

团 体 标 准

T/ISC 0056—2024

人工智能 加速卡技术要求及测试方法

Artificial intelligence—Technical requirements and testing methods for
accelerating card

2024 - 09 - 03 发布

2024 - 10 - 03 实施

中 国 互 联 网 协 会 发 布

目 次

前言 II

1 范围 1

2 规范性引用文件 1

3 术语和定义 1

4 缩略语 3

5 概述 3

6 技术要求 4

 6.1 加速卡通用技术要求 4

 6.2 训练卡技术要求 4

 6.3 推理卡技术要求 8

 6.4 加速卡安全性要求 11

7 测试环境 11

 7.1 测试对象 11

 7.2 测试组网 11

 7.3 系统配置 12

 7.4 环境条件 14

8 测试方法 14

 8.1 预置条件 14

 8.2 通用技术要求测试 14

 8.3 训练卡测试 17

 8.4 推理卡测试 22

 8.5 安全性测试 27

附录 A（资料性）系统配置 29

 A.1 操作系统 29

 A.2 深度学习框架 29

 A.3 参考测试用例 29

 A.3.1 训练场景 29

 A.3.2 推理场景 30

前 言

本文件按照GB/T 1.1—2020《标准化工作导则 第1部分：标准化文件的结构和起草规则》的规定起草。

本文件由中国互联网协会归口。

本文件起草单位：中国移动通信集团有限公司、中国互联网协会人工智能工作委员会、中国信息通信研究院、北京智源人工智能研究院、上海燧原科技股份有限公司、中科寒武纪科技股份有限公司、上海天数智芯半导体有限公司、南方电网人工智能科技有限公司、国能数智科技开发（北京）有限公司、中国石油化工集团有限公司、中移（苏州）软件技术有限公司、华为技术有限公司、海光信息技术股份有限公司、摩尔线程智能科技（北京）有限责任公司、新华三技术有限公司、曙光信息产业股份有限公司、北京智谱华章科技有限公司、广州趣丸网络科技有限公司、北京百度网讯科技有限公司、中讯邮电咨询设计院有限公司、浪潮通信技术有限公司。

本文件主要起草人：冯俊兰、邓超、邓凯、曹峰、门春雷、金镒、秦日臻、董昊、马建华、李青懋、靳震、曹汐、梅敬青、王思善、赵淑静、王辉、余雪松、胡铭珊、任正国、张晓东、赵学良、马德营、张久仙、张亚丽、杨鹏霖、肖国峰、万晓兰、贺群、冯涛、张顺四、蒋晓琳、申佳、尹梦君。

人工智能 加速卡技术要求及测试方法

1 范围

本文件规定了人工智能加速卡的技术要求，包括人工智能加速卡的通用技术要求、人工智能训练卡和推理卡的功能要求、性能要求、兼容性要求、可靠性要求、性能度量指标，以及人工智能加速卡的安全性要求，并给出了人工智能训练卡和推理卡的测试环境及测试方法。本文件规定的技术要求主要面向于数据中心或服务器使用的人工智能加速卡。

本文件适用于人工智能加速卡的生产方、评测方、使用方等对加速卡进行设计、测试、评估、选型和应用。

2 规范性引用文件

下列文件中的内容通过文中的规范性引用而构成本文件必不可少的条款。其中，注日期的引用文件，仅该日期对应的版本适用于本文件；不注日期的引用文件，其最新版本（包括所有的修改单）适用于本文件。

GB/T 9813.3-2017 计算机通用规范 第3部分：服务器

GB/T 17235.1-1998 信息技术 连续色调静态图像的数字压缩及编码 第1部分：要求和指南

GB/T 34986-2017 产品加速试验方法

GB/T 37092-2018 信息安全技术 密码模块安全要求

GB/T 41867-2022 信息技术 人工智能 术语

GB/T 42018-2022 信息技术 人工智能 平台计算资源规范

GM/T 0008-2012 安全芯片密码检测准则

GM/T 0028-2014 密码模块安全技术要求

YD/T 3944-2021 人工智能芯片基准测试评估方法

YD/T 4398-2023 电信行业云原生平台架构与技术要求

T/CESA 1303-2023 人工智能 异构人工智能加速器统一接口

ISO/IEC 15948:2004 信息技术 计算机图形和图像处理 便携式网络图形：功能规范 [Information technology – Computer graphics and image processing – Portable Network Graphics (PNG) : Functional specification]

ITU-T H.264—2021 通用视听服务高级视频编码（Advanced video coding for generic audiovisual services）

ITU-T H.265—2021 高效视频编码（High efficiency video coding）

3 术语和定义

GB/T 41867-2022、GB/T 42018-2022和YD/T 3944-2021界定的以及下列术语和定义适用于本文件。为了便于使用，以下重复列出了GB/T 41867-2022、GB/T 42018-2022和YD/T 3944-2021中的某些术语和定义。

3.1

人工智能 artificial intelligence

人工智能系统（3.2）相关机制和应用的研究和开发。

[来源：GB/T 41867-2022, 3.1.2]

3.2

人工智能系统 artificial intelligence system

针对人类定义的给定目标，产生诸如内容、预测、推荐或决策等输出的一类工程系统。

[来源：GB/T 41867-2022, 3.1.8]

3.3

人工智能服务器 artificial intelligence server

信息系统中能够为人工智能应用提供高效能计算处理能力的服务器。

注 1：以通用服务器为基础，配备人工智能加速卡后，为人工智能应用提供专用加速能力的服务器，称人工智能兼容服务器。

注 2：专为人工智能加速计算设计，提供人工智能专用计算能力的服务器，称人工智能一体机服务器。

[来源：GB/T 41867-2022, 3.1.3]

3.4

人工智能集群 artificial intelligence cluster

遵循统一控制的，人工智能计算功能单元的集合。

注 1：人工智能计算功能单元可包含人工智能加速处理器、人工智能服务器、人工智能加速模组等。

注 2：当由人工智能服务器组成时，人工智能集群可称为人工智能服务器集群，其中的人工智能服务器可称为节点。

[来源：GB/T 41867-2022, 3.1.4]

3.5

人工智能加速卡 artificial intelligence accelerating card

专为人工智能计算设计、符合人工智能服务器硬件接口的扩展加速设备，简称“加速卡”。

[来源：GB/T 42018-2022, 3.6]

注：文中的人工智能加速卡主要面向数据中心或服务器场景使用。

3.6

人工智能训练加速卡 artificial intelligence training accelerating card

一种旨在加快人工智能模型训练过程的集成电路板卡，简称“训练卡”。具备高度并行处理能力，可以显著提升人工智能模型的训练速度和效率。

3.7

人工智能推理加速卡 artificial intelligence inference accelerating card

一种旨在加快人工智能模型推理过程的集成电路板卡，简称“推理卡”。主要用于部署已经训练好的模型并在实际应用中推断和预测。推理卡通常具备高效的计算能力和低延迟，可提升人工智能模型在实时应用中的性能和响应速度。

3.8

批次大小 Batch size

单次处理时输入的样本（如图像，时间序列等）数量。

[来源：YD/T 3944-2021, 3.1.9]

3.9

云原生 cloud native

是面向云应用设计的一种思想理念，充分发挥云效能的最佳实践路径，帮助企业构建弹性可靠、松耦合、易管理、可观测的应用系统，提升交付效率，降低运维复杂度。

[来源：YD/T 4398-2023, 3.1]

4 缩略语

ARM: 高级精简指令集处理器 (Advanced Reduced Instruction Set Computer Machines)

BF16: 脑浮点数 (Brain Floating Point)

CPU: 中央处理单元 (Central Processing Unit)

ECC: 错误纠正码 (Error Correcting Code)

FP8: 8位浮点数 (8-bit Floating Point)

FP16: 半精度浮点数 (Half-precision Floating Point)

FP32: 单精度浮点数 (Single-precision Floating Point)

FPS: 帧每秒 (Frames Per Second)

HBM: 高带宽内存 (High Bandwidth Memory)

INT8: 8位四分之一精度整型 (8 bits quarter-precision INTeget)

LPDDR: 低功率双数据率 (Low Power Double Data Rate)

MTBF: 平均无故障工作时间 (Mean Time Between Failure)

OAM: 开放计算项目加速器模块 (Open Compute Project Accelerator Module)

PCIe: 外设部件互联高速通道 (Peripheral Component Interconnect Express)

RDMA: 远程直接内存访问 (Remote Direct Memory Access)

RoCE: 以太网上的远程直接内存访问 (RDMA over Converged Ethernet)

TF32: 张量单精度浮点数 (Tensor Float-32)

TFLOPs: 一万亿次浮点运算 (Tera Floating-point Operations)

TFLOPS: 每秒一万亿次浮点运算 (Tera Floating-point Operations Per Second)

TOPS: 每秒一万亿次运算 (Tera Operations Per Second)

TRNG: 真随机数发生器 (True Random Number Generator)

5 概述

人工智能加速卡是一种硬件设备，具有适配人工智能算法运算微架构、能够完成人工智能应用运算处理的集成电路元件，可作为服务器的一部分，与其他组件（如CPU、存储设备等）协同工作，提供更高效、更快速的计算能力。人工智能加速卡通常由多个处理器和内存组成，这些处理器能够高效地进行矩阵计算，使其相比于CPU具有更加出色的计算能力和效率，可加速人工智能模型的训练和推理速度。

人工智能加速卡被广泛应用于人工智能领域，如计算机视觉、自然语言处理、语音识别等场景。人工智能加速卡根据不同场景下对其功能和性能等的要求不同，通常可分为人工智能训练加速卡（简称训练卡）和人工智能推理加速卡（简称推理卡）。本文件规定的人工智能加速卡主要为面向数据中心及云端的产品。

本文件主要技术内容分为三个部分，包括技术要求、测试环境和测试方法。技术要求部分给出人工智能加速卡的通用技术要求，训练卡和推理卡的功能要求、性能要求、兼容性要求、可靠性要求、训练/推理性能度量指标，以及安全性要求。测试环境部分针对技术要求中的各项内容给出测试所需明确的

测试对象、测试组网、系统配置和环境条件。测试方法部分针对技术要求部分提出的各项要求，分别给出相应的测试方法。

6 技术要求

6.1 加速卡通用技术要求

人工智能加速卡的通用技术要求如下：

- a) 应内置生产厂家、产品型号、序列号、固件版本、显存信息等基础配置信息，且可被配置了加速卡的设备（如服务器）操作系统正常读取；
- b) 应支持资产管理功能，可通过服务器远程管理系统读取加速卡的序列号信息，且该信息应与配置了加速卡的设备操作系统读取的信息保持一致；
- c) 应支持固件版本管理功能，可通过服务器远程管理系统读取加速卡的固件版本信息，且该信息应与配置了加速卡的设备操作系统读取的信息保持一致；
- d) 应支持功耗监控功能，可通过服务器远程管理系统读取加速卡的当前功耗信息，且该信息与配置了加速卡的设备操作系统读取的功耗值差距应在 5%以内；
- e) 应支持温度监控功能，可通过服务器远程管理系统读取加速卡的当前温度信息，且该信息与配置了加速卡的设备操作系统读取的温度值差距应在 5%以内；
- f) 应支持至少一种 Linux 操作系统，操作系统版本可参考附录 A.1；
- g) 应支持至少一种满足信息技术应用创新要求的操作系统；
- h) 应具备与 CPU 的卡间通信功能；
- i) 应支持加速卡性能分析工具；
- j) 宜具备虚拟化功能，支持通过虚拟化软件对整张物理加速卡进行切分；
- k) 应具备电流过载或功率过载的保护机制；
- l) 应具备面向业务负载的动态功耗性能管理机制；
- m) 应具备针对错误或异常的处理及上报机制；
- n) 应具备云原生的接入能力，如支持 K8s 等技术。

6.2 训练卡技术要求

6.2.1 训练卡功能要求

训练卡的功能要求如下：

- a) 应支持 BF16、FP16、FP32 数据精度类型；
- b) 宜支持 INT8、FP8、TF32 数据精度类型中的一种或多种；
- c) 应支持混合精度训练；
- d) 应支持自定义算子开发功能，如矩阵乘法、卷积等；
- e) 宜支持 T/CESA 1303-2023 中给出的算子类型；
- f) 应支持服务器内部训练卡的卡间高速互联通信功能；
- g) 应支持服务器之间训练卡间的高性能通信能力（如支持 RoCE、InfiniBand 等 RDMA 技术）；
- h) 应支持集合通讯库及典型的集合通信算法（如 all reduce、all gather 等），具备卡间集合通信能力；
- i) 应支持数据并行、流水线并行、张量并行等并行策略中的一种或多种；
- j) 宜支持软件加速库，通过软件层面优化加速模型训练；

- k) 宜直接具备或与解码器配合实现图像和视频的解码能力（支持 ITU-T H.264-2021、ITU-T H.265-2021 等规定的视频格式中的一种或多种,支持 GB/T 17235.1-1998、ISO/IEC 15948:2004 等规定的图像格式中的一种或多种）。

6.2.2 训练卡性能要求

训练卡的性能要求如下：

- a) 峰值计算性能宜不低于 200 TOPS (INT8)、96 TFLOPS (BF16)、96 TFLOPS (FP16)、24 TFLOPS (FP32)；
- b) 显存容量宜不小于 32GB；
- c) 面向大模型等训练场景，显存带宽宜不低于 600GB/s；
- d) 面向大模型等训练场景，节点内卡间互联聚合带宽宜不低于 200GB/s（双向）。

6.2.3 训练卡兼容性要求

训练卡的兼容性要求如下：

- a) 应支持至少一种深度学习框架；
- b) 应支持至少一种分布式训练框架；
- c) 应支持 PCIe 接口或 OAM 接口；
- d) PCIe 接口形态卡应支持 PCIe4.0 或以上版本接口协议中的至少一种；
- e) OAM 接口形态卡应支持 OAM1.1 或以上版本接口协议中的至少一种；
- f) 应支持 HBM、GDDR、LPDDR 等高带宽内存中的一种或多种。

6.2.4 训练卡可靠性要求

训练卡的可靠性要求如下：

- a) 应支持模型断点续训功能，能够自动断点保存、故障诊断与上报、自动恢复训练等；
- b) 应通过 3×24 小时压力测试；
- c) 宜支持内存错误修复（如基于 ECC）；
- d) 宜具备在受控环境中的理想条件及非受控环境中的各种环境压力条件下的 MTBF 测试结果。

6.2.5 训练性能度量指标

6.2.5.1 训练时间

训练时间是指在特定数据集上训练一个模型使其达到目标准确率时所用的时间（不包括预处理和模型加载时间），一般采取运行多次去掉最低和最高的数字后取平均值。对于大规模预训练模型，可使用模型在特定数据集上训练一轮或多轮所用的时间来衡量。训练时间的测量方法如表1所示。

表1 训练时间测量方法

度量指标	说明	测量方法
训练时间	从训练开始命令调用到训练退出之间的时间间隔	a) 训练开始前，串行并紧邻调用计时命令，获得时间点 t_1 ； b) 训练退出时，串行并紧邻调用计时命令，获得时间点 t_2 ； c) 计算训练用时： $T = t_2 - t_1$ 。

6.2.5.2 训练吞吐率

训练吞吐率体现了训练卡对选定的模型训练任务的计算能力。对视觉类测试，单位为图片数每秒（images/s）；对自然语言处理类测试，单位为句数每秒（sentences/s）；对自然语言语句生成模型，吞吐率为定长输入（句中单词或字的个数）、输出条件下，每秒处理的语素数量，单位是tokens/s。训练吞吐率的测量方法如表2所示。

表2 训练吞吐率测量方法

度量指标	说明	测量方法
训练吞吐率	训练卡在训练过程中，每个训期处理的数据量与时间的比值。	a) 统计每个训期<i>i</i>所使用的时间T_i，计算每训期平均时间T； b) 训练吞吐率计算公式为： $\text{训练吞吐率} = \frac{\text{number of (训练集)}}{T}$ c) 对文本生成类的训练任务，训练吞吐率为： $\text{训练吞吐率} = \frac{\text{number of tokens (训练集)}}{T}$ 其中： number of (*)表示计量特定数据集合所含的样本数量； $\text{number of tokens (*)}$表示计量特定数据集合所含的语素数量。

6.2.5.3 训练功耗

训练功耗是指训练卡在执行模型训练任务期间，单位时间内所消耗的能源的值，单位为瓦（W）。训练功耗的测量方法如表3所示。

表3 训练功耗测量方法

度量指标	说明	测量方法
训练功耗	在执行训练任务期间，周期性测量被测设备的负载功率，并计算均值。	计算公式为： $P = \frac{1}{N} \sum_{i=1}^N p_i$ 其中： P：有效期内的平均输入功率； P_i：有效期内得到的输入功率值为 $\{p_1, p_2, \dots, p_N\}$； N：次数。

6.2.5.4 训练能效

训练能效是指训练卡在模型训练过程中，针对特定的数据精度，单位时间内消耗单位功耗，所完成的计算量，单位为万亿次浮点运算次数每瓦（TFLOPs/W）。训练能效的测试方法如表4所示。

表4 训练能效测量方法

度量指标	说明	测量方法
训练能效	训练卡单位时间内消耗单位功耗所完成的计算量。	计算公式为： $E = \frac{size\ of\ (训练集)}{T \times P}$ 其中： $size\ of\ (*)$ ：针对训练集，计算并转化为浮点运算次数，单位是TFLOPs； T ：每个训期的平均用时； P ：训练任务中每个训期的平均功率，可参照6.2.5.3的方法计算。

6.2.5.5 全精度训练能效

全精度训练能效是指训练卡在模型训练过程中，针对所支持的全部数据精度的训练能效总和。全精度训练能效的测量方法如表5所示。

表5 全精度训练能效测量方法

度量指标	说明	测量方法
全精度训练能效	训练卡所支持的全部数据精度的训练能效总和，分为张量算效和矢量算效。	计算公式为： $张量算效 = \sum_{i=1}^n \frac{T_i}{W_i}$ $矢量算效 = \sum_{i=1}^n \frac{V_i}{W_i}$ 其中： n ：支持的数据精度种类数量； T_i ：在第 <i>i</i> 种数据精度下进行模型训练的张量峰值算力，单位为GOPS； V_i ：在第 <i>i</i> 种数据精度下进行模型训练的矢量峰值算力，单位为GFLOPS； W_i ：在第 <i>i</i> 种数据精度下进行模型训练时的平均功耗。

6.2.5.6 多卡训练线性度

多卡训练线性度用来衡量加速卡在模型集群规模化训练下的可扩展性，可分为卡线性度和集群线性度。多卡训练线性度的测试方法如表6所示。

表6 多卡训练线性度测量方法

度量指标	说明	测量方法
卡线性度	选取某一模型训练任务，计算使用单台服务器节点的多张卡并行训练时每秒处理的样本数量，与使用单张卡训练时每秒处理的样本数量之间的比值，再用此比值除以卡的数量。	计算公式为： $卡线性度 = \frac{V_1}{N * V_2}$ 其中： V_1 ：采用N张卡并行训练时每秒处理的样本数量； V_2 ：采用单张卡训练时每秒处理的样本数量。

集群线性度	选取某一模型训练任务，计算使用包含多台服务器节点及多张训练卡的集群开展并行训练时每秒处理的样本数量，与使用单张卡训练时每秒处理的样本数量之间的比值，再用此比值除以集群中卡的数量。	计算公式为： $\text{集群线性度} = \frac{V_3}{N * V_4}$ 其中： V_3 ：采用包含N张卡的集群训练时每秒处理的样本数量； V_4 ：采用单张卡训练时每秒处理的样本数量。
-------	---	--

6.2.5.7 检查点保存和加载时间

检查点保存时间是指在模型训练过程中的任一时间点，将模型训练状态保存到存储设备所需要的时间（包括模型参数和优化器等模型状态的存储时间）；检查点加载时间是指将存储设备中的模型状态（包括模型参数和优化器等模型状态）加载到训练卡上并开始模型正常训练所需要的时间，一般采取运行多次去掉最低和最高的数字后取平均值。检查点保存和加载时间的测量方法如表7所示。

表7 检查点保存和加载时间测量方法

度量指标	说明	测量方法
保存时间	将模型状态从训练卡保存到存储设备所需的时间	a) 模型状态保存开始前，串行并紧邻调用计时命令，获得时间点 t_1 ； b) 模型状态保存完成后，串行并紧邻调用计时命令，获得时间点 t_2 ； c) 计算保存用时： $T_1 = t_2 - t_1$ 。
加载时间	从存储设备中将模型状态加载到训练卡中所需的时间	a) 模型状态加载开始前，串行并紧邻调用计时命令，获得时间点 t_3 ； b) 模型状态加载完成后，串行并紧邻调用计时命令，获得时间点 t_4 ； c) 计算加载用时： $T_2 = t_4 - t_3$ 。

6.3 推理卡技术要求

6.3.1 推理卡功能要求

推理卡的功能要求如下：

- a) 应支持 INT8、FP16 数据精度类型；
- b) 宜支持 FP8、BF16、FP32、TF32 数据精度类型中的一种或多种；
- c) 应支持自定义算子开发功能，如矩阵乘法、卷积等；
- d) 宜支持 T/CESA 1303-2023 中给出的算子类型；
- e) 宜支持服务器内部推理卡的卡间高速互联通信功能；
- f) 宜支持服务器之间推理卡间的高性能通信能力（如支持 RoCE、InfiniBand 等 RDMA 技术）；
- g) 应支持集合通讯库及典型的集合通信算法（如 all reduce、all gather 等），具备卡间集合通信能力；
- h) 应支持通过模型推理服务部署工具实现模型的在线服务部署和运行；
- i) 应支持流水线并行、张量并行等并行策略中的一种或多种；
- j) 宜直接具备或与解码器配合实现图像和视频解码能力（支持 ITU-T H.264-2021、ITU-T H.265-2021 等规定的视频格式中的一种或多种，支持 GB/T 17235.1-1998、ISO/IEC 15948:2004 等规定的图像格式中的一种或多种）。

6.3.2 推理卡性能要求

推理卡的性能要求如下：

- a) 峰值计算性能宜不低于 200 TOPS(INT8) 、96 TFLOPS(BF16) 、96 TFLOPS(FP16) 、24 TFLOPS(FP32)；
- b) 显存容量宜不小于 16GB；
- c) 面向大模型等训练场景，显存带宽宜不低于 300GB/s；
- d) 宜支持不低于 96 路 H. 264、H. 265 格式视频解码（1080P@30FPS）；
- e) 宜支持不低于 4000 Frames/s 分辨率为 1080P 的 JPEG 格式图片解码。

6.3.3 推理卡兼容性要求

推理卡的兼容性要求如下：

- a) 宜支持至少一种深度学习框架；
- b) 应支持至少一种深度学习推理引擎；
- c) 应支持 PCIe 接口或 OAM 接口；
- d) PCIe 接口形态卡应支持 PCIe4.0 或以上版本接口协议中的至少一种；
- e) OAM 接口形态卡应支持 OAM1.1 或以上版本接口协议中的至少一种；
- f) 应支持 HBM、GDDR、LPDDR 等高带宽内存中的一种或多种；
- g) 应支持部署运行经过模型格式转化的由不同厂商生产的加速卡所训练生成的模型。

6.3.4 推理卡可靠性要求

- a) 推理过程稳定运行，同一个模型连续多次推理的推理时延波动应相当；
- b) 应通过 3×24 小时压力测试；
- c) 宜支持内存错误修复（如基于 ECC）；
- d) 宜具备在受控环境中的理想条件及非受控环境中的各种环境压力条件下的 MTBF 测试结果。

6.3.5 推理性能度量指标

6.3.5.1 推理时延

推理时延是指推理任务从执行到结束的运行时间，即从内存发送样本数据到模型输出推理结果的时间间隔。对于自然语言语句生成类任务，使用首字时延和模型稳定输出时单token的生成时间来衡量推理时延性能。推理时延的测试方法如表8所示。

表8 推理时延测量方法

度量指标	说明	测量方法
推理时延	非自然语言语句生成类任务，计算被测设备对某样本推理的开始时间与结束时间的时间间隔	a) 推理开始前，串行并紧邻调用计时命令，获得时间点 t_1 ； b) 推理退出时，串行并紧邻调用计时命令，获得时间点 t_2 ； c) 计算推理用时： $T_1 = t_2 - t_1$ 。
	自然语言语句生成类任务的首字时延，为被测设备对某样本推理的开始时间与模型输出首个token的时间间隔	a) 推理开始前，串行并紧邻调用计时命令，获得时间点 t_3 ； b) 输出首个token时，串行并紧邻调用计时命令，获得时间点 t_4 ； c) 计算推理用时： $T_2 = t_4 - t_3$ 。

	自然语言语句生成类任务的单token生成时间，为被测设备稳定生成每个token所用的时间	a) 模型稳定输出时，选定某一token，在token生成后，串行并紧邻调用计时命令，获得时间点 t_5 ； b) 当模型生成下一个新的token后，串行并紧邻调用计时命令，获得时间点 t_6 ； c) 计算推理用时： $T_3 = t_6 - t_5$ 。
--	--	---

6.3.5.2 推理吞吐率

推理吞吐率代表了推理卡对特定推理任务的计算能力。对视觉类测试，单位为图片数每秒（images/s）；对自然语言处理类测试，单位为句数每秒（sentences/s）；对自然语言语句生成的模型，吞吐率为定长输入（句中单词或字的个数）、输出条件下，每秒处理的语素数量，单位是tokens/s。推理吞吐率的测试方法如表9所示。

表9 推理吞吐率测量方法

度量指标	说明	测量方法
推理吞吐率	推理卡在单位时间内，对于特定任务负载，完成处理的样本数量。	a) 计算整个推理测试过程的时间 T ； b) 推理吞吐率计算公式为： $\text{推理吞吐率} = \frac{\text{number of (推理集)}}{T}$ c) 对文本生成类的推理任务，推理吞吐率为： $\text{推理吞吐率} = \frac{\text{number of tokens (推理集)}}{T}$ 其中： number of (*) ：整个推理测试过程中，由所有实际发送的样本以及实际返回结果所计算得出的样本数量； $\text{number of tokens (*)}$ ：统计整个推理测试过程中，由所有实际发送的样本以及实际返回结果所计算得出的样本数量，再针对每个样本累计语素数量。

6.3.5.3 推理功耗

推理功耗是指推理卡在执行模型推理任务期间，单位时间内所消耗的能源的值，单位为瓦（W）。推理功耗的测量方法如表10所示。

表10 推理功耗测量方法

度量指标	说明	测量方法
推理功耗	在执行推理任务期间，周期性测量被测设备的负载功率，并计算均值。	计算公式为： $P = \frac{1}{N} \sum_{i=1}^N p_i$ 其中： P ：有效期内的平均输入功率； P_i ：有效期内得到的输入功率值为 $\{p_1, p_2, \dots, p_N\}$ ； N ：次数。

6.3.5.4 推理能效

推理能效是指推理卡在推理过程中，单位时间内消耗单位功耗，所完成的计算量，单位为万亿次浮点运算次数每瓦（TFLOPs/W）。推理能效的测试方法如表11所示。

表11 推理能效测量方法

度量指标	说明	测量方法
推理能效	推理卡单位时间内消耗单位功耗所完成的计算量。	计算公式为： $E = \frac{size\ of\ (数据量)}{T \times P}$ 其中： <i>size of (*)</i>：在整个推理测试过程中，累计返回结果的任务数据量，计算并转化为浮点运算次数； <i>T</i>：推理测试过程的用时； <i>P</i>：推理测试过程的平均功率，可参照6.3.5.3的方法计算。

6.4 加速卡安全性要求

人工智能加速卡的安全性要求如下：

- a) 宜具备安全启动能力，逐级校验固件的完整性，确保设备自身安全性；
- b) 应具备基于硬件的安全加解密能力，加解密功能应符合 GM/T 0008-2012 的相关规定，芯片密码模块应符合 GB/T 37092-2018 及 GM/T 0028-2014 的相关规定；
- c) 可基于硬件的密码运算功能支持模型和数据加解密的保护能力；
- d) 宜具备 TRNG 真随机数发生器。

7 测试环境

7.1 测试对象

本文件将内置了人工智能加速卡的人工智能服务器作为被测对象，并在人工智能服务器上安装测试所需的操作系统、深度学习框架、加速卡驱动、软件栈、辅助测试工具等，用于测试人工智能加速卡所具备的功能，所能达到的性能，以及兼容性、可靠性、安全性等技术指标，并通过加载多种训练或推理任务负载，测试人工智能训练加速卡的训练性能和推理加速卡的推理性能。

7.2 测试组网

7.2.1 组网策略

测试系统包含被测服务器和测试机，测试机可选用桌面个人电脑，人工智能加速卡安装于被测服务器，通过在测试机上控制被测服务器，完成各项指标的测试。为了全面测试人工智能加速卡的技术指标，构建包含多台服务器节点的人工智能集群，每台服务器内安装1张以上人工智能加速卡。测试组网如图1所示。基于图1所示的组网环境，可分别开展单机单卡环境测试、单机多卡环境测试、集群环境测试。




图1 人工智能服务器测试组网图

注 1：依据被测设备声明支持的节点内卡间互联方式，进行节点内加速卡的通信连接。
注 2：依据被测设备声明支持的节点间的网络通信方式，进行节点间的通信连接（如通过 RoCE、InfiniBand 等方式）。

7.2.2 单机单卡测试系统

通过相关设置，只启动服务器集群中的单台服务器中的单张人工智能加速卡，测试加速卡的相关技术指标。

7.2.3 单机多卡测试组网

通过相关设置，只启动服务器集群中的单台服务器中的多张人工智能加速卡，测试加速卡的相关技术指标。

7.2.4 集群测试组网

通过相关设置，启动服务器集群中的多个节点，以及服务器中的多张人工智能加速卡，测试加速卡的相关技术指标。

7.3 系统配置

7.3.1 软硬件配置

宜选用通用的x86或ARM架构服务器，服务器内安装需要进行测试的人工智能加速卡，并安装人工智能加速卡正常运行所需的驱动、软件栈等工具。

7.3.2 操作系统

被测设备应安装操作系统的开源或商业版本，常用的操作系统可参考附录A的表A. 1所示。

7.3.3 深度学习框架

测试人工智能加速卡的各项技术指标时，需在被测设备中安装深度学习框架，以加载和运行各种人工智能算法模型，常用的深度学习框架可参考附录A的表A. 2所示。

7.3.4 测试场景

本节给出测试人工智能训练加速卡和推理加速卡技术指标时宜加载的测试场景和任务，如表12所示。各类任务下用于测试加速卡技术指标的算法模型、数据集、模型的目标准确率等用例信息可参考附录A的A.3所示。

表12 测试场景

测试对象	模型类别	场景	任务
训练卡	传统模型	视觉类	图像分类
			目标检测
			图像分割
			视频分类
			文本识别
		语音类	语音识别
			声纹识别
			语音合成
		推荐类	智能推荐
	预训练模型	视觉类	
		语言类	
推理卡	传统模型	视觉类	图像分类
			目标检测
			图像分割
			视频分类
			文本识别
		语音类	声纹识别
			语音合成
		推荐类	智能推荐
	预训练模型	视觉类	
		语言类	

7.3.5 辅助工具

测试人工智能加速卡的各项技术指标，需要加速卡监控工具、功耗测试工具、通信带宽测试工具、加压测试工具等设备的配合，所需的辅助工具及用途如表13所示。

表13 辅助工具

序号	名称	用途
1	加速卡监控工具	加速卡各类指标的监控和读取
2	功耗测试工具	功耗测试
3	通信带宽测试工具	带宽测试
4	加压测试工具	稳定性测试

7.4 环境条件

除另外规定外，测试均在GB/T 9813.3-2017中规定的正常大气条件下进行，如表14所示。

表14 环境条件

序号	环境条件	数值范围
1	温度	15℃-35℃
2	相对湿度	25%-75%
3	大气压	86 kPa-106 kPa

8 测试方法

8.1 预置条件

测试人工智能加速卡的技术要求应满足如下预置条件：

- a) 被测设备电源供电正常；
- b) 被测设备安装稳定的商用 BIOS 版本及 BMC 版本；
- c) 被测设备预装业务操作系统并且各驱动程序安装正常；
- d) 被测设备预装容器化服务必要的组件，如容器化引擎、编排管理器、镜像仓库等；
- e) 被测设备安装加速卡驱动软件、计算引擎、开发环境等软件，且运行正常；
- f) 被测设备完成组网，可与测试机正常通信。

8.2 通用技术要求测试

8.2.1 基础配置管理功能测试

加速卡基础配置管理功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 使用命令查询加速卡的生产厂家、产品型号、序列号、固件版本、显存信息等基础配置信息；
- c) 验证相关信息是否可正常读取，并核对与加速卡实际配置及规格信息是否一致。

8.2.2 资产管理功能测试

加速卡资产管理功能的测试方法如下：

- a) 通过测试机登录被测设备的管理地址；
- b) 进入管理界面或带外命令，查看并读取加速卡的序列号信息；
- c) 登录到被测设备业务操作系统中，查看相应加速卡的序列号；
- d) 对比 b) 和 c) 中查询出来的加速卡序列号是否一致。

8.2.3 固件版本管理功能测试

加速卡固件版本管理功能的测试方法如下：

- a) 通过测试机登录被测设备的管理地址；
- b) 进入管理界面或带外命令，查看并读取加速卡的固件版本信息；
- c) 登录到被测设备业务操作系统中，查看相应加速卡的固件版本；
- d) 对比 b) 和 c) 中查询出来的加速卡固件版本信息是否一致。

8.2.4 功耗监控功能测试

加速卡功耗监控功能的测试方法如下：

- a) 通过测试机登录被测设备的管理地址；
- b) 进入管理界面或带外命令，查看并读取加速卡的功耗信息；
- c) 登录到被测设备业务操作系统中，查看相应加速卡的功耗值；
- d) 对比 b) 和 c) 中查询出来的加速卡功耗值差距是否在 5% 以内。

8.2.5 温度监控功能测试

加速卡温度监控功能的测试方法如下：

- a) 通过测试机登录被测设备的管理地址；
- b) 进入管理界面或带外命令，查看并读取加速卡当前温度信息；
- c) 登录到被测设备业务操作系统中，查看相应加速卡的当前温度值；
- d) 对比 b) 和 c) 中查询出来的加速卡温度值差距是否在 5% 以内。

8.2.6 加速卡操作系统适配测试

加速卡操作系统适配的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 执行操作系统检测脚本，检查业务操作系统中的版本和型号信息；
- c) 在此业务操作系统环境中，完成与加速卡所有技术要求对应的全部测试内容；
- d) 验证 b) 中获取的业务操作系统数据是否正确；
- e) 验证 c) 是否能够正常执行测试过程。

8.2.7 加速卡信创操作系统适配测试

加速卡信创操作系统适配的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 执行操作系统检测脚本，检查业务操作系统中的版本和型号信息，是否满足信创操作系统要求；
- c) 在此业务操作系统环境中，完成与加速卡所有技术要求对应的全部测试内容；
- d) 验证 b) 中获取的业务操作系统数据是否正确；
- e) 验证 c) 是否能够正常执行测试过程。

注：若 8.2.6 中使用的操作系统是信创操作系统，可复用测试结果。

8.2.8 与 CPU 通信能力的测试

加速卡与 CPU 之间通信能力的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 安装 CPU 与加速卡之间通信带宽的测试工具；
- c) 执行相关命令，通过 b) 中的测试工具获取 CPU 到加速卡之间的通信带宽，并记录所有带宽值；
- d) 执行相关命令，通过 b) 中的测试工具获取加速卡到 CPU 之间的通信带宽，并记录所有带宽值；
- e) 对 c) 和 d) 中获取的所有带宽值求平均值，得出 CPU 与加速卡之间的通信带宽性能（GB/s）。

8.2.9 加速卡性能分析工具测试

加速卡支持性能分析工具的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；

- b) 编译并安装加速卡性能分析工具以及依赖的软件工具；
- c) 从 7.3.4 节给出的任一测试任务中，选取至少 1 种该任务下对应的算法模型，启动训练或推理任务；
- d) 执行命令运行加速卡性能分析工具，记录性能分析工具运行状态以及输出的日志，日志中需包含对加速卡系统性能分析数据，以及对加速卡上运行的应用程序性能分析数据，性能分析数据格式不限；
- e) 判断步骤 d) 中的性能分析工具运行是否正常且有正常的日志输出。

8.2.10 加速卡虚拟化功能测试

加速卡虚拟化功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡虚拟化依赖的软件工具；
- c) 执行相关命令，通过步骤 b) 中的软件工具，根据加速卡支持的虚拟化比例进行预期设定操作，进入容器服务查看加速卡虚拟化的比例值，并记录输出；
- d) 验证加速卡虚拟化比例值与预期设定是否一致；
- e) 执行相关命令进入加速卡虚拟化容器中并执行加速卡基本计算测试脚本，并记录输出；
- f) 验证是否输出正确结果，以及计算过程是否对加速卡正常调用。

8.2.11 电流及功率保护机制测试

加速卡电流及功率保护机制的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡监控工具、加压测试工具；
- c) 执行相关命令，通过步骤 b) 中的软件工具，对加速卡施加负载进行压测，通过监控工具查看加速卡的电流值及功率值，记录输出结果；
- d) 验证加速卡的电流值及功率值是否超出额定范围，以及测试过程中是否对加速卡正常调用。

8.2.12 动态功耗性能管理功能测试

加速卡动态功耗性能管理功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装功耗测试工具、加速卡监控工具、加压测试工具；
- c) 执行相关命令，通过步骤 b) 中的软件工具，对加速卡分别施加空置、普通负载（宜设置不同比例的负载，如施加满负载占比 20%、50%、80% 的普通负载）、满负载等不同负载，通过加速卡监控工具查看加速卡的功率值、工作频率、使用率等信息，记录输出结果；
- d) 验证加速卡的功耗是否随负载动态变化，以及测试过程中是否对加速卡正常调用。

8.2.13 错误异常处理功能测试

加速卡错误异常处理功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 从 7.3.4 节给出的测试任务中，选取至少 1 种该任务下对应的算法模型；
- c) 检查加速卡异常上报机制设计及相关接口文档；
- d) 依据异常上报机制的相关设计，通过软件或人为模拟异常发生场景；
- e) 导入相关测试脚本并部署，加载数据集；
- f) 执行相关命令对 b) 中选择的模型进行训练或测试，直到运行结束；

g) 根据接口文档的相关错误码内容验证加速卡是否可捕获并上报硬件错误异常。

8.2.14 云原生接入功能测试

加速卡云原生接入功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡云原生接入依赖的软件工具，如 K8s；
- c) 编译并安装使能加速卡云原生接入的设备插件等软件工具；
- d) 在集群（如 K8s 集群）中验证设备插件等工具是否能正常上报加速卡信息。

8.3 训练卡测试

8.3.1 训练卡功能测试

8.3.1.1 训练卡支持的数据精度类型测试

训练卡支持的数据精度类型测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 确定需测试的数据精度类型，导入相关测试脚本并部署；
- c) 执行 b) 中的测试脚本，测试训练卡在额定功率条件运行下的算力；
- d) 验证 c) 中测试脚本的计算结果与预期结果是否一致；
- e) 获取训练卡在选定数据精度类型下的峰值算力；
- f) 重复步骤 c) 多次，计算选定数据精度类型下的平均峰值算力。

8.3.1.2 训练卡混合精度训练功能测试

训练卡混合精度训练功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 从 7.3.4 节给出的测试任务中，选取至少 1 种该任务下对应的可进行混合精度训练的算法模型，修改并开启混合精度训练的相关代码或参数；
- c) 导入相关测试脚本并部署，加载训练数据集和验证数据集；
- d) 执行相关命令对 b) 中选择的模型进行混合精度训练，直到训练结束；
- e) 使用验证数据集验证训练得到的模型准确率，要求达到训练目标准确率；
- f) 验证 d) 中的训练是否可以正常结束；
- g) 验证 e) 中训练得到的模型准确率是否达到目标准确率。

8.3.1.3 训练卡自定义算子开发功能测试

训练卡自定义算子开发功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装训练卡编译器功能依赖的软件工具；
- c) 执行相关命令，通过 b) 中的软件栈编译器工具，根据训练卡支持的编译阶段、编译输入、编译输出等条件，执行自定义算子脚本，记录输出结果；
- d) 验证输出结果与预期结果是否一致。

8.3.1.4 训练卡支持的算子类型测试

训练卡支持的算子类型的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；

- b) 选取至少一种深度学习框架并安装；
- c) 导入相关测试脚本并部署；
- d) 执行测试脚本，利用框架提供的 API 或加速卡命令，完成被测算子的相关操作，记录输出结果；
- e) 验证输出结果与预期结果是否一致。

8.3.1.5 训练卡卡间互联通信能力测试

训练卡卡间互联通信能力的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡之间的通信带宽测试工具；
- c) 执行相关命令，通过 b) 中的测试工具获取加速卡之间的通信带宽值；
- d) 进行多次测量，求加速卡之间通信带宽值的平均值（GB/s），计算卡间互联的聚合带宽。

8.3.1.6 训练卡节点间高性能通信能力测试

训练卡支持节点间高性能通信能力的测试方法如下：

- a) 按照 7.2.1 节给出的组网策略完成至少 2 台服务器节点间的高速通信方式组网（如通过 RDMA 协议）；
- b) 通过测试机登录被测设备业务操作系统中；
- c) 编译并安装服务器节点间加速卡的通信带宽测试工具；
- d) 执行相关命令，通过 c) 中的测试工具获取两台服务器节点间加速卡之间的通信带宽值；
- e) 进行多次测量，求两台服务器节点间加速卡之间的通信带宽平均值（Gb/s）。

8.3.1.7 训练卡集合通讯库测试

训练卡支持集合通讯库功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 选取至少一种支持集合通讯库的深度学习框架并安装；
- c) 编译并安装被测集合通讯库；
- d) 导入相关测试脚本并部署（相关操作需涵盖典型的集合通讯算法）；
- e) 在单机多卡或多机多卡组网环境下执行测试脚本；
- f) 验证训练卡是否支持集合通讯库正常运行，集合通讯操作结果与预期结果是否一致；
- g) 验证训练卡是否支持集合通讯库中典型的集合通讯算法（如 all reduce、all gather、all to all、gather、reduce、reduce scatter、scatter、sendrecv 等）。

8.3.1.8 训练卡并行策略功能测试

训练卡并行策略功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 选定至少一种并行训练策略；
- c) 选取至少一种支持并行训练策略的深度学习框架并安装；
- d) 从 7.3.4 节给出的测试任务中，选取至少 1 种该任务下对应的支持并行训练的算法模型，修改并开启并行训练的相关代码或参数；
- e) 导入相关测试脚本并部署，加载训练数据集和验证数据集；
- f) 执行相关命令对 c) 中选择的模型进行训练，直到训练结束；
- g) 使用验证数据集验证训练得到的模型准确率，要求达到训练目标准确率；
- h) 验证 f) 中的训练是否可以正常结束；

- i) 验证 g) 中训练得到的模型准确率是否达到目标准确率。

8.3.1.9 训练卡软件加速库功能测试

训练卡软件加速库功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 从 7.3.4 节给出的测试任务中，选取至少 1 种该任务下对应的支持软件加速的算法模型，修改并开启加速库训练的相关代码或参数(非单独混精加速训练模式)；
- c) 导入相关测试脚本并部署，加载训练数据集和验证数据集；
- d) 执行相关命令对 b) 中选择的模型进行加速训练，直到训练结束；
- e) 使用验证数据集验证训练得到的模型准确率，要求达到训练目标准确率；
- f) 验证 d) 中的训练是否可以正常结束；
- g) 与非加速训练过程对比每秒处理样本数据量，验证是否实现训练加速。

8.3.1.10 训练卡视频解码功能测试

训练卡视频解码功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装训练卡视频解码依赖的软件工具；
- c) 导入相关测试脚本及视频测试文件；
- d) 执行视频流压测脚本命令，稳定解码时间 30 分钟，记录训练卡可完成的解码总帧数到日志中，其中并发数不限制；
- e) 验证 d) 中执行视频流压测脚本后是否输出正确的解码结果。

8.3.1.11 训练卡图像解码功能测试

训练卡图像解码功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装训练卡图像解码依赖的软件工具；
- c) 导入相关测试脚本及图像测试文件；
- d) 执行图像压测脚本命令，稳定解码时间 30 分钟，记录训练卡可完成的解码总帧数到日志中，其中并发数不限制；
- e) 验证 d) 中执行图像压测脚本后是否输出正确的解码结果。

8.3.2 训练卡性能测试

8.3.2.1 训练卡峰值计算性能测试

训练卡的峰值计算性能采用 8.3.1.1 的测试方法进行测试。

8.3.2.2 训练卡显存性能测试

训练卡显存类型、容量及带宽的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡监控工具；
- c) 执行相关命令，读取加速卡的显存类型、显存容量和显存带宽。

8.3.2.3 训练卡卡间互联聚合带宽测试

训练卡的卡间互联聚合带宽采用8.3.1.5的测试方法进行测试。

8.3.3 训练卡兼容性测试

8.3.3.1 训练卡深度学习框架适配测试

训练卡深度学习框架适配的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 选取至少一种主流的深度学习框架并安装；
- c) 从7.3.4节给出的测试任务中，选取至少1种该任务下对应的算法模型；
- d) 导入相关测试脚本并部署，加载训练数据集和验证数据集；
- e) 执行相关命令对c)中选择的模型进行训练，直到训练结束；
- f) 使用验证数据集验证训练得到的模型准确率，要求达到训练目标准确率；
- g) 验证e)中的训练是否可以正常结束；
- h) 验证f)中训练得到的模型准确率是否达到目标准确率。

8.3.3.2 训练卡分布式训练框架适配测试

训练卡分布式训练框架适配的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 选用至少一种主流的分布式训练框架并安装；
- c) 从7.3.4节给出的测试任务中，选取至少1种该任务下对应的支持分布式训练框架的算法模型，修改开启分布式训练的相关代码或参数；
- d) 导入相关测试脚本并部署，加载训练数据集和验证数据集；
- e) 执行相关命令对c)中选择的模型进行分布式训练，直到训练结束；
- f) 使用验证数据集验证训练得到的模型准确率，要求达到训练目标准确率；
- g) 验证e)中的训练是否可以正常结束；
- h) 验证f)中训练得到的模型准确率是否达到目标准确率。

8.3.3.3 训练卡接口适配测试

训练卡接口适配的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡监控工具和通信带宽测试工具；
- c) 执行相关命令，读取训练卡使用的接口协议及版本；
- d) 执行相关命令，通过通信带宽测试工具获取训练卡与CPU之间的通信带宽值；
- e) 验证训练卡与CPU的通信带宽和接口版本标称值误差是否在合理范围内。

8.3.4 训练卡可靠性测试

8.3.4.1 训练卡断点续训功能测试

训练卡断点续训功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 从7.3.4节给出的测试任务中，选取至少1种该任务下对应的算法模型；
- c) 选取至少一种支持断点续训的深度学习框架并安装；
- d) 导入相关测试脚本并部署，加载训练数据集和验证数据集；

- e) 通过相关软件或人为模拟（如切断电源）故障发生场景；
- f) 执行相关命令对 b) 中选择的模型进行训练，直到训练结束；
- g) 使用验证数据集验证训练得到的模型准确率，要求达到训练目标准确率；
- h) 验证 e) 中的训练是否可以正常结束；
- i) 验证系统是否能够执行自动断点保存、进行故障诊断并上报、以及自动恢复训练等操作；
- j) 验证 f) 中训练得到的模型准确率是否达到目标准确率。

8.3.4.2 训练卡稳定性压力测试

训练卡稳定性压力测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 安装加速卡加压测试工具；
- c) 导入相关测试脚本并部署；
- d) 执行测试脚本，使训练卡在满额定功率下连续运行 72 小时；
- e) 验证训练卡是否均在位且运行正常，无告警，日志无报错；
- f) 查看服务器 BMC 的 Web 界面下系统风扇转速是否随训练卡温度升高而增加；
- g) 验证系统重启后是否可正常识别训练卡。

8.3.4.3 训练卡内存错误修复测试

按照 GB/T 42018-2022 中 7.2.3 的相关规定，设置 ECC 为开启状态，检查 ECC 是否工作正常，或检查生产者提供的测试过程记录。

8.3.4.4 训练卡平均失效间隔工作时间测试

参照 GB/T 34986-2017 及 GB/T 9813.3-2017 中 5.9 的相关规定，训练卡平均失效间隔工作时间的测试采用高加速寿命试验方法进行长期可靠性验证，根据厂商选择的加速模型、测试温度等，推算出相应的测试时间。

8.3.5 模型训练性能测试

8.3.5.1 测试目的

本节通过在满足 7.3.3 节要求的深度学习框架下，使用选定的深度学习算法模型在相应的数据集上开展训练和验证，对相关测试过程及结果进行统计和度量，来测试人工智能训练加速卡的模型训练性能。

8.3.5.2 测试方法

模型训练性能的测试方法如下：

- a) 选取 7.3.4 节给出的某一测试任务，选取至少 1 种该任务下对应的算法模型测试用例，确定训练模型、数据集、目标准确率；
- b) 选取可运行 a) 中模型训练的深度学习框架并安装；
- c) 导入相关测试脚本并部署，设置检查点保存和加载操作，加载训练数据集和验证数据集；
- d) 安装加速卡功耗测试工具；
- e) 根据模型训练的需要和测试目的，启用单机单卡、单机多卡，或者多机多卡的组网模式；
- f) 训练过程不限制数据精度、batch size、sequence length 等超参数，允许使用软件加速库；
- g) 执行相关命令对 a) 中选择的模型进行训练；

- 1) 对于传统模型，训练过程中使用验证数据集验证训练得到的模型准确率，要求模型最终达到训练目标准确率；
- 2) 对于大规模预训练模型，在训练数据集上完成一轮或多轮训练，要求loss收敛；
- 3) 对于大规模预训练模型，开启检查点保存和加载操作，在训练数据集上开展训练；
- h) 验证训练过程中，所有加速卡是否均在位且运行正常，无告警；
- i) 验证 g) 中训练得到的模型准确率是否达到目标准确率，对于预训练模型验证 loss 是否已经收敛；
- j) 训练过程中测量并记录训练卡的功耗等指标；
- k) 测量并记录训练时间、检查点保存和加载时间，测试过程可独立进行多次，为减少统计差异或选取最优结果的可能性，每个模型最终测试结果舍弃最快和最慢过程，取中间值为最终结果；将单个非收敛运行视为最慢运行并丢弃；测试有效结果不足 3 份，取最快过程值。如果有多个非收敛运行，则该最终测试结果无效；
- l) 重复以上测试流程，将 7.3.4 节给出的所有测试任务运行一遍。

8.3.5.3 性能度量

依据6.2.5节中给出的性能度量指标及其计算方法，在8.3.5.2节的测试过程中获取并记录相关数据，计算出训练卡在各种算法模型训练过程中的训练时间、训练吞吐率、训练功耗、训练能效、多卡训练线性度、检查点保存和加载时间等，通过相关指标对训练卡的模型训练性能进行度量。

8.4 推理卡测试

8.4.1 推理卡功能测试

8.4.1.1 推理卡支持的数据精度类型测试

推理卡支持的数据精度类型测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 确定需测试的数据精度类型，导入相关测试脚本并部署；
- c) 执行 b) 中的测试脚本，测试推理卡在额定功率条件运行下的算力；
- d) 验证 c) 中测试脚本的计算结果与预期结果是否一致；
- e) 获取推理卡在选定数据精度类型下的峰值算力；
- f) 重复步骤 c) 多次，计算选定数据精度类型下的平均峰值算力。

8.4.1.2 推理卡自定义算子开发功能测试

推理卡自定义算子开发功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装推理卡编译器功能依赖的软件工具；
- c) 执行相关命令，通过 b) 中的软件栈编译器工具，根据推理卡支持的编译阶段、编译输入、编译输出等条件，执行自定义算子脚本，记录输出结果；
- d) 验证输出结果与预期结果是否一致。

8.4.1.3 推理卡支持的算子类型测试

推理卡支持的算子类型的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 选取至少一种深度学习框架或深度学习推理引擎并安装；

- c) 导入相关测试脚本并部署；
- d) 执行测试脚本，利用框架提供的 API 或加速卡命令，完成被测算子的相关操作，记录输出结果；
- e) 验证输出结果与预期结果是否一致。

8.4.1.4 推理卡卡间互联通信能力测试

推理卡卡间互联通信能力的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡之间的通信带宽测试工具；
- c) 执行相关命令，通过 b) 中的测试工具获取加速卡之间的通信带宽值；
- d) 进行多次测量，求加速卡之间通信带宽值的平均值（GB/s），计算卡间互联的聚合带宽。

8.4.1.5 推理卡节点间高性能通信能力测试

推理卡支持节点间高性能通信能力的测试方法如下：

- a) 按照 7.2.1 节给出的组网策略完成至少 2 台服务器节点间的高速通信方式组网（如通过 RDMA 协议）；
- b) 通过测试机登录被测设备业务操作系统中；
- c) 编译并安装服务器节点间加速卡的通信带宽测试工具；
- d) 执行相关命令，通过 c) 中的测试工具获取两台服务器节点间加速卡之间的通信带宽值；
- e) 进行多次测量，求两台服务器节点间加速卡之间的通信带宽平均值（GB/s）。

8.4.1.6 推理卡集合通讯库测试

推理卡支持集合通讯库功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装集合通讯库运行所依赖的软件工具；
- c) 编译并安装被测集合通讯库；
- d) 导入相关测试脚本并部署（相关操作需涵盖典型的集合通讯算法）；
- e) 在单机多卡或多机多卡组网环境下执行测试脚本；
- f) 验证推理卡是否支持集合通讯库正常运行，集合通讯操作结果与预期结果是否一致；
- g) 验证推理卡是否支持集合通讯库中典型的集合通讯算法（如 all reduce、all gather、all to all、gather、reduce、reduce scatter、scatter、sendrecv 等）。

8.4.1.7 推理卡推理服务部署功能测试

推理卡推理服务部署功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装推理卡依赖的推理软件栈 runtime 等工具；
- c) 从 7.3.4 节给出的测试任务中，选取至少 3 种所列任务下对应的算法模型；
- d) 通过 b) 中的软件工具调用算法模型，通过运行模型推理服务部署工具实现模型的在线服务部署和运行；
- e) 通过相关测试脚本由客户端发起 http 或 grpc 协议请求，对统一部署的推理服务进行调用，判断是否有正确的推理输出结果；
- f) 通过相关测试脚本在客户端实现模型的动态加载和卸载；
- g) 验证 c) 中执行的推理服务统一部署状态是否正常；
- h) 验证 d) 中测试脚本并发请求返回值是否正常且稳定响应。

8.4.1.8 推理卡并行策略功能测试

推理卡并行策略功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 选定至少一种并行推理策略；
- c) 选取一种支持并行推理策略的深度学习框架或深度学习推理引擎并安装；
- d) 从 7.3.4 节给出的测试任务中，选取至少 1 种该任务下对应的支持并行推理的算法模型，修改并开启并行推理的相关代码或参数；
- e) 导入相关测试脚本并部署，加载测试数据集；
- f) 执行相关命令对 d) 中选择的模型执行数据推理，直到完成数据集所有数据的推理；
- g) 验证 f) 中的推理是否可以正常结束；
- h) 验证 f) 中推理得到的模型准确率是否达到目标准确率。

8.4.1.9 推理卡视频解码功能测试

推理卡视频解码功能的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装推理卡视频解码依赖的软件工具；
- c) 导入相关测试脚本及视频测试文件；
- d) 执行视频流压测脚本命令，模拟 96 路 1080P 的 H.264 或 H.265 格式视频流输入，帧率 30FPS，稳定解码时间 30 分钟，记录推理卡可完成的解码总帧数到日志中；
- e) 验证 d) 中执行视频流压测脚本后是否输出正确的解码结果。

8.4.1.10 推理卡图像解码功能测试

推理卡图像解码功能测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装推理卡图像解码依赖的软件工具；
- c) 导入相关测试脚本及图像测试文件（包含但不限于 1080P 的 JPEG 格式图像）；
- d) 执行图像压测脚本命令，稳定解码时间 30 分钟，记录推理卡可完成的解码总帧数到日志中；
- e) 验证 d) 中执行图像压测脚本后是否输出正确的解码结果；
- f) 验证 d) 中执行图像压测脚本后每秒完成的分辨率为 1080P 的 JPEG 格式图像解码率是否不低于 4000 Frames/s。

8.4.2 推理卡性能测试

8.4.2.1 推理卡峰值计算性能测试

推理卡的峰值计算性能采用 8.4.1.1 的测试方法进行测试。

8.4.2.2 推理卡显存性能测试

推理卡显存类型、容量及带宽的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡监控工具；
- c) 执行相关命令，读取加速卡的显存类型、显存容量和显存带宽。

8.4.2.3 推理卡视频解码性能测试

推理卡的视频解码性能采用8.4.1.9的测试方法进行测试。

8.4.2.4 推理卡图像解码性能测试

推理卡的图像解码性能采用8.4.1.10的测试方法进行测试。

8.4.3 推理卡兼容性测试

8.4.3.1 推理卡深度学习框架适配测试

推理卡深度学习框架适配的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 选取至少一种主流的深度学习框架并安装；
- c) 从7.3.4节给出的测试任务中，选取至少1种该任务下对应的算法模型；
- d) 导入相关测试脚本并部署，加载推理数据集；
- e) 执行相关命令用c)中选择的模型执行数据推理，直到完成数据集所有数据的推理；
- f) 验证e)中的推理是否可以正常结束；
- g) 验证e)中推理得到的模型准确率是否达到目标准确率。

8.4.3.2 推理卡深度学习推理引擎适配测试

推理卡深度学习推理引擎适配的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 安装推理卡支持的深度学习推理引擎；
- c) 从7.3.4节给出的测试任务中，选取至少1种该任务下对应的算法模型；
- d) 将模型文件处理、转换为可通过深度学习推理引擎运行的模型文件格式；
- e) 导入相关测试脚本并部署，加载推理数据集；
- f) 执行相关命令用c)中选择的模型执行数据推理，直到完成数据集所有数据的推理；
- g) 验证f)中的推理是否可以正常结束；
- h) 验证f)中推理得到的模型准确率是否达到目标准确率。

8.4.3.3 推理卡接口适配测试

推理卡接口适配的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡监控工具和通信带宽测试工具；
- c) 执行相关命令，读取推理卡使用的接口协议及版本；
- d) 执行相关命令，通过通信带宽测试工具获取推理卡与CPU之间的通信带宽值；
- e) 验证推理卡与CPU的通信带宽和接口版本标称值误差是否在合理范围内。

8.4.3.4 推理卡跨厂商模型推理兼容性测试

推理卡跨厂商模型推理兼容性的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 从7.3.4节给出的测试任务中，选取至少1种该任务下对应的算法模型；
- c) 选用1种非测试设备生产厂商所生产的训练加速卡；
- d) 通过模型训练生成模型文件，并将模型文件处理、转换为被测设备支持的模型文件格式；

- e) 导入相关测试脚本并部署，加载推理数据集；
- f) 执行相关命令采用 d) 中转换后的模型文件执行数据推理，直到完成数据集所有数据的推理；
- g) 验证 f) 中的推理是否可以正常结束；
- h) 验证 f) 中推理得到的模型准确率是否达到目标准确率。

8.4.4 推理卡可靠性测试

8.4.4.1 推理时延波动性测试

推理卡的推理时延波动性的测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 选取一种主流的深度学习框架或深度学习推理引擎并安装；
- c) 从 7.3.4 节给出的测试任务中，选取至少 1 种该任务下对应的算法模型；
- d) 导入相关测试脚本并部署，加载推理数据集；
- e) 执行相关命令用 c) 中选择的模型执行数据推理，直到完成数据集所有数据的推理；
- f) 重复开展 e) 中的数据推理操作，记录每次完成所有数据推理所用的总时间；
- g) 验证 e) 中的推理是否可以正常结束；
- h) 验证 e) 中推理得到的模型准确率是否达到目标准确率；
- i) 验证 f) 中得到的各次推理时间是否在合理范围内波动。

8.4.4.2 推理卡稳定性压力测试

推理卡稳定性压力测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 安装加速卡加压测试工具；
- c) 导入相关测试脚本并部署；
- d) 执行测试脚本，使推理卡在满额定功率下连续运行 72 小时；
- e) 验证推理卡是否均在位且运行正常，无告警，日志无报错；
- f) 查看服务器 BMC 的 Web 界面下系统风扇转速是否随推理卡温度升高而增加；
- g) 验证系统重启后是否可正常识别推理卡。

8.4.4.3 推理卡内存错误修复测试

按照 GB/T 42018-2022 中 7.2.3 的相关规定，设置 ECC 为开启状态，检查 ECC 是否工作正常，或检查生产者提供的测试过程记录。

8.4.4.4 推理卡平均失效间隔工作时间测试

参照 GB/T 34986-2017 及 GB/T 9813.3-2017 中 5.9 的相关规定，推理卡平均失效间隔工作时间的测试采用高加速寿命试验方法进行长期可靠性验证，根据厂商选择的加速模型、测试温度等，推算出相应的测试时间。

8.4.5 模型推理性能测试

8.4.5.1 测试目的

本节通过在 7.3.4 节给出的测试场景下，使用选定的深度学习算法模型在相应的数据集上开展测试，对相关测试过程及结果进行统计和度量，来测试人工智能推理加速卡的模型推理性能。

8.4.5.2 测试方法

模型推理性能的测试方法如下：

- a) 选取 7.3.4 节给出的某一测试任务，选取至少 1 种该任务下对应的算法模型测试用例，确定推理模型、数据集、目标准确率；
- b) 安装被测设备支持的推理引擎或可运行 a) 中模型推理的深度学习框架；
- c) 导入训练好的模型，并将模型文件处理、转换为被测设备支持的模型文件格式；
- d) 导入相关测试脚本并部署，加载测试数据集；
- e) 安装加速卡功耗测试工具；
- f) 根据模型推理的需要和测试目的，启用单机单卡、单机多卡，或者多机多卡的组网模式；
- g) 推理过程不限制数据精度、sequence length 等超参数，允许使用软件加载库；
- h) 执行相关命令使用 c) 中转换后的模型文件进行模型推理：
 - 1) 在整个数据集上迭代一轮（epoch=1）进行推理运算，并记录推理过程中每一个数据样本的推理结果，要求推理过程结束后模型准确率不低于准确率最低要求，并进行吞吐率等性能测试；
 - 2) 在数据集上进行推理运算，推理过程设定单次请求 stream=1（batch size=1），请求多次（如请求次数=1024），按顺序遍历数据集，要求推理过程结束后模型准确率不低于最低要求，并进行推理时延等性能测试；
- i) 验证推理过程中，所有加速卡是否均在位且运行正常，无告警；
- j) 验证 h) 中推理过程是否正常结束且准确率不低于最低要求；
- k) 推理过程中测量并记录推理卡的功耗等指标；
- l) 测试过程可独立进行多次，为减少统计差异或选取最优结果的可能性，每个模型最终测试结果舍弃最快和最慢过程，取中间值为最终结果；
- m) 重复以上测试流程，将 7.3.4 节给出的所有测试任务运行一遍。

8.4.5.3 性能度量

依据 6.3.5 节中给出的性能度量指标及其计算方法，在 8.4.5.2 节的测试过程中获取并记录相关数据，计算出推理卡在各种算法模型推理过程中的推理时延、推理吞吐率、推理功耗、推理能效，通过相关指标对推理卡的模型推理性能进行度量。

8.5 安全性测试

8.5.1 安全启动功能测试

通过对人工智能加速卡设计方案材料或测试证书等进行审查来测试加速卡的安全启动功能。

8.5.2 加解密功能测试

加速卡的加解密功能测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡运行依赖的软件工具；
- c) 准备输入数据，执行加密命令，记录输出结果；
- d) 验证输出结果与预期结果是否一致；
- e) 准备输入数据，执行解密命令，记录输出结果；
- f) 验证输出结果与预期结果是否一致。

8.5.3 模型与数据加解密功能测试

加速卡的模型与数据加解密功能测试方法如下：

- a) 通过测试机登录被测设备业务操作系统中；
- b) 编译并安装加速卡运行依赖的软件工具；
- c) 准备输入数据，执行加速卡支持的加解密算法，如国密 SM2/3/4 算法，与 host CPU 执行同样的加解密操作测试项，验证结果是否一致，以证明加速卡支持加解密操作；
- d) 使能加速卡的加解密通信功能，检查加速卡与 host CPU 之间的数据传输操作是否处于密文状态。

8.5.4 随机数生成功能测试

通过对人工智能加速卡设计方案材料或测试证书等进行审查来测试加速卡的TRNG真随机数生成功能。

附 录 A
(资料性)
系统配置

A. 1 操作系统

表A. 1 主流操作系统

操作系统	版本要求
Linux	Red Hat Enterprise Linux 7.6（64 bits）及以上版本 CentOS 7.6及以上版本 Ubuntu 18.04.1及以上版本 Anolis OS 8.2及以上版本 Euler 20.03及以上版本 银河麒麟V10及以上版本 UOS V20及以上版本 BC-Linux V8.2及以上版本 NingOS V3 及以上版本 包括但不限于以上操作系统的开源或商业版本

A. 2 深度学习框架

表A. 2 主流深度学习框架

深度学习框架	版本要求
训练/推理	Tensorflow 2.X版需2.5.0及以上版本、1.X版需1.15.5及以上版本 PyTorch 1.6及以上版本 PaddlePaddle 2.2.0及以上版本 MindSpore 1.6.0及以上版本 Oneflow 0.6.0及以上版本 包括但不限于以上深度学习框架

A. 3 参考测试用例

A. 3. 1 训练场景

本节给出用于测试人工智能训练加速卡的模型训练性能的参考算法模型、数据集及模型的目标准确率，如表A. 3所示。

表A.3 模型训练性能测试参考用例

类别	场景	任务	训练模型	数据集	目标准确率
传统模型	视觉类	图像分类	Resnet50	CIFAR10	acc ≥ 93.62%
			ResNet50	ImageNet2012	top1 acc ≥ 75.9%
			MobileNet v3	CIFAR10	top1 acc ≥ 92.97%
		目标检测	yolov5	COC02017	mAP(50-95) ≥ 37.4
		图像分割	Unet	Cityscape城市道路分割	mIoU ≥ 65%
			DeepLabv3+	Cityscape城市道路分割	mIoU ≥ 78.5%
		视频分类	TSM	something-something v2	top1 acc ≥ 58.95%
		文本识别	DBNet	ICDAR 2015	Precision ≥ 86% Recall ≥ 78% Hmean ≥ 82%
			CRNN	训练集: MJSynth、SynthText; 测试集: IIIT, SVT, IC03, IC13, IC15, SVTP, CUTE	acc ≥ 81%
	语音类	语音识别	conformer	中文Aishell-1	字准确率 ≥ 93%
		声纹识别	ECAPA-TDNN	Voxceleb2	err < 1%
		语音合成	fastspeech2+mb_melgan	中文标准女声音音库	RTF < 0.02
预训练模型	推荐类	智能推荐	DIN	movieLens	auc ≥ 0.72
			DLRM	Criteo Terabyte	auc ≥ 0.75
	视觉类	/	Swin-transformer	CIFAR10	acc ≥ 90%
	语言类	/	BERT-Base	TNEWS 今日头条中文新闻（短文本）分类	acc ≥ 89.8%
			T5(Text-to-Text Transfer Transformer)	CSL文本摘要生成	Rouge-L ≥ 54.43% Rouge-1 ≥ 58.64% Rouge-2 ≥ 44.21%
			GLM v2-6B	en-wiki	1、训练：完成目标数据集部分数据训练或特定轮数，loss满足相关收敛要求 2、微调：满足相应任务的准确率要求
			Baichuan2-7B	en-wiki	
			LLaMa2-13B	en-wiki	
			LLaMa2-70B	en-wiki	

A.3.2 推理场景

本节给出用于测试人工智能推理加速卡的模型推理性能的参考算法模型、数据集及模型的目标准确率，如表A.4所示。

表A.4 模型推理性能测试参考用例

类别	场景	任务	推理模型	数据集	目标准确率
传统模型	视觉类	图像分类	MobileNet v3	imagenet1k	top1 acc ≥ 67.52%
			Resnet50	imagenet	top1 acc ≥ 0.75

类别	场景	任务	推理模型	数据集	目标准确率
		目标检测	yolov5	COCO2017	mAP (50-95) ≥ 37.4
		图像分割	deeplab v3	Pascal voc 2013	mIoU $\geq 85\%$
		视频分类	TSM	something-something v2	top1 acc $\geq 58.95\%$
		文本识别	DBNet	ICDAR 2015	hmean $\geq 82\%$
			CRNN	IIIT, SVT, IC03, IC13, IC15, SVTP, CUTE	acc $\geq 81\%$
	语音类	声纹识别	ECAPA-TDNN	Voxceleb1	err $< 0.8\%$
		语音合成	fastspeech2+mb_melgan	中文标准女声语音库	RTF < 0.02 CMOS > -0.1
	推荐类	智能推荐	DLRM	Criteo Terabyte	auc ≥ 0.8025
预训练模型	视觉类	/	Swin-transformer	imagenet1k	acc ≥ 83.2
			Stable Diffusion (LoRa、DreamBooth、Textual inversion微调)	/	主观评判
	语言类	/	BERT-Base	TNEWS 今日头条中文新闻（短文本）分类	acc $\geq 89.78\%$
			BERT-Large	SQUAD V1.1	F1 $> 88.5\%$
			Baichuan2-7B	BookSum、GovReport、SQuALITY	Rouge
			LLaMa2-13B	BookSum、GovReport、SQuALITY	Rouge
			LLaMa2-70B	BookSum、GovReport、SQuALITY	Rouge