第四代英特尔® 至强® 可扩展处理器人工智能调优指南

概述

本指南面向已熟练掌握英特尔® AI 分析工具套件 (Intel® AI Analytics Toolkit) 和英特尔® 分发版 OpenVINO™ 工具包的用户，针对面向英特尔® 架构优化的 AI 工具包，提供基于第四代英特尔® 至强® 可扩展处理器平台的调优建议。所述硬件和软件配置在大多数情况下均可提供出色性能。但由于所涉及工具能够以多种方式进行部署，请用户就其特定场景对相关设置进行仔细斟酌。

第四代英特尔® 至强® 可扩展处理器平台是一个独特的可扩展平台，采用多项针对科学计算、AI、大数据、网络等工作负载的优化加速技术，具有更高性能和更优 TCO:

- 配置更多内核，每路可达 56 个内核，因此，一个 8 路平台可拥有多达 448 个内核
- 内置全新 AI 加速引擎——英特尔® 高级矩阵扩展（Intel® Advanced Matrix Extensions，英特尔® AMX），支持 BF16 和 INT8 两种数据类型，可加速包括自然语言处理 (NLP)、推荐系统、图像识别等在内的多种 AI 推理和训练工作负载
- 配备 DDR5（上一代配置 DDR4）和高带宽内存 (HBM)，为内存敏感型工作负载提供更大内存带宽和更高处理速度
- 配备全新内置存内数据库加速器 (In-Memory Database Accelerator, IAX)，提升数据分析速率
- 配备 PCIe 5.0，能够以高达 2 倍 I/O 带宽为时延敏感型工作负载提供更高吞吐量
- 内置英特尔® 动态负载均衡器（Intel® Dynamic Load Balancer，英特尔® DLB），高效处理网络数据，提升整体系统性能
- 内置英特尔® 数据保护与压缩加速技术（Intel® QuickAssist Technology，英特尔® QAT），使密码操作和数据压缩工作负载实现高达 4 倍加速

AI 应用开发阶段

典型的深度学习应用开发和部署包括以下几个阶段:

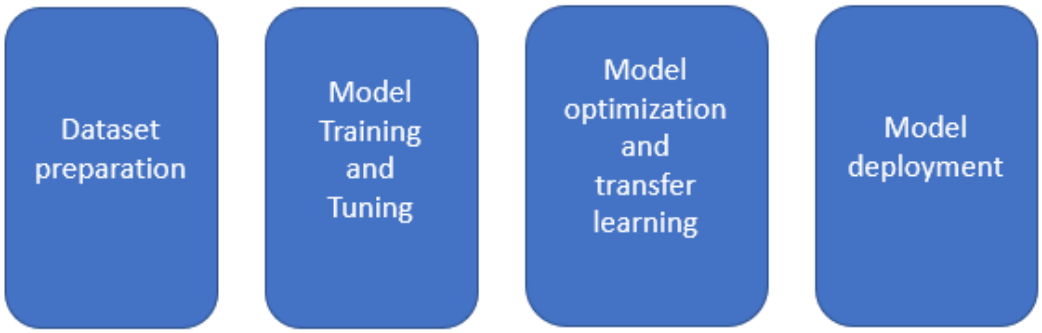

各阶段需要配置以下资源:

- 算力
- 内存
- 数据集存储设备

- 计算节点之间的通信链路
- 经优化的软件

选择合适的资源配置组合可以大幅提升 AI 业务效率。基于第四代英特尔® 至强® 可扩展处理器平台的基础设施可支持机器学习/深度学习训练和推理，因此从数据集准备、模型训练、模型优化到模型部署等各个阶段都可以在该基础设施上完成。推荐的基础设施示意图如下:

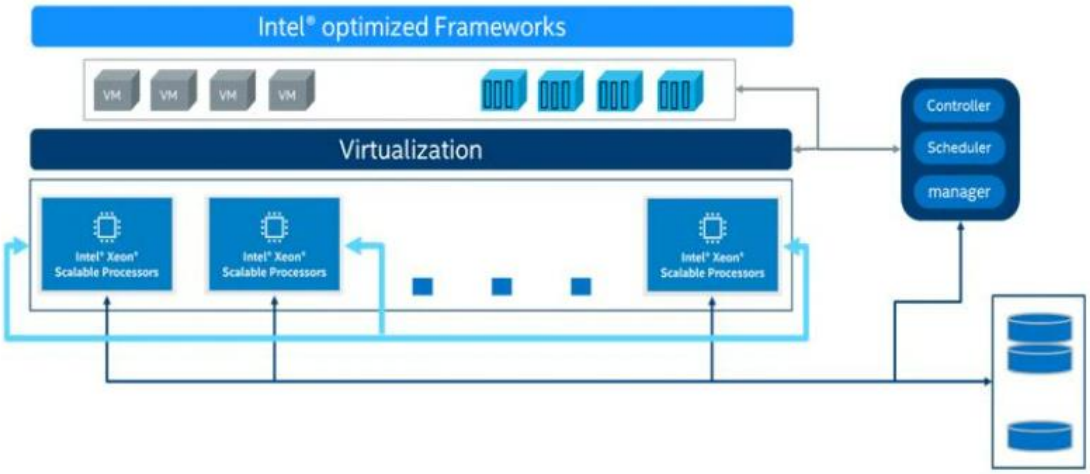

英特尔® AMX 介绍

英特尔® 高级矢量扩展 512 (Intel® Advanced Vector Extensions 512，英特尔® AVX-512) 是 x86 处理器上的一套单指令多数据 (SIMD) 指令集，用于实现通过一条指令执行多个数据操作。英特尔® AVX-512 顾名思义，使用位宽是 512 位的寄存器，可以支持 16 个 32 位单精度浮点数或 64 个 8 位整数。

英特尔® 至强® 可扩展处理器支持多种工作负载，包括复杂的 AI 工作负载。该处理器还借助英特尔® 深度学习加速技术（Intel® Deep Learning Boost，英特尔® DL Boost）进一步提升 AI 计算性能。英特尔® DL Boost 包含英特尔® AVX-512 VNNI（矢量神经网络指令）、英特尔® AVX512 BF16 和英特尔® AMX。

英特尔® AVX-512 VNNI 可以将三条指令（vpmaddubsw、vpmaddwd 和 vpaddd）合并成一条指令 (vpdpbusd) 执行，这进一步增强了新一代英特尔® 至强® 可扩展处理器的计算潜能，提升了 INT8 模型的推理性能。目前第二代、第三代和第四代英特尔® 至强® 可扩展处理器全部支持英特尔® VNNI。

英特尔® AVX-512 BF16 包含的 VDPBF16PS 指令可以进行 BF16 对点积运算并将结果累加成单精度 (FP32)，VCVTNE2PS2BF16 和 VCVTNEPS2BF16 指令可以将打包的单精度数据 (FP32) 转化为打包的 BF16 数据。

英特尔® AMX 是全新 64 位编程范式，由两部分构成：代表大型 2D 内存映像子阵列的一组 2D 寄存器 (TILE) 和在 TILE 执行操作的加速器，前者也称 TMUL（平铺矩阵乘法）单元。

英特尔® DL Boost

处理器	AVX-512 VNNI	AVX-512 BF16	AMX
Cascade Lake	V		
Cooper Lake	V	V	
Ice Lake	V		
Sapphire Rapids	V	V	V

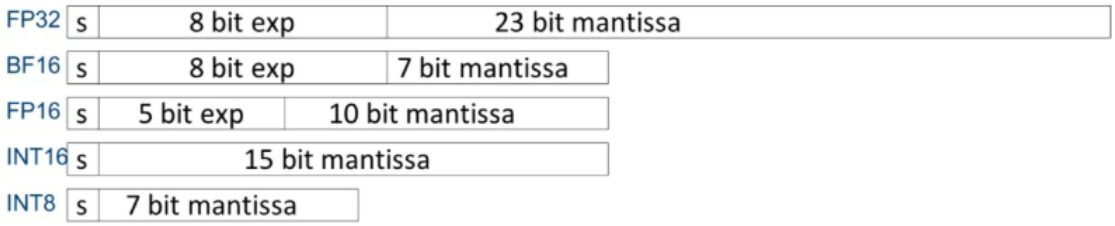

深度学习 VNNI

未使用 VNNI 的平台需要运行三条指令（vpmaddubsw、vpmaddwd 和 vpaddd）才能完成 INT8 卷积运算中的乘累加：

上文所述 INT8 卷积运算示意图

采用 VNNI 的平台仅需 vpdpbusd 一条指令即可完成 INT8 卷积运算：

上文所述 INT8 卷积运算示意图

英特尔® AMX

英特尔® AMX 引入一个包含 8 个名为“TILE”的二阶张量寄存器的全新矩阵寄存器文件，以及可在“TILE”上执行运算的加速器。矩阵寄存器文件包含 8 个“TILE”（按“TMM0”至“TMM7”命名），每个“TILE”最大为 16 行乘 64 字节列，总大小为 1 KiB/寄存器，整个寄存器文件总大小为 8 KiB。加载代表内存中较大映像一小部分的“TILE”，并在该“TILE”上执行运算，然后对代表该映像下一部分的下一个“TILE”重复相同操作。完成后，将生成的“TILE”存储至内存。平铺矩阵乘法（TMUL）单元为一组可在“TILE”上执行运算的融合乘加单元。

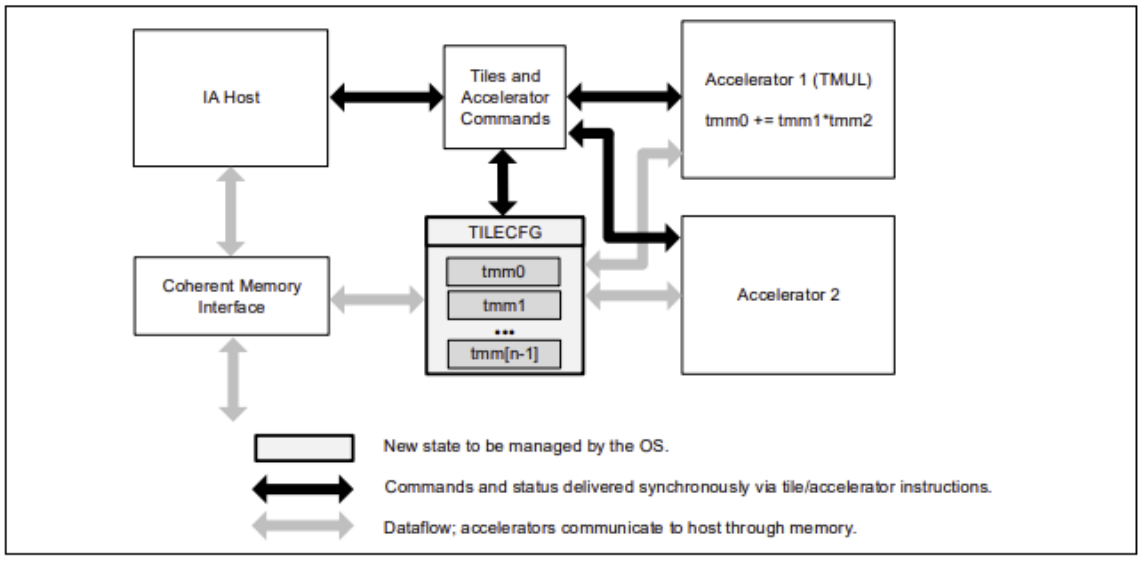

英特尔® AMX 子扩展及相关指令

英特尔® AMX 包含 3 个子扩展：AMX-TILE、AMX-INT8 和 AMX-BF16。

指令	AMX-TILE	AMX-INT8	AMX-BF16
LDTILECFG	V		

指令	AMX-TILE	AMX-INT8	AMX-BF16
STTILECFG	V		
TILELOADD	V		
TILELOADDT1	V		
TILESTORED	V		
TILERELEASE	V		
TILEZERO	V		
TDPBSSD		V	
TDPBSUD		V	
TDPBUSD		V	
TDPBUUD		V	
TDPBF16PS			V

环境

本配置的基础硬件为第四代英特尔® 至强® 可扩展处理器，服务器平台、内存、硬盘和网卡可按使用要求选用。针对本调优指南测试的硬件和软件包括：

硬件

硬件	型号
服务器平台（名称/品牌/型号）	英特尔® Eagle Stream 服务器平台
CPU	英特尔® 至强® 铂金 8480 CPU @ 2.00GHz
内存	8 x 32 GB DDR5，4800 MT/s

软件

软件	版本
操作系统	Ubuntu 22.04.1 LTS
内核	5.17.6
频率驱动程序	intel_pstate
频率调节器	性能

BIOS 设置

设置项目	建议
插槽配置 → 处理器配置	
（新 BIOS））启用 LP	单线程
（旧 BIOS））超线程 [全部]	禁用
插槽配置 → 高级电源管理配置	
CPU（P 状态）控制	将以下各项设置为“禁用”：

设置项目	建议
	SpeedStep（P 状态）、 高能效睿频、 CPU Flex Ratio Override、 Perf P-Limit
CPU C 状态（C-State）控制	将以下各项设置为“禁用”： CPU C1 自动降级、 禁止 CPU C1 自动降级、 CPU C6 报告、增强型空闲电源管理状态转换（C1E）
封装 C 状态（C-State）控制 → 封装 C 状态（C-State）	C0/C1 状态
插槽配置 → 高级电源管理配置 → 高级电源管理调优 → 能耗/性能偏差	
功耗性能调优	OS 控制 EPB

内存

使用所有可用的内存通道

CPU

第四代英特尔® 至强® 可扩展处理器采用全新英特尔® AMX 指令集。英特尔® AMX 可加速混合精度深度学习训练和推理工作负载。第四代英特尔® 至强® 可扩展处理器提供 AMX_BF16 和 AMX_INT8 两套指令集，可分别加速 bfloat16 和 int8 操作。

注：为确认 CPU 是否支持 AMX_BF16 和 AMX_INT8 指令集，请在 bash 终端输入以下命令，并在“flags”部分查找 AMX。如 AMX 指令集并不在列，请考虑将 Linux 内核升级至 5.17 或更高版本

```
$ cat /proc/cpuinfo
```

网络

如果需要搭建跨节点的训练集群，选择 25G/100G 网络等高速网络能够实现更好的可扩展性。

硬盘

为提高 I/O 效率，建议使用读写速度更快的固态盘及驱动器。

Linux 操作系统优化

调整面向并行编程的 Linux 操作系统，进一步提升处理速度。

OpenMP 参数设置

OpenMP 是一种并行编程规范。如您的应用实施基于 OpenMP 的线程，请使用下列环境变量进行测试并确定理想参数：

- OMP_NUM_THREADS =“容器中的 CPU 内核数”
- KMP_BLOCKTIME = 1 或者 0（根据模型的实际类型进行设置）
- KMP_AFFINITY=granularity=fine, verbose, compact,1,0

CPU 内核数

所用的 CPU 内核数对推理性能的影响如下：

- 批大小较小时（例如在线类服务），推理吞吐量的增幅会随着 CPU 内核数的增加而逐渐降低，实践中根据使用模型的不同，推荐 8-16 核 CPU 进行服务部署。
- 批大小较大时（例如离线类服务），推理吞吐量会随着 CPU 内核数的增加呈线性增长，实践中推荐使用 20 核以上的 CPU 进行服务部署。

```
# taskset -C xxx-xxx –p pid (limits the number of CPU cores used in service)
```

NUMA 配置

对于基于 NUMA 架构的服务器而言，在同一节点上配置 NUMA 较在不同节点上配置 NUMA 会有 5% - 10% 的性能提升。

```
#numactl -N NUMA_NODE -l command args ...(controls NUMA nodes running in service)
```

Linux 性能调节器配置

效率是关键考量因素。将 CPU 频率设置为峰值以确保最佳性能。

```
# cpupower frequency-set -g performance
```

CPUC 状态（C-States）设置

每个 CPU 都有几种功耗模式，统称为 C 状态或者 C 模式。为在 CPU 空闲时降低功耗，可命令其进入低功耗模式。禁用 C 状态可以提升性能。

```
#cpupower idle-set -d 2,3
```

利用面向英特尔® 架构优化的 TensorFlow*

自 TensorFlow 2.9 版开始，默认启用英特尔® oneAPI 深度神经网络库（Intel® oneAPI Deep Neural Network Library，英特尔® oneDNN）以提升性能。而面向英特尔® 架构优化的 TensorFlow* 添加了多项优化，可有效提升 TensorFlow 在英特尔® 硬件上运行的性能。这样可为运行在英特尔® 硬件上的 TensorFlow 提供诸如英特尔® AVX-512 VNNI 和英特尔® AMX 等新功能特性和优化技术。

面向英特尔® 架构优化的 TensorFlow* 已作为开源项目发布于 https://github.com/Intel-tensorflow/tensorflow

安装面向英特尔® 架构优化的 TensorFlow*

> **注：** 针对第四代英特尔® 至强® 可扩展处理器的优化从面向英特尔® 架构优化的 TensorFlow* 2.11 开始，并且需使用开发工具包。

```
conda create -n intel-tf python=3.8 -y

conda activate intel-tf

pip install intel-tensorflow==2.11.dev202242
```


```
conda create -n intel-tf python=3.8 -y
conda activate intel-tf
pip install intel-tensorflow==2.11.dev202242
```


基于 TensorFlow 的深度学习模型优化建议

为在英特尔® 平台上显著提升深度学习性能，面向英特尔® 架构优化的 Tensorflow* 利用了以下各项技术：

- NUMA 控制：numactl 规定了 NUMA 调度和内存布局策略
- 多线程：利用 OpenMP 在 CPU 内核间并行处理深度学习模型
- 线程亲和性：在多处理器计算机中使用 KMP_AFFINITY 将特定线程的执行限制在物理处理单元子集中

详情请见 Maximize TensorFlow* Performance on CPU（优化 CPU 上的 TensorFlow* 性能）。

启用 BF16

第四代英特尔® 至强® 可扩展处理器基于英特尔® DL Boost 和英特尔® AMX，利用低精度数据类型 BF16 和 INT8，实现 AI 推理加速。AMX_BF16、AMX_INT8、AVX512_BF16 和 AVX512_VNNI 等多种指令都可用于加速 AI 模型。

针对推理

预训练 FP32 模型（以下以来自 TensorFlow Hub 的 resnet50 为例）：

1. 除面向英特尔® 架构优化的 TensorFlow* 外，本示例还需安装 tensorflow_hub

```
pip install tensorflow_hub
```

2. 使用 export ONEDNN_VERBOSE=1 运行推理，可看到 AVX512_BF16 和 AMX_BF16 指令均已启用。
    - 将下列代码保存为 inference.py

```
import os
import tensorflow as tf
import tensorflow_hub as tf_hub

# Enable Auto Mixed Precision
tf.config.optimizer.set_experimental_options({"auto_mixed_precision_onednn_bfloat16": True})

os.environ["TFHUB_CACHE_DIR"] = 'tfhub_models'
model = tf_hub.KerasLayer('https://tfhub.dev/google/imagenet/resnet_v1_50/classification/5')
model(tf.random.uniform((1, 224, 224, 3)))
```

    - 在终端运行推理脚本

```
export ONEDNN_VERBOSE=1
python inference.py
```

    - 查看结果

```
dst_bf16::blocked:Adcb16a:f0,,,64x3x7x7,69.343

onednn_verbose,exec,cpu,convolution,jit:avx512_core_amx_bf16,forward_training,src_bf16::blocked:acdb:f0 wei_bf16::blocked:Adcb16a:f0 bia_undef::undef::f0 dst_bf16::blocked:acdb:f0,attr-scratchpad:user attr-post-ops:binary_sub:f32:2+binary_mul:f32:2+binary_mul:f32:2+binary_add:f32:2+eltwise_relu ,alg:convolution_direct,mb1_ic3oc64_ih224oh112kh7sh2dh0ph3_iw224ow112kw7sw2dw0pw3,3.29614

onednn_verbose,exec,cpu,pooling_v2,jit:avx512_core_bf16,forward_training,src_bf16::blocked:acdb:f0 dst_bf16::blocked:acdb:f0 ws_u8::blocked:acdb:f0,,alg:pooling_max,mb1ic64_ih112oh56kh3sh2dh0ph0_iw112ow56kw3sw2dw0pw0,5.21802
```

针对训练

您还可以用 TensorFlow Keras API 训练基于 BF16 的混合精度模型

- 将下列代码保存为 training.py

```
import tensorflow as tf

from keras.utils import np_utils

from tensorflow.keras import mixed_precision


# Enable Auto Mixed Precision

mixed_precision.set_global_policy('mixed_bfloat16')


# load data

cifar10 = tf.keras.datasets.cifar10

(x_train, y_train), (x_test, y_test) = cifar10.load_data()

num_classes = 10


# pre-process

x_train, x_test = x_train/255.0, x_test/255.0

y_train = np_utils.to_categorical(y_train, num_classes)

y_test = np_utils.to_categorical(y_test, num_classes)
```

```
# build model
feature_extractor_layer = tf.keras.applications.ResNet50(include_top=False, weights='imagenet')
feature_extractor_layer.trainable = False
model = tf.keras.Sequential([
  tf.keras.layers.Input(shape=(32, 32, 3)),
  feature_extractor_layer,
  tf.keras.layers.Flatten(),
  tf.keras.layers.Dense(1024, activation='relu'),
  tf.keras.layers.Dropout(0.2),
  tf.keras.layers.Dense(num_classes, activation='softmax')
])
model.compile(
 optimizer=tf.keras.optimizers.Adam(),
 loss=tf.keras.losses.CategoricalCrossentropy(),
 metrics=['acc'])

# train model
model.fit(x_train, y_train,
  batch_size = 128,
  validation_data=(x_test, y_test),
  epochs=1)

model.save('resnet_bf16_model')
```

- 在终端运行训练脚本

```
export ONEDNN_VERBOSE=1
python training.py
```

- 查看结果

dst_bf16::blocked:Adcb16a:f0,,,64x3x7x7,160.375

onednn_verbose,exec,cpu,convolution,jit:avx512_core_amx_bf16,forward_training,src_bf16::blocked:acdb:f0 wei_bf16::blocked:Adcb16a:f0 bia_bf16::blocked:a:f0 dst_bf16::blocked:acdb:f0,attr-scratchpad:user ,alg:convolution_direct,mb128_ic3oc64_ih32oh16kh7sh2dh0ph3_iw32ow16kw7sw2dw0pw3,2.0481

onednn_verbose,exec,cpu,batch_normalization,bnorm_jit:avx512_core_bf16,forward_inference,data_bf16::blocked:acdb:f0
diff_undef::undef::f0,,flags:GSR,mb128ic64ih16iw16,0.783203

onednn_verbose,exec,cpu,pooling_v2,jit:avx512_core_bf16,forward_training,src_bf16::blocked:acdb:f0 dst_bf16::blocked:acdb:f0 ws_u8::blocked:acdb:f0,,alg:pooling_max,mb128ic64_ih18oh8kh3sh2dh0ph0_iw18ow8kw3sw2dw0pw0,0.908936

启用 INT8

面向英特尔® 架构优化的 TensorFlow* 协同英特尔® Neural Compressor 能以相同的用户体验提供可兼容的 TensorFlow INT8 量化解决方案支持。

使用英特尔® Extension for PyTorch* 实现优化与性能提升

英特尔® Extension for PyTorch* 添加了多项优化，可有效提升 PyTorch 在英特尔® 硬件上运行的性能。其中大多数优化将包含在未来发布的 stock PyTorch 版本中。该扩展可为运行在英特尔® 硬件上的 PyTorch 带来，诸如英特尔® AVX-512 VNNI 和英特尔® AMX 等新功能特性和优化技术。

英特尔® Extension for PyTorch* 已作为开源项目发布于 https://github.com/intel/intel-extension-for-pytorch

使用深度学习框架 PyTorch*

请确认已安装 PyTorch，以确保扩展可正常运行。有关安装的更多信息请参考以下网址：https://intel.github.io/intel-extension-for-pytorch/latest/tutorials/installation.html#

部署 PyTorch

参考网址：https://intel.github.io/intel-extension-for-pytorch/latest/index.html

环境：Python 3.7 及以上

第 1 步：访问 PyTorch 官网：https://pytorch.org/

第 2 步：选择 CPU

目前，英特尔® oneDNN 已经集成至 PyTorch 的正式版本中，因此无需额外的安装步骤就可以在英特尔® 至强® 可扩展处理器平台上实现性能提升。为计算平台选择 CPU。具体见下图。

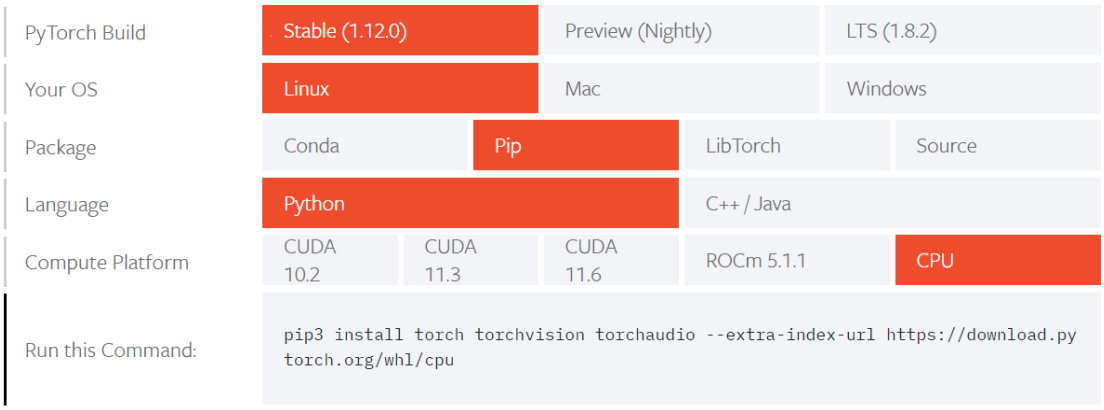

第 3 步：安装

```
pip3 install torch torchvision torchaudio --extra-index-url https://download.pytorch.org/whl/cpu
```

安装英特尔® Extension for PyTorch*

您可使用以下任意命令安装英特尔® Extension for PyTorch*：

```
python -m pip install intel_extension_for_pytorch

python -m pip install intel_extension_for_pytorch-fhttps://software.intel.com/ipex-whl-stable
```

开始

在使用英特尔® Extension for PyTorch* 开始前，用户须进行代码微调。可支持 PyTorch imperative 和 TorchScript 两种模式。

进行推理时，在模型对象中应用 ipex.optimize 函数。

进行训练时，在模型对象和优化器对象中应用 ipex.optimize 函数。

以下代码片段展示了用 BF16/FP32 数据类型进行训练的训练代码：请于 Example Page（示例页面）查看更多训练和推理示例

```
import torch

import intel_extension_for_pytorch as ipex


model = Model()
```

```
model = model.to(memory_format=torch.channels_last)

criterion = ...

optimizer = ...

model.train()


# For FP32

model, optimizer = ipex.optimize(model, optimizer=optimizer)


# For BF16

model, optimizer = ipex.optimize(model, optimizer=optimizer, dtype=torch.bfloat16)


# Setting memory_format to torch.channels_last could improve performance with 4D input data. This is optional.

data = data.to(memory_format=torch.channels_last)

optimizer.zero_grad()

output = model(data)
```

针对基于 PyTorch 的深度学习模型训练和推理的优化建议

尽管 PyTorch 和英特尔® Extension for PyTorch* 的默认原语均已进行了高度优化，但依然可通过额外配置选项进一步提升性能。多数情况下，可通过能够自动设置配置选项的启动脚本（launch script）来应用，这些配置选项主要针对下列内容：

1. OpenMP 库：[英特尔® OpenMP 库（默认）| GNU OpenMP 库]
2. 内存分配器：[PyTorch 默认内存分配器 | Jemalloc | TCMalloc（默认）]
3. 实例数量：[单个实例（默认）|多个实例]

更多详情，请见 Launch Script Usage Guide（启动脚本使用指南）

除启动脚本外，还有一些其他硬件设置，包括配置英特尔® CPU 的结构和非一致性内存访问（NUMA）。也可借助软件配置，利用 Channels Last 内存格式、OpenMP 和 numactl，在英特尔® Extension for PyTorch* 的支持下充分利用 CPU 的计算资源，进而提升性能。更多详情，请见 Performance Tuning Guide（性能调优指南）

启用 BF16 推理

第四代英特尔® 至强® 可扩展处理器可基于英特尔® DL Boost 和英特尔® AMX，使用低精度数据类型 BF16 和 INT8 加速 AI 推理。AMX_BF16、AMX_INT8、AVX512_BF16 和 AVX512_VNNI 等多种指令都可用于加速 AI 模型。

自动混合精度（AMP）

Torch.cpu.ampkezai 让运行期间的数据类型自动转换更易实现。torch.float16 或 torch.bfloat16 等低精度浮点数类型可为深度学习工作负载带来诸多裨益，这是因为其计算工作负载更轻、内存使用空间更小。自动混合精度（AMP）功能自动调优各算子间的数据类型转换。

AMX_BF16 的启用步骤

请使用 lscpu 命令确认特定 CPU 设备是否支持 AMX_BF16 指令。

Torch.cpu.amp.autocast 允许各脚本域以混合精度运行。在这些域内，所有操作均能够以 autocast class 所选择的数据类型运行，进而在保证准确性的同时提高性能。下方的简单网络展示了采用混合精度可实现加速：

```
class SimpleNet(torch.nn.Module):
  def __init__(self):
    super(SimpleNet, self).__init__()
    self.conv = torch.nn.Conv2d(64, 128, (3, 3), stride=(2, 2), padding=(1, 1), bias=False)

  def forward(self, x):
    return self.conv(x)
```

Torch.cpu.amp.autocast 是一个下文管理器，可让脚本域以混合精度运行。AMX_BF16 是比 AVX512_BF16 更新的版本，具有更多高级内联函数（intrinsics），可提供更加出色的性能来支持 AI 应用。因此，对于 BFloat16 而言，AMX_BF16 拥有最高的执行优先级。经英特尔优化的 AI 框架将优先选择 AMX_BF16。如 AMX_BF16 不可用，则选择 AVX512_BF16。更多详情，请参阅 Auto Mixed Precision [自动混合精度（AMP）]

```
model = SimpleNet().eval()
x = torch.rand(64, 64, 224, 224)
with torch.cpu.amp.autocast():
  y = model(x)
```

确定是否启用 AMX_BF16，请检查

Avx512_core_amx_bf16 JIT 内核使用情况。检查设置

ONEDNN_VERBOSE=1

英特尔® Extension for PyTorch* 的 github 链接如下：Intel® Extension for PyTorch*（英特尔® Extension for PyTorch*）

AI 神经网络模型低精度优化

概述

第四代英特尔® 至强® 可扩展处理器可基于英特尔® DL Boost 和英特尔® AMX，使用低精度数据类型 BF16 和 INT8 加速 AI 推理。

1. 量化

使用 INT8 数据类型优化 AI 模型是一种量化方式，即将连续的无限值映射到更小的一组有限离散值的过程。

2. 混合精度

混合精度使用 BF16 等精度更低的数据类型，使模型在训练和推理阶段以 16 位和 32 位混合浮点数据类型运行，从而以更少的内存占用实现更快的运行速度。

指令

第四代英特尔® 至强® 可扩展处理器支持多种可加速 AI 模型的指令：

内联函数	AVX512_VNNI	AVX512_BF16	AMX_INT8	AMX_BF16
数据类型	INT8	BF16	INT8	BF16
变量类型	矢量	矢量	矩阵	矩阵

AMX_INT8/AMX_BF16 是比 AVX512_VNNI/AVX512_BF16 更新的版本，具有更多高级内联函数 (intrinsics)，可提供更加出色的性能来支持 AI 应用。AMX_INT8 拥有最高执行优先级。经英特尔优化的 AI 框架将优先选择 AMX_INT8。如 AMX_INT8 不可用，则选择 AVX512_VNNI。

步骤

1. 将 FP32 模型转换为 INT8/BF16 模型。

运行量化或混合精度流程，获得 INT8/BF16 模型。

2. 在第四代英特尔® 至强® 可扩展处理器上，借助面向英特尔® 架构优化的 AI 框架执行 INT8/BF16 模型推理。

AI 框架将调用 CPU 中自身所支持的最高级内联函数，以获得更加出色的性能。

例如：如果 AI 框架调用的是 AVX512_VNNI 而非 AMX_INT8，请检查新版本是否支持 AMX_INT8 并安装正确的版本。