

基于无标签分类的波形光子计数研究

刘凯楠, 黄桂鸿*

五邑大学应用物理与材料学院, 广东 江门

收稿日期: 2026年4月15日; 录用日期: 2026年5月13日; 发布日期: 2026年5月22日

摘要

光电倍增管(PMT)广泛应用于粒子物理的光子探测。PMT波形重建精度直接影响探测器的空间与能量分辨性能。当多个光子在纳秒级时间窗口内相继到达时, 如何有效分辨单光子成为一个关键挑战。传统波形重建方法因依赖探测器的先验知识而性能受限; 监督深度学习方法虽性能上更优, 但在实际应用中往往难以获取光子真值标签, 制约了其推广。为此, 研究提出一种基于无标签分类(CWoLa)理论的弱监督波形光子计数方法, 利用两组混合样本的统计分布差异训练分类器, 并设计级联二分类框架, 实现无样本级真值标签的PMT波形光子计数重建。利用蒙特卡洛模拟的纯净度分别为100%和95%的波形样本对所提方法进行验证, 实验结果表明, 该方法的噪声鉴别准确率达99.89%, 在1~3 p.e.的低光子数区间分类准确率超过89%; 在1~10 p.e.的光子数区间, 重建分辨率显著优于传统电荷估计方法, 性能接近全监督训练下的ResNet50模型, 且在训练样本轻度污染下仍保持强鲁棒性。研究为大型粒子物理实验中普遍存在的缺乏真值标签的PMT波形分析问题提供了一条新颖有效的弱监督技术路径。

关键词

PMT波形, 无标签分类, 噪声鉴别, 光子计数

Research on Waveform Photon Counting Based on Classification Without Labels

Kainan Liu, Guihong Huang*

School of Applied Physics and Materials, Wuyi University, Jiangmen Guangdong

Received: April 15, 2026; accepted: May 13, 2026; published: May 22, 2026

Abstract

Photomultiplier tubes (PMTs) are widely used in particle physics for photon detection. The accuracy of PMT waveform reconstruction directly affects the spatial and energy resolution of detectors. A key

*通讯作者。

challenge arises when multiple photons arrive within a nanosecond-scale time window, making it difficult to resolve individual photoelectrons. Conventional waveform reconstruction methods are limited by their reliance on prior knowledge of the detector, and although supervised deep learning methods achieve superior performance, their practical application is hindered by the difficulty of obtaining ground-truth photon information in real data. To address this issue, this paper proposes a weakly supervised waveform photon counting method based on the Classification Without Labels (CWoLa) theory. The method trains a classifier using only the statistical distribution difference between two mixed samples and designs a cascaded binary classification framework, enabling photon counting reconstruction of PMT waveforms without sample-level ground-truth labels. Validation using waveform samples with purities of 100% and 95% generated by Monte Carlo simulations shows that the proposed method achieves a noise discrimination accuracy of 99.89%, maintains a classification accuracy above 89% in the low photon count region (1~3 p.e.), and significantly outperforms traditional charge estimation methods in terms of reconstruction resolution across the photon count range of 1~10 p.e., with performance approaching that of the fully supervised ResNet50 model while maintaining strong robustness under mild training sample contamination. This study provides a novel and effective weakly supervised technical pathway for PMT waveform analysis in large-scale particle physics experiments where ground-truth labels are unavailable.

Keywords

PMT Waveform, Classification Without Labels, Noise Discrimination, Photon Counting

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

近年来, 中微子探测实验取得多项突破性进展: Daya Bay 实验精确测量了 θ_{13} [1]; T2K [2]和 NOvA [3]发现中微子电荷 - 宇称(CP)破坏的强烈证据; IceCube [4]和 ORCA [5]相继探测到超高能中微子事件。在此背景下, 液闪基中微子实验 JUNO [6]旨在通过反应堆中微子振荡研究解决中微子质量顺序问题; 水基中微子实验 Hyper-K [7]和 ARCA [8]则通过加速器或大气中微子振荡, 进一步探索质量顺序与 CP 破坏相角。JUNO 对能量分辨率要求极高, Hyper-K 则同时对能量和方向分辨率提出严苛要求。在此类水基和液闪基实验中, 光电倍增管(PMT)作为核心光子探测器, 其输出的光子计数直接决定事例能量的重建质量。

传统的 PMT 波形重建方法主要包括波形拟合与反卷积。波形拟合技术通过匹配预期波形与观测波形反推原始信号, 如 IceCube 采用的 Lawson-Hanson 非负最小二乘法[9]及文献[10]提出的基于 FSMP 的贝叶斯随机采样方法。反卷积技术则通过抑制电子学噪声并去除系统响应来还原原始信号, 如 Daya Bay 提出的基于高斯滤波的反卷积方法[11]及文献[12]中开发的基于短时傅立叶变换的反卷积技术。与简单的过阈法相比, 这些方法在低光子密度场景下能够有效提升电荷和光子数的重建精度, 但其性能高度依赖于探测器的先验知识(如响应函数和噪声模型), 且在处理纳秒级时间间隔内的多光子重叠信号时, 分辨率显著下降。

以深度学习为代表的机器学习技术凭借强大的高维特征提取与复杂模式识别能力, 为 PMT 波形重建开辟了新的技术路径。研究表明, 基于监督学习的卷积神经网络(CNN)能够显著提升光子数重建精度, 进而改善 JUNO 实验的能量分辨率[13]。然而, 监督学习方法高度依赖光子真实标签, 在实际实验中, 此类

标签难以通过物理手段直接获取。

本文首次将无标签分类(CWoLa)的核心思想引入 PMT 波形噪声鉴别任务。通过构建两组具有固定信噪比差异的混合波形样本集, 训练分类神经网络区分这两组混合样本, 从而在无需单样本真值标签的情况下, 实现信号与噪声的弱监督鉴别。基于该任务的核心原理, 本研究进一步提出了级联二分类光子计数框架, 将多光子计数任务拆解为一系列串行的二分类子任务, 理论上具备弱监督光子数重建能力。本研究基于蒙特卡洛模拟生成的纯净度分别为 100% 和 95% 的 k p.e. 波形样本, 结合多光子混合的波形样本, 验证了该框架的理论可行性与鲁棒性。

本文结构安排如下: 第二节介绍 CWoLa 理论基础与 PMT 波形样本构建方法; 第三节描述网络结构与参数设置; 第四节给出两项实验设计与结果分析; 第五节为结论与展望。

2. 理论基础与 PMT 波形构建

2.1. CWoLa 理论基础

CWoLa 是本研究弱监督波形分析的核心理论基础, 该方法由 Metodiev 等人于 2017 年在高能物理领域提出[14]。其核心在于: 在无需单样本真值标签的条件下, 仅利用两组混合样本的统计分布差异, 即可训练出与全监督学习等价的最优二分类器。该方法适用于真实实验中难以获取事例真值标签的场景。

传统二分类任务依赖于标记信号(S)和背景(B)的样本, 以学习最优分类器。CWoLa 则通过构造两组混合样本 M_1 和 M_2 , 其信号占比分别为 f_1 和 f_2 且满足 $f_1 > f_2$ 。将 M_1 和 M_2 作为两个类别进行完全监督训练, 所得分类器可直接应用于区分 S 与 B, 无需额外调整。

根据 Neyman-Pearson 引理, 二分类任务的最优分类器由似然比决定。设 \bar{x} 为分类可观测量(本研究中为 PMT 波形), $p_S(\bar{x})$ 和 $p_B(\bar{x})$ 分别为信号和背景的概率密度分布, 则 S 与 B 的最优分类器为:

$$h_{\text{optimal}}(\bar{x}) = \frac{p_S(\bar{x})}{p_B(\bar{x})} \quad (1)$$

通过阈值 c 对分类器 h 输出 $h(\bar{x})$ 做决策($h(\bar{x}) > c$ 判定为信号 S, 反之判定为背景 B)。由此可定义其信号效率 ε_S 与背景误判率 ε_B :

$$\varepsilon_S(h) = \int p_S(\bar{x}) \theta(h(\bar{x}) - c) d\bar{x} \quad (2)$$

$$\varepsilon_B(h) = \int p_B(\bar{x}) \theta(h(\bar{x}) - c) d\bar{x} \quad (3)$$

其中, $\theta(\cdot)$ 为 Heaviside 阶跃函数。分类器的性能可通过其接收器工作特征(ROC)曲线表征, 该曲线反映了 $\varepsilon_B(h)$ 和 $\varepsilon_S(h)$ 之间的函数关系。若对于任何其他分类器 h' , 在相同 ε_S 下均有 $\varepsilon_B(h') \geq \varepsilon_B(h)$, 则称分类器 h 是最优的。因此, 实现无标签分类的核心目标是学习到与最优似然比 $h_{\text{optimal}}(\bar{x})$ 单调相关的分类器。

CWoLa 的理论依据在于: 区分混合样本 M_1 与 M_2 的最优分类器, 与区分样本 S 与 B 的最优分类器完全等价。两组混合样本的概率分布可表示为:

$$p_{M_1}(\bar{x}) = f_1 p_S(\bar{x}) + (1 - f_1) p_B(\bar{x}) \quad (4)$$

$$p_{M_2}(\bar{x}) = f_2 p_S(\bar{x}) + (1 - f_2) p_B(\bar{x}) \quad (5)$$

其中, $f_1 > f_2$ 。区分 M_1 与 M_2 和区分 S 与 B 的最优分类器均为二者的似然比:

$$L_{M_1/M_2}(\bar{x}) = p_{M_1}(\bar{x}) / p_{M_2}(\bar{x}) \quad (6)$$

$$L_{S/B}(\bar{x}) = p_S(\bar{x}) / p_B(\bar{x}) \quad (7)$$

在 $p_B(\bar{x}) \neq 0$ 的前提下(即混合样本包含背景样本), 可对两个似然比做代数变换:

$$L_{M_1/M_2} = \frac{p_{M_1}}{p_{M_2}} = \frac{f_1 p_S + (1-f_1) p_B}{f_2 p_S + (1-f_2) p_B} = \frac{f_1 L_{S/B} + (1-f_1)}{f_2 L_{S/B} + (1-f_2)} \quad (8)$$

对该式求关于 $L_{S/B}$ 的偏导数, 可得:

$$\frac{\partial L_{M_1/M_2}}{\partial L_{S/B}} = \frac{(f_1 - f_2)}{(f_2 L_{S/B} - f_2 + 1)^2} \quad (9)$$

由于分母恒大于 0, 且满足 $f_1 > f_2$, 因此该偏导数恒大于 0。这表明: L_{M_1/M_2} 是 $L_{S/B}$ 的严格单调递增函数, 二者具有完全等价的分类判别能力, 即 CWoLa 训练所得分类器等价于全监督下的最优分类器。

2.2. PMT 波形样本构建

为给后续模型训练与性能评估提供带真值标签的数据基础, 本研究采用电子学蒙特卡洛模拟(EMCS)方法生成 PMT 波形数据集。模拟参考 JUNO 和大亚湾实验探测器的关键参数, 引入液闪发光时间谱、单光电子(SPE)波形形状、单光电子电荷分布及噪声水平, 使波形特征贴近真实实验场景。

SPE 波形参考大亚湾实验的测量结果[11], 由主峰、过冲和反射峰三部分构成; 液闪发光时间谱采用四指数衰减模型描述[15], 如图 1 所示。该时间分布弥散越小, 光子数越多, 波形重叠概率越高。

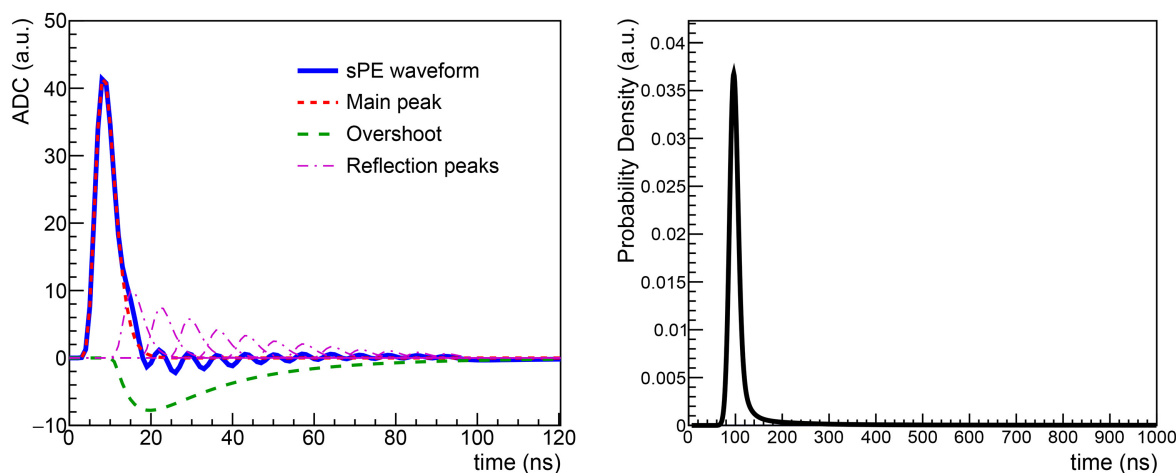


Figure 1. Single-photoelectron waveform template (left) and probability density function of liquid scintillation time distribution (right)

图 1. 单光电子波形模板(左图)与液闪发光时间分布的概率密度函数(右图)

EMCS 通过仿真光子数分布、单光电子的时间分布、波形形状、电荷分布和噪声频谱构建波形, 其过程可分为以下四个步骤:

- 1) 光子数和到达时间模拟: 根据预设分布随机抽样生成光子数及各光子的击中时间, 作为模拟真值;
- 2) 波形卷积处理: 每个光子与 SPE 波形模板卷积, SPE 幅度服从 30%分辨率的高斯分布;
- 3) 噪声与基线叠加: 添加标准差为 0.7 mV 的白噪声来模拟电子学噪声, 基线偏移设为零;
- 4) 波形数字化: 模拟波形以 1 GHz 采样率、10 位 ADC 精度进行数字化处理, 遵循舍入原则。

基于上述方法, 可构建两类真实实验情景下的波形数据集: 一是光子时间服从液闪发光时间分布, 光子数服从均值为 1 p.e.的泊松分布, 并叠加均值为 0.03 p.e.的泊松分布的暗噪声(光子时间服从均匀分布), 该数据集光子时间弥散少, 光子数范围小, 重叠程度低, 对应典型的单事例物理情形, 命名为“LT-

1PE”；二是光子时间服从液闪发光时间分布，光子数服从 0~10 p.e. 的均匀分布，该数据集光子数范围广，重叠程度高，对应多光强事例混合的情形，命名为“LT-UPE”。两类数据集将分别用于模型的训练与性能评估。

3. 网络结构及其参数设置

3.1. 一维 CNN 模型设计

CWoLa 框架的分类性能取决于基础分类器对 PMT 波形特征的提取能力。针对一维时域波形的特点，并兼顾 CWoLa 训练对分类器轻量、易收敛、泛化性强的需求，本研究设计了 6 层堆叠的一维 CNN 作为统一的基础二分类器，其网络结构如图 2 所示。网络以长度为 1000 的一维 PMT 采样波形为输入，输出两组混合样本的二分类概率。网络主体由 6 组卷积特征提取模块串联构成，每组模块包含一维卷积层(Conv1D)、ReLU 激活函数、批归一化层(Batch Normalization)与一维最大池化层(MaxPooling1D)。首个卷积模块采用 15×1 大尺寸卷积核，用于捕捉波形的大范围时域轮廓特征(如脉冲整体形态)；后续 5 组卷积模块均采用 3×1 小尺寸卷积核，提取光子脉冲上升沿、下降沿、脉冲重叠等局域精细特征。池化操作压缩特征维度，增强特征平移不变性并控制参数量，规避过拟合风险。多维特征经扁平层(Flatten)展开为一维特征向量后，接入以 Softmax 激活函数的全连接层，输出二分类概率，完成 CWoLa 框架下的混合样本二分类任务。

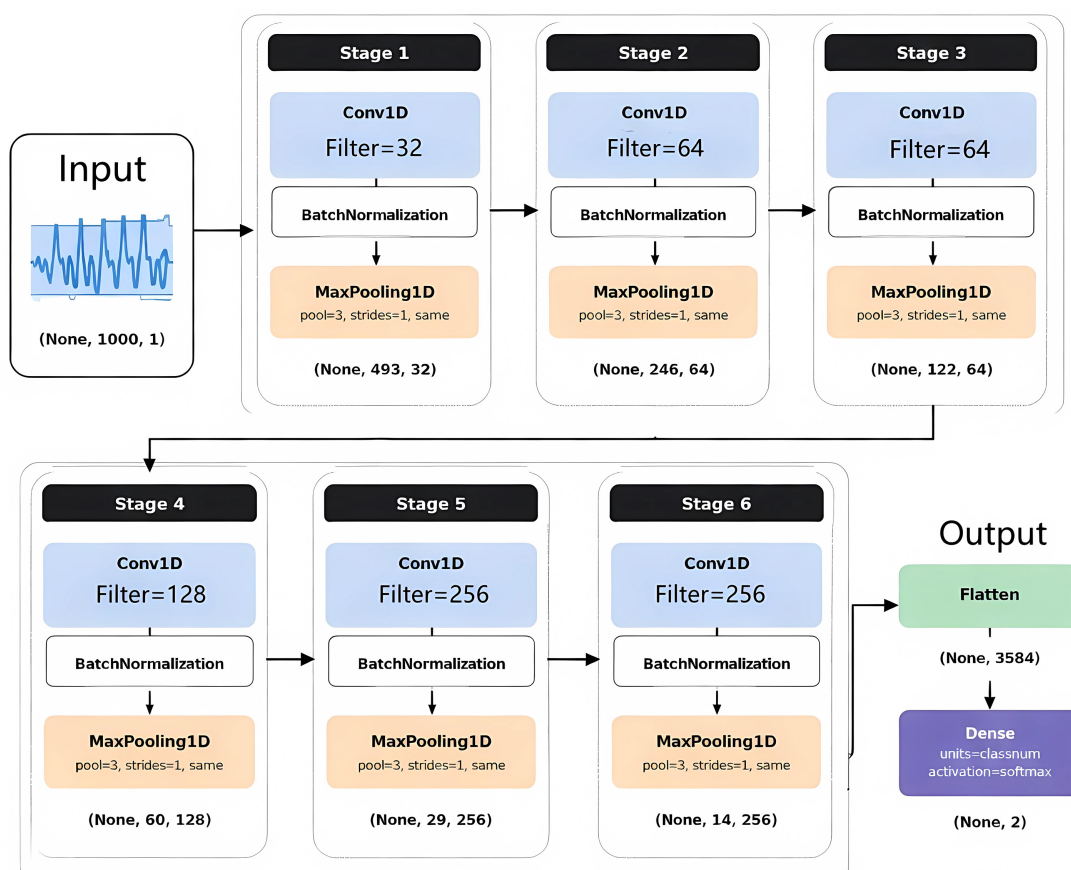


Figure 2. Complete forward propagation architecture of the 1D CNN

图 2. 一维 CNN 网络的完整前向传播结构

为保障 CWoLa 训练的收敛稳定性与实验可复现性，所有网络超参数均经预实验优化确定，核心配置

如表 1 所示。网络通道宽度配置为[32, 64, 64, 128, 128, 256], 通过逐层提升滤波器数量, 实现特征的层级化抽象; 权重采用 Glorot 均匀分布初始化, 保证各层输入输出方差一致, 缓解梯度消失问题; 优化器选用 Adam, 配合余弦衰减学习率调度策略(初始学习率为 0.02, 衰减步数 50000 步), 兼顾训练初期的收敛速度与后期的稳定性; 损失函数采用分类交叉熵(Categorical Crossentropy), 适配 Softmax 输出的二分类任务; 批次大小固定为 128, 最大训练轮次设为 100 轮, 保证模型充分收敛。本研究所有 CWoLa 二分类实验均采用上述统一的网络架构与超参数配置, 确保实验变量唯一、结果可比且可复现。

Table 1. Hyperparameter settings of the 1D CNN

表 1. 一维 CNN 的超参数设置

Parameter	Value
Optimizer	Adam
Learning Rate Strategy	Cosine Decay
	Learning Rate = 0.02
	Decay Steps = 50000
	Alpha = 0.00
Loss Function	Categorical Crossentropy

3.2. 基准模型: ResNet50

为评估所提方法的性能, 选取 ResNet50 [16]作为全监督基准模型。ResNet50 通过残差连接缓解梯度消失问题, 适用于深层特征学习。为适配一维波形数据, 将原始结构中的二维卷积与池化均替换为一维形式(如 3×3 卷积核改为 3×1), 瓶颈残差块结构保持不变。输出端采用全局平均池化后连接全连接层, 实现多分类输出。

适配一维波形任务的 ResNet50 的超参数配置详见表 2。网络训练采用 AdamW 优化器, 并设置权重衰减系数为 10^{-4} , 初始学习率设为 1×10^{-3} , 以在深层残差架构中兼顾收敛稳定性与正则化效果; 同时, 引入动态衰减学习率调度策略, 使模型在训练后期能更精细地收敛。此外, 为抑制异常梯度峰值, 施加了轻量级梯度裁剪, 梯度裁剪阈值为 0.1。批次大小为 256; 训练轮次为 100; 损失函数选用稀疏分类交叉熵。

Table 2. Hyperparameter configuration of the ResNet50 baseline model

表 2. ResNet50 基线模型的超参数配置

Parameter	Value
Optimizer	AdamW (Betas: $\beta_1 = 0.9, \beta_2 = 0.999$; Weightdecay: 10^{-4})
Learning Rate Strategy	ReduceLROnPlateau (Learning Rate: 1×10^{-3} ; Factor: 0.5; Patience: 5)
Activation	ReLU
Loss Function	Sparse Categorical Crossentropy
Gradient Clipping	0.1

4. 实验设计和结果分析

前文阐述了 CWoLa 弱监督分类理论及适配 PMT 波形特征提取的一维 CNN 基础分类器架构。CWoLa 方法最初应用于高能物理领域的夸克与胶子喷注鉴别任务, 本研究将 CWoLa 方法迁移至 PMT 波形分析, 开展 PMT 波形的噪声鉴别与光子计数两项任务。

4.1. 噪声鉴别

噪声鉴别旨在区分纯噪声波形(0 p.e.)与含光子信号的波形(≥ 1 p.e.)，是 PMT 波形光子计数重建的基础。本节基于 CWoLa 理论构建弱监督二分类框架，通过多组对照实验量化混合样本信号占比差异对分类性能的影响，并与全监督学习的性能上限进行对比。

4.1.1. CWoLa 二分类框架

基于 CWoLa 单调等价性理论，构建适配于 PMT 波形噪声鉴别的二分类框架，完整流程如图 3 所示，分为训练与推理两个核心阶段：

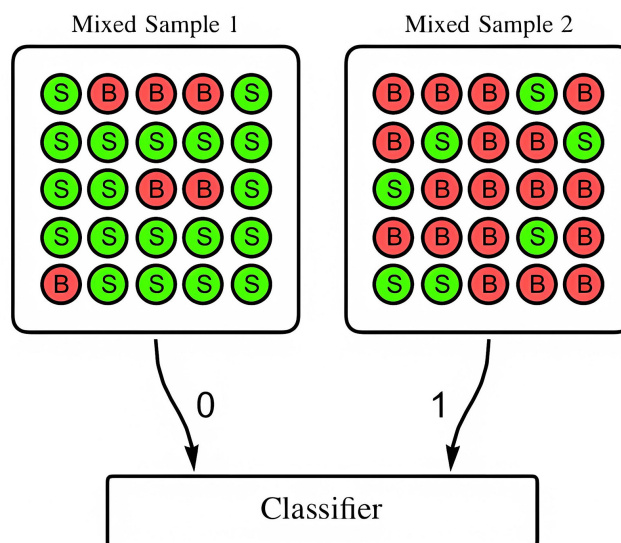


Figure 3. Schematic of the CWoLa binary classification framework [14]

图 3. CWoLa 二分类框架[14]

1) 训练阶段：制备两组混合样本 M_1 和 M_2 ，均由纯噪声(B)与信号波形(S)混合而成，两者的信号占比分别为 f_1 和 f_2 且满足 $f_1 > f_2$ 。将 M_1 全部样本标记为 0， M_2 全部样本标记为 1，拼接后作为训练集，采用全监督范式训练一维 CNN 基础分类器。训练全程无需使用单样本的真值标签，也无需精确已知 f_1 、 f_2 ，仅需保证二者存在统计差异。

2) 推理与阈值确定：训练所得分类器可直接迁移至待分类的波形样本 M_{test} ，输出每个样本的分类概率 $h(\bar{x})$ 。根据 CWoLa 的单调等价性， $h(\bar{x})$ 与信号/背景分类的似然比严格单调相关，仅需确定分类阈值即可完成类别判定。本研究采用直方图谷值法确定阈值：绘制分类器在样本 M_{test} 上的输出概率分布直方图，选取分布中两个特征峰之间的谷值作为分类阈值，全程无需标签信息即可完成决策边界的确定。

4.1.2. 实验设置与数据集

为量化混合样本信号占比差异对分类效果的影响，定义信噪比差异因子 f ：

$$f = \frac{f_1}{(f_1 + f_2)} \quad (10)$$

其中， $f_1 > f_2$ ，因此 f 的取值范围为(0.5, 1.0]。 f 值越接近 1.0，两组混合样本的信噪比差异越大；当 $f=1.0$ 时，对应 M_1 为纯信号样本、 M_2 为纯噪声样本，即传统完全监督学习，作为本实验的性能上限基线。本实验共设置 6 组对照实验，对应 $f=0.6$ 、0.7、0.8、0.9、0.99、1.00，训练与验证样本均基于 EMCS 方法

生成, 各组实验的混合样本配置如表 3 所示。所有实验组采用统一的 LT-IPE 测试集, 该样本覆盖纯噪声 (0 p.e.) 与不同光子数的信号波形 (≥ 1 p.e.), 信噪比适中, 可客观、公平地评估模型的泛化性能。

Table 3. Datasets for training, validation, and testing used in the six comparative experiments

表 3. 6 组对照实验所用训练、验证与测试的数据集

f	f_1	f_2	M ₁ Training	M ₂ Training	M ₁ Validation	M ₂ Validation
0.60	0.75	0.50	500,000	500,000	50,000	50,000
0.70	0.84	0.36	500,000	500,000	50,000	50,000
0.80	0.89	0.22	500,000	500,000	50,000	50,000
0.90	0.95	0.10	500,000	500,000	50,000	50,000
0.99	0.995	0.005	500,000	500,000	50,000	50,000
1.00	1.0	0.0	500,000	500,000	50,000	50,000

Testing Dataset: LT-IPE 50,000 Waveforms

4.1.3. 性能分析

对于每组 f 值实验均采用统一的一维 CNN 架构与超参数配置完成训练, 训练过程中的损失与准确曲线如图 4 所示。从收敛特性来看, 所有实验组模型均可在 100 轮训练内稳定收敛, 训练与验证损失随训练轮次快速下降, 20 轮左右进入平稳区间, 训练与验证曲线无明显分叉, 未出现过拟合; 模型分类性能呈现显著的 f 值依赖性: 随 f 值增大, 收敛后损失值显著降低, 准确率同步提升。 $f = 0.6$ 时验证损失约 0.68、准确率仅 0.62, 略高于随机猜测水平; $f = 0.99$ 时验证损失降至 0.036、准确率提升至 0.994, 已接近全监督基线 ($f = 1.0$, 准确率 0.9995)。该规律印证了 CWoLa 理论的核心特性: 两组混合样本的信号占比差异越大, 模型越容易学习到信号与噪声的本质区分特征, 分类性能越优、收敛效率越高。所有模型均选取拟合稳定后验证损失最低的轮次权重作为最终推理模型, 最大化泛化性能。

将 6 组实验的最优模型应用于 LT-IPE 测试集, 绘制输出概率分布直方图如图 5 所示。 f 值较小时 ($f = 0.6、0.7$), 输出概率呈多峰重叠特征, 信号与噪声的特征峰无明确分界, 无法确定清晰的分类阈值; 随 f 值增大 ($f = 0.8、0.9$), 双峰逐渐分离, 峰间谷值清晰度提升; $f = 0.99$ 时, 分布呈完全分离的双峰特征, 与全监督基线 ($f = 1.0$) 的输出分布形态基本一致。特征峰分离度越高, CWoLa 模型分类性能越稳定, 本质原因是混合样本成分差异越大, 分类器对最优似然比的学习越精准。

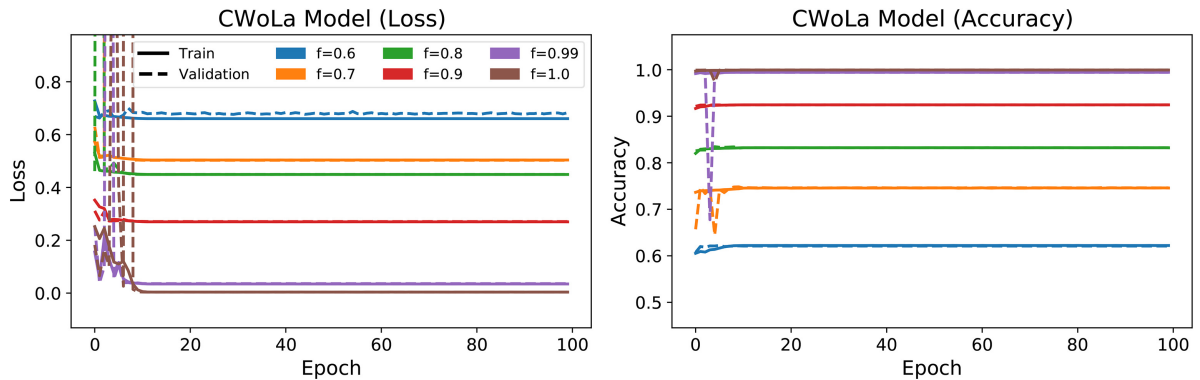


Figure 4. Evolution curves of loss and accuracy during the training process of each CWoLa model

图 4. 各 CWoLa 模型训练过程中损失与准确率的演化曲线




Figure 5. Histograms of the model output probability distributions under different f values

图 5. 不同 f 值下模型输出概率分布直方图

上述结果表明, CWoLa 模型的噪声鉴别性能与混合样本的信噪比差异呈显著正相关, 当 f 趋近于 0.99 时, 模型性能已接近全监督学习的理论上限, 可实现高精度的信号与噪声分类。据此, 可推导出最优样本构造策略: 令 M_2 为纯噪声样本 ($f_2 = 0$) 或极低信噪比样本 ($f_2 \rightarrow 0$), 此时无论 M_1 的信号占比 f_1 为多少, 信噪比差异因子 f 均趋近于 1.0。换言之, “纯噪声样本 + 任意含信号样本” 的组合, 可在无需预先控制信号占比的条件下实现接近理论上限的弱监督噪声鉴别效果。

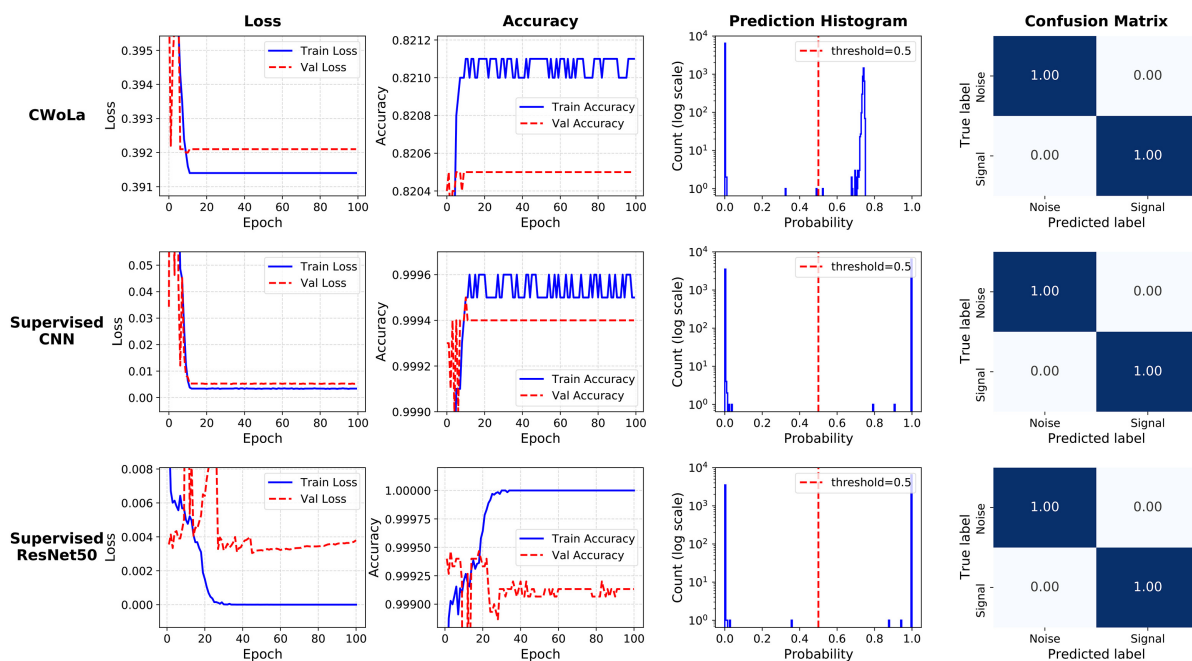


Figure 6. Comparison of training convergence, output probability distributions, and confusion matrices among CWoLa-CNN, the fully supervised CNN (ablation) and fully supervised ResNet50

图 6. CWoLa-CNN、全监督 CNN 与全监督 ResNet50 的训练收敛性、输出概率分布和混淆矩阵对比

为验证所提最优样本构造策略的有效性, 并通过消融实验排除模型架构与训练方法的干扰, 本研究以纯噪声样本与 LT-1PE 作为训练集, 构建以下三种对比模型: ① 采用 CWoLa 训练本文设计的一维 CNN; ② 采用全监督方法训练同一 CNN; ③ 采用全监督方法训练 ResNet50 作为外部架构基准。三者的训练收敛曲线、测试集输出概率分布和归一化混淆矩阵如图 6 所示, 核心分类性能指标(准确率、精确度、召回率和 F1 分值)汇总于表 4。

从训练收敛特性来看, CWoLa 模型的验证损失收敛至 0.392, 验证准确率稳定在 0.8205, 与全监督模型(损失接近 0, 准确率接近 1)存在明显差异。该结果符合 CWoLa 范式的理论预期: 训练过程的损失与准确率仅反映对混合样本组别的区分能力, 不代表最终的信号与噪声鉴别性能。在测试集上, CWoLa 模型输出概率分布在 0 与 0.7~0.75 区间, 而两个全监督模型输出均集中于 0 和 1 两端, 呈现清晰的双峰分离, 以 0.5 为阈值即可精准划分信号与噪声, 表明 CWoLa 模型已充分学习到信号与噪声的本质特征差异, 其输出的相对似然比可等价实现精准分类。归一化混淆矩阵与量化指标进一步验证: CWoLa 整体分类准确率达 99.89%, 与全监督模型的 99.95% 近乎持平, 噪声识别、信号识别的精确率、召回率与 F1 分数均处于同一水平。

Table 4. Noise discrimination performance comparison among the three models (CWoLa-CNN, the fully supervised CNN, and fully supervised ResNet50).

表 4. 三种模型(CWoLa-CNN、全监督 CNN 与全监督 ResNet50)的噪声鉴别性能对比

Method	Overall Accuracy	Noise Accuracy	Signal Accuracy	Precision	Recall	F1 Score
CWoLa	0.9989	0.9980	0.9994	0.9989	0.9994	0.9992
Supervised CNN	0.9995	0.9997	0.9994	0.9998	0.9994	0.9996
Supervised ResNet50	0.9992	0.9993	0.9996	0.9995	0.9993	0.9994

上述实验结果表明, 采用最优样本构造策略的 CWoLa 弱监督模型可实现与全监督模型近乎一致的噪声鉴别性能。在 JUNO 等大型粒子物理实验中, 纯噪声样本可直接从暗噪声数据中获取, 无需任何真值标注, 即可通过 CWoLa 二分类框架训练得到高精度的信号与噪声分类器, 为实测 PMT 波形数据的预处理提供了一种高可行性与高可靠性的解决方案。

4.2. 波形光子计数重建

基于噪声鉴别任务验证的 CWoLa 最优样本构造策略, 本节将 CWoLa 二分类范式扩展至多光子精细分类任务, 提出级联二分类光子计数重建框架。该框架将多分类任务拆解为一系列串行的二分类子任务, 为实现无样本级真值标签的 PMT 波形全范围光子计数提供可能性。本节基于 EMCS 生成的纯净 k p.e. 样本, 完成框架的理论可行性验证与理想性能上限测试, 并与全监督 ResNet50 模型进行性能对比。

4.2.1. 级联二分类光子计数框架

光子计数的核心目标是对输入 PMT 波形精准预测其包含的总光子数, 本质为覆盖 0 p.e. 至 n p.e. 的多分类任务, 而 CWoLa 原生为二分类范式, 无法直接实现多类别分类。4.1 节已验证, CWoLa 二分类任务的最优样本构造策略为“纯目标类别样本 + 含非目标类别的混合样本”, 该策略可泛化至任意光子数的二分类任务: 仅需保证两组训练样本中目标光子数的占比存在显著统计差异, 无需单样本真值标签, 即可训练得到高性能的二分类器。

基于上述泛化策略, 本研究构建了光子数重建的级联二分类框架, 完整流程如图 7 所示。定义目标光子计数的覆盖范围为 0 p.e. 至 n p.e., 超出 n p.e. 的波形统一归类为 $\geq n$ p.e.; 对于第 k 级分类任务

($k \in \{0, 1, 2, \dots, n-1\}$), 分离的目标光子数为 k p.e.; 每一级 CWoLa 分类器的两组训练输入分别为: 纯 k p.e. 目标类别样本集 M_2 , 以及上一级输出的待分类混合样本集 M_1 ; 经第 k 级分类器分离后, 判定为 k p.e. 的样本集合记为 C_k , 剩余未被分类的混合样本集记为 S_k , 作为下一级分类任务的输入 M_1 。级联流程如下:

- 第 0 级分类($k=0$): 以纯 0 p.e. 波形样本作为 M_2 , 待重建的全范围混合样本作为 M_1 , 训练首个 CWoLa 二分类器; 通过该级验证集的输出概率直方图确定最优分类阈值, 分离出 0 p.e. 的样本集 C_0 ; 剩余未分类波形构成混合样本集 S_0 , 进入下一级分类。
- 第 k 级分类($1 \leq k \leq n-1$): 以纯 k p.e. 波形样本作为 M_2 , 以上一级输出的混合样本集 S_{k-1} 作为 M_1 , 训练 CWoLa 二分类器; 通过输出概率直方图确定分类阈值, 分离出 k p.e 样本集 C_k ; 剩余未分类的波形构成混合样本集 S_k , 进入下一级分类。
- 最终分类: 经最后一级分类器分离出 $(n-1)$ p.e. 样本集 C_{n-1} 后, 剩余所有未分类的波形统一归类为 $\geq n$ p.e. 类别, 记为 $C_{\geq n}$ 。

汇总各级分类结果 $C = \{C_0, C_1, C_2, \dots, C_{n-1}, C_{\geq n}\}$, 即完成输入混合样本的无标签光子计数重建。该框架中各级分类器相互独立、权重不共享, 分类阈值通过对应验证集独立确定, 可最大化单级分类精度, 降低级联过程中的误差累积; 推理阶段, 待重建波形依次通过预训练的各级分类器, 实现 0 p.e. 至 n p.e. 的端到端弱监督分类。

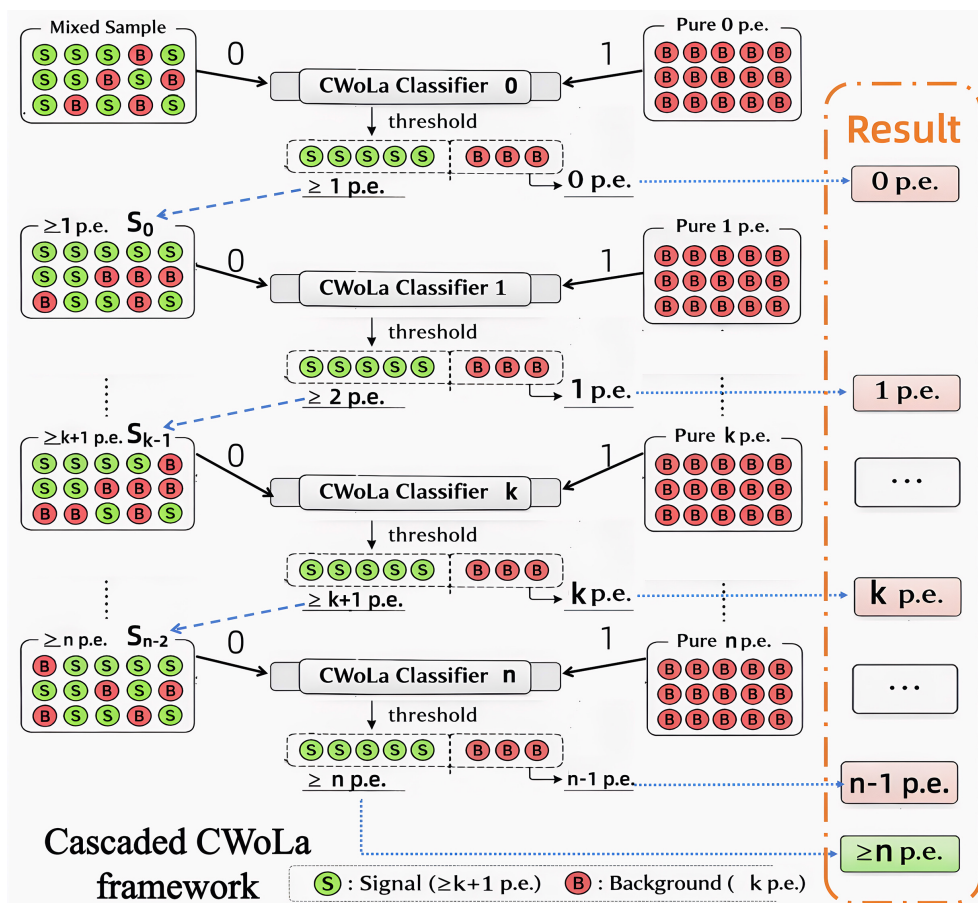


Figure 7. Overall workflow of the cascade binary classification photon counting framework

图 7. 级联二分类光子计数框架的完整流程

4.2.2. 实验安排

级联 CWoLa 实验数据集分为两类：各级分类器训练所需的 k p.e. 样本集，以及待分类的混合多光子样本集。纯 k p.e. 样本(0 p.e. 至 $n-1$ p.e.) 通过 EMCS 方法生成，作为基线训练集。为进一步评估级联框架对训练样本纯度的鲁棒性，另构建一组非纯净训练集：对每个 k p.e. 类别，采用 95% 的纯净 k p.e. 样本混合 5% 的 $(k-1)$ 和 $(k+1)$ p.e. 样本(比例各半，0 p.e. 类别仅掺杂 1 p.e. 样本)。采用 LT-UPE 数据集(覆盖 0~10 p.e.) 作为训练、验证与测试的多光子混合样本，可真实模拟多光子堆叠的物理情形，用于评估级联框架的光子计数重建性能。详细配置如表 5 所示。

Table 5. Datasets for photon counting reconstruction via the cascade binary classification framework
表 5. 级联二分类框架实现光子计数重建所需数据集

Dataset	Training	Validation
Pure k p.e. Waveform	100,000/Class	10,000/Class
Contaminated k p.e. Waveform (95% Pure + 5% Neighbors)	100,000/Class	10,000/Class
LT-UPE	1,000,000	1,00,000
Testing Dataset: LT-UPE 100,000 Waveforms		

需特别说明的是，本节的模拟实验分为两部分：首先，基于纯净 k p.e. 样本开展理想条件下的验证，旨在验证级联分类方法的理论可行性与理想性能上限；其次，通过引入非纯净样本，模拟真实实验中样本不纯的情况，进而测试级联框架的性能退化趋势，评估其在实际应用中的鲁棒性。根据 CWoLa 理论，训练样本无需达到 100% 绝对纯净度，仅需样本集中目标光子数的占比显著高于其他类别，即可使分类器学习到目标类别的核心统计特征，实现接近最优的分类效果。在 JUNO 等真实实验中，0 p.e. 样本可直接从噪声数据采集，1 p.e. 样本可通过极低光强 LED 刻度数据结合泊松分布筛选， $k \geq 2$ p.e. 的多光子样本可采用其他波形重建方法进行初步筛选，或通过高保真仿真模拟获取，具备可行的落地路径。

4.2.3. 性能分析

级联框架中各级独立 CWoLa 二分类器选取拟合稳定后验证损失最低的轮次作为最优模型，分类阈值通过对验证集的输出概率直方图的谷值独立确定，以最大化单级分类精度，降低累积误差。

分别采用纯净训练集与非纯净训练集训练各级分类器，并与全监督 ResNet50 模型对比，训练收敛曲线如图 8 所示。所有分类器均在 100 轮内稳定收敛，训练与验证曲线高度贴合，无过拟合。纯净训练集与非纯净训练集下的模型分类性能均与目标光子数 k 呈显著负相关：随 k 增大，纯净样本下的稳态损失从 $k=0$ 时的 0.185 (非纯净训练集为 0.204) 上升至 $k=9$ 时的 0.457 (非纯净训练集为 0.542)，稳态验证准确率从 0.935 (非纯净训练集为 0.925) 下降至 0.775 (非纯净训练集为 0.740)。该规律源于光子数升高导致波形堆积效应加剧， k p.e. 与 $\geq k+1$ p.e. 波形的信号差异持续缩小，特征区分度降低，分类难度提升。此外，尽管非纯净训练集下的分类器性能较纯净训练集有所下降，但其级联框架仍保持优秀的分类能力，表明 CWoLa 方法对训练样本的污染数据具备强鲁棒性。

各级分类器在验证集上的输出概率分布如图 9 所示。在低光子数区间($k=0, 1, 2, 3$ p.e.)，两组分类器的输出均呈现目标类别与非目标类别的双峰分离特征，峰间谷值清晰，极易实现高精度分类。其中，污染训练集下的分类器在低概率端出现了额外的子峰，该现象源于训练样本中引入少量相邻类别污染，导致模型对部分边界样本的预测置信度降低，从而形成两个置信度群体。尽管如此，该子峰与高概率端的非目标类别峰之间仍存在清晰谷值，因此分类准确率未显著下降。随 k 增大，两组分类器的输出概率分

布趋于一致, 双峰重叠度提升, 谷值逐渐模糊, 分类的误判概率增大; $k \geq 5$ p.e. 时非目标类别特征峰无明显集中分布趋势, 与目标峰大范围重叠, 将导致各级分类器的准确率出现大幅下降。

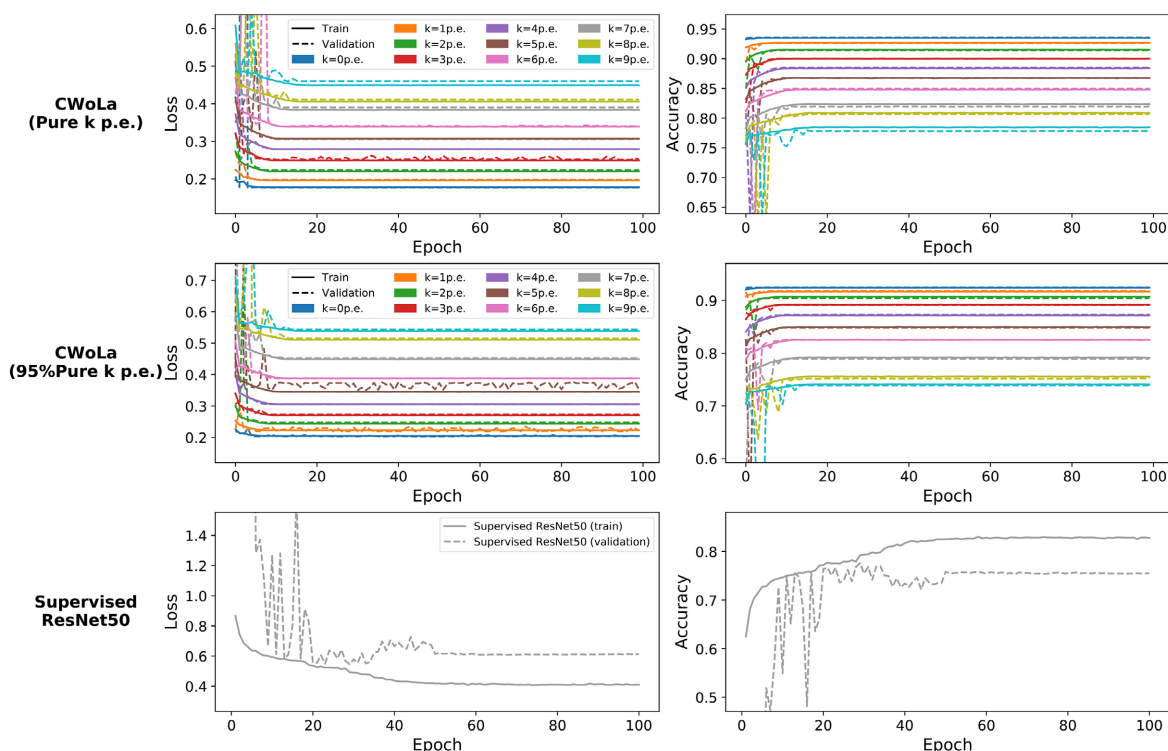


Figure 8. Comparison of training convergence curves: multi-level CWoLa classifiers trained on pure k p.e. samples (top), multi-level CWoLa classifiers trained on 95% pure k p.e. samples (middle), and the fully supervised ResNet50 model (bottom)

图 8. 纯净样本集下各级 CWoLa 二分类器(上)、污染样本集下各级 CWoLa 二分类器(中)与 ResNet50 监督模型(下)的训练收敛曲线对比

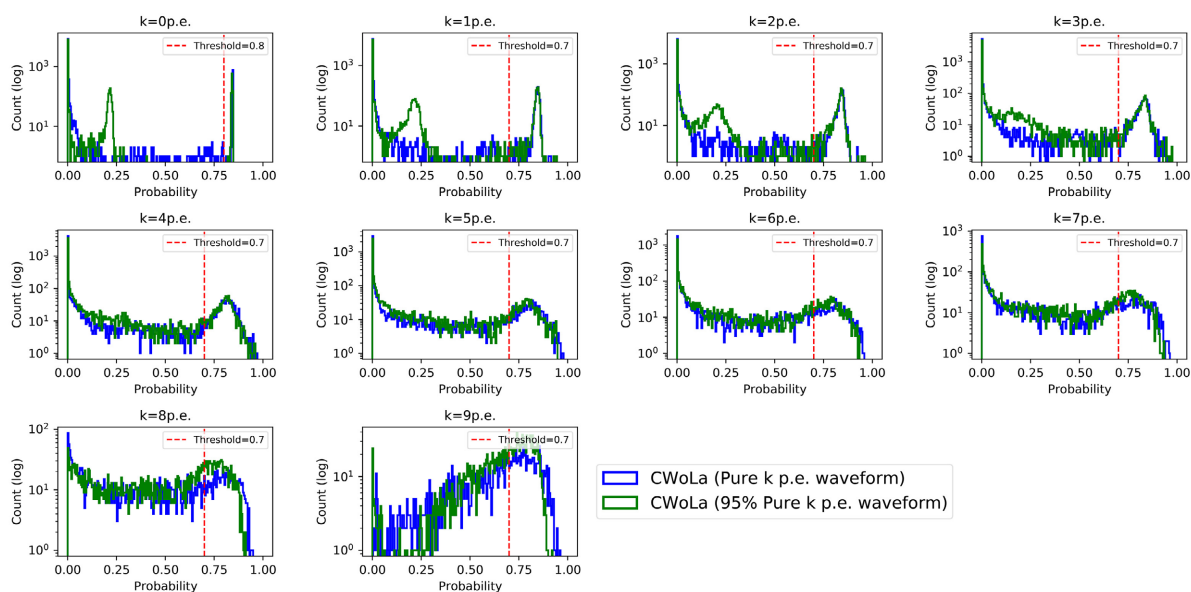


Figure 9. Comparison of output probability distribution histograms of cascaded CWoLa classifiers under different training sample

图 9. 不同训练样本下级联 CWoLa 分类器的输出概率分布直方图对比

将各级分类结果按级联流程汇总, 得到全光子数范围的分类结果, 其归一化混淆矩阵对比如图 10 所示(从左到右依次为: 纯净训练集下的级联 CWoLa 分类器、非纯净训练集下的级联 CWoLa 分类器、全监督 ResNet50 模型)。结果表明, 级联 CWoLa 框架在低光子数区间(0~3 p.e.)的表现与全监督模型近乎持平: 0 p.e.样本识别准确率接近 100%, 纯净训练集分类器的 1 p.e.样本识别准确率 99%(非纯净训练集分类器为 99%, 监督模型为 100%), 2 p.e.样本为 96% (非纯净训练集分类器 96%, 监督模型 98%), 3 p.e.为 89% (非纯净训练集分类器 87%, 监督模型 91%)。该区间内光子信号波形特征差异显著, 即使引入 5% 的样本污染, 弱监督 CWoLa 分类器依然可有效学习到类别间的本质特征, 实现逼近监督模型的分类效果。随光子数增加, 波形堆积效应加剧, 三类模型的分类精度均出现不同程度下降, 但纯净样本集下的级联 CWoLa 分类器与 ResNet50 监督模型的差距始终控制在较小范围(5%以内), 而非纯净训练集分类器性能在纯净训练集分类器的基础上进一步下降 1%~5%, 其中 9 p.e.时两个级联 CWoLa 分类器仍有 49% 的准确率, 接近监督模型的效果; 而在 ≥ 10 p.e.中, 三组模型的异常高准确率均源于分类模型带来的边界效应。

为进一步量化级联框架的光子计数重建能力, 我们定义真实光子数为 n 时重建均值为 $\bar{k}_n = \sum_{k=0}^{\infty} k \cdot P(k|n)$, 重建标准差为 $\sigma_{k_n} = \sqrt{\sum_{k=0}^{\infty} (k - \bar{k}_n)^2 \cdot P(k|n)}$, 分别反映了光子数重建的偏差和分辨率, 结果如图 11 所示。在系统偏差方面, 三组模型的重建均值均与理想线性关系 $\bar{k} = n$ 基本吻合, 0~9 p.e.光子数区间的重建均值相对偏差均小于 2%, 仅 ≥ 10 p.e.时出现约 3% 的负偏差。从统计分辨率来看, 三组深度学习模型均显著优于传统电荷估计法的理论分辨率 $\sigma_{Q_n} = \sqrt{n}\sigma_{Q_1}$ 。在 1~4 p.e.低光子数区间, 级联 CWoLa 框架与全监督 ResNet50 模型的重建标准差均较传统方法大幅降低, 其中 1 p.e.时纯净样本集分类器仅约 0.11 p.e., 较传统电荷估计方法精度提升约 72% (监督模型约 80%); 非纯净样本集分类器在 1 p.e.时的重建标准差约为 0.14 p.e., 精度提升约 60%, 表明即使训练样本存在轻度污染, 深度学习模型仍能利用波形的全时域结构特征, 有效规避了电荷涨落的干扰。随 n 增加, 三组模型的分辨率优势逐渐收窄, 但纯净样本集下的级联 CWoLa 分类器始终与 ResNet50 监督模型保持相近水平, 非纯净样本集分类器的性能略有下降但仍显著优于传统方法。

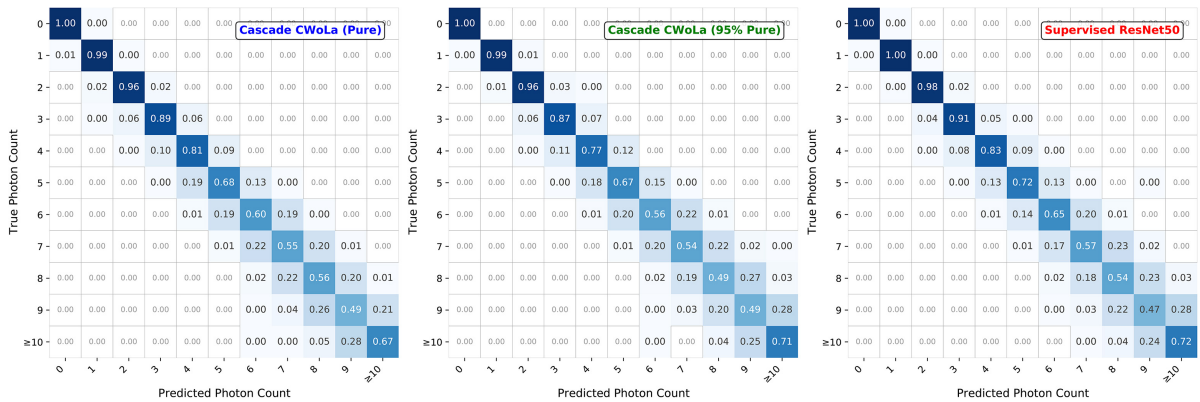


Figure 10. Normalized confusion matrices for photon number classification: cascaded CWoLa classifier trained on pure samples (left), cascaded CWoLa classifier trained on contaminated samples (middle), and fully supervised ResNet50 (right)

图 10. 光子数分类归一化混淆矩阵对比: 纯净样本训练级联 CWoLa 分类器(左)、非纯净样本训练级联 CWoLa 分类器(中)、全监督 ResNet50 (右)

综上, 在噪声鉴别任务, 采用最优样本构造策略的 CWoLa 弱监督模型可实现与全监督模型近乎一致的性能; 在光子计数重建方面, 级联二分类框架在理想纯净样本与轻度污染样本训练条件下, 0~10 p.e.光

子数区间均展现出与全监督 ResNet50 模型相近的重建均值和分辨率, 验证了弱监督光子计数重建的可行性与高性能潜力。




Figure 11. Comparison of mean and resolution for photon counting reconstruction: cascaded CWoLa (pure), cascaded CWoLa (95% pure), fully supervised ResNet50, and the ideal linear baseline

图 11. 光子计数重建均值与分辨率对比: 纯净训练集 CWoLa 分类器、非纯净训练集 CWoLa 分类器、全监督 ResNet50 及理想线性基线

5. 结论与展望

提升 PMT 波形光子数重建精度对改善探测器能量分辨率具有重要意义, 也是粒子物理实验中长期存在的关键挑战之一。针对传统方法精度不足、监督学习依赖于高精度标签的问题, 本文探索了基于 CWoLa 理论的 PMT 波形弱监督分析方法, 主要包括两项工作: 一是噪声鉴别, 通过构建两组信噪比差异显著的混合样本训练分类器, 实现了无真值标签的噪声与信号分类, 当采用“纯噪声样本 + 任意含信号样本”的最优构造策略时, CWoLa 分类器的整体分类准确率可达 99.89%, 与全监督模型近乎持平。二是提出了级联二分类光子计数框架, 将多光子计数问题分解为一系列串行的二分类子任务。基于 EMCS 生成的纯净度分别为 100% 和 95% 的样本开展实验, 结果表明: 在 0~3 p.e. 的低光子数区间, 该框架的分类精度与全监督训练的 ResNet50 模型几乎一致; 在 4~9 p.e. 区间, 纯净训练集 CWoLa 分类器的分类准确率与监督模型的差距控制在 5% 以内, 污染训练集 CWoLa 分类器的性能较纯净模型略微下降, 但仍显著优于传统电荷估计方法; 在 0~10 p.e. 全光子数区间, 重建均值无明显偏差, 重建分辨率均显著优于传统电荷估计方法。上述结果验证了该框架在多光子计数任务中的可行性与鲁棒性。

未来工作将聚焦真实实验场景下的弱监督性能验证, 基于 JUNO 实测刻度数据完成不同光子数样本的提纯与测试, 并进一步研究训练样本污染程度与框架性能下降之间的定量关系, 为实际应用中的样本质量控制提供指导。

基金项目

广东省教育厅普通高校特色创新项目(2024KTSCX044)以及五邑大学高层次人才科研启动基金(2021AL027)。

参考文献

- [1] Daya Bay Collaboration (2023) Precision Measurement of Reactor Antineutrino Oscillation at Kilometer-Scale Baselines by Daya Bay. *Physical Review Letters*, **130**, Article 161802.
- [2] Abe, K., Akhlaq, N., Akutsu, R., *et al.* (2023) Measurements of Neutrino Oscillation Parameters from the T2K Experiment Using 3.6×10^{21} Protons on Target. *European Physical Journal C: Particles and Fields*, **83**, Article 782.

-
- [3] Acero, M.A., Adamson, P., Aliaga, L., *et al.* (2022) Improved Measurement of Neutrino Oscillation Parameters by the NOvA Experiment. *Physical Review D*, **106**, Article 032004.
- [4] Adriani, O., Aiello, S., Albert, A., *et al.* (2025) Ultrahigh-Energy Event KM3-230213A within the Global Neutrino Landscape. *Physical Review X*, **15**, Article 031016.
- [5] IceCube Collaboration (2013) Evidence for High-Energy Extraterrestrial Neutrinos at the IceCube Detector. *Science*, **342**, Article 1242856. <https://doi.org/10.1126/science.1242856>
- [6] An, F.P., An, G.P., An, Q., *et al.* (2016) Neutrino Physics with JUNO. *Journal of Physics G: Nuclear and Particle Physics*, **43**, Article 030401.
- [7] Hyper-Kamiokande Collaboration, Abe, K., Aihara, H., *et al.* (2018) Hyper-Kamiokande Design Report. <https://arxiv.org/abs/1805.04163>
- [8] Aiello, S., Albert, A., Alves Garre, S., *et al.* (2022) Determining the Neutrino Mass Ordering and Oscillation Parameters with KM3NeT/ORCA. *The European Physical Journal C*, **82**, Article No. 26.
- [9] Peterson, J.H. (2021) Developments in Waveform Unfolding of PMT Signals in Future IceCube Extensions. *Journal of Instrumentation*, **16**, C09032. <https://doi.org/10.1088/1748-0221/16/09/c09032>
- [10] Wang, Y., Zhang, A., Wu, Y., Xu, B., Liu, X., Chen, J., *et al.* (2026) The Fast Stochastic Matching Pursuit for Neutrino and Dark Matter Experiments. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, **1082**, Article 170986. <https://doi.org/10.1016/j.nima.2025.170986>
- [11] Daya Bay Collaboration (2019) A High Precision Calibration of the Nonlinear Energy Response at DayaBay. *Nuclear Instruments & Methods in Physics Research Section A*, **940**, 230-242.
- [12] Tang, J., Xiao, T., Tang, X. and Huang, Y. (2025) Investigation and Optimization of the Deconvolution Method for PMT Waveform Reconstruction. *Journal of Instrumentation*, **20**, P03019. <https://doi.org/10.1088/1748-0221/20/03/p03019>
- [13] Jiang, W., Huang, G., Liu, Z., Luo, W., Wen, L. and Luo, J. (2025) Machine-Learning Based Photon Counting for PMT Waveforms and Its Application to the Improvement of the Energy Resolution in Large Liquid Scintillator Detectors. *The European Physical Journal C*, **85**, Article No. 69. <https://doi.org/10.1140/epjc/s10052-024-13724-3>
- [14] Metodiev, E.M., Nachman, B. and Thaler, J. (2017) Classification without Labels: Learning from Mixed Samples in High Energy Physics. *Journal of High Energy Physics*, **2017**, Article No. 174. [https://doi.org/10.1007/jhep10\(2017\)174](https://doi.org/10.1007/jhep10(2017)174)
- [15] Beretta, M., Houria, F., Ferraro, F., Basilico, D., Brigatti, A., Caccianiga, B., *et al.* (2025) Fluorescence Emission of the JUNO Liquid Scintillator. *Journal of Instrumentation*, **20**, P05009. <https://doi.org/10.1088/1748-0221/20/05/p05009>
- [16] He, K., Zhang, X., Ren, S. and Sun, J. (2016) Deep Residual Learning for Image Recognition. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 770-778. <https://doi.org/10.1109/cvpr.2016.90>