

# 英特尔® AMX 助力增强 阿里云地址标准化 AI 推理性能



第四代英特尔®至强®  
可扩展处理器

## 挑战

为了给用户提供高效、精准的地址标准化服务，阿里云机器学习平台团队希望能够在算力平台的构建中，重点化解如下挑战：

- 加速数据清理、模型推理等多个工作负载，加快平台的一站式性能。
- 高效使用现有的硬件资源，并且充分利用阿里巴巴公有云、私有云和混合云中的服务器资源，以降低硬件成本。

## 解决方案概述

深度学习 (DL) 作为一项重要的人工智能 (AI) 技术，被广泛应用于多个领域，例如计算机视觉 (CV)、自然语言处理 (NLP) 和推荐系统。但是，随着数据量的爆炸性增长以及 DL 模型复杂性的不断提高，推理正面临巨大的计算挑战。用户希望优化硬件、软件和算法，以提升性能，充分释放硬件的潜能，并降低总体系统成本。此外，优化 DL 算法还能帮助用户采用更复杂的 DL 模型，从而提高准确率，同时保持相同的时延。

为了提高地址标准化服务的性能，阿里云机器学习平台 (PAI) 团队与英特尔和阿里巴巴达摩院的 NLP 团队开展创新协作。基于第四代英特尔®至强®可扩展处理器的平台使用英特尔®高级矩阵扩展 (英特尔®AMX) 优化端到端推理性能 (比前代高出 2.5 倍)<sup>1</sup>，并且准确率也保持在可接受的范围内。

## 阿里云地址标准化服务

阿里云地址标准化<sup>2</sup>是一种高效的标准地址算法服务 (AaaS)，由阿里巴巴达摩院的 NLP 团队依托阿里云海量的地址语料库而开发。该 AaaS 是一个一站式闭环地址数据处理服务平台。它使用 NLP 算法，针对各行业业务系统所登记的地址数据进行纠错、补全、归一、结构化和标签化，实现地址库的清洗和标准化。它提供 20 多种地址服务<sup>3</sup>，可灵活地部署在公有云、私有云或混合云上。

<sup>1</sup> 测试数据配置：单节点，双路英特尔®至强®铂金 8369B 处理器 (32 内核) 以及双路英特尔®至强®铂金 8475B 处理器 (48 内核)，超线程启用，睿频启用，1 实例/内核，BS=32，seq\_len=24，数据类型：INT8 实例/内核，BS=32，seq\_len=24，数据类型：INT8。

<sup>2</sup> <https://www.aliyun.com/product/addresspurification/addrp>

<sup>3</sup> [https://help.aliyun.com/document\\_detail/169746.html](https://help.aliyun.com/document_detail/169746.html)

## 采用第四代英特尔® 至强® 可扩展处理器优化地址标准化服务

阿里云地址标准化采用了 BERT<sup>4</sup> 作为地址标准化搜索模块的核心模型。BERT 是一个广泛用于多任务向量召回和精排 (Fine Ranking) 的关键模型。为了优化 BERT 性能，阿里云 PAI 团队采用了第四代英特尔® 至强® 可扩展处理器集成的英特尔® AMX 等高级特性进行优化。

第四代英特尔® 至强® 可扩展处理器通过创新架构增加了每个时钟周期的指令，每个插槽多达 56 个核心，支持 8 通道 DDR5 内存，有效提升了内存带宽与速度，并通过每 PCIe 5.0 (80 个通道) 实现了更高的 PCIe 带宽提升。第四代英特尔® 至强® 可扩展处理器提供了现代性能和安全性，可根据用户的业务需求进行扩展。借助内置的加速器，用户可以在 AI、分析、云和微服务、网

络、数据库、存储等类型的工作负载中获得优化的性能。通过与强大的生态系统相结合，第四代英特尔® 至强® 可扩展处理器能够帮助用户构建更加高效、安全的基础设施。

第四代英特尔® 至强® 可扩展处理器在 AI 性能上更进一步。该处理器内置了创新的英特尔® AMX 加速引擎。英特尔® AMX 针对广泛的硬件和软件优化，它进一步增强了前代技术 — 向量神经网络指令 (VNNI) 和 BF16，从一维向量发展为二维矩阵，以便最大限度地利用计算资源，提高高速缓存利用率，以及避免潜在的带宽瓶颈，显著增加了人工智能应用程序的每时钟指令数 (IPC)，可为 AI 工作负载中的训练和推理提供显著的性能提升。

### 数据中心架构的新标准

多 Tile SoC 有助于实现可扩展性	物理上划分 Tile，逻辑上保持统一	通用和专用加速引擎
----------------------	--------------------	-----------

### 专为云、微服务和 AI 工作负载而设计

性能和架构	工作负载专用加速
-------	----------

### 引领高级内存和 IO 转型

DDR 5 和 HBM	PCIe 5.0	增强的虚拟化功能
-------------	----------	----------

## 第四代英特尔® 至强® 可扩展处理器

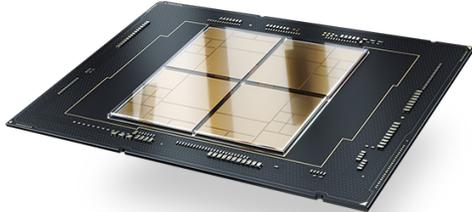


图 1. 第四代英特尔® 至强® 可扩展处理器

<sup>4</sup> BERT: 用于语言理解的预训练的深度双向 Transformer (Devlin J., Chang MW., Lee K 等, ACL 2019)。

## 英特尔® Advanced Matrix Extensions (英特尔® AMX) 概述

### 新的内置 AI 加速引擎 (英特尔® 深度学习加速)

第二代英特尔® 至强® 可扩展处理器	第三代英特尔® 至强® 可扩展处理器	第四代英特尔® 至强® 可扩展处理器
<b>英特尔® 深度学习加速 (简介)</b> 英特尔® AVX-512 (VNNI/INT8)	<b>英特尔深度学习加速技术</b> 英特尔® AVX-512: VNNI/INT8 (CPX/ICX) 与 BFloat16 (CPX)	<b>英特尔深度学习加速技术</b> 英特尔® AMX – INT8 和 BFloat16 支持 英特尔® AVX-512 (VNNI/INT8)
<b>价值主张</b> <ul style="list-style-type: none"> <li>广泛的硬件 (专用芯片/TILE 和矩阵乘法指令集/TMUL) 和软件 (跨市场相关框架、工具集和库) 优化, 增强英特尔® 至强® 可扩展处理器上的内置 AI 加速性能</li> <li>英特尔® Advanced Matrix Extensions (英特尔® AMX) 支持 INT8 (推理) 和 BFloat16 (训练/推理) 数据类型</li> </ul>		
<b>目标工作负载/用途</b> <ul style="list-style-type: none"> <li>图像识别</li> <li>推荐系统</li> <li>机器/语言翻译</li> <li>强化学习</li> <li>自然语言处理/NLP</li> <li>媒体处理与交付</li> <li>媒体分析</li> </ul>		
<b>作用</b> <ul style="list-style-type: none"> <li>与上一代英特尔® 至强® 可扩展处理器相比, 为 AI/深度学习推理和训练工作负载带来显著的性能提升</li> </ul>		

图 2. 英特尔® AMX 简介

阿里云地址标准化服务还利用 Blade 优化地址标准化的推理性能, Blade 是阿里云机器学习 PAI 团队引入的一款通用推理优化工具。Blade 集成了多种优化方法, 包括计算图优化, 优化库, 例如英特尔® oneAPI, 英特尔® 深度神经网络库 (英特尔® oneDNN)、BladeDISC 编译器、Blade 高性能运算符库、自定义后端和 Blade 混合精度。

通过将英特尔® Custom Backend<sup>5</sup> 作为 Blade 的软件后端, 阿里云地址标准化服务可提升量化和稀疏化推理方面的模型性能。它主要包括 3 级优化: 首先使用原始高速缓存策略优化内存; 然后优化图融合; 最后在运算符级别, 构建一个包括自定义和稀疏内核的高效运算符库。



图 3. 英特尔® Custom Backend 结构

<sup>5</sup> [https://github.com/intel/neural-compressor/commits/inc\\_with\\_engine](https://github.com/intel/neural-compressor/commits/inc_with_engine)

英特尔® AMX 极大地改进了 INT8 的功能，英特尔® Custom Backend 也可以利用英特尔® oneDNN 支持 INT8。因此，相比 VNNI，基于英特尔® AMX 的 INT8 量化可显著提升模型性能。

阿里云和英特尔还对地址标准化模型进行了调整，以提升 PAI Blade 的推理性能。测试数据显示，相比采用 INT8 量化的前代平台，阿里云地址标准化服务 BERT 在第四代英特尔® 至强® 可扩展处理器上实现了 2.5 倍的性能提升<sup>6</sup>。

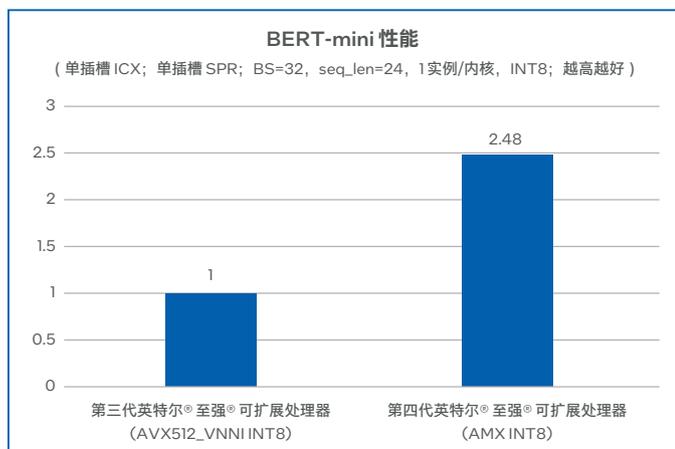


图 4. BERT 模型的推理性能<sup>7</sup>

在精度方面，基于 CCKS2021 中文 NLP 地址相关性任务<sup>8</sup> 的验证显示，基于 FP32 的优化的精度仍保持在 78.72，而基于 INT8 的优化的模型精度为 78.85。



<sup>6,7</sup> 测试数据配置：单节点，双路英特尔® 至强® 铂金 8369B 处理器（32 内核）以及双路英特尔® 至强® 铂金 8475B 处理器（48 内核），超线程启用，睿频启用，1 实例/内核，BS=32，seq\_len=24，数据类型：INT8 1 实例/内核，BS=32，seq\_len=24，数据类型：INT8。

<sup>8</sup> <https://tianchi.aliyun.com/competition/entrance/531901/introduction>

性能因使用情况、配置和其他因素而异。更多信息请访问 [www.Intel.com/PerformanceIndex](http://www.Intel.com/PerformanceIndex)

性能结果基于配置信息中显示的日期进行测试，且可能并未反映所有公开可用的安全更新。详情请参阅配置信息披露。没有任何产品或组件是绝对安全的。

您的成本和结果可能会有所不同。

英特尔技术可能需要启用硬件、软件或服务激活。

英特尔未做出任何明示和默示的保证，包括但不限于，关于适销性、适合特定目的及不侵权的默示保证，以及在履约过程、交易过程或贸易惯例中引起的任何保证。

英特尔并不控制或审计第三方数据。请您审查该内容，咨询其他来源，并确认提及数据是否准确。

© 英特尔公司版权所有。英特尔、英特尔标识以及其他英特尔商标是英特尔公司或其子公司在美国和/或其他国家的商标。其他的名称和品牌可能是其他所有者的资产。

## 收益

- 在保持模型精度的前提下，显著提升了 BERT 模型性能，有助于提供更加高效的地址标准化服务；
- 通过软件优化充分释放了硬件潜力，有效利用服务器资源，从而降低了地址标准化服务的 TCO。

## 展望

在阿里云地址标准化的 AI 推理优化过程中，使用英特尔® 深度学习加速充分释放第四代英特尔® 至强® 可扩展处理器在处理 AI 推理工作负载方面的巨大潜力，从而帮助阿里云显著提升端到端推理性能，并解决实际的业务问题。对于用户而言，该解决方案有助于降低部署专用加速器（例如独立显卡）时的开销，以及更有效地控制地址标准化的总体拥有成本（TCO）。

为了提升更多 DL 模型的端到端性能，英特尔和阿里云正在扩大他们与客户之间的协作，探索以创新方式优化软硬件集成，以加速 DL 模型的性能，最大限度地发挥英特尔技术的价值。英特尔还希望与行业合作伙伴开展更深入的协作，不断为 AI 技术的部署和实施做出自己的贡献。