



(12) 发明专利申请

(10) 申请公布号 CN 120031107 A

(43) 申请公布日 2025. 05. 23

(21) 申请号 202510096043.2

G06F 9/50 (2006.01)

(22) 申请日 2025.01.21

G06F 8/60 (2018.01)

(71) 申请人 中煤科工开采研究院有限公司

地址 101399 北京市顺义区中关村科技园
区顺义园临空二路1号

(72) 发明人 吕依濛

(74) 专利代理机构 北京清亦华知识产权代理事

务所(普通合伙) 11201

专利代理师 白雪静

(51) Int. Cl.

G06N 3/098 (2023.01)

G06N 3/0464 (2023.01)

G06N 3/048 (2023.01)

G06N 5/04 (2023.01)

G06N 5/01 (2023.01)

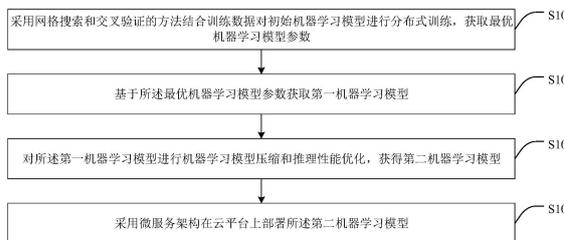
权利要求书2页 说明书8页 附图3页

(54) 发明名称

机器学习模型的训练与部署方法、装置、设备及存储介质

(57) 摘要

本申请提出一种机器学习模型的训练与部署方法、装置、设备及存储介质,其中,该方法可以应用于云计算平台,该方法包括:采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数;基于所述最优模型参数获取第一机器学习模型;对所述第一机器学习模型进行模型压缩和推理性能优化,获得第二机器学习模型;采用微服务架构在云计算平台上部署所述第二机器学习模型。通过本申请的技术方案,能够实现机器学习模型的高效优化与部署。



1. 一种机器学习模型的训练与部署方法,其特征在于,所述方法应用于云计算平台,所述方法包括:

采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数;

基于所述最优模型参数获取第一机器学习模型;

对所述第一机器学习模型进行模型压缩和推理性能优化,获得第二机器学习模型;

采用微服务架构在云计算平台上部署所述第二机器学习模型。

2. 如权利要求1所述的方法,其特征在于,所述采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数,包括:

将所述训练数据划分为至少一个子数据集;

将所述初始模型划分为至少一个子模型单元;

基于所述子数据集的数量、所述子模型单元的数量、所述训练数据的数据总量和所述初始模型的模型总量,获取第一数值;

基于所述第一数值和预设的第一阈值,确定目标并行方案;

基于所述目标并行方案,并采用网格搜索和交叉验证的方法对所述子模型单元进行分布式训练。

3. 如权利要求2所述的方法,其特征在于,所述训练数据包括训练集和验证集,所述采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数可表示如下:

$$\theta^* = \arg \min_{\theta} \sum_{i=1}^k \text{Loss} (D_{val}^i; \theta)$$

其中, θ^* 为所述最优模型参数,k为交叉验证的折叠数, D_{val}^i 是第i次折叠的验证集。

4. 如权利要求2所述的方法,其特征在于,采用以下公式基于所述子数据集的数量、所述子模型单元的数量、所述训练数据的数据总量和所述初始模型的模型总量,获取第一数值:

$$V = \text{round} \left(\frac{S}{s} + Z_1 \right) \times s + \text{round} \left(\frac{M}{m} + Z_2 \right) \times m$$

其中,V为所述第一数值,S为所述训练数据的数据总量,s为所述子数据集的数量,M为所述初始模型的模型总量,m为所述子模型单元的数量, Z_1 和 Z_2 为预设的参数值。

5. 如权利要求2所述的方法,其特征在于,所述基于所述目标并行方案,并采用网格搜索和交叉验证的方法对所述子模型单元进行分布式训练,包括:

基于参数服务器,采用所述目标并行方案和梯度压缩方法进行分布式训练。

6. 如权利要求1所述的方法,其特征在于,所述推理性能优化所采用的推理性能优化方法包括模型量化、模型剪枝和硬件加速中的至少一种,所述对所述第一机器学习模型进行模型压缩和推理性能优化,获得第二机器学习模型,包括:

对所述第一机器学习模型进行模型压缩;

获取每种所述推理性能优化方法对应的权重值;

基于每种所述推理性能优化方法对应的权重值,确定每种所述推理性能优化方法的使

用概率;

基于所述使用概率和所述推理性能优化方法,对所述第一机器学习模型进行推理性能优化,获得所述第二机器学习模型。

7.一种机器学习模型的训练与部署装置,其特征在于,所述装置应用于云计算平台,包括:

第一处理模块,用于采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数;

第二处理模块,用于基于所述最优模型参数获取第一机器学习模型;

第三处理模块,用于对所述第一机器学习模型进行模型压缩和推理性能优化,获得第二机器学习模型;

部署模块,用于采用微服务架构在云计算平台上部署所述第二机器学习模型。

8.一种电子设备,其特征在于,包括:处理器,以及与所述处理器通信连接的存储器;

所述存储器存储计算机执行指令;

所述处理器执行所述存储器存储的计算机执行指令,以实现如权利要求1~6中任一项所述的方法。

9.一种计算机可读存储介质,其特征在于,所述计算机可读存储介质中存储有计算机执行指令,所述计算机执行指令被处理器执行时用于实现如权利要求1~6中任一项所述的方法。

10.一种计算机程序产品,其特征在于,包括计算机程序,所述计算机程序在被处理器执行时实现如权利要求1~6中任一项所述的方法。

机器学习模型的训练与部署方法、装置、设备及存储介质

技术领域

[0001] 本申请涉及机器学习技术领域,尤其涉及一种机器学习模型的训练与部署方法、装置、设备及存储介质。

背景技术

[0002] 机器学习是人工智能的核心分支之一,它使计算机能够在无需明确编程的情况下,通过数据进行学习和改进。机器学习模型的优化对模型的性能和准确性至关重要,也是后续部署与优化的基础。同时,如何将机器学习模型高效部署到生产环境并确保其稳定运行也面临很多挑战。

发明内容

[0003] 本申请旨在至少在一定程度上解决相关技术中的技术问题之一。

[0004] 第一方面,本申请提出一种机器学习模型的训练与部署方法,所述方法应用于云计算平台,所述方法包括:采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数;基于所述最优模型参数获取第一机器学习模型;对所述第一机器学习模型进行模型压缩和推理性能优化,获得第二机器学习模型;采用微服务架构在云计算平台上部署所述第二机器学习模型。

[0005] 在一种实现方式中,所述采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数,包括:将所述训练数据划分为至少一个子数据集;将所述初始模型划分为至少一个子模型单元;基于所述子数据集的数量、所述子模型单元的数量、所述训练数据的数据总量和所述初始模型的模型总量,获取第一数值;基于所述第一数值和预设的第一阈值,确定目标并行方案;基于所述目标并行方案,并采用网格搜索和交叉验证的方法对所述子模型单元进行分布式训练。

[0006] 在一种可选地实现方式中,所述训练数据包括训练集和验证集,所述采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数可表示如下:

$$[0007] \quad \theta^* = \arg \min_{\theta} \sum_{i=1}^k \text{Loss} (D_{val}^i; \theta)$$

[0008] 其中, θ^* 为所述最优模型参数,k为交叉验证的折叠数, D_{val}^i 是第i次折叠的验证集。

[0009] 在一种可选地实现方式中,采用以下公式基于所述子数据集的数量、所述子模型单元的数量、所述训练数据的数据总量和所述初始模型的模型总量,获取第一数值:

$$[0010] \quad V = \text{round} \left(\frac{S}{s} + Z_1 \right) \times s + \text{round} \left(\frac{M}{m} + Z_2 \right) \times m$$

[0011] 其中,V为所述第一数值,S为所述训练数据的数据总量,s为所述子数据集的数量,M为所述初始模型的模型总量,m为所述子模型单元的数量, Z_1 和 Z_2 为预设的参数值。

[0012] 在一种可选地实现方式中,所述基于所述目标并行方案,并采用网格搜索和交叉验证的方法对所述子模型单元进行分布式训练,包括:基于参数服务器,采用所述目标并行方案和梯度压缩方法进行分布式训练。

[0013] 在一种实现方式中,所述推理性能优化所采用的推理性能优化方法包括模型量化、模型剪枝和硬件加速中的至少一种,所述对所述第一机器学习模型进行模型压缩和推理性能优化,获得第二机器学习模型,包括:对所述第一机器学习模型进行模型压缩;获取每种所述推理性能优化方法对应的权重值;基于每种所述推理性能优化方法对应的权重值,确定每种所述推理性能优化方法的使用概率;基于所述使用概率和所述推理性能优化方法,对所述第一机器学习模型进行推理性能优化,获得所述第二机器学习模型。

[0014] 第二方面,本申请提出一种机器学习模型的训练与部署装置,所述装置应用于云计算平台,所述装置包括:第一处理模块,用于采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数;第二处理模块,用于基于所述最优模型参数获取第一机器学习模型;第三处理模块,用于对所述第一机器学习模型进行模型压缩和推理性能优化,获得第二机器学习模型;部署模块,用于采用微服务架构在云计算平台上部署所述第二机器学习模型。

[0015] 在一种实现方式中,所述第一处理模块具体用于:将所述训练数据划分为至少一个子数据集;将所述初始模型划分为至少一个子模型单元;基于所述子数据集的数量、所述子模型单元的数量、所述训练数据的数据总量和所述初始模型的模型总量,获取第一数值;基于所述第一数值和预设的第一阈值,确定目标并行方案;基于所述目标并行方案,并采用网格搜索和交叉验证的方法对所述子模型单元进行分布式训练。

[0016] 在一种可选地实现方式中,所述训练数据包括训练集和验证集,所述采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数可表示如下:

$$[0017] \quad \theta^* = \arg \min_{\theta} \sum_{i=1}^k \text{Loss} (D_{val}^i; \theta)$$

[0018] 其中, θ^* 为所述最优模型参数, k 为交叉验证的折叠数, D_{val}^i 是第*i*次折叠的验证集。

[0019] 在一种可选地实现方式中,所述第一处理模块采用以下公式获取第一数值:

$$[0020] \quad V = \text{round} \left(\frac{S}{s} + Z_1 \right) \times s + \text{round} \left(\frac{M}{m} + Z_2 \right) \times m$$

[0021] 其中, V 为所述第一数值, S 为所述训练数据的数据总量, s 为所述子数据集的数量, M 为所述初始模型的模型总量, m 为所述子模型单元的数量, Z_1 和 Z_2 为预设的参数值。

[0022] 在一种可选地实现方式中,所述第一处理模块具体用于:基于参数服务器,采用所述目标并行方案和梯度压缩方法进行分布式训练。

[0023] 在一种实现方式中,所述推理性能优化所采用的推理性能优化方法包括模型量化、模型剪枝和硬件加速中的至少一种,所述对所述第一机器学习模型进行模型压缩和推理性能优化,获得第二机器学习模型,包括:对所述第一机器学习模型进行模型压缩;获取每种所述推理性能优化方法对应的权重值;基于每种所述推理性能优化方法对应的权重值,确定每种所述推理性能优化方法的使用概率;基于所述使用概率和所述推理性能优化

方法,对所述第一机器学习模型进行推理性能优化,获得所述第二机器学习模型。

[0024] 第三方面,本申请提出一种电子设备,包括:至少一个处理器;以及与所述至少一个处理器通信连接的存储器;其中,所述存储器存储有可被所述至少一个处理器执行的指令,所述指令被所述至少一个处理器执行,以使所述至少一个处理器能够执行如第一方面所述的机器学习模型的训练与部署方法。

[0025] 第四方面,本申请提出一种计算机可读存储介质,用于存储有指令,当所述指令被执行时,使如第一方面所述的方法被实现。

[0026] 第五方面,本申请提出一种计算机程序产品,包括计算机程序,所述计算机程序在被处理器执行时实现如第一方面所述的机器学习模型的训练与部署方法的步骤。

[0027] 本申请提供的机器学习模型的训练与部署方法、装置、设备及存储介质,可以采用网格搜索和交叉验证的方法结合训练数据对初始机器学习模型进行分布式训练,获取最优机器学习模型参数,以基于所述最优机器学习模型参数获取第一机器学习模型,并对所述第一机器学习模型进行机器学习模型压缩和推理性能优化获得第二机器学习模型,并将第二机器学习模型采用微服务架构在云计算平台上进行部署。能够实现机器学习模型的高效优化与部署。

[0028] 本申请附加的方面和优点将在下面的描述中部分给出,部分将从下面的描述中变得明显,或通过本申请的实践了解到。

附图说明

[0029] 本申请上述的和/或附加的方面和优点从下面结合附图对实施例的描述中将变得明显和容易理解,其中:

[0030] 图1是本申请实施例提供的一种机器学习模型的训练与部署方法的流程示意图;

[0031] 图2是本申请实施例提供的一种卷积神经网络的连接示意图;

[0032] 图3是本申请实施例提供的另一种机器学习模型的训练与部署方法的流程示意图;

[0033] 图4是本申请实施例提供的一种机器学习模型的训练与部署装置的结构示意图;

[0034] 图5是本申请实施例提供的电子设备的结构示意图。

具体实施方式

[0035] 下面详细描述本申请的实施例,所述实施例的示例在附图中示出,其中自始至终相同或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的,旨在用于解释本申请,而不能理解为对本申请的限制。

[0036] 下面参考附图描述本申请实施例的机器学习模型的训练与部署方法和装置。

[0037] 图1是本申请实施例提供的一种机器学习模型的训练与部署方法的流程示意图。该方法可以应用于云计算平台。如图1所示,该方法可以包括但不限于以下步骤:

[0038] 步骤S101:采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数。

[0039] 在一种实现方式中,采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数,包括:将训练数据划分为至少一个子数据集;将初始模

型划分为至少一个子模型单元；基于子数据集的数量、子模型单元的数量、训练数据的数据总量和初始模型的模型总量，获取第一数值；基于第一数值和预设的第一阈值，确定目标并行方案；基于目标并行方案，并采用网格搜索和交叉验证的方法对子模型单元进行分布式训练。

[0040] 其中，在本申请的实施例中，上述目标并行方案为数据并行和模型并行中的一种。

[0041] 在一种实现方式中，采用以下公式基于子数据集的数量、子模型单元的数量、训练数据的数据总量和初始模型的模型总量，获取第一数值：

$$[0042] \quad v = \text{round} \left(\frac{s}{S} + Z_1 \right) \cdot S + \text{round} \left(\frac{m}{M} + Z_2 \right) \cdot M$$

[0043] 其中，v为第一数值，s为子数据集的数量，S为训练数据的数据总量，m为子模型单元的数量，M为初始模型的模型总量， Z_1 和 Z_2 为预设的初始值。以第一阈值为 α 为例，若 $v \leq \alpha$ 则采用数据并行方案；若 $v > \alpha$ 则采用模型并行方案。

[0044] 需要说明的是，模型总量可以为机器学习模型的参数总量，即模型中所有参数的总数。

[0045] 在一种实现方式中，采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练，获取最优模型参数可表示如下：

$$[0046] \quad \theta^* = \arg \min_{\theta} \sum_{i=1}^k \text{Loss} (D_{val}^i; \theta)$$

[0047] 其中， θ^* 为最优模型参数，k为交叉验证的折叠数， D_{val}^i 是第i次折叠的验证集。

[0048] 步骤S102：基于最优模型参数获取第一机器学习模型。

[0049] 在一些实施例中，可以采用CNN(Convolutional neural network,卷积神经网络)模型架构，基于最优模型参数建立第一机器学习模型。

[0050] 示例性地，CNN的卷积层公式可表示如下：

$$[0051] \quad o_{i,j}^l = \sigma \left(\sum_m \sum_n I_{i+m,j+n}^{l-1} \cdot K_{m,n}^l + b^l \right)$$

[0052] 池化层的输出可表示如下：

$$[0053] \quad p = \text{pooling}(o)$$

[0054] 其中， $o_{i,j}^l$ 表示第l层卷积层在位置(i,j)的输出特征图。 $I_{i+m,j+n}^{l-1}$ 为l-1层输入特征图在位置(i,j)处的值， $K_{m,n}^l$ 为位置(m,n)处l层卷积核的权重， b^l 是l层的变差值， σ 是激活函数，m,n是卷积核的坐标，pooling代表池化操作。作为一种示例，请参见图2，图2是本申请实施例提供的一种卷积神经网络的连接示意图。

[0055] 步骤S103：对第一机器学习模型进行模型压缩和推理性能优化，获得第二机器学习模型。

[0056] 示例性地，对第一机器学习模型进行量化、剪枝模型压缩处理，以减少模型的体积和推理时间，并对经模型压缩后的第一机器学习模型进行推理性能优化，得到第二机器学习模型。

[0057] 在一种可选地实现方式中，量化操作可以表示为：

$$[0058] \quad Q = \text{round}\left(\frac{W}{S} + Z\right) \cdot S$$

[0059] 其中,Q是量化权重,W是最初权重,S是量化步骤的尺寸,Z是量化初始值。

[0060] 在一种可选地实现方式中,剪枝操作可以表示为:

$$[0061] \quad W' = W \cdot M$$

[0062] 其中,W'是剪枝后的权重,W是初始权重,M是剪枝掩码。

[0063] 步骤S104:采用微服务架构在云计算平台上部署第二机器学习模型。

[0064] 通过实施本申请实施例,可以采用网格搜索和交叉验证的方法结合训练数据对初始机器学习模型进行分布式训练,获取最优机器学习模型参数,以基于最优机器学习模型参数获取第一机器学习模型,并对第一机器学习模型进行机器学习模型压缩和推理性能优化获得第二机器学习模型,并将第二机器学习模型采用微服务架构在云计算平台上进行部署。能够实现机器学习模型的高效优化与部署。

[0065] 在一些实施例中,可以从多种推理性能优化方法中选择相应的方法,对第一机器学习模型进行推理性能优化。作为一种示例,请参见图3,图3是本申请实施例提供的另一种机器学习模型的训练与部署方法的流程示意图。方法可以应用于云计算平台。如图3所示,该方法可以包括但不限于以下步骤:

[0066] 步骤S301:采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数。

[0067] 本申请的实施例中,步骤S301可以分别采用本申请的各实施例中的任一种方式实现,本申请实施例并不对此作出限定,也不再赘述。

[0068] 步骤S302:基于最优模型参数获取第一机器学习模型。

[0069] 本申请的实施例中,步骤S302可以分别采用本申请的各实施例中的任一种方式实现,本申请实施例并不对此作出限定,也不再赘述。

[0070] 步骤S303:对第一机器学习模型进行模型压缩。

[0071] 本申请的实施例中,步骤S303可以分别采用本申请的各实施例中的任一种方式实现,本申请实施例并不对此作出限定,也不再赘述

[0072] 步骤S304:基于每种推理性能优化方法对应的权重值,确定每种推理性能优化方法的使用概率。

[0073] 其中,在本申请的实施例中,上述推理性能优化方法包括模型量化、模型剪枝和硬件加速。

[0074] 示例性地,可以采用以下公式基于每种推理性能优化方法对应的权重值,确定每种推理性能优化方法的使用概率。

$$[0075] \quad p(n) = \frac{p_i}{p_1 + p_2 + p_3}$$

[0076] 其中,p₁、p₂、p₃分别为模型量化、模型剪枝和硬件加速对应的权重值,i=1、2、3,p(n)为模型量化、模型剪枝和硬件加速对应的使用概率。

[0077] 作为一种示例,若p₁为模型量化对应的权重值,则当p_i=p₁时所求得p(n)即为模型量化对应的使用概率。

[0078] 步骤S305:基于使用概率和推理性能优化方法,对第一机器学习模型进行推理性

能优化,获得第二机器学习模型。

[0079] 示例性地,选取使用概率最大的推理性能优化方法对第一机器学习模型进行推理性能优化,获得第二机器学习模型。

[0080] 步骤S306:采用微服务架构在云计算平台上部署第二机器学习模型。

[0081] 通过实施本申请实施例,可以基于每个推理性能优化方法对应的权重值获取每个推理性能优化方法的使用概率,从而基于使用概率选取相应的推理性能优化方法对第一机器学习模型进行推理性能优化得到第二机器学习模型。能够实现机器学习模型的高效优化与部署。

[0082] 请参见图4,图4是本申请实施例提供的一种机器学习模型的训练与部署装置的结构示意图。该装置可以应用于云计算平台。如图4所示,该装置400包括:第一处理模块401,用于采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数;第二处理模块402,用于基于最优模型参数获取第一机器学习模型;第三处理模块403,用于对第一机器学习模型进行模型压缩和推理性能优化,获得第二机器学习模型;部署模块404,用于采用微服务架构在云计算平台上部署第二机器学习模型。

[0083] 在一种实现方式中,第一处理模块401具体用于:将训练数据划分为至少一个子数据集;将初始模型划分为至少一个子模型单元;基于子数据集的数量、子模型单元的数量、训练数据的数据总量和初始模型的模型总量,获取第一数值;基于第一数值和预设的第一阈值,确定目标并行方案;基于目标并行方案,并采用网格搜索和交叉验证的方法对子模型单元进行分布式训练。

[0084] 在一种可选地实现方式中,训练数据包括训练集和验证集,采用网格搜索和交叉验证的方法结合训练数据对初始模型进行分布式训练,获取最优模型参数可表示如下:

$$[0085] \quad \theta^* = \arg \min_{\theta} \sum_{i=1}^k \text{Loss} (D_{val}^i; \theta)$$

[0086] 其中, θ^* 为最优模型参数, k 为交叉验证的折叠数, D_{val}^i 是第*i*次折叠的验证集。

[0087] 在一种可选地实现方式中,第一处理模块401采用以下公式获取第一数值:

$$[0088] \quad V = \text{round} \left(\frac{S}{s} + Z_1 \right) \times s + \text{round} \left(\frac{M}{m} + Z_2 \right) \times m$$

[0089] 其中, V 为第一数值, S 为训练数据的数据总量, s 为子数据集的数量, M 为初始模型的模型总量, m 为子模型单元的数量, Z_1 和 Z_2 为预设的参数值。

[0090] 在一种可选地实现方式中,第一处理模块401具体用于:基于参数服务器,采用目标并行方案和梯度压缩方法进行分布式训练。

[0091] 在一种实现方式中,推理性能优化所采用的推理性能优化方法包括模型量化、模型剪枝和硬件加速中的至少一种,第三处理模块403具体用于:对第一机器学习模型进行模型压缩;获取每种推理性能优化方法对应的权重值;基于每种推理性能优化方法对应的权重值,确定每种推理性能优化方法的使用概率;基于使用概率和推理性能优化方法,对第一机器学习模型进行推理性能优化,获得所述第二机器学习模型。

[0092] 通过本申请实施例的装置,可以采用网格搜索和交叉验证的方法结合训练数据对初始机器学习模型进行分布式训练,获取最优机器学习模型参数,以基于所述最优机器学习

习模型参数获取第一机器学习模型,并对所述第一机器学习模型进行机器学习模型压缩和推理性能优化获得第二机器学习模型,并将第二机器学习模型采用微服务架构在云计算平台上进行部署。能够实现机器学习模型的高效优化与部署。

[0093] 需要说明的是,前述对机器学习模型的训练与部署方法实施例的解释说明也适用于该实施例的机器学习模型的训练与部署装置,此处不再赘述。

[0094] 为了实现上述实施例,本申请还提出一种电子设备。请参见图5,图5是本申请实施例提供的电子设备的结构示意图。如图5所示,电子设备500包括:处理器501,以及与所述处理器501通信连接的存储器502;所述存储器502存储计算机执行指令;所述处理器501执行所述存储器存储的计算机执行指令,以实现执行前述实施例所提供的方法。

[0095] 为了实现上述实施例,本申请还提出一种计算机可读存储介质,计算机可读存储介质中存储有计算机执行指令,所述计算机执行指令被处理器执行时用于实现前述实施例所提供的方法。

[0096] 为了实现上述实施例,本申请还提出一种计算机程序产品,包括计算机程序,该计算机程序被处理器执行时实现前述实施例所提供的方法。

[0097] 其中,在本申请的描述中,除非另有说明,“/”表示或的意思,例如,A/B可以表示A或B;本文中的“和/或”仅仅是一种描述关联对象的关联关系,表示可以存在三种关系,例如,A和/或B,可以表示:单独存在A,同时存在A和B,单独存在B这三种情况。

[0098] 在前述各实施例描述中,参考术语“一个实施例”、“一些实施例”、“示例”、“具体示例”、或“一些示例”等的描述意指结合该实施例或示例描述的具体特征、结构、材料或者特点包含于本申请的至少一个实施例或示例中。在本说明书中,对上述术语的示意性表述不必针对的是相同的实施例或示例。而且,描述的具体特征、结构、材料或者特点可以在一个或多个实施例或示例中以合适的方式结合。此外,在不相互矛盾的情况下,本领域的技术人员可以将本说明书中描述的不同实施例或示例以及不同实施例或示例的特征进行结合和组合。

[0099] 此外,术语“第一”、“第二”仅用于描述目的,而不能理解为指示或暗示相对重要性或者隐含指明所指示的技术特征的数量。由此,限定有“第一”、“第二”的特征可以明示或者隐含地包括至少一个该特征。在本申请的描述中,“多个”的含义是至少两个,例如两个,三个等,除非另有明确具体的限定。

[0100] 流程图中或在此以其他方式描述的任何过程或方法描述可以被理解为,表示包括一个或更多个用于实现定制逻辑功能或过程的步骤的可执行指令的代码的模块、片段或部分,并且本申请的优选实施方式的范围包括另外的实现,其中可以不按所示出或讨论的顺序,包括根据所涉及的功能按基本同时的方式或按相反的顺序,来执行功能,这应被本申请的实施例所属技术领域的技术人员所理解。

[0101] 在流程图中表示或在此以其他方式描述的逻辑和/或步骤,例如,可以被认为是在于实现逻辑功能的可执行指令的定序列列表,可以具体实现在任何计算机可读介质中,以供指令执行系统、装置或设备(如基于计算机的系统、包括处理器的系统或其他可以从指令执行系统、装置或设备取指令并执行指令的系统)使用,或结合这些指令执行系统、装置或设备而使用。就本说明书而言,“计算机可读介质”可以是任何可以包含、存储、通信、传播或传输程序以供指令执行系统、装置或设备或结合这些指令执行系统、装置或设备而使用的装

置。计算机可读介质的更具体的示例(非穷尽性列表)包括以下:具有一个或多个布线的电连接部(电子装置),便携式计算机盘盒(磁装置),随机存取存储器(RAM),只读存储器(ROM),可擦除可编程只读存储器(EPROM或闪速存储器),光纤装置,以及便携式光盘只读存储器(CDROM)。另外,计算机可读介质甚至可以是可在其上打印所述程序的纸或其他合适的介质,因为可以例如通过对纸或其他介质进行光学扫描,接着进行编辑、解译或必要时以其他合适方式进行处理来以电子方式获得所述程序,然后将其存储在计算机存储器中。

[0102] 应当理解,本申请的各部分可以用硬件、软件、固件或它们的组合来实现。在上述实施方式中,多个步骤或方法可以用存储在存储器中且由合适的指令执行系统执行的软件或固件来实现。如,如果用硬件来实现和在另一实施方式中一样,可用本领域公知的下列技术中的任一项或他们的组合来实现:具有用于对数据信号实现逻辑功能的逻辑门电路的离散逻辑电路,具有合适的组合逻辑门电路的专用集成电路,可编程门阵列(PGA),现场可编程门阵列(FPGA)等。

[0103] 本技术领域的普通技术人员可以理解实现上述实施例方法携带的全部或部分步骤是可以通程序来指令相关的硬件完成,所述的程序可以存储于一种计算机可读存储介质中,该程序在执行时,包括方法实施例的步骤之一或其组合。

[0104] 此外,在本申请各个实施例中的各功能单元可以集成在一个处理模块中,也可以是各个单元单独物理存在,也可以两个或两个以上单元集成在一个模块中。上述集成的模块既可以采用硬件的形式实现,也可以采用软件功能模块的形式实现。所述集成的模块如果以软件功能模块的形式实现并作为独立的产品销售或使用,也可以存储在一个计算机可读取存储介质中。

[0105] 上述提到的存储介质可以是只读存储器,磁盘或光盘等。尽管上面已经示出和描述了本申请的实施例,可以理解的是,上述实施例是示例性的,不能理解为对本申请的限制,本领域的普通技术人员在本申请的范围内可以对上述实施例进行变化、修改、替换和变型。

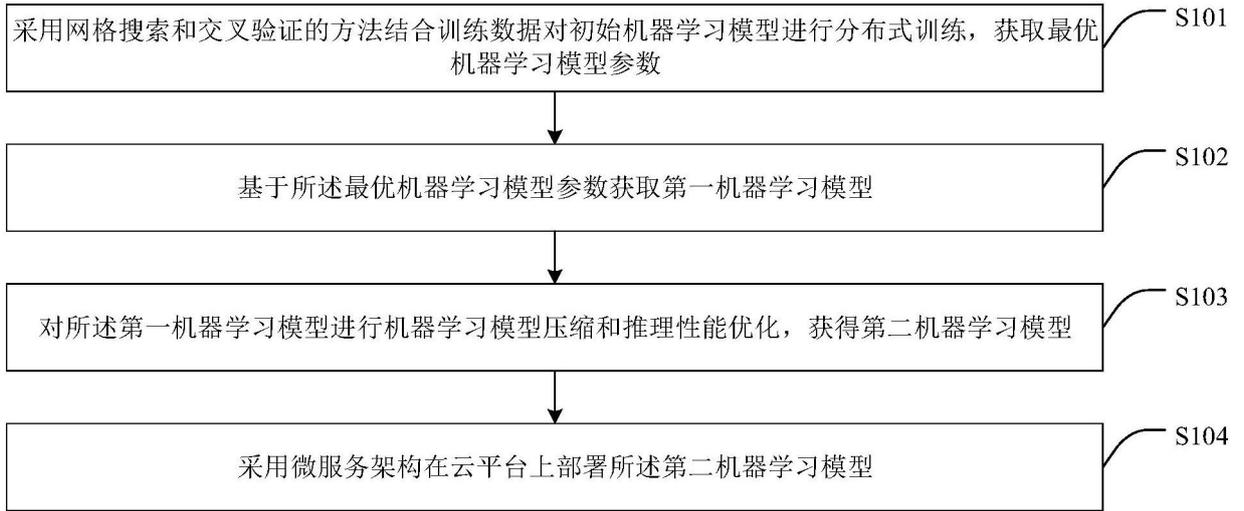


图1

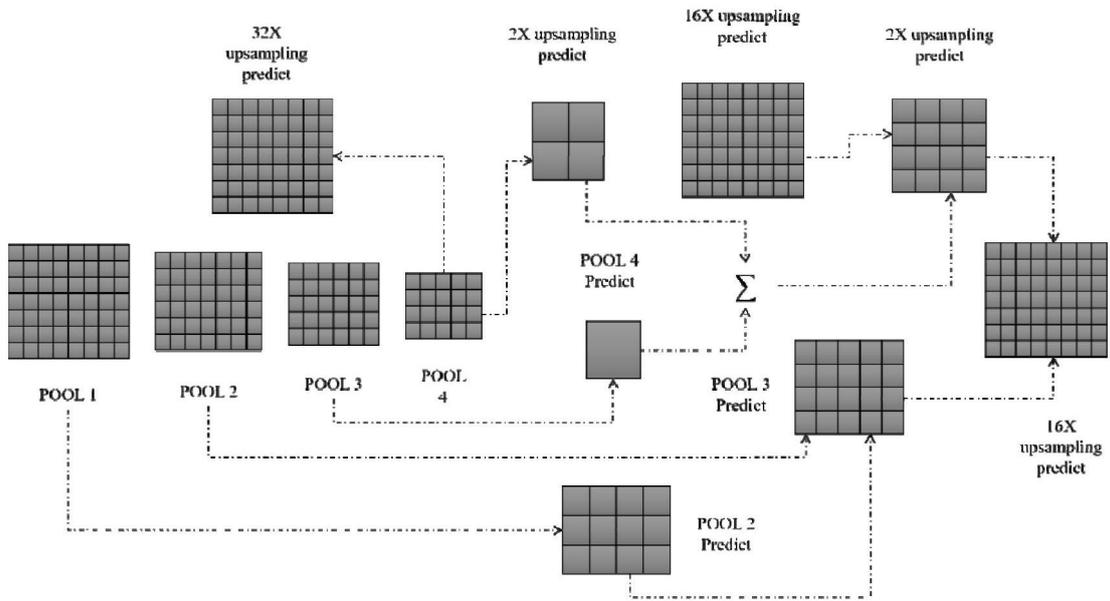


图2

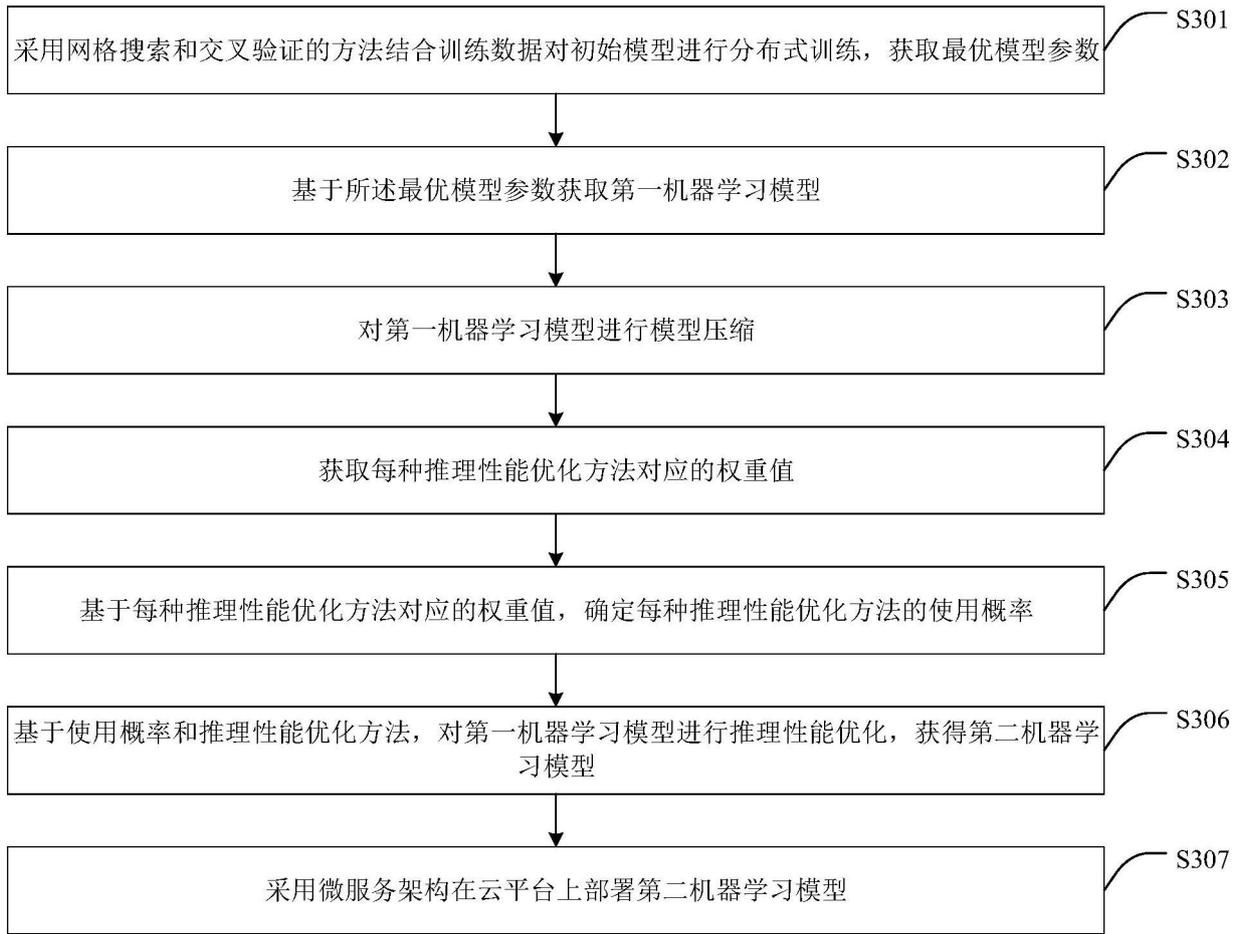


图3

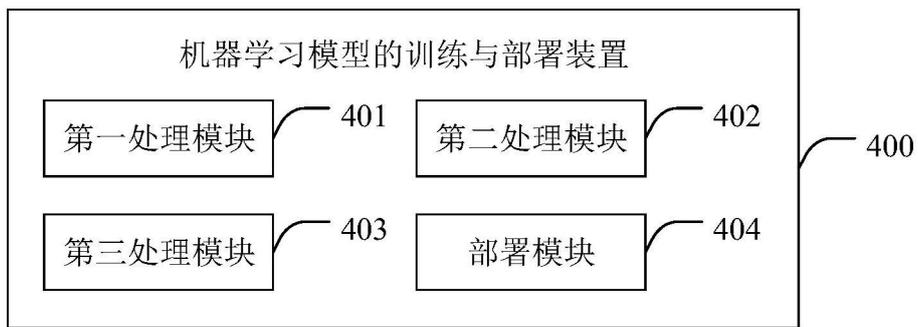


图4

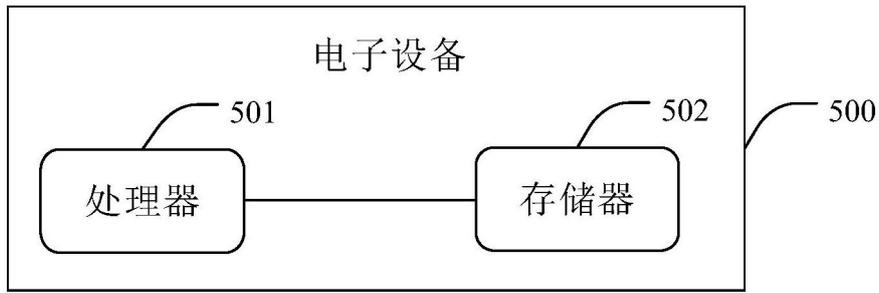


图5