深度学习增强型里德伯原子传感器中的局部放电信号指纹识别

Yi-Ming Yin[1,2], *Qi-Feng Wang*[1,2], *Yu Ma*[1,2], *Tian-Yu Han*[1,2], *Jia-Dou Nan*[1,2], *Zheng-YuanZhang*[1,2], *Han-Chao Chen*[1,2], *Xin Liu*[1,2], *Shi-Yao Shao*[1,2], *Jun Zhang*[1,2], *Qing Li*[1,2], *Ya-Jun Wang*[1,2], *Dong-Yang Zhu*[1,2],*Qiao-Qiao Fang*[1,2], *Chao Yu*[1,2], *Bang Liu*[1,2], *Li-Hua Zhang*[1,2], *Dong-Sheng Ding*[1],*2,*[*] *and Bao-Sen Shi*[1,2][l] *Key Laboratory of Quantum Information, University of Science and Technology of China, Hefei, Anhui 230026, China.*[2] *Synergetic Innovation Center of Quantum Information and Quantum Physics, University of Science and Technology of China, Hefei, Anhui 230026, China. and*

（日期：2026年3月4日）

局部放电源于高压设备中的微观绝缘缺陷，被广泛视为早期劣化的关键标志。传统局部放电检测方法通常受限于带宽有限，且往往依赖预先设定的特征提取方式，这阻碍了对宽带瞬态信号的可靠识别。在本研究中，我们采用里德堡原子传感器直接捕获局部放电发射的时域响应，并为不同类型构建独特的光谱指纹。随后，采用一维残差网络深度学习模型从时域信号中识别这些指纹，无需手动进行特征工程。在源-天线距离增大、光谱特征显著衰减的情况下，该模型对四类局部放电的识别准确率仍达到约 94%，展现出对衰减和噪声的鲁棒性。我们还在模拟早期预警场景中验证了该方法：对混有噪声的局部放电信号进行分析后，模型成功生成了预测性警报。这些结果凸显了将基于里德堡原子的宽带传感与数据驱动分析相结合，用于电气绝缘系统非侵入式、高灵敏度诊断的潜力。

arXiv:2603.02925v1 [quant-ph] 3 Mar 2026

I. 引言

局部放电是高压设备绝缘中的局部电击穿，被广泛认为是绝缘老化的早期指标 [1, 2]。它会产生具有亚纳秒上升时间的瞬态电磁脉冲，其宽带频谱范围覆盖兆赫兹至吉赫兹。鉴于不同局部放电类型呈现出不同的频谱特征 [3],，宽带测量对于捕获其判别性特征并实现可靠识别至关重要。

传统局部放电检测技术，尤其是特高频（UHF）传感器和脉冲电流法，与深度学习方法相结合时已实现较高的识别率 [4–6]。然而，这些硬件方法往往受限于由传感器几何结构决定的有限带宽，并且需要复杂的校准链。相比之下，基于里德堡原子的电场传感器近来已成为一种极具前景的宽带诊断平台。通过利用电磁诱导透明（EIT） [7–10], 、交流斯塔克频移 [10–12],和 Autler–Townes 劈裂 [9, 10], ，这些传感器凭借基本物理常数展现出独特的物理优势，具体包括固有的 SI可溯源性和自校准能力 [13] ，以及从 MHz 起延伸的超宽动态频率响应范围直至太赫兹 [14–19]。此外，其非金属结构和各向同性响应使其能够在无需金属探针的情况下直接耦合电场 [20, 21], ，从而利用原子响应将入射电场内在地映射为光谱指纹。

为识别这些光谱指纹，我们采用了一种基于一维残差网络的深度学习模型，能够准确分析从里德伯原子传感器中提取的时域信号，无需手动进行特征工程 [22–27]。该模型通过反向传播更新其权重，能够从大型数据集中自主学习相关表征，而无需预先了解底层物理原理或实验系统。凭借这些优势，深度神经网络已成功应用于需要从噪声测量中识别细微模式的领域，包括多频微波识别 [28], 远场亚波长声学成像 [29], 时变原子磁力测量 [30], 光学涡旋识别 [31, 32],以及自动量子控制 [33–38]。

在本工作中，我们提出了一种将里德伯原子传感与一维残差网络模型相结合的识别方案。原子系统将局部放电特征编码为光谱指纹，这些指纹会随着源传感器距离的增加而减弱。为确保可靠识别，我们在实验指纹数据集上训练该模型，即使在低信号条件下也能实现稳健识别。使用模拟真实放电场景的信号进行的测试进一步证明了其早期预警能力，将量子传感器的潜力与深度学习相结合，用于宽带、非侵入式诊断。

* dds@ustc.edu.cn

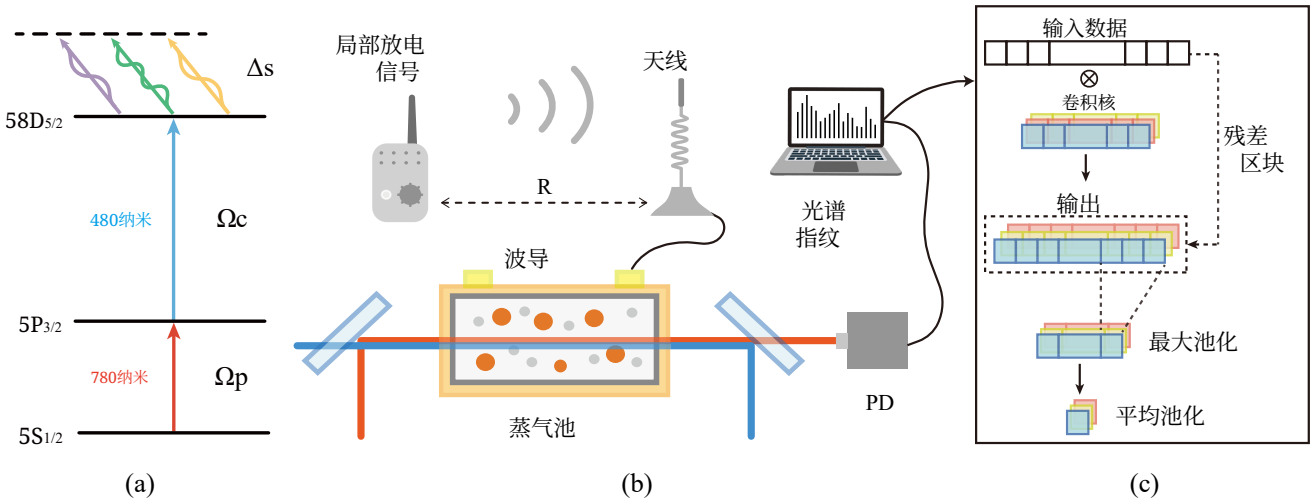

图1. **装置示意图和物理示意图**。(a) 实验能级图概览。探测光（780纳米）和耦合光（480纳米）使基态 $5S_{1/2}$、中间态 $5P_{3/2}$ 和里德堡态 $58D_{5/2}$的原子态耦合，形成阶梯型电磁感应透明（EIT）方案。在局部放电电场作用下，里德堡能级 $58D_{5/2}$ 因交流斯塔克效应而发生能量偏移 Δs 。(b) 实验装置。天线在不同距离 R 处接收局部放电信号，并将其耦合至波导，再直接辐射到铷蒸气室。通过光电探测器（PD）检测探测光束的电磁感应透明透射，以获得光谱指纹。(c) 残差神经网络示意图。该网络由一维卷积层、残差块、最大池化层和全局平均池化层组成。有关这些层的更多详情，请参见“方法”部分。

II. 物理模型

实验装置和实验能级图见图1(a-b)。超宽带（UWB）天线（950 MHz–7吉赫兹）作为前端收集器，用以提高局部放电辐射进入容纳铷蒸气室的波导（300 MHz–24吉赫兹）的耦合效率。在原子层面，^{85}铷原子从基态5S被激发$_{1/2}$ 至里德堡态58D$_{5/2}$，经由双光子电磁感应透明过程实现。因此，三能级阶梯系统中的里德堡原子$\{|g\rangle, |e\rangle, |r\rangle\}$ 与超宽带天线所传递的振荡电场之间的相干相互作用可由总哈密顿量描述

$$H = \frac{\hbar}{2}\left(\Omega_p|g\rangle\langle e| + \Omega_c|e\rangle\langle r| + \text{H.c.}\right) + \Delta_s|r\rangle\langle r|, \quad (1)$$

其中，Ω_p 和Ω_c 分别为探测光和耦合光的拉比频率，H.c.表示厄米共轭，Δ_s 表示局部放电场引起的交流斯塔克频移。斯塔克微扰可近似表示为

$$\Delta_s \approx \alpha(\omega)|E_t|^2, \quad (2)$$

其中，E_t 为局部放电场振幅，$\alpha(\omega)$为频率相关极化率[4]。由于极化率与 $\alpha(\omega) \propto n^7$成比例，主量子数的选择需要在灵敏度与环境敏感性之间进行权衡。在本研究中，选取 $58D_{5/2}$ 态，以兼顾弱信号检测所需的高灵敏度和防止态混合所需的光谱稳定性。这种斯塔克位移同时改变EIT共振的中心频率和线宽，有效地将探测光敏感度转换为 $\chi(\Delta_p, E_t)$，其中编码了不同局部放电类型的光谱指纹。

为解码这些指纹，我们采用图中所示的残差神经网络1(c)，该网络实现了一种非线性映射

$$f_\theta:\ \chi(\Delta_p, E_t) \mapsto y, \quad (3)$$

其中，$\chi(\Delta_p,\ E_t)$表示经斯塔克效应修饰后的测量指纹，$y \in \{0, 1, 2, 3\}$ 表示局部放电类别，θ 表示可训练参数。

从物理角度来看，网络的浅层卷积层对EIT共振中由明显的斯塔克效应引起的调制所产生的局部振荡特征较为敏感，而深层卷积层则捕捉峰分布和线宽变化等全局结构。每层中的卷积运算可形式化地表示为

$$h_j^{(l+1)}(t) = \sigma\left(\sum_i \int K_{ij}^{(l)}(\tau)\, \chi_i(t-\tau)\, d\tau + b_j^{(l)}\right), \quad (4)$$

其中，l 表示层索引，i 和 j 分别表示输入通道和输出通道，$K_{ij}^{(l)}$ （τ）表示用于捕捉局部特征的卷积核，$b_j^{(l)}$ 表示偏置，σ 表示激活函数。该表述直接将原子响应与网络中的层次化特征提取联系起来，从物理角度阐释了局部斯塔克效应诱导的振荡和全局频谱模式如何编码为学习到的表征。

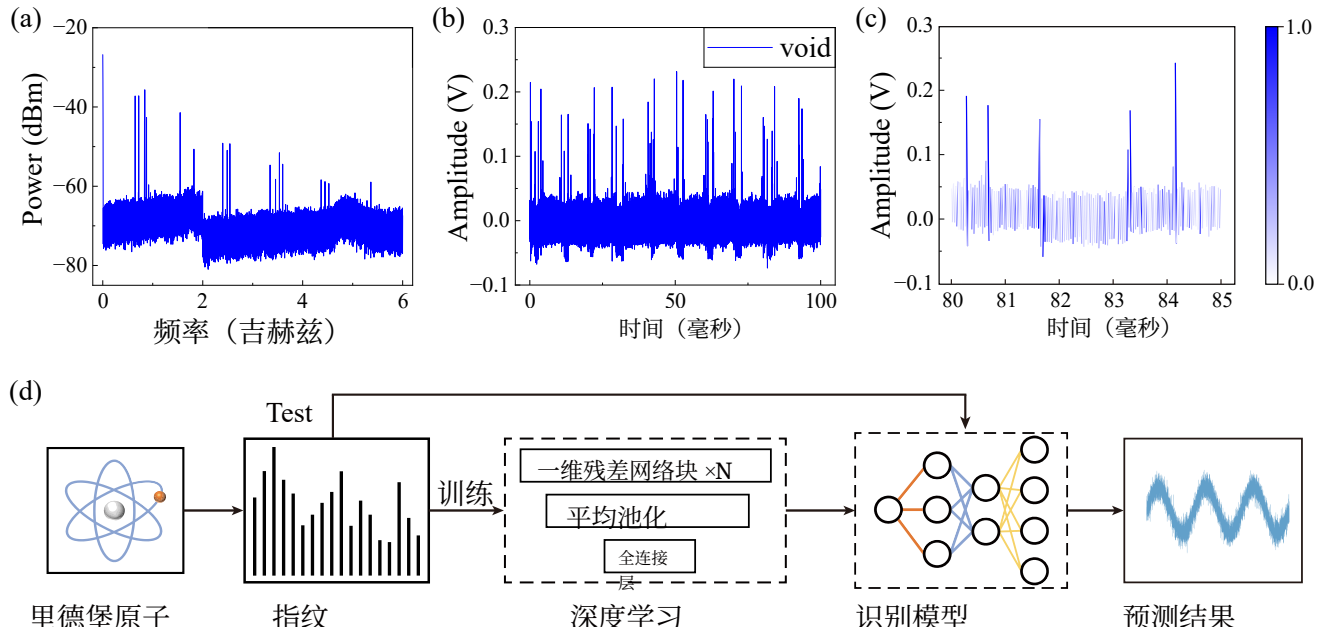

图2. **频谱指纹构建与识别过程**。(a) 气隙型局部放电信号在 0-6吉赫兹范围内的实测频谱。通过将放电源直接连接到频谱分析仪，获取数据以表征该放电源的固有频率成分。(b) 当局部放电源距天线 1 cm 时，从里德伯原子传感器提取的时域波形。(c) 显著性图可视化结果，突出显示模型对信号不同时间区域的注意力。(d) 指纹识别流程图。局部放电信号经天线传输至里德堡原子系统，并编码为光谱指纹，随后划分为训练集和测试集。训练集用于训练残差网络，以生成识别模型；然后在测试集上评估该模型，以衡量识别性能。有关训练和测试过程的详细信息，请参见“方法”部分。

III. 结果

A. 指纹的构建与识别

每种局部放电信号的频谱特征本质上各不相同，因此从里德堡原子传感器提取的时域波形也各有差异。图 2（a–b）分别展示了气隙型局部放电信号的频率范围及其对应的时域波形。为探究深度学习模型如何从这些时域波形中构建光谱指纹，我们引入显著性图来可视化模型在不同时间区域的注意力，如图2（c）所示。在显著性图中，颜色深浅表示模型在各个时间点的注意力程度：出现显著幅度偏差或突变的时刻通常对应较深的颜色。这表明模型主要关注波形中的局部极值或瞬态特征。这些独特的瞬态特征承载着每种局部放电类型的特征，使模型能够提取并整合这些特征，形成可区分不同局部放电信号类别的光谱指纹。

图。2（d）展示了整体光谱指纹识别过程。在此过程中，首先通过天线采集局部放电信号，并由里德堡原子传感系统将其转换为时域波形。随后，深度学习模型对这些波形进行处理，提取相关特征并将其编码为光谱指纹。最终得到的指纹被划分为训练集和测试集：训练集用于训练残差网络，而测试集用于评估识别性能。该流程能够有效地对局部放电信号类型进行分类，并确保光谱指纹忠实地表征各信号类别的区别性特征。

B. 深度学习

随着天线与局部放电源之间的距离增加，信号会迅速衰减，同时噪声增强，导致信噪比（SNR）显著下降。信噪比定义为

$$\mathrm{SNR} = 20\log_{10}\left(\frac{A_{\mathrm{signal}}}{A_{\mathrm{noise}}}\right), \tag{5}$$

当距离从 1 厘米增加到 30厘米时，信噪比从 16 dB 降至 2 dB。在这种情况下，

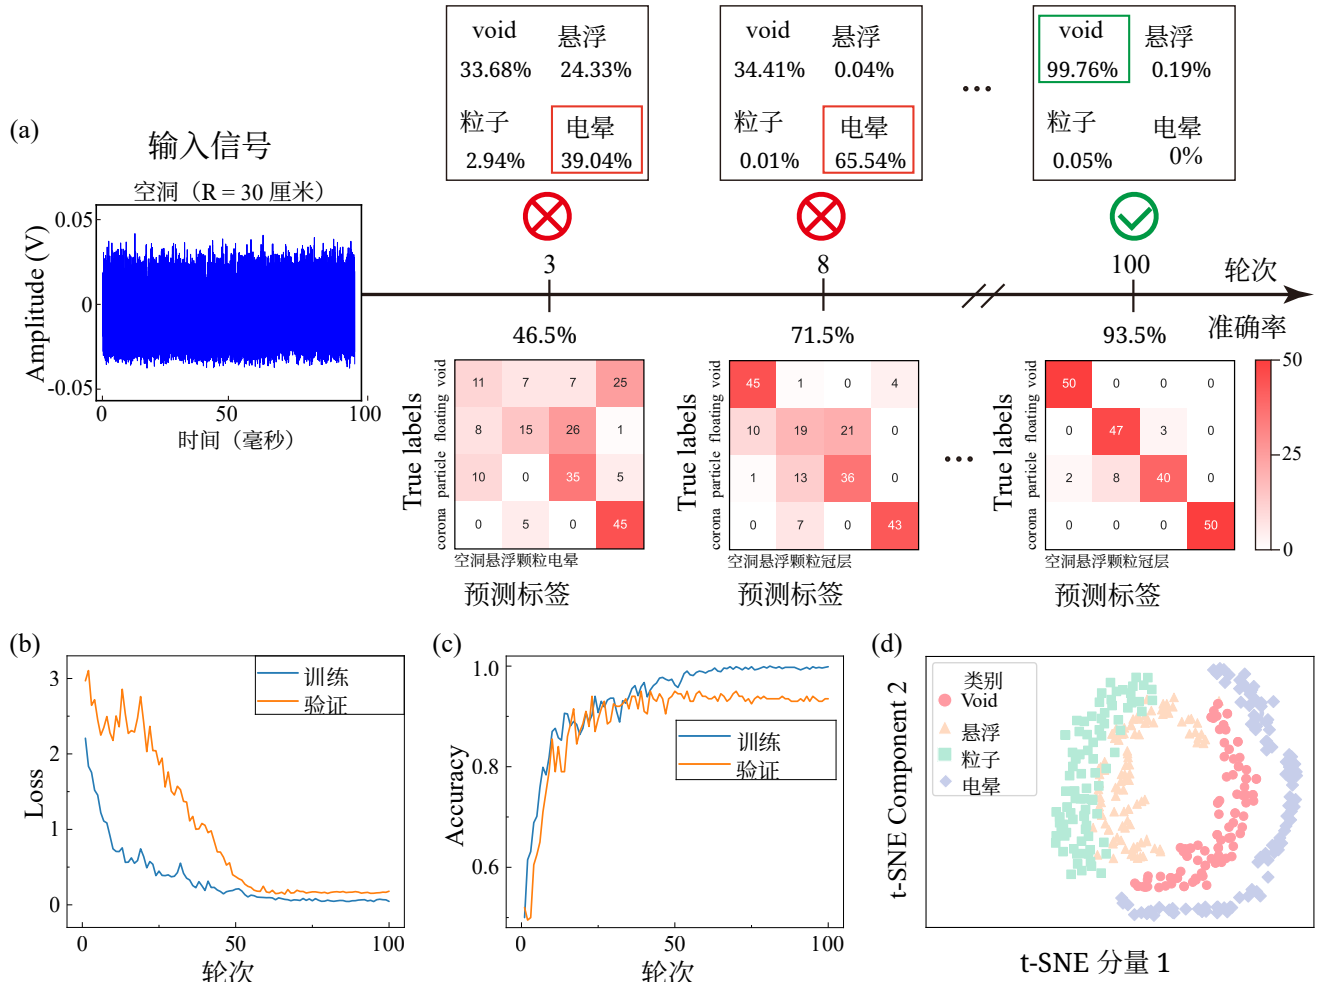

图3. **深度学习模型在不同训练轮次下的识别性能**。(a) 在训练3、8和100轮次后测得的30厘米处信号的混淆矩阵，整体识别准确率分别为46.5%、71.5%和93.5%。(b-c) 训练集（蓝色）和验证集（橙色）的损失和准确率曲线随轮次的变化。(d) 提取的特征表示的 t-SNE 可视化。

信号的独特特征变得过于微弱，无法通过视觉辨别，因此需要使用深度学习模型提取其潜在表示，以实现可靠识别。

为评估低信噪比条件下的识别性能，我们在30厘米距离处采集了1000个信号样本，每种局部放电类型各有250个信号。采用标准的80/20划分，将80%的数据用于训练，20%用于测试。不同训练阶段的识别结果汇总于图3(a)。在训练早期（第3轮），网络将信号误分类为电晕，如矩阵所示，整体准确率较低，仅为46.5%。到第8轮时，预测仍然错误，但整体准确率提高至71.5%。经过充分训练（第100轮）后，模型正确地将信号识别为空洞，分类准确率提升至93.5%。这些结果表明，残差网络逐步提取具有判别性的光谱特征最终从指纹中提取这些特征，即使在较远距离下信噪比较低，仍能实现稳健识别。

训练动态如图3(b–c)所示。由于信噪比极低，模型需要近 50 轮次才能收敛，学习曲线在稳定之前呈现明显振荡。最终，训练准确率接近 100%，而验证准确率则始终稳定在约 94%，表明模型学习效果良好，但泛化能力有限。图3(d)中的 t-SNE 可视化进一步体现了这一趋势：四个信号类别仍然可以区分，但各簇显得不够紧凑且部分重叠，这表明噪声污染降低了潜在空间中的类别可分性。总的来说，这些结果表明存在轻微过拟合：模型能够很好地拟合训练集，但对未见数据的泛化能力有限。主要原因并非训练样本不足，因为两个数据集都包含 1000 个信号，而是

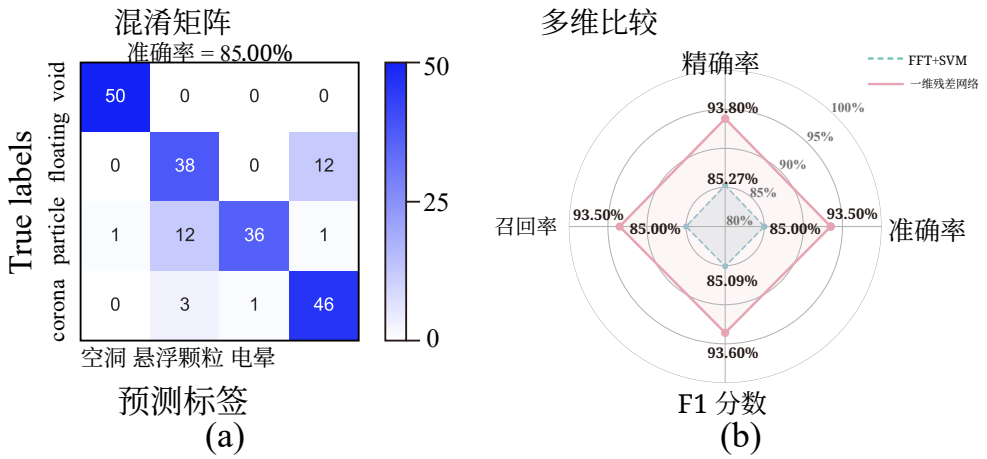

图 4. **经典基线与深度学习方法的性能比较。** (a) FFT+SVM 基线的混淆矩阵，显示悬浮放电与微粒放电之间存在明显的误分类。(b) FFT+SVM（虚线）与一维残差网络（实线）在四项评估指标上的多维比较雷达图，展示了深度学习方法的综合优势。

较远距离下信噪比降低，削弱了判别性特征的显著性。因此，当关键特征被噪声淹没时，学习任务本身会变得更加困难，最终可达到的性能受输入信号物理质量的限制，而非数据量或网络容量。

为严格验证网络的性能是由学习到的物理特征驱动，而非过拟合所致，我们将一维残差网络与经典 FFT+SVM 基线进行了比较。如图4(a) 所示，SVM 基线达到了 85% 的可靠准确率，证实即使在低信噪比条件下，里德伯数据集仍包含具有物理信息的指纹。然而，混淆矩阵表明，经典方法难以区分“悬浮放电”和“微粒放电”，这两类放电导致了大多数误分类。

至关重要的是，我们的深度学习模型显著优于这一基准，准确率高出 8.5%，且在所有类别中均取得了近乎一致的提升。图4(b) 中的多维比较直观地总结了这一全面优势：一维残差网络的轮廓在所有指标（准确率、精确率、召回率和 F1分数）上均完全包围基准模型。这一比较表明，前文观察到的簇紧凑性方面的挑战源于信号固有的物理复杂性，而非模型过拟合。结果表明，残差网络能够有效捕捉里德伯指纹中的复杂非线性依赖，而这些依赖无法通过标准频谱分析获取，从而证明了所提出的深度学习架构的必要性。

C. 基于光谱指纹的早期预警

为评估将频谱指纹识别应用于实际监测场景的可行性，我们进行了早期预警模拟。图5(a) 展示了在 30厘米处测得的一种典型空洞型局部放电时域波形。我们提取了一个可变时间窗 Δt，并将其用作模型输入，预测准确率如图5(b) 所示。结果显示，预测准确率明显取决于观测时间：较短的时间窗提供的判别信息有限，而随着 Δt 增大，准确率迅速提高，并在 $\Delta t \geq 30$ ms 时超过 90%。这一现象表明，即使仅对光谱指纹进行部分采样，其中仍包含足以实现可靠识别的独特特征，凸显了基于里德伯原子的传感方案具有良好的鲁棒性。

为模拟真实的预警场景，我们进一步构建了一个复合信号，其中空洞型放电嵌入随机噪声中，如图5(c)所示。模型预测结果如图5(d)所示，并映射到 0（绿色）至 1（红色）的概率尺度，其中 0.5 定义为报警阈值。模型输出的概率呈现高度极化：放电事件的得分始终接近 1，而噪声的得分接近 0。这种明显的区分验证了在当前设置中，0.5 是生成预测性警报的有效截断值。此外，在实际应用中，该阈值可以调整，从而灵活权衡精确率与召回率，以适应不同的运行环境。

为验证预警机制的可靠性，我们进一步分析了图中与放电事件和非放电事件相对应的代表性片段。5(e–f)。配套的注意力图揭示了对模型决策影响最大的时间区域。

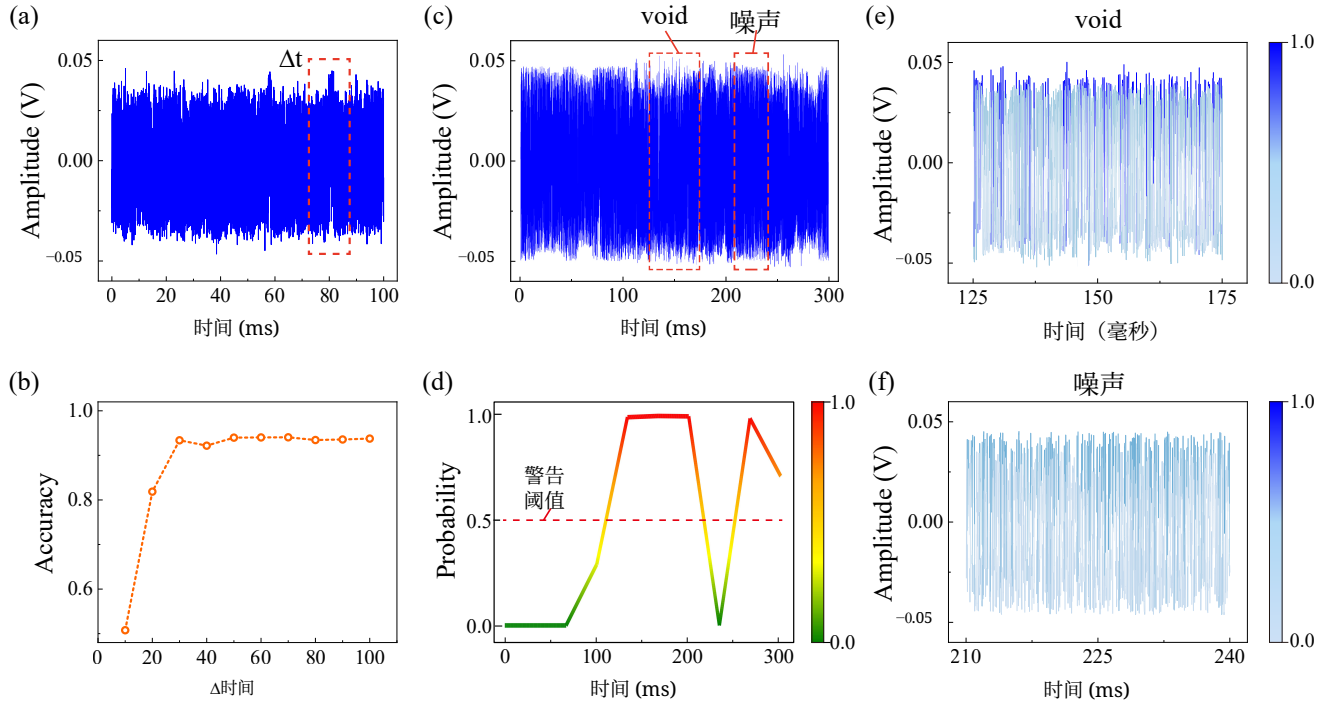

图5。**局部放电信号的预测性能与预警**。(a) 在30厘米处测得的气隙型局部放电信号的时域波形。(b) 预测准确率随时间窗长度（Δt）的变化。(c) 由空穴信号和噪声组成的300毫秒信号。(d) (c)中所示信号用于预警检测时，概率随时间的变化，报警阈值设为0.5。(e-f) 空穴信号和噪声的显著性图。

值得注意的是，突出显示的区域与局部放电脉冲的特征瞬态相吻合。这一观察结果与我们的传感方法所依据的物理机制相符：原子交流斯塔克频移将光谱特征以物理方式编码到从里德堡传感器提取的时域波形中，从而形成了本研究所分析的“光谱指纹”。注意力权重与这些物理特征之间的对应关系有力地表明，模型并未依赖虚假相关性，而是正确识别了底层的光谱—时间指纹。

IV. 讨论

在本研究中，我们建立了一种识别框架，将里德伯原子传感与一维残差网络模型相结合，用于分析局部放电信号。通过将放电事件编码为光谱指纹，原子系统能够以宽带、非侵入的方式探测瞬态电磁场。利用该框架，我们实现了对四种具有代表性的局部放电类型进行分类，准确率约为 94%。该模型在不同时间窗口下也保持了较高的性能：当观测时间达到 30 ms 时，准确率超过 90 %，且在受噪声污染的条件下仍然有效。此外，早期预警仿真表明，放电事件可以借助基于概率的阈值与噪声可靠地区分开来，而注意力图则证实，模型的判定依据是具有物理意义的瞬态信号。

总之，我们证明，基于里德堡原子的光谱指纹技术结合深度学习，能够可靠地识别局部放电信号并进行预警，彰显了量子增强传感作为宽带、无创诊断工具的潜力。为充分发挥其固有的超宽带特性并尽量减少侵入性，未来的工作旨在以无天线全介电架构取代当前的金属天线耦合。此外，为促进系统在不同环境中的实际部署 [39–42]，例如存在可变负载或未知放电行为的环境 [43]，，系统可以采用增量学习或迁移学习策略 [44]。这些方法使预训练骨干网络能够利用少量新样本进行高效微调，从而快速适应复杂的真实场景，而无需进行大规模重新训练。

V. 方法

A. 深度学习层

我们的深度学习模型由一个一维卷积神经网络层、三个残差块层和一个全连接层 [45–47] 组成。该

模型关键组件的数学示意如下。

给定输入波形$\mathbf{x} \in \mathbb{R}^{1\times L}$，模型首先应用一个卷积干，由四种操作组成：一维卷积、批归一化 [48], ReLU 激活和最大池化。卷积层使用

$$z^c(n) = (\mathbf{x} \otimes W^c)(n) = \sum_{m=0}^{k-1} \mathbf{x}_{(n+m)} \cdot W^c_m, \tag{6}$$

其中，$\mathbf{x}$ 表示输入信号，W^c 是输出通道c的卷积核，m 是核索引，n 是输出时间索引。

随后依次应用批归一化和 ReLU，即 $\hat{z} = (z - \mu_B)/\sqrt{\sigma_B^2 + \epsilon}$，$y = \gamma\hat{z} + \beta$，以及$f(x) = \max(0, x)$。最后，使用大小为 3 的卷积核进行最大池化，计算如下：

$$y(m) = \max_{i\in[m,m+k-1]} x(i), \tag{7}$$

这会降低时间分辨率，同时保留显著特征。

网络的核心由三个堆叠的残差块组成。每个块包含两个卷积层（卷积核大小为 3），每层之后均应用批归一化和 ReLU。为缓解深层网络中的性能退化问题，残差连接将块的输入直接加到其输出上：

$$\mathbf{y} = \mathrm{ReLU}(z_2 + \boldsymbol{S}(\mathbf{x})), \tag{8}$$

其中，当维度匹配时，$\boldsymbol{S}(\mathbf{x}) = \mathbf{x}$；否则，$\boldsymbol{S}(\mathbf{x}) = \mathrm{BN}(\text{一维卷积}_{1\times1}(\mathbf{x}))$。

最终残差块的输出 $\mathbf{Z} \in \mathbb{R}^{C\times T}$ 经自适应平均池化处理，生成定长向量 $v_c = \frac{1}{T}\sum_{t=1}^{T} Z_{c,\,t}$，在我们的实现中得到 $\mathbf{v} \in \mathbb{R}^{C}$ with$C = 256$ 。最终预测通过全连接层获得：

$$\mathbf{y} = \mathbf{W} \cdot \mathbf{v} + \mathbf{b}, \tag{9}$$

然后经过 softmax 函数

$$\hat{y}_i = \frac{e^{y_i}}{\sum_{j=1}^{K} e^{y_j}}, \tag{10}$$

从而得到类别概率。

模型通过最小化分类交叉熵损失进行训练

$$\mathcal{L}_{CE} = -\sum_{i=1}^{K} y_i \log(\hat{y}_i), \tag{11}$$

其中，$y_i \in \{0, 1\}$ 是独热真实标签，$\hat{y}_i$ 是类别 i的预测概率。参数使用Adam优化器更新。

该网络使用 Python 3.12.6 [49] 上的 PyTorch 2.6.0 框架实现。所有权重均采用 PyTorch 默认方式初始化。深度学习模型的超参数（包括卷积核大小、通道数和学习率）根据验证性能进行经验调优。

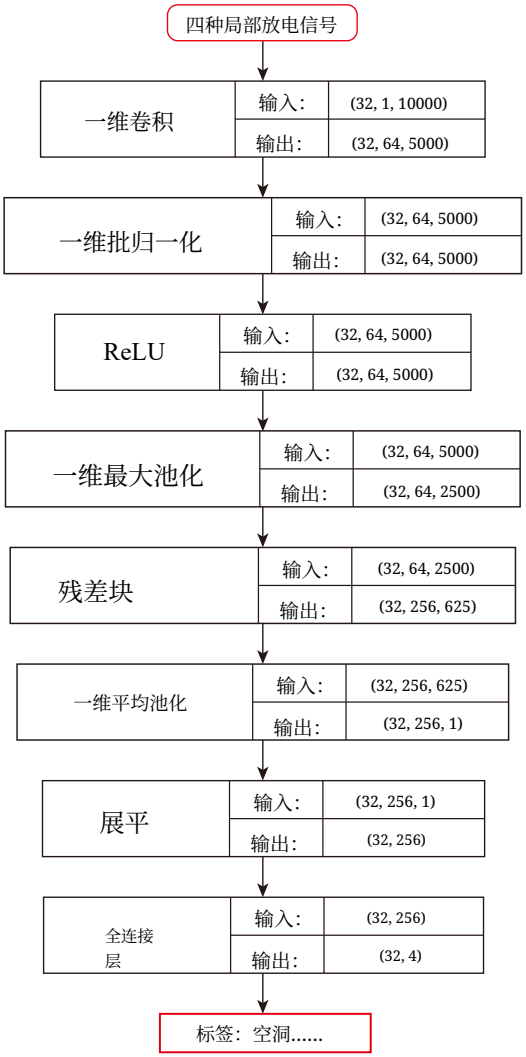

图6. **我们的深度学习模型结构和数据规模**。每个批次包含 32 个样本，输入形状为 (1, 10000)。该网络由卷积干、批归一化、ReLU、池化层、残差块和全连接输出层组成。特征维度逐步缩减，最终得到四分类输出。

B. 深度学习流程

为确保不同样本之间的一致性，所有原始波形信号均被重采样为固定长度的 10,000 个点。随后，使用标准化器对数据进行标准化，该标准化器在训练集上拟合并保存，以便在推理时保持分布对齐。标

签被编码为包含四个元素的独热向量，分别对应局部放电信号的四个类别。

深度学习模型的结构如图6所示。输入张量的格式为（批次大小、通道数、信号长度）。在我们的实现中，批次大小设为 32，通道数为 1，信号长度为 10,000，因此输入形状为（32, 1, 10000）。深度学习模型使用 Adam优化器训练 50 轮，初始学习率为 10^{-4} ，权重衰减为 10^{-5}。目标函数为分类交叉熵损失。

为提升泛化能力并加快收敛速度，我们采用了学习率调度器 $ReduceLROnPlateau$ 。每当验证损失连续 p 轮未下降时，学习率 η 便会按因子 γ降低：

$$\eta \leftarrow \gamma \cdot \eta \text{ if no improvement for } p \text{ epochs.} \tag{12}$$

在我们的实验中，设置为 $\gamma = 0.1$ 和 $p = 3$。在此配置下，该模型在我们的实验平台上通常能在 100 轮内收敛，耗时约 10 分钟。较低的时间成本有利于快速迭代模型，并支持潜在的现场更新。

使用分层抽样将数据集随机划分为训练集和验证集，比例为 80:20，以保持类别分布。在所有训练轮次中均使用相同的数据划分，以确保一致性。每轮训练中，模型在训练集上进行训练，并在验证集上进行评估。训练完成后，保存模型参数和拟合后的缩放器，以用于下游测试和部署。

C. 里德堡-EIT 相干性的电场调制

探测光和耦合激光以及外部局部放电场作用下三能级阶梯系统$\{|g\rangle, |e\rangle, |r\rangle\}$ 的动力学，由 Lindblad主方程支配

$$\dot{\rho} = -\frac{i}{\hbar}[H, \rho] + \mathcal{L}[\rho], \tag{13}$$

其中， ρ 为原子密度矩阵， $\mathcal{L}[\rho]$ 表示弛豫和退相干过程。

在旋转波近似下，系统的哈密顿量可写成矩阵形式：

$$H = \frac{\hbar}{2}\begin{pmatrix} 0 & \Omega_p & 0 \\ \Omega_p & -2\Delta_p & \Omega_c \\ 0 & \Omega_c & -2(\Delta_p + \Delta_c + \Delta_s) \end{pmatrix}, \tag{14}$$

其中，Ω_p 和 Ω_c 分别为探测光和耦合光的拉比频率， Δ_p 和 Δ_c 分别表示探测光和耦合光失谐， Δ_s 为局部放电场引起的交流斯塔克频移。斯塔克微扰近似为

$$\Delta_s(t) \approx \alpha(\omega)|E_t(t)|^2, \tag{15}$$

其中， $\alpha(\omega)$为频率相关的极化率，$E_t(t)$为局部放电场的振幅。

在弱探测极限（$\Omega_p \ll \Omega_c,\ \gamma$）下求解主方程，得到 $|g\rangle$与 $|e\rangle$ 之间的稳态相干性，表达式为

$$\rho_{ge}(\Delta_p, t) = \frac{i\Omega_p/2}{\gamma_{eg} - i\Delta_p \dfrac{|\Omega_c|^2/4}{\gamma_{rg} - i(\Delta_p + \Delta_c + \Delta_s(t))}}, \tag{16}$$

介质的线性极化率可表示为

$$\chi(\Delta_p, t) = \frac{N|d_{ge}|^2}{\varepsilon_0 \hbar}\rho_{ge}(\Delta_p, t), \tag{17}$$

其中， N 为原子密度， d_{ge} 为探测跃迁的偶极矩阵元。

最后，探测光透过长度为 L的蒸气池后的透射率表示为

$$T(\Delta_p, t) = \exp\left[-kL\mathrm{Im}\chi(\Delta_p, t)\right], \tag{18}$$

其中 k 为探测光波数。

[1]G. A. Hussain、W. Hassan、F. Mahmood、M. Shafiq、H. Rehman 和 J. A. Kay，《电力系统中高压设备局部放电诊断技术综述》，IEEE Access **11**，51382 (2023)。[2] J. K. R. Wong、H. A. Illias、A. H. A. Bakar 和 H. Mokhlis，《局部放电分类：近期进展综述》，Measurement**68**，164 (2015)。[3] G. Robles、J. M. Fresno、J. M. Martínez-Tarifa， *et al.*《使用粒子群优化对高频、甚高频和特高频频段的局部放电频谱进行表征》，Sensors **18**，10339018030746 2018。/s( )。[4] R. A. M. Dalila 和 A. K. Turkben，《基于人工智能的局部放电检测，采用卷积神经网络和

用于提高电气绝缘质量的 K近邻算法，《发现计算》**28**，101（2025）。[5] D. Evagorou、A. Kyprianou、P. L. Lewin、A. Stavrou、V. Efthymiou、A. C. Metaxas 和 G. E. Georghiou，使用小波包变换提取局部放电信号特征，并通过概率神经网络进行分类，IET Science, Measurement & Technology **4**，177（2010）。[6] Y. Wang、H. dong Chiang 和 N. Dong，基于希尔伯特–黄变换特征的电力线路局部放电识别，Energies **15**，6521（2022）。[7] K.-Y. Liao、H.-T. Tu、S.-Z. Yang、C.-J. Chen、X.-H. Liu、J. Liang、X.-D. Zhang、H. Yan 和 S.-L. Zhu，微波

利用冷里德堡原子中的电磁诱导吸收进行电测量，《物理评论 A》101，053432（2020）。[8] M. Fleischhauer、A. Imamoglu 和 J. P. Marangos，电磁诱导透明：相干介质中的光学，《现代物理评论》77，633（2005）。[9] T. Y. Abi-Salloum，电磁诱导透明与 Autler–Townes 劈裂：三能级原子系统两类中的两种相似但不同的现象，《物理评论 A》81，053836（2010）。[10] C. J. Foot，《原子—光子相互作用》（John Wiley & Sons, Ltd，1998），第 641–643 页。[11] S. H. Autler 和 C. H. Townes，快速变化场中的斯塔克效应，《物理评论》100，703（1955）。[12] P. Bohlouli-Zanjani、J. A. Petrus 和 J. D. D. Martin，利用交流斯塔克频移增强里德堡原子相互作用，《物理评论快报》98，203005（2007）。[13] C. Holloway、J. Gordon 和 G. Raithel，宽带里德堡原子电场探测器：用于国际单位制溯源、且可自校准的测量，《IEEE 天线与传播汇刊》62，6169（2014）。[14] M. G. Bason 和 C. S. Adams，射频场缀饰里德堡暗态的电场灵敏度增强，《新物理学杂志》12，065015（2010）。[15] B. Liu、L.-H. Zhang、Z.-K. Liu、Z.-Y. Zhang、Z.-H. Zhu、W. Gao、G.-C. Guo、D.-S. Ding 和 B.-S. Shi，利用里德堡原子传感器高灵敏度测量兆赫兹射频电场，《物理评论应用》18，014045（2022）。[16] D. H. Meyer 和 K. C. e. a. Cox，评估里德堡原子用于宽带电场传感的性能，《物理学杂志 B》53，034001（2020）。[17] D. H. Meyer、P. D. Kunz 和 K. C. Cox，0 至 20 吉赫兹波导耦合里德堡频谱分析仪，《物理评论应用》15，014053（2021）。[18] Q.-F. Wang 和 L.-H. e. a. Zhang，基于里德堡原子的电弧射频信号测量，《物理评论应用》24，014006（2025）。[19] L.-H. Zhang、B. Liu、Z.-K. Liu、Z.-Y. Zhang、S.-Y. Shao、Q.-F. Wang、Y. Ma、T.-Y. Han、G.-C. Guo、D.-S. Ding 和 B.-S. Shi，基于空分复用射频芯片模块的超宽带双频段里德堡原子接收器，《Chip》3，100089（2024）。[20] C. Holloway、M. Simons、J. Gordon、G. Raithel 和 D. Anderson，面向国际单位制溯源的电场计量：原子蒸气中电磁诱导透明的系统测量不确定度，《应用物理学杂志》（2017）。[21] J. A. Sedlacek、A. Schwettmann、H. K¨ubler、R. L¨ow、T. Pfau 和 J. P. Shaffer，使用蒸气池中的里德堡原子和明亮原子共振进行微波电测量，《自然·物理》8，819（2012）。[22] K. He、X. Zhang、S. Ren 和 J. Sun，面向图像识别的深度残差学习，载于 *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*（2016），第 770–778 页。[23] H. I. Fawaz、G. Forestier、J. Weber 和 L. I. et al.，时间序列分类的深度学习：综述，《数据挖掘与知识发现》33，917（2019）。[24] H. I. Fawaz、B. Lucas 和 G. F. et al.，InceptionTime：为时间序列分类寻找 AlexNet，《数据挖掘与知识发现》34，1936（2020）。[25] F. Pedregosa、G. Varoquaux、A. Gramfort 和 et al.，Scikit-learn：Python 机器学习，《机器学习研究杂志》12，2825（2011）。[26] Q. Song、X. Zhou、Y. Zhang、X. Chen、W. Lei、S. Huang 和 Z. Deng，基于1D ResNet-SE的多通道网络实现实时、普适的雷达目标分类，《遥感》16，10.3390/rs16213986（2024）。[27] Y. Mao、W. Ren 和 Z. Yang，基于 SEP-ResNet 的雷达信号调制识别，Sensors 21，7474（2021）。[28] Z.-K. Liu、L.-H. Zhang、B. Liu、Z.-Y. Zhang、G.-C. Guo、D.-S. Ding 和 B.-S. Shi，深度学习增强的里德堡多频微波识别，《自然·通讯》13，1997（2022）。[29] B. Orazbayev 和 R. Fleury，利用深度学习实现远场亚波长声学成像，《物理评论 X》10，031029（2020）。[30] M. Khanahmadi 和 K. Mølmer，利用循环神经网络进行时变原子磁力测量，《物理评论 A》103，032406（2021）。[31] T. Giordani、A. Suprano 和 E. P. 等，基于机器学习的矢量涡旋光束分类，《物理评论快报》124，160401（2020）。[32] Z. Liu、S. Yan 和 H. L. 等，深度学习方法辅助的光学涡旋模式超高分辨率识别，《物理评论快报》123，183902（2019）。[33] P. B. Wigley、P. J. Everitt、A. van den Hengel 等，超冷原子实验的快速机器学习在线优化，《科学报告》6，25890（2016）。[34] R. Mukherjee、H. Xie 和 F. Mintert，里德堡晶格中 Greenberger-Horne-Zeilinger态的贝叶斯最优控制，《物理评论快报》125，203603（2020）。[35] A. D. Tranter、H. J. Slatyer 和 M. R. H. 等，利用深度学习对磁光阱进行多参数优化，《自然·通讯》9，4360（2018）。[36] K. Mills、P. Ronagh 和 I. Tamblyn，利用强化学习寻找自旋哈密顿量的基态，《自然·机器智能》2，509（2020）。[37] Z. T. Wang、Y. Ashida 和 M. Ueda，量子倒立摆的深度强化学习控制，《物理评论快报》125，100401（2020）。[38] M. Bukov、A. G. R. Day 和 D. S. 等，量子控制不同阶段中的强化学习，《物理评论 X》8，031086（2018）。[39] T. Zhang、P. Ren 和 Z. Ren，用于可靠轻量级设备识别的深度无线电指纹 ResNet，载于*Proc. IEEE Veh. Technol. Conf. (VTC-Fall)*（2021），第1–6页。[40] N. Soltanieh 和 Y. N. 等，射频指纹技术综述，《IEEE射频识别期刊》（2020）。[41] G. Shen 和 J. Z. 等，由无监督对比学习驱动的联邦射频指纹识别，《IEEE信息取证与安全汇刊》10.1109/TIFS.2024.xxxxxx（2024）。[42] J. Zhang 和 G. S. 等，面向长度适应性与抗噪性的射频指纹识别，《IEEE信息取证与安全汇刊》10.1109/TIFS.2023.xxxxxx（2023）。[43] J. Hu、L. Shen 和 G. Sun，挤压 - 激励网络，载于 *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*（2018），第7132–7141页。[44] D. Sahoo、Q. Pham 和 J. L. 等，在线深度学习：即时学习深度神经网络，载于 *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence, IJCAI-18*（国际人工智能联合会议组织，

2018），第2660–2666页。[45] N. Srivastava、G. Hinton 和 A. e. a. Krizhevsky，Dropout：一种防止神经网络过拟合的简单方法，载于 *Journal of Machine Learning Research*，第15卷（2014），第1929–1958页。[46] G. Huang、Z. Liu 和 L. e. a. Van Der Maaten，密集连接卷积网络，载于 *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* 2017 4700 4708 （），第–页。[47] L. Wan、M. Zeiler 和 S. e. a. Zhang，使用 DropConnect 对神经网络进行正则化，载于 *Proceedings of the 30th International Conference on Machine Learning (ICML)* (2013) 第1058–1066页。[48] S. Ioffe 和 C. Szegedy，《批归一化：通过减少内部协变量偏移加速深度网络训练》，载于 *International Conference on Machine Learning (ICML)* 2015 448 456 (PMLR，)第–页。[49] J. Ansel、E. Yang、H. He 等人，《Pytorch 2：通过动态Python字节码转换和图编译加速机器学习》，载于 *Proceedings of the 29th ACM International Conference on Architectural Support for Programming Languages and Operating Systems (ASPLOS '24)* 2024 ()。