如第 3.2 节所述，二值门的联合熵分解为 $H(\mathbf{s}) = \sum_{i=1}^{M} H(\mathbf{s}_i) - TC(\mathbf{s})$。为了监测负载均衡机制如何影响这些项，我们在每个任务之后使用确定性评估（例如，处于推理模式的批归一化）在测试集上对它们进行评估。对于每个单元 i，我们根据测试输入上的经验放电率估计边缘激活概率 $\Pr(\mathbf{s}_i = 1)$，并计算相应的伯努利熵 $H(\mathbf{s}_i)$。我们报告总和 $\sum_{i=1}^{M} H(\mathbf{s}_i)$，将其作为总边缘容量的度量；其最大值为 M 比特，此时每个单元恰好在一半输入上处于激活状态。请注意，这些放电率是在推理时测量的，使用的是冻结的归一化统计量和固定的 β，因此不一定与控制器在训练期间维持的放电率一致。所有熵结果均在 3 个随机种子上取平均。

直接估计高维$\mathbf{s}$的总相关 $TC(\mathbf{s})$ 是不可行的，因为这需要计算$\{0,1\}^M$上的完整联合分布。因此，我们采用 Chow–Liu 树近似（Chow & Liu，1968）。具体而言，我们首先根据经验联合激活计数，估计所有成对的互信息 $I(\mathbf{s}_i;\mathbf{s}_j)$。然后，以 $I(\mathbf{s}_i;\mathbf{s}_j)$ 为边权重，构建最大生成树（MST）。对于按照该树结构分解的分布，总相关为

$$TC(\mathbf{s}) = \sum_{(i,j)\in \mathrm{MST}} I(\mathbf{s}_i;\mathbf{s}_j), \tag{8}$$

也就是说，它等于树边上的互信息之和。我们将这一数值作为一种易于计算的近似，在忽略高阶交互的同时捕捉主要的成对依赖关系。

$\sum_{i=1}^{M} H(\mathbf{s}_i)$ 的轨迹以及 $TC(\mathbf{s})$ 的 Chow–Liu 估计如图 5 所示。若不进行负载均衡，边缘熵之和会随着任务推进而持续下降。负载均衡能够遏制这种下降，而且目标范围越窄，遏制效果越明显：50% 的目标范围可使总和维持在接近初始水平的位置

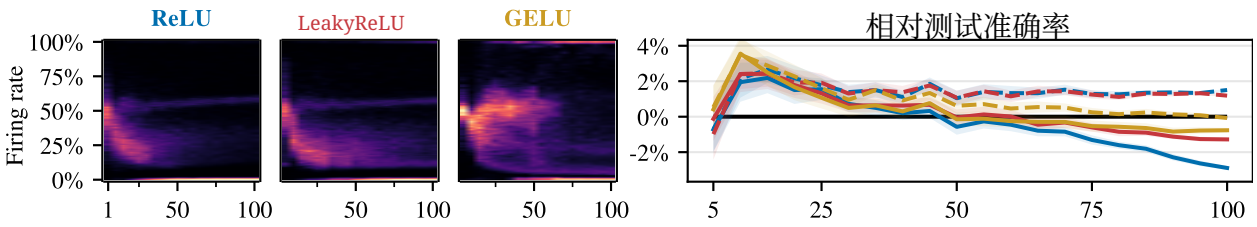

图6：**类别增量 CIFAR-100：** 基于 BN +L2正则化设置的 ReLU、LeakyReLU 和 GELU 的放电率分布（左）与测试准确率（右）。右图中的虚线表示负载均衡为 50% 时的结果。

，并接近其 M 位的上限，而 5–95% 则只能部分遏制下降。负载均衡下的总相关项也更高，但远不及边缘熵的增幅。由于树结构只能捕捉成对依赖关系，Chow–Liu 估计是实际 $TC(\mathbf{s})$ 的下界，而 $\sum_{i=1}^{M} H(\mathbf{s}_i) - TC(\mathbf{s})$ 相应地是联合熵 $H(\mathbf{s})$ 的上界。在整个训练过程中，负载均衡下的这一上界都显著更高，这与额外的逐单元容量能够支撑更多不同的仿射区域、而非冗余神经元相符。三种配置在熵上的排序也与准确率上的排序一致——LB 50%、LB 5–95%、然后是无约束基线（表4）——这正是第 3 节论述所预测的。

研究结果总结。 本节表明，通过负载均衡显式控制放电率能够提升持续学习性能。将放电率限制在中间范围（例如 40–60%）或固定为 50%，在两个基准测试上都比基于重置的基线和 CBP 获得更高的准确率。这些设置能够保持多样化的激活模式，并与前文关于 50% 放电率可最大化激活状态熵并支撑非线性的论述相一致。与此一致的是，我们的 Chow–Liu 估计显示，负载均衡使边缘熵之和远高于无约束基线，同时仅以小得多的幅度提高冗余，因此联合熵 H（s）的上界——以及相应的有效活跃区域数量——也保持在更高水平。总体而言，这些结果凸显了均衡神经元利用率这一目标的价值，并表明放电率控制是改善可塑性和知识迁移的一种实用机制。

5 负载均衡的普适性

到目前为止，我们已在两个监督式持续学习基准上，将负载均衡应用于 ReLU 网络。现在我们要探究这一机制的适用范围：它能否推广到其他激活函数，以及强化学习?

5.1 超越 ReLU

本文主要关注 ReLU 激活。不过，自然也会产生这样的问题：控制放电率会如何影响其他激活函数。我们将负载均衡应用于 LeakyReLU（Maas 等，2013）和 GELU（Hendrycks 与 Gimpel，2016）。结果如图6和图16所示。在每张图中，左侧面板显示未采用负载均衡时的放电率分布，右侧面板则比较了未采用负载均衡（实线）与采用 50% 负载均衡（虚线）时的性能。

在类别增量 CIFAR-100（图6）上，三种激活函数都会失去可塑性，并且都能从 50% 负载均衡中受益。ReLU 的提升最大：未采用负载均衡时，它是三者中表现最弱的；采用负载均衡后则最强，与经过负载均衡的 LeakyReLU 相当。

在持续学习 ImageNet（图 16）上，三者一开始都没有表现出明显的可塑性丧失，因为该设置已经采用了批归一化和 L2 正则化。在为每种激活函数分别调优学习率和 L2 强度后，三者在全部 10 个任务序列上仍然有所提升：将各自与未进行负载均衡的对应版本比较，ReLU 提升 $+0.99 \pm 0.05$，LeakyReLU 提升 $+0.88 \pm 0.11$，GELU 提升 $+0.31 \pm 0.05$。作为未采用负载均衡时表现最强的激活函数，GELU 的提升最小；采用负载均衡后，三者的差距最终都在 0.12 分以内。

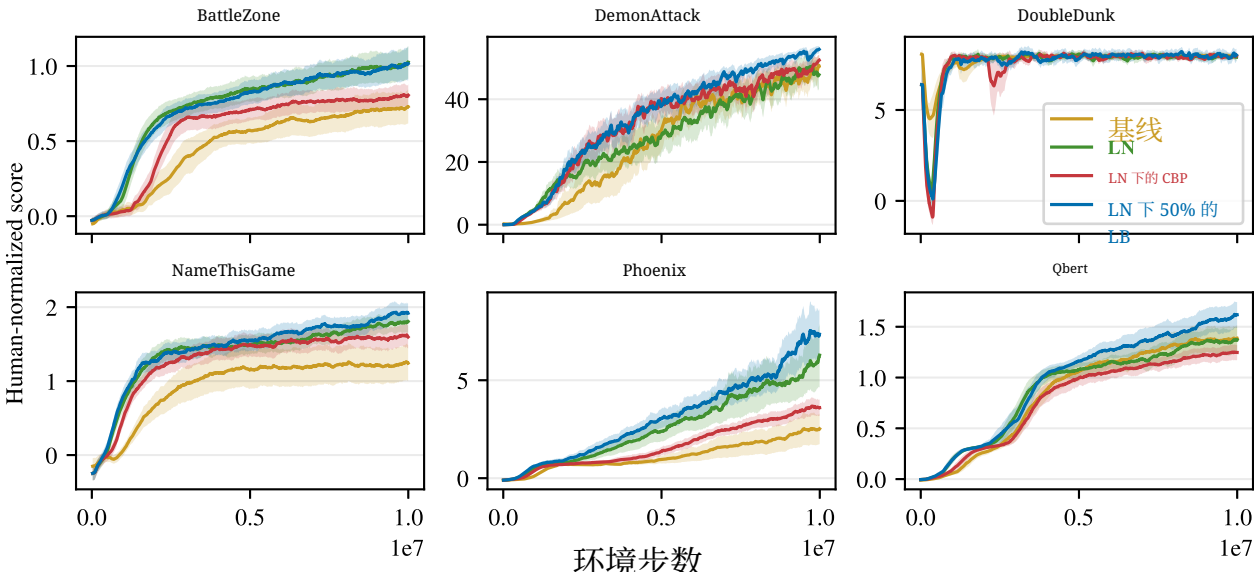

图 7：**Rainbow DQN：** 在 6 款 Atari 游戏上，四种变体的得分（随机玩家 $0=$、人类玩家 $1=$）经人类归一化后的结果：原始基线、采用层归一化（LN）的基线，以及目标比例为 50% 的负载均衡和应用于该层归一化智能体的 CBP（LN 下 50% 的 LB 和 LN 下的 CBP）。曲线显示 5 个随机种子的均值，并经过时间加权指数移动平均平滑处理。

5.2 强化学习

除了监督式持续学习之外，我们还在强化学习设置中测试了负载均衡机制。我们在 Atari-5 基准（Aitchison 等人，2023年）和 *DemonAttack* 环境上使用 Rainbow DQN（Hessel 等人，2018年）进行了实验；后者曾被用于展示可塑性丧失（Sokar 等人，2023年）。我们考察了四种智能体：（i）原始的 Rainbow DQN 基线；（ii）在隐藏层中加入层归一化的 Rainbow DQN；（iii）在相同架构上进一步加入我们的负载均衡层，并将放电率设为 50%（LN 下 50% 的 LB）；以及（iv）采用层归一化和 CBP 的模型（LN 下的 CBP）。我们发现，禁用价值头的负载均衡能够始终提升性能，因此所有报告结果均采用这一配置。除这些架构变更外，我们固定 Rainbow 超参数，并使用 Adam 优化器；完整细节见 C 节。性能以人类归一化得分（HNS）报告，计算方式如下：

$$\mathrm{HNS} = \frac{\mathrm{score}_{\mathrm{agent}} - \mathrm{score}_{\mathrm{random}}}{\mathrm{score}_{\mathrm{human}} - \mathrm{score}_{\mathrm{random}}}, \tag{9}$$

其中，0 对应随机智能体，1 对应人类专家。

在这 6 款游戏中，负载均衡智能体在其中 4 款游戏中取得四个智能体里最高的人类归一化得分，并在其余 2 款游戏中并列最高（图 7 和表 5）。原始 Rainbow 基线在部分游戏中仍具有竞争力——在 *DoubleDunk* 中，它与所有其他智能体不相上下；在 *DemonAttack* 和 *Qbert* 中，它与层归一化表现相当——但在 6 款游戏中的 5 款里不及负载均衡。负载均衡在 6 款游戏中的 5 款里优于 CBP，并在 *DoubleDunk*中与其表现相当。

图 8 中的放电率分布与这些性能趋势相呼应。在原始 Rainbow 基线中，几乎所有神经元的放电率都很低，表明网络严重塌缩。加入层归一化后，这种情况有所缓解，但大多数放电率仍远低于 50%。相比之下，采用负载均衡后，隐藏层中的大多数神经元都以接近 50% 的目标放电率运行（按设计不包括价值头）。这些分布也解释了为什么负载均衡在 *DemonAttack* 中有效，却在 *BattleZone*中无效：在 *BattleZone*中，层归一化基线已经使更多神经元更频繁地放电，因此改进空间较小；而在*DemonAttack* 中，层归一化基线仍然高度塌缩，负载均衡带来的放电率变化则大得多。

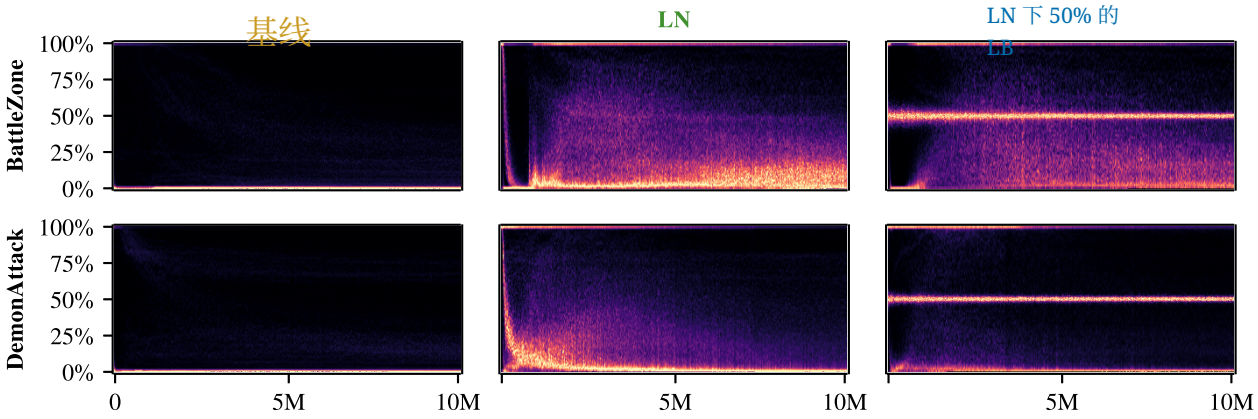

图 8：**Rainbow DQN：** 放电率分布，行对应每个游戏，列对应每个智能体，顺序与图 7 相同。基线在两个游戏中都塌缩到极低的放电率；层归一化将其提升了一部分；负载均衡使隐藏层的放电率维持在接近 50 % 的目标值，而 0% 和 100% 处的剩余质量来自价值头，该部分按设计被排除在外。两个游戏之间的差异解释了准确率结果：仅层归一化就已经提高了 *BattleZone* 中的放电率，因此负载均衡几乎没有额外提升空间；而在 *DemonAttack* 中则并非如此。

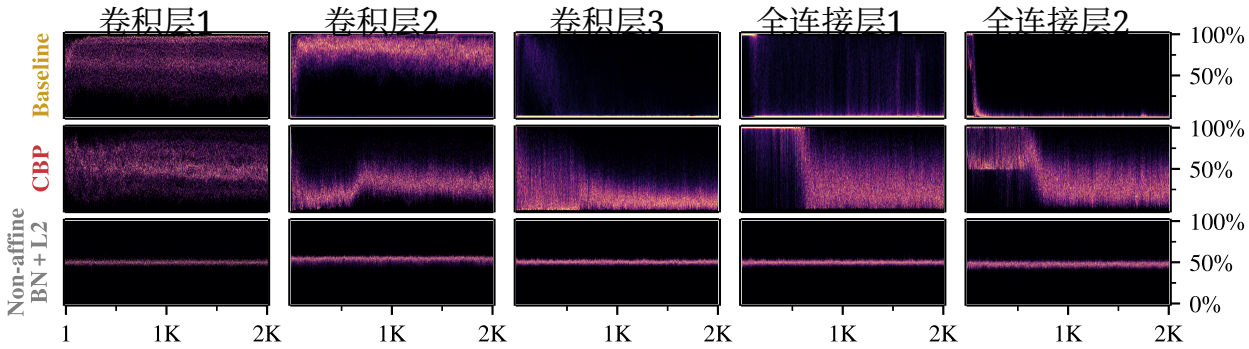

图9：**持续学习 ImageNet：** 跨任务的逐层发放率分布。行对应不同方法，列对应连续的各层。在基线中，早期层保持活跃，而后期层发生塌缩；CBP 表现出异质性行为；非仿射批归一化 +L2 使各层的放电率保持近乎均衡。

6 作为诊断指标的放电率

前文各节通过放电率来阐释并评估一种机制。本节则反过来审视这一诊断指标本身的价值：网络崩溃实际发生在网络的什么位置，放电率与文献中已有的可塑性指标相比如何，以及这些指标是否足够有信息量，能够指导架构设计。

6.1 逐层放电率

截至目前，我们已经可视化了 relu 网络中神经元激活的一个重要方面。化汇总。按层查看可以揭示崩溃或线性化出现的位置。所有热力图均遵循之前相同的可视化约定。

e 或线性化突触融象。所有热力图均遵循之前相同的可视化约定。

在图9中，我们展示了持续学习 ImageNet 中各层放电率的动态变化。第一行（基线）中，前两个卷积层保持高活跃度，而后续层则逐渐塌缩至 0%。第二行（CBP）中，各层的活跃度随时间显著变化。相比之下，非仿射 BN +L2（第三

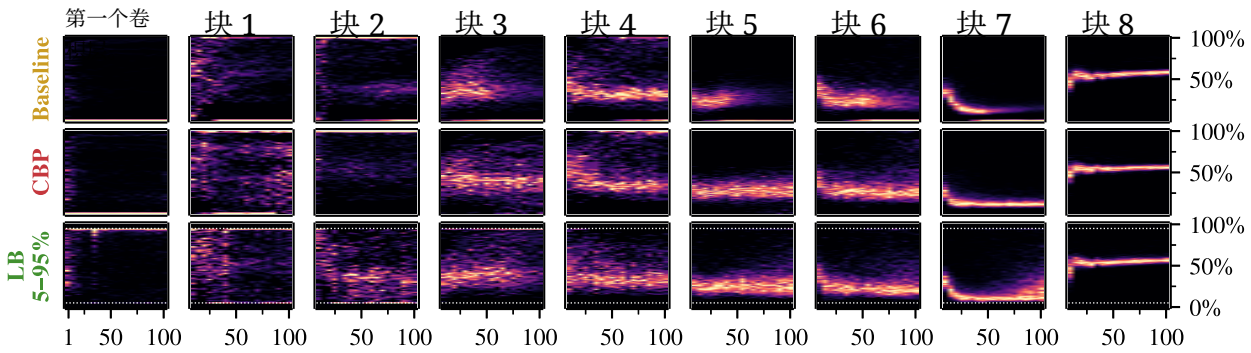

图10：**类别增量 CIFAR-100：** 各任务中的逐层放电率分布。持续训练和 CBP 在块 2 中呈现线性化。采用 95% 上限的负载均衡可避免这一现象，但代价是早期层的一些神经元在达到上限时出现饱和。

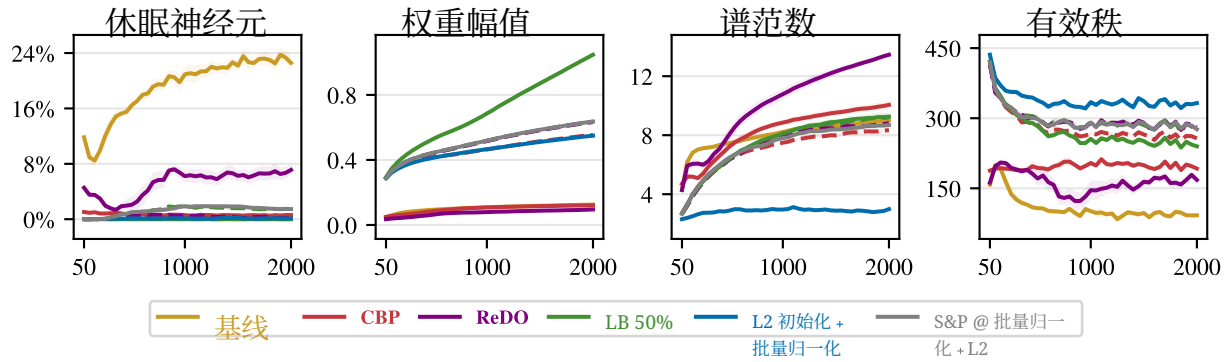

图11：**持续学习 ImageNet：** 从左到右依次为：休眠神经元比例（阈值 $\tau_{\text{d}} = 0.01$）、权重幅值、各层中的整体最大谱范数，以及各任务中的有效秩（Lewandowski 等人，2025）。虚线表示基于批归一化骨干网络构建的变体（BN + L2，但 L2 初始化 +BN 不会额外添加 L2）。结果为 5 次运行的平均值，带有 ± 1 标准误差带。

行）在各层维持稳定且近乎均衡的放电率。所有方法的完整结果见图18。

在图19（类别增量 CIFAR-100）中，我们观察到持续训练和 CBP 下，第二个 ResNet 模块（块 2）开始出现线性化。采用 95% 上限的负载均衡可以避免这一现象，这或许有助于提高测试准确率。然而，在负载均衡下，早期层的放电率有时会累积至 95% 的上限，表明出现了同样不理想的饱和。所有方法的完整结果见图19。

6.2 与现有可塑性指标的关系

放电率并不是针对可塑性丧失所提出的唯一诊断指标。本节将其与文献中的三个量联系起来——休眠神经元比例、权重幅值，以及谱范数和有效秩；这些量均在与上述结果相同的运行中进行测量。与准确率结果一样，每条曲线都是 5 次运行的均值，并带有 ± 1 标准误差带，因此，我们在下文读出的排序可以与不同随机种子之间的波动进行对照。

休眠神经元。 可塑性的一个常见代理指标是休眠神经元所占的比例（Sokar 等人，2023）。按照他们的定义，神经元的得分是其激活幅值相对于同一层其他神经元激活幅值的归一化值，并在整个数据集上取平均；如果神经元的得分低于阈值 τ_{d}（我们采用 $\tau_{\text{d}} = 0.01$），则将其标记为休眠神经元。在图 11 和图 12 中，大多数方法都将休眠单元的比例维持在接近各自基线的水平

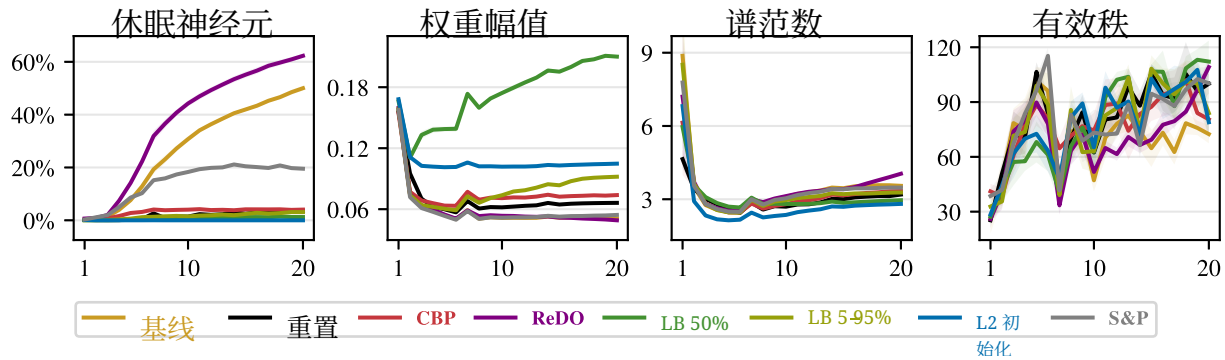

图12：**类别增量 CIFAR-100：** 从左到右依次为：休眠神经元比例（阈值$\tau_d = 0.01$）、权重幅值、各层整体最大谱范数，以及有效秩（Lewandowski 等人，2025年），均按任务统计。结果为5次运行的平均值，并带有 ±1标准误差带。

。有两种方法例外，且都出现在类别增量 CIFAR-100 上，其差距远大于随机种子带来的波动范围。ReDO 最终的休眠单元比例为 $62.3 \pm 0.7\%$，高于持续训练基线的 $50.0 \pm 0.9\%$。S&P 最终为 $19.5 \pm 0.5\%$，显著低于基线，但几乎是下一个最高值的五倍，因为其余方法均未超过 5%。其放电率分布已经体现了这一点：在图 2 中，S&P 将分布向重置状态区域移动，同时许多神经元仍接近 $\approx 0\%$。总体而言，0% 的放电率是休眠的充分（但非必要）条件，这解释了这些指标之间观察到的一致性。休眠状态主要反映低活跃神经元。放电率分布所涵盖的范围更广，因为它们揭示了低放电率坍缩、高放电率线性化以及中间范围的活动。

权重幅值。 据报道，可塑性丧失通常伴随着权重范数增长（Dohare 等，2024年）。我们没有观察到这种关联。在持续学习 ImageNet 上，权重幅值区分的是两个骨干网络，而非不同方法。三种不使用批量归一化层的方法最终低于0.13，而基于该层构建的六种方法均高于0.54；两组内部都没有一致的排序。这一差距并非 L2 效应，因为最终幅值最低的方法恰恰都是在不使用权重衰减的情况下训练的。在类别增量 CIFAR-100 上，所有方法共享同一架构和同一权重衰减，其关联方向却相反。休眠程度最高的两种方法 ReDO 和基线最终具有最小的权重幅值，而休眠程度最低的两种方法 L2 初始化和 LB 50% 的权重幅值最大（在全部八种方法上，斯皮尔曼 $\rho = -0.95$，$p < 0.001$）。休眠神经元不会接收梯度，因此权重衰减会在没有抵抗的情况下缩小其权重；在架构和 L2 均固定时，权重幅值反映了网络中仍处于活跃状态的部分。这与 Lyle 等人（2025年）的发现一致：训练结束时的参数范数与可塑性之间不存在单调关系；他们还指出，单元饱和的网络不会传播那些会促成范数增长的梯度。负载均衡符合这一趋势，而不是打破它；它在前置批量归一化层中诱导的偏置增长（该偏移会与学习到的偏置竞争）使 LB 50% 偏离得最远。

谱范数和有效秩。 Lewandowski 等人（2025年）已表明，网络层的谱范数和有效秩与可塑性相关。在图 11 和图 12 中，我们评估了跨层的整体最大谱范数以及有效秩。在持续学习 ImageNet 上，有效秩确实能够对这些方法进行排序。基线最终的数值低得多（92 ± 5），而基于批量归一化（BN）+L2正则化构建的变体都保持在 257 到 333 之间，这一差距通过随机种子可以轻松分辨。谱范数则不太一致。其最大值属于 ReDO，后者也是第二休眠程度最高的方法；但接下来最大的值却属于几乎没有休眠单元的方法，而基线——所有方法中休眠程度最高的——仅排名第五，其数值与位于它两侧的三种方法均处于一个标准误之内。在类别增量 CIFAR-100 上，这两个指标出现了分歧。有效秩完全无法对这些方法进行排序，因为曲线在不同任务之间反复交叉，而且连续排名方法之间的七个间隔中有六个小于相应的标准误。谱范数在这里确实产生了排序，并且

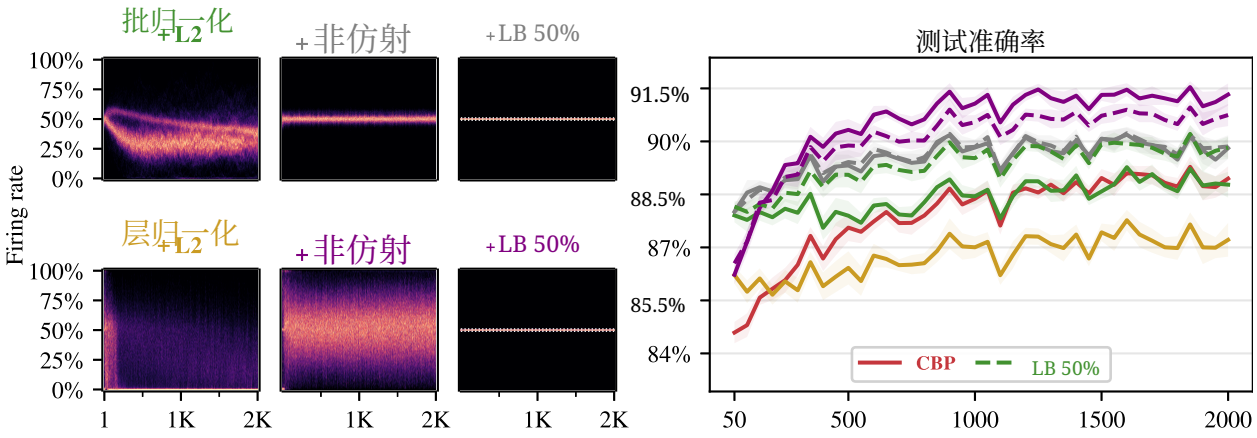

图13：**持续学习 ImageNet：** 非仿射归一化对放电率分布（左）和测试准确率（右）的影响。非仿射批归一化 ＋L2 会将放电率聚集在50%左右，而非仿射层归一化 +L2 则使各层的分布更加宽广。两种配置都能提高准确率，其中非仿射层归一化在所有方法中取得了最高性能。在非仿射层归一化的基础上通过负载均衡强制达到50%，虽然能使放电率更加集中，但会降低准确率。

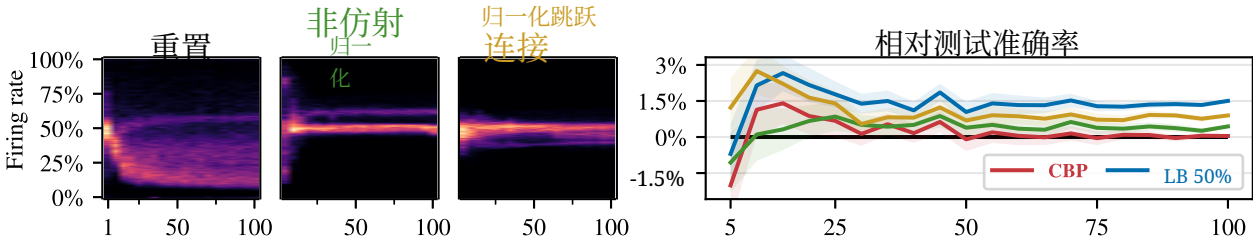

图14：**类别增量 CIFAR-100：** 非仿射归一化和归一化跳跃连接下的放电率分布（左）与测试准确率（右）；准确率相对于重置进行比较，与图4相同。两种修改都将放电率引导至平衡状态，并使准确率超过重置和 CBP。

这一排序几乎完全反映了休眠程度：ReDO 和基线最高，而保持神经元活跃的方法最低。该排序与持续学习 ImageNet 上的结果恰好相反，而且其范围被压缩在 2.8 到 4.0 之间，而前者为 3.0 到 13.5；因此，这一排序依赖的是随机种子区间能够分辨的差异，而不是曲线之间肉眼可见的跨度。在这两个基准测试上，这两个指标的表现也都不相同；相比之下，放电率分布在两种设置中都能提供有效信息。这正是我们对诊断指标的要求：当基准发生变化时，它不应停止区分不同方法，也不应改变其所能区分的对象。

6.3 案例研究：设计平衡网络

前几节表明，可塑性与未塌缩的放电率分布相关，且在接近50%时效果最佳。虽然负载均衡能够显式地实现这一点，但我们现在要探讨的是，仅凭架构是否也能诱导出相同的行为。在放电率诊断的指导下，通过追踪逐层分布，我们确定了最低限度且有效的修改方案。我们的目标不是穷尽所有架构设计，而是针对性地研究放电率视角如何转化为实际的设计选择。

非仿射归一化。 让 ReLU 单元保持在约 50% 放电区间的直接方法，是使其预激活值以阈值（零）为中心。归一化层会计算标准化信号，并

随后应用带有缩放参数 γ 和偏移参数 δ的可学习仿射变换：

$$\hat{x} = \frac{x - \mathbb{E}[x]}{\sqrt{\mathrm{Var}(x) + \epsilon}} \cdot \gamma + \delta. \tag{10}$$

批归一化（Ioffe 与 Szegedy，2015年）在批次上估计均值和方差；层归一化（Ba 等人，2016年）则在特征维度上进行。关键在于，学习到的偏移量 δ 可以将归一化信号移离零点，因此这些层通常不会使激活以 ReLU 阈值为中心。

因此，我们考虑去除学习到的缩放因子 γ 和偏移量 δ的非仿射变体。如图13所示，非仿射批归一化 $+$L2 产生了紧密聚集在 $\approx 50\%$ 附近的放电率，并在全部10个任务序列（$+0.38 \pm 0.10$）上都优于 CBP @ 批归一化 $+$ L2。相比之下，非仿射层归一化 $+$L2 产生的放电率广泛分布于0–100%之间，并在该基准上取得了最高准确率，甚至超过了我们的负载均衡结果。这表明，尽管居中有助于促进平衡活动，但放电率在逐层变异性上的扩大同样可以带来性能提升。

在非仿射层归一化上添加以严格 50% 放电率为目标的负载均衡，会降低准确率（-0.53 ± 0.06，见图13）；而在非仿射批归一化上采用相同目标，则会略微提升准确率（$+0.19 \pm 0.06$）：效果的方向取决于归一化方式，而非目标本身。这表明，对所有单元强制采用同一放电率并非普遍最优；如果均衡利用已经分布在完整的放电率范围内，且随层和单元而异，那么进一步收紧范围就会损害准确率。在图14中，非仿射批归一化也提升了类别增量 CIFAR-100 上的准确率，并且已优于基于重置的基线和 CBP。相应的放电率分布集中在中间范围，而非塌缩至 0% 或饱和在接近 100% 的水平。

归一化跳跃连接。 基于归一化视角，图17绘出了类别增量 CIFAR-100 中每个 ResNet 模块的第一个和第二个 ReLU 的放电率。尽管使用了非仿射批归一化，第二个 ReLU 的分布仍然偏斜（第二个面板）。原因在于架构设计：采用 He 等人（2016）提出、Dohare 等人（2024）使用的经典后激活模块（`Conv-BatchNorm-ReLU-Conv-BatchNorm`，跳跃连接，第二个 ReLU）时，第二个 ReLU 的预激活并未经过归一化。在“归一化跳跃连接”变体中，我们对跳跃路径应用非仿射批归一化。图17右侧的面板显示，这使分布围绕 50% 更加对称。图14证实了整个网络呈现相同趋势，准确率也有所提升。尽管原始后激活模块存在缺点早已为人所知，我们的结果从放电率均衡的角度提供了互补的解释。

研究结果概述。 非仿射归一化层和归一化跳跃连接会使放电率分布趋向均衡状态，通常接近 50%，并且能持续提升持续学习基准上的准确率。虽然已有研究从其他视角探讨了它们的益处，但从放电率动态的角度来看，便能理解这些改动为何能提升性能。

7 局限性

对于 ReLU 激活（在一定程度上也适用于 LeakyReLU 和 GELU，见第5.1节），可以通过预激活值的符号轻松定义放电率。然而，对于双曲正切或 Sigmoid 这类饱和的对称激活函数，如何控制放电率则不那么明确。可选方案包括控制饱和程度（较大的预激活值绝对值）以及线性度（接近零的预激活值）。我们将基于熵的视角与这些情况的联系留待未来工作探讨。

我们的负载均衡层旨在与归一化层协同工作，由后者稳定预激活值，使放电率的变化具有意义。CBP 等方法对底层架构的依赖性较低。尽管如此，负载均衡易于实现，只需为每个神经元添加一个不可训练的偏移量和一个逐元素偏移操作，并且能够自然地集成到 ResNet 等广泛使用的架构中。

我们的证据也有一些值得指出的局限。持续学习 ImageNet 中的效应绝对值较小——准确率大约只差一个百分点——只有因为所有方法都在相同的

任务序列上进行评估，这些效应才得以显现；在这一样本量下，我们不认为它们能在未配对比较中显现出来。第 6.2 节中的可塑性指标取 5 次运行的平均值，而准确率采用的是 10 次和 15 次运行，因此我们据此判定的最小差异，其误差带也相应更宽。熵分析依赖 Chow–Liu 近似，该近似给出联合熵的上界，而非对其进行估计，因此它表明额外的逐单元容量并未被冗余抵消，但并不意味着联合熵达到了某个特定值。最后，固定的 50% 目标并非始终最佳：第 6.3 节发现了一种配置，其放电率分布在整个范围内，且表现优于该目标。因此，边际熵论证虽是有用的指导，但并未完整解释均衡利用带来的益处。

8 结论

本研究指出，神经元放电率是一种简单且易于解释的信号，可用于诊断和改善持续学习中的可塑性。我们发现，持续训练往往会使放电率走向极端，导致单元失活或实际表现为线性单元。为此，我们提出了一种轻量级负载均衡机制，使放电率保持在目标范围内；在监督学习基准和 Atari 上，该机制的表现均优于基于重置的方法。我们还进一步证明，架构选择能够在不显式干预的情况下促成类似的平衡——在持续学习 ImageNet 上，这种平衡的效果足以胜过显式控制。综上，这些结果表明，放电率分布是一种实用的设计工具，有助于构建更稳健的持续学习器。

致谢

本研究由德国联邦研究、技术与空间部和北莱茵-威斯特法伦州资助并支持，是 Lamarr机器学习与人工智能研究所相关工作的一部分。

更广泛影响声明

本研究探讨了神经网络为何会随着数据分布发生变化而丧失持续学习的能力，并提出了一种可缓解这一问题的轻量级机制。维持可塑性可以减少每当数据变化时从头重新训练模型的需求，从而降低保持已部署模型更新所需的计算与能源成本；这也让模型更容易持续吸收新数据，因此，关于持续更新模型所用训练数据的常规考量仍然适用。我们认为，本研究没有需要进一步讨论的特有影响。

可复现性声明

我们的实验基于 Dohare 等人（2024）的官方实现[1]。在类别增量 CIFAR-100 上，我们采用其论文中报告的超参数。在持续学习 ImageNet 上，由于我们的配置与其配置不同，我们针对每种方法重新调整学习率和正则化强度；所有搜索范围和选定值均见第 C 节。除此之外，我们还做了两处调整。首先，我们将负载均衡层添加在每个 ReLU激活之前（实现细节见第4节）。其次，在使用 L2 正则化时，我们仅将其应用于权重，不包括偏置和归一化层参数（更多细节见第 C 节）。所有新增超参数均在正文中说明。

大语言模型（LLM）的使用

本文在准备过程中使用了大语言模型（LLM）作为辅助工具。在写作方面，它们帮助润色措辞、提升表达清晰度和撰写图注，并对个别段落提出修改建议。此外，它们还被用于协助阐释熵和互信息等背景概念。在分析方面，LLM 编程助手帮助编写脚本，从已记录的训练运行中生成表格和图

[1] https://github.com/shibhansh/loss-of-plasticity

，并根据这些运行结果核对报告中的数值。它们还帮助规划和明确了额外的超参数调优运行。研究问题、负载均衡方法和理论论证均由作者提出。作者审阅了所有由 LLM 生成的文本和代码，并对本文内容承担全部责任。

参考文献

Zaheer Abbas、Rosie Zhao、Joseph Modayil、Adam White 和 Marlos C. Machado。持续深度强化学习中的可塑性丧失。载于 Sarath Chandar、Razvan Pascanu、Hanie Sedghi 和 Doina Precup（编），*终身学习智能体会议*，*2023*年*8*月*22*日至*25*日，麦吉尔大学，蒙特利尔，魁北克，加拿大，第 232 卷，机器学习研究论文集，第 620–636 页。PMLR，2023年。URL https://proceedings.mlr.press/v232/abbas23a.html。

Matthew Aitchison、Penny Sweetser 和 Marcus Hutter。Atari-5：将街机学习环境提炼为五款游戏。载于 Andreas Krause、Emma Brunskill、KyungHyun Cho、Barbara Engelhardt、Sivan Sabato 和 Jonathan Scarlett（编），国际机器学习会议，*ICML 2023*，*2023*年*7*月*23*日至*29*日，美国夏威夷檀香山，第 202 卷，机器学习研究论文集，第 421–438 页。PMLR，2023年。URL https://proceedings.mlr.press/v202/aitchison23a.html。

Jordan T. Ash 和 Ryan P. Adams。关于神经网络训练的热启动。载于 Hugo Larochelle、Marc'Aurelio Ranzato、Raia Hadsell、Maria-Florina Balcan 和 Hsuan-Tien Lin（编），神经信息处理系统进展第*33*卷：神经信息处理系统年度会议 *2020*，*NeurIPS 2020*，*2020*年*12*月*6*日至*12*日，线上，2020年。URL https://proceedings.neurips.cc/paper/2020/hash/288cd2567953f06e460a33951f55daaf-Abstract.html。

Lei Jimmy Ba、Jamie Ryan Kiros 和 Geoffrey E. Hinton。层归一化。*CoRR*，abs/1607.06450，2016年。URL http://arxiv.org/abs/1607.06450。

Randall Balestriero 和 Richard G Baraniuk。批归一化详解。*arXiv* 预印本 *arXiv:2209.14778*，2022年。

Tudor Berariu、Wojciech Czarnecki、Soham De、Jörg Bornschein、Samuel L. Smith、Razvan Pascanu 和 Claudia Clopath。关于神经网络可塑性的研究。*CoRR*，abs/2106.00042，2021年。URL https://arxiv.org/abs/2106.00042。

Rudy R Bunel、Ilker Turkaslan、Philip Torr、Pushmeet Kohli 和 Pawan K Mudigonda。分段线性神经网络验证的统一视角。载于 S. Bengio、H. Wallach、H. Larochelle、K. Grauman、N. Cesa-Bianchi 和 R. Garnett（编），神经信息处理系统进展，第 31 卷。Curran Associates, Inc.，2018年。URL https://proceedings.neurips.cc/paper_files/paper/2018/file/be53d253d6bc3258a8160556dda3e9b2-Paper.pdf。

Yanshuai Cao、Gavin Weiguang Ding、Kry Yik-Chau Lui 和 Ruitong Huang。通过二值化表示熵（BRE）正则化改进生成对抗网络训练。载于国际学习表征会议，2018年。URL https://openreview.net/forum?id=BkLhaGZRW。

GA Carpenter。模拟输入模式的稳定类别识别编码自组织。《应用光学》，3：4919–4930，1987年。

C. K. Chow 和 C. N. Liu。使用依赖树近似离散概率分布。《IEEE 信息论汇刊》，14(3)：462–467，1968年。doi：10.1109/TIT.1968.1054142。URL https://doi.org/10.1109/TIT.1968.1054142。

Marelie Davel、Marthinus Theunissen、Arnold Pretorius 和 Etienne Barnard。深度神经网络作为协作分类器层。载于*AAAI* 人工智能会议论文集，第34卷，第3725–3732页，2020 年。

Jia Deng、Wei Dong、Richard Socher、Li-Jia Li、Kai Li 和 Li Fei-Fei。《ImageNet：一个大规模层次化图像数据库》。载于*2009*年 *IEEE* 计算机视觉与模式识别会议，第 248–255 页。IEEE，2009年。

Shibhansh Dohare、J Fernando Hernandez-Garcia、Qingfeng Lan、Parash Rahman、A Rupam Mahmood 和 Richard S Sutton。《深度持续学习中的可塑性丧失》。《自然》，632(8026)：768–774，2024年。

Mohamed Elsayed 和 A. Rupam Mahmood。应对持续学习中的可塑性丧失和灾难性遗忘。载于第十二届国际学习表征会议，*ICLR 2024*，奥地利维也纳，*2024*年*5*月*7*日至*11*日。OpenReview.net，2024年。URL https://openreview.net/forum?id=sKPzAXoylB。

Vivek Farias 和 Adam Daniel Jozefiak。持续学习中的可塑性自归一化重置。载于第十三届国际学习表征会议，2025年。URL https://openreview.net/forum?id=G82uQztzxl。

Pierre Foret、Ariel Kleiner、Hossein Mobahi 和 Behnam Neyshabur。通过尖锐度感知最小化高效提升泛化能力。载于第九届国际学习表征会议，*ICLR 2021*，虚拟会议，奥地利，*2021*年*5*月*3*日至*7*日。OpenReview.net，2021 年。URL https://openreview.net/forum?id=6Tm1mposlrM。

Alexis Goujon、Arian Etemadi 和 Michael Unser。关于分段线性神经网络的区域数量。《计算与应用数学杂志》，441:115667，2024年。doi：10.1016/J.CAM.2023.115667。URL https://doi.org/10.1016/j.cam.2023.115667。

David Hartmann、Daniel Franzen 和 Sebastian Brodehl。研究前馈ReLU网络训练期间神经激活模式的演变。《人工智能前沿》，第 4 卷—2021 年，2021 年。ISSN 2624-8212。doi：10.3389/frai.2021.642374。URL https://www.frontiersin.org/journals/artificial-intelligence/articles/10.3389/frai.2021.642374。

Kaiming He、Xiangyu Zhang、Shaoqing Ren 和 Jian Sun。用于图像识别的深度残差学习。载于*IEEE* 计算机视觉与模式识别会议论文集，第 770–778 页，2016年。

Dan Hendrycks 和 Kevin Gimpel。高斯误差线性单元（GELU）。*arXiv* 预印本 *arXiv:1606.08415*，2016年。

Matteo Hessel、Joseph Modayil、Hado van Hasselt、Tom Schaul、Georg Ostrovski、Will Dabney、Dan Horgan、Bilal Piot、Mohammad Gheshlaghi Azar 和 David Silver。Rainbow：结合深度强化学习中的改进。载于 Sheila A. McIlraith 和 Kilian Q. Weinberger（编），第三十二届 *AAAI* 人工智能会议、第三十届人工智能创新应用会议（*IAAI-18*）及第八届 *AAAI*人工智能教育进展研讨会（*EAAI-18*）论文集，*2018*年*2*月*2*日至*7*日，美国路易斯安那州新奥尔良，第3215–3222页。AAAI出版社，2018年。doi：10.1609/AAAI.V32I1.11796。URL https://doi.org/10.1609/aaai.v32i1.11796。

Shengyi Huang、Rousslan Fernand Julien Dossa、Chang Ye、Jeff Braga、Dipam Chakraborty、Kinal Mehta 和 JoÃčo G.M. AraÃžjo。Cleanrl：高质量的深度强化学习算法单文件实现。《机器学习研究杂志》，23(274):1–18，2022年。URL http://jmlr.org/papers/v23/21-1342.html。

Sergey Ioffe 和 Christian Szegedy。批归一化：通过减少内部协变量偏移来加速深度网络训练。载于 Francis R. Bach 和 David M. Blei（编），第*32*届国际机器学习会议论文集，*ICML 2015*，法国里尔，*2015*年*7*月*6*日至*11*日，*JMLR*研讨会与会议论文集第37卷，第448–456页。JMLR.org，2015年。URL http://proceedings.mlr.press/v37/ioffe15.html。

Khimya Khetarpal、Matthew Riemer、IrinaRish 和 Doina Precup。迈向持续强化学习：综述与展望。人工智能研究杂志，75：1401–1476，2022年。

Alex Krizhevsky、Geoffrey Hinton 等。学习微型图像中的多层特征。技术报告，多伦多大学，2009年。

Saurabh Kumar、Henrik Marklund 和 Benjamin Van Roy。通过再生正则化在持续学习中保持可塑性，2024年。网址 https://openreview.net/forum?id=lyoOWX0e0O。

Hojoon Lee、Hanseul Cho、Hyunseung Kim、Daehoon Gwak、Joonkee Kim、Jaegul Choo、Se-Young Yun 和 Chulhee Yun。PLASTIC：提升样本效率强化学习中的输入可塑性和标签可塑性。载于 Alice Oh、Tristan Naumann、Amir Globerson、Kate Saenko、Moritz Hardt 和 Sergey Levine（编），神经信息处理系统进展第 *36* 卷：神经信息处理系统 *2023* 年年会，*NeurIPS 2023*，美国路易斯安那州新奥尔良，*2023*年*12*月*10*日至*16*日，2023年。网址 http://papers.nips.cc/paper_files/paper/2023/hash/c464fc4516aca4e68f2a14e67c6f0402-Abstract-Conference.html。

Alex Lewandowski、Michal Bortkiewicz、Saurabh Kumar、András György、Dale Schuurmans、Mateusz Os- taszewski 和 Marlos C. Machado。通过谱正则化持续学习。载于第十三届国际学习表征会议，*ICLR 2025*，新加坡，*2025*年*4*月*24*日至*28*日。OpenRe- view.net，2025年。URL https://openreview.net/forum?id=Hcb2cgPbMg。

Ralph Linsker。感知网络中的自组织。*Computer*，21(3):105–117，1988年。doi：10.1109/2.36。URL https://doi.org/10.1109/2.36。

Zhuang Liu、Hanzi Mao、Chao-Yuan Wu、Christoph Feichtenhofer、Trevor Darrell 和 Saining Xie。面向 2020 年代的卷积网络。载于*IEEE/CVF*计算机视觉与模式识别会议论文集，第 11976–11986 页，2022年。

Clare Lyle、Mark Rowland 和 Will Dabney。理解并防止强化学习中的容量损失。载于第十届国际学习表征会议，*ICLR 2022*，线上，*2022*年*4*月*25*日至*29*日。OpenReview.net，2022年。URL https://openreview.net/forum?id=ZkC8wKoLbQ7。

Clare Lyle、Zeyu Zheng、Khimya Khetarpal、Hado van Hasselt、Razvan Pascanu、James Martens 和 Will Dabney。解构神经网络可塑性丧失的原因。载于第三届终身学习智能体会议，机器学习研究论文集第274卷，第750–783页。PMLR，2025年。URL https://proceedings.mlr.press/v274/lyle25a.html。

Andrew L Maas、Awni Y Hannun 和 Andrew Y Ng。整流非线性改进神经网络声学模型。载于*ICML* 音频、语音和语言处理深度学习研讨会，2013年。

Michael McCloskey 和 Neal J. Cohen。《联结主义网络中的灾难性干扰：序列学习问题》。载于 Gordon H. Bower（编），学习与动机心理学，第 24 卷，第 109–165 页。Academic Press，1989 年。doi：https://doi.org/10.1016/S0079-7421(08)60536-8。URL https://www.sciencedirect.com/science/article/pii/S0079742108605368。

Guido Montúfar、Razvan Pascanu、KyungHyun Cho 和 Yoshua Bengio。《深度神经网络线性区域的数量》。载于 Zoubin Ghahramani、Max Welling、Corinna Cortes、Neil D. Lawrence 和 KilianQ. Weinberger（编），神经信息处理系统进展 *27*：神经信息处理系统年度会议 *2014*，*2014*年*12*月*8*日至*13*日，加拿大魁北克省蒙特利尔，第 2924–2932 页，2014 年。URL https://proceedings.neurips.cc/paper/2014/hash/109d2dd3608f669ca17920c511c2a41e-Abstract.html。

Yunhao Ni、Yuxin Guo、Junlong Jia 和 Lei Huang。关于层归一化的非线性。载于 Ruslan Salakhutdinov、Zico Kolter、Katherine Heller、Adrian Weller、Nuria Oliver、Jonathan Scarlett 和 Felix Berkenkamp（编），第*41*届国际机器学习会议论文集，机器学习研究论文集第235卷，第37957–37998页。PMLR，2024年7月21日至27日。URLhttps://proceedings.mlr.press/v235/ni24b.html。

Evgenii Nikishin、Max Schwarzer、Pierluca D'Oro、Pierre-Luc Bacon 和 Aaron C. Courville。深度强化学习中的首因偏差。载于 Kamalika Chaudhuri、Stefanie Jegelka、Le Song、Csaba Szepesvári、Gang Niu 和 Sivan Sabato（编），国际机器学习会议，*ICML 2022*，*2022*年*7*月*17*日至*23*日，巴尔的摩，马里兰州，美国，机器学习研究论文集第162卷，第16828–16847页。PMLR，2022年。URL https://proceedings.mlr.press/v162/nikishin22a.html。

Evgenii Nikishin、Junhyuk Oh、Georg Ostrovski、Clare Lyle、Razvan Pascanu、Will Dabney 和 André Barreto。《通过可塑性注入实现深度强化学习》。载于 Alice Oh、Tristan Naumann、Amir Globerson,

Kate Saenko、Moritz Hardt 和 Sergey Levine（编），神经信息处理系统进展 *36*：*2023* 年神经信息处理系统年度会议，*NeurIPS 2023*，美国路易斯安那州新奥尔良，*2023*年*12*月*10*日至*16*日，2023年。网址 http://papers.nips.cc/paper_files/paper/2023/hash/75101364dc3aa7772d27528ea504472b-Abstract-Conference.html。

Yookoon Park、Sangho Lee、Gunhee Kim 和 David Blei。通过神经激活编码进行无监督表示学习。载于 Marina Meila 和 Tong Zhang（编），第*38*届国际机器学习会议论文集，机器学习研究论文集第139卷，第8391–8400页。PMLR，2021年7月18日至24日。URL https://proceedings.mlr.press/v139/park21b.html。

Thiago Serra、Christian Tjandraatmadja 和 Srikumar Ramalingam。深度神经网络线性区域的界定与计数。载于 Jennifer G. Dy 和 Andreas Krause（编），第*35*届国际机器学习会议（*ICML 2018*），于瑞典斯德哥尔摩的 *Stockholmsmässan* 举行，*2018*年*7*月*10*日至*15*日，机器学习研究论文集第80卷，第4565–4573页。PMLR，2018年。URL http://proceedings.mlr.press/v80/serra18b.html。

Ghada Sokar、Rishabh Agarwal、Pablo Samuel Castro 和 Utku Evci。深度强化学习中的休眠神经元现象。载于 Andreas Krause、Emma Brunskill、KyungHyun Cho、Barbara Engelhardt、Sivan Sabato 和 Jonathan Scarlett（编），国际机器学习会议，*ICML 2023*，*2023*年*7*月*23*日至*29*日，美国夏威夷檀香山，机器学习研究论文集第 202 卷，第 32145–32168 页。PMLR，2023 年。网址： https://proceedings.mlr.press/v202/sokar23a.html。

Yuuki Takai、Akiyoshi Sannai 和 Matthieu Cordonnier。关于构成深度神经网络的线性函数数量：迈向神经网络复杂度的精确定义。载于 Arindam Banerjee 和 Kenji Fukumizu（编），第二十四届人工智能与统计学国际会议，*AISTATS 2021*，*2021*年*4*月*13*日至*15*日，线上，机器学习研究论文集第 130 卷，第 3799–3807 页。PMLR，2021 年。网址 http://proceedings.mlr.press/v130/takai21a.html。

Michael Satosi Watanabe。多变量相关性的信息论分析。*IBM*研究与开发期刊，4（1）：66–82，1960年。doi：10.1147/RD.41.0066。URL https://doi.org/10.1147/rd.41.0066。

Xiao Zhang 和 Dongrui Wu。深度神经网络中线性区域性质的实证研究。载于<text style id='1'>国际学习表征会议，2020 年。URL https://openreview.net/forum?id=SkeFl1HKwr。

A 附加结果

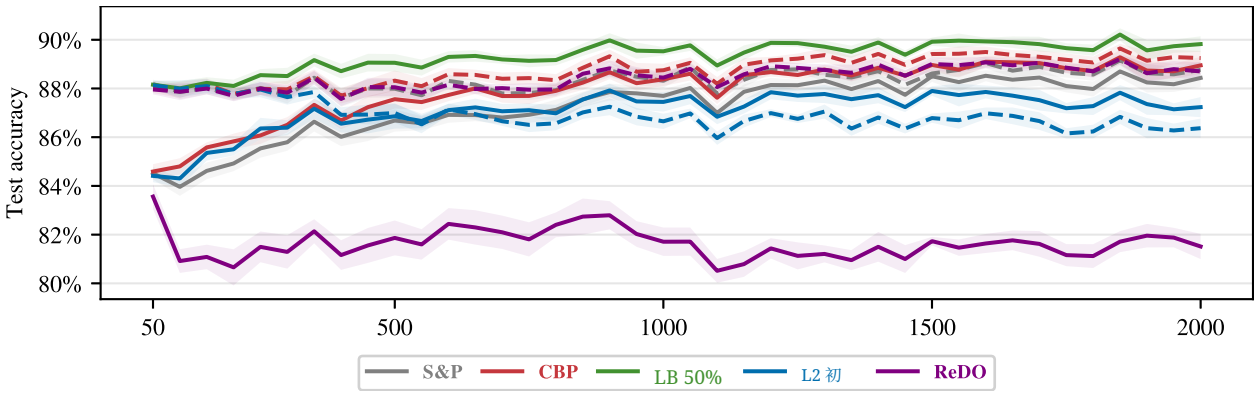

图 15：**持续学习 ImageNet：**其他基线方法的测试准确率。虚线表示基于批归一化骨干网络构建的变体（BN + L2，但 L2 初始化 + BN 除外，它不再添加 L2 正则化）。

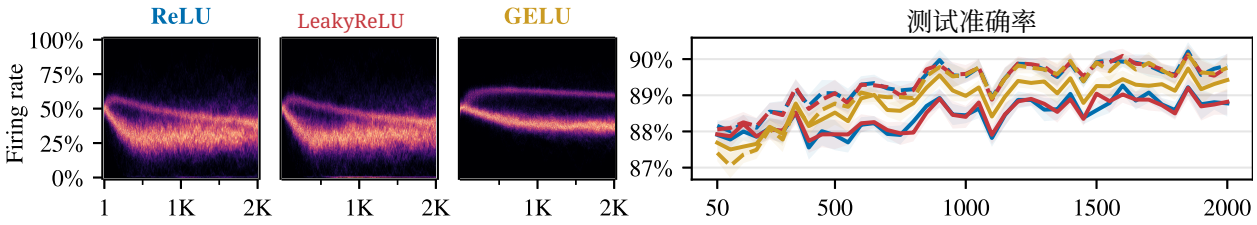

图 16：**持续学习 ImageNet：**基于 BN + L2 设置的 ReLU、LeakyReLU 和 GELU 的放电率分布（左）与测试准确率（右）。右图中的虚线表示负载均衡率为 50% 时的结果。

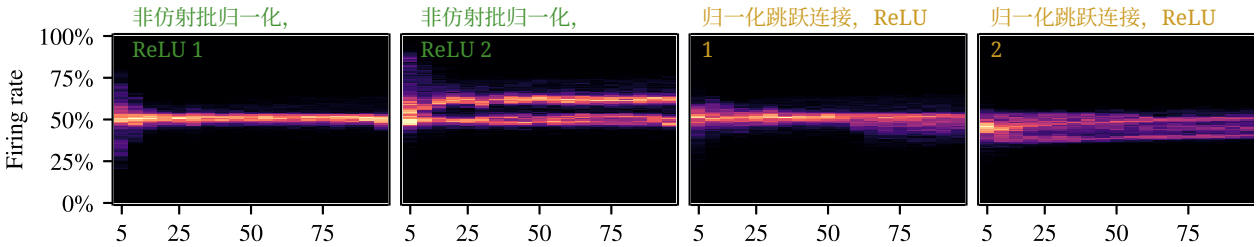

图17：**类别增量 CIFAR-100：**所有 ResNet 模块中第一个和第二个 ReLU 的放电率分布。**左图：**非仿射批归一化基线；第二个 ReLU 的分布存在偏斜。**右图：**在加法之前对跳跃路径应用非仿射批归一化，可使第二个 ReLU 的预激活重新居中，从而形成围绕 50% 更对称的分布。

B 扩展理论讨论

超越连续分段仿射网络。当网络由仿射层与分段线性运算（例如 ReLU 和最大池化）构成时，整体输入—输出映射是连续分段仿射（CPWA）的，因此激活模式可以标示计算过程中的仿射区域（Montúfar 等人，2014 年；Serra 等人，2018年；Goujon 等人，2024年）。这包括常见的卷积神经网络和残差网络，以及在推理时使用批归一化的网络：在运行统计量被冻结的情况下，批归一化可简化为仿射变换，因此能够保持分段线性结构（Bunel 等人，2018年；Balestriero 和 Baraniuk，2022年）。在架构

采用 LayerNorm 等平滑归一化方法后，该映射不再是分段仿射的，因为 LayerNorm 通过逐样本标准差进行归一化（涉及平方根和除法），即使周围层是线性的，也会引入平滑非线性（Ba 等人，2016年；Ni 等人，2024年）。在这种情况下，应将 S 理解为对运行状态 或有效子网络的索引（即采用了哪些 ReLU 分支，从而实现了哪种局部计算），而不是对精确仿射区域的索引。尽管如此，编码视角仍然具有实用价值：针对激活编码的熵或互信息目标，被认为可以在不依赖严格 CPWA 假设的情况下，促进多样且抗噪的内部运行状态（Park等人，2021 年）。

平均汉明距离。 这里明确说明边缘熵目标与二进制激活编码之间的平均汉明距离有何关系。令 $p_i \coloneqq \Pr(\mathbf{s}_i = 1)$，并考虑两个相互独立的输入 $x,\ x' \sim P_{\mathbf{x}}$，其编码分别为 $S(x)$ 和 $S(x')$。它们的期望汉明距离可分解为

$$\bar{d}_H \coloneqq \mathbb{E}_{x,x'}\big[d_H\big(S(x), S(x')\big)\big] \tag{11}$$

$$= \sum_{i=1}^{M} \Pr\big(\mathbf{s}_i(x) \neq \mathbf{s}_i(x')\big) \tag{12}$$

$$= \sum_{i=1}^{M} 2\,p_i(1-p_i). \tag{13}$$

伯努利熵 $H(\mathbf{s}_i)$ 和方差项 $p_i(1-p_i)$ 均在 $p_i = 1/2$ 处达到最大值，并且随着 p_i 向 0 或 1 移动而严格递减。因此，最大化 $\sum_i H(\mathbf{s}_i)$ 不仅可以避免死单元或饱和单元，¯还会增大激活模式之间的平均汉明距离 d_H，使不同输入对应的码字更加分离。这一观点与 Park等人（2021）的噪声信道分析密切相关。他们表明，在其神经激活编码目标中，输入与噪声二值编码之间的互信息为码字之间的平均汉明距离提供下界，因此，最大化互信息可以得到分离程度最大的抗噪激活编码。

C 训练细节

持续学习 ImageNet。 该模型是一个紧凑型卷积神经网络，由三个卷积层和两个全连接层组成，并采用 ReLU 激活。L2 正则化仅应用于权重，不包括偏置和归一化层的参数。这与原始 CBP 代码库有所不同，但遵循了常见做法，也是取得良好 L2 性能所必需的。所有报告的准确率均为 10 次运行的平均值，这些运行所采样的任务序列各不相同；每种方法均在相同的 10 个序列上进行评估。第 6.2 节的可塑性指标需要额外记录每个任务的数据，并取 5 次运行的平均值，运行所采用的任务序列以相同方式抽取。所有实验均在单张 NVIDIA A100、H100 或 H200 GPU 上运行， `torch.compile`且除 CBP 外均采用 fp16 混合精度。对于大多数方法，在 A100 上完成一次完整运行大约需要 2.8 小时；实测的挂钟时间中位数报告于本节末尾。

所有超参数和搜索范围均列于表格 1 中；集合值条目表示我们在搜索中考察的取值。我们调优两种参考配置，作为后续实验的起点：**基线**（不使用批归一化和 L2正则化）以及**批量归一化 + L2正则化**（两者均启用）。对于基于归一化和正则化的附加方法（批归一化、*L2*正则化、*S&P*、*L2* 初始化、非仿射归一化及其组合），我们联合搜索学习率和相关的正则化超参数（适用时的 L2 强度、S&P 的噪声尺度，以及 L2 初始化的正则化强度），选择在最后 100 个任务上平均准确率最高的设置。随后，我们使用表格中报告的完整运行次数重新运行所选设置，并报告这些运行结果。表现最佳的超参数如下：

- **基线：** 学习率 0.001
- **仅批归一化：** 学习率 0.01
- **仅 L2正则化：** 学习率 0.03，L2 强度 3e−06
- **S&P：** 学习率 0.01，L2 强度 1e−05，噪声尺度 1e−05
- **S&P @ 批量归一化 + L2：** 学习率 0.03，L2 强度 1e−06，噪声尺度 1e−06

- **L2 初始化：** 学习率 0.01，L2 初始化强度 1e$-$05
- **L2 初始化 + 批量归一化：**学习率 0.03，L2 初始化强度 1e$-$05
- **批量归一化 + L2正则化：** 学习率 0.03，L2 强度 1e$-$06
- **非仿射批归一化 + L2正则化：** 学习率 0.1，L2 强度 1e$-$06
- **非仿射层归一化 + L2正则化：** 学习率 0.1，L2 强度 1e$-$06

列表中的两种命名模式是有意为之的：S&P @ 批量归一化 +L2 正则化是在调优后的批量归一化 +L2 正则化参考配置上实例化的，并保留其 L2 强度；而 L2 初始化 + 批归一化则将 L2 初始化与批归一化结合使用，不再额外采用 L2 正则化——由向初始化值施加的正则化取而代之。对于引入自身超参数的方法（$ReDO$、CBP、负载均衡），我们在调优后的参考配置之上实例化这些方法，并固定参考超参数（学习率以及在适用时的 L2 强度）。随后，我们仅调整方法特定的超参数，并再次根据最后 100 个任务上的准确率进行选择。表现最佳的特定方法超参数为：

- **ReDO @ 基线：** 休眠阈值 0.1，回收周期 10
- **ReDO @ 批量归一化 + L2正则化：** 休眠阈值 0，回收周期 10
- **CBP @ 基线：** 替换率 0.0003
- **CBP @ 批量归一化 + L2正则化：** 替换率 0.0003
- **负载均衡 @ 批量归一化 + L2正则化：** 目标范围 50%

GELU 和 LeakyReLU 与其他变体采用相同方式进行调优：在 BN +L2 骨干网络上联合调整学习率和 L2 强度（最佳值分别为学习率 0.01 和 0.03，二者的 L2 强度均为 1e$-$06），并在这些设置下加入负载均衡。

类别增量 CIFAR-100。 每个任务开始时，从 CIFAR-100 中随机抽取五个类别。每经过 200 个训练轮次，就引入另外五个类别，并训练模型对迄今为止遇到的所有类别进行分类。架构采用 ResNet-18 和 ReLU 激活，并针对 32×32 CIFAR-100 图像进行了调整。每个新任务都从前一个任务的最佳检查点开始，该检查点依据验证准确率选出，实质上相当于采用早停（Dohare 等，2024）。所有报告的准确率均为 15 个随机种子的平均值。第 6.2 节中的可塑性指标需要额外记录每个任务的数据，并取 5 个随机种子的平均值。所有实验均在单块 NVIDIA A100、H100 或 H200 GPU 上运行，使用 `torch.compile` 和 fp16 混合精度；在 A100 上，每个随机种子的完整运行约需 6 小时。

所有超参数和搜索范围均列于表 2。对于所有方法，我们采用与 Dohare 等人（2024）相同的基础学习率和学习率调度。对于 CBP 和 S&P，我们采用 Dohare 等人（2024）报告的超参数。我们发现，L2 初始化与常规 L2 正则化（趋向于零）结合使用时效果更好。其余表现最佳的超参数如下：

- **L2 初始化：** L2 初始化强度 0.0001
- **ReDO：** 休眠阈值 0.1，回收周期 100
- **负载均衡：** 目标范围 50%

Rainbow DQN。 我们的 Rainbow DQN 实现使用 CleanRL 代码库（Huang 等人，2022年）。我们没有更改任何超参数。所有结果均为 5 个随机种子的平均值。所有实验均在单块 NVIDIA A100 或 H100 GPU 上运行；在 A100 上，一次运行约需 15 小时。

负载均衡的敏感性 超参数。 负载均衡引入了三个超参数 ：目标范围 $[\rho_{\mathrm{mi}}$ $_{\mathrm{n}}$，$\rho_{\max}]$、步长 α 和 EMA 衰减 τ。只有目标范围需要调整 .我们在两个监督学习基准上，将目标范围遍历为{5$-$95% 20$-$80% 40$-$60%，50%}，并在表格 3 和 4 中报告全部四种设置。在这两个骨干网络上，随着区间收窄，准确率单调提升：在持续学习 ImageNet 上从 88.8% 提升至 89.8%，在类别增量 CIFAR-100 上则从 77.1% 提升至 78.0%

相差 1.0 和 0.9 个百分点。最宽的区间最没有用；在持续学习 ImageNet 上，它与 BN +L2正则化基准本身无法区分（88.8%），因此，几乎不施加任何约束的目标范围也几乎不会带来任何收益。

步长和 EMA 衰减的影响要小得多。在持续学习 ImageNet 上，固定 BN + L2正则化骨干网络，每次只调整一个超参数，每种设置使用两个随机种子，我们对 α 取值{1e$-$04,3e$-$04, 1e$-$03, 3e$-$03, 1e$-$02, 3e$-$02} 以及 τ 取值{0.8, 0.9, 0.95, 0.99, 0.995, 0.999, 0.9995}进行扫描。步长扫描范围跨越 300 倍，最后 100 个任务的准确率在目标范围为 50% 时波动 0.31 个百分点，在 $5-95$% 时波动 0.23 个百分点；EMA 衰减扫描中，波动分别为 0.35 和 0.59 个百分点。所有设置与默认值的差距都在 0.6 个百分点以内，且没有一种设置失效，因此这两项的影响都远不及目标范围。这为默认值 $\alpha = 0.001$ 和 $\tau = 0.99$提供了依据，我们在所有实验中均沿用这些默认值，不作更改。

计算性能开销。负载均衡层不增加任何可训练参数。每层为每个神经元保留两个标量——平均放电率 $\bar{\rho}$ 和偏移量 β ——二者都不接收梯度，也不占用优化器状态。在类别增量 CIFAR-100 ResNet-18 上，负载均衡安装在 17 个激活处，覆盖 3,904 个神经元，因此仅为包含 11,224,932 个可训练参数的模型增加 7,808 个浮点数。这相当于参数量的 0.07%，还少于网络本身已有的批归一化运行统计量（9,600 个浮点数）。

在推理时，该层只需执行一次逐元素加法，因为算法 1 中的更新受 `self.training`保护。训练期间，它还会为每层计算一个阈值化均值，并在与批归一化完全相同的轴上进行归约，同时执行 $O(d)$ 的工作来更新这两个标量。与不同运行之间的波动相比，由此产生的开销无法测量：在持续学习 ImageNet 上，A100 每次运行的实际运行时间中位数为：BN +L2 时 2.79 小时，启用负载均衡且比例为 50% 时 2.85 小时，以及比例为 $40-60$% 时 2.73 小时。

表 1：**持续学习 ImageNet：** 超参数和搜索范围。集合值条目是我们搜索中考虑的取值。

超参数	值
任务数量	2000
每个任务的训练轮数	250
早停	No
批量大小	100
优化器	SGD
学习率	{0.001,0.003,0.01, 0.03, 0.1}
L2 强度	{1e$-$06,3e$-$06, 1e$-$05,3e$-$05} 或 0
学习率调度	None
动量	0.9
L2 初始化强度	{0.01,0.001, 0.0001, 0.00001}
S&P 噪声尺度	{1e$-$07,1e$-$06, 1e$-$05, 1e$-$04}
ReDO	
休眠阈值	{0, 0。01, 0。1}
回收周期	{10, 100,1000,10000, 100000}
CBP	
替换率	{0.00003,0.0001, 0.0003,0.001, 0.003}
成熟度阈值	100
衰减率	0.99
负载均衡	
目标范围	{5$-$95% 20$-$80% 40$-$60%，50%}
步长	0.001
EMA 衰减	0.99

表 2：**类别增量 CIFAR-100：** 超参数和搜索范围。集合值条目是我们在搜索中考察的值。

超参数	值
任务数量	20
每个任务的训练轮数	200
早停	Yes
批量大小	128
优化器	SGD
基础学习率	0.1
学习率调度（每个任务）	在第 60、120、160 个周期进行阶梯衰减
学习率衰减	0.2
动量	0.9
L2 初始化强度	{0.01，0.001，0.0001，0.00001}
S&P 噪声尺度	1e$-$05
ReDO	
休眠阈值	{0, 0.01, 0.1}
回收周期	{10,100, 1000, 10000, 100000}
CBP	
替换率	1e$-$05
成熟度阈值	1000
衰减率	0.99
负载均衡	
目标范围	{5$-$95% 20$-$80% 40$-$60%,50%}
步长	0.001
EMA 衰减	0.99

D 准确率表格

表 3 至表 5 报告了三项基准测试中所有方法的最终测试准确率和得分，结果以多次运行的均值 ±均值标准误表示。

在两个监督学习基准上，各方法还共享其随机化设置，因此可以进行更有力的比较。在持续学习 ImageNet 中，每个任务都是随机抽取的一对类别，而该类别对的难度主导了不同运行之间的变化：仅批量归一化 +L2正则化基准在其 10 次运行中的结果就从 87.7 跨越到 90.0。此变化源于任务序列，而非方法本身；每种方法的运行 k 都抽取相同的序列——因此在逐次运行差值中会相互抵消，而 LB 50% 相对于批量归一化 +L2正则化的相同 10 个差值仅跨越 0.49 个百分点。在类别增量 CIFAR-100 上，随机种子同样起到这一作用：类别顺序由随机种子决定，并且每种方法都在相同的 15 个随机种子上运行。

因此，表 3 和表 4 同时报告了这两项指标——带有自身标准误的均值，以及相对于基准方法的配对差值；后者在持续学习 ImageNet 上可提高 2–5× 倍精度，在类别增量 CIFAR-100 上可提高 1.2–1.8×倍精度。方法之间的比较应参考配对列。

表3：**持续学习 ImageNet：** 在任务 1900–2000 上取平均的最终测试准确率，以及 10 次运行的均值标准误。所有方法均在相同的 10 个任务序列上进行评估，因此最后一列报告的是相对于经过调优的批量归一化 + L2基线的逐次运行配对 差值。任务采样方差是共同的，因此在此处相互抵消，使比较精确度提高 2–5× 倍，超过基于该基线的方法各自均值所能达到的精度。对于稳定性最低的方法，提升最小——对于基线，两种标准误相同，因为其运行间波动源于自身的不稳定性，而非所分配的类别。各行按准确率排序，配对差值的排序也相同。 $^{*}p < 0.05$, $^{**}p < 0.001$，双侧配对 t检验，$\mathrm{df} = 9$。

方法	准确率（%）	Δ 与批量归一化 + L2 相比
非仿射层归一化 + L2	91.2 ± 0.22	$+2.43 \pm 0.05^{**}$
非仿射层归一化 + L2 + LB 50%	90.7 ± 0.18	$+1.90 \pm 0.06^{**}$
非仿射批归一化 + L2 + LB 50%	89.8 ± 0.18	$+1.05 \pm 0.06^{**}$
LB 50%	89.8 ± 0.20	$+0.99 \pm 0.05^{**}$
GELU + LB 50%	89.7 ± 0.19	$+0.89 \pm 0.07^{**}$
LeakyReLU + LB 50%	89.7 ± 0.25	$+0.87 \pm 0.11^{**}$
非仿射批归一化 + L2正则化	89.6 ± 0.20	$+0.85 \pm 0.07^{**}$
负载均衡 40–60%	89.5 ± 0.20	$+0.72 \pm 0.04^{**}$
GELU	89.4 ± 0.20	$+0.57 \pm 0.08^{**}$
CBP @ 批量归一化 + L2正则化	89.3 ± 0.23	$+0.48 \pm 0.08^{**}$
负载均衡 20–80%	89.1 ± 0.19	$+0.26 \pm 0.07^{*}$
CBP @ 基线	88.8 ± 0.24	$+0.04 \pm 0.08$
负载均衡 5–95%	88.8 ± 0.20	$+0.01 \pm 0.10$
批量归一化 + L2正则化	88.8 ± 0.21	—
LeakyReLU	88.8 ± 0.22	-0.01 ± 0.05
ReDO @ 批量归一化 + L2正则化	88.7 ± 0.23	-0.04 ± 0.11
S&P @ 批量归一化 +L2正则化	88.7 ± 0.20	-0.12 ± 0.08
仅 L2正则化	88.6 ± 0.22	-0.19 ± 0.09
仅批量归一化	88.5 ± 0.22	$-0.25 \pm 0.07^{*}$
S&P	88.3 ± 0.24	$-0.49 \pm 0.17^{*}$
L2 初始化	87.2 ± 0.23	$-1.60 \pm 0.16^{**}$
仅层归一化	87.2 ± 0.23	$-1.61 \pm 0.10^{**}$
层归一化 + L2正则化	87.1 ± 0.30	$-1.69 \pm 0.13^{**}$
L2 初始化 + 批量归一化	86.3 ± 0.22	$-2.47 \pm 0.07^{**}$
ReDO @ 基线	81.7 ± 0.38	$-7.10 \pm 0.31^{**}$
基线	79.0 ± 0.62	$-9.77 \pm 0.60^{**}$

表4：**类别增量 CIFAR-100：** 任务 15–20 的平均最终测试准确率，以及 15 次运行的均值标准误。类别顺序由每次运行的随机种子决定，所有方法使用相同的 15 个随机种子，因此最后一列报告的是相对于重置的配对逐次运行差值；准确率面板也以从头训练参考为对照。这里配对带来的增益小于持续学习 ImageNet 上的增益（1.2–1.8× 对比 2–5×）：前者涵盖 100 个近乎独立的任务，而这里是 5 个难度高度相关的连续任务。各行按准确率排序，配对差值的排序也相同。 $^{*}p < 0.05$, $^{**}p < 0.001$，双侧配对 t-检验，$\mathrm{df} = 14$。

方法	准确率（%）	Δ与重置相比
LB 50%	78.0 ± 0.10	$+1.36 \pm 0.06^{**}$
LeakyReLU + LB 50%	77.9 ± 0.09	$+1.24 \pm 0.05^{**}$
LB 40–60%	77.7 ± 0.09	$+1.05 \pm 0.06^{**}$
归一化跳跃连接	77.5 ± 0.10	$+0.84 \pm 0.05^{**}$
负载均衡 20–80%	77.1 ± 0.11	$+0.51 \pm 0.06^{**}$
负载均衡 5–95%	77.1 ± 0.11	$+0.43 \pm 0.06^{**}$
非仿射批归一化	77.0 ± 0.10	$+0.37 \pm 0.06^{**}$
L2 初始化	76.9 ± 0.08	$+0.22 \pm 0.05^{**}$
GELU + LB 50%	76.7 ± 0.11	$+0.10 \pm 0.07$
CBP	76.7 ± 0.10	$+0.05 \pm 0.06$
重置	76.6 ± 0.09	—
GELU	75.9 ± 0.18	$-0.72 \pm 0.15^{**}$
LeakyReLU	75.5 ± 0.12	$-1.08 \pm 0.06^{**}$
S&P	75.5 ± 0.14	$-1.12 \pm 0.10^{**}$
基线	74.4 ± 0.13	$-2.24 \pm 0.08^{**}$
ReDO	72.7 ± 0.14	$-3.95 \pm 0.10^{**}$

表 5：**Rainbow DQN：** 使用时间加权指数移动平均计算的最终人类归一化得分（± 5 个随机种子上的均值标准误）。LN 是在隐藏层中使用层归一化的 Rainbow DQN，最后两列分别是在其基础上实现的负载均衡和 CBP。粗体表示每行中唯一的最佳均值；没有粗体项的行表示最佳均值并列。

环境	基线	LN	LN 下 50% 的 LB	LN 下的 CBP
BattleZone	0.7 ± 0.1	1.0 ± 0.1	1.0 ± 0.1	0.8 ± 0.1
DemonAttack	50.6 ± 3.5	47.8 ± 4.5	**55.9** ± 1.1	52.5 ± 1.7
DoubleDunk	8.0 ± 0.1	7.9 ± 0.2	8.0 ± 0.3	8.0 ± 0.2
NameThisGame	1.2 ± 0.2	1.8 ± 0.2	**1.9** ± 0.1	1.6 ± 0.2
Phoenix	2.5 ± 0.8	6.3 ± 1.6	**7.4** ± 1.3	3.6 ± 0.4
Qbert	1.4 ± 0.1	1.4 ± 0.1	**1.6** ± 0.1	1.2 ± 0.1

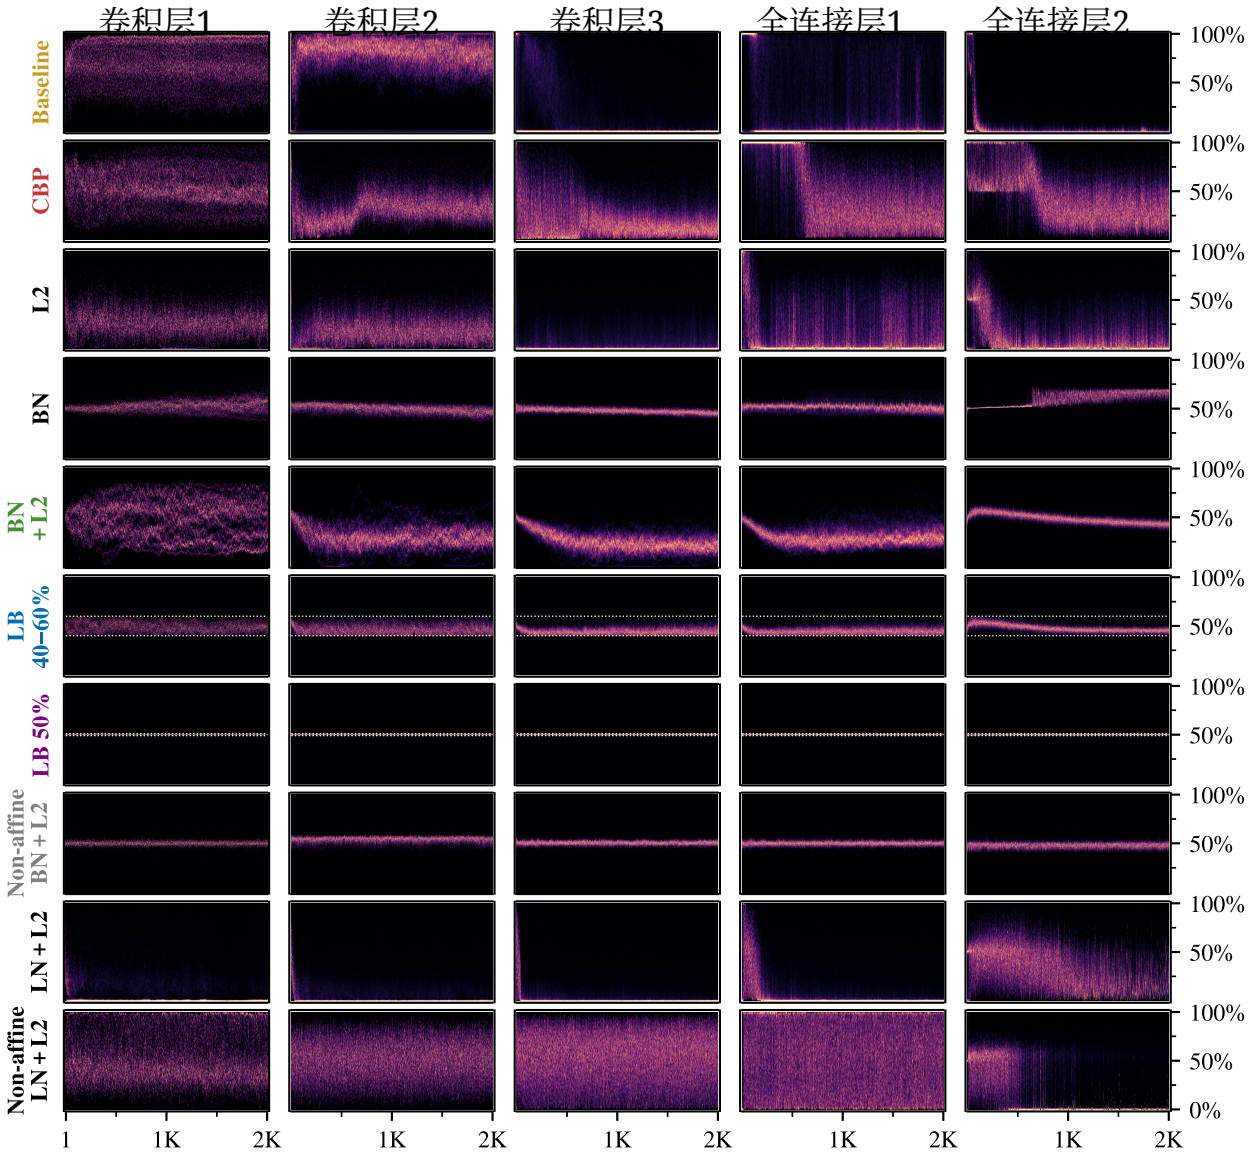

Figure 18: **持续学习 ImageNet：**所有方法的逐层发放率分布 .

E 所有方法的逐层放电率

第 6.1 节展示了具有代表性的一组方法的逐层放电率。这里我们为评估的每种方法都提供了相同的可视化结果。

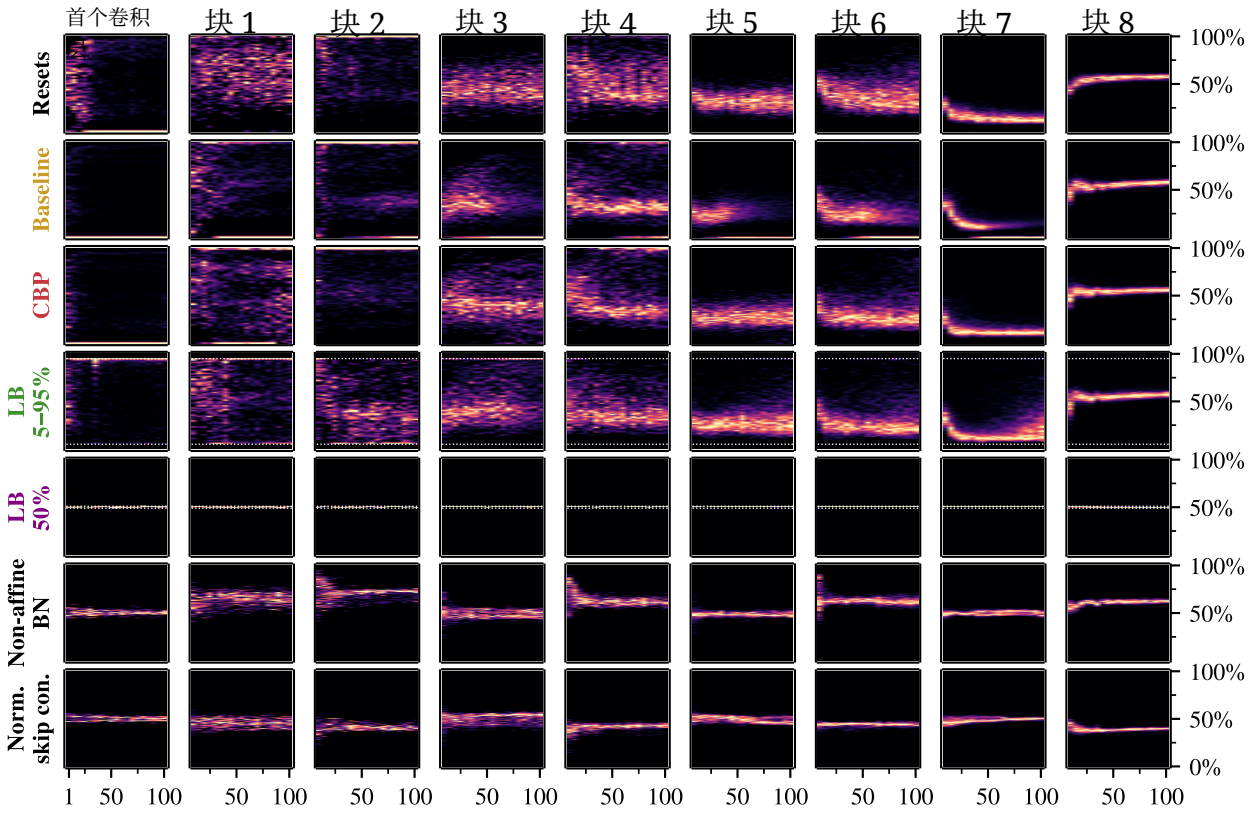

图19：Cl **ass-incremental CIFAR-100：** 所有方法的逐层发放率分布 .