



利用FPGA加快 嵌入式人工智能系统的部署

北京威视锐科技

姚远



公司简介



北京威视锐科技有限公司, 成立于 2008年的国家级高新技术企业, 专注于提供创新性科研和教学解决方案, 主要面向无线通信频谱安全、人工智能视觉感知与核生化监测防护等领域。

威视锐是全球最大的可编程芯片厂商XILINX的认证设计伙伴和授权培训中心, 也是全球领先的模拟芯片厂商ADI的中国区大学计划推广合作伙伴。同时, 威视锐也是IBM研究院和微软研究院的长期技术提供商。




软件定义无线电SDR



软件定义测试仪SDI



软件定义视觉平台SDVision



软件定义SoC平台SDSoC

典型客户



1000+
行业客户



200+
大学和研究机构




20+
国家和地区

Microsoft®

Duke
UNIVERSITY



SONY



FUJITSU



ZTE中兴



NOKIA
Connecting People



无线通信频谱安全

核心产品

行业定制

学术合作

联合实验室



面向不同应用的全系列SDR平台
实时软件无线电平台，
加快下一代无线通信系统的验证



人工智能视觉感知



从终端到云端的机器学习推断

机器学习的应用正迅速地扩展至越来越多的终端市场，在终端、在云端或者在那些基于端处理与基于云的数据分析相结合的混合解决方案中。Xilinx 为部署高级高效率神经网络、算法及应用提供各种开发堆栈及硬件平台。

核生化监测防护

放射性元素测量仪器

核设施环境检测

高能物理科研和教学仪器





电子工程师训练营

PART
4

V3学院是威视锐旗下的教育培训品牌, 专注于提供系统化工程教育培训, 解决高校人才培养和企业用人需求的矛盾。V3学院的专业设置主要有嵌入式系统、人工智能和IC设计等几个方向的国内紧缺专业。

目前, V3学院拥有北京和上海两大培训基地, 西安、南昌等多个培训中心。每年参加V3学院培训或者研讨会的在校学生数量超过2000人, 在职工程师数量超过1000人。

同时, V3学院通过免费视频、在线直播、微信课堂等多种在线方式, 帮助学员完成远程学习和训练。公司2008年成立以来, 网络上免费的培训资料影响近万人。



目录

C O N T E N T S

1

AI和深度学习背景

- 发展简史
- 行业背景
- 平台对比
- FPGA优势

2

云端智能应用

- 业务需求
- 产品形态
- 开发案例
- 机遇挑战

3

终端智能应用

- 面向低延迟
- 面向工业检测




PART
1

AI背景介绍

发展历史 行业应用 平台对比 FPGA优势

AI发展简史



AI视觉大事件

人工智能 | 机器学习 | 计算机视觉

2012年, ImageNet上图像识别率一下子提高十几个百分点 (以往通常是1年1~2个点) ;

2016年, 谷歌下了一盘棋叫AlphaGo;

2017年, 人工智能在自动驾驶 (百度)、医疗诊断 (IBM) 方面不断有突破

2018年, AI芯片批量上市, 行业门槛降低, 出现成熟应用场景

技术要素



深度学习核心：

学习算法的设计，你设计的大脑到底够不够聪明；
要有高性能的计算能力，训练一个大的网络；
必须要有大数据；

适当的用户场景；
成熟的商业模式。



深度学习计算平台

CPU

面向逻辑运算和事务处理

首要目标是人机界面和多任务调度。

GPU

面向密集的、高并行的计算

首要目标是运算以及数据吞吐量。

CPU+GPU

异构运算结构，协同工作

深度学习的主流架构，大量开源资源

ARM+FPGA

半定制化的可编程硬件电路

可以根据网络结构和运算加速，效率更高

TPU和各种SoC

全定制化的加速芯片

Google为Tensor Flow专门定制，效率最高





FPGA Vs. GPU

- **Cloud端**

峰值性能、灵活性、功耗

- **Edge端**

体积、功耗、实时性



FPGA优势

体积
功耗

动态
配置

结构
定制

可转
ASIC



FPGA芯片结构特别适合模型预测，但是开发难度和门槛限制了其广泛应用。



云端部署

PART
2

业务需求 产品形态 开发案例 机遇挑战



云端的业务需求

全球七大数据中心

阿里巴巴、亚马逊、百度、脸书(Facebook)、谷歌、微软和腾讯




高计算量负载业务

基因测算、金融分析、视频处理、大数据、安全加密、机器学习推断、流媒体、视频直播


FPGA 的优势

动态配置 | 重复调用 | 可池化或隔离

利用动态可重配置技术，FPGA能在一秒之内快速切换到不同的设计方案，面对下一个工作负载进行硬件优化。



产品形态



XCVU9P-L2FSGD2104E




Amazon EC2 F1 实例

在 AWS 云中运行可自定义 FPGA



快速部署自定义硬件加速

借助 F1 实例，您只需在 AWS 管理控制台中单击几下，即可在 AWS 上部署自定义 FPGA。F1 实例可以有一个或多个与其关联的 AFI，让您能够快速灵活地在同一个实例上运行多个加速。此外，F1 实例还为您提供了编程、模拟、调试和编译硬件加速代码所需的易于访问的工具。



改变 FPGA 的经济性

借助 F1 实例，您无需自行购买 FPGA 或购买专门的硬件来运行 FPGA，即可为您的工作负载部署硬件加速，从而大幅降低为应用程序部署硬件加速所需的成本。如此一来，您便能够将 FPGA 用于更多工作负载，如基因组学研究和财务风险建模。



可预测的性能

FPGA 通过一种专用的 PCI Express (PCIe) 结构连接到您的 F1 实例，从而使各个 FPGA 能够共用同一内存空间，并能够以高达 12GBps 的速度相互通信。PCI Express 结构与其他网络相隔离，且 FPGA 不会跨实例、用户或账户进行共享。此设计可确保您在使用 FPGA 时只有您的逻辑在其上运行，有助于提供一致的性能。



可使用您现有的 FPGA 算法

您可以轻松地将您现有的加速算法引入 AWS，并在 F1 实例中使用它们。F1 实例中的 FPGA 和 HDK 中的开发人员工具与硬件加速代码和采用 Verilog 和 VHDL 等常用硬件设计语言或 C 和 Go 等高级语言的设计工具兼容。

F1实例配置

F1实例详细信息

实例类型	FPGA 卡	vCPU	实例内存 (GiB)	SSD 存储 (GB)	增强型联网	优化的 EBS
f1.2xlarge	1	8	122	470	是	是
f1.16xlarge	8	64	976	4 x 940	是	是

- Xilinx UltraScale+ VU9P，采用16纳米制程工艺制造。

- 64 GiB ECC保护内存，配合288位总线（四DDR4通道）。


- 专用PCIe x 16 CPU接口。

- 约250万逻辑元素。

- 约6800套数字信号处理（简称DSP）引擎。

- 提供虚拟JTAG接口用于调试。

工作方式



产品应用



财务分析

金融服务行业对多种应用程序的 HPC 功能需求一直在不断增加，包括风险建模和分析、针对安全性的事务分析、高频交易等。金融服务组织可以使用 F1 实例来提高风险建模和分析的准确性，从而显著改进他们的决策制定流程。



大数据搜索和分析

许多大数据应用程序对数据分析和搜索的数量、多样性和速度要求不断提高，导致客户正在寻求硬件加速来满足这些要求。对于这些应用程序，客户可以利用 F1 实例的增强性能来满足其大数据分析和搜索要求。

基因组学研究

必须由基因组学研究人员处理的生物数据的数量和复杂性不断增加，逐步达到了 PB 级范围。研究人员和临床医生必须非常快速地处理这些数据集，以满足医生及其患者的需求。对于此类有时间要求的使用案例，F1 实例是理想的解决方案。



实时视频处理

高性能广播级视频应用程序 (如图片处理、视频分析及视频转码和压缩) 需要使用实时分析功能。F1 实例是满足这些应用程序要求的理想解决方案，且不会影响视频质量。



安全性

F1 实例对于许多安全性应用程序来说非常有用，其中包括防篡改、信息保证和可信关系管理解决方案。



机遇挑战

开启了FPGA as a Service (FaaS) 的新时代

国内的BAT和华为也推出类似的服务

为行业加速用户提供新的选项，可能会出现新的商业模式



PART
3

终端部署

CNN的特点 性能优化 SDSoC PowerAI

终端的场景

规模化应用：消费电子、安防、零售

差异化应用：工业自动化、机器人

SoC方案

FPGA和嵌入式GPU方案




从终端到云端的机器学习推断

机器学习的应用正迅速地扩展至越来越多的终端市场，在终端、在云端或者在那些基于端处理与基于云的数据分析相结合的混合解决方案中。Xilinx 为部署高级高效率神经网络、算法及应用提供各种开发堆栈及硬件平台。


响应时间的优势

Embedded GPU & Typical SoC





ZYNQ

ZYNQ
MPSoC





基于机器学习的视觉应用



DeepRED: 面向低延迟应用解决方案





IBM PowerAI Vision



IBM PowerAI工具AccDNN软件（云端）和 Xilinx Vivado 设计流程

典型应用：低延迟、快速响应、功耗受限、桌面GPU级算力需求

应用示例



PowerAI Inference Engine service for FPGA embedded system



Pre-trained models & weights files by Caffe

Choose hardware and upload trained DNN result


Estimate FPGA resource and performance by profiling

SuperVessel Cloud

Encrypt the FPGA IP

Generate FPGA IP for DNN

Change AccDNN parameters and do optimization



Compile FPGA SDK with DNN IP

Flash FPGA

Third party embedded system



IBM PIE工具开发流程

步骤1: 登录PowerAI 云服务器

The screenshot displays the PowerAI Interference Engine web interface. At the top, there is a navigation bar with the logo and the text "PowerAI Interference Engine". Below this, a central banner features a stylized head icon with a brain-like pattern and the text "PowerAI Interference Engine". A descriptive paragraph follows: "PowerAI Interference Engine (PIE)是一种可以将训练好的深度神经网络自动转换成FPGA RTL级实现的全新解决方案, 无需任何编程工作。你可以将生成的IP核导入到我们官方支持的FPGA开发套件用于原型验证, 或者用于你自己的加速设计方案。"

Two main action buttons are visible: "加速器" (Accelerator) with the subtext "创建/删除/运行加速器" and "加速器开发套件" (Accelerator Development Kit) with the subtext "下载加速器开发套件".

The main content area is titled "创建加速器" (Create Accelerator). It includes a "概述" (Overview) section with a "名称" (Name) field containing "dddd". The "选择硬件" (Select Hardware) section is highlighted with a red box and contains a dropdown menu with the following options: "Xilinx ZC706 Evaluation Board", "Xilinx ZC706 Evaluation Board", and "V3 Technology DeepRed Board". Below this, a table lists hardware specifications:

PL SIDE MEMORY	LUTS	18KB BLOCK RAMS	DSP SLICES
DDR3 SODIMM 1GB	218600	1090	900

The "选择FPGA资源利用率" (Select FPGA Resource Utilization) section shows a dropdown menu set to "30%".

At the bottom, a progress bar indicates the current step: "设置名称" (Set Name) is completed, "选择硬件" (Select Hardware) is the current step, and "上传网络模型" (Upload Network Model), "评估FPGA资源" (Evaluate FPGA Resources), and "上传权重文件" (Upload Weight Files) are pending. Navigation buttons for "上一步" (Previous Step) and "下一步" (Next Step) are also present.

步骤2: 上传网络模型文件, 评估资源利用效率

← 创建加速器

概述

名称: cifar10_quick_ristretto
利用率: 50%
板卡: Xilinx ZC706 Evaluation Board
网络模型文件: cifar10_quick_MAX.prototxt

资源评估结果

批处理数量: 1

optimize

KPF: 核并行化因子, 在3D卷积中同时计算的核的个数。
CPF: 通道并行化因子, 在3D卷积中同时计算的通道数。

吞吐量: 3906.25 图片/秒, DSP效率: 99.34%

层名称	类型	CPF	KPF	乘累加	DSP	参数	BRAM18E	延迟(US)	DDR带宽(MB/S)
conv1	Convolution	4	16	3276800	64	3200	39	256.00	6400.00
pool1	Pooling		32	0	0	0	15	11.52	
conv2	Convolution	16	8	6553600	128	25600	76	256.00	25600.00
pool2	Pooling		32	0	0	0	15	2.88	
conv3	Convolution	8	8	3276800	64	51200	48	256.00	25600.00
pool3	Pooling		32	0	0	0	15	1.44	



上一步

下一步

← 创建加速器

概述

名称: cifar10_quick_ristretto
利用率: 50%
板卡: Xilinx ZC706 Evaluation Board
网络模型文件: cifar10_quick_MAX.prototxt

上传权重文件

请上传Caffe训练好的权重.cafemodel文件。

选择文件



上一步




创建

深度学习加速器列表


加速器名称	创建时间	完成时间	状态	操作
[模糊]	[模糊]	[模糊]	已完成	下载 ↓ 删除 🗑
[模糊]	[模糊]	[模糊]	已完成	下载 ↓ 删除 🗑
cifar10_quick_ristretto	2017-09-25 05:23:49	2017-09-25 05:25:26	已完成	下载 ↓ 删除 🗑

步骤3: 上传权重文件, 生产IPcore

利用威视锐SDK，生成FPGA下载文件



实际路测



面向工业检测应用解决方案-EagleGo


Xilinx SDSoC软件工具

威视锐 EagleGo: 基于Xilinx Zynq 7020 FPGA,
集成视频输入输出和扩展IO

典型场景: 体积小、功耗低、可定制





CNNs网络典型结构




卷积层的计算量累计超过整个算法的90%!

[1] A. Krizhevsky, etc. Imagenet classification with deep convolutional neural networks. NIPS 2012.

[2] J. Cong and B. Xiao. Minimizing computation in convolutional neural networks. ICANN 2014



FPGA上硬件实现的挑战



挑战：资源利用率限制

解决方案：循环展开&流水线



挑战：片上存储器限制

解决方案：循环平铺



挑战：带宽限制

解决方案：数据复用


系统解决方案：联合优化

— 将计算和通信进行匹配

系统优化

实现案例：物体分类摄像头


```
float result[10]={0};
// resize 1080P to 32X32 --||
zoom(pVideoBuffer, tgt_img);
conv1(tgt_img,rst1);
conv2(rst1,rst2);
//image process
identi_cal((float*)rst2,result);
//classification
int item_class=0;
int i;
float Pmax = 1.0;
for(i=0;i<10;i++)
{
    if(result[i]>Pmax)
    {
        Pmax=result[i];
        item_class=i;
    }
}
```



实现案例：SDSoc技术实现卷积核加速

```
14 | int i,j,x,y;
15 | for (i = 0; i < 28; i++) {
16 |     for (j = 0; j < 28; j++) {
17 |         #pragma HLS PIPELINE
18 |         float result = 0;
19 |         for (x = 0; x < A_NCOLS; x++) {
20 |             // multiply accumulate broken into individual operators
21 |             // so that AutoESL can infer two FP operators
22 |             #pragma HLS UNROLL
23 |             for(y = 0; y < A_NCOLS; y++) {
24 |                 float product_term = in_A[x][y] * in_B[x+i][y+j];
25 |                 result += product_term;
26 |             }
27 |         }
28 |         out_C[i*28+j] = result;
29 |     }
30 | }
31 | }
```

功能演示：基于Caffe的物体分类 (ZYNQ 7020)



AI领域合作伙伴

Microsoft[®]

IBM

Baidu 百度

megvii

DEEPIH TECH
深鉴科技

DEEPLINT
格 灵 深 瞳

创新应用方向





更多信息

威视锐: <http://www.v3t.com.cn>

V3学院: <http://www.v3edu.org>

V3学院微信课堂 (服务号)

