竞争性可塑性以降低学习的能量成本

Mark C.W. van Rossum

2023年4月6日

心理学院和数学科学学院，诺丁汉大学，诺丁汉 NG7 2RD，英国

arXiv:2304.02594v1 [cs.NE] 4 Apr 2023

摘要

大脑不仅受到为计算提供能量所需能量的限制，也受到形成记忆所需能量的限制。实验表明，学习简单的条件作用任务已经会带来显著的代谢成本。然而，学习像MNIST 这样达到95% 准确率的任务，似乎至少需要 10^8 突触更新。因此，大脑很可能已经进化出以尽可能少的能量进行学习的能力。我们探究了前馈神经网络中学习所需的能量。基于一种简约的能量模型，我们提出了两种节省能量的可塑性限制算法：1）仅修改具有较大更新的突触；2）将可塑性限制在形成穿过网络的路径的突触子集上。结合这两种方法可以显著节省能量，同时仅导致学习时间小幅增加。在生物网络中，网络规模通常远大于任务所需的规模。尤其在这种情况下，可以实现大量节省。因此，以竞争方式限制可塑性有助于节省与突触可塑性相关的代谢能。这些结果可能有助于更好地理解生物可塑性，并促进人工学习与生物学习之间更好的匹配。此外，这些算法也可能使硬件受益，因为在电子设备中，存储器存储同样具有很高的能量成本。

能量可用性是生物体的一项vitalnecessity。神经系统是一个特别高强度的能量消耗主体。尽管它约占人体质量的 2%，但却负责基础代谢的约 20%——持续消耗约 20W（Attwell和 Laughlin，2001年；Harris 等人，2012年）。神经信号传递的能量需求如今被广泛视为大脑的一项重要设计约束。稀疏编码和稀疏连接（剪枝）可用于降低能量需求（Levy和 Baxter，1996年）。人们已经设计出能够产生节能网络的学习规则（Sacramento等人，2015年；Grytskyy 和 Jolivet，2021年）。

然而，学习本身也需要付出能量代价：在以苍蝇为对象的经典条件作用实验中，当苍蝇随后处于饥饿状态时，长期记忆的形成使其寿命缩短了20%（Mery和 Kawecki，2005年）。此外，挨饿的果蝇会停止长期记忆形成；然而，强制其进行记忆表达会缩短其寿命（Plaçais和 Preat，2013年）。我们估计果蝇的学习成本为10mJ/bit（Girard等人，2023年）。在哺乳动物中，有生理学证据表明，能量可用性会对持久性可塑性形式发挥门控作用（Potter 等人，2010年）。此外，在人类中，有行为学证据表明代谢与记忆之间存在相关性（Smith 等人，2011年；Klug 等人，2022）。

鉴于这些证据，我们假设生物神经可塑性旨在实现能量高效，并且纳入能量约束可能会产生更接近生物学的计算学习规则，以及对已观察到的突触可塑性规则有更好的理解。由于精确的代谢

成本模型尚不可用，因此我们的目标是探寻提升能源效率的算法原理，而非生物物理机制。具体而言，我们将研究如何在维持整体学习性能的同时，减少可塑性所需的能量。

我们的研究受到以下实验观察的启发：尽管突触强度普遍存在波动，但经历永久性修饰的突触数量似乎受到限制。首先，可塑性在空间上受到限制，例如在运动学习过程中，可塑性仅限于某些树突分支（Cichon and Gan,2015）。其次，可塑性在时间上受到限制。例如，不可能在短时间内连续两次诱导晚期LTP（Rioult-Pedottietal.,2000；Kramár et al., 2012）。这与传统的反向传播形成鲜明对比：传统反向传播会在每个 试验中更新每个突触，而正如我们将看到的，这可能导致学习效率极低。

我们使用人工神经网络作为神经学习的模型。虽然使用反向传播训练的神经网络是对生物学习的抽象，但它提供了一种有效的方法来教会网络复杂的关联，而目前更具生物学特征的网络或算法尚无法与之匹敌。已有研究提出了反向传播的生物学实现方式（例如 Sacramento et al., 2018），但这些实现方式的能量效率可能较低，因为学习时间通常更长。

在人工神经网络研究中，人们对限制可塑性也有类似的兴趣，但通常出于其他原因。仔细选择要修改的突触可以防止覆盖先前存储的信息，也称为灾难性遗忘 (Sezener et al., 2021)。随机开启和关闭可塑性有助于正则化，如 Dropout 及其变体 (Salvetti et al., 1994)。与记忆系统的通信在计算机硬件中也是能量成本高昂的。引人注目的是，在 DRAM 中存储两个 32 位数字远比将它们相乘更昂贵 (Han et al., 2016)。最近的研究开始探索通过限制对权重矩阵的更新来降低这些成本的算法 (Han et al., 2016; Golub et al., 2018)。

方法

数据集

作为数据集，我们使用标准MNIST 数字分类任务。在 Fashion-MNIST数据集上也发现了类似的结果。我们对数据进行了偏移，使输入均值为零。这一常见的预处理步骤非常重要。也就是说，当使用反向传播进行训练时，对输入 x_j 与误差为 δ_i 的单元之间的权重 w_{ij}进行的权重更新是

$$\Delta w_{ij} = -\epsilon W \delta_i x_j$$

由于权重更新与输入值 x_j 成正比，因此当输入值为零时，即使 $\delta_i \neq 0$，也不会发生可塑性变化。不过，这可能会造成混杂因素，因为我们希望完全对可塑性事件的数量加以对照。对输入进行零均值化后，恰好为零的输入数量微乎其微，因此不会出现这一问题。然而，这一假设并不会显著影响可实现节省的相对幅度，见图 6。

网络架构

我们使用了一个网络，该网络具有784个输入单元（等于MNIST像素的数量）并带有偏置、单个隐藏层中数量可变的（非卷积）隐藏单元，以及 10 个输出单元（每个数字对应一个）。网络采用全连接的非卷积连接。隐藏层单元使用

带泄漏的线性整流激活函数（lReLU），使得 $g(x) = x$ if $x \geq 0$ and $g(x) = \beta x$ with$\beta = 0.1$。线性整流激活函数 $g(x) = \max(0, x)$ 会导致在给定样本中，隐藏层有相当一部分神经元的激活值为零，并使隐藏层与输出层之间许多突触的可塑性关闭。如上所述，这可能会造成混淆，但使用“泄漏”单元可以避免这一问题。这并未显著改变可实现的节省，见图 6。

训练

十个输出单元的激活值用于训练网络。目标分布是图像标签的独热编码。对于分类任务，通常会应用 softmax 非线性函数 $y_i = \exp(h_i)/\sum_j \exp h_j$，其中 h_i 是每个单元的净输入，从而使输出活动值表示一个归一化概率分布。随后，通过最小化输出分布与目标分布之间的交叉熵损失来训练网络。

然而，很容易看出，当目标是确定性的独热（0 和 1）分布时，交叉熵损失只有在 h_i趋于无穷大时才会趋于零，而这又要求权重趋于无穷大。由于最小化交叉熵损失会降低能量效率，我们采用线性输出单元，并最小化输出与目标之间的均方误差。这并未显著改变可实现的节能效果，见图 6。

我们使用反向传播学习算法训练网络。权重以较小的高斯值初始化（$\sigma = 0.01$）。在初步模拟中，我们发现正则化对能量或节省效果没有显著影响，因此后续未采用。样本以随机顺序呈现。由于批量处理需要跨样本存储突触更新，这在生物学上难以实现，因此训练未采用批量处理，并在每个样本之后更新突触权重。采用 ADAM 等自适应学习方案时，我们未发现显著的能量节省。此外，这类方案在生物学上也难以实现，因此我们改为固定学习率。

每1000个样本训练被中断，并在验证数据集上测量性能。作为性能和计算要求之间的合理折衷，网络总是训练直到达到验证集准确率标准的95%。

估算可塑性所需的能量

我们的方法需要一个关于学习所需代谢能的模型。目前尚不清楚为什么某些形式的可塑性的代谢成本如此之高，也不清楚哪一过程是主要的能量消耗者。在苍蝇中，持久的、依赖蛋白质合成的记忆，其成本远高于不依赖蛋白质合成的记忆形式。人们可能会推测，蛋白质合成本身成本高昂，然而也有观点认为蛋白质合成相对廉价（Karbowski,2019）。毕竟，即使不存在突触可塑性，也会发生大量的蛋白质周转。其他成本高昂的过程可能包括蛋白质向突触的运输、肌动蛋白丝踏车运动和突触发生。此外，可能还存在与单个突触可塑性无关的能量成本，例如重放过程（见讨论）。

我们提出了一个关于突触可塑性代谢能 M 的通用模型，基于以下假设：

1) 虽然众所周知，邻近突触的可塑性之间存在相互作用（例如Harvey 和 Svoboda，2007；Wiegert等人，2018），但我们假设，就突触成本而言不存在空间相互作用。两个突触的增强可能相对更便宜，比

单个突触的增强，例如，当高成本通路可以共享时，如突触标记与捕获中的情况（Frey 和 Morris，1997年；Barrett 等人，2009年；Redondo 和 Morris，2011年）。然而，也可能存在资源竞争（Fonseca 等人，2004年；Sajikumar 等人，2014年；Jeong 等人，2021年），且两个邻近突触的增强可能会带来额外的高成本（Triesch 等人，2018）。一个突触发生增强而另一个突触发生抑制时，两者之间的相互作用可能更加复杂，因为资源可能会被重复利用。总之，协同和竞争性相互作用可能都存在，但由于目前尚无关于其能量学的信息，我们需要忽略它们。这意味着能量是各项单独成本的总和，$M = \sum_i M^{(i)}$，其中 i 对网络中的所有权重求和，而 $M^{(i)}$ 是修改突触 i 所需的能量。

2)关于可塑性之间的时间相互作用，也可以提出类似的论点。同样，关于可塑性诱导和表达中的时间相互作用，已有大量文献（Petersen etal., 1998年；Abraham et al.,2002年；Kramár etal., 2012年）。从能量角度来看，快速连续两次增强一个突触的成本可能更低，但同样也可能成本更高。我们假设突触成本不存在时间相互作用。这意味着总代谢成本是对所有时间步 $M = \sum_t M(t)$ 求和得到的。

3) 接下来，我们假设突触增强和抑制产生相同的成本。由于我们通常关注算法之间的能量节省，这一假设事实证明影响很小。考虑这样一种情况：例如，突触增强消耗能量，而抑制不消耗能量。由于突触在训练期间经历数量相近的增强和抑制事件，这种变体会使成本减半；然而，它并不会实质性地改变可实现的节省，见图 6。

在假设空间和时间独立的情况下，我们仍需要一个表达式来描述修改单个突触所需的成本。我们提出，这一成本按 $|\delta w_i|^\alpha$ 缩放，其中 α 是一个参数。对所有神经元和所有训练时间步求和，得到总能量：

$$M_\alpha = \sum_{i,t} |\delta w_i(t)|^\alpha$$

参数 α 表示权重变化中的比例关系。对于 $\alpha = 1$，能量（M_1）与权重变化量呈线性关系，代表累积的权重变化。例如，这与蛋白质合成所消耗的能量有关，因为较大的变化需要更多蛋白质。α 的值越大，就越可能出现这样一种情况：将一个突触更新两次，比一次更新两倍的量更便宜。这并非不可能，但似乎不太可能。

在极限情况下，$\alpha \to 0$，M_α 统计突触更新的总次数，而不考虑每次更新的幅度。例如，当突触标记设定成本较高时（Barrett 等，2009年），就会出现这种情况。对于数字计算机架构而言，这也是一种合理的成本函数，因为写入记忆的成本与其数值无关。虽然 α 的中间取值以及各项的组合也有可能，我们将重点讨论 M_0 和 M_1。

网络的两层的能量测量值相加。两层的突触数量都与隐藏单元的数量成正比。但根据任务的要求，输入到隐藏层每个隐藏单元有 784 个突触，而隐藏到输出层每个隐藏单元只有 10 个突触。在未修改网络中，输入到隐藏层的可塑性成本因此占总能量的主导地位。

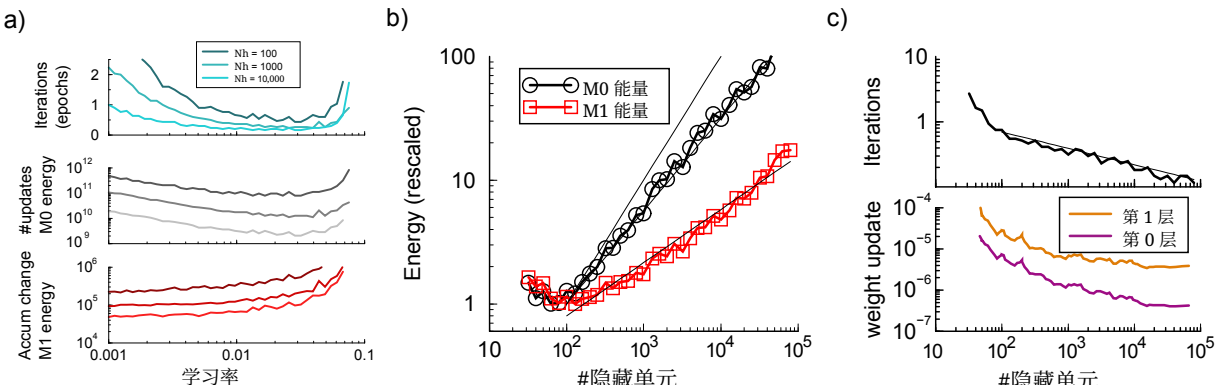


图 1：**训练大型标准反向传播网络的能量需求**。a). 学习率不同的情况下，训练具有 100、1000 或 10000 个隐藏单元的网络所需的能量。上图：达到 95% 准确率所需的迭代次数。中图：当迭代次数最少时，更新总数（M_0 能量）也最少。下图：在学习率趋近于零时，累积变化（M_1 能量）最低。b). 能量度量与网络规模的关系。由于网络只有一个隐藏层，网络规模以隐藏单元数量表示。黑线表示更新次数（M_0），红线表示所有绝对变化之和（M_1）；两者在大型网络中都会增加。纵轴经过缩放，使最小能量为 1。三条细线分别表示斜率为 1 的直线和幂律拟合（见正文）。c). 学习速度和更新大小与网络规模的关系。上图：大型网络达到 95% 准确率标准的速度略快于小型网络。下图：大型网络的平均绝对权重更新较小。

结果

学习的能量

我们首先探究了训练标准大型网络的能量需求。我们比较了包含 100、1000 和 10000 个隐藏单元的网络的训练情况，见图 1a。除了测量达到判定标准性能所需的迭代次数（上图）外，我们还测量了方法部分所述的两种能量变体。突触更新的总次数，称为 M_0，与学习时间成正比。学习率过低，学习就会耗时过长；过高则学习无法收敛。中等的学习率可使学习时间最短，因此也能使 M_0 能量最低，见图 1a 中图。最优学习率在很大程度上独立于网络规模。

累积权重变化称为 M_1 能量，用于度量训练过程中所有突触的绝对权重变化总量，图1a；底部面板。在学习率较小时，这一能量度量最小，并且在该极限下变得与学习率无关。学习率较小时，权重空间中的路径更加谨慎，不会出现较大学习率所伴随的过冲。虽然能量测量 M_0 和 M_1 因此具有不同的最佳学习率，但下文我们采用0.01的学习率作为折中，以便进行直接比较。

大型网络中的学习成本

MNIST分类网络通常具有由数百个单元组成的层。然而，正如生物学中神经元的数量极其庞大一样（见讨论），我们考察了能量消耗作为网络规模函数的变化，如图1b所示。首先考虑更新总数，M_0。由于我们的设置排除了意外地恰好为零的突触更新（见方法），非零更新的数量等于网络中的突触总数乘以迭代次数

T。较大的网络比规模较小的网络学习速度稍快，$T \propto N_h^{-0.249}$，图1c顶部，其中 N_h 表示隐藏层中的单元数量。因此，能量与网络规模呈次线性关系（$M_0 \propto N_h T \propto N_h^{0.75}$）。

累积突触变化能耗 M_1 也会随着网络规模增大而增加，不过增幅较小，见图 1b。尽管学习率固定，较大网络中的单次权重更新幅度更小，见图 1c 下图（参见 Lee 等人，2019）。在大型网络中，单个突触 1）采取的步数更少、步幅更小；2）最终单个权重的范数更小，因为大型网络更大的参数空间允许找到更接近初始权重的解。我们发现，能耗与规模之间近似呈平方根关系，$M_1 \propto N_h^{0.43}$，见图 1b。

随机限制可塑性以节省能量

上述结果表明，尽管大型、过度参数化的网络学习速度稍快，但训练它们要消耗多得多的能量——限制可塑性或许能节省能量。为考察这一点，我们首先只允许随机选取的一部分突触具有可塑性，方法是使用随机二值掩码。掩码元素取自伯努利分布。整个训练过程中掩码保持不变。如果每次试验都使用不同的随机掩码（如 Salvetti et al., 1994），学习只会变慢，而且掩码并不能节省能量；对每个输出类别使用不同的掩码，同样无法节省能量。

使用掩码后，两种能量度量都显著降低，见图 2a 中的绿色曲线。最优掩码密度通过计数论证进行了估计。（我们还对输入层中可塑性突触所占的比例进行了数值优化；结果类似。）上述观察表明，在所有连接都具有可塑性的情况下，要达到判定标准性能，至少需要约 100 个隐藏单元，见图 1b。换言之，任意输入与任意输出之间应有约 $\mu n_{in} n_{out}$ 条可塑性通路，其中 $n_{in} = 28^2$ 是输入的数量，$n_{out} = 10$ 是输出单元的数量，而 $\mu = 100$。现在我们假设这是网络的关键性质。根据超几何分布，在输入层和输出层使用随机掩码会将可塑性通路的平均数量降低至 $\mu = f_0 f_1 N_h$，其中 f_i 表示层 i中可塑性连接所占的比例。

在最优概率下，我们发现不同网络规模和层中的权重变化大致相同。因此，M_0和 M_1能量都与 $m(f_0,\ f_1) = n_{in} N_h f_0 + n_{out} N_h f_1$成正比。我们在满足 $\mu = f_0 f_1 N_h$ 和 $0 \le f_i \le 1$的条件下，将 m 最小化。对于给定的 $\mu \geq N_h$，当 $f_0^* = \frac{\mu}{N_h} \max(1, \sqrt{\frac{N_h n_{out}}{\mu n_{in}}})$ 且 $f_1^* = \min(1, \sqrt{\frac{\mu n_{in}}{N_h n_{out}}})$ 时，能量达到最小，见图 2b。由于输入的数量远远超过输出的数量，因此保留所有隐藏层到输出层的连接为可塑性连接是最优的（$f_1 = 1$）。只有当 $N_h \gtrsim \mu n_{in}^2 / n_{out} \approx 8000$时，保留所有输出连接为可塑性连接才会造成浪费，此时最好也降低可塑性输出突触的比例。能量按以下方式缩放

$$m(f_0^*, f_1^*) = \mu n_{in} \max\left(1, \sqrt{\frac{N_h n_{out}}{\mu n_{in}}}\right) + N_h n_{out} \min\left(1, \sqrt{\frac{\mu n_{in}}{N_h n_{out}}}\right) \tag{1}$$

根据这一估算得出的能量以图 2 中的虚线表示，其比例常数是根据 $N_h = 100$ 处的能量值提取的。在大型网络中，能量会增加，因为并非输入到隐藏层中的每个可塑性连接都对应着隐藏到输出层中的一个可塑性连接。对于大型网络，能量按 $m \propto \sqrt{N_h}$ 的比例增长。

—

一种类似的方法是以每个神经元为基础进行掩码处理，仅允许隐藏层中固定子集的神经元具有可塑性。在实践中，我们将反向传播误差的向量与固定的二值掩码逐元素相乘。针对每种网络规模以及两者，均对掩码密度进行了优化

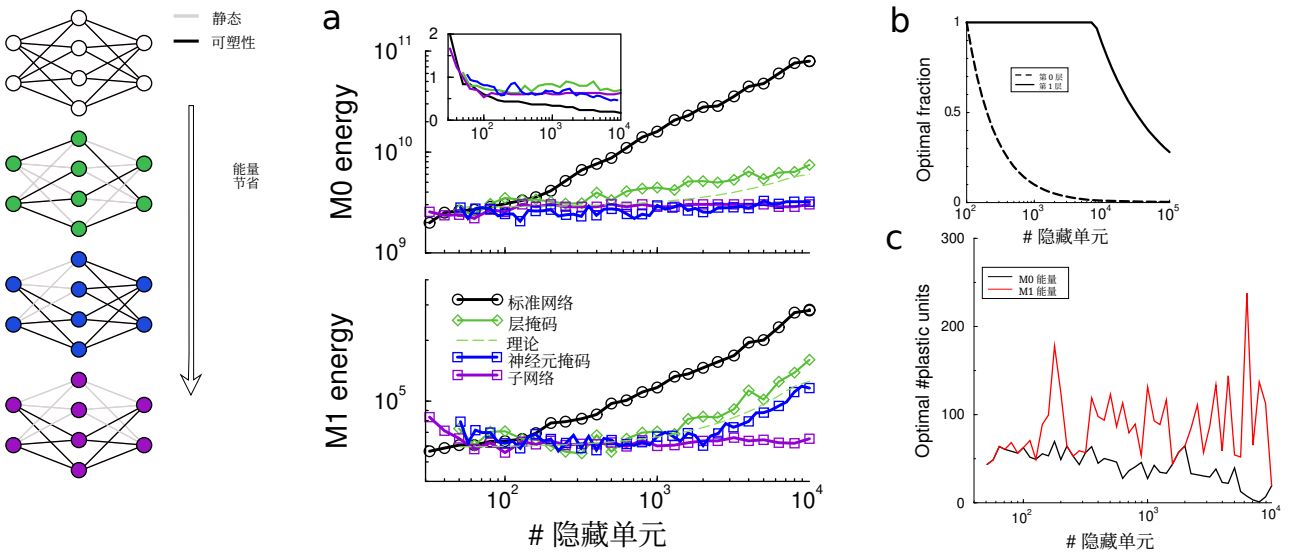


图 2：使用随机掩码限制可塑性可节省能量。
a) 标准网络的 M0能量（更新总数）和 M1能量（累积变化）随网络规模的变化（黑色）。随机突触掩码可以节省能量，但无法防止大型网络中的能量最终增加（绿色；虚线绿色表示理论值）。当只有隐藏层中随机子集的神经元具有可塑性时，还能节省更多能量（蓝色）。当输入可塑性和输出可塑性相协调，使具有可塑性输入的神经元也具有可塑性输出时，节省的能量最多，并且能量与网络规模无关（紫色）。
a-right) 各种掩码设置的示意图。b) 可塑性突触的理论最优数量（用于面板 a 中的绿色曲线）。c) 使用神经元掩码时发现的可塑性神经元最优数量（对应于 a 中的蓝色曲线）。

分别测量能量。该算法节省了略多一些能量，但在大型网络中，输入层和输出层的可塑性之间缺乏协调，再次造成能量浪费，见图2a，蓝色曲线。对于 M_1 能量，隐藏层中可塑性单元的最佳数量约为 50...100，与网络规模无关，见图2c。相比之下， M_0 能量在较少数量的可塑性神经元下达到最小值，更倾向于进行次数更少但规模更大的突触更新。

节能和学习速度之间存在权衡。在不受限制的网络中，训练在大型网络中更快，但不出所料，对于所有掩码变体，训练不再加速，Fig.2a inset。

值得注意的是，对于具有许多隐藏单元的网络（$N_h \gtrsim 5000$），可以固定隐藏层中的所有突触，并将可塑性限制在隐藏层到输出层的突触上，这种方法称为极限学习机（Schmidt 等，1992年；Huang 等，2006年）。然而，隐藏层到输出层突触的可塑性仍需要消耗能量。我们发现，使用随机梯度下降训练时，这种设置并不比本文介绍的方法节省更多能量。此外，它还需要对输入层到隐藏层权重的方差进行精确调节。

可塑性的协调：子网络

与标准反向传播相比，上述算法确实节省了大量能量，但非常大的网络仍然需要更多能量。受掩码算法的启发，我们在神经元的输入和输出之间协调可塑性：当且仅当神经元的输入连接具有可塑性时，其输出连接也具有可塑性。对于大型网络而言，这样可以节省能量，因为这种协调确保了能量

变得与网络规模无关，图2a，紫色图示+曲线。这有一个直接的解释：输入与输出可塑性的协调产生了嵌入更大固定网络中的可塑性子网络。可塑性所需的能量与规模等于该子网络的网络相同，因此静态神经元的存在既不会阻碍也不会促进学习。可塑性子网络的最佳规模在很大程度上取决于所使用的能量度量（对于 M_0约为60，对于 M_1约为100）。从图2a可以推断，使用例如1000个神经元作为子网络并不会显著增加能量。

将可塑性限制在具有大更新的突触上

为了进一步降低能量需求，我们接下来仅修改具有最大幅度更新的突触（Golub et al., 2018）。在呈现训练样本时，通过标准反向传播计算输入到隐藏层中的提议权重更新。然而，仅竞争性地选择并修改具有最大幅度更新（正或负）的突触。隐藏到输出层中的突触始终被更新。所选突触的集合在每次迭代中重新计算。

竞争通过两种方式进行：1）在每个神经元的层面上，使每个神经元中只有一部分突触具有可塑性；2）在整个输入到隐藏层范围内进行。也可以只选择活动值最大的神经元，或反向传播误差最大的神经元，使其具有可塑性突触。这样也能节省能量，但不如按每层的权重更新进行选择所节省的能量多。图 3a 展示了一个包含 1000 个隐藏单元的网络中的节省量。将突触更新限制为梯度最大的突触，尤其能节省 M_0 能量，如图 3a 所示。

我们想知道，这种竞争算法实际上是否与固定掩码的工作方式相同。换句话说，它是否总是选择相同的突触进行更新？为此，我们计算了在整个训练过程中某个给定突触被更新的概率，并提取了逆辛普森指数 $q = 1/[N\sum_i p_i^2]$ (Hill，1973)，其中 p_i 是突触 i的更新概率。当始终更新相同的 k 突触时， $q = k/N$。当更新分布于所有突触时， $q = 1$。我们发现， $q \approx 0.6$ 在训练开始和结束时都是如此，这远大于 $k/N \approx 0.01$。与上文使用的固定掩码不同，在这种算法下，可塑性会持续在不同突触之间切换。

图3b考察了不同网络规模下的节省情况，显示出大量 M_0 但很少 M_1 节省。其原因可从图3c 的示意图中看出。当权重轨迹不发生回溯时（顶行）， M_1 能量，即L1路径长度，与权重轨迹无关。只有当权重路径发生回溯时， M_1 才可以被节省（中行），但即使如此也并不一定能够节省（底行）。

接下来，我们进一步试图通过仅选择子网络中具有最大更新的突触来降低能量需求。这与上述算法相同，但现在仅限于子网络。这进一步降低了能量需求，并再次使其独立于网络规模，图3（紫色曲线）。

总之，当满足以下条件时，可实现最高能效的可塑性：1）对于给定样本，仅实施最大更新；2）这些突触在网络中形成可塑性通路。通过最大值进行竞争性选择相比固定掩码还有另一项优势。固定掩码会限制网络容量，而最大值选择不会。为证明这一点，我们使用了一个小型网络（100 个隐藏单元），并训练了30轮次，此时准确率已经饱和。使用固定掩码时，受限网络的性能会随着掩码大小的增加而下降，如图3d所示。然而，使用任一种竞争性选择机制时，最大准确率的下降幅度要小得多。

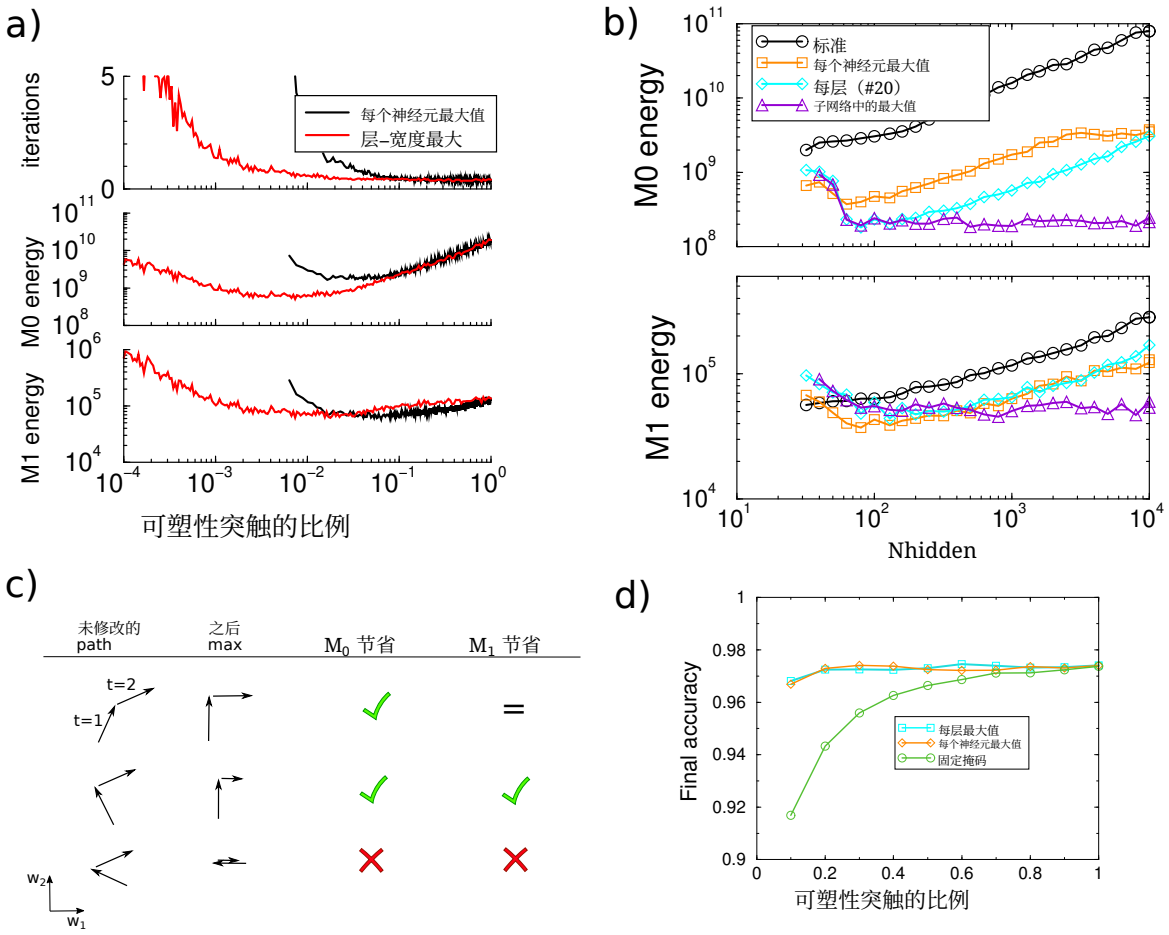


图3：仅修改具有较大更新的突触时，网络训练所需的能量。a）具有1000个隐藏单元的网络中的迭代次数和能量随可塑性突触比例的变化。最大更新是在整层范围内（红色）或针对每个隐藏层单元（黑色）选出的。b）能量需求随网络规模的变化。与更新所有突触的标准网络（黑色曲线）相比，每层仅允许最大突触更新可节省大量能量（青色曲线），每个神经元仅允许最大更新也同样如此（橙色曲线）。针对每种网络规模优化了更新突触的比例。将选择限制在子网络范围内（紫色）还能进一步节省能量，使能量需求不受规模影响。c）三个假设情形中连续两次权重更新的示意图（从上到下）。经过最大值选择后，更新沿坐标轴方向进行。特别是，当权重轨迹没有回到自身（顶部）时，这种选择可节省 M_0 能量，但 M_1 能量保持不变。d）训练至饱和的小型网络（100个隐藏单元）的测试准确率。固定掩码会限制性能，但最大值选择不会。

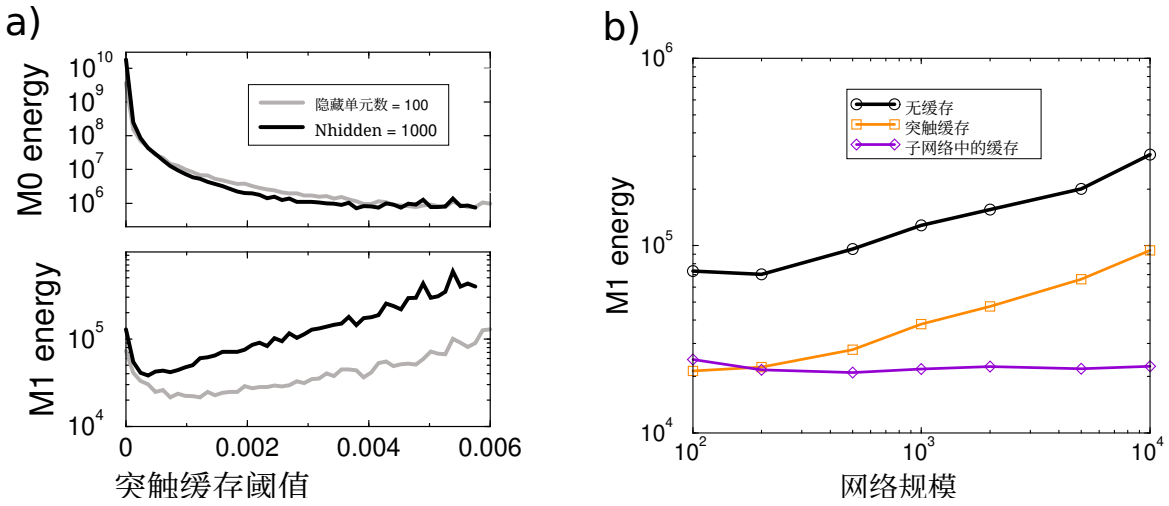


图4：**突触缓存**。 a) 对于包含100和1000个隐藏单元的网络，突触缓存所实现的能量节省。仅统计巩固事件的 M_0 能量在阈值较大时最小，且与网络规模无关。 M_1 能量在瞬态可塑性成本、巩固成本和学习时间之间进行权衡。

b)突触缓存节省 M_1 能量。通过将可塑性限制在子网络中，使 M_1 能量与规模无关。

将掩码与突触缓存相结合

看起来我们似乎已经穷尽了所有节省可塑性能耗的方法，但通过减少试次间的低效可以获得额外节省。在学习过程中，突触权重遵循随机游走，常常部分撤销前一次试次的更新。这是低效的。

另一种节省可塑性所消耗能量的不同方式，利用了并非所有形式的可塑性成本都同样高这一点。突触强度的短暂变化（哺乳动物中的早期相长时程增强、果蝇中的ARM）在代谢上成本较低，而相比之下，永久性变化（哺乳动物中的晚期LTP、果蝇中的长时记忆）成本较高（Mery和 Kawecki，2005年；Plaçais 和 Preat，2013年；Potter等人，2010年）。可以通过先将更新存储在短暂型可塑性中，仅偶尔利用持久可塑性巩固累积变化，来节省代谢成本。我们将这种节省算法称为突触缓存（Li 和VanRossum，2020年）。它与机器学习中的批处理算法有些相似。

通过将可塑性分布在瞬态和持久形式中，突触缓存可以节省能量。节省的量取决于瞬态可塑性相对于样本呈现衰减的速度，以及其可能的代谢成本。当瞬态可塑性没有成本且衰减得足够慢，以至于所有巩固都可以推迟到学习结束时的单一巩固步骤时，可以实现最大的节省。

为探索本研究中引入的算法是否与突触缓存兼容，我们在以 w^{trans} andw^{pers} 编码的网络中实现了瞬态和持久性两种形式的可塑性。神经元之间的总连接强度为 $w^{\text{trans}} + w^{\text{pers}}$。权重的更新首先存储在瞬态组件中。只有当瞬态组件的绝对值达到阈值时，才会将瞬态权重加到持久性权重上，并将瞬态组件重置为零。瞬态权重的衰减率为每次样本呈现 10^{-3}；瞬态可塑性的成本设为 $M_1^{\text{trans}} = c\sum_i |w_i^{\text{trans}}|$，常数为 $c = 0.01$（参见 Li 和

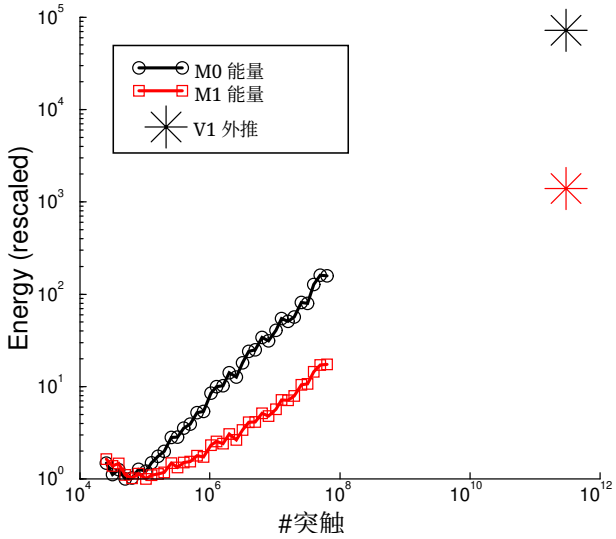


图5：将图 1b的结果外推至猕猴初级视觉皮层中的突触数量。朴素的、不受限制的反向传播学习将使用 $10^5\times$ 更多突触更新，并消耗 $10^3\times$ 更多 M_1 能量，而这些更新和能量是最低要求。

Van Rossum, 2020年 用于动机和进一步参数探索)。

图4 展示了能量测量随巩固阈值变化的情况。突触缓存节省了大量能量。由于瞬态可塑性不计入 M_0能量度量，因此现在它只统计突触巩固事件的数量。在较高的巩固阈值下，该数量最低；在更高的阈值（$\gtrsim 0.06$）下，学习不再收敛。通过限制并推迟巩固，采用突触缓存时的 M_0 能量几乎不受网络规模影响。

然而， M_1 能量仍会随着网络规模的增大而增加，其对网络规模的依赖关系与标准网络相似，见图4b。这仍会导致大型网络产生高昂的成本。协调瞬态可塑性和持久可塑性，即将可塑性限制在子网络中，则再次消除了这种增长。我们还尝试了一种变体，其中瞬态可塑性分布于整个网络中，仅协调巩固过程，但这并未节省能量。

总之，将突触缓存与上述节省策略相结合，可以节省最多的能量。对于M_0 能量而言，突触缓存甚至完全消除了在大型网络中采用额外节省策略的需要。不过，我们强调，突触缓存确实依赖于额外的突触复杂性，即两个突触可塑性组成部分和一种巩固机制。此外，如果瞬态组成部分的更新也会产生 M_0 能量，那么还可能存在其他节省策略。

讨论

实验表明，即使是简单的联想学习也需要付出高昂的代谢成本。对于学习更复杂任务的神经网络而言，能量成本可能会变得非常高，尤其是在网络规模较大时。例如，猕猴初级视觉皮层拥有约1.5亿个神经元和约 300×10^9个突触（Vanni等，2020年）。根据图1进行外推，如果可塑性分布于所有这些突触上，突触更新的数量将约为所需数量的 10^5 倍。 M_1 能量随网络规模增长得不那么陡峭，但仍将高出约700倍，见图5。因此，大型网络功能强大，但如果不加限制，可塑性的代谢成本可能会非常高。

我们介绍了两种降低成本的方法。首先，将可塑性限制在部分突触中。

当神经元输入端和输出端的可塑性相互协调时，效率最高，这样一来，神经元的输入发生改变时，其输出也会随之改变。人们确实观察到了这种效应，尽管其确切规律似乎较为复杂（Fitzsimonds 等，1997；Tao 等，2000；Zhang 等，2021）。

其次，仅在更新幅度较大的突触中表达可塑性。这也与神经科学数据一致，神经科学数据中通常存在可塑性诱导阈值。我们的研究表明，可能存在一种竞争算法，其中只有一定比例的突触会被修改。从生物物理学角度看，神经元层面的竞争可能自然源于资源限制。

这些策略可以与我们早期关于突触缓存的工作相结合。最后，在学习过程中跳过信息量不足的样本也是可行的，从而进一步节省成本（Pache 和 van Rossum，2023年）。

未来的研究可以探讨如何根据任务难度或网络架构自动调整节能算法。另一个有趣的研究方向是寻找迁移学习过程中能量效率最高的突触修改方式（参见 von Oswald 等，2021）。

鉴于缺乏生物学数据以及主要能量消耗主体的不确定性，我们提出的能量模型目前较为粗略。特别是独立性假设不太可能完全正确；甚至相互作用的符号（协同 vs 竞争）也未知。我们假设能量与突触数量成正比。可能存在一个与突触数量无关的较大组成部分，例如重放过程所需的能量。在这种情况下，问题是在多少突触数量时能量变得近似成正比。随着更多实验数据的出现，能量模型可以得到改进，所提出算法的效率也可以重新审视。

最后，我们没有考虑神经信号传递所需的能量，例如突触传递和脉冲产生。最终，学习规则还应旨在降低这些成本。

致谢

谨此感谢 Mikhail Belkin、Simon Laughlin、Thomas Oertner、Aaron Pache、Joao Sacramento、Long Tran-Thanh 和 Silviu Ungureanu参与讨论。本研究获得了英伟达的资助，并使用了 NVIDIA RTX A6000。

参考文献

W. C. Abraham、B. Logan、J. M. Greenwood 和 M. Dragunow。海马体中持续数月的稳定长时程增强的诱导和经验依赖性巩固。《神经科学杂志》，22:9626–9634，2002年。D. Attwell 和 S. B. Laughlin。大脑灰质中信号传导的能量预算。《脑血流与代谢杂志》，21(10):1133–1145，2001。A. B. Barrett、G. O. Billings、R. G. M. Morris 和 M. C. W. van Rossum。长时程增强和突触标记与捕获的基于状态的模型。《公共科学图书馆·计算生物学》，5(1):e1000259，2009年。J. Cichon 和 W.-B. Gan。分支特异性树突 ca-2+尖峰导致持续性突触可塑性。《自然》，520:180–185，2015年。

R. M. Fitzsimonds、H. J. Song 和 M. M. Poo。简单神经网络中活动依赖性突触抑制的传播。《自然》，388:439–448，1997年。R. Fonseca、U. Nägerl、R. Morris 和 T. Bonhoeffer。蛋白质合成减少条件下海马长时程增强的记忆竞争。*Neuron*，44:1011–1020，2004年。U. Frey 和 R. G. Morris。突触标记与长时程增强。《自然》，385(6616):533–536，1997年。M. Girard、J. Jiang 和 M. C. van Rossum。估计长期记忆形成的能量需求。*arxiv*，第 2301.09565 页，2023年。M. Golub、G. Lemieux 和 M. Lis。在剪枝权重预算下进行完整深度神经网络训练。*arXiv preprint arXiv:1806.06949*，2018。D. Grytskyy 和 R. B. Jolivet。前馈神经网络中平衡能量消耗和信息最大化的学习规则，2021。URL https://arxiv.org/abs/2103.06562。S. Han、X. Liu、H. Mao、J. Pu、A. Pedram、M. A. Horowitz 和 W. J. Dally。EIE：压缩深度神经网络上的高效推理引擎。*ACM SIGARCH*《计算机体系结构新闻》，44(3): 243–254，2016。J. J. Harris、R. Jolivet 和 D. Attwell。突触能量使用与供应。*Neuron*，75(5):762–777，2012年。C. D. Harvey 和 K. Svoboda。锥体神经元树突中的局部动态突触学习规则。《自然》，450(7173):1195–1200，2007。M. O. Hill。多样性和均匀度：统一符号及其后果。《生态学》，54:427–432，1973。G. Huang、Q. Zhu 和 C. Siew。极限学习机：理论与应用。《神经计算》，70:489–501，2006年。Y. Jeong、H.-Y. Cho、M. Kim、J.-P. Oh、M. S. Kang、M. Yoo、H.-S. Lee 和 J.-H. Han。突触可塑性依赖性竞争规则影响记忆形成。《自然·通讯》，12: 3915，2021年。J. Karbowski。突触学习和记忆的代谢限制。《神经生理学杂志》，122(4): 1473–1490，2019。S. Klug、G. M. Godbersen、L. Rischka、W. Wadsak、V. Pichler、M. KlÃ¶bl、M. Hacker、R. Lanzenberger 和 A. Hahn。学习诱导代谢需求和功能性脑网络的协调神经元可塑性。《通讯·生物学》，5:428，2022。E. A. Kramár、A. H. Babayan、C. F. Gavin、C. D. Cox、M. Jafari、C. M. Gall、G. Rumbaugh 和 G. Lynch。间隔学习功效的突触证据。《美国国家科学院院刊》，109(13): 5121–5126，2012年。J. Lee、L. Xiao、S. Schoenholz、Y. Bahri、R. Novak、J. Sohl-Dickstein 和 J. Pennington。任意深度的宽神经网络在梯度下降下演变为线性模型。《神经信息处理系统进展》，32，2019。

W. B. Levy 和 R.A. Baxter。《高能效神经编码》。*Neural Computation*，8(3):531–543，1996年。H.Li 和M. C. W. Van Rossum。《高能效突触可塑性》。***eLife***，9:e50804，2020年。F. Mery 和 T. J.Kawecki。《果蝇长期记忆的代价》。《科学》，308(5725):1148，2005年。A. Pache和M. vanRossum。《惰性学习：一种用于快速且高能效突触可塑性的生物启发式可塑性规则》。电子预印本，arXiv:2303.16067，2023年。C. C. H. Petersen、R. C. Malenka、R.A.Nicoll和 J.J. Hopfield。《CA3-CA1突触处的全或无增强》。《美国国家科学院院刊》，95:4732–4737，1998年。P.-Y. Plaçais和T.Preat。《为应对食物短缺以利生存，大脑会禁用高代价记忆》。《科学》，339(6118):440–442，2013年。W. B. Potter、K. J. O'Riordan、D.Barnett、S. M.Osting、M.Wagoner、C.Burger和A.Roopra。《能量传感器AMPK对神经元可塑性的代谢调节》。《公共科学图书馆·综合》，5(2):e8996，2010年。R.L.Redondo和R.G. M. Morris。《让记忆持久：突触标记与捕获假说》。《自然综述：神经科学》，12(1):17–30，2011年。M. S. Rioult-Pedotti、D. Friedman 和 J. P. Donoghue。《新皮层中学习诱导的长时程增强》。《科学》，290(5491):533–536，2000年。J.Sacramento、A.Wichert和 M.C.W. vanRossum。《由不平衡突触可塑性规则产生的高能效稀疏连接》。《公共科学图书馆·计算生物学》，11(6):e1004265，2015年。J. Sacramento、R.P.Costa、Y. Bengio 和 W. Senn。《树突皮层微回路近似反向传播算法》。载于《神经信息处理系统进展》，第8721–8732页，2018。S. Sajikumar、R. G. Morris和M.Korte。《新近增强的突触输入之间的竞争揭示了突触标记与捕获的赢家通吃阶段》。《美国国家科学院院刊》，111(33):12217–12221，2014年。A. Salvetti、B. M.Wilamowski 和C. Dagli。《在反向传播算法中引入随机过程以改善收敛》。载于《工程中的人工神经网络论文集》。ANNIE，1994年。W. F. Schmidt、M. A.Kraaijveld、R. P. Duin 等。《具有随机权重的前馈神经网络》。载于国际模式识别会议，第1–1页。IEEE计算机学会出版社，1992年。E. Sezener、A.Grabska-Barwińska、D. Kostadinov、M.Beau、S. Krishnagopal、D. Budden、M.Hutter、J. Veness、M. Botvinick、C. Clopath 等。《生物神经回路的快速高效学习规则》。***bioRxiv***，第2021–03页，2021年。M. A. Smith、L. M. Riby、J. A.M.vanEekelen和 J.K.Foster。《葡萄糖对人类记忆的增强作用：葡萄糖促进记忆效应的综合研究综述》。《神经科学与生物行为评论》，35(3):770–783，2011年。H. Tao、L.I.Zhang、G.Bi 和M. Poo。《特定神经网络中长时程增强的选择性突触前传播》。《神经科学杂志》，20:3233–3243，2000年。

J.Triesch、A.D.Vo和A.-S. Hafner。对突触构建基元的竞争塑造了突触可塑性。*eLife*，7:e37836，2018。S.Vanni、H. Hokkanen、F. Werner 和A. Angelucci。猕猴视觉皮层区域 V1、V2 和 V5/MT的解剖学与生理学：生物学逼真模型的基础。《大脑皮层》*(*纽约，纽约州：*1991)*，30:3483–3517，2020年。J.von Oswald、D. Zhao、S. Kobayashi、S. Schug、M. Caccia、N.Zucchet 和 J.Sacramento。学习在哪里学习：元学习与持续学习中的梯度稀疏性。*arXiv*，第2110.14402页，2021年。J. S. Wiegert、M.Pulin、C.E.Gee 和 T.G. Oertner。海马突触的命运取决于诱导可塑性的事件序列。***eLife***，7:e39151，2018。T.Zhang、X. Cheng、S.Jia、M.-M. Poo、Y. Zeng和 B. Xu。突触修饰的自反向传播提高了脉冲神经网络和人工神经网络的效率。《科学进展》，7: eabh0146，2021年。

附录

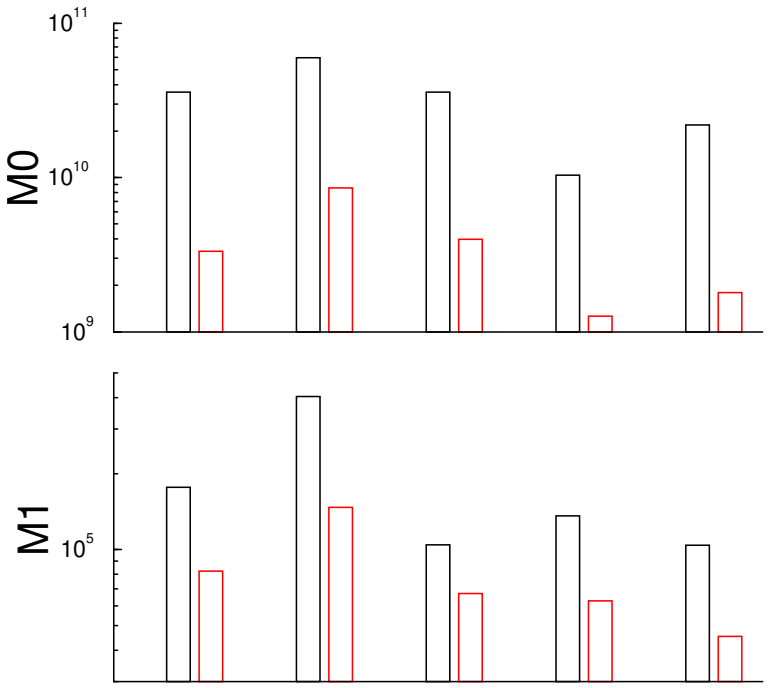


图 6：各种假设对能量的影响。每组柱形图显示了具有 2500 个隐藏单元的网络在可塑性不受约束（黑色）以及使用固定掩码时采用最佳可塑性突触比例（红色）所需的能量。从左到右，**对照：** 与正文相同，用于比较；**交叉熵：** 使用交叉熵损失函数进行训练；**无零均值化：** 数据未经零均值化；**ReLU：** 在隐藏层中使用线性整流（ReLU）单元；**仅计入长时程增强成本：** 只有正向权重变化会消耗能量，负向变化不消耗能量。尽管能量水平有所变化，可实现的节省幅度仍相近。