

深度学习在移动端的应用

杨延展 百度多模交互搜索部 高级工程师

目录

- 深度学习简介
 - 移动端落地方案
 - 移动端局限及解决技巧
-

目录

- 深度学习简介
- 移动端落地方案
- 移动端局限及解决技巧

深度学习 - 目标：寻找最佳函数

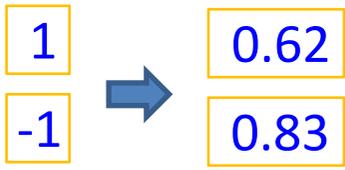
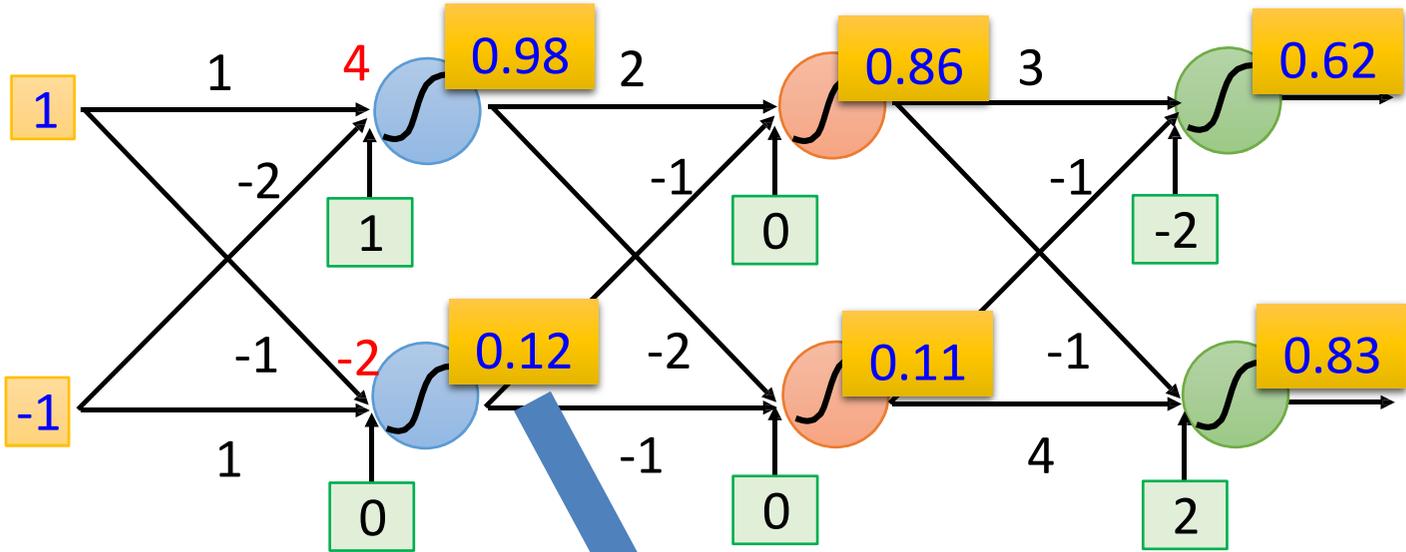
$$f(\text{audio waveform}) = \text{你好}$$

$$f(\text{cat image}) = \text{猫}$$

$$f(\text{嗨!}) = \text{你好}$$



深度学习 - 层（举例）：全连接层



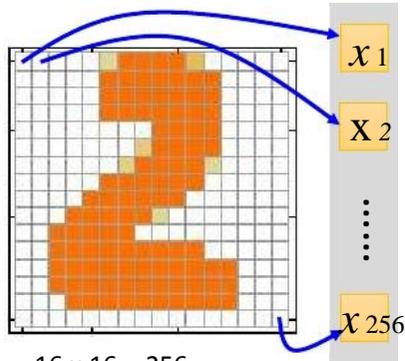
→ 猫

$$S(x) = \frac{1}{1 + e^{-x}}$$

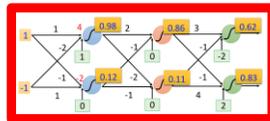
深度学习 - 预测过程

$$f\left(\begin{array}{|c|} \hline \text{Image of '2'} \\ \hline \end{array}\right) = \square 2 \square$$

Input



16 x 16 = 256
Ink → 1
No ink → 0

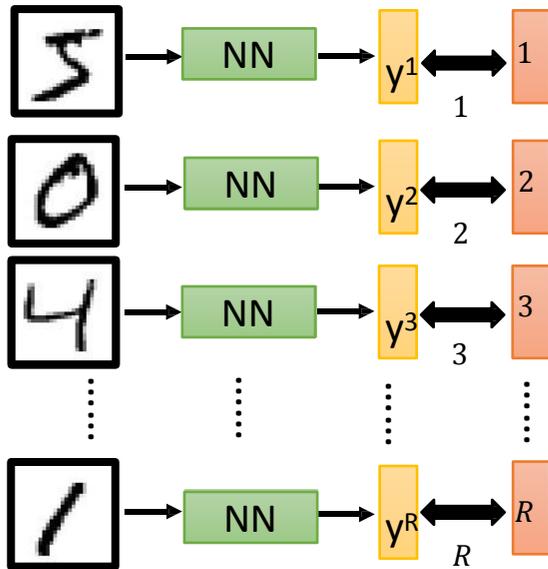


Output

	向量	概率	输出
Y ₀	0.62	0.05	is 0
Y ₂	0.83	0.8	is 2
...
Y ₉	...	0.1	is 9

The image is "2"

深度学习 - 训练过程



$$f\left(\begin{array}{|c|} \hline \text{2} \\ \hline \end{array} \right) = \square 2 \square$$

交叉熵：计算和目标向量的距离

图片

目标向量

$$\frac{1}{N} \sum_{i=1} D(S(WX_i + b), L_i)$$

平均交叉熵

概率函数

目录

- 深度学习简介
- 移动端落地方案
- 移动端局限及解决技巧

落地方案 - 可能的服务端及移动端分工

- 服务端训练 + 服务端识别
- 移动端训练 + 移动端识别
- 服务端训练 + 移动端识别

落地方案 - 移动端只适合识别过程



PC Server 训练模型文件



Model File

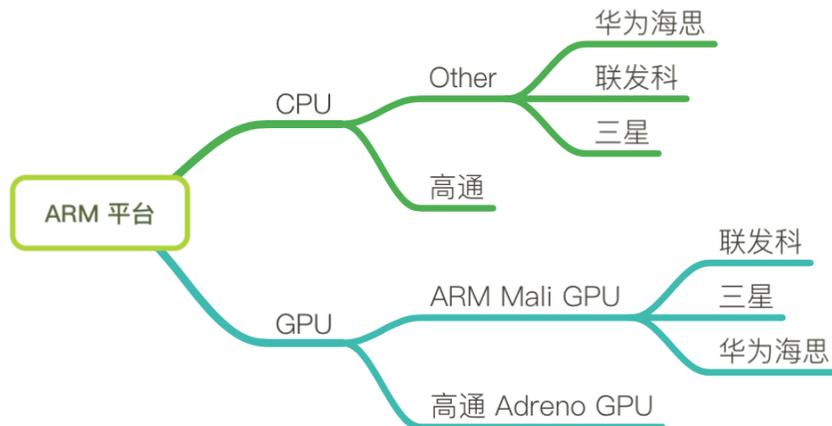


移动端加载模型进行识别

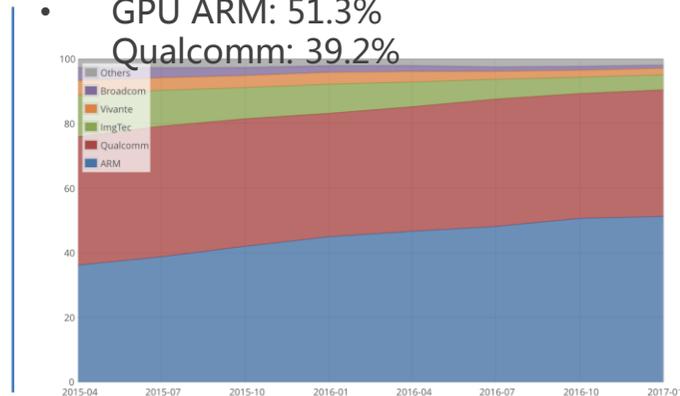


落地方案 - Android硬件现状

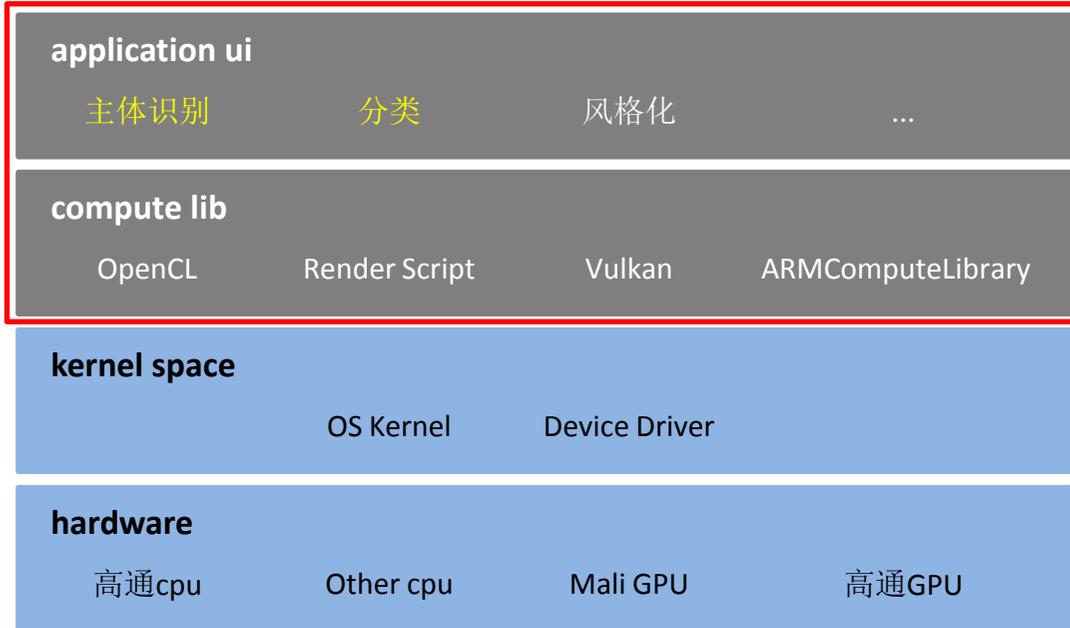
- CPU : 高通 & (三星、联发科、华为)
- GPU : Mali GPU
- CPU门槛1 : 骁龙600以上
- CPU门槛2 : Mali T820 4核以上



- CPU 98.1% 是ARMv7
- GPU ARM: 51.3%
Qualcomm: 39.2%



落地方案 - Android深度学习软件现状



落地方案 - 模型选择 CNN卷积和池化

1	0	0	0	0	1
0	1	0	0	1	0
0	0	1	1	0	0
1	0	0	0	1	0
0	1	0	0	1	0
0	0	1	0	1	0

原图

1	-1	-1
-1	1	-1
-1	-1	1

-1	1	-1
-1	1	-1
-1	1	-1

两个卷积核

Only $9 \times 2 = 18$ parameters

1 _{x1}	1 _{x0}	1 _{x1}	0	0
0 _{x0}	1 _{x1}	1 _{x0}	1	0
0 _{x1}	0 _{x0}	1 _{x1}	1	1
0	0	1	1	0
0	1	1	0	0

Image

4		

Convolved Feature

-1	-1	-1	-1
-1	-1	-2	1
-1	-1	-2	1
-1	0	-4	3

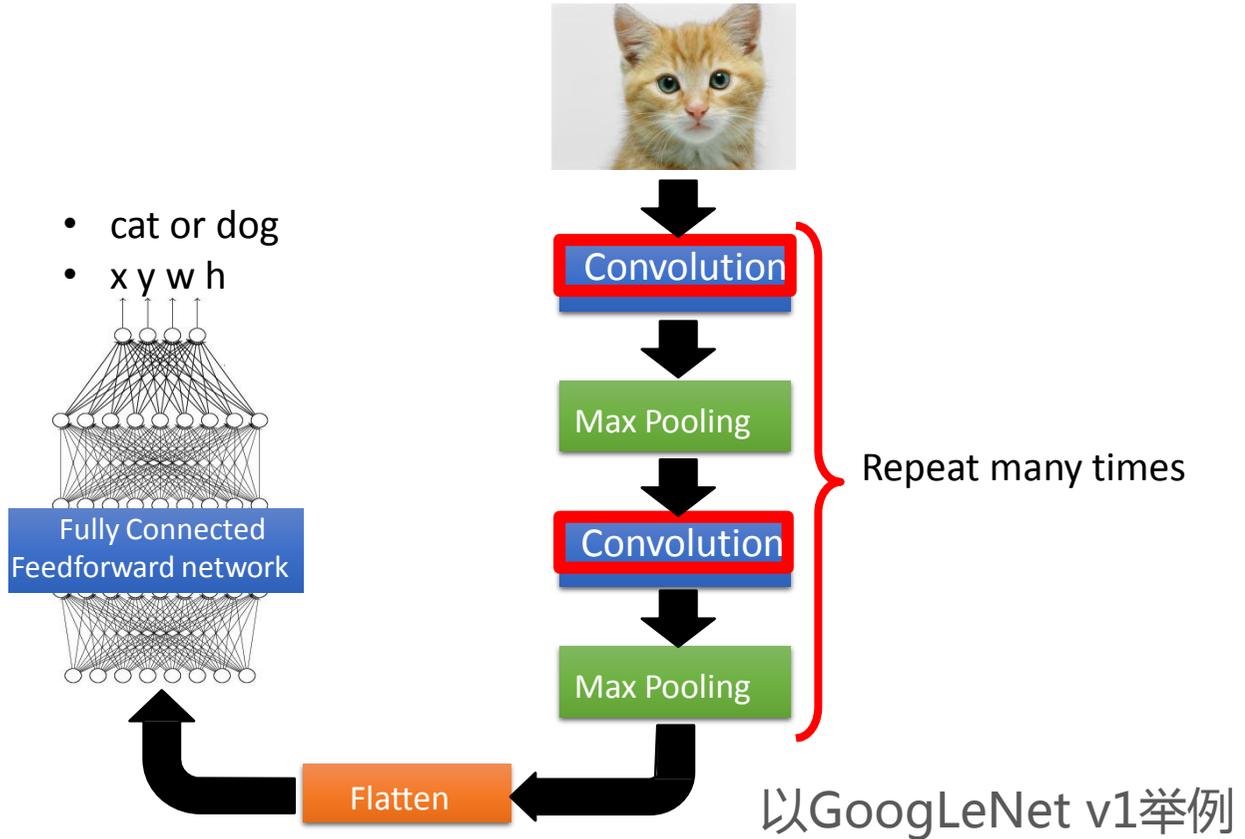


最大池化

-1	1
0	3



落地方案 - 模型选择 CNN常见拓扑



落地方案 - 框架选择

- 基于Caffe二次开发
 - 可读性
 - 通用性
 - 图像领域应用已久
 - 移植成功案例
- 针对CPU做主要优化
 - GPU的内存拷贝成本与运算效率的综合考量

目录

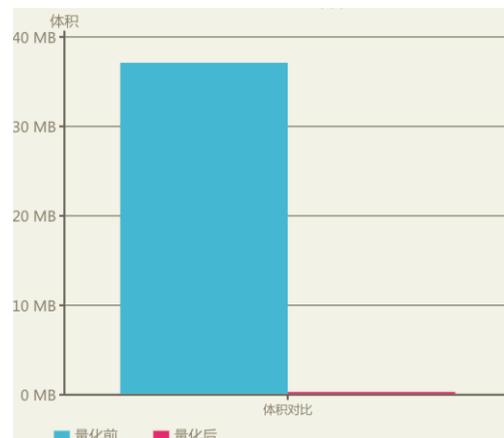
- 深度学习简介
- 移动端落地方案
- 移动端局限及解决技巧

移动端局限 - 安卓落地难点

	服务端	移动端
SO体积	无限制	特定App下严格限制
模型体积	500M+	<10M
加密	无需考量	特定App下严禁泄露
预测速度	类库极其成熟	有待填补
内存限制	无严格限制	内存极其有限
耗电量	无限制	严格限制

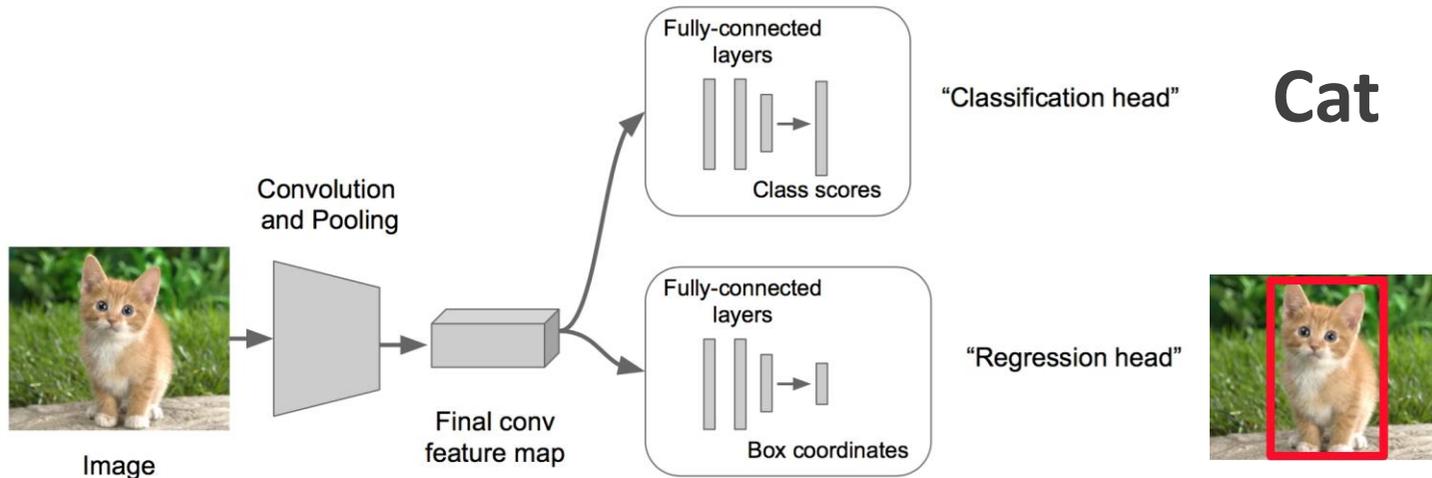
Tricks - SO体积：代码剪枝

Before	After
OpenBlas	手工实现
Glog、Gflag	摘除
Protobuf	手工实现Json解析
后向传播	摘除
层	缩减数量

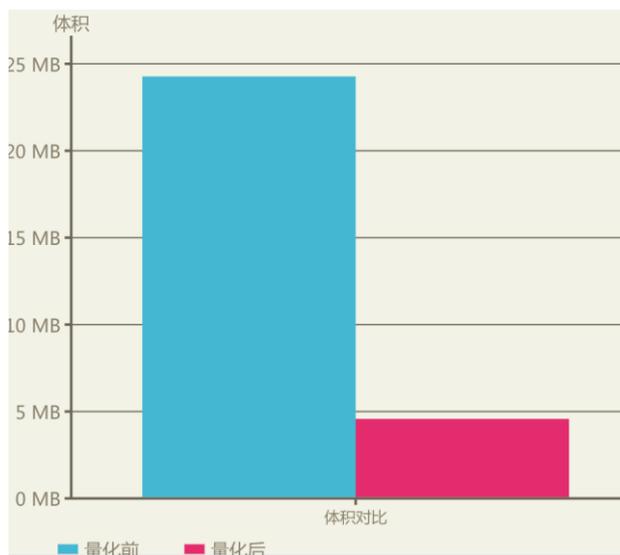


37MB -> 100k

Tricks - 模型体积：权值共享

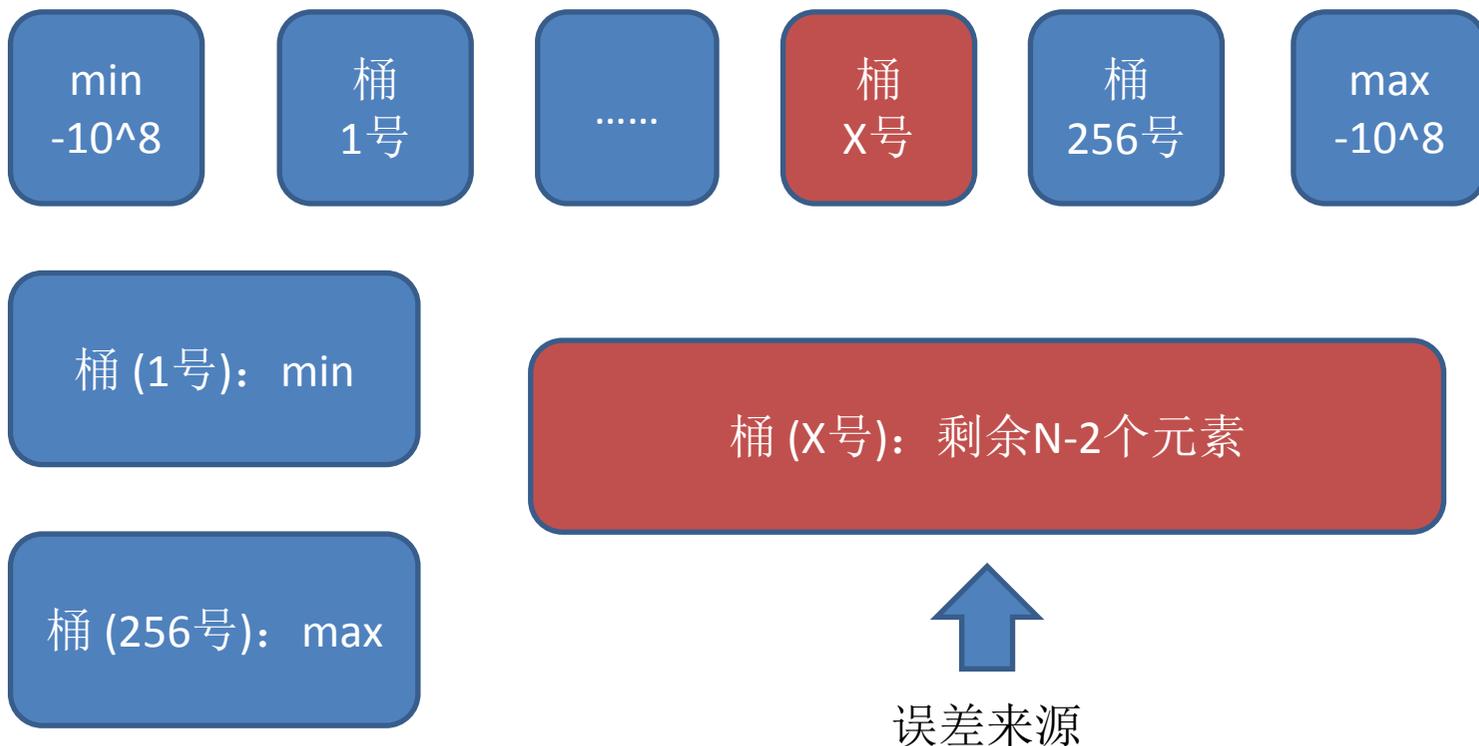


Tricks - 模型体积：量化

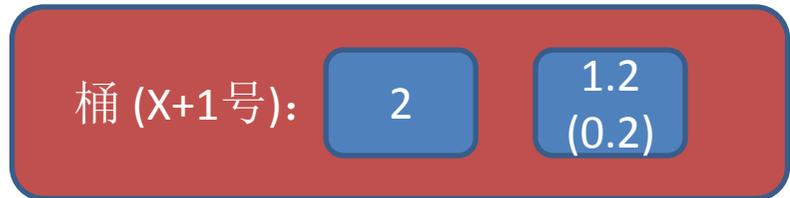
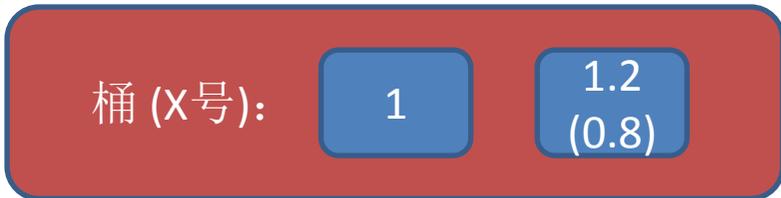
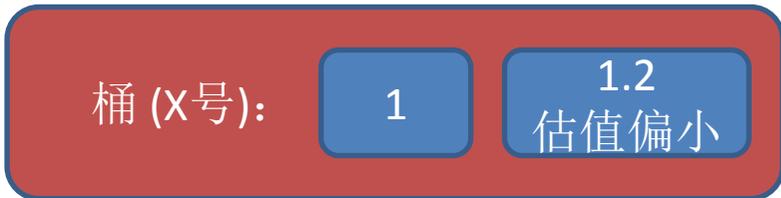
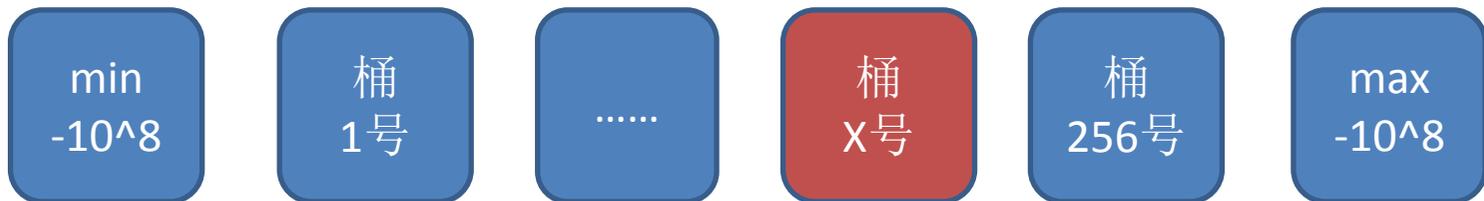


24.2 -> 4.5MB

Tricks - 模型体积：纠正量化的误差



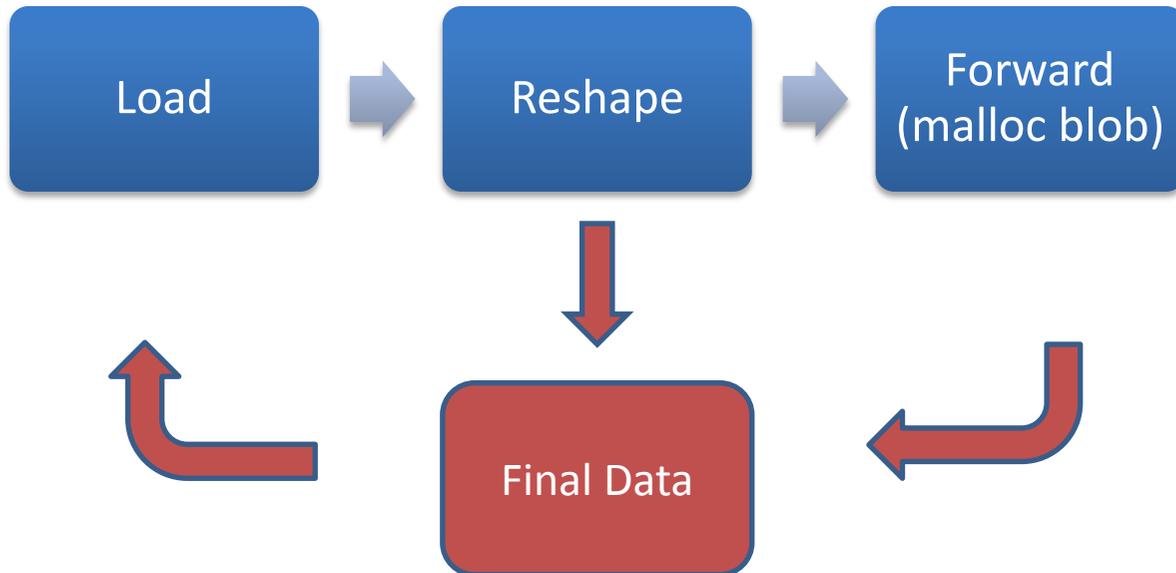
Tricks - 模型体积：纠正量化的偏好



Tricks - 模型体积：加密



Tricks - 速度：常规优化 调整overhead



Tricks - 速度：常规优化 数值计算

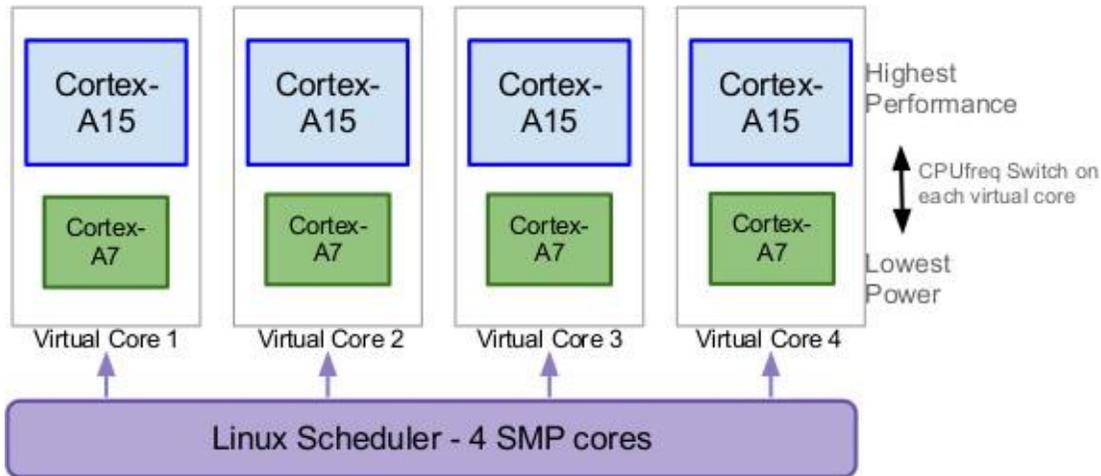
$$e^x = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \dots$$

$$\cos x = 1 - \frac{x^2}{2!} + \frac{x^4}{4!} - \frac{x^6}{6!} + \dots$$

$$\sin x = x - \frac{x^3}{3!} + \frac{x^5}{5!} - \frac{x^7}{7!} + \dots$$

记录Taylor展开的系数，用以实现快速的近似计算

Tricks - 速度 : CPU Affinity

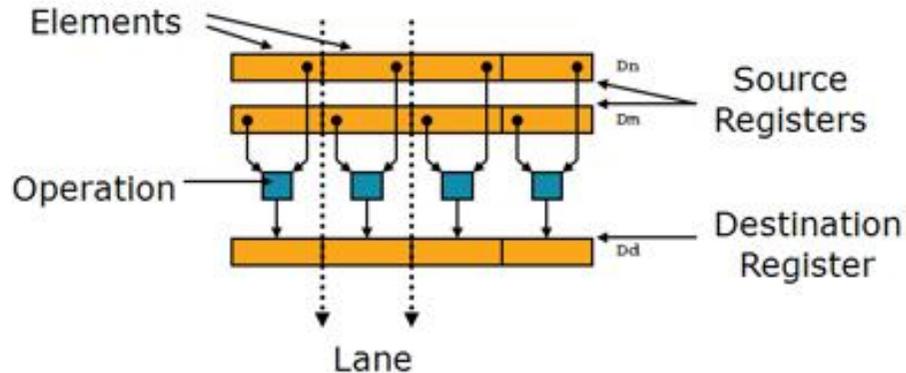
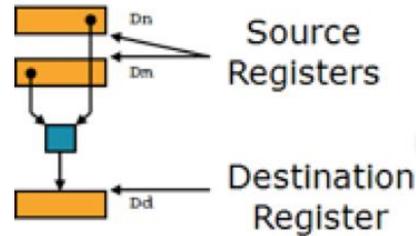


设置亲密度:

1. 减少线程切换。
2. 强制使用Big核心。

Tricks - 速度 : NEON intrinsics

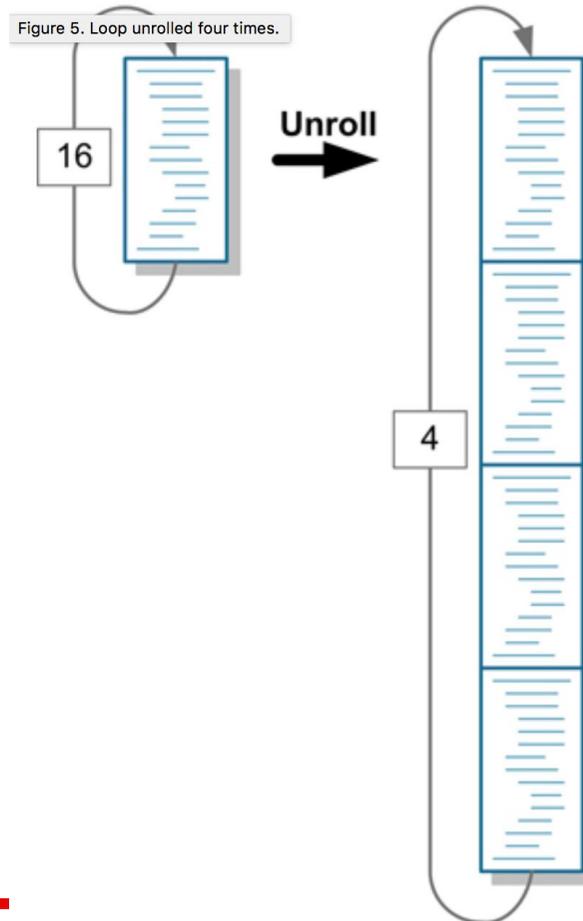
- 卷积
- 池化
- LocalRespNorm



Tricks - 速度：内联汇编

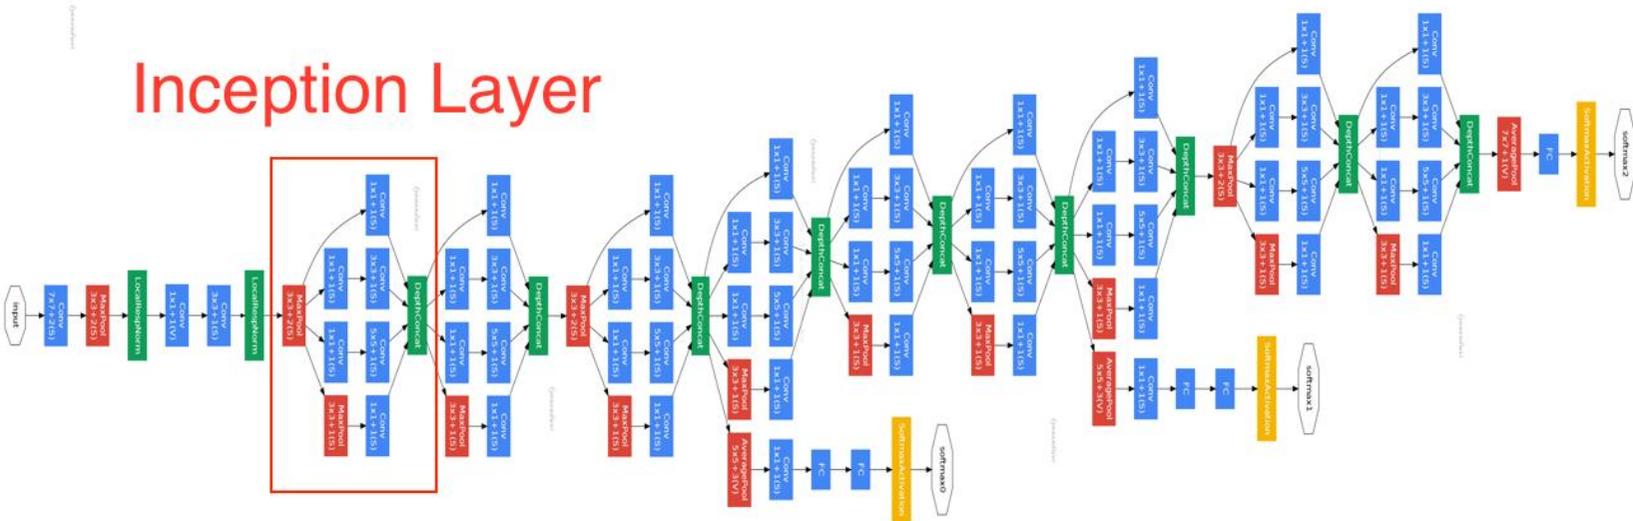
- assembly文件
纯汇编文件，后缀为“.S”或“.s”。注意对寄存器数据的保存。
- inline assembly内联汇编
在C/C++代码中嵌入汇编，调用简单，容易调试。

Tricks - 速度 : Loop Unrolling



Tricks - 速度：利用拓扑结构执行多线程

Inception Layer



利用SplitLayer和ConcatLayer，自动进行多线程分配

Tricks - 速度：改用MobileNet模型

Depthwise Separable Convolution由两部分组成：

- depthwise convolutions
- pointwise convolutions (simple 1×1 convolution)

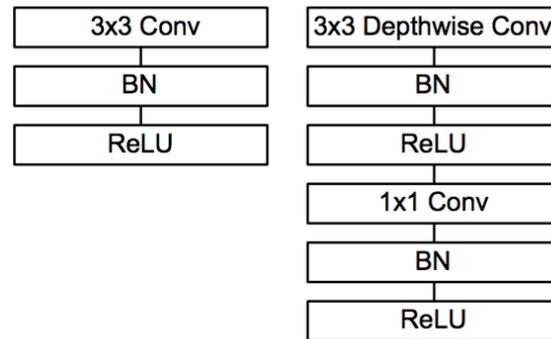
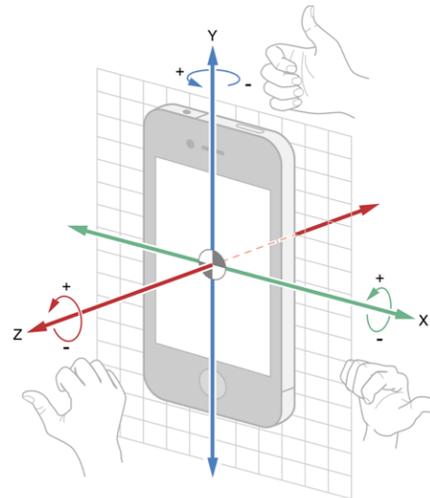
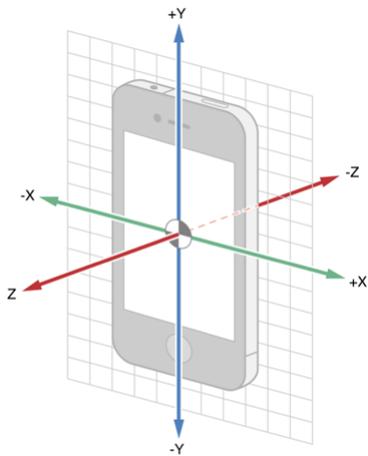


Figure 3. Left: Standard convolutional layer with batchnorm and ReLU. Right: Depthwise Separable convolutions with Depthwise and Pointwise layers followed by batchnorm and ReLU.

Tricks - 耗电量：精准确定预测时机

- 在移动客户端运行神经网络耗电量巨大，采用以下策略：
 - 用户手机达到稳定后一段时间开始识别
 - 通过选取合适的识别间隔

陀螺仪&加速计



THANKS!
