

Развёртывание нейронной сети на платформе Zynq UltraScale+

Дмитрий Шадрин,
Инженер по применению Xilinx

Макро Групп – официальный партнёр Xilinx в России


План вебинара

- ◆ Виды нейронных сетей и сферы их применения;
- ◆ Методы повышения производительности нейронных сетей;
- ◆ Обзор продуктов Xilinx для развёртывания нейронных сетей;
- ◆ Обзор поддерживаемых нейронных сетей ;
- ◆ Перспективные аппаратные решения;
- ◆ Пример развёртывания готовой нейронной сети на базе отладочной платы ZCU104.


1. Виды нейронных сетей и сферы их применения

Виды нейронных сетей и сферы их применения


Нейронная сеть – это математическая модель, а также её программная или аппаратная реализации, построенная по принципам функционирования биологических нейронных сетей — сетей нервных клеток живого организма.



Нервные клетки



Нейронная сеть



Виды нейронных сетей и сферы их применения

Основными сферами применения нейронных сетей в мире являются:



Экономика




Медицина



Транспорт



Телекоммуникации



Производство



Безопасность



Обработка данных

Виды нейронных сетей и сферы их применения

Xilinx делает упор на 2 сферы применения нейронных сетей:



Безопасность

- Классификация объектов
- Детектирование и распознавание лиц
- Детектирование и распознавание позы человека




Транспорт


- Семантическая сегментация
- Определение дорожной разметки
- Обнаружение пешеходов и автомобилей
- Распознавание номерных знаков автомобиля

Виды нейронных сетей и сферы их применения


Виды нейронных сетей:




Перцептрон



Сеть Хопфилда



Автокодировщик



Свёрточная нейронная сеть


Методы повышения производительности нейронных сетей

Квантование

Float32




Int8



Original Value — Quantized Value

Прореживание (pruning)

Удаление связей



Обзор продуктов Xilinx для развёртывания нейронных сетей

DNNDK (Deep Neural Network Development Kit)



Особенности:

- Решение с полным стеком для разработки приложений глубокого обучения;
- Полный набор оптимизированных инструментов;
- API для программирования на C / C++.



Инструменты:

DECENT

N²Cube

DNNC

Simulator

DNNAS

Profiler

Обзор продуктов Xilinx для развёртывания нейронных сетей

DECENT



Прореживание (pruning) и квантование нейронных сетей

DNNC



Компилятор для DPU – процессора глубокого обучения

DNNAS



Сборка инструкций DPU в двоичный код ELF

N2Cube



Загрузчик приложений DNNDK

Simulator



Симулятор DPU

Profiler



Сбор и визуализация данных


Обзор продуктов Xilinx для развёртывания нейронных сетей

Vitis AI

Особенности:

- Набор предварительно оптимизированных моделей;
- Большая коллекция инструментов для работы с свёрточными сетями;
- Унифицированные высокоуровневые API C++ и Python для максимальной переносимости;
- Настраивает эффективные и масштабируемые IP-ядра

Инструменты:



Обзор продуктов Xilinx для развёртывания нейронных сетей

DPU



Deep-Learning Processor Unit – инструмент для работы с глубокими нейронными сетями

AI Optimizer



Инструмент прореживания (pruning) нейронных сетей

AI Quantizer



Инструмент квантования нейронных сетей

AI Compiler



Компилятор моделей и сборщик инструкций

AI Profiler



Профилирование и визуализация приложений

AI Library




Набор высокоуровневых библиотек и API для DPU

AI Runtime



Загрузчик приложений

Обзор продуктов Xilinx для развёртывания нейронных сетей



Обзор поддерживаемых нейронных сетей

Применение	Задача	Алгоритм
Общее	Классификация изображений	Resnet50, Inception v1, BN-inception, VGG16, SqueezeNet, MobilenetV2
	Обнаружение объекта	MobilenetV2-SSD, SSD, YOLO v2, YOLO v3, Tiny YOLO v2, Tiny YOLO v3
	Сегментация	ENet, ESPNet
Лицо	Обнаружение лица	SSD, Densebox
	Распознавание лица	ResNet + Triplet / A-softmax Loss
	Распознавание атрибутов лица	Classification and regression
Пешеход	Обнаружение пешеходов	SSD
	Оценка позы	Coordinates Regression

Обзор поддерживаемых нейронных сетей

Применение	Задача	Алгоритм
Видео Аналитика	Обнаружение объекта	SSD, RefineDet
	Распознавание пешеходов	GoogleNet
	Распознавание автомобильных атрибутов	GoogleNet
	Распознавание логотипа автомобиля	Модифицированный Densebox + GoogleNet
	Обнаружение номерного знака	Модифицированный DenseBox
	Распознавание номерных знаков	GoogleNet + Многозадачное обучение
ADAS/AD	Обнаружение объекта	SSD, YOLOv2, YOLOv3
	Обнаружение переулка	VPGNet
	Семантическая сегментация	FPN

Перспективные аппаратные решения

Ускорительные карты Alveo



Базы данных



90x

Машинное Обучение



20x

Финансы



89x

Видео



12x


HPC & Life Sciences



10x

Перспективные аппаратные решения


Ускорительные карты Alveo



Перспективные аппаратные решения


Ускорительные карты Alveo

REDUCE ML INFERENCE LATENCY BY 3X



Перспективные аппаратные решения

Ускорительные карты Alveo



- вывод быстрее в 4 раза, чем на GPU
- высочайшая производительность на ватт
- лёгкие в работе ML-фреймворки и API



NIMBIX

Alibaba Cloud
aliyun.com



aws marketplace




Xilinx Alveo

Перспективные аппаратные решения


Новая архитектура Versal ACAP

- ◆ Scalar Engines
 - Arm® Cortex™-A72 APU
 - Arm Cortex-R5 RPU
- ◆ Adaptable Engines
 - CLBs
 - Internal Memory
- ◆ Intelligent Engines
 - AI Engine
 - DSP Engine
- ◆ Connectivity
 - PCIe w/CCIX
 - Ethernet
 - DDR Memory Controllers
 - Transceivers
 - I/O
- ◆ Platform Resources
 - Network-On-Chip
 - Platform Management Controller




Перспективные аппаратные решения

Новая архитектура Versal ACAP




Перспективные аппаратные решения Everspin STT-MRAM для Xilinx FPGA

- Энергонезвисимость
- Объем 256 Мбит и 1 Гбит
- 256 Мбит организация
(32Мб x 8, 16Мб x 16)
- 256Мбит:
VDD = 1.5v +/- 0.075v
- 1 Гбит организация
(128Мб x8, 64Мб x16)
- 1 Гбит:
VDD = VDDQ = 1.2v
- Тактовая частота 667MHz
- Интерфейс ST-DDR3 и ST-DDR4
- Корпус 78-BGA и 96-BGA



Перспективные аппаратные решения

Everspin nvNITRO Storage Accelerator




Перспективные аппаратные решения

Everspin nvNITRO Storage Accelerator



Form Factor	PCIe (HHHL)	U.2 (15mm)
Interface	PCIe Gen3 x8	PCIe Gen3 x4
Capacity	1GB,	1GB
Protocol/Access Modes	NVMe 1.2.1 & Direct Memory Access (PCIe MMIO, CMB, P2Pmem, PMR)	
Performance IOPs (R/W) (4K Random R/W)	1.5M / 1.5M (x8 PCIe)	750K / 750K
Latency (R/W) QD=1	5.1 μ S (Read) / 5.9 μ S (Write)	
BER / Data Retention	< 1 e ⁻¹⁸ / Powered down DR is 3+ months @ 50C, Powered up DR is lifetime at full operating temperature	
Endurance	1e ⁹ Access to each and every page, Unlimited uniform access for 10+ years	

Пример развёртывания нейронной сети на базе отладочной платы ZCU104



Подробное описание
процесса установки в
документе [UG1354](#)

Пример развёртывания нейронной сети на базе отладочной платы ZCU104




Настройка загрузки платы с
microSD-карты

Необходимое ПО для Windows:



Xming



Tera Term

Спасибо за внимание!

Компания Макро Групп:

- ◆ официальный партнер Xilinx
- ◆ комплексная поставка электронных компонентов
- ◆ техническая поддержка по всем вопросам применения продукции и ПО Xilinx
- ◆ контрактное производство электроники

Обращайтесь:

- ◆ Dmitriy.Shadrin@macrogroup.ru
- ◆ Dmitry.Khorkov@macrogroup.ru
- ◆ fpga@macrogroup.ru



Ссылки на материалы

[Инструкция по установке и запуску \(GitHub\)](#)

[UG1354-Vitis AI Library User Guide](#)

[Образ для ZCU104](#)

[ZCU104 AI Model](#)

[Vitis AI Library 1.0](#)

Команды для терминала

Задаём IP-адрес платы (через Com-порт):

```
sudo ip link set eth0 up  
sudo ip addr add 169.254.177.200/255.255.0.0 dev eth0
```

Устанавливаем пакеты:

```
dpkg -i vitis_ai_model_ZCU104_2019.2-r1.0.deb  
dpkg -i vitis_ai_library_2019.2-r1.0.deb
```

Запуск facedetect:

```
cd /usr/share/vitis_ai_library/samples/facedetect  
./test_video_facedetect densebox_640_360 0 -t 8
```

Запуск Yolov3 (дорожная ситуация):

```
cd /usr/share/vitis_ai_library/samples/yolov3  
./test_video_yolov3 yolov3_bdd 0 -t 8
```

Запуск posedetect:

```
cd /usr/share/vitis_ai_library/samples/posedetect  
./test_video_posedetect sp_net 0 -t 8
```

Запуск classification:

```
cd /usr/share/vitis_ai_library/samples/classification  
./test_video_classification resnet50 0 -t 8
```

Запуск segmentation:

```
cd /usr/share/vitis_ai_library/samples/segmentation  
./test_video_segmentation fpn 0 -t 8
```