

超越速率编码：替代梯度使尖峰神经网络中的尖峰时间学习成为可能

Ziqiao Yu¹, Pengfei Sun¹, and Dan F. M. Goodman¹

¹*Department of Electrical and Electronic Engineering, Imperial College London*

摘要

我们研究了使用替代梯度下降 (Surrogate GD) 训练的尖峰神经网络 (SNNs)，在有无延迟学习的情况下，能否从精确的尖峰时间而非仅发火率中学习。我们首先设计了合成任务，以分离出在同一神经元内的尖峰间隔和跨神经元同步性，并且保持匹配的尖峰计数。在一个更复杂的基于尖峰的语音识别数据集 (Spiking Heidelberg Digits (SHD) 和 Spiking Speech Commands (SSC)) 中，我们构建了去除尖峰计数信息而仅保留时间信息的变体，并表明使用替代梯度下降训练的 SNN 能够显著超越随机水平的表现，而纯粹基于速率模型则表现于随机水平。我们进一步评估了受生物启发的扰动下的鲁棒性——包括每个尖峰或每神经元高斯抖动和删除尖峰——揭示了一致但特定于扰动的退化。当时间反转尖峰序列时，网络显示出明显的性能下降，对于使用延迟训练的 SNN 来说，性能下降更大，表明这些网络在行为上更像人类。为了促进对时间编码的进一步研究，我们发布了修改后的 SHD 和 SSC 数据集。

1 介绍

脉冲神经网络 (SNNs) 是通过离散、稀疏的脉冲而非连续激活来计算的生物启发模型 [Maass, 1997]。这种事件驱动框架不仅捕获了丰富的时态模式 (如脉冲间隔 (ISI)、跨神经元同步性、因果脉冲序列 [Bohte, 2004])，还支持节能型神经形态硬件 [Painkras et al., 2013, Akopyan et al., 2015, Davies et al., 2018, Orchard et al., 2021, Su et al., 2024]。

尽管前景看好，但仍存在一个持续的挑战：如何将精确的脉冲时间转换为有效的学习信号。替代梯度下降 (Surrogate GD) 通过用平滑的替代函数替换非可微分的脉冲，从而允许时间反向传播 [Nefci et al., 2019]。后续的工作通过强制稀疏梯度 [Perez-Nieves and Goodman, 2021] 和开发更自适应的替代函数 [Wang et al., 2023] 提高了其效率和适应性。由替代 GD 训练的网络在多个神经形态基准上与基于速率的 RNN 匹敌或优于它们 [Shrestha and Orchard, 2018, Dampfhofer and Mesquida, 2024, Hammouamri et al., 2024, Sun et al., 2025]，但仍不清楚这些成功是源自真正的时序编码还是依赖于粗糙的放电率特征。

为了解决这种模糊性，研究人员引入了各种时间归纳偏置：异质时间常数 [Perez-Nieves et al., 2021, Habashy et al., 2024]；可学习的轴突延迟 [Shrestha et al., 2022, Sun et al., 2022, Patiño-Saucedo et al., 2023]；突触延迟 [Zhang et al., 2020, Yu et al., 2022, Sun et al., 2024, Hammouamri

et al., 2024]; 以及树突延迟模型 [D’ agostino et al., 2024, Zheng et al., 2024]。然而即使有了这些改进，替代 GD 本身可能仍然缺乏捕获精确时机所需的偏置。

这种不确定性导致了一个核心问题：代理 GD 基础的 SNN 能否学习并依赖超越率统计的尖峰时间编码？为了解决这个问题，我们通过多阶段评估来研究这一问题。首先，我们在控制脉冲计数的情况下构建合成基准任务，以分离 ISI 和脉冲同步的贡献，这基于先前的工作，该工作强调了 SNN 利用时间编码进行分类的能力 [Bohte et al., 2002, Mirsadeghi et al., 2021]。然后，我们在具有现实世界时间复杂性的数据集（SHD 和 SSC）上评估模型 [Cramer et al., 2020]，并引入脉冲计数归一化的变体以消除速率混淆因素。最后，我们评估在生物启发的扰动下的鲁棒性——每脉冲、每神经元应用高斯抖动 [Amarasingham et al., 2012, Agmon, 2012]、脉冲删除 [Mainen and Sejnowski, 1995, Chen et al., 2022] 以及时间反转。

我们的研究表明，Surrogate GD 训练的 SNN 可以提取精细的时间结构，即使没有脉冲率信息，包括单神经元 ISI 和跨神经元同步。延迟学习进一步增强了模型利用这些时间特征的能力。在各种扰动下——每脉冲和每神经元高斯抖动以及每脉冲删除——我们观察到不同的退化模式，揭示了模型时间编码中的脆弱性和鲁棒性。值得注意的是，在时间反转的情况下，Surrogate GD 训练的 SNN 不仅利用逆不变特征如 ISI 和巧合，还捕捉到了脉冲时间上的时间依赖关系，表明存在分层的时间表示。

2 替代梯度下降使多样化的尖峰时间编码学习成为可能

在本节中，我们分析了两个合成基准测试，这些测试隔离了特定的时间特征——**神经元内脉冲间隔 (ISI)** 和 **神经元同步**。前向传播使用 Heaviside 脉冲函数，而反向传播则采用平滑替代函数。

$$\frac{\partial H(x)}{\partial x} \approx \frac{1}{(\alpha \cdot |x| + 1)^2}, \quad \alpha = 100, \quad (1)$$

遵循 [Neftci et al., 2019] 提出的一般形式。除非另有说明，否则在整个本工作中的所有 SGD 模型中一致使用。

2.1 代理 GD 成功学习基于 ISI 的时间编码

本实验评估使用替代梯度训练的 SNNs 是否能从精细的脉冲间期 (ISI) 结构中学习。每个样本包含 $N = 10$ 个输入神经元，每个生成具有固定类别特定 $\text{ISI}\delta$ 和放电率 r 的脉冲对。脉冲分布在 $T = 1000$ 毫秒窗口内，并置于非重叠位置。脉冲数量和 ISI 步数通过以下方式计算：

$$\text{Number of spike pairs} = \left\lfloor r \cdot \frac{T}{1000} \right\rfloor, \quad \text{ISI steps} = \max(1, \lfloor \delta \rfloor). \quad (2)$$

该模型由输入层、具有 100 个神经元的尖峰隐藏层和一个共享的学习膜时间常数 τ 组成。该模型是非递归的，分类基于最终时间步长上的输出膜电位使用交叉熵损失进行。

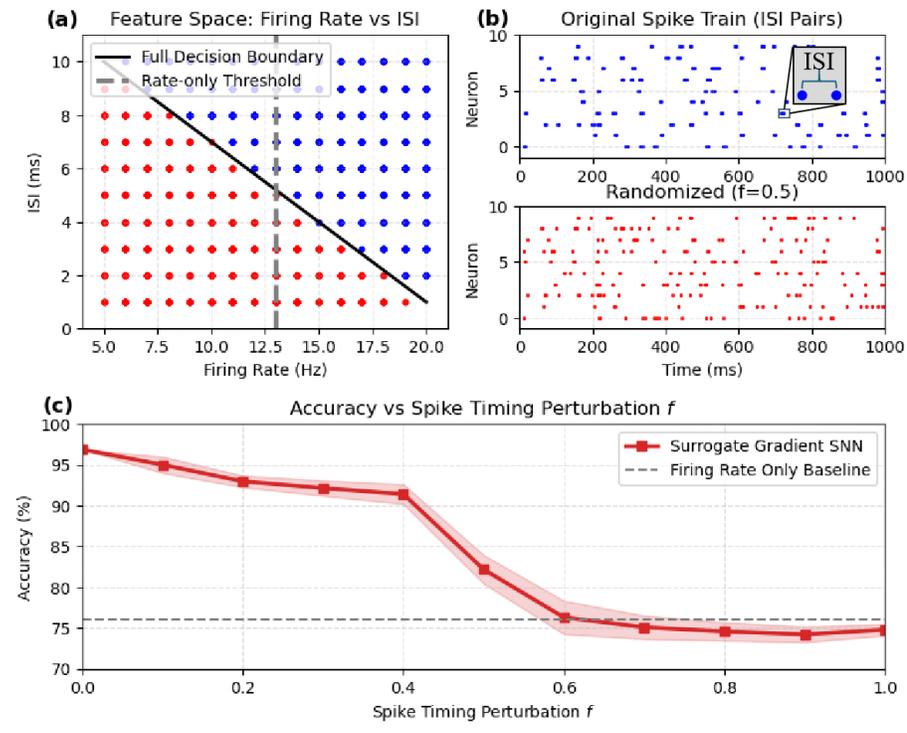


图 1: 基于 ISI 的数据集。(a) 类决策边界在 ISI 速率空间中。水平率截止 (灰色) 仅实现部分分离。(b) 使用固定 ISI 对生成的示例尖峰串 (顶部) 及其随机对应项与 $f = 0.5$ (底部)。(c) 随着增加的尖峰时间扰动 f (随机重绘的尖峰时间的比例), 测试准确率下降。准确率向尖峰计数基线退化为 $f \rightarrow 1$ 。

随机替换。为了模拟定时退化, 在每个神经元的脉冲序列中移除 $f \in [0, 1]$ 的脉冲, 并用 $[0, T)$ 上均匀采样的新脉冲替换:

$$S'_i = (S_i \setminus \mathcal{R}_i) \cup \mathcal{U}_i, \quad |\mathcal{R}_i| = |\mathcal{U}_i| = \lfloor f \cdot |S_i| \rfloor. \quad (3)$$

如图 fig. 1(c) 所示, 在输入条件干净的情况下 ($f = 0$), 该模型达到了约 95% 的准确率, 成功解决了 ISI 分类任务。这证实了替代梯度下降使 SNN 能够从脉冲间隔中提取信息——这是尖峰定时编码的基本形式之一。

随着扰动因子 f 的增加, 尖峰时间信息变得越来越混乱, 导致模型性能下降。对于 $f > 0.5$, 大多数 ISIs 被破坏——因为每个间隔需要一对尖峰——有效地消除了时间线索。然后, 该模型主要依赖于放电率, 准确性收敛到大约 75%。这高于偶然水平 (50%), 但反映了基于速率的区分的极限。

2.2 代理梯度下降成功学习基于巧合的时序编码

本实验评估使用替代梯度下降训练的 SNNs 是否可以根据群体级别的同步模式对输入进行分类。每个样本包含 $N = 60$ 输入神经元, 均匀分为三组。在总时长为 T 的时间内生成非重叠窗口大小为 $w = 10$ 的脉冲, 并限制在一个 5 步的中心子窗口内以引入轻微的时间抖动同时保持

同步。

类别身份由三个组中的哪两个同步放电，而第三个反转来定义。例如，A 类对应于第 1 组和第 2 组之间的同步，第 3 组处于关闭状态。为了消除基于速率的线索，在每个窗口中 ON/OFF 组活动随机切换，并且总尖峰计数在样本之间保持平衡。

形式上，对于每个窗口 w_i ，设 $\mathcal{T}_i = \{t_i + 2, \dots, t_i + 6\}$ 为有效尖峰时间槽。对于每组 g 和类别 c ：

$$k_i^{(g)} \sim P_c(k; \mu_{\text{on/off}}), \quad \text{activate } k_i^{(g)} \text{ neurons in group } g \text{ at times } t \in \mathcal{T}_i. \quad (4)$$

为了控制任务难度，我们通过同步重叠因子 $\lambda \in [0, 1]$ 对 ON/OFF 脉冲计数分布进行插值：

$$\mu_{\text{on}} = (1 - \lambda) \cdot \mu_{\text{on}}^{(0)} + \lambda \cdot \mu_{\text{avg}}, \quad \mu_{\text{off}} = (1 - \lambda) \cdot \mu_{\text{off}}^{(0)} + \lambda \cdot \mu_{\text{avg}}, \quad (5)$$

其中 $\mu_{\text{on}}^{(0)} = 12, \mu_{\text{off}}^{(0)} = 2$ 和 $\mu_{\text{avg}} = 5$ 。随着 λ 的增加，ON 和 OFF 脉冲分布收敛，减少了同步可分辨性（见 fig. 2(a)）。

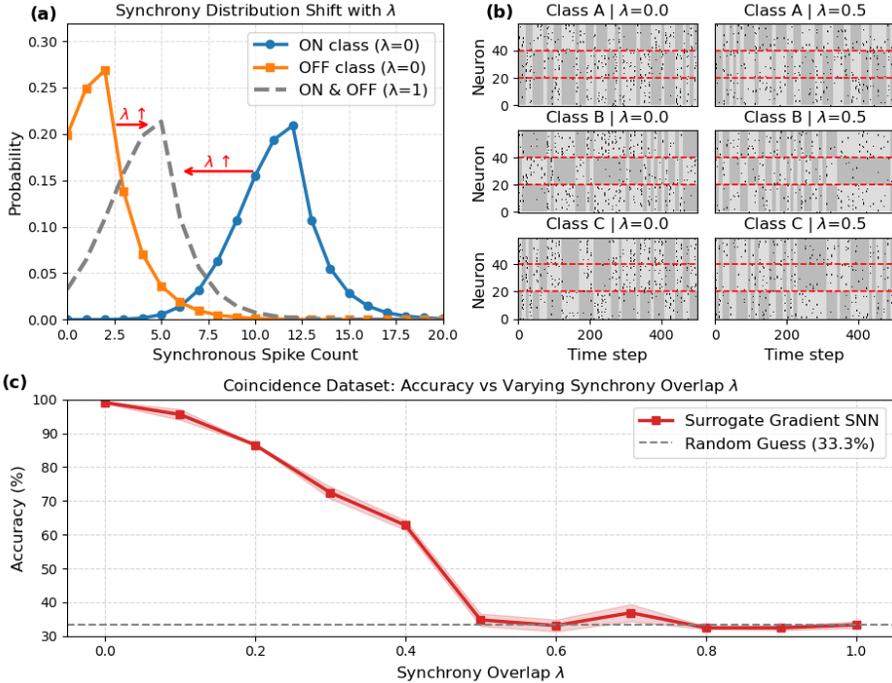


图 2: 基于巧合的数据集。(a) ON/OFF 类别在 $\lambda = 0$ 和 $\lambda = 1$ 处的同步尖峰计数分布。随着 λ 的增加，ON 和 OFF 分布趋于一致。(b) 每个类别在低 ($\lambda = 0$) 和中等 ($\lambda = 0.5$) 同步性下的尖峰光栅图重叠。红线标记组边界。浅灰色和深灰色条带分别表示 ON 和 OFF 神经元组。(c) Surrogate GD 训练的 SNN 在不同同步性重叠水平 λ 下的测试准确性。

我们采用了一个紧凑的架构，其中包括一个 60 神经元的输入层、一个 3 神经元的尖峰隐藏层（每个组一个）和一个 3 神经元的非尖峰输出层。这个最小的隐藏层大小允许直接解释同步模式如何映射到类别标签。分类基于输出层最终膜电位使用交叉熵损失进行。

如 fig. 2(c) 所示，模型在 $\lambda = 0$ 处达到了近乎完美的准确率，表明成功学习了群体级别的尖峰同步。随着 λ 的增加和同步性下降，准确率降低，并趋向于基于速率的基线 33.3%。

3 SHD/SSC 数据集上的尖峰定时学习验证

受我们的合成任务结果启发，结果显示代理 GD 训练的 SNN 可以利用时间信息，我们对更复杂的语音识别数据集进行了评估—SHD 和 SSC，这些数据集表现出显著的脉冲计数偏差，使得 MLPs 能够达到非平凡的准确性。为了隔离真正的基于时间的学习，因此我们构建了两个时间归一化变体（见 fig. 3），这些变体去除了速率信息同时保留了每个样本的时间结构。

3.1 定时归一化 SHD 和 SSC 数据集的构建

尖峰神经网络（SNN）基准测试如 SHD 和 SSC 表现出复杂的时空脉冲模式 [Cramer et al., 2020]。然而，它们的原始版本存在明显的脉冲计数偏差：某些通道的放电频率远高于其他通道，并且总体活动水平在不同类别之间差异显著。因此，即使仅仅基于每个样本的脉冲计数训练的简单多层感知器也能达到非同寻常的准确性（见 fig. 5），这使得很难确定 SNNs 是否真正利用了精确的时间信息还是仅仅是利用了基于速率的线索。

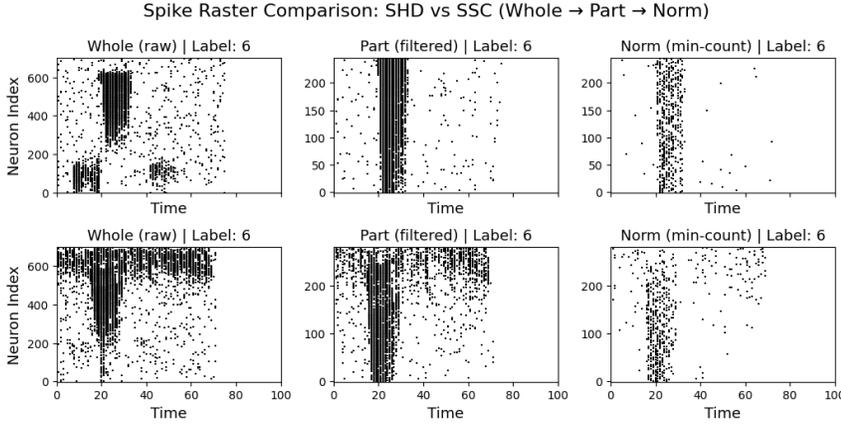


图 3: 示例尖峰光栅图（顶部为 SHD 样本，底部为 SSC 样本）跨越整个 → 部分和 → 范数归一化阶段。神经元选择和尖峰计数归一化逐步去除基于速率的信息，同时保留时间结构。

为了解决这一问题，我们构建了 SHD 和 SSC 数据集的两种时间归一化变体，每种变体都去除了越来越多基于速率的信息。这些变体旨在消除脉冲计数混淆因素同时保留判别性时间结构。归一化过程遵循两阶段策略：

阶段 1：神经元和样本过滤以实现脉冲计数归一化（整个 → 部分）。为了消除基于速率的信息同时保留时间结构，我们旨在对每个神经元在所有样本中的尖峰计数进行归一化。然而，某些神经元在某些样本中发出零个尖峰，使得精确的归一化不可行。

令 $X \in \{0,1\}^{M \times N \times T}$ 表示一个包含 M 个样本、 N 个神经元和 T 个时间步的数据集，其中 $x_{m,i,t} = 1$ 表示在第 m 个样本中，神经元 i 在时间 t 出现了一个脉冲。对于每个神经元 i ，我们计算其在样本中的最小脉冲计数：

$$c_i^{\min} = \min_m \sum_{t=1}^T x_{m,i,t}. \quad (6)$$

具有 $c_i^{\min} < \theta$ (我们使用 $\theta = 2$) 的神经元最初被标记为排除。然而, 在许多情况下, 一个神经元的低 c_i^{\min} 是由少量不活跃样本引起的。为了保留更多神经元, 我们应用了一个额外的样本过滤步骤: 如果一个神经元的低活动影响的样本少于某个阈值比例, 我们就移除那些样本而不是神经元。形式上, 对于每个神经元 i , 我们定义受影响的样本集:

$$\mathcal{M}_i = \left\{ m \mid \sum_{t=1}^T x_{m,i,t} < \theta \right\}, \quad (7)$$

并应用条件

$$\text{if } \frac{|\mathcal{M}_i|}{M} < \epsilon, \text{ then exclude all samples in } \mathcal{M}_i. \quad (8)$$

我们为 SHD 和 SSC 都设定了 $\epsilon = 0.01$, 反映了数据集特定的权衡。这在神经元保留和样本保存之间引入了平衡: 删除更多的样本使我们可以保留更多神经元, 但过度删除会扭曲类别分布。为了缓解这一点, 我们避免将任何类别的大小减少到其原始规模的 50% 以下。例如, 在 SHD 中, 每个类别最初包含大约 500 个样本; 过滤后, 只有第 2 类被减少到 273 个样本, 而像第 19 类这样的类别几乎没有受到影响。此策略显著增加了神经元保留量, 同时为训练保持了足够的每类样本。

过滤后, 我们仅保留每个剩余样本中至少发放 θ 次的神经元, 形成**部分变体** ($N' \ll N$)。为了确保各分类之间的公平比较, 我们将每类随机下采样以匹配最小一类的大小。这一平衡步骤提升了后续实验中准确度指标的可解释性。

第二阶段: 最小计数尖峰标准化 (第 \rightarrow 范数)。为了完全消除脉冲计数信息同时保留脉冲时间, 我们将每个脉冲序列下采样以确保每样本中的每个神经元 i 保持恰好 c_i^{\min} 个脉冲, 其中 c_i^{\min} 是在第一阶段定义的过滤样本中最小的脉冲计数。具体来说, 我们从每个样本中每个神经元的脉冲序列中随机选择 c_i^{\min} 个脉冲时间, 确保整个数据集中每神经元的脉冲计数固定:

$$x_{m,i,t}^{\text{norm}} = \text{Subsample}(\{t \mid x_{m,i,t} = 1\}, c_i^{\min}). \quad (9)$$

这个过程去除了所有基于速率的信息, 同时保留了每个保持下来的脉冲内的精确脉冲时间。然而, 这可能会扭曲全局的时间模式, 如脉冲间期 (ISIs) 或神经元之间的同步性, 具体取决于哪些脉冲被保留下来。生成的**范数**数据集保留了 Part 变体的形状, 并作为基于尖峰定时学习的严格测试。

3.2 替代梯度下降使 SNN 能够利用真实数据集中的脉冲时间

在这项工作中, 所有实验都在 SLAYER 框架 [Shrestha and Orchard, 2018] 内进行, 比较了一个基于替代梯度下降 (SGD) 训练的前馈 SNN 基线和一个集成可学习轴突延迟 (SGD-延迟) 的增强变体 [Sun et al., 2023]。

两种架构如 fig. 4 所示。两个模型均采用两层 SNN, 每层包含 128 个神经元, 并使用 Spikemax 损失函数进行训练 [Shrestha et al., 2022]。在 SGD-延迟模型中, 轴突延迟不受限, 允许它们在训练过程中自由适应数据。

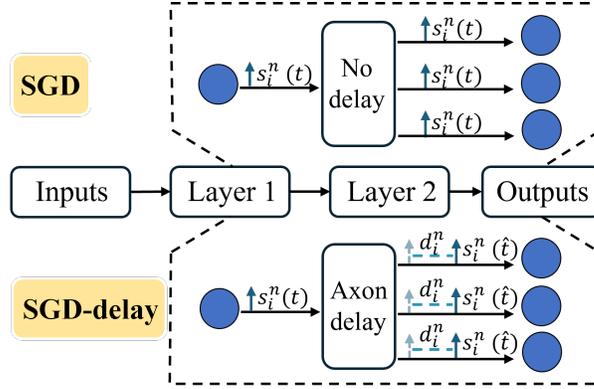


图 4: 使用 SGD 和 SGD 延迟训练的 SNN 架构比较。顶部一行显示了一个没有延迟组件的模型。底部一行在层之间插入了可学习的轴突延迟。

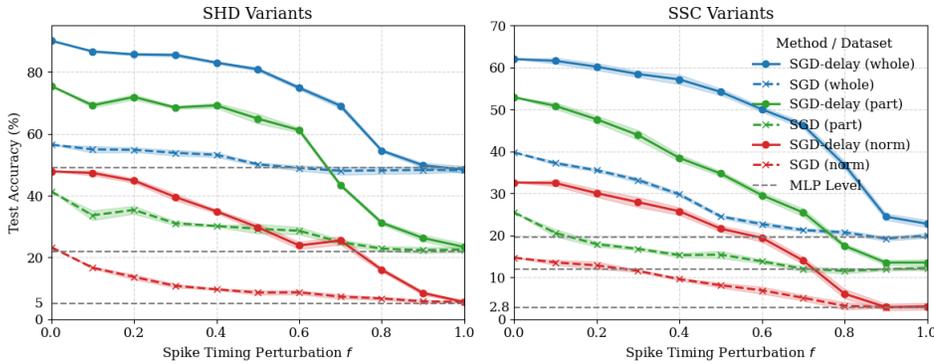


图 5: 尖峰时间扰动 f 在 SHD (左) 和 SSC (右) 数据集上的测试准确率。蓝色: 整体; 绿色: 部分; 红色: 规范。对于规范变体, 完全移除了尖峰计数信息, 因此 MLP 准确率对应于机会水平 (SHD 为 5%, SSC 为 2.8%)。

我们将 SGD 和 SGD-delay 训练方法在 SHD 和 SSC 数据集上进行比较, 以评估它们从尖峰序列中提取时间信息的能力。两种方法都应用于三个数据集变体 (整体、部分、归一化), 其中范数变体消除了样本之间的尖峰计数差异, 将尖峰时机作为唯一的有用线索。

如图 5 所示, SGD 和 SGD-delay 训练的 SNN 都优于 MLP 基线模型 (红色虚线), 这表明它们能够仅从脉冲时间中提取信息。这证实了基于替代梯度的学习不仅限于学习速率相关的特征, 实际上可以从精确的脉冲时间中学习, 即使没有明确的时间延迟建模。

值得注意的是, SGD-delay 在两个数据集上始终比 SGD 达到更高的准确率。例如, 在 SHD-norm 的 $f = 0$ 处, SGD 实现 23.32%, 而 SGD-delay 达到 47.86%; 在 SSC-norm 中, 得分分别为 14.69% 和 32.60%。这些范数结果作为仅基于尖峰时间的基线, 并突显了延迟学习的优势。改进反映了可学习的延迟模块能够实现更准确的时间信用分配并引入更强的向尖峰时间偏置——同时只增加极少量参数: SGD 模型有 mn 个参数, 而 SGD-delay 仅添加了 n 个额外的延迟项, 其中 m 和 n 是输入和隐藏维度。

在 SHD 和 SSC 数据集上, 我们观察到 SGD 延迟性能的一个共同趋势: 随着 f 的增加, 准确率下降急剧加速——这表明对高保真脉冲时间有很强的依赖性。大约在 $f=0.8$ 处, 曲线迅速降

至对应的 MLP 基线水平，之后衰减趋于平稳。这种饱和行为表明，一旦脉冲时间被破坏到无法使用，SGD 延迟就会过渡到类似速率的机制，收敛至 MLP 性能（对于范数变体来说是随机水平）。

4 通过替代梯度下降训练的 SNNs 对时间结构和反转敏感

4.1 时间扰动诱导独特但可预测的退化

为进一步评估用替代梯度训练的 SNNs 的时间敏感性，我们超越了早期章节中使用的随机脉冲替换（见 eq. (2)），并系统设计了三种受生物启发的时间扭曲：单个脉冲和每个神经元的抖动，以及单个脉冲删除。这些扰动针对基于脉冲编码的不同方面，并使我们能够评估每种类型的时间中断如何影响分类性能。

(a) 每个尖峰的抖动。此扰动通过向单个尖峰时间添加均值为零的高斯噪声来模拟突触噪声，破坏了尖峰间间隔 (ISIs) 和跨神经元同步性，同时保持了尖峰计数：

$$t'_{i,j} = \text{clip}(t_{i,j} + \delta_{i,j}, 0, T), \quad (10)$$

其中 $\delta_{i,j} \sim \mathcal{N}(0, \sigma^2)$ 和 $\text{clip}(\cdot)$ 确保尖峰保持在范围内。

(b) 每个神经元的抖动。我们将一个恒定的高斯时间偏移应用于神经元发出的所有尖峰，保持单个神经元内的 ISI 结构同时破坏神经元间的精确尖峰时间对齐：

$$t'_{i,j} = \text{clip}(t_{i,j} + \Delta_i, 0, T), \quad (11)$$

其中 $\Delta_i \sim \mathcal{N}(0, \sigma_N^2)$ 。这种扰动测试了模型在解码过程中对跨神经元同步的依赖性。

(c) 每个脉冲删除。每个尖峰以概率 p_d 独立删除：

$$\mathbb{P}[\text{delete } t_{i,j}] = p_d. \quad (12)$$

这种失真通过减少时间线索的数量和精度来降低所有基于时间的表示，包括 ISIs、同步性和速率。它作为在严重信息丢失情况下模型鲁棒性的一个强大测试。

我们在所有三种 SHD 变体（整体、部分和规范）上评估了这些扰动下的模型鲁棒性（参见 fig. 6）。首先，我们比较了在高噪声水平下每个脉冲与每个神经元的抖动（ $\sigma = \sigma_N = 25$ 毫秒）。尽管使用相同的高斯扰动原理，粒度差异导致不同的结果：在 fig. 6(a) 中，每个脉冲抖动下的模型仍比 MLP 基线高出超过 10% 的准确性，而在 fig. 6(b) 中，每个神经元抖动将性能降到了 MLP 水平。这表明每个脉冲抖动保留了更多的有用时间信息。关键区别在于扰动范围：每个脉冲抖动独立影响每个脉冲，允许某些定时提示得以幸存，而每个神经元抖动则均匀移动所有脉冲，消除了跨神经元的相对脉冲时间，并更严重地破坏了跨神经元同步。

尽管逐神经元抖动在设计上保留了单个神经元的 ISI，但在所有数据集变体（整体、部分、标准化）中的表现始终劣于逐脉冲抖动，这表明 ISI 本身并非主导分类的唯一时间特征。相反，精细的跨神经元时序似乎对模型性能更为关键。

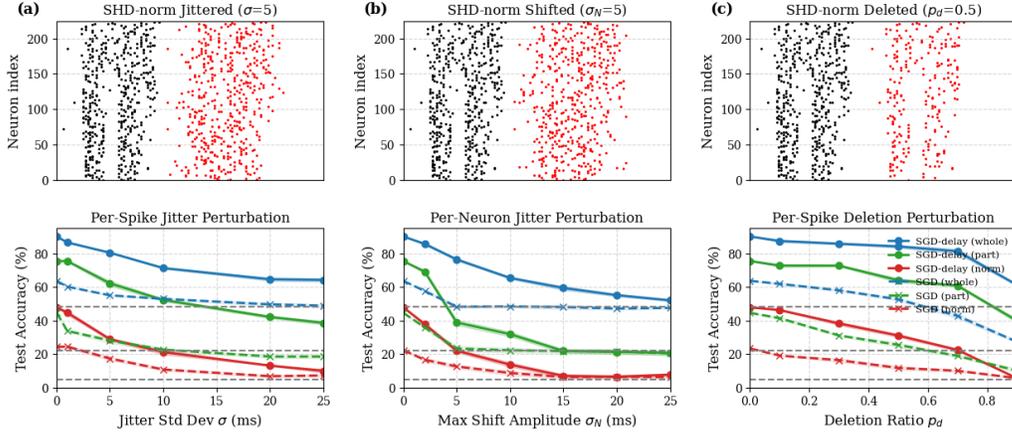


图 6: SNN 在时间扰动下的性能: (a) 每个脉冲抖动, (b) 每个神经元抖动, (c) 每个脉冲删除。顶部: 特定 SHD-norm 样本在扰动前 (黑色) 和扰动后 (红色) 的脉冲光栅图。底部: 使用带有和不带延迟学习的 SGD, 在三种数据集变体 (Whole, Part, Norm) 上的测试精度。

相比之下, fig. 6(c) 表明逐个尖峰删除会破坏尖峰时间和数量。随着删除概率的增加, 在整个和部分数据集上训练的模型性能下降至低于 MLP 基线, 表明包括尖峰冗余和计数在内的关键信息丢失了。对于已经进行了计数归一化的范数数据集, 删除导致性能接近随机水平。

总体而言, 代理训练的 SNN 在时间扰动下表现出一致的退化趋势, 但其脆弱性强烈依赖于扭曲类型。细粒度抖动比粗粒度神经元级移位保留了更多信息, 而删除通过直接移除尖峰证明是最具破坏性的。

4.2 易受时间逆转影响如同人类

人类对感官输入的因果结构非常敏感——例如, 倒放的语音变得无法理解 [Saber and Perrott, 1999]。为了考察 SNNs 是否表现出类似的时序敏感性, 我们在其活跃时间窗口内反转脉冲串进行了时间反演实验。

给定输入 $x \in \{0, 1\}^{N \times T}$, 我们确定包含所有尖峰的最小区间:

$$[t_{\text{start}}, t_{\text{end}}] = [\min\{t \mid x_{i,t} = 1\}, \max\{t \mid x_{i,t} = 1\}], \quad (13)$$

并在该区间内反转每个神经元的尖峰序列:

$$x'_{i,t} = x_{i,t_{\text{start}}+t_{\text{end}}-t}, \quad \forall t \in [t_{\text{start}}, t_{\text{end}}], \quad (14)$$

保持尖峰数量和神经元身份不变, 但颠倒时间顺序。

我们评估预训练的代理梯度模型在时间反转 SHD 变体上的性能, 以评估其对反转时间结构的敏感性。无需重新训练, 我们将通过应用转换 eq. (14) 来测试零样本泛化到时间倒置输入的能力。此外, 我们引入不同水平的随机扰动 f , 以检查噪声是否可以减轻反转的影响。

Figure 7 揭示了在代理训练的 SNN 中, 由反转引起的脆弱性和反转不变的鲁棒性。对于全部数据集, 在 $f=0$ 处准确率最低, 无论是 fig. 7(b) 和 (c), 精确但反转了的尖峰时间强烈误导

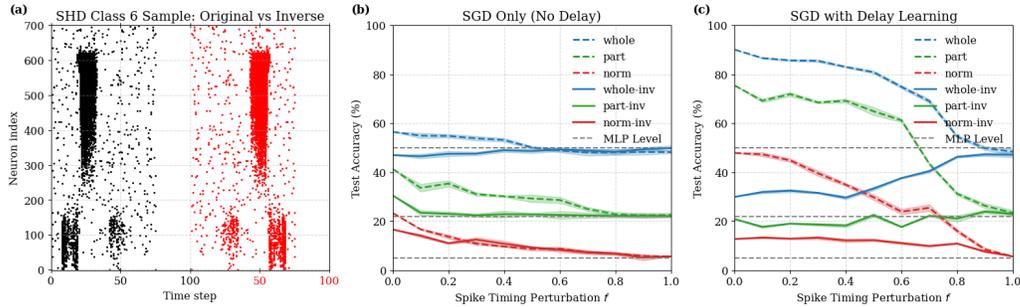


图 7: 脉冲时间扰动下 f 的原始和时间反转 SHD 变体的测试精度。(a) 单一样本在时间反演前后的脉冲光栅图。(b) 使用 SGD 训练的模型的结果。(c) 使用 SGD-delay 训练的模型的结果。每条曲线对应于原始形式和倒置形式中的**整个**、**部分**或**范数**数据集之一。

模型——尤其是 SGD-delay，它学习更丰富的时序依赖关系。随着 f 的增加和尖峰时间变得越来越随机化，这种误导结构被削弱，并且准确率逐渐恢复。这表明时序噪声抑制有害模式并使模型从依赖尖峰时间转移到依赖尖峰计数。

相比之下，对于**范数逆**数据集，两组中的 SGD 训练的 SNNs 的准确率均超过了 MLP 基线，在 $f = 0$ 处。这表明 SGD 使模型能够学习突触时间特征——例如脉冲间隔 (ISIs) 或跨神经元同步性——即使输入的时间顺序被反转，这些特征仍然具有信息量。

有趣的是，对于 SGD 和延迟训练的模型而言，反变体相对于 MLP 基准表现出一种进步趋势：**全部-逆**的表现低于 MLP 水平，**部分-逆**保持接近 MLP，而**范数逆**达到了超过 MLP 的准确率。这种单调变化表明，**整个**数据集包含大量的尖峰时间信息，这些信息对时间反转敏感，在时间顺序被倒置时误导模型。当我们从**整个**移动到**部分**再到**范数**时，许多这些脆弱的时间特征逐渐被过滤掉。

这些发现表明，通过替代梯度下降训练的 SNNs 表现出与人类类似的对时间因果关系的敏感性：当输入遵循自然的时间顺序时表现良好，但在反转情况下则会出现错误——这反映了众所周知的现象，即时间倒置的感觉输入（例如语音）往往对人类来说是无法理解的。

5 讨论

替代梯度下降及相关方法 [Neftci et al., 2019, Shrestha and Orchard, 2018] 已经证明在训练非可微尖峰神经网络以完成具有挑战性的任务方面表现出色。然而，问题仍然存在：使用这些算法找到的解决方案是否涵盖了尖峰神经网络的所有能力范围，或者它们是否偏向于特定子类别的解决方案。在这两种情况下，所找到的解决方案是否类似于生物神经网络会学习的内容？我们特别解决了关于动作电位的时间而非速率可以被利用到何种程度的问题。

原则上，基于时间的编码可以比基于速率的编码高效得多。假设尖峰时间精确到 1 毫秒以内且没有对放电率的限制，那么在一个 k 毫秒的时间窗口内，尖峰计数可以编码 $k + 1$ 个不同的值，而使用尖峰时间我们可以编码 2^k 个值。实际上，神经噪声的存在和完全解码可能的全部时间代码范围的困难将限制这一点。尖峰时间的一些无疑能够稳健解码的方面包括：尖峰间隔（两

次尖峰之间的时间)、跨神经元同时性, 以及至少一些更复杂的空间-时间尖峰模式。在我们的结果中, 我们展示了基于代理梯度下降的方法可以利用这些定时编码的所有方面提取信息, 无论是受控合成数据集还是基于记录语音的较为混乱的数据集。此外, 在各种形式的尖峰时间扰动下, 它们在大多数情况下都能优雅地降级。

特别是, 我们研究了 Spiking Heidelberg Digits 和 Spiking Speech Commands 数据集 (SHD, SSC)。这些数据集已经成为尖峰神经网络和神经形态计算领域广泛使用的基准。我们发现这些数据集中确实包含大量可利用的时间信息, 但仅使用脉冲计数或经过各种类型的脉冲时间扰动后进行分类也非常准确。因此, 如果希望探究不同的基于脉冲的模型能多大程度上利用时间信息, 这个数据集可能不是理想的。我们构建了一个衍生数据集 (SHD-norm), 通过构造消除了所有脉冲计数信息。(注意虽然剩下的唯一信息是时间性的, 但所应用的转换也很可能会移除大量的时间信息。) 我们公开发布了该数据集以促进对尖峰神经网络中基于时间计算的研究。

最后, 我们解决了这些算法是否能找到在生物学上可行的解决方案的问题, 通过考虑当在一个声音集上训练网络, 然后通过对那些声音进行反转来测试它会发生什么。由于人类在这项任务中表现不佳, 我们可以预期以与人类更相似的方式学习的模型也会表现不佳。我们发现具有延迟和没有延迟的脉冲神经网络都受到时间反转的影响, 但带有延迟的网络受影响的程度要大得多。这表明带有延迟的网络可能在生物学上更为相关, 至少在建模听觉系统的情况下是如此, 在这种情况下我们知道时序信息很重要。

在未来的工作中, 研究基于尖峰定时的编码的其他方面将是很有趣的, 例如时间顺序 (A 在 B 之前放电), 或者对可以学习的空间-时间尖峰模式进行更细致的分析。设计进一步的数据集, 在这些数据集中时间信息比基于速率的信息重要得多, 也会很有趣。

数据和代码

所有代码均可在 GitHub 仓库中获得:<https://github.com/neural-reckoning/temporal-shd>。数据集已归档于 Zenodo[Yu et al., 2025] (<https://doi.org/10.5281/zenodo.16153275>)。

致谢

该项目部分由高级研究+发明机构 (ARIA) 资助。

参考文献

- Wolfgang Maass. Networks of spiking neurons: the third generation of neural network models. *Neural networks*, 10(9):1659–1671, 1997.
- Sander M Bohte. The evidence for neural information processing with precise spike-times: A survey. *Natural Computing*, 3(2):195–206, 2004.

- Eustace Painkras, Luis A Plana, Jim Garside, Steve Temple, Francesco Galluppi, Cameron Patterson, David R Lester, Andrew D Brown, and Steve B Furber. Spinnaker: A 1-w 18-core system-on-chip for massively-parallel neural network simulation. *IEEE Journal of Solid-State Circuits*, 48(8):1943–1953, 2013.
- Filipp Akopyan, Jun Sawada, Andrew Cassidy, Rodrigo Alvarez-Icaza, John Arthur, Paul Merolla, Nabil Imam, Yutaka Nakamura, Pallab Datta, Gi-Joon Nam, et al. Truenorth: Design and tool flow of a 65 mw 1 million neuron programmable neurosynaptic chip. *IEEE transactions on computer-aided design of integrated circuits and systems*, 34(10):1537–1557, 2015.
- Mike Davies, Narayan Srinivasa, Tsung-Han Lin, Gautham China, Yongqiang Cao, Sri Harsha Choday, Georgios Dimou, Prasad Joshi, Nabil Imam, Shweta Jain, et al. Loihi: A neuromorphic manycore processor with on-chip learning. *Ieee Micro*, 38(1):82–99, 2018.
- Garrick Orchard, E Paxon Frady, Daniel Ben Dayan Rubin, Sophia Sanborn, Sumit Bam Shrestha, Friedrich T Sommer, and Mike Davies. Efficient neuromorphic signal processing with loihi 2. In *2021 IEEE Workshop on Signal Processing Systems (SiPS)*, pages 254–259. IEEE, 2021.
- Zhe Su, Simone Ramini, Demetra Coffen Marcolin, Alessandro Veronesi, Milos Krstic, Giacomo Indiveri, Davide Bertozzi, and Steven M Nowick. An ultra-low cost and multicast-enabled asynchronous noc for neuromorphic edge computing. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 2024.
- Emre O Neftci, Hesham Mostafa, and Friedemann Zenke. Surrogate gradient learning in spiking neural networks: Bringing the power of gradient-based optimization to spiking neural networks. *IEEE Signal Processing Magazine*, 36(6):51–63, 2019.
- Nicolas Perez-Nieves and Dan Goodman. Sparse spiking gradient descent. *Advances in Neural Information Processing Systems*, 34:11795–11808, 2021.
- Ziming Wang, Runhao Jiang, Shuang Lian, Rui Yan, and Huajin Tang. Adaptive smoothing gradient learning for spiking neural networks. In *International conference on machine learning*, pages 35798–35816. PMLR, 2023.
- Sumit B Shrestha and Garrick Orchard. Slayer: Spike layer error reassignment in time. *Advances in neural information processing systems*, 31, 2018.
- Manon Dampfhofer and Thomas Mesquida. Neuromorphic lip-reading with signed spiking gated recurrent units. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 2141–2151, 2024.
- Ilyass Hammouamri, Ismail Khalfaoui Hassani, and Timothée Masquelier. Learning delays in spiking neural networks using dilated convolutions with learnable spacings. In *ICLR*, 2024.

- Pengfei Sun, Jibin Wu, Paul Devos, and Dick Botteldooren. Towards parameter-free attentional spiking neural networks. *Neural Networks*, 185:107154, 2025.
- Nicolas Perez-Nieves, Vincent CH Leung, Pier Luigi Dragotti, and Dan FM Goodman. Neural heterogeneity promotes robust learning. *Nature communications*, 12(1):5791, 2021.
- Karim G Habashy, Benjamin D Evans, Dan FM Goodman, and Jeffrey S Bowers. Adapting to time: Why nature may have evolved a diverse set of neurons. *PLOS Computational Biology*, 20(12):e1012673, 2024.
- Sumit Bam Shrestha, Longwei Zhu, and Pengfei Sun. Spikemax: spike-based loss methods for classification. In *2022 international joint conference on neural networks (IJCNN)*, pages 1–7. IEEE, 2022.
- Pengfei Sun, Longwei Zhu, and Dick Botteldooren. Axonal delay as a short-term memory for feed forward deep spiking neural networks. In *ICASSP 2022-2022 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, pages 8932–8936. IEEE, 2022.
- Alberto Patiño-Saucedo, Amirreza Yousefzadeh, Guangzhi Tang, Federico Corradi, Bernabé Linares-Barranco, and Manolis Sifalakis. Empirical study on the efficiency of spiking neural networks with axonal delays, and algorithm-hardware benchmarking. In *2023 IEEE International Symposium on Circuits and Systems (ISCAS)*, pages 1–5, 2023. doi:[10.1109/IS-CAS46773.2023.10181778](https://doi.org/10.1109/IS-CAS46773.2023.10181778).
- Malu Zhang, Jibin Wu, Ammar Belatreche, Zihan Pan, Xiurui Xie, Yansong Chua, Guoqi Li, Hong Qu, and Haizhou Li. Supervised learning in spiking neural networks with synaptic delay-weight plasticity. *Neurocomputing*, 409:103–118, 2020.
- Qiang Yu, Jialu Gao, Jianguo Wei, Jing Li, Kay Chen Tan, and Tiejun Huang. Improving multispike learning with plastic synaptic delays. *IEEE Transactions on Neural Networks and Learning Systems*, 34(12):10254–10265, 2022.
- Pengfei Sun, Jibin Wu, Malu Zhang, Paul Devos, and Dick Botteldooren. Delay learning based on temporal coding in spiking neural networks. *Neural Networks*, 180:106678, 2024.
- Simone D’agostino, Filippo Moro, Tristan Torchet, Yiğit Demirağ, Laurent Grenouillet, Niccolò Castellani, Giacomo Indiveri, Elisa Vianello, and Melika Payvand. Denram: neuromorphic dendritic architecture with rram for efficient temporal processing with delays. *Nature communications*, 15(1):3446, 2024.
- Hanle Zheng, Zhong Zheng, Rui Hu, Bo Xiao, Yujie Wu, Fangwen Yu, Xue Liu, Guoqi Li, and Lei Deng. Temporal dendritic heterogeneity incorporated with spiking neural networks for learning multi-timescale dynamics. *Nature Communications*, 15(1):277, 2024.
- Sander M Bohte, Joost N Kok, and Han La Poutre. Error-backpropagation in temporally encoded networks of spiking neurons. *Neurocomputing*, 48(1-4):17–37, 2002.

- Maryam Mirsadeghi, Majid Shalchian, Saeed Reza Kheradpisheh, and Timothée Masquelier. Stidi-bp: Spike time displacement based error backpropagation in multilayer spiking neural networks. *Neurocomputing*, 427:131–140, 2021.
- Benjamin Cramer, Yannik Stradmann, Johannes Schemmel, and Friedemann Zenke. The heidelberg spiking data sets for the systematic evaluation of spiking neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, 33(7):2744–2757, 2020.
- Asohan Amarasingham, Matthew T Harrison, Nicholas G Hatsopoulos, and Stuart Geman. Conditional modeling and the jitter method of spike resampling. *Journal of neurophysiology*, 107(2):517–531, 2012.
- Ariel Agmon. A novel, jitter-based method for detecting and measuring spike synchrony and quantifying temporal firing precision. *Neural systems & circuits*, 2(1):5, 2012.
- Zachary F Mainen and Terrence J Sejnowski. Reliability of spike timing in neocortical neurons. *Science*, 268(5216):1503–1506, 1995.
- Junren Chen, Chenxi Wu, Giacomo Indiveri, and Melika Payvand. Reliability analysis of memristor crossbar routers: collisions and on/off ratio requirement. In *2022 29th IEEE International Conference on Electronics, Circuits and Systems (ICECS)*, pages 1–4. IEEE, 2022.
- Pengfei Sun, Yansong Chua, Paul Devos, and Dick Botteldooren. Learnable axonal delay in spiking neural networks improves spoken word recognition. *Frontiers in Neuroscience*, 17:1275944, 2023.
- Kouros Saberi and David R Perrott. Cognitive restoration of reversed speech. *Nature*, 398(6730):760–760, 1999.
- Ziqiao Yu, Pengfei Sun, and Dan Goodman. Temporalshd, July 2025. URL <https://doi.org/10.5281/zenodo.16153275>.