少量神经元条件下神经形态关键词检测时间编码器的比较

Mattias Nilsson*、Ton Juny Pina†‡、Lyes Khacef†‡、Foteini Liwicki*、Elisabetta Chicca†‡和Fredrik Sandin*
*嵌入式智能系统实验室（*EISLAB*），吕勒奥理工大学，瑞典吕勒奥 *971 87*mattias.k.nilsson@proton.me

†仿生电路与系统（*BICS*）实验室，泽尔尼克先进材料研究所，格罗宁根大学，荷兰格罗宁根 *9747 AG*

‡格罗宁根认知系统与材料中心（*CogniGron*），格罗宁根大学，荷兰格罗宁根 *9747 AG*t.juny.pina@rug.nl

arXiv:2301.09962v1 [cs.NE] 24 Jan 2023

摘要——**随着人工智能虚拟助手的普及，人们需要低功耗关键词检测系统，为后续计算量较大的语音识别提供“唤醒”机制。一种颇具前景的方法是利用神经形态传感器和部署于神经形态处理器上的脉冲神经网络（SNN），实现稀疏事件驱动感知。然而，这要求脉冲神经网络具备资源高效的时间编码机制，并考虑到此类系统以流式方式处理信息，且物理时间是其运行的内在属性。本研究针对近期文献所述的两种可用于脉冲神经网络时间编码和特征提取的候选神经计算元件——脉冲时间差编码器（TDE）和双突触兴奋性–抑制性（E–I）元件——进行了比较研究。研究任务是对 TIDIGITS 数据集中口语数字计算得到的共振峰进行关键词检测。尽管两种编码器相较于直接对训练数据中的共振峰特征进行分类都有所提升，并使逻辑回归模型能够完成二元分类，但在测试集上的表现并未显示出明显改善。资源高效的关键词检测应用或可从这些编码器中受益，但要探究其全部潜力，还需进一步研究学习时间常数和权重的方法。**

索引词——**神经形态计算、边缘智能、关键词检测、时间编码、神经异质性。**

I. 引言

随着越来越多的技术设备采用语音交互（即“语音助手”），语音识别正逐渐成为一项日益重要的计算任务。由于识别数千种不同口语词汇所需的模型复杂度较高，这项任务的计算开销很大。相比之下，关键词检测仅需识别一个或少数几个特定单词或短语，因此对计算复杂度和资源的需求显著较低。因此，关键词检测被用于“唤醒”语音交互设备，使其随后能够启动资源需求更高的语音识别计算。

新一代受脑启发的神经形态处理器 [1]为开发用于关键词检测的超低功耗模型铺平了道路。这些设备由具备大规模并行能力并采用事件驱动运行方式的存内计算元件构成，可实现时空稀疏且高效的实时类脑计算 [2]。由于关键词检测需要低功耗，近期已有研究探讨将神经形态计算应用于这一任务 [3]–[6]。然而，这些模型依赖各种时间编码方法。其中一些方法，例如缓冲、传输延迟和精细调节的时间常数，并不特别适合在混合信号神经形态硬件上实现高效的实时处理。

时间编码是对时变模式进行高效神经形态实时处理的重要方面[7]。物理时间是脉冲神经网络（SNNs）运作的内在组成部分，可通过多种方式利用它，高效地表示处理数据中的关系 [8]。此外，为了构建资源高效的神经形态实现（例如关键词检测），人们希望尽可能减少成功分类所需的神经元和脉冲数量。

本文比较了两种不同的 SNN 机制在 TIDIGITS 数据集 [9]上的关键词检测任务中进行时间编码的效果。所研究的编码器分别为时间差编码器（TDE） [10] 和双突触兴奋性–抑制性（E–I）元件 [11]，两者均旨在实现低功耗神经形态硬件。TDE 对输入通道对上的脉冲之间的时间差进行编码，而 E–I 元件则提供了一种延迟的替代方案，利用模拟硬件的异质性来实现表征多样性。我们使用这两种编码器处理相同的输入数据——口语数字的共振峰，并比较评估它们对后续线性分类的影响。

我们发现，与直接对共振峰输入数据进行线性分类所达到的79%–96%准确率相比，两种编码器均能分别实现对训练集的完全二元分类。然而，在测试数据上，使用任一种编码器都没有带来明显的性能提升。我们得出结论，所研究的两种方法都可能适用于资源高效的关键词检测应用，但似乎需要提高神经异质性，并在两种情况下开发或实施训练方案 [12], [13] 。

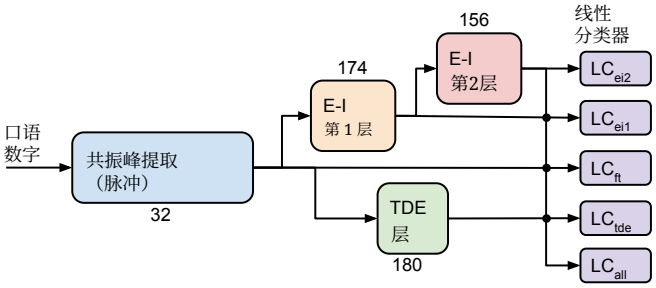

图1：**采用不同时间编码层的脉冲神经网络用于关键词检测**。线性分类器（LC）采用逻辑回归模型，并使用 ℓ_2 正则化进行拟合。

II. 方法

所研究系统的示意图如**图1**所示。输入数据经过并行处理，分别通过一层TDE神经元 [10]，（见第II-B节）以及两层依次连接、含有双突触兴奋-抑制元件 [11],[14], 的神经元（见第II-C节）。该系统通过关键词检测任务，对比评估每种神经突触结构在线性分类性能方面带来的提升，见第II-A节。线性分类器采用逻辑回归模型，并使用 scikit-learn 中的 LIBLINEAR 求解器进行拟合，同时加入 ℓ_2 正则化。

A. 任务与数据集

本研究中的关键词检测任务设置为对 TIDIGITS 数据集 [9] 中口语数字进行一对其余 二元分类。具体而言，我们使用了所有成年说话者的单个数字语音（“oh”以及从“zero”到“nine”），其中男性 111 人，女性 114 人，做法与 [15]相同。我们采用该数据集默认的训练-测试划分，将每个说话者组——“男性”和“女性”——划分为测试子集和训练子集，每个数字分别包含 224 个和 226 个样本。在使用关键词数字的所有样本的同时，我们通过将每个非关键词数字的样本数除以非关键词数字总数（10），并四舍五入到最接近的整数，对数据集进行平衡。因此，对于关键词检测任务中的每个关键词，数据集分别包含 224 对 10×22 个训练样本，以及 226 对 10×23 个测试样本。

为了简化输入数据，我们按照 [3], 中的做法，从语音录音中提取共振峰——即频谱峰值——而不是使用完整数据。共振峰是人类感知中主要用于区分不同语音声音的特征属性。在这里，我们使用 Sinewave speech analysis for MATLAB [16]，从 32 个频带的语音数据中提取振幅最高的四个“第一”共振峰。频带数量的选择基于神经形态耳蜗设计背后的分析 [17]。随后，我们以 1 毫秒为时间窗，将共振峰转换为脉冲序列：在与共振峰频带（即瞬时频谱峰值）对应的四个输入通道上生成一个脉冲。生成的脉冲数据示例见**图 2**。

按照**图1**所示，数据经过脉冲神经网络层处理后，我们将生成的脉冲序列转换为每个输入数据样本的脉冲计数，从而进一步简化数据；每个样本对应一段数字语音。随后，我们使用 Python 机器学习库 scikit-learn 拟合逻辑回归模型，基于脉冲计数数据执行一对多分类任务。

B. 时间差编码器

时间差编码器（TDE） [10]是用于在脉冲神经网络中编码脉冲时间差的计算单元，见**图 3**。每个 TDE 单元由一个基于电流的漏积分发放（CuBa LIF）神经元、一个额外的“增益”区室和两个输入突触组成：易化突触和触发突触。易化突触接收到的脉冲会产生一个呈指数衰减的增益因子。触发突触接收到的脉冲会产生兴奋性突触后电流（EPSC），该电流被积分到膜电位中，其振幅与增益因子的瞬时数值成正比。因此，神经元积分的电流取决于突触前脉冲之间的时间差，进而通过脉冲簇对这一时间差进行编码。脉冲数量和脉冲间隔均取决于两个输入之间的时间差。因此，每对输入通道都需要一个 TDE 神经元；在此处，输入通道指听觉频带，且每对通道都需对其时间差进行编码。

*1) TDE*拓扑结构：时间差编码层的目标是对共振峰轨迹的时间变化进行编码，这类似于在图像处理中使用卷积层提取图像中的基本特征。为此，TDE应捕捉单条共振峰轨迹内部的时间变化信息。因此，需要避免由对应不同共振峰轨迹的脉冲触发某些TDE的激活。为此，定义了突触前输入通道之间的最大横向距离为 $d_{\max} = 3$。如上一节所述，每个TDE神经元接收来自两个不同输入通道的输入。因此，为每种可能的输入通道组合各设置一个TDE，共得到180个TDE神经元。

*2) TDE*实现：使用Python软件包Nengo [20]对SNN架构中的时间差编码层进行了仿真，见**图1**。TDE的参数依据使用Speech Commands数据集中的口语数字进行的网格搜索结果设定 [21], ，见**表 I**。使用不同说话者的数据集来调优特征提取器，而非用于训练最终分类器，这类似于一种开发流程：在开发期间调优特征提取器，而使用消费级产品的最终用户数据训练分类器。

C. 兴奋性–抑制性双突触元件

兴奋性–抑制性（E–I）双突触元件 [11]通过对每个突触前连接的一个兴奋性和一个抑制性突触后电流求和，产生

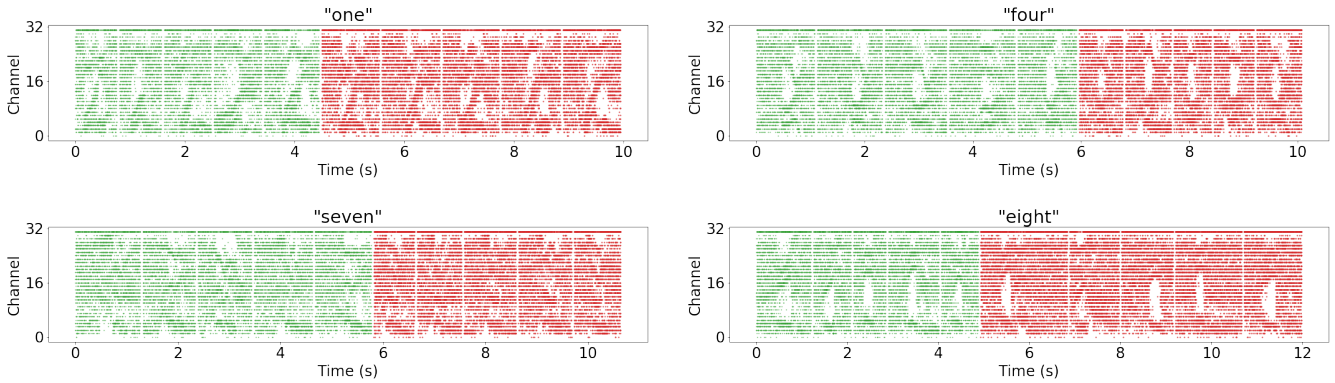

图 2：**共振峰脉冲数据示例**。在 1 毫秒的时间窗内，对应于最活跃听觉频带的四个通道各产生一个脉冲。图中展示了每个指定数字的后续十个样本。绿色表示图 7 中所有单神经元系统均生成真阳性测试的样本，红色表示假阴性。

对神经元膜电位的有效延迟兴奋，见**图4**。由此，它们模拟了抑制后反跳这一神经生物学现象。对于脉冲神经网络而言，E–I 元件为专用延迟机制或树突仿真提供了一种资源开销较低的替代方案，因为这些方法在神经形态硬件上的实现成本很高。此前，人们已在 DYNAP-SE 神经形态处理器中研究过 E–I 元件的实现 [11], [14], [22], ，并利用模拟神经元和突触电路的异质性，将其作为生成延迟时变异性的来源。

1）兴奋–抑制拓扑：基于前文对 TDE 拓扑的阐述，兴奋性-抑制性层也设置了最大输入距离 $d_{\max} = 3$。此处，基于双突触时空相关器（dSTC）网络的拓扑结构 [14], 我们将这一横向输入范围转换为：每个兴奋–抑制神经元连接四个相邻的输入通道，每个连接均通过一个兴奋–抑制元件实现。在第一层兴奋性-抑制性层中，我们针对每个由四个相邻输入通道组成的连续序列设置一个神经元，共得到 29 个兴奋–抑制神经元。为使兴奋–抑制神经元的搜索空间规模与 TDE 相近，我们为每个兴奋–抑制

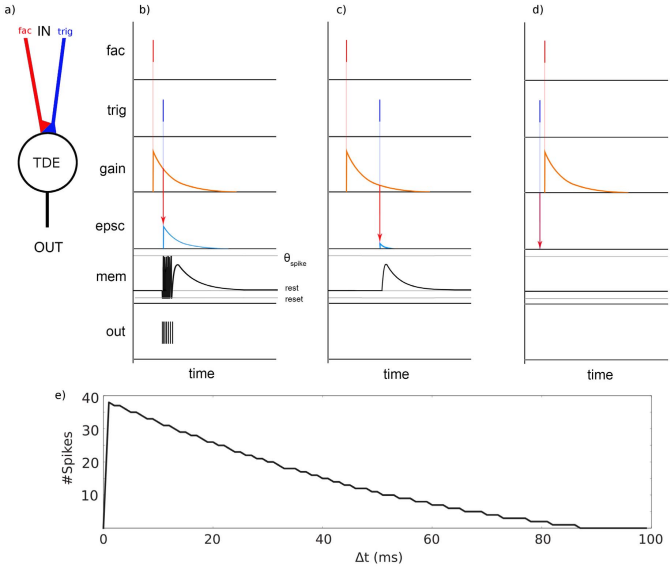

Fig. 3：**时间差编码器（TDE）的基本原理**。改编自 [18] 和 [19]。**（a）**一个时间差编码器神经突触单元。触发（trig）突触接收的输入由促进性（fac）突触进行门控，其增益取决于两个输入之间的时间差。**（b）–（d）**分别为较小、较大和负时间差下的时间差编码器响应。**（e）**TDE 时间差脉冲响应曲线。

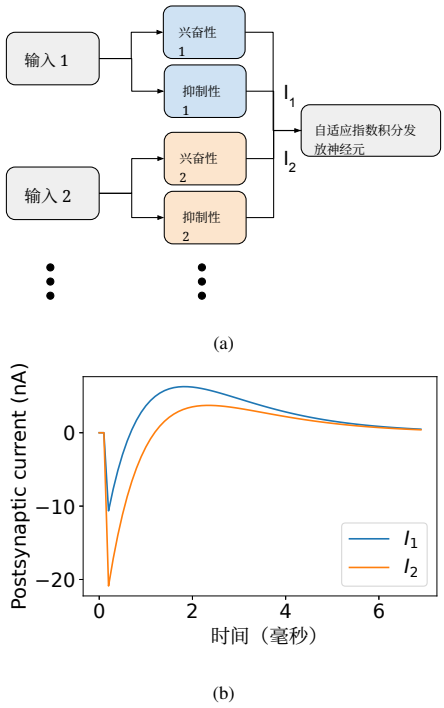

图4：**双突触兴奋–抑制（E–I）元件的基本原理**。**（a）**一个自适应指数积分发放神经元通过两个不同的兴奋–抑制元件接收输入，每个元件由一个兴奋性（Exc.）动态突触和一个抑制性（Inh.）动态突触组成，二者的时间常数不同。**（b）**两个兴奋–抑制元件的突触后电流（I_1 和 I_2）因电路非均匀性（“器件失配”）而有所不同，导致抑制后兴奋的时间延迟和幅度各不相同。

表 I：**突触参数值**。

模型	参数	符号	数值
TDE	易化时间常数	τ_{fac}	8 ms
	触发时间常数	τ_{trig}	2 ms
	易化权重	w_{fac}	50,000
	触发权重	w_{trig}	50,000
E–I	兴奋性时间常数	τ_{e}	1.5 毫秒
	抑制性时间常数	τ_{i}	1 ms
	兴奋性权重	w_{e}	105 纳安
	抑制性权重	w_{i}	-147 纳安
	时间常数标准差	σ_τ	50%
	权重标准差	σ_w	50%

神经元设置了六个副本，共得到 174 个神经元。

由于每个兴奋–抑制神经元都充当一个小型时空特征检测器，我们还添加了第二个后续兴奋性–抑制性层，以研究该架构中深度的影响，以及由此产生的更长有效时间常数。对于通往第二个兴奋性–抑制性层的前向连接，分别为第一层的六个副本重复了上述连接模式，最终共有 156 个神经元。

2) 兴奋–抑制实现：使用 teili 工具箱 [23] 在 Brian 2 脉冲神经网络模拟器[24]中对兴奋性–抑制性层进行模拟。Teili 提供了 DYNAP-SE [25]的模拟神经元和突触电路模型实现——自适应指数积分发放（AdEx）神经元模型和差分对积分器（DPI）突触电路；在这些模拟中，分别使用了 teili 神经元模型 DPI 和突触模型 DPISyn。兴奋–抑制元件的时间常数经过设置，使其产生约 2 ms 的有效延迟——设置依据是文献 [3] 中的延迟量级（原始描述见 [26]）；权重则经过设置，使兴奋–抑制神经元在至少四个输入脉冲在时间上重合时产生输出脉冲，见**表 I**。其他所有参数均采用 teili 神经元和突触模型的默认值。由于此处所述兴奋性–抑制性层的拓扑结构依赖突触动力学的方差来形成不同的特征检测器，因此我们使用 teili 的器件失配功能，为所有兴奋–抑制突触的突触时间常数和权重引入这种方差。失配服从具有给定标准差的高斯分布；此处将标准差设为 50%，以显著强调这一效应，而 teili 的默认值为 20%。

III. 结果

A. 神经元的置换重要性

图 5 展示了所有神经元（包括共振峰输入通道）的置换重要性。置换重要性定义为单个特征的数值（在本例中为单个脉冲……）变化时模型得分的下降。

每个神经元的计数会被随机置换 [27]。具体做法是使用单个线性分类器，对图1所示网络中每一层的输出进行分类。因此，置换重要性可以反映每个神经元编码的特定类别信息的相对多少。对于时间差编码层，

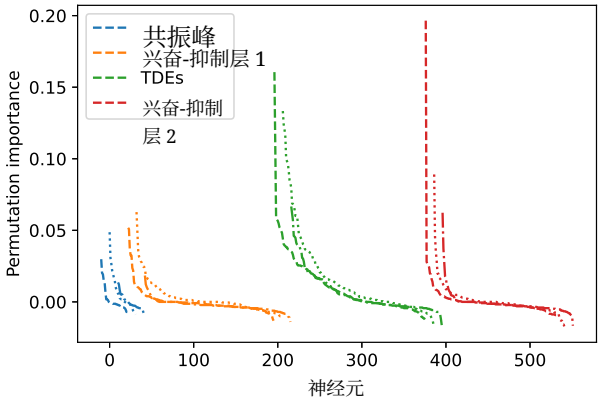

图 5：**神经元的置换重要性**。不同的线型分别对应关键词“one”（虚线）、“two”（点线）和“three”（点划线），相应的曲线沿 x 轴偏移 = 10，以提高可见性。置换重要性是在测试集上评估的，所用逻辑回归模型基于神经网络所有层的训练数据拟合。每层内的神经元按照置换重要性的绝对值排序。

以及第2个兴奋-抑制层，置换重要性最高的那部分编码器，其数值是共振峰的3到4倍。这些结果印证了我们的直觉：这些计算单元有助于从输入数据中提取有关时空模式的信息。

B. 线性分类

图6 展示了训练数据集经过网络不同层后进行线性分类的平均准确率。每个分类器都会接收来自指定层及其之前各层的脉冲计数。这些结果表明，所有受研究的编码器都提取了足够的信息，能够对训练

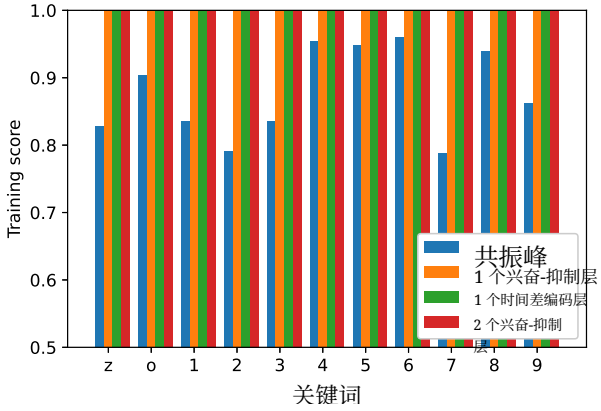

图6：**使用所示架构的所有神经元在训练集上取得的平均准确率**。在此情况下，线性分类器不仅接收该架构最后一层的脉冲计数，还通过旁路连接接收前面各层的脉冲计数。因此，不同架构使用的神经元总数为：共振峰：32；1 个兴奋性-抑制性层： 32+174；1 个时间差编码层：32+180；2 个兴奋性-抑制性层： 32+174+156。

数据（共444个样本，准确率为100%）进行完整的线性分类。此外，结果表明，无需进一步处理，提取出的共振峰就足以支持相当准确的线性分类；针对不同关键词，平均准确率介于79%至96%之间，而随机猜测的准确率为50%。

C. 少量神经元的分类

图 7a 展示了使用单个神经元对测试数据集进行分类时的平均准确率。神经元是根据其在训练集上的最高准确率选出的。与使用单个共振峰通道相比，使用 TDE 和兴奋性-抑制性层中单个元素的输出，并未明显提高准确率。此外，增加第二个兴奋性-抑制性层也没有带来系统性的提升。**图 7a**还展示了真正例和真负例分别占所有正确分类总数的比例。两者所占比例相当均衡，因此这并不表明分类错误集中于正类或负类预测。**图 7b** 展示了每个神经元处理不同关键词的单条语音时产生的平均脉冲数。尽管 TDE 和兴奋 – 抑制神经元的脉冲计数可能会通过参数调优加以优化，但值得注意的是，对于几乎所有关键词，TDE 产生的脉冲数都比其他神经元多出约 100 个。这是一项重要指标，因为在 DYNAP-SE [25] 这类神经形态处理器中，脉冲生成和路由构成了动态功耗的大部分，因而也占总功耗的相当大一部分。

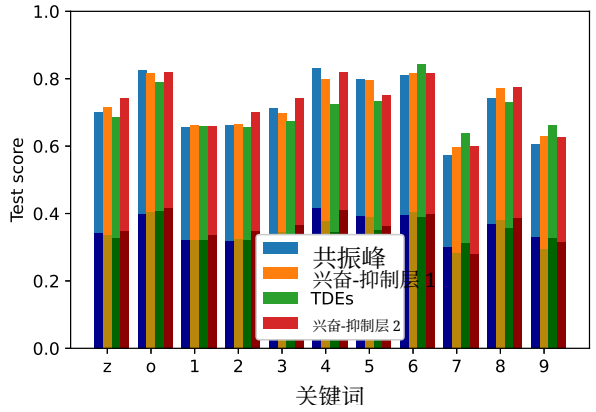

(a)

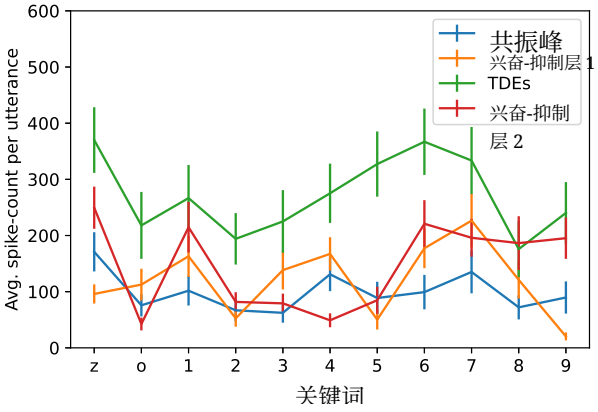

(b)

图 7：**使用单个神经元进行分类。(a)** 测试集上的平均准确率。浅色和深色分别表示真正例和真负例占正确分类总数的比例。**(b)** 每次关键词发音的平均脉冲数。误差线表示标准差。

图 8 展示了在测试集中，随着**图 7** 中的神经元数量增加至最多 10 个，不同网络层对四个不同关键词的平均准确率。与之前一样，每一层中的第一个神经元按训练得分最高进行选择，后续神经元则按置换重要性最高进行选择。选择一组对分类具有较高置换重要性的神经元，相比使用单个神经元略微提升了结果。另一方面，与使用部分共振峰通道相比，使用 TDE 或兴奋-抑制元素并未带来明显改善。

本节所呈现的结果凸显了该系统缺乏泛化能力。不过，一个值得关注的比较是，另一项在相同数据集上使用脉冲神经网络进行关键词检测的研究，在特征
特征提取层的分类准确率分别约为 9%、27% 和 61% [15]。

对于 TDE，所有单元的时间常数和权重都设为相同的数值。同样，兴奋–抑制元件的参数值取自均值恒定的高斯分布。为了使编码器能够对每个关键词的特征时空特征产生敏感性，从而有效提升对未知样本的分类能力，两种编码器可能都需要采用参数值的非均匀分布。此外，由于手动调整数百个参数或通过网格搜索进行调整并不可行，因此需要通过学习来优化这些参数值

[12], [13]。对于兴奋–抑制元件，这意味着要为每个兴奋–抑制神经元优化非均匀神经元和突触电路的选择，而不是像本文这样，依赖从大量随机非均匀神经突触单元中进行采样。

IV. 结论

我们展示了一项研究的结果，该研究比较了两种不同神经计算元件——时间差编码器和双突触兴奋-抑制元件——用于时空编码，以实现资源高效的关键词检测，并使其适用于始终开启的神经形态硬件。训练数据上的结果表明，这两种编码器都能够实现完整的一对其余线性分类；而测试数据上的结果则表明，与直接对共振峰数据进行线性分类相比，并无明显改进。使用这两种编码器时，改进的一个重要来源可能是采用异质权重和时间常数，并通过训练对其进行优化，以最大限度地提高针对特定关键词的检测准确率。

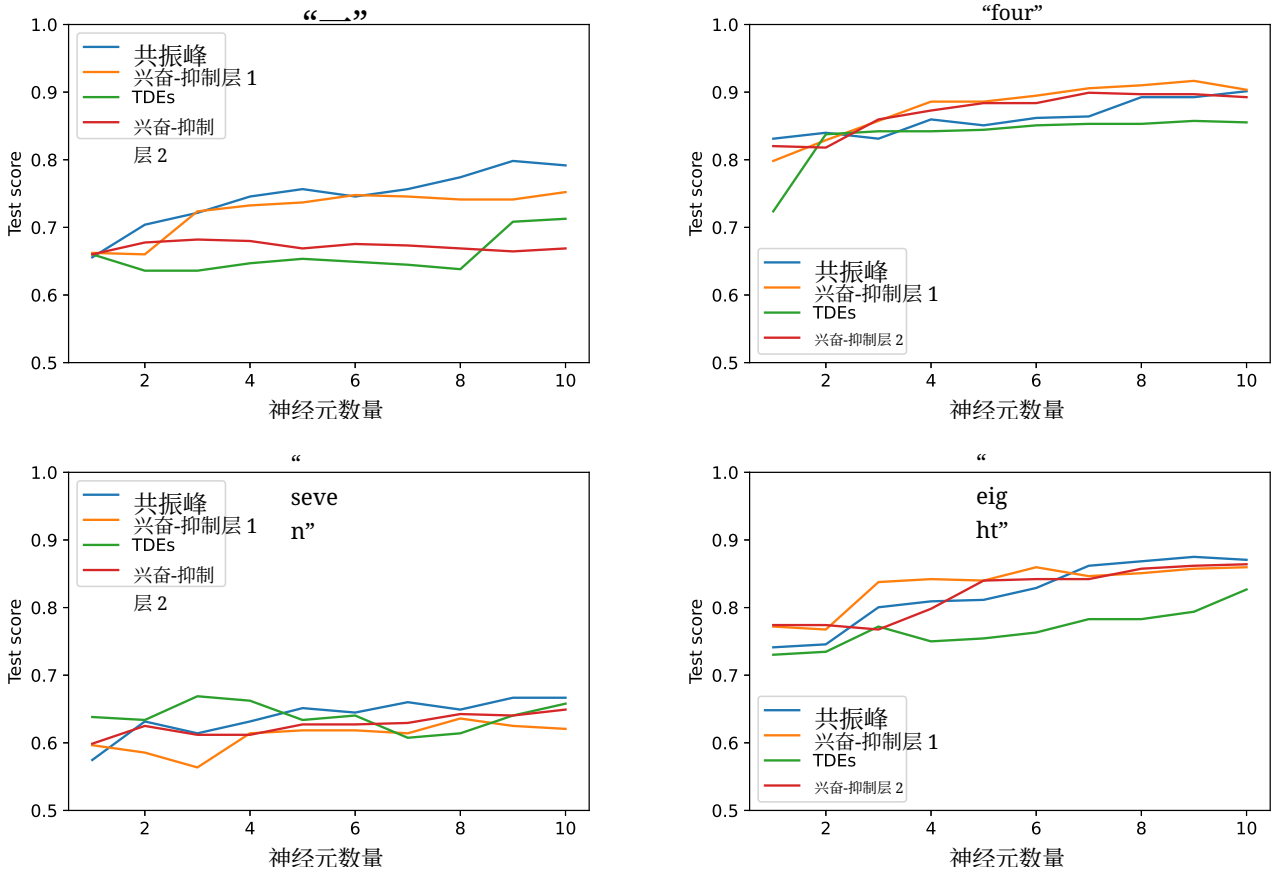

图 8：**使用数量有限的读出神经元时，在测试集上的平均准确率**。第一个神经元根据最高训练得分选出，后续神经元则根据最高置换重要性选出。

致谢

本研究部分由 Kempe 基金会根据合同 JCK-1809、ECSEL JU 根据资助编号 737459、CogniGron 研究中心以及 Ubbo Emmius 基金（格罗宁根大学）资助。

参考文献

[1] K. Roy、A. Jaiswal 和 P. Panda，“借助神经形态计算实现基于脉冲的机器智能”，《自然》，第 575 卷，第 7784 期，第 607–617 页，2019 年。[2] M. Davies、A. Wild、G. Orchard、Y. Sandamirskaya、G. A. F. Guerra、P. Joshi、P. Plank 和 S. R. Risbud，“借助 Loihi 推进神经形态计算：成果综述与展望”，《*IEEE* 会议录》，第 109 卷，第 5 期，第 911–934 页，2021 年。[3] M. Coath、S. Sheik、E. Chicca、G. Indiveri、S. Denham 和 T. Wennekers，“适用于神经形态实现的鲁棒声音感知模型”，《神经科学前沿》，第 7 卷，第 278 页，2014 年。[4] P. Blouw、X. Choo、E. Hunsberger 和 C. Eliasmith，“神经形态硬件上关键词检测效率的基准测试”，载于第七届神经启发计算元件年度研讨会论文集，NICE ’19 系列。美国纽约：计算机协会，2019 年。[5] P. Weidel 和 S. Sheik，“WaveSense：利用脉冲神经网络实现高效时间卷积的关键词检测”，*arXiv* 预印本 *arXiv:2111.01456*，2021 年。[6] B. Yin、Q. Guo、F. Corradi 和 S. Bohte，“面向端到端流式关键词检测的持续运行脉冲循环神经网络的注意力决策与动态重置”，载于国际会议论文集，主题为神经形态系统 *2022*，系列出版物 ICONS ’22。美国纽约州纽约市：计算机协会，2022 年。[7] G. Indiveri 和 Y. Sandamirskaya，《空间与时间对神经形态智能体信号处理的重要性：开发可与环境交互的低功耗自主智能体所面临的挑战》，《*IEEE* 信号处理杂志》，第 36 卷，第 6 期，第 16–28 页，2019 年。[8] D. Auge、J. Hille、E. Mueller 和 A. Knoll，《脉冲神经网络信号处理编码技术综述》，《神经处理快报》，第 53 卷，第 6 期，第 4693–4710 页，2021 年。[9] R. G. Leonard 和 G. Doddington，《TIDIGITS LDC93S10》，网络下载。费城：语言数据联盟，1993 年。[10] M. B. Milde、O. J. N. Bertrand、H. Ramachandran、M. Egelhaaf 和 E. Chicca，《神经形态系统中的脉冲式基本运动检测器》，《神经计算》，第 30 卷，第 9 期，第 2384–2417 页，2018 年，PMID：30021082。[11] F. Sandin 和 M. Nilsson，《用于受昆虫启发的时间特征检测的突触延迟》，《神经科学前沿》，第 14 卷，第 150 页，2020 年。[12] N. Perez-Nieves、V. C. Leung、P. L. Dragotti 和 D. F. Goodman，《神经异质性促进稳健学习》，《自然通讯》，第 12 卷，第 1 期，第 1–9 页，2021 年。[13] M. S. Bouanane、D. Cherifi、E. Chicca 和 L. Khacef，《脉冲神经元泄漏和网络循环连接对基于事件的时空模式识别的影响》，*arXiv* 预印本 *arXiv:2211.07761*，2022 年。[14] M. Nilsson、F. Liwicki 和 F. Sandin，《利用异构动态突触在单个混合信号 VLSI 神经元中进行时空模式识别》，载于神经形态系统国际会议论文集 *2022*，系列出版物 ICONS ’22。美国纽约州纽约市：计算机协会，2022 年。[15] J. Wu、Y. Chua 和 H. Li，《基于脉冲神经网络的生物学上合理的语音识别框架》，载于2018 年国际

神经网络联合会议（*IJCNN*），2018 年，第 1–8 页。[16] D. P. W. Ellis，《Matlab 中的正弦波语音分析/合成》。[在线]。网址：http://www.ee.columbia.edu/ln/labrosa/matlab/sws/ [17] V. Chan、S.-C. Liu 和 A. van Schaik，《AER EAR：带地址事件表示接口的配对硅耳蜗》，*IEEE* 电路与系统汇刊 *I*：常规论文，第 54 卷，第 1 期，第 48–59 页，2007 年。[18] G. D'Angelo、E. Janotte、T. Schoepe、J. O'Keeffe、M. B. Milde、E. Chicca 和 C. Bartolozzi，《利用时间差编码进行基于事件的偏心运动检测》，《神经科学前沿》，第 14 卷，2020 年。[19] D. Gutierrez-Galan、T. Schoepe、J. P. Dominguez-Morales、A. Jimenez-Fernandez、E. Chicca 和 A. Linares-Barranco，《用于神经形态系统的基于事件的数字时间差编码器模型实现》，*IEEE* 神经网络与学习系统汇刊，第 33 卷，第 5 期，第 1959–1973 页，2022 年。[20] T. Bekolay、J. Bergstra、E. Hunsberger、T. DeWolf、T. Stewart、D. Rasmussen、X. Choo、A. Voelker 和 C. Eliasmith，《Nengo：用于构建大规模功能性脑模型的 Python 工具》，神经信息学前沿，第 7 卷，2014 年。[21] P. Warden，《语音命令：用于有限词汇语音识别的数据集》，2018 年。[22] M. Nilsson、F. Liwicki 和 F. Sandin，《利用动态神经形态处理器对时空特征进行突触整合》，载于*2020* 年神经网络国际联合会议（*IJCNN*），2020 年，第 1–7 页。[23] M. Milde、A. Renner、K. Burelo、S. Solinas、N. Risi、M. Cartiglia、M. Rasetto、G. Haessig、D. Zendrikov、A. M. Whatley 和 V. Leite，《teili：使用脉冲神经元构建和测试神经算法与计算原语的工具箱》，2018 年，文档：https://teili.readthedocs.io/。 [在线]。网址：https://gitlab.com/neuroinf/teili [24] M. Stimberg、R. Brette 和 D. F. Goodman，《Brian 2：直观高效的神经模拟器》，*eLife*，第 8 卷，文章编号 e47314，2019 年。[25] S. Moradi、N. Qiao、F. Stefanini 和 G. Indiveri，《用于动态神经形态异步处理器（DYNAPs）的可扩展多核架构及异构存储结构》，*IEEE* 生物医学电路与系统汇刊，第 12 卷，第 1 期，第 106–122 页，2018 年。[26] S. Sheik、M. Coath、G. Indiveri、S. Denham、T. Wennekers 和 E. Chicca，《实时神经形态 VLSI 系统中涌现式听觉特征调谐》，《神经科学前沿》，第 6 卷，第 17 页，2012 年。[27] L. Breiman，《随机森林》，机器学习，第 45 卷，第 1 期，第 5–32 页，2001 年。