

推理引擎-模型压缩

知识蒸馏



ZOMI



Talk Overview

1. 推理系统介绍

- 推理系统与推理引擎区别
- 推理工作流程
- 推理系统介绍
- 推理引擎介绍

2. 模型小型化

- 基础参数概念
- CNN小型化结构
- Transform小型化结构

3. 离线优化压缩

- 低比特量化
- 模型剪枝
- 知识蒸馏
- 二值化网络

4. 部署和运行优化

- 图转换优化（算子融合/重排/替换）
- 并发执行与内存分配
- 动态batch与bin Packing

Talk Overview

I. 知识蒸馏

- Background of KD - 知识蒸馏的背景
- Knowledge Format - 蒸馏的知识形式
- Distillation Schemes – 具体方法
- Hinton 经典蒸馏算法解读

推理引擎架构

对模型进行压缩

- 减少模型大小
- 加快训练速度
- 保持相同精度




知识蒸馏背景

- Knowledge Distillation (KD) 最初是 Hinton 在 “Distilling the Knowledge in a Neural Network” 提出，与 Label smoothing 动机类似，但是 KD 生成 soft label 方式通过教师网络得到。
- KD 可以视为将教师网络学到的知识压缩到学生网络中，另外一些工作 “Circumventing outlier of auto augment with knowledge distillation” 则将 KD 视为数据增强方法的一种。


知识蒸馏主要思想

- Student Model 学生模型模仿 Teacher Model 教师模型，二者相互竞争，直到学生模型可以与教师模型持平甚至卓越的表现：



知识蒸馏组成

- 知识蒸馏的算法，主要由：1) 知识 Knowledge、2) 蒸馏算法 Distillate、3) 师生架构三个关键部分组成：




蒸馏知识的方式

Knowledge Distillation: A Survey

Knowledge 知识的方式

1. response-based knowledge
2. feature-based knowledge
3. relation-based knowledge
4. Architecture-base knowledge




Response-Based Knowledge

- 主要指Teacher Model 教师模型输出层的特征。主要思想是让 Student Model 学生模型直接学习教师模式的预测结果 (Knowledge) 。
- 假设张量 z_t 为教师模型输出，张量 z_s 为学生模型输出，Response-based knowledge 蒸馏形式可以被描述为：

$$L_{Res D}(z_t, z_s) = \mathcal{L}_R(z_t, z_s)$$

Response-Based Knowledge

- Response-based knowledge 主要指 Teacher Model 教师模型最后一层 —— 输出层的特征。其重要思想是让学生模型直接模仿教师模式的最终预测：




Feature-Based Knowledge

- 深度神经网络善于学习到不同层级的表征，因此中间层和输出层的都可以被用作知识来训练学生模型，中间层学习知识的 Feature-Based Knowledge 对于 Response-Based Knowledge 是一个很好的补充，其主要思想是将教师和学生的特征激活进行关联起来。Feature-Based Knowledge 知识转移的蒸馏损失可表示为：

$$L_{Fea D}(f_t(x), f_s(x)) = \mathcal{L}_F(\phi_t(f_t(x)), \phi_t(f_s(x)))$$

Feature-Based Knowledge

- 虽然基于特征的知识迁移为学生模型的学习提供了良好的信息，但如何有效地从教师模型中选择提示层，从学生模型中选择引导层，仍有待进一步研究。由于提示层和引导层的大小存在显著差异，如何正确匹配教师和学生的特征表示也需要探讨。




Relation-Based Knowledge

- 基于 Feature-Based Knowledge 和 Response-Based Knowledge 知识都使用了教师模型中特定层中特征的输出。基于关系的知识进一步探索了不同层或数据样本之间的关系。一般情况下，基于特征图关系的关系知识的蒸馏损失可以表示为：

$$L_{Rel D}(f_t(x), f_s(x)) = \mathcal{L}_R(\psi_t(\hat{f}_t, \check{f}_t), \psi_t(\hat{f}_s, \check{f}_s))$$

Relation-Based Knowledge

- 传统的知识转移方法往往涉及到个体知识的提炼。教师的个人软标签 Soft Label 被直接提炼到学生中，实际上经过提炼的知识不仅包含了特征信息，还包含了数据样本之间的相互关系。




知识蒸馏 方法

Knowledge Distillation: A Survey


蒸馏方法

- 知识蒸馏可以划分为 1) offline distillation, 2) online distillation , 3) self-distillation



Offline Distillation


- 大多数蒸馏采用 Offline Distillation，蒸馏过程被分为两个阶段：1) 蒸馏前教师模型预训练；2) 蒸馏算法迁移知识。因此 Offline Distillation 主要侧重于知识迁移部分。
- 通常采用单向知识转移和两阶段训练过程。在步骤1) 中需要教师模型参数量比较大，训练时间比较长，这种方式对学生模型的蒸馏比较高效。



- **Cons**：这种训练模式下的学生模型往往过度依赖于教师模型

Online Distillation

- Online Distillation 主要针对参数量大、精度性能好的教师模式不可获得的情况。教师模型和学生模型同时更新，整个知识蒸馏算法是一种有效的端到端可训练方案。



- **Cons** : 现有的 Online Distillation 往往难以获得在线环境下参数量大、精度性能好的教师模型。

Self-Distillation

- 教师模型和学生模型使用相同的网络结构，同样采样端到端可训练方案，属于 Online Distillation 的一种特例。



蒸馏方法

1) offline distillation, 2) online distillation , 3) self-distillation 三种蒸馏方法可以看做是学习过程 :


1. Offline Distillation 指知识渊博教师向传授学生知识 ;
2. Online Distillation 是指教师和学生共同学习 ;
3. Self-Distillation 是指学生自己学习知识。

Hinton经典蒸馏 算法解读

Distilling the Knowledge in a Neural Network

Hard-target 和 Soft-target

- 传统的神经网络训练方法是定义一个损失函数，目标是使预测值尽可能接近于真实值（Hard-target），损失函数就是使神经网络的损失值和尽可能小。这种训练过程是对ground truth求极大似然。在知识蒸馏中，是使用大模型的类别概率作为 Soft-target 的训练过程。



Softmax with Temperature

- softmax函数：

$$q_i = \frac{\exp(z_i)}{\sum_j \exp(z_j)}$$


- 使用软标签就是修改了softmax函数，增加温度系数T：

$$q_i = \frac{\exp(z_i/T)}{\sum_j \exp(z_j/T)}$$

- 其中 q_i 是每个类别输出的概率， z_i 是每个类别输出的 logits，T 是温度。温度 T=1 时，为标准 Softmax。T 越高，softmax 的 output probability distribution 越趋平滑，其分布的熵越大，负标签携带的信息会被相对地放大，模型训练将更加关注负标签。

Softmax with Temperature

- 其中 q_i 是每个类别输出的概率， z_i 是每个类别输出的 logits， T 是温度。温度 $T=1$ 时，为标准 Softmax。 T 越高，softmax 的 output probability distribution 越趋平滑，其分布的熵越大，负标签携带的信息会被相对地放大，模型训练将更加关注负标签。



随着 T 的增加，Softmax 的输出分布越来越平缓，信息熵会越来越大

如何选择 T ?

负标签中包含一定的信息，尤其是那些负标签概率值显著高于平均值的负标签。但由于Teacher模型的训练过程决定了负标签部分概率值都比较小，并且负标签的值越低，其信息就越不可靠。因此温度的选取需要进行实际实验的比较，本质上就是在下面两种情况之中取舍：

- 当想从负标签中学到一些信息量的时候，温度T应调高一些；
- 当想减少负标签的干扰的时候，温度T应调低一些；

与传统训练流程的区别

其中KD的训练过程和传统的训练过程的对比：

- 传统training过程 Hard Targets: 对 ground truth 求极大似然 Softmax 值。
- KD的training过程 Soft Targets: 用 Teacher 模型的 class probabilities作为soft targets。


Distilling the Knowledge in a Neural Network

知识蒸馏使用offline distillation 的方式，采用经典的Teacher-Student 结构，其中 Teacher 是“知识”的输出者，Student 是“知识”的接受者。知识蒸馏的过程分为2个阶段：

1. **教师模型训练**：训练 Teacher 模型, 简称为 Net-T，特点是模型相对复杂，精度较高。对 Teacher模型不作任何关于模型架构、参数量等方面限制。唯一的要求就是，对于输入 X，其都能输出 Y，其中 Y 经过 softmax 映射，输出值对应相应类别的概率值。
2. **学生模型蒸馏**：训练Student模型, 简称为 Net-S，它是参数量较小、模型结构相对简单的模型。同样对于输入 X，其都能输出 Y，Y经过 softmax 映射后能输出与 Net-T 对应类别概率值。


Distilling the Knowledge in a Neural Network

- 论文中，Hinton 将问题限定在分类问题下，或者属于分类的问题，共同点是模型最后有 soft max 层，其输出值对应类别的概率值。知识蒸馏时，由于已经有一个泛化能力较强的 Net-T，在利用 Net-T 来蒸馏 Net-S 时，可以直接让 Net-S 去学习 Net-T 的泛化能力。



Distilling the Knowledge in a Neural Network

1. 训练 Teacher Model ;
2. 利用高温 T_{high} 产生 soft target ;
3. 使用 $\{\text{soft target}, T_{high}\}$ 与 $\{\text{hard target}, T_{high}\}$ 同时训练 Student Model ;
4. 设置温度 $T = 1$, Student Model用于线上推理 ;



Distilling the Knowledge in a Neural Network

- 训练 Net-T 的过程中，高温蒸馏过程的目标函数由distill loss（对应soft target）和student loss（对应hard target）加权得到：


$$L = \alpha L_{soft} + \beta L_{hard}$$

$$L_{soft} = - \sum_j^N p_j^T \log(q_j^T)$$

$$L_{hard} = - \sum_j^N c_j \log(q_j)$$

参考文献

1. Knowledge Distillation: A Survey
2. Distilling the Knowledge in a Neural Network
3. Circumventing outlier of autoaugment with knowledge distillation
4. 模型压缩 (上) —— 知识蒸馏(Distilling Knowledge) <https://www.jianshu.com/p/a6d87b338bcf>
5. DeiT : 注意力也能蒸馏 <https://www.cnblogs.com/ZOMI/p/16496326.html>



BUILDING A BETTER CONNECTED WORLD

THANK YOU

Copyright©2014 Huawei Technologies Co., Ltd. All Rights Reserved.

The information in this document may contain predictive statements including, without limitation, statements regarding the future financial and operating results, future product portfolio, new technology, etc. There are a number of factors that could cause actual results and developments to differ materially from those expressed or implied in the predictive statements. Therefore, such information is provided for reference purpose only and constitutes neither an offer nor an acceptance. Huawei may change the information at any time without notice.