

探测器前端神经网络算法及专用集成电路研究

艾鹏程

华中师范大学 PLAC 实验室

Tuesday 17th October, 2023




華中師範大學

内容


- 1 研究背景
 - 核仪器上的波形采样系统
 - 神经网络的应用现状
- 2 研究内容
 - 算法研究
 - 硬件架构
- 3 总结展望

核仪器上的波形采样 (1)

百 MHz 前端数字化系统广泛用于**高能物理**探测器，以量能器为例：



CMS 桶形量能器
(160 MHz ADC)

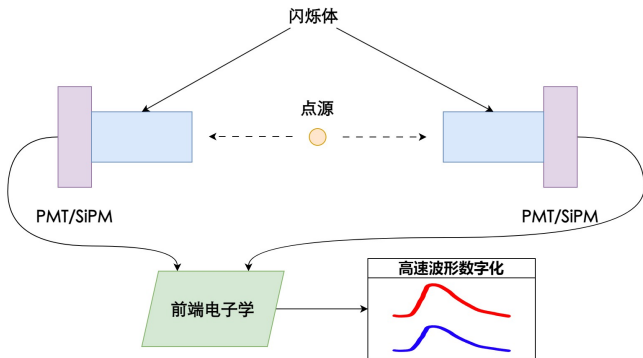


NICA-MPD 电磁量能器
(250 MHz ADC)

其它例子：STCF ECAL (100~125 MHz)、Mu2e Calorimeter (150~250 MHz) ...

核仪器上的波形采样 (2)

高采样率 (\sim GHz) 的波形采样设备常用于探测器的性能分析和标定, 以核仪器 TOF-PET 研究为例:



探测器符合测量典型设置

时间分辨, 能量分辨, 位置分辨...

神经网络用于核探测器信号处理

神经网络形式:




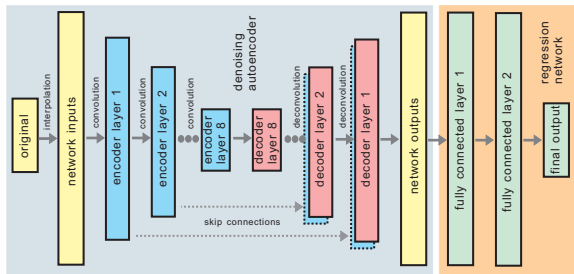
- ❑ 深度前馈网络 (DNN)
- ❑ 卷积神经网络 (CNN) 及残差神经网络 (ResNet)
- ❑ 循环神经网络 (RNN)
- ❑ ...

应用领域:

- ❑ Neutron/Gamma 甄别: 飞行时间 (ToF) 估计, 基于脉冲形状的 n/γ 甄别...
- ❑ 脉冲形状甄别 (PSD): 闪烁体中中子、光子区分, 单晶金刚石中的粒子鉴别、中微子事例鉴别...
- ❑ 核医学: 飞行时间 (ToF) 估计, 作用深度 (DoI) 和位置分辨...
- ❑ 探测器**前端信号处理**: 人工智能智慧传感器, 低延迟、高性能的神经网络前端推理...

算法研究

基于一维卷积自编码器的脉冲定时




□ 网络架构：降噪自编码器 + 回归网络

- * 自编码器：一维卷积，一维转置卷积
- * 回归网络：全连通运算

□ 训练方法：自编码器预训练 + 定时标签微调

□ 三种非理想因素：长时漂移，短时改变，随机噪声


基于一维卷积自编码器的脉冲定时 (2)




- ❑ 实验设置: ALICE PHOS 量能器, APD, LED 触发脉冲信号
- ❑ 改变成形电路的成形时间, 观察时间分辨随采样率的变化
- ❑ 两种定时方法: 曲线拟合, 神经网络
- ❑ 结论: 神经网络提升时间分辨 (100 ns 时提升 24.7%)

(P. Ai et al 2019 *JINST* 14 P03002)


1 μ s 成形时间结果




100 ns 成形时间结果



神经网络脉冲定时的理论下限



理论下限分析对比流程



神经网络

联合概率密度:

$$\ln p_{r,\theta}(\mathbf{R}, \Theta) = \ln p_{r|\theta}(\mathbf{R}|\Theta) + \ln p_{\theta}(\Theta)$$

Fisher 信息矩阵:

$$\mathbf{J}_T \triangleq \mathbf{J}_D + \mathbf{J}_P$$

$$\mathbf{J}_D = -E \left[\nabla_{\Theta} \left(\left\{ \nabla_{\Theta} \ln p_{r|\theta}(\mathbf{R}|\Theta) \right\}^T \right) \right]$$

$$\mathbf{J}_P = -E \left[\nabla_{\Theta} \left(\left\{ \nabla_{\Theta} \ln p_{\theta}(\Theta) \right\}^T \right) \right]$$

参数预测理论下限:

$$E[\theta_{\epsilon_i}^2] \geq Q_T^{ii} \quad (Q_T \text{ 为 } \mathbf{J}_T \text{ 逆矩阵})$$

信号建模 ($w(t)$ 来自高斯过程):

$$r(t) = s(t) + w(t), \quad w(t) \sim \mathcal{N}(0, \sigma_w^2)$$

$$s(t) \triangleq s(t; \Theta) \triangleq s(t; \Theta_{\text{int}}, \Theta_{\text{ext}})$$

Fisher 信息矩阵计算:

$$J_{Dij} = \left(\frac{\partial \mu_R}{\partial \theta_i} \right)^T \cdot \Sigma_R^{-1} \cdot \frac{\partial \mu_R}{\partial \theta_j}$$

$$\mathbf{J}_P = \begin{pmatrix} \Sigma_{\Theta_{\text{int}}}^{-1} & 0 \\ 0 & 0 \end{pmatrix}$$

神经网络脉冲定时的理论下限 (2)

(P. Ai et al 2021 *JINST* **16** P09019)

单光子脉冲波形函数:

$$S_{\text{origin}}(t; \Theta_{\text{int}}, \Theta_{\text{ext}}) = f_{\text{spad}}(t - \eta; C_d, V_{br}, R_q, C_q, C_g)$$

其中:

$$\Theta_{\text{int}} = \{C_d, V_{br}, R_q, C_q, C_g\},$$



$$\Theta_{\text{ext}} = \{\eta\}$$

量能器信号脉冲波形函数:

$$S_{\text{origin}}(t; \Theta_{\text{int}}, \Theta_{\text{ext}}) = \kappa \cdot f_{\text{gamma}}\left(\frac{t - \tau - \eta}{\beta}, \alpha\right)$$


其中:

$$\Theta_{\text{int}} = \{\alpha, \tau, \beta, \kappa\}, \quad \Theta_{\text{ext}} = \{\eta\}$$



多特征提取及不确定度估计

神经网络集成模型



预测均值和方差综合方法:

$$\mu_{j,*}(\mathbf{x}) = \frac{1}{T} \sum_{t=1}^T \mu_{j,\theta_t}(\mathbf{x})$$

$$\sigma_{j,*}(\mathbf{x})^2 = \frac{1}{T} \sum_{t=1}^T (\sigma_{j,\theta_t}(\mathbf{x})^2 + \mu_{j,\theta_t}(\mathbf{x})^2) - \mu_{j,*}(\mathbf{x})^2$$


模型输出和损失函数:

$$f_{\text{NN}}(\mathbf{x}; \theta) = [\mu(\mathbf{x}), \sigma(\mathbf{x})^2], \quad \mu, \sigma^2 \in \mathbb{R}^M, \quad \sigma^2 > 0$$


$$\mathcal{L}(\theta) = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M \frac{1}{2\sigma_j(\mathbf{x}^{(i)})^2} \left\| y_j^{(i)} - \mu_j(\mathbf{x}^{(i)}) \right\|^2 + \frac{1}{2} \log \sigma_j(\mathbf{x}^{(i)})^2$$

多特征提取及不确定度估计 (2)


(P. Ai et al 2022 *JINST* 17 P02032)



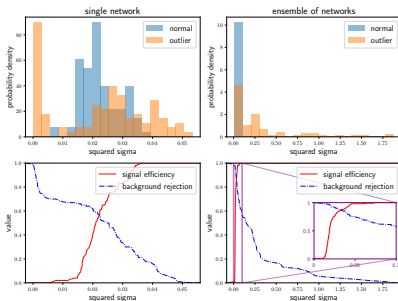
DESY 束流测试实验设置



正常与异常波形样例

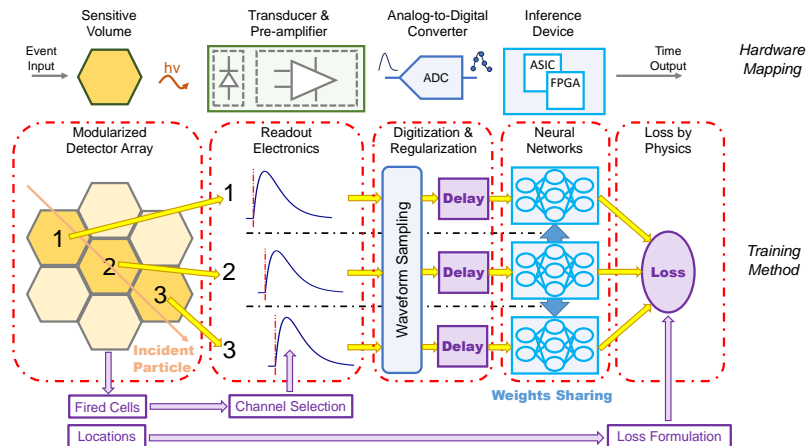


神经网络与传统方法的校准曲线



基于单类别方差阈值的集成模型异常检测

基于物理约束的无标签神经网络定时



无标签定时算法框架及硬件映射

基于物理约束的无标签神经网络定时 (2)

正则化方法 (随机化预测值):

$$y_i = f_{\text{NN}}(s_0(0t_s - (t_i + \Delta t_i)|\theta_i, n_{i,0}), \dots, s_{K-1}((K-1)t_s - (t_i + \Delta t_i)|\theta_i, n_{i,K-1})) - \Delta t_i \\ \approx f(t_i + \Delta t_i + \Delta T_i) - \Delta t_i = f(t_0 + a_i t_c + \Delta t_i + \Delta T_i) - \Delta t_i \quad (1)$$

损失函数:

$$\mathbf{A} [t_0 \quad t_c]^T = \mathbf{Y} \quad (\text{线性物理约束}) \\ l(\mathbf{Y}) = \left\| \left(\mathbf{I} - \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \right) \mathbf{Y} \right\|_2^2 = \mathbf{Y}^T \mathbf{M}^T \mathbf{M} \mathbf{Y} = \mathbf{Y}^T \mathbf{M} \mathbf{Y} \quad (2)$$

命题 1

Assume t_0, t_c are random variables. $\Delta t_0, \dots, \Delta t_{N-1} \sim \mathcal{N}(0, \sigma_1^2)$ and $\Delta T_0, \dots, \Delta T_{N-1} \sim \mathcal{N}(0, \sigma_2^2)$, both of which are i.i.d random variables, and $N \geq 3$. $l(\mathbf{Y})$ is from equation (2) and y_i in \mathbf{Y} is from equation (1), where a_0 is fixed at 0, and a_1, a_2, \dots, a_{N-1} are not all zeros. For $f: \mathbb{R} \mapsto \mathbb{R}$, if:

$$f(x) = kx + b \quad \text{where:} \quad k = \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}, \quad b = \text{const},$$

the following functional:

$$L(f) = \int_{\mathbb{R}^{2N} \times \Omega(t_0, t_c)} l(\mathbf{Y}) p(\Delta \mathbf{t}) p(\Delta \mathbf{T}) p(t_0) p(t_c) d\Delta \mathbf{t} d\Delta \mathbf{T} dt_0 dt_c$$

is minimized and takes the minimum value $\sigma_1^2 \sigma_2^2 \text{tr}(\mathbf{M}) / (\sigma_1^2 + \sigma_2^2)$.

基于物理约束的无标签神经网络定时 (3)

Algorithm 1 无标签训练算法

Require: \mathbf{w}_0 : initial weights; $f_{NN}(\cdot; \mathbf{w})$: NN model; η : learning rate; T : steps for training; $P(\Delta t)$: probability distribution for regularizers; D : size of calibration dataset; G : steps for linear shift.


Model training:

```

 $\mathbf{w} \leftarrow \mathbf{w}_0$                                 ▷ Initialize weights for the NN model
for  $i \leftarrow 1, 2, \dots, T$  do                ▷ Main loop for training
     $N, \mathbf{a}_0, \mathbf{a}_1, \dots, \mathbf{a}_{N-1} \leftarrow \text{ACQUIRE\_GEOMETRY}()$ 
     $\mathbf{s}_0, \mathbf{s}_1, \dots, \mathbf{s}_{N-1} \leftarrow \text{ACQUIRE\_SIGNAL}()$ 
    Sample  $\Delta t_0, \Delta t_1, \dots, \Delta t_{N-1} \sim P(\Delta t)$ 
    for  $j \leftarrow 0, 1, \dots, N-1$  do
         $\hat{\mathbf{s}}_j \leftarrow \text{SHIFT\_WAVEFORM}(\mathbf{s}_j, \Delta t_j)$                 ▷ Shift as regularizers
         $y_j \leftarrow f_{NN}(\hat{\mathbf{s}}_j; \mathbf{w}_{i-1}) - \Delta t_j$                 ▷ Apply the NN model
    end for
     $\mathbf{w}_i \leftarrow \mathbf{w}_{i-1} - \eta \nabla_{\mathbf{w}} J(y_0, y_1, \dots, y_{N-1}; \mathbf{a}_0, \mathbf{a}_1, \dots, \mathbf{a}_{N-1})$     ▷ From equation (2)
end for
return  $\mathbf{w}^* \leftarrow \mathbf{w}_T$ 




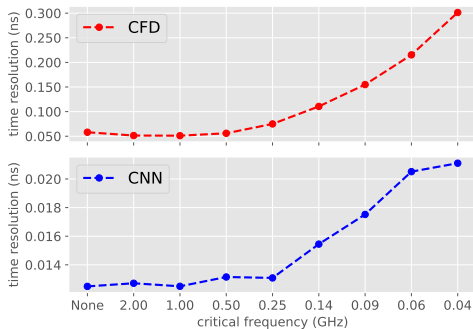
```

基于物理约束的无标签神经网络定时 (4)





Coincidence of two channels (σ_{double})

$$\text{note: } \sigma_{\text{single}} = \sigma_{\text{double}} / \sqrt{2}$$

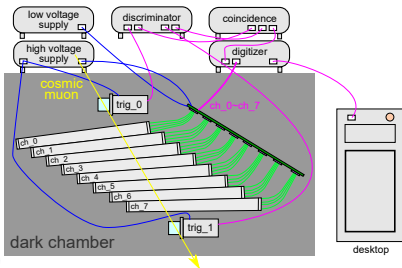

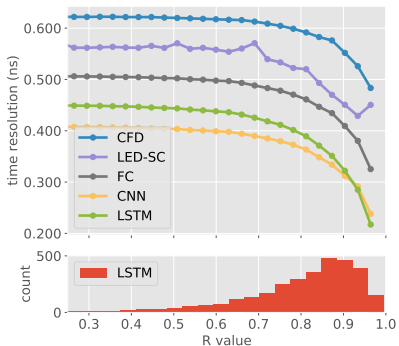


对数据漂移的鲁棒性

基于物理约束的无标签神经网络定时 (5)



Timing performance vs. threshold of R value



Pearson 相关系数大于 0.7 时,
CNN (LSTM) 时间分辨为 384 ps (424 ps)
(MLST <https://doi.org/10.1088/2632-2153/acfd09>)


硬件架构

PulseDL—设计背景


大型探测器系统的升级带来“数据爆炸”的问题：

- ❑ 事例率和数据通量达到前端电子学的极限
- ❑ 若原样存储原始数据，占用大量带宽，显著增加功耗

若在前端电子学处理数据……




研究对象：ALICE-PHOS 量能器



PulseDL—系统方案

基于降噪自编码器 (DAE) 的前端特征提取:




神经网络接口:




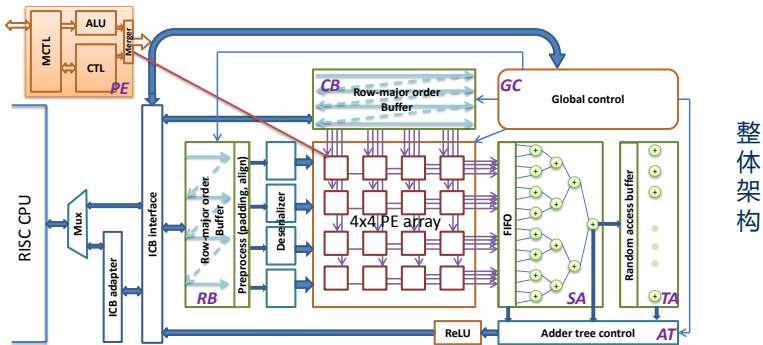
- ❑ 输入: 采样点脉冲序列
- ❑ DAE 输出: 去噪后的标准波形
- ❑ 回归网络输出: 物理特征

神经网络实现:

- ❑ 量化方案: 8-bit/16-bit 定点数
- ❑ 分层动态量化策略



PulseDL—硬件架构



PulseDL—仿真测试



神经网络硬件推理分层测试:

Name	Input Length	Input Channels	Kernel Length	Output Channels	Output Length	Time Budget (μ s)	GOPS/W (avg.)
Encoder1	32	1	4	16	16	47.6	0.538
Encoder2	16	16	4	32	8	75.9	5.40
Encoder3	8	32	4	64	4	186.7	4.39
Encoder4	4	64	4	128	2	490.1	3.34
Encoder5	2	128	4	128	1	905.9	1.81
Decoder5	1	128	4	128	2	904.7	3.62
Decoder4	2	128+128	4	64	4	918.8	7.13
Decoder3	4	64+64	4	32	8	265.3	12.4
Decoder2	8	32+32	4	16	16	137.0	12.0
Decoder1	16	16+16	4	1	32	27.0	3.79

Name	Input Length	Number of Weights and Biases	Output Length	Time Budget (μ s)	GOPS/W (avg.)
FC1	32	W=32*256, B=256	256	280.7	0.741
FC2	256	W=256*256, B=256	256	966.7	1.70
Final Out	256	W=256*1, B=1	1	11.8	0.542

PulseDL—仿真测试 (2)

This design	
Process	GSMCR013 (130 nm)
Area	24 mm ²
Target	General purpose convolutional neural networks
Voltage	1.2V (core), 3.3V (PAD)
Design Freq.	25 MHz
Pads	35 outputs, 52 inputs
Pad Current	4 mA
Registers	69 kb
On-chip RAM	None
Precision	Input: 8/16 bit fixed-point Output: 32 bit fixed-point



Type	Compact	Balanced	Precise
DAE layers	3*2	4*2	5*2
Reg. layers	2	2	2
Reg. weights	256-256	256-256	256-256
Total instructions (64-bit word)	1179	1920	3539
Total data storage (byte)	1860	2372	2756
Total parameters (byte)	98756	172484	336324
Time cost (ms)	1.892	2.962	5.218
Support channels (25MHz @ 35Hz)	15.1	9.6	5.5


改变卷积网络层数
测试结果

(P. Ai et al *NIMA* 978 (2020) 164420)

PulseDL-II—设计动机

NICA-MPD ECAL 现有前端电子学：

- ❑ 64-ch, 12-bit, 62.5-MSPS ADC 模块
- ❑ 通过光纤链路读出、触发和定时
- ❑ 功耗 ~ 250 mW/ch, 水冷散热



ECAL 现有系统的局限性：

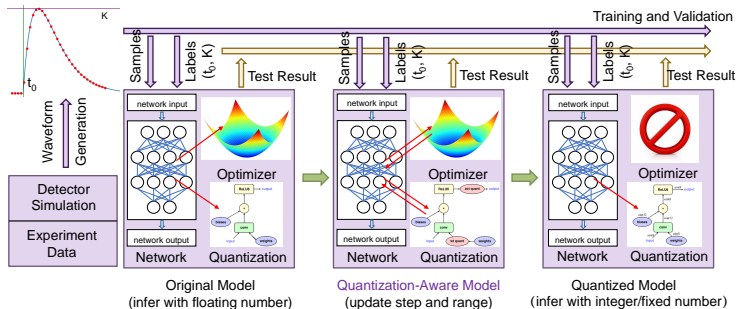
- ❑ 需传输**每个通道**的 ADC 采样数据，数据**带宽**要求高，并因此带来**高功耗**
- ❑ ADC 采样率偏低，仍有提高**时间和能量分辨**的潜力
- ❑ 分立器件使得电子学系统较复杂

初代芯片 PulseDL 在延迟、功耗等方面尚有欠缺，还需解决如下技术问题：

- ❑ 需要**外部**的处理器进行数据传输和任务调度
- ❑ **动态量化**方案会带来额外的时间开销
- ❑ 硬件架构中某些设计还有提升的空间（例如**加法树**结构）
- ❑ 还未建立工具链以支持**深度学习框架**

PulseDL-II—网络设计和量化

训练中量化 (Quantization-Aware Training, QAT) 的算法流程:



采用 QAT 技术, 可以减少由于定点数量化带来的精度损失:

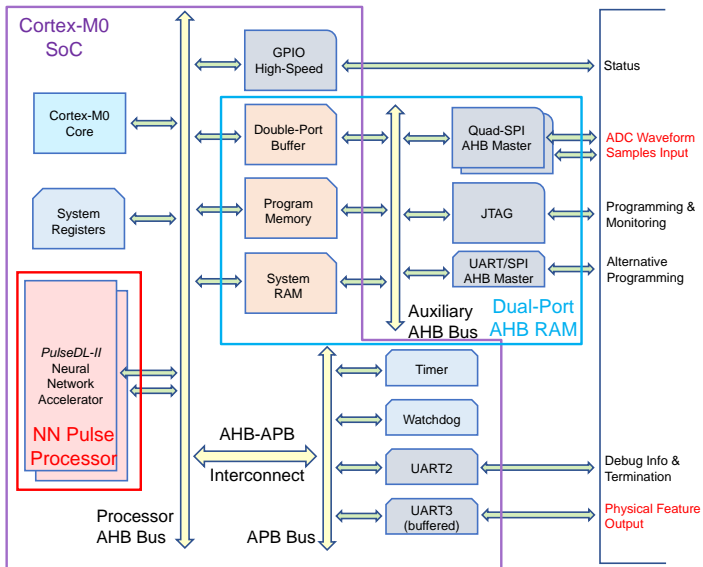
- ❑ 更少的量化位数和更高的精度
- ❑ 适合于 PulseDL-II 的 QAT 方案



基于自编码器的神经网络

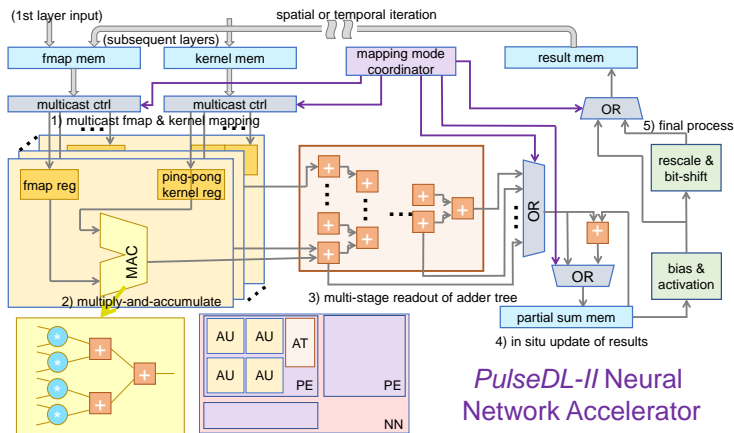
PulseDL-II—片上系统 (SoC) 结构

PulseDL-II 将一块Cortex-M0 微控制器内核嵌入数字设计:



PulseDL-II—神经网络加速器架构

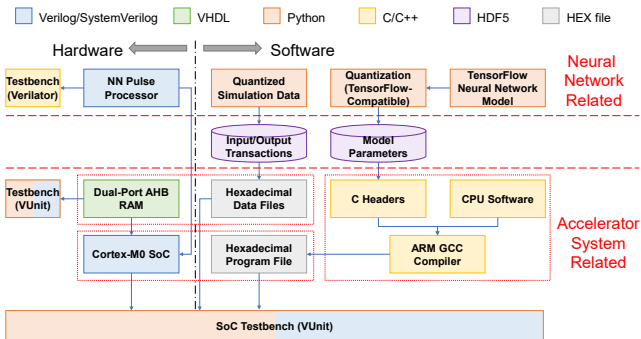
PulseDL-II 中的 NN 加速器采用基于模板的设计方法:



- AU, PE, NN 三级参数化的设计模板
- 与上一版设计相比, PE 具有更加独立的功能


PulseDL-II—软硬件协同设计方案

通过软硬件协同设计，与TensorFlow深度学习框架融合：




基于权重不变的嵌入式软件：

- 按层流水线推理
- 事件级别并行操作




PulseDL-II—性能仿真评估




使用的网络负载 (33.4k MACs, 18.8k param)

评估平台: Xilinx ZCU104 评估板


- 推理时间: 减少 1.83 倍
- 消耗能量: 减少 1.81 倍
- LUTs/乘法器: 减少 1.40 倍



性能



功耗



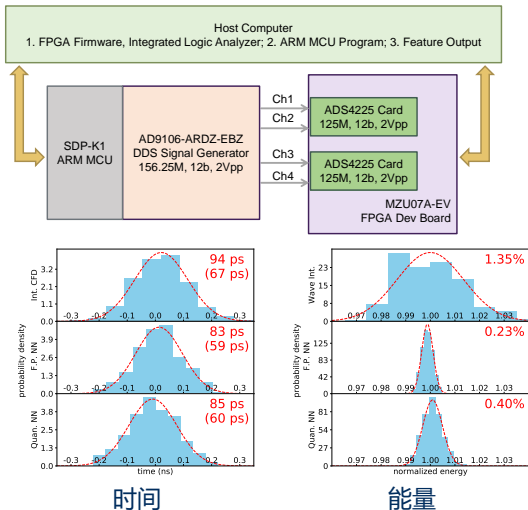
面积

PulseDL-II—实验验证



Xilinx Zynq UltraScale+ FPGA

- ❑ 功耗消耗：数据获取前端 (0.371 W)、加速器 SoC (0.541 W)
- ❑ 总延迟：165 μs (神经网络推理 113.8 μs)
- ❑ 吞吐量：8.3k 事件/s



(P. Ai et al 2023 TNS 70(6) 971–978)

总结展望

ECAL 现有前端电子学

NICA-MPD ECAL 现有前端电子学的结构和主要参数:

探测器主要参数:

- 截面积: 40*40 mm²
- WLS光纤数: 16根
- 堆叠层数: 220层
- 铅片厚度: 0.35 mm
- 闪烁体厚度: 1.5 mm
- 辐射长度: 11.8 X₀

耦合



SiPM

SiPM主要参数:

- 像素尺寸: 25 um
- 光敏面积: 6*6 mm²
- 像素数量: 57600
- 填充因子: 47%

焊接

电缆连接


波形处理



64路ADC
采样板

光纤传出

事件重建




Shashlik探测器



前放板PCB

提供偏压



高压系统

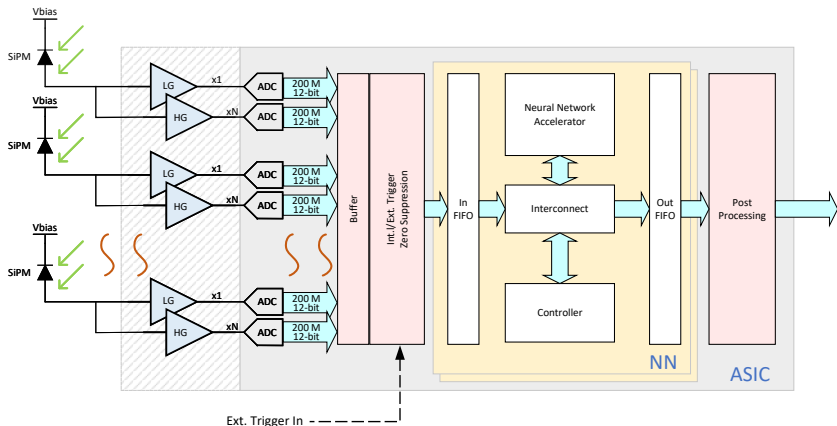
前端电子学主要参数:

- 64通道, 12比特, 62.5 M采样率ADC
- 通过光纤链路进行数据读出、触发和定时
- 功耗约为250 mW/通道, 需要专门的水冷系统进行散热

5

ECAL 前端电子学的升级

基于 ADC 和脉冲神经网络加速器的前端电子学方案：



小结

从算法角度：

- 以神经网络为代表的机器学习算法，能在**更大的参数范围**（系统带宽，电子学噪声）取得**近似最优**的性能
- 鉴于人工智能的不断发展，许多成果可以应用于**探测器前端信号处理**，其理论和实践在具体问题上得到进一步的丰富和增强

从硬件角度：

- 在探测器前端完成特征的提取和压缩，可降低电子学带宽和功耗，给系统设计者提供了新的**参考路径**
- 该项技术在高能物理探测器、核医学影像与治疗设备、高能激光物理研究等方面有**潜在的应用价值**

谢谢!



华中师范大学
CENTRAL CHINA NORMAL UNIVERSITY