

一种神经网络蒸馏方法以及装置

技术领域

本申请涉及人工智能领域，尤其涉及一种神经网络蒸馏方法以及装置。

5

背景技术

知识蒸馏是一种模型压缩技术，将复杂、学习能力强的网络学到的特征表示“知识”蒸馏出来并传递给参数量小、学习能力弱的网络。知识蒸馏可以将一个网络的知识转移到另一个网络，两个网络可以是同构或者异构。做法是先训练一个 teacher 网络，然后使用这个 teacher 网络的输出训练 student 网络。

10

然而，训练 student 网络的训练集可能存在偏置，容易导致 student 网络的输出结果不准确。并且，在通过 teacher 网络指导 student 网络时，student 网络的精度受限于 teacher 网络的精度影响，student 网络的输出精度无法有更大空间的提升。因此，如何得到输出更准确的网络，成为亟待解决的问题。

15

发明内容

本申请实施例提供了一种神经网络蒸馏方法以及装置，用于提供输出偏置更低的神经网络，提高神经网络的输出精度，且可以根据不同的场景选择合适的蒸馏方式，泛化能力强。

20

有鉴于此，本申请第一方面提供一种神经网络蒸馏方法，包括：首先，获取样本集，该样本集中包括有偏数据集和无偏数据集，该有偏数据集中包括有偏置的样本，该无偏数据集中包括无偏置的样本，通常，有偏数据集的数据量大于无偏数据集的数据量；随后，根据样本集的数据特征来确定第一蒸馏方式，在该第一蒸馏方式中，老师模型是使用无偏数据集进行训练得到的，学生模型是使用有偏数据集训练得到；随后，基于有偏数据集和无偏数据集，按照第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络。

25

因此，在本申请中，可以使用无偏数据集所包括的无偏样本，对第一神经网络的知识蒸馏过程进行指导，从而使更新后的第一神经网络可以输出无偏置的结果，实现对输入样本的纠偏，提高第一神经网络的输出准确率。此外，本申请提供的神经网络蒸馏方法中，可以选择与样本集的数据特征匹配的蒸馏方式，针对不同的场景可以使用不同的蒸馏方式，适应不同的场景，提高了对神经网络进行知识蒸馏的泛化能力。在不同条件下选择不同的知识蒸馏方式，最大化知识蒸馏的效益。

30

在一种可能的实施方式中，第一蒸馏方式是从预设的多种蒸馏方式中选择得到，多种蒸馏方式包括老师模型对学生模型的指导方式不相同的至少两种蒸馏方式。

因此，本申请实施方式中，针对不同的场景可以使用不同的蒸馏方式，适应不同的场景，提高了对神经网络进行知识蒸馏的泛化能力。在不同条件下选择不同的知识蒸馏方式，最大化知识蒸馏的效益。

35

在一种可能的实施方式中，有偏数据集和无偏数据集中的样本包括输入特征和实际标

签，第一蒸馏方式为基于样本集的样本的输入特征进行蒸馏。

本申请实施方式中，无偏数据集可以通过样本的形式，对有偏数据集的模型的知识蒸馏过程进行指导，从而使得到的更新后的第一神经网络的输出的偏置程度更低。

在一种可能的实施方式中，基于有偏数据集和无偏数据集，按照第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，可以包括：交替使用有偏数据集和无偏数据集对第一神经网络进行训练，得到更新后的第一神经网络，其中，在一个交替过程中，使用有偏数据集对第一神经网络进行训练的批训练次数，和使用无偏数据集对第一神经网络进行训练的批训练次数为预设比例，且样本包括输入特征作为第一神经网络的输入。因此，在本申请实施方式中，可以交替使用有偏数据集和无偏数据集进行训练，在使用无偏数据集中的样本对使用有偏数据集训练的第一神经网络进行纠偏，从而使更新后的第一神经网络的输出的偏置程度更低。

在一种可能的实施方式中，当预设比例为 1 时，在第一神经网络的损失函数中增加第一正则项和第二正则项的差值，第一正则项是使用无偏数据集包括的样本对第一神经网络进行训练得到的参数，第二正则项是使用有偏数据集包括的样本对第一神经网络进行训练得到的参数。

因此，在本申请实施方式中，可以通过有偏数据集和无偏数据集 1:1 的交替方式来训练第一神经网络，在使用无偏数据集中的样本对使用有偏数据集训练的第一神经网络进行纠偏，从而使更新后的第一神经网络的输出的偏置程度更低。

在一种可能的实施方式中，基于有偏数据集和无偏数据集，按照第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，可以包括：为有偏数据集中的样本设置置信度，置信度用于表示样本的偏置程度；基于有偏数据集、有偏数据集中的样本的置信度和无偏数据集，对第一神经网络进行训练，得到更新后的第一神经网络，且在对第一神经网络进行训练时样本包括输入特征作为第一神经网络的输入。

在本申请实施方式中，可以通过为样本设置表示偏置程度的置信度，以在训练神经网络时，学习到样本的偏置程度，从而降低更新后的神经网络的输出结果的偏置程度。

在一种可能的实施方式中，有偏数据集和无偏数据集所包括的样本包括输入特征和实际标签，第一蒸馏方式为基于无偏数据集所包括的样本的预测标签进行蒸馏，预测标签由更新后的第二神经网络针对无偏数据集中的样本输出，更新后的第二神经网络为使用无偏数据集对第二神经网络进行训练得到。

因此，本申请实施方式中，可以通过无偏数据集所包括的样本的预测标签对第一神经网络进行知识蒸馏，可以理解为，可以使用老师模型输出的无偏数据集中的样本的预测标签，完成对学习模型的指导，从而使更新后的第一神经网络在老师模型输出的预测标签的指导下，得到偏置程度更低的输出结果。

在一种可能的实施方式中，样本集中还包括未观测数据集，该未观测数据集中包括了多个未观测样本；上述的基于有偏数据集和无偏数据集，按照第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，可以包括：通过有偏数据集对第一神经网络进行训练，得到训练后的第一神经网络，以及通过无偏数据集对第二神经网络进行训练，得

-3-

到更新后的第二神经网络；从样本集中采集多个样本，得到辅助数据集；使用辅助数据集，以数据集中样本的预测标签作为约束，更新训练后的第一神经网络，得到更新后的第一神经网络，辅助数据集中样本的预测标签由更新后的第二神经网络输出的标签。

5 本申请实施方式中，可以引入未观测数据集，从而降低有偏数据集对第一神经网络训练过程中的偏置影响，使最终得到的第一神经网络的输出结果偏置程度更低。

在一种可能的实施方式中，基于有偏数据集和无偏数据集，按照第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，包括：通过无偏数据集对第二神经网络进行训练，得到更新后的第二神经网络；通过更新后的第二神经网络输出有偏数据集中样本的预测标签；将样本的预测标签和样本的实际标签进行加权合并，得到样本的合并标签；
10 使用样本的合并标签训练第一神经网络，得到更新后的第一神经网络。

本申请实施方式中，可以通过将样本的预测标签和样本的实际标签进行加权合并的方式，完成无偏数据集在训练第一神经网络的过程中的指导，使最终得到的第一神经网络的输出结果偏置程度更低。

在一种可能的实施方式中，样本集的数据特征包括第一比例，该第一比例为所述无偏数据集的样本量和所述有偏数据集的样本量之间的比例，根据样本集的数据特征确定第一蒸馏方式，可以包括：从多种蒸馏方式中选择与第一比例匹配的第一蒸馏方式。
15

因此，在本申请实施方式中，可以通过无偏数据集的样本量和有偏数据集的样本量之间的比例，来选择第一蒸馏方式，从而可以适应无偏数据集的样本量和有偏数据集的样本量之间的不同比例的场景。

20 在一种可能的实施方式中，第一蒸馏方式包括：基于从无偏数据集中提取到的特征训练老师模型，得到训练后的老师模型，并通过训练后的老师模型以及有偏数据集对学生模型进行知识蒸馏。

因此，本申请实施方式中，可以使用从无偏数据集中提取到的特征训练老师模型，得到偏置程度更低、更稳定的老师模型，在此基础上，进一步使通过老师模型指导得到的学生模型的输出结果偏置程度更低。
25

在一种可能的实施方式中，基于有偏数据集和无偏数据集，按照第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，可以包括：通过预设算法从无偏数据集中筛选出部分样本的输入特征，该预设算法可以是深度全局平衡回归算法（deep global balancing regression, DGBR）算法；根据该部分样本的输入特征对第二神经网络进行训练，得到更新后的第二神经网络；将更新后的第二神经网络作为老师模型，第一神经网络作为学生模型，使用有偏数据集对第一神经网络进行知识蒸馏，得到更新后的第一神经网络。
30

因此，在本申请实施方式中，可以通过计算无偏数据集的稳定特征，并使用该稳定特征训练第二神经网络，得到输出结果偏置程度更低、鲁棒性更优的更新后的第二神经网络，并使用更新后的第二神经网络作为老师模型，第一神经网络作为学生模型，使用有偏数据集对第一神经网络进行知识蒸馏，从而得到输出偏置程度更低的更新后的第一神经网络。
35

在一种可能的实施方式中，样本集的数据特征包括该特征维度数量，上述的根据样本

集的数据特征确定第一蒸馏方式，可以包括：从多种蒸馏方式中选择与特征维度数量匹配的第一蒸馏方式。

因此，在本申请实施方式中，可以根据无偏数据集以及有偏数据集中所包括的特征维度数量，来选择基于特征蒸馏的方式，可以适应特征维度数量更大的场景，得到输出偏置程度更低的学生模型。

在一种可能的实施方式中，基于有偏数据集和无偏数据集，按照第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，可以包括：通过无偏数据集更新第二神经网络，得到更新后的第二神经网络；将更新后的第二神经网络作为老师模型，第一神经网络作为学生模型，使用有偏数据集对第一神经网络进行知识蒸馏，得到更新后的第一神经网络。

因此，在本申请实施方式中，可以使用常规的神经网络知识蒸馏过程，使用无偏数据集来训练老师模型，降低了老师模型的输出偏置程度，并通过该老师模型，使用有偏数据库对学生模型进行知识蒸馏，从而降低学生模型的输出偏置程度。

在一种可能的实施方式中，上述的样本集的数据特征确定第一蒸馏方式，可以包括：样本集的数据特征包括第二比例，计算无偏数据集中包括的正样本的数量和负样本的数量的第二比例，从多种蒸馏方式中选择与第二比例匹配的第一蒸馏方式；或者，样本集的数据特征包括第三比例，计算有偏数据集中包括的正样本的数量和负样本的数量的第三比例，从多种蒸馏方式中选择与第三比例匹配的第一蒸馏方式。

因此，在本申请实施方式中，可以通过无偏数据集或者有偏数据集中的正负样本比例来选择常规的基于模型结构的蒸馏方式，从而适应于无偏数据集或者有偏数据集中的正负样本比例的场景。

在一种可能的实施方式中，有偏数据集包括的样本的类型，和无偏数据集包括的样本的类型不相同。

因此，在本申请实施方式中，有偏数据集包括的样本的类型和无偏数据集包括的样本的类型不相同，可以理解为有偏数据集包括的样本和无偏数据集包括的样本属于不同领域的的数据，从而可以使用不同领域的的数据来进行指导和训练，使得到的更新后的第一神经网络可以输出与输入数据不同领域的的数据，如在推荐场景中，可以实现跨领域的推荐。

在一种可能的实施方式中，在得到更新后的第一神经网络之后，上述方法可以还包括：获取目标用户的至少一个样本；将至少一个样本作为更新后的第一神经网络的输入，输出目标用户的至少一个标签，至少一个标签用于构建目标用户的用户画像，用户画像用于确定与目标用户匹配的样本。

因此，在本申请实施方式中，可以通过更新后的第一神经网络，输出用户的一个或者多个标签，根据该一个或者多个标签来确定用户的代表特征，从而构建目标用户的用户画像，该用户画像用于描述目标用户，从而在后续的推荐场景中，可以通过该用户画像确定与目标用户匹配的样本。

第二方面，本申请提供一种推荐方法，包括：

获取目标用户的信息和候选推荐对象的信息；将目标用户的信息和候选推荐对象的信息

-5-

息输入至推荐模型，预测目标用户对候选推荐对象有操作动作的概率；其中，推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络进行训练得到，有偏数据集中包括有偏置的样本，无偏数据集中包括无偏置的样本，第一蒸馏方式是根据样本集的数据特征确定的，有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第一用户是否对第一推荐对象有操作动作，无偏数据集中的样本包括第二用户的信息和第二推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第二用户是否对第二推荐对象有操作动作。

其中，可以推荐模型是使用无偏数据训练得到的老师模型，对有偏数据训练得到的学生模型进行指导得到的，从而可以使用输出偏置程度低的推荐模型，来为用户推荐匹配的推荐对象，使推荐结果更准确，提高用户体验。

在一种可能的实施方式中，无偏数据集是在候选推荐对象集合中的候选推荐对象被展示的概率相同的情况下获得的，第二推荐对象为候选推荐对象集合中的一个候选推荐对象。

在一种可能的实施方式中，无偏数据集是在候选推荐对象集合中的候选推荐对象被展示的概率相同的情况下获得的，包括：无偏数据集中的样本是在候选推荐对象集合中的候选推荐对象被随机展示给第二用户的情况下获得的；或者无偏数据集中的样本是在第二用户搜索第二推荐对象的情况下获得的。

在一种可能的实施方式中，无偏数据集中的样本属于源域的数据，有偏数据集中的样本属于目标域的数据。

第三方面，本申请提供一种推荐方法，其特征不在于，包括：显示第一界面，第一界面包括至少一个应用程序的学习列表，该至少一个应用程序的学习列表中的第一应用程序的学习列表包括至少一个选项，至少一个选项中的选项关联一个应用程序；感知到用户在第一界面上的第一操作；响应于第一操作，打开或关闭第一应用程序在第一应用程序的学习列表中部分或全部选项所关联的应用程序中的跨域推荐功能。

根据本申请实施例中的方案，通过在不同域间进行知识（例如，用户的兴趣偏好）进行迁移和共享，将源域和目标域的用户交互历史记录都纳入到学习中，以使推荐模型能够更好地学习用户的偏好，使推荐模型在目标域也能很好的拟合用户的兴趣偏好，给用户推荐符合其兴趣的推荐结果，实现跨域推荐，缓解冷启动问题。

在一种可能的实施方式中，一个或多个推荐对象是通过将用户的信息和候选推荐对象的信息输入推荐模型中，预测用户对候选推荐对象有操作动作的概率确定的。

在一种可能的实施方式中，推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络进行训练得到，有偏数据集中包括有偏置的样本，无偏数据集中包括无偏置的样本，第一蒸馏方式是根据样本集的数据特征确定的，有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第一用户是否对第一推荐对象有操作动作，无偏数据集中的样本包括第二用户的信息和第二推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第二用户是否对第二推荐对象有操作动作。

第四方面，本申请提供一种神经网络蒸馏装置，该神经网络蒸馏装置具有实现上述第

—6—

一方面神经网络蒸馏方法的功能。该功能可以通过硬件实现，也可以通过硬件执行相应的软件实现。该硬件或软件包括一个或多个与上述功能相对应的模块。

第五方面，本申请提供一种推荐装置，该推荐装置具有实现上述第二方面推荐方法的功能。该功能可以通过硬件实现，也可以通过硬件执行相应的软件实现。该硬件或软件包
5 括一个或多个与上述功能相对应的模块。

第六方面，本申请提供一种电子设备，该电子设备具有实现上述第一方面推荐方法的功能。该功能可以通过硬件实现，也可以通过硬件执行相应的软件实现。该硬件或软件包括一个或多个与上述功能相对应的模块。

第七方面，本申请实施例提供一种神经网络蒸馏装置，包括：处理器和存储器，其中，
10 处理器和存储器通过线路互联，处理器调用存储器中的程序代码用于执行上述第一方面任一项所示的神经网络蒸馏方法中与处理相关的功能。

第八方面，本申请实施例提供一种推荐装置，包括：处理器和存储器，其中，处理器和存储器通过线路互联，处理器调用存储器中的程序代码用于执行上述第二方面任一项所示的推荐方法中与处理相关的功能。

第九方面，本申请实施例提供一种电子设备，包括：处理器和存储器，其中，处理器和存储器通过线路互联，处理器调用存储器中的程序代码用于执行上述第三方面任一项所示的推荐方法中与处理相关的功能。

第十方面，本申请实施例提供了一种神经网络蒸馏装置，该神经网络蒸馏装置也可以称为数字处理芯片或者芯片，芯片包括处理单元和通信接口，处理单元通过通信接口获取程序指令，程序指令被处理单元执行，处理单元用于执行如上述第一方面或第一方面任一
20 可选实施方式中与处理相关的功能。

第十一方面，本申请实施例提供了一种推荐装置，该推荐装置也可以称为数字处理芯片或者芯片，芯片包括处理单元和通信接口，处理单元通过通信接口获取程序指令，程序指令被处理单元执行，处理单元用于执行如上述第二方面或第二方面任一可选实施方式中
25 与处理相关的功能。

第十二方面，本申请实施例提供了一种电子设备，该电子设备也可以称为数字处理芯片或者芯片，芯片包括处理单元和通信接口，处理单元通过通信接口获取程序指令，程序指令被处理单元执行，处理单元用于执行如上述第三方面或第三方面任一可选实施方式中与处理相关的功能。

第十三方面，本申请实施例提供了一种计算机可读存储介质，包括指令，当其在计算机上运行时，使得计算机执行上述第一方面、第一方面任一可选实施方式、第二方面、第二方面任一可选实施方式、第三方面或第三方面任一可选实施方式中的方法。

第十四方面，本申请实施例提供了一种包含指令的计算机程序产品，当其在计算机上运行时，使得计算机执行上述第一方面、第一方面任一可选实施方式、第二方面、第二方面任一可选实施方式、第三方面或第三方面任一可选实施方式中的方法。
35

附图说明

图 1 为本申请应用的一种人工智能主体框架示意图；
图 2 为本申请提供的一种系统架构示意图；
图 3 为本申请实施例提供的一种卷积神经网络结构示意图；
图 4 为本申请实施例提供的另一种卷积神经网络结构示意图；
5 图 5 为本申请提供的另一种系统架构示意图；
图 6 为本申请提供的一种神经网络蒸馏方法的流程示意图；
图 7 为本申请提供的一种点击率和推荐位置的关系示意图；
图 8 为本申请提供的一种神经网络蒸馏架构的示意图；
图 9 为本申请提供的另一种神经网络蒸馏架构的示意图；
10 图 10 为本申请提供的另一种神经网络蒸馏架构的示意图；
图 11 为本申请提供的一种推荐方法的流程示意图；
图 12 为本申请提供的推荐方法的一种应用场景示意图；
图 13 为本申请提供的推荐方法的一种应用场景示意图；
图 14 为本申请提供的推荐方法的一种应用场景示意图；
15 图 15 为本申请提供的推荐方法的一种应用场景示意图；
图 16 为本申请提供的推荐方法的一种应用场景示意图；
图 17 为本申请提供的推荐方法的一种应用场景示意图；
图 18 为本申请提供的推荐方法的一种应用场景示意图；
图 19 为本申请提供的推荐方法的一种应用场景示意图；
20 图 20 为本申请提供的另一种推荐方法的流程示意图；
图 21 为本申请提供的一种神经网络蒸馏装置的结构示意图；
图 22 为本申请提供的一种推荐装置的结构示意图；
图 23 为本申请提供的一种电子设备的结构示意图；
图 24 为本申请提供的另一种神经网络蒸馏装置的结构示意图
25 图 25 为本申请提供的另一种推荐装置的结构示意图；
图 26 为本申请提供的另一种电子设备的结构示意图；
图 27 为本申请提供的一种芯片结构示意图。

具体实施方式

30 下面将结合本申请实施例中的附图，对本申请实施例中的技术方案进行描述，显然，所描述的实施例仅仅是本申请一部分实施例，而不是全部的实施例。基于本申请中的实施例，本领域技术人员在没有作出创造性劳动前提下所获得的所有其他实施例，都属于本申请保护的范围。

35 本申请提供的训练集处理方法可以应用于人工智能（artificial intelligence, AI）场景中。AI 是利用数字计算机或者数字计算机控制的机器模拟、延伸和扩展人的智能，感知环境、获取知识并使用知识获得最佳结果的理论、方法、技术及应用系统。换句话说，人工智能是计算机科学的一个分支，它企图了解智能的实质，并生产出一种新的能以人类

智能相似的方式作出反应的智能机器。人工智能也就是研究各种智能机器的设计原理与实现方法，使机器具有感知、推理与决策的功能。人工智能领域的研究包括机器人，自然语言处理，计算机视觉，决策与推理，人机交互，推荐与搜索，AI 基础理论等。

首先对人工智能系统总体工作流程进行描述，请参见图 1，图 1 示出的为人工智能主体框架的一种结构示意图，下面从“智能信息链”（水平轴）和“IT 价值链”（垂直轴）两个维度对上述人工智能主题框架进行阐述。其中，“智能信息链”反映从数据的获取到处理的一系列过程。举例来说，可以是智能信息感知、智能信息表示与形成、智能推理、智能决策、智能执行与输出的一般过程。在这个过程中，数据经历了“数据—信息—知识—智慧”的凝练过程。“IT 价值链”从人智能的底层基础设施、信息（提供和处理技术实现）到系统的产业生态过程，反映人工智能为信息技术产业带来的价值。

（1）基础设施

基础设施为人工智能系统提供计算能力支持，实现与外部世界的沟通，并通过基础平台实现支撑。通过传感器与外部沟通；计算能力由智能芯片（CPU、NPU、GPU、ASIC、FPGA 等硬件加速芯片）提供；基础平台包括分布式计算框架及网络等相关的平台保障和支持，可以包括云存储和计算、互联互通网络等。举例来说，传感器和外部沟通获取数据，这些数据提供给基础平台提供的分布式计算系统中的智能芯片进行计算。

（2）数据

基础设施的上一层的数据用于表示人工智能领域的数据来源。数据涉及到图形、图像、语音、文本，还涉及到传统设备的物联网数据，包括已有系统的业务数据以及力、位移、液位、温度、湿度等感知数据。

（3）数据处理

数据处理通常包括数据训练，机器学习，深度学习，搜索，推理，决策等方式。

其中，机器学习和深度学习可以对数据进行符号化和形式化的智能信息建模、抽取、预处理、训练等。

推理是指在计算机或智能系统中，模拟人类的智能推理方式，依据推理控制策略，利用形式化的信息进行机器思维和求解问题的过程，典型的功能是搜索与匹配。

决策是指智能信息经过推理后进行决策的过程，通常提供分类、排序、预测等功能。

（4）通用能力

对数据经过上面提到的数据处理后，进一步基于数据处理的结果可以形成一些通用的能力，比如可以是算法或者一个通用系统，例如，翻译，文本的分析，计算机视觉的处理，语音识别，图像的识别等等。

（5）智能产品及行业应用

智能产品及行业应用指人工智能系统在各领域的产品和应用，是对人工智能整体解决方案的封装，将智能信息决策产品化、实现落地应用，其应用领域主要包括：智能终端、智能交通、智能医疗、自动驾驶、平安城市等。

本申请实施例涉及了大量神经网络的相关应用，为了更好地理解本申请实施例的方案，下面先对本申请实施例可能涉及的神经网络的相关术语和概念进行介绍。

(1) 神经网络

神经网络可以是由神经单元组成的, 神经单元可以是指以 x_s 和截距 1 为输入的运算单元, 该运算单元的输出可以如公式 (1-1) 所示:

$$h_{w,b}(x) = f(W^T x) = f(\sum_{s=1}^n W_s x_s + b) \quad (1-1)$$

5 其中, $s=1, 2, \dots, n$, n 为大于 1 的自然数, W_s 为 x_s 的权重, b 为神经单元的偏置。 f 为神经单元的激活函数 (activation functions), 用于将非线性特性引入神经网络中, 来将神经单元中的输入信号转换为输出信号。该激活函数的输出信号可以作为下一层卷积层的输入, 激活函数可以是 sigmoid 函数。神经网络是将多个上述单一的神经单元联结在一起形成的网络, 即一个神经单元的输出可以是另一个神经单元的输入。每个神经单元的
10 输入可以与前一层的局部接受域相连, 来提取局部接受域的特征, 局部接受域可以是由若干个神经单元组成的区域。

(2) 深度神经网络

深度神经网络 (deep neural network, DNN), 也称多层神经网络, 可以理解为具有多层中间层的神经网络。按照不同层的位置对 DNN 进行划分, DNN 内部的神经网络可以分为三类: 输入层, 中间层, 输出层。一般来说第一层是输入层, 最后一层是输出层, 中间
15 的层数都是中间层。层与层之间是全连接的, 也就是说, 第 i 层的任意一个神经元一定与第 $i+1$ 层的任意一个神经元相连。

(3) 卷积神经网络

卷积神经网络 (convolutional neuron network, CNN) 是一种带有卷积结构的深度神经网络。卷积神经网络包含了一个由卷积层和子采样层构成的特征抽取器, 该特征抽取器
20 可以看作是滤波器。卷积层是指卷积神经网络中对输入信号进行卷积处理的神经元层。在卷积神经网络的卷积层中, 一个神经元可以只与部分邻层神经元连接。一个卷积层中, 通常包含若干个特征平面, 每个特征平面可以由一些矩形排列的神经单元组成。同一特征平面的神经单元共享权重, 这里共享的权重就是卷积核。共享权重可以理解为提取图像信息的方式与位置无关。卷积核可以以随机大小的矩阵的形式初始化, 在卷积神经网络的训练
25 过程中卷积核可以通过学习得到合理的权重。另外, 共享权重带来的直接好处是减少卷积神经网络各层之间的连接, 同时又降低了过拟合的风险。示例性地, 卷积神经网络的结构可以参阅图 3 以及图 4 所示的结构。

(4) 循环神经网络 (recurrent neural networks, RNN) 是用来处理序列数据的。在传统的神经网络模型中, 是从输入层到中间层再到输出层, 层与层之间是全连接的, 而对于
30 每一层层内之间的各个节点是无连接的。这种普通的神经网络虽然解决了很多难题, 但是却仍然对很多问题无能为力。例如, 你要预测句子的下一个单词是什么, 一般需要用到前面的单词, 因为一个句子中前后单词并不是独立的。RNN之所以称为循环神经网络, 即一个序列当前的输出与前面的输出也有关。具体的表现形式为网络会对前面的信息进行记忆
35 并应用于当前输出的计算中, 即中间层本层之间的节点不再无连接而是有连接的, 并且中间层的输入不仅包括输入层的输出还包括上一时刻中间层的输出。理论上, RNN能够对任

何长度的序列数据进行处理。对于RNN的训练和对传统的CNN或DNN的训练一样。

(5) 加法神经网络 (Adder Neural Network, ANN)

加法神经网络是一种几乎不包含乘法的神经网络。不同于卷积神经网络，加法神经网络使用 L1 距离来度量神经网络中特征和滤波器之间的相关性。由于 L1 距离中只包含加法和减法，神经网络中大量的乘法运算可以被替换为加法和减法，从而大大减少了神经网络的计算代价。

在 ANN 中，通常使用一种只具有加法的度量函数，即 L1 距离，来代替卷积神经网络中的卷积计算。通过使用 L1 距离，输出的特征可以被重新计算为：

$$Y(m,n,t) = \sum_{i=0}^{d-1} \sum_{j=0}^{d-1} \sum_{k=1}^C |X(m+i,n+j,k) + F(i,j,k,t)| \quad (1)$$

$$\text{或, } Y(m,n,t) = \sum_{i=0}^{d-1} \sum_{j=0}^{d-1} \sum_{k=1}^C -|X(m+i,n+j,k) + F(i,j,k,t)| \quad (2)$$

其中， $|\cdot|$ 为取绝对值运算， $\sum(\cdot)$ 为求和运算， $Y(m,n,t)$ 为所述至少一个输出子特征图， $Y(m,n,t)$ 为所述输出特征图中第 m 行、第 n 列及第 t 页的元素， $X(m+i,n+j,k)$ 为所述至少一个输入子特征图中的第 i 行、第 j 列及第 k 页的元素， $F(i,j,k,t)$ 为所述特征提取核中的第 i 行、第 j 列及第 k 页的元素， t 为所述特征提取核的通道数， d 为所述特征提取核的行数， C 为所述输入特征图的通道数， d 、 C 、 i 、 j 、 k 、 m 、 n 、 t 均为整数。

可以看到，ANN 只需要使用加法，通过将卷积中计算特征的度量方式改为 L1 距离，可以只使用加法来提取神经网络中的特征，并构建加法神经网络。

(5) 损失函数

在训练深度神经网络的过程中，因为希望深度神经网络的输出尽可能的接近真正想要预测的值，所以可以通过比较当前网络的预测值和真正想要的目标值，再根据两者之间的差异情况来更新每一层神经网络的权重向量（当然，在第一次更新之前通常会有初始化的过程，即为深度神经网络中的各层预先配置参数），比如，如果网络的预测值高了，就调整权重向量让它预测低一些，不断地调整，直到深度神经网络能够预测出真正想要的目标值或与真正想要的目标值非常接近的值。因此，就需要预先定义“如何比较预测值和目标值之间的差异”，这便是损失函数（loss function）或目标函数（objective function），它们是用以衡量预测值和目标值的差异的重要方程。其中，以损失函数举例，损失函数的输出值(loss)越高表示差异越大，那么深度神经网络的训练就变成了尽可能缩小这个 loss 的过程。在本申请实施方式中，目标函数与损失函数的区别在于，目标函数中除了包括损失函数，还可能包括约束函数，用于对神经网络的更新进行约束，使更新得到的神经网络更接近期望的神经网络。

(6) 反向传播算法

神经网络可以采用误差反向传播（back propagation, BP）算法在训练过程中修正初始的神经网络模型中参数的大小，使得神经网络模型的重建误差损失越来越小。具体地，前向传递输入信号直至输出会产生误差损失，通过反向传播误差损失信息来更新初始的神经

网络模型中参数，从而使误差损失收敛。反向传播算法是以误差损失为主导的反向传播运动，旨在得到最优的神经网络模型的参数，例如权重矩阵。

参见附图 2，本申请实施例提供了一种系统架构 200。该系统架构中包括数据库 230、客户设备 240。数据采集设备 260 用于采集数据并存入数据库 230，训练模块 202 基于数据库 230 中维护的数据生成目标模型/规则 201。下面将更详细地描述训练模块 202 如何基于数据得到目标模型/规则 201，目标模型/规则 201 即本申请以下实施方式中构建得到的神经网络，具体参阅以下图 6-图 20 中的相关描述。

计算模块可以包括训练模块 202，训练模块 202 得到的目标模型/规则可以应用不同的系统或设备中。在附图 2 中，执行设备 210 配置收发器 212，该收发器 212 可以是无线收发器、光收发器或有线接口（如 I/O 接口）等，与外部设备进行数据交互，“用户”可以通过客户设备 240 向收发器 212 输入数据，例如，本申请以下实施方式，客户设备 240 可以向执行设备 210 发送目标任务，请求执行设备构建神经网络，并向执行设备 210 发送用于训练的数据库。

执行设备 210 可以调用数据存储系统 250 中的数据、代码等，也可以将数据、指令等存入数据存储系统 250 中。

计算模块 211 使用目标模型/规则 201 对输入的数据进行处理。具体地，计算模块 211 用于：获取有偏数据集和无偏数据集，有偏数据集中包括有偏置的样本，无偏数据集中包括无偏置的样本，有偏数据集的数据量大于无偏数据集的数据量；根据有偏数据集所包括的数据或无偏数据集所包括的数据中的至少一种，从预设的多种蒸馏方式中选择第一蒸馏方式，多种蒸馏方式在进行知识蒸馏时老师模型对学生模型的指导方式不相同，且使用无偏数据集训练得到的模型指导使用有偏数据集训练得到的模型；基于有偏数据集和无偏数据集，按照第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络。

最后，收发器 212 将构建得到的神经网络返回给客户设备 240，以在客户设备 240 或者其他设备中部署该神经网络。

更深层地，训练模块 202 可以针对不同的任务，基于不同的数据得到相应的目标模型/规则 201，以给用户提供更佳的结果。

在附图 2 中所示情况下，可以根据用户的输入数据确定输入执行设备 210 中的数据，例如，用户可以在收发器 212 提供的界面中操作。另一种情况下，客户设备 240 可以自动地向收发器 212 输入数据并获得结果，若客户设备 240 自动输入数据需要获得用户的授权，用户可以在客户设备 240 中设置相应权限。用户可以在客户设备 240 查看执行设备 210 输出的结果，具体的呈现形式可以是显示、声音、动作等具体方式。客户设备 240 也可以作为数据采集端将采集到与目标任务关联的数据存入数据库 230。

需要说明的是，附图 2 仅是本申请实施例提供的一种系统架构的示例性的示意图，图 35 中所示设备、器件、模块等之间的位置关系不构成任何限制。例如，在附图 2 中，数据存储系统 250 相对执行设备 210 是外部存储器，在其它场景中，也可以将数据存储系统 250 置于执行设备 210 中。

在本申请所提及的训练或者更新过程可以由训练模块 202 来执行。可以理解的是，神

神经网络的训练过程即学习控制空间变换的方式，更具体即学习权重矩阵。训练神经网络的目的是使神经网络的输出尽可能接近期望值，因此可以通过比较当前网络的预测值和期望值，再根据两者之间的差异情况来更新神经网络中的每一层神经网络的权重向量（当然，在第一次更新之前通常可以先对权重向量进行初始化，即为深度神经网络中的各层预先配置参数）。例如，如果网络的预测值过高，则调整权重矩阵中的权重的值从而降低预测值，经过不断的调整，直到神经网络输出的值接近期望值或者等于期望值。具体地，可以通过损失函数（loss function）或目标函数（objective function）来衡量神经网络的预测值和期望值之间的差异。以损失函数举例，损失函数的输出值（loss）越高表示差异越大，神经网络的训练可以理解为尽可能缩小 loss 的过程。本申请以下实施方式中更新起点网络的权重以及对串行网络进行训练的过程可以参阅此过程，以下不再赘述。

如图 2 所示，根据训练模块 202 训练得到目标模型/规则 201，该目标模型/规则 201 在本申请实施例中可以是本申请中的第一神经网络，具体的，本申请实施例提供的第一神经网络、第二神经网络、老师模型或者学生模型等，可以是深度卷积神经网络（deep convolutional neural networks, DCNN）、循环神经网络（recurrent neural network, RNNs）等等。本申请提及的神经网络可以包括多种类型，如深度神经网络（deep neural network, DNN）、卷积神经网络（convolutional neural network, CNN）、循环神经网络（recurrent neural networks, RNN）或残差网络其他神经网络等。

参见附图 5，本申请实施例还提供了一种系统架构 500。执行设备 210 由一个或多个服务器实现，可选的，与其它计算设备配合，例如：数据存储、路由器、负载均衡器等设备；执行设备 210 可以布置在一个物理站点上，或者分布在多个物理站点上。执行设备 210 可以使用数据存储系统 250 中的数据，或者调用数据存储系统 250 中的程序代码实现本申请以下图 6 对应的训练集处理方法的步骤。

用户可以操作各自的用户设备（例如本地设备 501 和本地设备 502）与执行设备 210 进行交互。每个本地设备可以表示任何计算设备，例如个人计算机、计算机工作站、智能手机、平板电脑、智能摄像头、智能汽车或其他类型蜂窝电话、媒体消费设备、可穿戴设备、机顶盒、游戏机等。

每个用户的本地设备可以通过任何通信机制/通信标准的通信网络与执行设备 210 进行交互，通信网络可以是广域网、局域网、点对点连接等方式，或它们的任意组合。具体地，该通信网络可以包括无线网络、有线网络或者无线网络与有线网络的组合等。该无线网络包括但不限于：第五代移动通信技术（5th-Generation, 5G）系统，长期演进（long term evolution, LTE）系统、全球移动通信系统（global system for mobile communication, GSM）或码分多址（code division multiple access, CDMA）网络、宽带码分多址（wideband code division multiple access, WCDMA）网络、无线保真（wireless fidelity, WiFi）、蓝牙（bluetooth）、紫蜂协议（Zigbee）、射频识别技术（radio frequency identification, RFID）、远程（Long Range, Lora）无线通信、近距离无线通信（near field communication, NFC）中的任意一种或多种的组合。该有线网络可以包括光纤通信网络或同轴电缆组成的网络等。

在另一种实现中, 执行设备 210 的一个方面或多个方面可以由每个本地设备实现, 例如, 本地设备 501 可以为执行设备 210 提供本地数据或反馈计算结果。

本申请实施例提供的数据处理方法可以在服务器上被执行, 还可以在终端设备上被执行。其中该终端设备可以是具有图像处理功能的移动电话、平板个人电脑 (tablet personal computer, TPC)、媒体播放器、智能电视、笔记本电脑 (laptop computer, LC)、个人数字助理 (personal digital assistant, PDA)、个人计算机 (personal computer, PC)、照相机、摄像机、智能手表、可穿戴式设备 (wearable device, WD) 或者自动驾驶的车辆等, 本申请实施例对此不作限定。

通常, 知识蒸馏可以将一个网络的知识转移到另一个网络, 两个网络可以是同构或者异构。做法是先训练一个 teacher 网络, 或者称为老师模型, 然后使用这个 teacher 网络的输出训练 student 网络, 或者称为学生模型。在进行知识蒸馏时, 可以通过采用预先训练好的复杂网络去训练另外一个简单的网络, 以使得简单的网络可以具有和复杂网络相同或相似的数据处理能力。

知识蒸馏可以快速方便地实现一些小型的网络, 例如, 可以在云服务器或企业级服务器训练大量数据的复杂网络模型, 然后进行知识蒸馏得到实现了相同功能的小型模型, 并将该小型模型压缩并迁移到小型设备 (如手机、智能手环等) 上。又例如, 通过收集大量用户在智能手环上的数据, 在云服务器上进行复杂并耗时的网络训练, 得到用户行为识别模型, 再把该模型压缩并迁移到智能手环这一小型载体, 可以在保证保护用户隐私的同时, 快速训练模型, 并提升用户体验。

然而, 在使用老师模型对学生模型进行指导时, 通常学生模型的输出精度受到老师模型的输出精度的限制, 导致学生模型的输出精度无法更大空间的提升。并且, 在进行知识蒸馏时, 通常使用的是存在偏置的数据集, 从而使训练得到的学生模型的输出存在偏置, 即输出结果不准确。

因此, 本申请提供一种神经网络蒸馏方法, 用于针对训练所使用的数据集选择合适的指导方式, 完成神经网络的知识蒸馏, 并且, 使用无偏数据集所训练的模型对有偏数据集训练得到的模型进行指导, 降低学生模型的输出偏置程度, 提高学生模型的输出准确度。

本申请提供的神经网络蒸馏方法, 可以应用于推荐系统、用户画像、图像识别或者其他去偏置场景等。该推荐系统可以用于为用户推荐应用程序 (Application, App)、音乐、图像、视频或商品等。该用户画像用于反映用户的特征或者喜好等。

下面对本申请提供神经网络蒸馏方法进行详细介绍。参阅图 6, 本申请提供的一种神经网络蒸馏方法的流程示意图。

601、获取样本集, 样本集中包括有偏数据集和无偏数据集。

其中, 样本集至少包括有偏数据集和无偏数据集, 有偏数据集中包括了存在偏置的样本 (以下称为有偏样本), 无偏数据集中包括了无偏置的样本 (以下称为无偏样本), 且通常有偏数据集的数据量大于无偏数据集的数据量。

为便于理解, 存在偏置的样本可以理解为与用户的实际使用样本存在偏差的样本。例如, 推荐系统作为反馈循环 (feedback loop) 系统, 通常会面临着各种偏置问题, 如位置

偏置，流行偏置和前序模型偏置，这些偏置的存在使得推荐系统收集到的用户反馈数据并不能反映用户的真实偏好。

而样本的偏置在不同的场景中也可能不相同，如位置偏置、选择偏置或者流行偏置等。例如，以为用户推荐物品的场景为例，位置偏置可以理解为：描述用户时，倾向性地选择处于更好位置的物品进行交互，这种倾向性与物品是否满足用户的实际需求无关。选择偏置可以理解为：发生于“被研究群体”不能够代表“目标群体”，以至于对“被研究群体”的风险或者收益的衡量不能够准确地表征“目标群体”，导致所获结论不能够被有效地泛化。

示例性地，以为用户推荐 APP 的场景为例，图 7 表示在随机投放策略下，同一个 APP 在各个推荐位置的点击率，可以看出，随着推荐位置的靠后，该 APP 的点击率越低，说明了位置偏置对于点击率的影响。位置偏置导致推荐位置更靠前的 APP 的点击率更高，而推荐位置更靠后的 APP 的点击率更低，若使用这样的点击数据训练模型，则会加剧训练得到的模型的马太效应，导致模型的输出结果两极分化。例如，若用户在推荐系统中搜索 APP，若符合用户需求的 APP 包括了 APP1 和 APP2，且 APP2 更符合用户的搜索需求。但因 APP1 的点击率较高，因此 APP1 的推荐位置更优，导致用户点击了 APP1，而未点击 APP2，后续在为用户推荐 APP 时，结合了用户点击 APP1 的历史数据（即有偏样本）来进行推荐，而用户的实际需求应该与 APP2（即无偏样本）相关关联，则可能导致对用户的推荐不准确。

无偏数据可以通过随机流量（uniform data）的方式采集。以推荐系统为例。采集无偏数据集的具体过程可以包括：从所有的候选集中进行随机采样，然后将随机采样得到的样本进行随机展示，然后收集针对该随机展示的样本的反馈数据，并从反馈数据中获取到无偏样本。可以理解为候选集中的所有样本均有机会均等地展示给用户进行选择，因此它可以被视为一个好的无偏代理。

602、根据样本集的数据特征确定第一蒸馏方式。

其中，可以根据样本集所包括的数据特征，确定第一蒸馏方式。具体地，在得到有偏数据集和无偏数据集之后，基于有偏数据集和/或无偏数据集，从预设的多种蒸馏方式中选择匹配的蒸馏方式，得到第一蒸馏方式。

通常，第一蒸馏方式是从预设的多种蒸馏方式中选择得到，多种蒸馏方式中包括老师模型对学生模型的指导方式不相同的至少两种蒸馏方式。通常，无偏数据集用于训练老师模型，有偏数据集用于训练学生模型，即使用无偏数据集训练得到的模型来指导使用有偏数据集得到的模型。

可选地，该预设的多种蒸馏方式可以包括但不限于以下一种或者多种：样本蒸馏、标签蒸馏、特征蒸馏或模型结构蒸馏等。

其中，样本蒸馏是指使用有偏数据集和无偏数据集中的样本来进行蒸馏。如使用无偏数据集中的样本来指导对学生模型的知识蒸馏。

35 标签蒸馏是指使用基于无偏数据集中的样本的预测标签作为指导对学生模型进行蒸馏，该预测标签由老师模型输出，该老师模型是基于无偏数据集进行训练得到。

特征蒸馏是指基于从无偏数据集中提取到的特征训练老师模型，并通过老师模型以及

有偏数据集进行知识蒸馏。

模型结构蒸馏,即使用无偏数据集训练得到老师模型,使用老师模型以及有偏数据集,对学生模型进行知识蒸馏,得到更新后的学生模型。

具体地,针对前述的多种蒸馏方式的更详细的介绍可以参阅以下图 8 的介绍,此处不再赘述。

在一些可能的实施方式中,可以基于无偏数据集的样本量和有偏数据集的样本量、无偏数据集中正样本和负样本之间的比例、有偏数据集中正样本和负样本之间的比例、或者无偏数据集和有偏数据集的所包括的数据的特征维度数量等来选择匹配的蒸馏方式作为第一蒸馏方式。例如,样本集中的样本的输入特征的数据类型可能不相同,例如,每一个类型的数据类型即可理解为一个维度,特征维度数量即样本集中所包括的数据类型的种类。

示例性地,选择蒸馏方式的方式可以包括但不限于:

条件 1: 计算无偏数据集的样本和有偏数据集的样本量之间的第一比例,当该第一比例小于第一阈值时,选择样本蒸馏作为第一蒸馏方式。

条件 2: 当第一比例不小于第一阈值时,选择标签蒸馏作为第一蒸馏方式。

条件 3: 计算无偏数据集中包括的正样本的数量和负样本的数量的第二比例,当该第二比例大于第二阈值时,选择模型结构蒸馏作为第一蒸馏方式;或者,计算有偏数据集中包括的正样本的数量和负样本的数量的第三比例,当该第三比例大于第三阈值时,选择模型结构蒸馏作为第一蒸馏方式。

条件 4: 计算有偏无偏数据集以及有偏数据集中所包括的特征维度数量,当该特征维度数量大于预设维度时,选择特征蒸馏作为第一蒸馏方式。

其中,可以预先设定每种蒸馏方式的优先级,当上述的多种条件同时满足时,可以按照优先级选择合适的蒸馏方式。例如,特征蒸馏的优先级>模型结构蒸馏的优先级>样本蒸馏的优先级=标签蒸馏的优先级,当无偏数据集和无偏数据集同时满足条件 3 和条件 4 时,则选择特征蒸馏作为第一蒸馏方式。

当然,每种蒸馏方式的优先级在不同的场景中可以不同,此处仅仅是示例性说明,不作为限定。

还需要说明的是,本申请所指的老师模型和学生模型,可以是结构不相同的模型,也可以是针对相同结构的模型,使用不同的数据集得到的模型,具体可以根据实际应用场景进行调整,本申请对此并不作限定。

603、基于有偏数据集和所述无偏数据集,按照第一蒸馏方式对第一神经网络进行训练,得到更新后的第一神经网络。

在选择第一蒸馏方式之后,即可按照该第一蒸馏方式所包括的指导方式,对第一神经网络进行知识蒸馏,得到更新后的第一神经网络。

为便于理解,以一种场景为例,通过 Uniform data 采集到的无偏数据集不受到前序模型的影响,并且符合期望的模型的样本属性,即所有候选集机会均等地展示给用户进行选择。因此无偏数据集可以被视为一个好的无偏代理。但由于无偏数据集的样本量少,无法直接用于训练线上模型。且通过无偏数据集训练的模型更无偏,但方差较大,而有偏数据

训练的模型有偏置，但方差相对较小，因此，本申请实施方式中，有效结合了无偏数据集和有偏数据集进行训练，使无偏数据集对有偏数据集的训练形成指导，从而使最终得到的第一神经网络的输出结果的偏置程度更低，提高第一神经网络的输出结果的准确度。

具体地，下面以几种蒸馏方式为例，对步骤 603 进行详细说明。

5 一、当第一蒸馏方式为样本蒸馏。

其中，基于数据集中的样本蒸馏的方式可以有多种，有偏数据集和无偏数据集中的样本包括输入特征和实际标签，可以将无偏数据集中的样本的输入特征作为老师模型的输入，训练老师模型，将有偏数据集中样本的输入特征作为学生模型的输入，学生模型即第一神经网络，从而完成对第一神经网络的知识蒸馏，得到更新后的第一神经网络。

10 在一种可能的实施方式中，进行知识蒸馏的具体过程可以包括：交替使用有偏数据集和无偏数据集对第一神经网络进行训练，得到更新后的第一神经网络，其中，在一个交替过程中，使用有偏数据集对第一神经网络进行训练的批训练次数，和使用无偏数据集对第一神经网络进行训练的批训练次数为预设比例，且在训练第一神经网络时，样本的输入特征作为第一神经网络的输入。

15 因此，在本申请实施方式中，可以通过交替使用有偏数据集和无偏数据集对第一神经网络进行训练，在通过无偏数据集进行训练时，可以纠正使用有偏数据集进行训练时产生的偏置，使最终得到的第一神经网络的输出结果的偏置程度更低，输出结果更准确。

20 在一种可能的实施方式中，当预设比例为 1 时，在第一神经网络的损失函数中增加第一正则项和第二正则项的差值，第一正则项是使用无偏数据集包括的样本对第一神经网络进行训练得到的参数，第二正则项是使用有偏数据集包括的样本对第一神经网络进行训练得到的参数。

因此，在本申请实施方式中，

25 在一种可能的实施方式中，进行知识蒸馏的具体过程可以包括：为有偏数据集中的全部或者部分样本设置置信度，该置信度用于表示样本的偏置程度；基于有偏数据集、有偏数据集中的样本的置信度和无偏数据集，对第一神经网络进行训练，得到更新后的第一神经网络，且在对第一神经网络进行训练时样本包括输入特征作为第一神经网络的输入。

二、当第一蒸馏方式为标签蒸馏。

30 其中，可以使用无偏数据集对第二神经网络进行训练，然后通过训练后的第二神经网络输出有偏数据集中的样本的预测标签，然后使用该预测标签作为约束，对第一神经网络进行训练，得到更新后的第一神经网络。

35 在一种可能的实施方式中，前述的样本集中还包括未观测数据集，未观测数据集中包括多个未观测样本，进行知识蒸馏的具体过程可以包括：通过有偏数据集对第一神经网络进行训练，得到训练后的第一神经网络，以及通过无偏数据集对第二神经网络进行训练，得到更新后的第二神经网络；从全量数据集中采集多个样本，得到辅助数据集；使用辅助数据集，以辅助数据集中样本的预测标签作为约束，更新训练后的第一神经网络，得到更新后的第一神经网络。通常，辅助数据集中样本具有至少两个预测标签，且该至少两个预测标签由更新后的第一神经网络和第二神经网络分别输出。

因此，本申请实施方式中，可以通过引入未观测数据集的方式，通过未观测数据集所包括的样本来降低偏置数据集在对第一神经网络训练时的偏置影响，降低更新后的第一神经网络的输出结果的偏置程度。

5 在一种可能的实施方式中，进行知识蒸馏的具体过程可以包括：通过无偏数据集对第二神经网络进行训练，得到更新后的第二神经网络；通过更新后的第二神经网络输出有偏数据集中样本的预测标签；将样本的预测标签和样本的实际标签进行加权合并，得到样本的合并标签；使用样本的合并标签训练第一神经网络，得到更新后的第一神经网络。

10 因此，本申请实施方式中，可以使用第二神经网络输出的有偏数据集中的样本的预测标签与样本的实际标签进行合并后的标签对第一神经网络进行更新，可以理解为老师模型使用预测标签的方式对第一神经网络的更新进行了指导，从而降低更新后的第一神经网络的输出结果的偏置程度，提高更新后的第一神经网络的输出结果的准确度。

三、当第一蒸馏方式为特征蒸馏。

15 其中，可以从无偏数据集中提取稳定特征，然后基于该稳定特征训练第二神经网络，得到更新后的第二神经网络。然后使用有偏数据集对第一神经网络进行训练，并将更新后的第二神经网络作为老师模型，将第一神经网络作为学生模型，进行知识蒸馏，得到更新后的第一神经网络。

20 在一种可能的实施方式中，进行知识蒸馏的具体过程可以包括：通过预设算法输出无偏数据集的部分样本的输入特征，该部分样本的输入特征可以理解为无偏数据集集中的稳定特征，该预设算法可以是 DGBR 算法；根据该部分样本的输入特征对第二神经网络进行训练，得到更新后的第二神经网络；将更新后的第二神经网络作为老师模型，第一神经网络作为学生模型，使用有偏数据集对第一神经网络进行知识蒸馏，得到更新后的第一神经网络。

25 因此，在本申请实施方式中，可以使用无偏数据集集中的稳定特征来训练第二神经网络，得到更新后的第二神经网络，即老师模型，因此，老师模型的输出更稳定，准确度更高。在此基础上，使用该老师模型进行知识蒸馏，得到的学生模型的输出也更稳定，准确度更高。

四、当第一蒸馏方式为模型结构蒸馏。

30 其中，可以使用无偏数据集对第二神经网络进行训练，得到更新后的第二神经网络。然后将更新后的神经网络作为老师模型，第一神经网络作为学生模型，使用有偏数据集，以及老师模型的中间层的输出结果，对第一神经网络进行知识蒸馏，得到更新后的神经网络。

因此，在本实施方式中，可以使用偏数据集所包括的无偏样本，对第一神经网络的知识蒸馏过程进行指导，从而使更新后的神经网络可以输出无偏置的结果，实现对输入样本的纠偏，提高第一神经网络的输出准确率。

35 因此，在本申请中，可以使用无偏数据集所包括的无偏样本，对第一神经网络的知识蒸馏过程进行指导，从而使更新后的神经网络可以输出无偏置的结果，实现对输入样本的纠偏，提高第一神经网络的输出准确率。此外，本申请提供的神经网络蒸馏方法中，可以

选择与无偏数据集和有偏数据集匹配的蒸馏方式，针对不同的场景可以使用不同的蒸馏方式，适应不同的场景，提高了对神经网络进行知识蒸馏的泛化能力。在不同条件下选择不同的知识蒸馏方式，根据数据集的大小、正负例比、不同数据的占比等条件进行适配，最大化知识蒸馏的效益。

5 在一种可能的实施方式中，无偏数据集中的样本的类型和有偏数据集中的样本的类型不相同。例如，无偏数据集所包括的样本类型为音乐，有偏数据集所包括的样本的类型为视频。因此，本申请实施方式中，可以使用不同领域的数据进行知识蒸馏，实现跨领域的神经网络的训练，从而可以实现跨领域的用户推荐，提高用户体验。

10 在一种可能的实施方式中，在得到更新后的第一神经网络之后，可以获取目标用户的至少一个样本，将该至少一个样本作为该更新后的第一神经网络的输入，输出目标用户的至少一个标签，使用该至少一个标签构建目标用户的用户画像，该用户画像用于描述该目标用户，或者为用户推荐匹配的样本。例如，可以获取用户 A 点击过的 APP，将用户点击过的 APP 作为更新后的第一神经网络的输入，输出用户 A 的一个或者多个标签，该一个或者多个标签可以用于表示用户点击对应的 APP 的概率，当该概率超过预设概率时，即可使用对应的 APP 的特征作为用户 A 的特征，从而构建用户 A 的用户画像，该用户画像所包括的特征用于描述用户，或者为用户推荐匹配的 APP 等。

15 本申请实施方式中，可以使用更新后的第一神经网络，生成用户画像，从而通过该用户画像来描述用户，或者为用户推荐匹配的样本。因该更新后的神经网络是进行了纠偏后的神经网络，可以降低输出结果的偏置，从而使得到的用户画像更准确，提高用户的推荐体验。

20 前述对本申请提供的神经网络蒸馏方法的流程进行了介绍，下面结合更具体的应用场景，对本申请提供的神经网络蒸馏方法进行更详细的介绍。

首先，获取有偏数据集 801 和无偏数据集 802。

25 预先设定的蒸馏方式可以包括样本蒸馏 803、标签蒸馏 804、特征蒸馏 805 和模型结构蒸馏 806。

结合有偏数据集 801 和无偏数据集 802 从样本蒸馏 803、标签蒸馏 804、特征蒸馏 805 和模型结构蒸馏 806 中选择匹配的蒸馏方式，然后进行知识蒸馏 807，得到更新后的第一神经网络。

下面对本申请实施例中所涉及的数据和步骤进行详细介绍。

30 具体地，有偏数据集 801 可以包括构建或者采集到的样本。例如，该有偏数据集 801 可以是用户点击或者下载过的 APP；用户点击或者播放过的音乐；用户点击或者播放过的视频；用户点击或者保存过的图片等。为便于理解，以下将有偏数据集称为 S_c 。

35 无偏数据集可以是使用随机流量 (uniform data) 方式采集到的数据集，即从候选集中随机采样多个样本，然后从该多个样本。例如，以为用户推荐 APP 为例，可以从候选集中随机采样多个 APP，并在推荐界面中对该多个 APP 的图片进行随机排列显示，然后收集用户点击或者下载过的 APP，得到无偏置的样本，组成无偏数据集。又例如，以为用户推荐图片的场景为例，可以从候选集中随机采样多个图片，并在推荐界面中对该多个图片的

缩略图进行随机排列显示，然后收集用户点击或者下载过的图片，得到无偏数据集。为便于理解，以下将有偏数据集称为 S_t 。

可选地， S_c 和 S_t 可以是不同领域的的数据，例如， S_c 可以是采集到的用户点击或者播放过的音乐， S_t 可以是用户点击过的图片或者视频等。因此，后续实现跨领域的知识蒸馏，从而使第一神经网络可以输出与输入数据不同领域的预测结果。例如，在跨领域的推荐系统中，可以根据用户对一类物品的喜好，预测其对另一类物品的喜好，缓解新应用场景的冷启动问题，提高用户体验。

在得到 S_c 和 S_t 之后，基于该 S_c 和 S_t 从多种蒸馏方式中选择合适的蒸馏方式。

例如，计算 S_t 与 S_c 样本量的比例，当 S_t 的样本量所占的比例较小时，使用 S_t 训练的模型的方差将较大，不适合标签蒸馏，而更加适合样本蒸馏，即选择样本蒸馏 803 作为蒸馏方式。当 S_t 样本量所占的比例较大时，选择标签蒸馏 804 作为蒸馏方式。

又例如，计算 S_t 中的正负样本的比例，当该比例较大时，优于样本分布不均匀，样本蒸馏或者标签蒸馏效果变差，此时可以选择模型结构蒸馏作为蒸馏方式。或者，计算 S_c 中的正负样本的比例，当该比例较大时，优于样本分布不均匀，样本蒸馏或者标签蒸馏效果变差，此时可以选择模型结构蒸馏作为蒸馏方式。

还例如，通常，随着数据集中所包括的样本的特征维度数量增大时，最终训练得到的模型也将变得复杂，模型的输出效果也将提升。因此，当 S_t 和 S_c 所包括的样本的特征维度数量较大时，可以选择特征蒸馏，从而使最终得到的模型输出效果更好。

在选择了合适的蒸馏方式之后，即可使用该蒸馏方式对第一神经网络进行知识蒸馏，得到更新后的第一神经网络。

下面对使用各种蒸馏方式进行蒸馏的具体过程进行详细介绍。

一、样本蒸馏

其中，进行样本蒸馏可以分为多种方式，下面示例性地对几种可能的实施方式进行介绍。

1、因果表征 (causal embedding) 策略

其中，可以使用 S_c 和 S_t 对相同的模型进行交替训练，并使用 S_t 的训练结果约束使用 S_c 进行的训练。

具体地，首先选定第一神经网络的结构，该第一神经网络可以是 CNN，也可以是 ANN 等。然后交替使用 S_c 和 S_t 对该第一神经网络进行训练。为便于理解，以一次交替过程为例，将使用 S_t 训练得到的模型表示为 M_t ，将使用 S_c 训练得到的模型表示为 M_c ， M_t 可以理解为老师模型， M_c 可以理解为学生模型。

其中，在进行训练时，可以使用目标函数对第一神经网络进行训练，该目标函数除了包括损失函数，还可以包括约束函项，该约束项用于对第一神经网络的更新形成约束，以使在交替训练的过程中， M_c 和 M_t 的参数接近或者一致。然后基于目标函数的值对权重参数和结构参数进行求导以及梯度更新等，得到更新后的参数，如权重参数或者结构参数等，从而得到更新后的第一神经网络。

例如，该目标函数可以表示为：

$$\begin{aligned} & \min_{\mathcal{W}_c, \mathcal{W}_t} \frac{1}{|S_c|} \sum_{(i,j) \in S_c} \ell(y_{ij}, \hat{y}_{ij}^c) + \frac{1}{|S_t|} \sum_{(i,j) \in S_t} \ell(y_{ij}, \hat{y}_{ij}^t) + \lambda_c R(\mathcal{W}_c) + \lambda_t R(\mathcal{W}_t) \\ & + \lambda_{\|t-c\|} \|\mathcal{W}_t - \mathcal{W}_c\|_F^2 \end{aligned}$$

其中, $|S_c|$ 和 $|S_t|$ 分别指的是 S_c 和 S_t 的样本量, $\hat{y}_{ij}^c$ 是 S_c 代入第一神经网络的输出, $\hat{y}_{ij}^t$ 是 S_t 代入第一神经网络的输出, $\ell(y_{ij}, \hat{y}_{ij}^c)$ 和 $\ell(y_{ij}, \hat{y}_{ij}^t)$ 分别指的是 S_c 和 S_t 代入第一神经网络之后的损失函数的值, 该损失函数可以是二值、交叉熵或者均值误差损失等。 $\mathcal{W}_c$ 和 $\mathcal{W}_t$ 分别指的是 S_c 和 S_t 模型的参数, $R(\mathcal{W}_c)$ 和 $R(\mathcal{W}_t)$ 分别指的是 S_c 和 S_t 模型参数的正则项, λ_c 和 λ_t 分别指 M_c 和 M_t 模型正则项的权重参数, $\lambda_{\|t-c\|}$ 指的是参数的平方差项的权重参数。在该目标函数中, 除了包括针对 S_c 和 S_t 的损失函数之外, 还可以包括针对 S_c 和 S_t 的正则项, 以及参数的平方差项, 从而在后续更新第一神经网络的参数时形成约束, 使 M_c 和 M_t 的参数更接近或者一致。

因此, 在本申请实施方式中, 可以使用 S_c 和 S_t 对第一神经网络交替进行训练, 从而使用 S_t 训练得到的模型对使用 S_c 进行训练的模型进行指导, 完成对学生模型的纠偏, 降低学生模型的输出结果的偏置。

2、交替组合 (delayed combination) 策略

此策略的蒸馏方式与前述因果表征策略类似, 区别在于, 前述的因果表征测量可以以 1: 1 的批训练次数比例进行交替训练, 而在本策略中, 可以使用 s: 1 的批训练次数比例进行交替训练, 该 s 为大于 1 的整数。例如, s 可以取 1-20 范围内的整数。该批训练次数可以理解每一轮训练过程中, 对神经网络进行迭代训练的迭代次数。通常, 神经网络的训练过程分为多个 epoch, 每个 epoch 包含多个 batch, 该 batch 就是批训练。例如, 若训练使用的数据集中包括了 6000 张图片, 每个 epoch 训练所使用的图片数量可以是 6000 张, 一个 batch 过程使用了 600 张图片, 总共包括 100 个 batch, 即批训练次数为 100。

相应地, 第一神经网络的目标函数可以设置为:

$$\begin{cases} \min_{\mathcal{W}_c} \frac{1}{|S_c|} \sum_{(i,j) \in S_c} \ell(y_{ij}, \hat{y}_{ij}^c) + \lambda_c R(\mathcal{W}_c) S_c \text{ step} \\ \min_{\mathcal{W}_t} \frac{1}{|S_t|} \sum_{(i,j) \in S_t} \ell(y_{ij}, \hat{y}_{ij}^t) + \lambda_t R(\mathcal{W}_t) S_t \text{ step} \end{cases}$$

其中, $S_t \text{ step}$ 表示使用 S_t 对第一神经网络进行训练的批训练次数, $S_c \text{ step}$ 表示使用 S_c 对第一神经网络进行训练的批训练次数, 该比例可以是 s: 1。

3、加权组合 (weighted combination) 策略

其中, 为 S_c 和 S_t 中全部或者部分样本添加一个置信度变量 α_{ij} , 取值在[0, 1]范围内, 该 α_{ij} 用于指示样本的偏置程度。

例如, 针对第一神经网络进行更新所使用的目标函数可以表示为:

$$\min_{\mathcal{W}_c, \mathcal{W}_t} \frac{\alpha_{ij}}{|S_c|} \sum_{(i,j) \in S_c} \ell(y_{ij}, \hat{y}_{ij}^c) + \frac{1}{|S_t|} \sum_{(i,j) \in S_t} \ell(y_{ij}, \hat{y}_{ij}^t) + \lambda_c R(\mathcal{W}_c) + \lambda_t R(\mathcal{W}_t)$$

通常, S_t 中的样本的置信度变量可以设置为 1。 S_c 的样本的置信度通过两种不同的机制来设置: 在全局机制中, 该置信度被设置成一个预定义的在 $[0,1]$ 内的值; 在局部机制中, 样本关联一个独立的置信度, 并在模型训练过程中学习。该置信度变量用于在使用 S_c 对第一神经网络进行训练时, 针对 S_c 进行约束, 从而可以使对第一神经网络的训练过程中, 可以使用 S_c 和 S_t 中的样本结合样本的置信度, 对第一神经网络进行训练。可以理解为, 可以使用置信度变量来反应 S_c 中的样本的偏置程度, 从而在后续的训练过程中, 通过该置信度变量对使用 S_c 进行的训练进行约束, 实现去偏置的效果, 降低更新后的第一神经网络的输出结果的偏置程度。

10 二、标签蒸馏

其中, 标签蒸馏是指使用基于无偏数据集中的样本的预测标签作为指导对学生模型进行蒸馏, 该预测标签由老师模型输出, 该老师模型是基于无偏数据集进行训练得到。

具体地, 标签蒸馏也可以使用多种策略, 示例性地对几种可能的策略进行说明。

1、搭桥 (Bridge) 策略

15 在本策略中, 使用 S_c 和 S_t 分别进行训练得到 M_c 和 M_t 。

引入未观测数据集, 该未观测数据集中包括了多个未观测样本。例如, 以为用户推荐 APP 为例, 可以在推荐界面中展示为用户推荐的 APP 的图标, 用户点击或者下载过的 APP 即可以理解为前述的偏置样本, 而推荐界面中用户未点击过的 APP 即未观测样本。

20 以下将 S_c 、 S_t 和未观测数据集的组合称为全量数据集, 然后从对该全量数据集进行随机采样多个样本, 得到辅助数据集 S_a 。通常, 由于数据稀疏性, S_a 中的大部分数据都属于未观测样本。

其中, 在对第一神经网络进行更新时, 可以使用 S_a 来进行训练, 从而约束 M_c 和 M_t 在对 S_a 中的样本的预测结果相同或者接近。所使用的目标函数可以包括:

$$\begin{aligned} & w_{c,t}^{\min} \frac{1}{|S_c|} \sum_{(i,j) \in S_c} \ell(y_{ij}, \hat{y}_{ij}^c) + \frac{1}{|S_t|} \sum_{(i,j) \in S_t} \ell(y_{ij}, \hat{y}_{ij}^t) + \frac{1}{|S_a|} \sum_{(i,j) \in S_a} \ell(\hat{y}_{ij}^{c'}, \hat{y}_{ij}^{t'}) \\ & + \lambda_c R(\mathcal{W}_c) + \lambda_t R(\mathcal{W}_t) \end{aligned}$$

25 $|S_a|$ 指的是未观测样本 S_a 数据集的样本量, $\ell(\hat{y}_{ij}^c, \hat{y}_{ij}^t)$ 表示 S_a 中的样本在 S_c 训练的模型和 S_t 训练的模型上的预测标签的误差函数, $\hat{y}_{ij}^c$ 为 S_a 代入第一神经网络的输出结果, $\hat{y}_{ij}^{t'}$ 为 S_a 代入第二神经网络的输出结果。因此, 在本策略中, 引入了未观测数据集来进行纠偏, 减少了 M_c 模型和 M_t 模型之间的差异, 在目标函数引入了 S_a 中的样本在 M_c 模型和 M_t 模型上的预测标签的误差函数, 来对第一神经网络的训练形成约束, 从而降低第一神经网络的输出结果的偏置。

30 2、重定义 (Refine) 策略

S_t 使用预训练 M_t , 然后使用 M_t 对 S_c 进行预测, 得到 S_c 中样本的预测标签; 将该预测标

签和 S_c 的真实标进行签加权合并；然后使用新标签训练 M_c 。注意由于预测标签和 S_c 的实际标签可能存在分布上的差异，需要对预测标签进行归一化，从而减少预测标签和实际标签之间的差异。

具体地，对第一神经网络进行训练使用的目标函数可以表示为：

$$\min_{\mathcal{W}_c} \frac{1}{|S_c|} \sum_{(i,j) \in S_c} \ell(y_{ij} + \alpha N(\hat{y}_{ij}^t), \hat{y}_{ij}^c) + \lambda_c R(\mathcal{W}_c)$$

- 5 其中， α 表示预测标签的权重系数， $N(\hat{y}_{ij}^t)$ 表示对于预测标签 $\hat{y}_{ij}^t$ 的归一化处理， y_{ij} 表示 S_t 中的样本的实际标签， $\hat{y}_{ij}^t$ 表示 M_t 输出的 S_c 中的样本的预测标签。

三、特征蒸馏

- 10 其中，可以从 S_t 中筛选出稳定特征，然后使用该稳定特征进行训练得到 M_t ，即老师模型，然后使用 S_c 上训练一个 M_c ，并使用 M_t 对 M_c 进行知识蒸馏，得到蒸馏后的 M_c 。

为便于理解，该稳定特征可以理解为：使用不同的数据集对神经网络进行训练，得到不同的神经网络，而该不同的神经网络的输出结果相差较小，则该不同的数据集中的相同的特征，即可理解为有代表性的稳定特征。例如，可以使用深度全局平衡回归算法（deep global balancing regression, DGBR）算法从 S_t 中筛选出有代表性的稳定特征。

- 15 使用特征蒸馏方式对第一神经网络进行知识蒸馏的具体过程可以例如，可以通过DGBR算法从 S_t 筛选出具有稳定特征的样本，然后基于该具有稳定特征的样本训练第二神经网络，并将训练后的第二神经网络作为老师模型，第一神经网络作为学生模型，使用 S_c 训练第一神经网络，并对该第一神经网络进行知识蒸馏，得到更新后的第一神经网络。具体例如，确定学生模型和老师模型中一部分神经网络层之间的对应关系，需要说明的是，这里的对应关系是指该神经网络层在学生模型和老师模型中的相对位置是相同或相似的，例如，若
- 20 学生模型和老师模型是不同类型的网络，而学生模型和老师模型包括的神经网络层的数量是相同的，在这种情况下，学生模型中的第一神经网络层为从输入层开始计数的第N层，老师模型中的第二神经网络层为从输入层开始计数的第N层，此时第一神经网络层和第二神经网络层为具有对应关系的神经网络层；其中，上述神经网络层可以包括中间层和输出层，在进行知识蒸馏时，学生模型和老师模型分别对待处理数据进行处理，并将具有对应关系的神经网络层的输出来构建损失函数，通过损失函数对学生模型进行知识蒸馏，直到满足预设条件。此时，知识蒸馏后的学生模型和老师模型在对相同的待处理数据进行处理时，上述具有对应关系的神经网络层的输出是相似或相同的，以此，使得知识蒸馏后的学生模型可以具有和老师模型相同或相似的数据处理能力。以上述第一神经网络层和第二神经网络层为例，知识蒸馏后的学生模型和老师模型在对相同的待处理数据进行处理时，第
- 30 一神经网络层和第二神经网络层的输出是相似的，由于具有对应关系的神经网络层的数量可以是多个，使得知识蒸馏后的学生模型和老师模型中的一部分或全部神经网络层具有相同或相似的数据处理能力，进而使得知识蒸馏后的学生模型和老师模型具有相同或相似的数据处理能力。

因此,在本蒸馏方式中,可以使用稳定特征训练得到老师模型,从而使用该基于稳定特征训练得到的老师模型来对学生模型进行蒸馏,使后续得到的学生模型也可以在老师模型的指导下,输出无偏置或者偏置较低的结果。

四、模型结构蒸馏

5 在本蒸馏方式中,可以使用 S_t 进行训练得到 M_t 。然后使用 M_t 的中间层的输出结果,对 M_c 的训练进行指导。

例如,为了对齐 M_t 和 M_c 的特征嵌入(feature embedding),在 S_t 上训练得到 M_t 的特征嵌入,然后使用该特征嵌入作为 M_c 的变量的初始化值。在 S_c 上训练得到特征嵌入,将该特征嵌入对 M_c 的变量的进行随机初始化,然后对该初始化值和随机初始化的值进行加权运算,使用加权运算的结果去训练 M_c ,得到训练后的 M_c 。

又例如,可以 M_c 和 M_t 中选择需要进行对齐的 Hint 层进行配对(一个或者多个,且 M_c 和 M_t 对应的网络层索引可以无需保持一致),然后添加配对项到 M_c 的目标函数中,该配对项可以表示为 $\alpha * y_t + (1 - \alpha) * y_c$, $\alpha \in (0.5, 1)$, y_t 表示 M_t 的 Hint 层的输出结果, y_c 表示 M_c 的 Hint 层的输出结果, α 表示 y_t 所占的比例。

15 还例如,可以引入温度变量和 softmax 操作得到 M_t 预测的软标签,即由 M_t 的 softmax 层之前的网络层输出的标签,然后在训练 M_c 的过程中,约束 M_c 的 softmax 层之前的网络层输出的标签与 M_t 的 softmax 层之前的网络层输出的标签相同或者接近。如可以在 M_c 的目标函数中添加相应的配对项,该配对项可以表示为 $\omega * y_t + (1 - \omega) * y_c$, $\omega \in (0.5, 1)$, y_t 表示 M_t 的 softmax 层之前的网络层的输出结果, y_c 表示 M_c 的 softmax 层之前的网络层的输出结果, ω 表示 y_t 所占的比例。

因此,在本蒸馏方式中,可以使用老师模型的中间层,来指导学生模型的中间层的训练,因老师模型是使用无偏数据集训练得到的,因此,老师模型在对学生模型的指导过程中,将对学生模型的输出结果形成约束,降低学生模型的输出结果的偏置,提高学生模型的输出结果的准确性。

25 在通过上述的其中一种方式进行知识蒸馏,得到更新后的第一神经网络之后,即可使用该第一神经网络进行后续的预测。例如,可以应用于推荐场景中,为用户推荐音乐、视频或者图像等。

前述对本申请提供的神经网络蒸馏方法的流程进行了详细介绍,下面结合前述流程,对本申请提供的神经网络蒸馏方法的应用场景进行示例性说明。

30 例如,可以建立针对用户的“终身学习项目”,基于用户在视频、音乐、新闻等域的历史数据,通过各种模型和算法,仿照人脑机制,构建认知大脑,搭建用户终身学习系统框架。

该终身学习项目示例性地划分为四个阶段,即使用用户的历史数据进行学习(第一阶段),监控用户的实时数据(第二阶段),预测用户的未来数据(第三阶段),以及为用户进行决策(第四阶段)。本申请提供的神经网络蒸馏方法,可以应用于第一阶段、第三阶段或者第四阶段。

例如,可以根据音乐 APP、视频 APP 和浏览器 APP 等多域平台获取用户的数据(包含

端侧短信、照片、邮件事件等信息),一方面使用获取到的数据构建用户画像,另一方面实现基于用户信息过滤、关联分析、跨域推荐、因果推理等的学习与记忆模块,构建用户个人知识图谱。

示例性地,如图9所示,若用户进入推荐系统的界面,会触发一个推荐的请求,推荐系统会将该请求及其相关信息输入到预测模型,然后预测用户对系统内的商品的点击率。下一步,根据预测的点击率或基于该点击率的某个函数将商品降序排列,推荐系统按顺序将商品展示在不同的位置作为对用户的推荐结果。用户浏览不同的位置并发生用户行为,如浏览、点击下载等。同时,用户的实际行为会存入日志中作为训练数据,通过离线训练不断更新预测模型的参数,提高模型的预测效果。本申请对应于推荐系统的离线训练,同时会改变预测模型的预测逻辑。具体例如,用户打开手机浏览器APP即可触发浏览器的推荐模块,浏览器的推荐模块根据用户的历史下载记录、用户点击记录,应用的自身特征,时间、地点等环境特征信息,预测用户下载给定的各个候选新闻/文章的可能性。根据计算的结果,浏览器按照可能性按序展示,达到提高应用下载概率的效果。具体来说,将更有可能下载的新闻排在靠前的位置,将不太可能下载的新闻排列在靠后的位置。而用户的行为也会存入日志并通过离线训练对预测模型的参数进行训练和更新。

更具体地,可以将本申请提供的神经网络蒸馏方法引入终身学习中,以应用于终端上的一种推荐系统为例,如图10所示,本申请提供的一种推荐系统的框架示意图。其中,终端上安装有各种APP,如第三方APP、视频APP、音乐APP、浏览器APP或者应用市场APP等,或者短信、邮件、照片、日历或者其他终端的系统APP等。用户在使用终端上安装的APP时,可以通过收集用户使用产生的数据,从而获取到用户行为数据,如短信、照片、邮件事件、视频、浏览记录等信息。当然,采集APP的数据之前,可以获取采集权限,以保障用户的隐私。

无偏数据集和有偏数据集都可以通过上述APP采集得到。例如,在采集无偏数据集时,以在应用市场中推荐APP为例,可以从APP候选集中随机采样部分APP来为用户进行推荐,并在推荐界面中随机展示采样到的APP的图标,然后获取用户点击过的APP的信息。又例如,以音乐APP为例,可以从音乐候选集中随机采样部分音乐,然后在推荐界面中随机展示采样到的音乐的信息,如因为标题、歌手等信息,随后获取用户点击过的音乐的信息。例如,在采集有偏数据集时,可以按照预先设定的推荐规则,如为用户推荐于用户的标签关联度更高的APP、音乐或者视频等,采集用户点击或者下载过的音乐、APP或者视频等,得到有偏数据集。

可选地,还可以采集未观测数据集,例如,若选择了100个APP进行推荐,而推荐界面中仅显示了10个APP的图标,则剩余的90个APP即为未观测样本。

在采集到无偏数据集和有偏数据集之后,即可使用该无偏数据集和有偏数据集进行知识蒸馏,即将无偏数据集和有偏数据集输入至图10中所示的基于知识蒸馏的反事实推荐(knowledge distillation counterfactual recommend, KDCRec)模块,以进行知识蒸馏,得到训练后的第一神经网络,即图10中所示的记忆模型。知识蒸馏的过程可以参阅前述图8的介绍,此处不再赘述。可选地,还可以集合未观测数据集进行知识蒸馏,参阅前述图8

中的标签蒸馏 804 的相关介绍，此处不再赘述。因此，在知识蒸馏的过程中，可以通过本申请提供的神经网络蒸馏方法，纠正用户历史数据的偏置问题（包括位置偏置、选择偏置及流行偏置等），得出用户的真实数据分布。

在得到记忆模型之后，即可通过该记忆模型输出用户对应的一个或者多个预测标签，该一个或者多个标签用于构建出，例如，该标签可以用于表示用户点击某个 APP 的概率，当该概率大于预设概率值时，即可将该标签对应的样本的特征作为用户的特征加入用户图像中。该用户画像中所包括的标签用于描述用户，如用户偏好的 APP 类型、音乐类型等。

可选地，还可以输出用户的特征知识化数据和知识可推理数据等，即通过关联分析、跨域学习、因果推理等技术挖掘用户特征，借助外部通用知识图谱实现基于知识的推理和呈现，并将基于通用知识的特征扩展输入到增强用户画像模块，通过可视化、动态化的方式，增强用户画像。

然后，业务服务器可以基于增强的用户画像，确定为用户推荐的音乐、APP 或者视频等信息，完成针对用户的精准推荐，提高用户体验。

可以理解为，本申请提供了一种基于广义知识蒸馏的反事实学习方法，用于实现无偏的跨域推荐，构建无偏的用户画像系统和无偏的个人知识图谱。对本申请展开实验，包括跨域推荐、基于因果推理的兴趣挖掘和构建用户画像系统。离线实验结果如下：在用户画像中，基于性别预测的算法较基线准确率提升超 3%，年龄多分类任务较基线准去了提升近 8%，引入反事实因果学习使得各年龄段的准确率方差降低 50%。基于反事实因果推理的用户兴趣挖掘，替换了基于关联规则学习的算法，有效降低了用户的有效动作集，并提供出对于用户喜好标签的可解释性。

例如，以某一个应用市场为例，可以在应用市场的推荐界面中，显示多个榜单，根据用户、候选集商品和上下文特征预测用户对候选集商品的点击概率，并以次概率将候选商品降序排列，将最可能被下载的应用排在最靠前的位置。用户看到应用市场的推荐结果之后，根据个人的兴趣，选择浏览、点击或者下载等操作，这些用户行为被存入日志。

将这些累积的用户行为日志作为训练数据训练点击率预测模型，离线训练点击率预测模型时，需要用到用户行为日志。而收集的用户数据存在位置偏置、选择偏置等问题，为消除这些偏置对于点击率预测模型的影响，我们引入随机流量数据 uniform data，结合本发明提出的 101 决策机制模块，从前述图 8 中的 803-806 中选择合适的蒸馏方式，联合用户日志数据即有偏数据，共同训练推荐模型，即第一神经网络。基于标签蒸馏的反事实技术相较于基线在受试者工作特征曲线与坐标轴围成面积（the area under the roc curve, AUC）上有 8.7%的提升，基于样本蒸馏的反事实因果学习技术较基线有 6%的提升，基于模型结构蒸馏的反事实因果学习技术较基线有 5%的提升。

前述对本申请提供的神经网络蒸馏方法的流程以及应用场景进行了详细说明。针对前述方法得到的第一神经网络，可以应用于推荐场景，下面结合前述的方法，对本申请提供的推荐方法进行详细介绍。

图 11 示出了本申请实施例提供的推荐方法 1100 的示意图。图 11 所示的方法可以由推荐装置来执行，该装置可以是云服务设备，也可以是终端设备，例如，电脑、服务器等运

算能力足以用来执行推荐方法的装置，也可以是由云服务设备和终端设备构成的系统。示例性地，方法 1100 可以由图 2 或图 5 中的执行设备 210 或图 5 中的本地设备执行。

例如，方法 1100 具体可以由如图 3 所示的执行设备 210 执行，所述方法 1100 中的目标用户和候选推荐对象可以是如图 3 中的数据库 230 中的数据。

5 方法 1100 包括步骤 S1110 和步骤 S1120。下面对步骤 S1110 至步骤 S1120 进行详细介绍。

S1110，获取目标用户的信息和候选推荐对象的信息。

例如，当用户进入推荐系统时，会触发推荐请求。推荐系统可以将触发该推荐请求的用户作为目标用户，将推荐系统中可以展示给用户的推荐对象作为候选推荐对象。

10 示例性地，目标用户的信息可以包括用户的标识，例如目标用户 ID，目标用户的信息还可以包括用户个性化的一些属性信息，例如，目标用户的性别、目标用户的年龄、目标用户的职业、目标推荐用户的收入、目标用户的爱好或目标用户的教育情况等。

示例性地，候选推荐对象的信息可以包括候选推荐对象的标识，例如候选推荐对象 ID。候选推荐对象的信息还可以包括候选推荐对象的一些属性信息，例如，候选推荐对象的名称或候选推荐对象的类型等。

15 S1120，将目标用户的信息和候选推荐对象的信息输入至推荐模型，预测目标用户对候选推荐对象有操作动作的概率。

其中，推荐模型是前述图 6 中得到的更新后的第一神经网络，为便于理解，以下将该更新后的第一神经网络称为推荐模型，该推荐模型的训练方式可以参阅前述步骤 601-603 中的相关描述，此处不再赘述。

20 示例性地，可以通过预测目标用户对候选推荐对象有操作动作的概率对候选推荐集中的候选推荐对象进行排序，从而得到候选推荐对象的推荐结果。例如，选择概率最高的候选推荐对象展示给用户。比如，候选推荐对象可以是候选推荐应用程序。

25 如图 12 所示，图 12 示出了应用市场中的“推荐”页，该页面上可以有多个榜单，比如，榜单可以包括精品应用和精品游戏。以精品游戏为例，应用市场的推荐系统根据用户的信息和候选推荐应用程序的信息预测用户对候选推荐应用程序有下载（安装）行为的概率，并以此概率将候选推荐应用程序降序排列，将最可能被下载的应用程序排在最靠前的位置。

30 示例性地，在精品应用中推荐结果可以是 App5 位于精品游戏中的推荐位置一、App6 位于精品游戏中的推荐位置二、App7 位于精品游戏中的推荐位置三、App8 位于精品游戏中的推荐位置四。当用户看到应用市场的推荐结果之后，可以根据自身的兴趣爱好对上述推荐结果进行操作动作，用户的操作动作执行后会被存入用户行为日志中。

图 12 所示的应用市场可以通过用户行为日志得到训练数据训练推荐模型。

35 应理解，上述举例说明是为了帮助本领域技术人员理解本申请实施例，而非要将本申请实施例限于所例示的具体数值或具体场景。本领域技术人员根据所给出的上述举例说明，显然可以进行各种等价的修改或变化，这样的修改或变化也落入本申请实施例的范围内。

推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络

络进行训练得到，有偏数据集中包括有偏置的样本，无偏数据集中包括无偏置的样本，第一蒸馏方式是根据样本集的数据特征确定的，有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第一用户是否对第一推荐对象有操作动作，无偏数据集中的样本包括第二用户的信息和第二推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第二用户是否对第二推荐对象有操作动作。

在一种可能的实施方式中，无偏数据集是在候选推荐对象集合中的候选推荐对象被展示的概率相同的情况下获得的，第二推荐对象为候选推荐对象集合中的一个候选推荐对象。

在一种可能的实施方式中，无偏数据集是在候选推荐对象集合中的候选推荐对象被展示的概率相同的情况下获得的，可以包括：无偏数据集中的样本是在候选推荐对象集合中的候选推荐对象被随机展示给第二用户的情况下获得的；或者无偏数据集中的样本是在第二用户搜索第二推荐对象的情况下获得的。

在一种可能的实施方式中，无偏数据集中的样本属于源域的数据，有偏数据集中的样本属于目标域的数据。

可以理解图 6 对应的方法为该推荐模型的训练阶段（如图 3 所示的训练模块 202 执行的阶段），具体训练是采用由图 6 的方法中提供的更新后的第一神经网络，即推荐模型进行的；而图 11 对应的方法则可以理解是该推荐模型的应用阶段（如图 3 所示的执行设备 210 执行的阶段），具体可以体现为采用由图 6 对应的方法训练得到的推荐模型，并根据目标用户的信息和候选推荐对象的信息，从而得到输出结果，即目标用户对候选推荐对象有操作的概率。

下面通过三个示例（示例 1、示例 2 和示例 3）对本申请实施例的方案应用于不同场景进行说明，应理解，下面描述的推荐模型的训练方法可以视为前述图 6 对应的方法的一种具体实现方式，下面描述的推荐方法可以视为图 11 的发明的一种具体实现方式，为了避免不必要的重复，下面在介绍本申请实施例的三个示例时适当省略重复的描述。

示例 1：

如图 13 所示，对于每个推荐请求，推荐系统中通常需要基于用户画像对全量库中的所有物品执行召回、精排或者人工规则等多个流程来生成最终的推荐结果，然后展示给用户。被推荐给用户的物品的数量远远小于物品的总数量，在该过程中引入了多种偏置问题，例如，位置偏置和选择偏置。

用户画像指的是用户个性化偏好的标签集合。例如，用户画像可以由用户的交互历史生成。

选择偏置指的是由于物品被展示的概率不同导致采集到的数据有偏置。理想的训练数据是在将物品按照相同的展示概率展示给用户的情况下得到的。实际情况中，由于展示位的数量限制，无法展示所有物品。推荐系统通常根据预测的用户对物品的选择率为用户进行推荐，用户只能与被展示出来的物品中进行交互，而没有得到展示的机会的物品无法被选择，即无法参与交互，这样导致物品得到展示的机会并不相同。在整个推荐流程中，例如召回、精排等多个流程，均会出现截断操作，即从候选推荐对象中选择部分推荐对象进

行展示。

位置偏置指的是由于物品展示的位置不同导致采集到的数据有偏置。推荐系统通常按照从上到下或从左到右的先后顺序依次展示推荐结果。按照人们的浏览习惯，位于前面的物品更容易被看到，用户的选择率更高。例如，在应用市场的一个榜单中，同一个应用程序（application，APP）可以展示在第一位，也可以展示在最后一位。通过随机投放策略可以验证，该 APP 展示在第一位的下载率远高于展示在最后一位的下载率。如图 13 所示，通过执行精排流程，导致物品展示位置出现差异，由此引入位置偏置。

由于偏置问题的存在，导致展示机会多的物品被用户选择的概率更高，用户选择的概率越高，在之后的推荐中该物品更容易被推荐给用户，进而获得更多的展示机会，容易被其他用户点击，加剧了偏置问题的影响，造成马太效应，导致长尾问题的加剧。长尾问题导致绝大部分小众的个性化需求无法得到满足，影响了用户体验。此外，推荐系统中的很多物品由于没有曝光机会，也就无法产生实际的商业价值，空耗存储资源和计算资源，造成资源的浪费。

示例 2：

终生学习项目指的是基于用户在视频、音乐、新闻等多个领域的历史数据，通过各种模型和算法，仿照人脑机制，构建认知大脑，实现终生学习的目标的项目。

图 14 中示出了一种终生学习框架的示意图。在该框架中包括视频 APP、阅读 APP 和浏览器 APP 等多个推荐场景。传统的推荐学习方案是在每个推荐场景或者说每个域中学习用户在该域的历史行为中隐藏的规律，然后根据学习到的规律进行推荐，整个学习与实施过程完全不考虑域间的知识迁移与共享。

然而，在新的推荐场景上线初期，用户的交互历史匮乏，如果仅基于本域的交互历史学习得到的推荐模型难以发现用户的历史行为中隐藏的规律，进而导致预测结果不准确，也就是新的推荐场景中存在冷启动问题。

跨域推荐是学习用户在源域的偏好并应用于目标域的推荐方法。通过跨域推荐能够利用在源域学习到的规律指导目标域中的推荐结果，实现域间的知识迁移和共享，解决冷启动问题。

例如，通过根据用户在阅读 App 的推荐场景中的阅读喜好来预测其对音乐、视频的偏好，从而解决该用户在音乐 App 的推荐场景中的冷启动问题。

如图 15 所示，在阅读 APP 的推荐场景中，为用户 A 推荐图书，基于用户 A 的交互历史数据可以学习用户 A 在阅读 APP 的推荐场景中的兴趣偏好，基于该用户 A 在阅读 APP 的推荐场景中的兴趣偏好可以确定与该用户 A 的兴趣相同的邻居用户。在音乐 APP 的推荐场景中，为用户推荐音乐，基于邻居用户在音乐 APP 的推荐场景中的交互历史数据学习邻居用户的在音乐 APP 的推荐场景中的兴趣偏好，然后基于学习到的兴趣偏好指导在音乐 APP 的推荐场景中为用户 A 提供推荐结果。阅读 APP 的推荐场景即为源域，音乐 APP 的推荐场景即为目标域。然而，源域和目标域的数据分布往往不一致，那么源域的数据分布相对于目标域的数据分布是有偏的，直接利用上述关联规则等方式实现跨域推荐会导致在学习过程中引入偏置。模型会更多的考虑用户在源域的兴趣偏好来进行推荐，也就是说训练出来的

模型是有偏的，这样导致在源域的数据上学习的模型不能在目标域得到有效泛化，模型存在失真风险。

示例 3:

下面以阅读 APP 的推荐场景作为源域、视频 APP 的推荐场景作为目标域为例对步骤 S1110 的一种实现方式进行说明。

阅读 APP 的推荐场景指的是为用户推荐图书的推荐场景，视频 APP 的推荐场景指的是为用户推荐视频的推荐场景。

如 16 图所示，有偏样本是根据视频 APP 的推荐场景（目标域）中的用户的交互历史得到的。

表 1 示出了视频 APP 的推荐场景中基于用户的交互历史（例如，用户行为日志）获得的数据。

表 1

标签	用户 ID	视频 ID	标签	制片商	演员	评分
1	13718bbd	5316a17f	惊悚	1 号制片商	张三	6.8
0	0b153874	93bad2c0	文艺	2 号制片商	李四	7.1
...	...	...	...	...	...	...

表 1 中的一行即为一个样本。以该训练样本为有偏样本为例，有偏样本包括第一用户的信息和第一推荐对象的信息。第一用户的信息包括第一用户的 ID，第一推荐对象为视频，第一推荐对象的信息包括第一推荐对象的 ID、第一推荐对象的标签、第一推荐对象的制片商、第一推荐对象的演员和第一推荐对象的评分。也就是说有偏样本中共包括 6 类特征。

应理解，表 1 仅为示意，用户的信息以及推荐对应的信息还可以包括比表 1 更多或更少项的信息，或者说更多或更少类特征信息。

进一步地，以 libSVM 格式存储处理后的数据，例如表 1 中的数据可以按照如下形式存储：

1 25173:1 38553:1 50053:1 50216:1 59109:1 98079:1
0 19468:1 19850:1 79800:1 81901:1 85533:1 13010:1
...

基于上述数据可以得到 n 个有偏样本，组成有偏数据集。

如图 16 所示，无偏样本是根据阅读 APP 的推荐场景（源域）中的用户的交互历史得到的。需要说明的是，图 16 中仅为示意，源域中的数据还可以包括其他推荐场景的数据，也可以包括多个推荐场景的数据，例如，源域的数据可以包括阅读 APP 的推荐场景中的用户历史数据和音乐 APP 的推荐场景中的用户历史数据。

应理解，图 16 中仅为示意，也可以不将无偏样本作为验证集中的数据。

表 2 示出了阅读 APP 的推荐场景中基于用户的交互历史（例如，用户行为日志）获得的数据。

表 2

标签	用户 ID	图书 ID	标签	出版社	作者	评分
1	25c83c98	68fd1e64	悬疑	1 号出版社	张三	6.8
0	efea433b	0b153874	艺术	2 号出版社	李四	7.1
...	...	...	...	...	...	...

表 2 中的一行即为一个训练样本。该样本为无偏样本，无偏样本包括第二用户的信息和
第二推荐对象的信息。第二用户的信息包括第二用户的 ID，第二推荐对象为图书，第二
推荐对象的信息包括第二推荐对象的 ID、第二荐对象的标签、第二推荐对象的出版社、第
5 二推荐对象的作者和第二推荐对象的评分。也就是说无偏样本中共包括 6 类特征。

应理解，表 2 仅为示意，用户的信息以及推荐对应的信息还可以包括比表 2 更多或更
少项的信息，或者说更多或更少类特征信息。

进一步地，以 libSVM 格式存储处理后的数据，例如表 2 中的数据可以按照如下形式存
储：

10 1 77891:1 81901:1 82101:1 83267:1 83896:1 91899:1
 0 55060:1 59115:1 60857:1 75847:1 97576:1 42803:1
 ...

该推荐模型可以应用于目标域中，例如，图 16 中的视频 APP 的推荐场景中。

相对于视频 APP 的推荐场景，阅读 APP 的推荐场景中的用户的交互数据更丰富，数据
15 分布更能准确反映用户的偏好，根据直观推理以及用户在阅读场景与视频场景的兴趣的互
通性，通过本申请实施例的方案，能够使推荐模型更好地把握用户在阅读场景的个性化偏
好，进而指导在视频场景中的推荐结果，提高推荐结果的准确率。

通过在不同域间进行知识（例如，用户的兴趣偏好）进行迁移和共享，将源域（例如，
阅读 APP 的推荐场景）和目标域（例如，视频 APP 的推荐场景）的用户交互历史记录都纳
20 入到学习中，这样训练得到的模型在源域有较好的评估效果，此时训练得到的模型很好的
捕获了用户在源域的兴趣偏好，而在近似的推荐场景中，用户的兴趣偏好也类似，因此推
荐模型在目标域也能很好的拟合用户的兴趣偏好，给用户推荐符合其兴趣的推荐结果，实
现跨域推荐，缓解冷启动问题。

推荐模型可以在目标域中预测用户对推荐对象有操作动作的概率，也就是预测用户选
25 择该推荐对象的概率。将目标推荐模型部署于目标域（例如，视频 APP 的推荐场景中），推
荐系统可以基于该目标推荐模型的输出确定推荐结果展示给用户。

如前所述，传统的推荐学习方案是在每个推荐场景或者说每个域中学习用户在该域
的历史行为中隐藏的规律，然后根据学习到的规律进行推荐，整个学习与实施过程完全不考
虑域间的知识迁移与共享。

30 目前，很多电子设备例如手机、平板电脑中都具有多个应用程序，每个应用程序均可
视为一个应用场景。应用程序在为用户进行推荐时，通常仅基于用户在该应用程序中的
交互数据学习用户的偏好，进而为用户进行推荐，不考虑用户在其他应用程序中的交互数

据。

然而，在用户刚下载的应用程序中，用户的交互数据匮乏，如果仅基于本域的交互历史学习得到的推荐模型难以发现用户的历史行为中隐藏的规律，进而导致预测结果不准确，影响用户体验，也就是新的推荐场景中存在冷启动问题。

5 本申请实施例提供了一种推荐方法和电子设备，可以通过学习其他域中的用户的偏好，为用户进行推荐，从而提高预测结果的准确率，提升用户体验。

应理解，本申请实施例中，“用户行为数据”、“用户交互数据”、“交互数据”、“行为数据”等可以认为表达相同的含义，均可以理解为当推荐对象被展示给用户时，与用户的操作行为相关的数据。

10 为了便于理解，本申请将以手机作为电子设备，首先介绍本申请的一些人机交互实施例。图 17 是本申请实施例提供的一组图形用户界面（graphical user interface, GUI）示意图。

用户可以执行对手机中的设置应用程序的点击操作，响应于该点击操作，手机进行设置应用程序的主界面 301，设置应用程序的主界面可以显示如图 17 的（a）图所示的内容。
15 在该主界面 301 中，可以包括批量管理控件、各个应用程序的跨域推荐管理控件以及侧边栏字母排序索引控件等。主界面 301 中还可以显示各个应用程序（例如音乐 APP、阅读 APP、浏览器 APP、新闻 APP、视频 APP 或购物 APP 等）的跨域推荐功能“已开启”或“已关闭”。在一些实施例中，主界面 301 中显示的各个应用程序的跨域推荐管理控件可以按照应用名称首字母从“A”到“Z”的顺序显示，其中每个应用程序都对应着各自的跨域推荐管理控件。应理解，主界面 301 还可以包括其他更多或更少或类似的显示内容，本申请对此不作限定。
20

当用户点击某个应用程序的跨域推荐管理控件时，手机可以显示该应用程序对应的跨域推荐管理界面。示例性地，用户执行图 17 中的（a）图中所示的对浏览器 APP 的跨域推荐管理控件的点击操作，响应于该点击操作，手机进入浏览器 APP 跨域推荐管理界面 302，
25 跨域推荐管理界面 302 可以显示如图 17 中的（b）图所示的内容。在跨域推荐管理界面 302 中，可以包括允许跨域推荐控件。应理解，跨域推荐管理界面 302 还可以包括其他更多或更少类似的显示内容，跨域推荐管理界面 302 也可以依据应用的不同而包括不同的显示内容，本申请实施例对此不作限定。

可选地，跨域推荐管理控件的默认状态可以为关闭状态。

30 示例性地，如图 17 中的（b）图所示，允许跨域推荐控件处于开启状态，浏览器 APP 的跨域推荐功能开启，相应地，浏览器 APP 可以从多个 APP 中获取用户交互数据，并进行学习，以便为用户推荐相关视频。进一步地，当允许跨域推荐控件处于开启状态，跨域推荐管理界面 302 还可以呈现浏览器 APP 的学习列表，学习列表中包括多个选项。跨域推荐管理界面 302 上的一个选项可以理解为一个应用的名称及其对应的开关控件。因此，也可以说，跨域推荐管理界面 302 包括允许跨域推荐控件和多个选项，该多个选项中的每个选项
35 关联一个应用程序，与该应用相关联的选项用于控制浏览器 APP 从该应用中获取用户行为数据的权限的开启和关闭。也可以理解为与某个应用相关联的选项用于控制浏览器 APP

基于该应用中的用户行为数据执行跨域推荐功能。为了方便理解，以下实施例中仍以开关控件来示意选项之义。

如前所述，学习列表中包括多个选项，也就是说跨域推荐管理界面 302 上呈现多个应用的名称及其对应的开关控件。如图 17 中的 (b) 所示，当一个应用对应的开关控件开启状态，视频 APP 可以从该 APP 中获取用户行为数据，并进行学习，以便为用户进行推荐。跨域推荐界面 302 中还可以显示“已允许”或“已禁止”开启跨域推荐功能的应用程序获取各个应用程序（例如音乐 APP、阅读 APP、浏览器 APP、新闻 APP、视频 APP 或购物 APP 等）中的用户数据。如图 17 中的 (b) 图所示，当允许跨域推荐控件处于开启状态，第一界面上呈现多个开关控件，该多个开关控件分别与音乐 APP、阅读 APP、购物 APP、视频 APP、新闻 APP 和聊天 APP 等应用程序对应。以音乐 APP 对应的控件为例，当“音乐 APP 对应的控件处于开启状态，即该音乐 APP 下方处于“已允许”状态，浏览器 APP 可以从音乐 APP 中获取用户行为数据，并进行学习，以为用户进行推荐。

若用户执行对音乐 APP 对应的控件的关闭操作，响应于该关闭操作，手机呈现如图 17 中的 (c) 所示的内容，浏览器 APP 不再从音乐 APP 中获取用户行为数据，即不允许浏览器 APP 获取音乐 APP 中的用户行为数据。若用户执行对允许跨域推荐控件的关闭操作，响应于该关闭操作，浏览器 APP 将关闭跨域推荐功能，即不允许浏览器 APP 获取其他 APP 中的用户交互数据。例如，用户执行如图 17 中的 (b) 图所示的对允许跨域推荐控件的点击操作，响应于该点击操作，手机执行关闭浏览器 APP 的跨域推荐功能。跨域推荐管理界面可以显示如图 17 中 (d) 图所示的内容，浏览器 APP 在该学习列表中的所有应用中的跨域推荐功能被关闭。这样，可以提高管理效率，提升用户体验。

应用程序为用户推荐的内容即为推荐对象，推荐对象可以在应用程序中显示。当用户进入应用程序，可以触发一条推荐请求，由推荐模型针对该推荐请求为用户推荐相关内容。

示例性地，浏览器 APP 为用户推荐的信息流可以在浏览器 APP 的主界面中显示。

示例性地，当用户执行对浏览器 APP 的点击操作，响应于该点击操作，手机显示如图 18 的 (a) 中所示的浏览器 APP 的主界面 303，该浏览器 APP 的主界面 303 中可以显示一个或多个推荐内容的推荐列表，该一个或多个推荐内容即为浏览器 APP 中的推荐对象。应理解，浏览器 APP 的主界面 303 中还可以包括其他更多或更少的显示内容，本申请对此不作限定。

用户可以对浏览器 APP 的主界面 303 的推荐列表所呈现的内容执行一定操作以查看推荐内容、删除（或忽略）推荐内容或查看推荐内容的相关信息等。例如用户点击某个推荐内容，响应于该点击操作，手机可以打开该推荐内容。再如用户向左快滑（或向右快滑）某个推荐内容，响应于该操作，手机可以将该推荐内容从推荐列表中删除。又如，用户长按某个推荐内容，响应于该长按操作，手机可以显示该推荐内容的相关信息。如图 18 中的 (a) 图所示，用户执行如图 18 中的 (a) 所示的长按操作，响应于该长按操作，手机可以显示如图所示的提示框。选择框中显示了提示信息，该提示信息用于提示用户该推荐内容是基于其他应用程序中的用户交互数据推荐的。如图 18 中的 (a) 所示，该提示信息用于提示用户该推荐内容是基于用户在视频 APP 中的数据为用户推荐的内容。

应理解，在一些其他实施例中，用户可以通过其他方式打开视频或删除推荐内容，也可以通过其他方式例如左右慢滑方式调出该推荐内容的相关信息，本申请实施例不作限定。

示例性地，当用户对浏览器 APP 的点击操作，响应于该点击操作，手机还可以显示如图 18 的 (b) 中所示的浏览器 APP 的主界面 304，该主界面 304 中可以显示一个或多个推荐内容的推荐列表以及该一个或多个推荐内容对应的提示信息，该一个或多个推荐内容即为浏览器 APP 中的推荐对象。应理解，主界面 304 中还可以包括其他更多或更少的显示内容，本申请对此不作限定。该提示信息用于提示用户该推荐内容是基于其他应用程序中的用户交互数据推荐的。

用户可以对主界面 304 的推荐列表所呈现的视频执行一定操作以查看推荐内容、删除（或忽略）推荐内容等。例如用户点击某个推荐内容，响应于该点击操作，手机可以打开该推荐内容。再如用户向左快滑（或向右快滑）某个推荐内容，响应于该操作，手机可以将该推荐内容从推荐列表中删除。应理解，在一些其他实施例中，用户可以通过其他方式打开推荐内容或删除推荐内容，也可以通过其他方式例如左右慢滑方式删除该推荐内容的相关信息，本申请实施例不作限定。

应理解，提示信息主要是为用户提供参考信息，以使用户知晓当前推荐对象是基于跨域推荐的功能得到的，其提示信息的内容还可以有其他形式，本申请实施例不作限定。

需要说明的是，本申请实施例中，用户在主界面中删除推荐内容，可以理解为用户只是在主界面的推荐列表中删除了某个推荐内容，也就是说用户对该推荐内容不感兴趣。该行为可以被记录在用户行为日志中用作推荐模型的训练数据。例如，作为前述方法中的有偏样本。

当手机上存在大量的应用时，对于一些需要跨域推荐的应用，可以打开应用程序的跨域推荐功能。示例性地，可以通过以下两种方式打开或关闭应用程序的跨域推荐功能。

一种是单点关闭或打开某个应用的跨域推荐功能。例如，如图 13 所示，在应用程序对应的跨域推荐管理界面中，开启或关闭允许跨域推荐控件，可以实现单点打开或关闭该应用程序的跨域推荐功能。

另一种是批量关闭或打开全部应用的跨域推荐功能。例如，如图 19 的 (a) 图显示的是与图 17 的 (a) 图相同的界面。用户执行图 19 的 (a) 图中所示的批量管理控件的点击操作，响应于该点击操作，用户进入批量管理界面 305 中，可以包括搜索应用控件、跨域推荐总开关控件、各个应用程序的跨域推荐开关控件或侧边栏字母排序索引控件等。用户可以通过控制跨域推荐总开关控件（即图中“全部”后的开关）的打开和关闭，实现整体打开全部应用程序的跨域学习功能或整体关闭全部应用程序的跨域推荐功能。在批量管理界面 305 还包括各个应用的跨域推荐开关控件，用户也可以通过控制某个应用程序的跨域推荐开关控件的打开和关闭，实现单个应用程序的跨域推荐功能的打开或关闭。在一些实施例中，批量管理界面 305 中显示的各个应用程序的跨域推荐开关控件可以按照应用名称首字母从“A”到“Z”的顺序显示，每个应用的跨域推荐功能都由各自的跨域推荐开关控件控制。

应理解，本申请实施例中，“关闭跨域推荐”、“关闭应用的跨域推荐”、“关闭跨

域推荐功能”、“关闭应用的跨域推荐功能”可以认为是表达相同的含义，均可以理解为关闭了应用的跨域推荐功能，该应用程序不再进行跨域推荐。同理，“开启跨域推荐”、“开启应用的跨域推荐”、“打开跨域推荐功能”、“打开应用的跨域推荐功能”可以认为是表达相同的含义，均可以理解为打开了应用程序的跨域推荐功能，应用程序可以进行跨域推荐。

结合上述实施例及相关附图，本申请实施例提供了一种推荐方法，该方法可以在电子设备（例如手机、平板电脑等）中实现。图 20 是本申请实施例提供的推荐方法的示意性流程图，如图 20 所示，该方法 1200 可以包括以下步骤：

S1210，显示第一界面。

该第一界面可以包括至少一个应用程序的学习列表，该至少一个应用程序的学习列表中的第一应用程序的学习列表包括至少一个选项，该至少一个选项中的每个选项关联一个应用程序。

示例性地，如图 17 中的（b）图所示，第一界面可以为浏览器 APP 的跨域推荐管理界面 302。该跨域推荐管理界面 302 用于控制浏览器 APP 的跨域推荐功能的开启和关闭。

示例性地，如图 17 中的（b）图所示，第一应用程序的学习列表可以为浏览器 APP 的学习列表。

示例性地，如图 17 中的（b）图所示，该至少一个选项可以与应用名称相同，例如“购物”选项、“地图”选项、“健康”选项、“视频”选项等。该至少一个选项中的每个选项关联一个应用程序，与应用相关联的选项用于控制在该应用程序中学习用户的行为的功能的开启和关闭。换言之，与应用相关联的选项用于控制是否允许第一应用程序获取该应用程序的数据以进行跨域推荐。

S1220，感知到用户在第一界面上的第一操作。

第一操作可以为点击操作、双击操作、长按操作或滑动操作等。

S1230，响应于第一操作，打开或关闭第一应用程序在第一应用程序的学习列表中部分或全部选项所关联的应用程序中的跨域推荐功能。

也就是说，允许第一应用程序在部分或全部选项所关联的应用程序中获取用户行为数据，学习在该应用程序中的用户的偏好，以在第一应用程序中为用户进行推荐。

第一操作后，用户可以从界面上看出第一应用程序的跨域推荐功能处于打开状态或关闭状态。

在一个实施例中，第一操作作用于第一选项，响应于用户对第一选项的第一操作，打开或关闭第一应用程序在第一选项所关联的应用程序中的跨域推荐功能；其中，第一选项位于第一应用程序的学习列表中。

示例性地，如图 17 中的（c）图所示，该第一选项可以为第一界面上的“音乐”选项。应理解，该第一选项可以为第一界面上第一应用程序的学习列表中的任意一个与应用相关联的选项，例如“音乐”选项、“购物”选项、“浏览器”选项等等。

示例性的，如图 17 中的（c）图所示，该第一操作可以是对第一选项所对应的开关控件的打开或关闭操作。例如当第一选项所对应的开关控件处于打开状态时，第一操作可以

用于将第一选项所对应的开关控件关闭，相应地，关闭了第一应用程序在第一选项所关联的应用程序中进行跨域推荐的功能。例如，当第一选项所对应的开关控件处于关闭状态时，第一操作可以用于将第一选项所对应的开关控件打开，相应地，打开了第一应用程序在第一选项所关联的应用程序中进行跨域推荐的功能。这样，用户可以单独控制第一应用程序

5 在其他每个应用程序中的跨域推荐功能的开和关。

一个实施例中，第一操作作用于第一应用程序的学习列表对应的开关控件，响应于用户对开关控件的第一操作，打开或关闭第一应用程序在第一应用程序的学习列表中全部选项所关联的应用程序中的跨域推荐功能。

示例性地，如图 17 中的 (b) 图所示，该第一操作可以是对允许跨域推荐控件的关闭操作。可选地，若允许跨域推荐控件在第一操作之前处于关闭状态，则第一操作可以是对允许跨域推荐控件的打开操作。这样，用户可以整体控制第一应用程序的跨域推荐功能，提高管理效率，提升用户体验。

10

一个实施例中，方法 1200 还包括：显示第二界面，所述第二界面用于呈现一个或多个推荐对象以及所述一个或多个推荐对象的提示信息，所述一个或多个推荐对象的提示信息用于指示所述一个或多个推荐对象是基于所述至少一个应用程序中的应用程序中的用户行为数据确定的。

15

示例性地，如图 18 中的 (a) 图所示，第二界面可以为浏览器 APP 的主界面 303。

示例性地，如图 18 中的 (b) 图所示，第二界面可以为浏览器 APP 的主界面 304。

示例性地，如图 18 所示，该提示信息可以用于提示用户当前推荐内容是基于视频 APP 的数据得到的。

20

一个实施例中，一个或多个推荐对象是通过将用户的信息和候选推荐对象的信息输入推荐模型中，预测用户对候选推荐对象有操作动作的概率确定的。

例如，将该视频 APP 中的用户行为数据作为源域的数据，将浏览器 APP 中的用户行为作为目标域的数据，执行前述方法 1100 可得到推荐模型，利用该推荐模型可以预测用户对候选推荐对象有操作动作的概率，基于该概率值确定推荐内容，进而显示如图 14 所示的内容。

25

在一个实施例中，推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络进行训练得到，有偏数据集中包括有偏置的样本，无偏数据集中包括无偏置的样本，第一蒸馏方式是根据样本集的数据特征确定的，有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第一用户是否对第一推荐对象有操作动作，无偏数据集中的样本包括第二用户的信息和第二推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第二用户是否对第二推荐对象有操作动作。

30

例如，当用户允许第一应用程序开启跨域推荐功能时，第一应用程序可以从第一选项关联的应用程序中获取用户行为数据，将第一选择关联的应用程序中的用户行为数据作为源域的数据。应理解，源域的数据还可以包括其他应用中的用户行为数据。例如，当用户允许第一应用程序在第一应用程序的学习列表中的所有选项关联的应用程序中进行跨域学

35

习时，第一应用程序可以从所有选项关联的应用程序中获取用户行为数据，并将获取到的用户行为数据均作为源域的数据。

示例性地，推荐模型可以采用前述图 6 训练得到的更新后的第一神经网络。具体描述可以参见前述图 6 所示的方法的步骤，此处不再赘述。

- 5 一个实施例中，在显示第一界面之前，还包括：显示第三界面，该第三界面包括至少一个应用对应的开关控件；在第三界面上检测用户对该至少一个应用程序对应的开关控件中的第一应用程序的开关控件的第三操作；响应于该第三操作，显示第一界面。

示例性地，如图 17 中的 (a) 图所示，第三界面可以为设置应用程序主界面 301。

- 10 示例性的，如图 17 中的 (a) 图所示，第一应用程序的开关控件可以为浏览器 APP 的跨域推荐管理控件。

示例性的，如图 17 中的 (a) 图所示，该第三操作可以是对第一应用程序对应的开关控件的点击操作，响应于该点击操作，显示如图 17 中的 (b) 所示的界面。

- 15 根据本申请实施例中的方案，通过在不同域间进行知识（例如，用户的兴趣偏好）进行迁移和共享，将源域和目标域的用户交互历史记录都纳入到学习中，以使推荐模型能够更好地学习用户的偏好，使推荐模型在目标域也能很好的拟合用户的兴趣偏好，给用户推荐符合其兴趣的推荐结果，实现跨域推荐，缓解冷启动问题。

前述对本申请提供的神经网络蒸馏方法以及推荐方法的流程进行了详细介绍，下面结合前述的方法的流程，对本申请提供的装置进行说明。

参阅图 21，本申请提供的一种神经网络蒸馏装置的结构示意图。

- 20 该神经网络蒸馏装置可以包括：

采集模块 2101，用于样本集，样本集包括获取有偏数据集和无偏数据集，有偏数据集中包括有偏置的样本，无偏数据集中包括无偏置的样本，通常，有偏数据集的样本量大于无偏数据集的样本量；

- 25 决策模块 2102，用于根据样本集的数据特征确定第一蒸馏方式，其中，不同的蒸馏方式在进行知识蒸馏时老师模型对学生模型的指导方式不相同，老师模型是使用无偏数据集训练得到的，学生模型是使用有偏数据集训练得到；

训练模块 2103，用于基于有偏数据集和无偏数据集，按照第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络。

- 30 在一种可能的实施方式中，样本集中的样本包括输入特征和实际标签，第一蒸馏方式为基于有偏数据集和无偏数据集中的样本的输入特征进行蒸馏。

在一种可能的实施方式中，训练模块 2103，具体用于交替使用有偏数据集和无偏数据集对第一神经网络进行训练，得到更新后的第一神经网络，其中，在一个交替过程中，使用有偏数据集对第一神经网络进行训练的批训练次数，和使用无偏数据集对第一神经网络进行训练的批训练次数为预设比例，且样本包括输入特征作为第一神经网络的输入。

- 35 在一种可能的实施方式中，当预设比例为 1 时，在第一神经网络的损失函数中增加第一正则项和第二正则项的差值，第一正则项是使用无偏数据集包括的样本对第一神经网络进行训练得到的参数，第二正则项是使用有偏数据集包括的样本对第一神经网络进行训练

得到的参数。

在一种可能的实施方式中，训练模块 2103，具体用于为有偏数据集中的样本设置置信度，置信度用于表示样本的偏置程度；基于有偏数据集、有偏数据集中的样本的置信度和无偏数据集，对第一神经网络进行训练，得到更新后的第一神经网络，且在对第一神经网络进行训练时样本包括输入特征作为第一神经网络的输入。

在一种可能的实施方式中，有偏数据集和无偏数据集所包括的样本包括输入特征和实际标签，第一蒸馏方式为基于无偏数据集所包括的样本的预测标签进行蒸馏，预测标签由更新后的第二神经网络针对无偏数据集中的样本输出，更新后的第二神经网络为使用无偏数据集对第二神经网络进行训练得到。

在一种可能的实施方式中，样本集中还包括未观测数据集，未观测数据集中包括多个未观测样本；训练模块 2103，具体用于：通过有偏数据集对第一神经网络进行训练，得到训练后的第一神经网络，以及通过无偏数据集对第二神经网络进行训练，得到更新后的第二神经网络；从样本集中采集多个样本，得到辅助数据集；使用辅助数据集，以数据集中样本的预测标签作为约束，更新训练后的第一神经网络，得到更新后的第一神经网络，数据集中样本的预测标签由更新后的第二神经网络输出。

在一种可能的实施方式中，训练模块 2103，具体用于：通过无偏数据集对第二神经网络进行训练，得到更新后的第二神经网络；通过更新后的第二神经网络输出有偏数据集中样本的预测标签；将样本的预测标签和样本的实际标签进行加权合并，得到样本的合并标签；使用样本的合并标签训练第一神经网络，得到更新后的第一神经网络。

在一种可能的实施方式中，决策模块 2102，具体用于计算无偏数据集的样本量和有偏数据集的样本量之间的第一比例，从多种蒸馏方式中选择与第一比例匹配的第一蒸馏方式，样本集的数据特征包括第一比例。

在一种可能的实施方式中，第一蒸馏方式包括：基于从无偏数据集中提取到的特征训练老师模型，并通过老师模型以及有偏数据集对学生模型进行知识蒸馏。

在一种可能的实施方式中，训练模块 2103，具体用于：通过预设算法输出无偏数据集的特征；根据无偏数据集的特征对第二神经网络进行训练，得到更新后的第二神经网络；将第二神经网络作为老师模型，第一神经网络作为学生模型，使用有偏数据集对第一神经网络进行知识蒸馏，得到更新后的第一神经网络。

在一种可能的实施方式中，训练模块 2103，具体用于：获取无偏数据集以及有偏数据集中所包括的特征维度数量；从多种蒸馏方式中选择与特征维度数量匹配的第一蒸馏方式，样本集的数据特征包括特征维度数量。

在一种可能的实施方式中，训练模块 2103，具体用于：通过无偏数据集更新第二神经网络，得到更新后的第二神经网络；将更新后的第二神经网络作为老师模型，第一神经网络作为学生模型，使用有偏数据集对第一神经网络进行知识蒸馏，得到更新后的第一神经网络。

在一种可能的实施方式中，根据有偏数据集所包括的数据或无偏数据集所包括的数据中的至少一种，决策模块 2102，具体用于：计算无偏数据集中包括的正样本的数量和负样

本的数量第二比例，从多种蒸馏方式中选择与第二比例匹配的第一蒸馏方式，样本集的数据特征包括第二比例；或者，计算有偏数据集中包括的正样本的数量和负样本的数量第三比例，从多种蒸馏方式中选择与第三比例匹配的第一蒸馏方式，样本集的数据特征包括第三比例。

- 5 在一种可能的实施方式中，有偏数据集包括的样本的类型，和无偏数据集包括的样本的类型不相同。

在一种可能的实施方式中，在得到更新后的第一神经网络之后，装置还包括：

- 10 输出模块 2104，用于获取目标用户的至少一个样本；将至少一个样本作为更新后的第一神经网络的输入，输出目标用户的至少一个标签，至少一个标签组成目标用户的用户画像，该用户画像用于确定与目标用户匹配的样本。

请参阅图 22，本申请提供一种推荐装置的结构示意图，如下所述。

获取单元 2201，用于获取目标用户的信息和候选推荐对象的信息；

处理单元 2202，用于将目标用户的信息和候选推荐对象的信息输入至推荐模型，预测目标用户对候选推荐对象有操作动作的概率；

- 15 其中，推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络进行训练得到，有偏数据集中包括有偏置的样本，无偏数据集中包括无偏置的样本，第一蒸馏方式是根据样本集的数据特征确定的，有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第一用户是否对第一推荐对象有操作动作，无偏数据集中的样本包括第二用户的信息和第二推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第二用户是否对第二推荐对象有操作动作。
- 20

在一种可能的实施方式中，无偏数据集是在候选推荐对象集合中的候选推荐对象被展示的概率相同的情况下获得的，第二推荐对象为候选推荐对象集合中的一个候选推荐对象。

- 25 在一种可能的实施方式中，无偏数据集是在候选推荐对象集合中的候选推荐对象被展示的概率相同的情况下获得的，可以包括：无偏数据集中的样本是在候选推荐对象集合中的候选推荐对象被随机展示给第二用户的情况下获得的；或者无偏数据集中的样本是在第二用户搜索第二推荐对象的情况下获得的。

在一种可能的实施方式中，无偏数据集中的样本属于源域的数据，有偏数据集中的样本属于目标域的数据。

- 30 请参阅图 23，本申请提供一种电子设备的结构示意图，如下所述。

显示单元 2301，显示单元用于显示第一界面，第一界面包括至少一个应用程序的学习列表，该至少一个应用程序的学习列表中的第一应用程序的学习列表包括至少一个选项，至少一个选项中的选项关联一个应用程序；

处理单元 2302，处理单元用于感知到用户在第一界面上的第一操作；

- 35 显示单元还用于响应于第一操作，打开或关闭第一应用程序在第一应用程序的学习列表中部分或全部选项所关联的应用程序中的跨域推荐功能。

在一种可能的实施方式中，一个或多个推荐对象是通过将用户的信息和候选推荐对象

的信息输入推荐模型中，预测用户对候选推荐对象有操作动作的概率确定的。

在一种可能的实施方式中，推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络进行训练得到，有偏数据集中包括有偏置的样本，无偏数据集中包括无偏置的样本，第一蒸馏方式是根据样本集的数据特征确定的，有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第一用户是否对第一推荐对象有操作动作，无偏数据集中的样本包括第二用户的信息和第二推荐对象的信息以及实际标签，无偏数据集中的样本的实际标签用于表示第二用户是否对第二推荐对象有操作动作。

请参阅图 24，本申请提供的另一种神经网络蒸馏装置的结构示意图，如下所述。

10 该神经网络蒸馏装置可以包括处理器 2401 和存储器 2402。该处理器 2401 和存储器 2402 通过线路互联。其中，存储器 2402 中存储有程序指令和数据。

存储器 2402 中存储了前述图 6 中的步骤对应的程序指令以及数据。

处理器 2401 用于执行前述图 6 中任一实施例所示的神经网络蒸馏装置执行的方法步骤。

可选地，该神经网络蒸馏装置还可以包括收发器 2403，用于接收或者发送数据。

15 本申请实施例中还提供一种计算机可读存储介质，该计算机可读存储介质中存储有用于程序，当其在计算机上运行时，使得计算机执行如前述图 6 所示实施例描述的方法中的步骤。

可选地，前述的图 24 中所示的神经网络蒸馏装置为芯片。

请参阅图 25，本申请提供的另一种推荐装置的结构示意图，如下所述。

20 该推荐装置可以包括处理器 2501 和存储器 2502。该处理器 2501 和存储器 2502 通过线路互联。其中，存储器 2502 中存储有程序指令和数据。

存储器 2502 中存储了前述图 11 中的步骤对应的程序指令以及数据。

处理器 2501 用于执行前述图 11 中任一实施例所示的推荐装置执行的方法步骤。

可选地，该推荐装置还可以包括收发器 2503，用于接收或者发送数据。

25 本申请实施例中还提供一种计算机可读存储介质，该计算机可读存储介质中存储有程序，当其在计算机上运行时，使得计算机执行如前述图 11 所示实施例描述的方法中的步骤。

可选地，前述的图 25 中所示的推荐装置为芯片。

请参阅图 26，本申请提供的另一种电子设备的结构示意图，如下所述。

30 该电子设备可以包括处理器 2601 和存储器 2602。该处理器 2601 和存储器 2602 通过线路互联。其中，存储器 2602 中存储有程序指令和数据。

存储器 2602 中存储了前述图 20 中的步骤对应的程序指令以及数据。

处理器 2601 用于执行前述图 20 所示的电子设备执行的方法步骤。

可选地，该电子设备还可以包括收发器 2603，用于接收或者发送数据。

35 本申请实施例中还提供一种计算机可读存储介质，该计算机可读存储介质中存储有程序，当其在计算机上运行时，使得计算机执行如前述图 20 所示实施例描述的方法中的步骤。

可选地，前述的图 26 中所示的电子设备为芯片。

本申请实施例还提供了一种神经网络蒸馏装置，该神经网络蒸馏装置也可以称为数字

处理芯片或者芯片，芯片包括处理单元和通信接口，处理单元通过通信接口获取程序指令，程序指令被处理单元执行，处理单元用于执行前述图 6-图 20 的方法步骤。

本申请实施例还提供一种数字处理芯片。该数字处理芯片中集成了用于实现上述处理器 2401、处理器 2501、处理器 2601，或者处理器 2301、处理器 2501、处理器 2601 的功能的电路和一个或者多个接口。当该数字处理芯片中集成了存储器时，该数字处理芯片可以完成前述实施例中的任一个或多个实施例的方法步骤。当该数字处理芯片中未集成存储器时，可以通过通信接口与外置的存储器连接。该数字处理芯片根据外置的存储器中存储的程序代码来实现上述实施例中神经网络蒸馏装置、推荐装置或者电子设备执行的动作。

本申请实施例中还提供一种包括计算机程序产品，当其在计算机上行驶时，使得计算机执行如前述图 6-图 20 所示实施例描述的方法的步骤。

本申请实施例提供的神经网络蒸馏装置可以为芯片，芯片包括：处理单元和通信单元，所述处理单元例如可以是处理器，所述通信单元例如可以是输入/输出接口、管脚或电路等。该处理单元可执行存储单元存储的计算机执行指令，以使服务器内的芯片执行上述图 6-图 10 所示实施例描述的训练集处理方法。可选地，所述存储单元为所述芯片内的存储单元，如寄存器、缓存等，所述存储单元还可以是所述无线接入设备端内的位于所述芯片外部的存储单元，如只读存储器 (read-only memory, ROM) 或可存储静态信息和指令的其他类型的静态存储设备，随机存取存储器 (random access memory, RAM) 等。

具体地，前述的处理单元或者处理器可以是中央处理器 (central processing unit, CPU)、网络处理器 (neural-network processing unit, NPU)、图形处理器 (graphics processing unit, GPU)、数字信号处理器 (digital signal processor, DSP)、专用集成电路 (application specific integrated circuit, ASIC) 或现场可编程逻辑门阵列 (field programmable gate array, FPGA) 或者其他可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件等。通用处理器可以是微处理器或者也可以是任何常规的处理器等。

示例性地，请参阅图 27，图 27 为本申请实施例提供的芯片的一种结构示意图，所述芯片可以表现为神经网络处理器 NPU 270，NPU 270 作为协处理器挂载到主 CPU (Host CPU) 上，由 Host CPU 分配任务。NPU 的核心部分为运算电路 2703，通过控制器 2704 控制运算电路 2703 提取存储器中的矩阵数据并进行乘法运算。

在一些实现中，运算电路 2703 内部包括多个处理单元 (process engine, PE)。在一些实现中，运算电路 2703 是二维脉动阵列。运算电路 2703 还可以是一维脉动阵列或者能够执行例如乘法和加法这样的数学运算的其它电子线路。在一些实现中，运算电路 2703 是通用的矩阵处理器。

举例来说，假设有输入矩阵 A，权重矩阵 B，输出矩阵 C。运算电路从权重存储器 2702 中取矩阵 B 相应的数据，并缓存在运算电路中每一个 PE 上。运算电路从输入存储器 2701 中取矩阵 A 数据与矩阵 B 进行矩阵运算，得到的矩阵的部分结果或最终结果，保存在累加器 (accumulator) 2708 中。

统一存储器 2706 用于存放输入数据以及输出数据。权重数据直接通过存储单元访问控

制器 (direct memory access controller, DMAC) 2705, DMAC 被搬运到权重存储器 2702 中。输入数据也通过 DMAC 被搬运到统一存储器 2706 中。

总线接口单元 (bus interface unit, BIU) 2710, 用于 AXI 总线与 DMAC 和取指存储器 (instruction fetch buffer, IFB) 2709 的交互。

- 5 总线接口单元 2710 (bus interface unit, BIU), 用于取指存储器 2709 从外部存储器获取指令, 还用于存储单元访问控制器 2705 从外部存储器获取输入矩阵 A 或者权重矩阵 B 的原数据。

DMAC 主要用于将外部存储器 DDR 中的输入数据搬运到统一存储器 2706 或将权重数据搬运到权重存储器 2702 中或将输入数据数据搬运到输入存储器 2701 中。

- 10 向量计算单元 2707 包括多个运算处理单元, 在需要的情况下, 对运算电路的输出做进一步处理, 如向量乘, 向量加, 指数运算, 对数运算, 大小比较等等。主要用于神经网络中非卷积/全连接层网络计算, 如批归一化(batch normalization), 像素级求和, 对特征平面进行上采样等。

- 在一些实现中, 向量计算单元 2707 能将经处理的输出的向量存储到统一存储器 2706。
15 例如, 向量计算单元 2707 可以将线性函数和/或非线性函数应用到运算电路 2703 的输出, 例如对卷积层提取的特征平面进行线性插值, 再例如累加值的向量, 用以生成激活值。在一些实现中, 向量计算单元 2707 生成归一化的值、像素级求和的值, 或二者均有。在一些实现中, 处理过的输出的向量能够用作到运算电路 2703 的激活输入, 例如用于在神经网络中的后续层中的使用。

- 20 控制器 2704 连接的取指存储器 (instruction fetch buffer) 2709, 用于存储控制器 2704 使用的指令;

统一存储器 2706, 输入存储器 2701, 权重存储器 2702 以及取指存储器 2709 均为 On-Chip 存储器。外部存储器私有于该 NPU 硬件架构。

其中, 循环神经网络中各层的运算可以由运算电路 2703 或向量计算单元 2707 执行。

- 25 其中, 上述任一处提到的处理器, 可以是一个通用中央处理器, 微处理器, ASIC, 或一个或多个用于控制上述图 6-图 20 的方法的程序执行的集成电路。

- 另外需说明的是, 以上所描述的装置实施例仅仅是示意性的, 其中所述作为分离部件说明的单元可以是或者也可以不是物理上分开的, 作为单元显示的部件可以是或者也可以不是物理单元, 即可以位于一个地方, 或者也可以分布到多个网络单元上。可以根据实际的需要选择其中的部分或者全部模块来实现本实施例方案的目的。另外, 本申请提供的装置实施例附图中, 模块之间的连接关系表示它们之间具有通信连接, 具体可以实现为一条或多条通信总线或信号线。

- 通过以上的实施方式的描述, 所属领域的技术人员可以清楚地了解到本申请可借助软件加必需的通用硬件的方式来实现, 当然也可以通过专用硬件包括专用集成电路、专用 CPU、
35 专用存储器、专用元器件等来实现。一般情况下, 凡由计算机程序完成的功能都可以很容易地用相应的硬件来实现, 而且, 用来实现同一功能的具体硬件结构也可以是多种多样的, 例如模拟电路、数字电路或专用电路等。但是, 对本申请而言更多情况下软件程序实现是

5 更佳的实施方式。基于这样的理解，本申请的技术方案本质上或者说对现有技术做出贡献的部分可以以软件产品的形式体现出来，该计算机软件产品存储在可读取的存储介质中，如计算机的软盘、U 盘、移动硬盘、只读存储器（read only memory, ROM）、随机存取存储器（random access memory, RAM）、磁碟或者光盘等，包括若干指令用以使得一台计算机设备（可以是个人计算机，服务器，或者网络设备等）执行本申请各个实施例所述的方法。

在上述实施例中，可以全部或部分地通过软件、硬件、固件或者其任意组合来实现。当使用软件实现时，可以全部或部分地以计算机程序产品的形式实现。

10 所述计算机程序产品包括一个或多个计算机指令。在计算机上加载和执行所述计算机程序指令时，全部或部分地产生按照本申请实施例所述的流程或功能。所述计算机可以是通用计算机、专用计算机、计算机网络、或者其他可编程装置。所述计算机指令可以存储在计算机可读存储介质中，或者从一个计算机可读存储介质向另一计算机可读存储介质传输，例如，所述计算机指令可以从一个网站站点、计算机、服务器或数据中心通过有线（例如同轴电缆、光纤、数字用户线（DSL））或无线（例如红外、无线、微波等）方式向另一个网站站点、计算机、服务器或数据中心进行传输。所述计算机可读存储介质可以是计算机能够存储的任何可用介质或者是包含一个或多个可用介质集成的服务器、数据中心等数据存储设备。所述可用介质可以是磁性介质，（例如，软盘、硬盘、磁带）、光介质（例如，15 DVD）、或者半导体介质（例如固态硬盘（solid state disk, SSD））等。

20 本申请的说明书和权利要求书及上述附图中的术语“第一”、“第二”、“第三”、“第四”等（如果存在）是用于区别类似的对象，而不必用于描述特定的顺序或先后次序。应该理解这样使用的数据在适当情况下可以互换，以便这里描述的实施例能够以除了在这里图示或描述的内容以外的顺序实施。此外，术语“包括”和“具有”以及他们的任何变形，意图在于覆盖不排他的包含，例如，包含了一系列步骤或单元的过程、方法、系统、产品或设备不必限于清楚地列出的那些步骤或单元，而是可包括没有清楚地列出的或对于这些过程、方法、产品或设备固有的其它步骤或单元。

25 最后应说明的是：以上，仅为本申请的具体实施方式，但本申请的保护范围并不局限于此，任何熟悉本技术领域的技术人员在本申请揭露的技术范围内，可轻易想到变化或替换，都应涵盖在本申请的保护范围之内。因此，本申请的保护范围应以权利要求的保护范围为准。

权 利 要 求

1、一种神经网络蒸馏方法，其特征在于，包括：

获取样本集，所述样本集包括有偏数据集和无偏数据集，所述有偏数据集中包括有偏置的样本，所述无偏数据集中包括无偏置的样本；

根据所述样本集的数据特征确定第一蒸馏方式，其中，在所述第一蒸馏方式中，使用所述无偏数据集训练老师模型，使用所述有偏数据集训练学生模型；

基于所述有偏数据集和所述无偏数据集，按照所述第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络。

10

2、根据权利要求1所述的方法，其特征在于，所述样本集的样本包括输入特征和实际标签，所述第一蒸馏方式为使用所述样本集中的样本的输入特征进行蒸馏。

3、根据权利要求2所述的方法，其特征在于，所述基于所述有偏数据集和所述无偏数据集，按照所述第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，包括：

交替使用所述有偏数据集和所述无偏数据集对所述第一神经网络进行训练，得到所述更新后的第一神经网络，其中，在一个交替过程中，使用所述有偏数据集对所述第一神经网络进行训练的批训练次数，和使用所述无偏数据集对所述第一神经网络进行训练的批训练次数为预设比例，且所述样本集中的样本的输入特征作为所述第一神经网络的输入。

4、根据权利要求2所述的方法，其特征在于，所述基于所述有偏数据集和所述无偏数据集，按照所述第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，包括：

为所述有偏数据集中的样本设置置信度，所述置信度用于表示所述样本的偏置程度；
基于所述有偏数据集、所述有偏数据集中的样本的置信度和所述无偏数据集，对第一神经网络进行训练，得到所述更新后的第一神经网络，且在对所述第一神经网络进行训练时所述样本包括输入特征作为所述第一神经网络的输入。

5、根据权利要求1所述的方法，其特征在于，所述第一蒸馏方式为基于所述无偏数据集所包括的样本的预测标签进行蒸馏，所述预测标签由更新后的第二神经网络针对所述无偏数据集中的样本输出，所述更新后的第二神经网络为使用所述无偏数据集对第二神经网络进行训练得到。

6、根据权利要求5所述的方法，其特征在于，所述样本集中还包括未观测数据集，所述未观测数据集中包括多个未观测样本；

所述基于所述有偏数据集和所述无偏数据集，按照所述第一蒸馏方式对第一神经网络

35

进行训练，得到更新后的第一神经网络，包括：

通过所述有偏数据集对第一神经网络进行训练，得到训练后的第一神经网络，以及通过所述无偏数据集对第二神经网络进行训练，得到所述更新后的第二神经网络；

从所述样本集中采集多个样本，得到辅助数据集；

- 5 使用所述辅助数据集，以所述辅助数据集中样本的预测标签作为约束，更新所述训练后的第一神经网络，得到所述更新后的第一神经网络，所述数据集中样本的预测标签包括所述更新后的第二神经网络输出的标签。

- 7、根据权利要求 5 所述的方法，其特征在于，所述基于所述有偏数据集和所述无偏数据集，按照所述第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，包括：

通过所述无偏数据集对第二神经网络进行训练，得到所述更新后的第二神经网络；

通过所述更新后的第二神经网络输出所述有偏数据集中样本的预测标签；

将样本的预测标签和样本的实际标签进行加权合并，得到所述样本的合并标签；

- 15 使用所述样本的合并标签训练所述第一神经网络，得到所述更新后的第一神经网络。

8、根据权利要求 2-7 中任一项所述的方法，其特征在于，所述样本集的数据特征包括所述第一比例，所述第一比例为所述无偏数据集的样本量和所述有偏数据集的样本量之间的比例，所述根据所述样本集的数据特征确定第一蒸馏方式，包括：

从多种蒸馏方式中选择与所述第一比例匹配的所述第一蒸馏方式。

20

9、根据权利要求 1 所述的方法，其特征在于，所述第一蒸馏方式包括：基于从所述无偏数据集中提取到的特征训练所述老师模型，得到训练后的所述老师模型，并通过训练后的所述老师模型以及所述有偏数据集对所述学生模型进行知识蒸馏。

- 25 10、根据权利要求 9 所述的方法，其特征在于，所述基于所述有偏数据集和所述无偏数据集，按照所述第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络，包括：

通过深度全局平衡回归 DGBR 算法从所述无偏数据集中筛选出部分样本的输入特征；

根据所述部分样本的输入特征对第二神经网络进行训练，得到更新后的第二神经网络；

- 30 将更新后的所述第二神经网络作为所述老师模型，所述第一神经网络作为所述学生模型，使用所述有偏数据集对所述第一神经网络进行知识蒸馏，得到所述更新后的第一神经网络。

- 11、根据权利要求 9 或 10 所述的方法，其特征在于，所述样本集的数据特征包括所述样本集的特征维度数量，所述根据所述样本集的数据特征确定第一蒸馏方式，包括：

从多种蒸馏方式中选择与所述特征维度数量匹配的所述第一蒸馏方式。

35

12、根据权利要求 1-11 中任一项所述的方法，其特征在于，所述第一蒸馏方式是从预设的多种蒸馏方式中选择得到，所述多种蒸馏方式中包括所述老师模型对所述学生模型的指导方式不相同的至少两种蒸馏方式。

5 13、一种推荐方法，其特征在于，包括：

获取目标用户的信息和候选推荐对象的信息；

将所述目标用户的信息和所述候选推荐对象的信息输入至推荐模型，预测所述目标用户对所述候选推荐对象有操作动作的概率；

10 其中，所述推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络进行训练得到，所述有偏数据集中包括有偏置的样本，所述无偏数据集中包括无偏置的样本，所述第一蒸馏方式是根据所述样本集的数据特征确定的，所述有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，所述无偏数据集中的样本的实际标签用于表示所述第一用户是否对所述第一推荐对象有操作动作，所述无偏数据集中的样本包括第二用户的信息和第二推荐对象的信息以及实际标签，所述无偏数据集中的样本的实际标签用于表示所述第二用户是否对所述第二推荐对象有操作动作。

15 14、根据权利要求 13 所述的方法，其特征在于，所述无偏数据集是在候选推荐对象集合中的所述候选推荐对象被展示的概率相同的情况下获得的，所述第二推荐对象为所述候选推荐对象集合中的一个候选推荐对象。

20 15、根据权利要求 14 所述的方法，其特征在于，所述无偏数据集是在候选推荐对象集合中的所述候选推荐对象被展示的概率相同的情况下获得的，包括：

所述无偏数据集中的样本是在所述候选推荐对象集合中的候选推荐对象被随机展示给所述第二用户的情况下获得的；

或者所述无偏数据集中的样本是在所述第二用户搜索所述第二推荐对象的情况下获得的。

25 16、一种推荐方法，其特征在于，包括：显示第一界面，所述第一界面包括至少一个应用程序的学习列表，所述该至少一个应用程序的学习列表中的第一应用程序的学习列表包括至少一个选项，所述至少一个选项中的选项关联一个应用程序；

感知到用户在所述第一界面上的第一操作；

30 响应于所述第一操作，打开或关闭所述第一应用程序在所述第一应用程序的学习列表中部分或全部选项所关联的应用程序中的跨域推荐功能。

17、根据权利要求 16 所述的方法，其特征在于，所述一个或多个推荐对象是通过将所述用户的信息和候选推荐对象的信息输入推荐模型中，预测所述用户对所述候选推荐对象有操作动作的概率确定的。

35 18、根据权利要求 17 所述的方法，其特征在于，所述推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络进行训练得到，所述有偏数据集中包括有偏置的样本，所述无偏数据集中包括无偏置的样本，所述第一蒸馏方式是根据所述

—46—

样本集的数据特征确定的，所述有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，所述无偏数据集中的样本的实际标签用于表示所述第一用户是否对所述第一推荐对象有操作动作，所述无偏数据集中的样本包括第二用户的信息和第二推荐对象的信息以及实际标签，所述无偏数据集中的样本的实际标签用于表示所述第二用户是否对所述第二推荐对象有操作动作。

19、一种神经网络蒸馏装置，其特征在于，包括：

采集模块，用于获取样本集，所述样本集包括有偏数据集和无偏数据集，所述有偏数据集中包括有偏置的样本，所述无偏数据集中包括无偏置的样本；

10 决策模块，用于根据所述样本集的数据特征确定第一蒸馏方式，其中，在所述第一蒸馏方式中，老师模型是使用所述无偏数据集训练得到的，学生模型是使用所述有偏数据集训练得到；

训练模块，用于基于所述有偏数据集和所述无偏数据集，按照所述第一蒸馏方式对第一神经网络进行训练，得到更新后的第一神经网络。

15

20、根据权利要求 19 所述的装置，其特征在于，所述样本集中的样本包括输入特征和实际标签，所述第一蒸馏方式为使用所述样本集中的样本的输入特征进行蒸馏。

21、根据权利要求 20 所述的装置，其特征在于，

20 所述训练模块，具体用于交替使用所述有偏数据集和所述无偏数据集对所述第一神经网络进行训练，得到所述更新后的第一神经网络，其中，在一个交替过程中，使用所述有偏数据集对所述第一神经网络进行训练的批训练次数，和使用所述无偏数据集对所述第一神经网络进行训练的批训练次数为预设比例，且所述样本集中的样本的输入特征作为所述第一神经网络的输入。

25

22、根据权利要求 20 所述的装置，其特征在于，

所述训练模块，具体用于为所述有偏数据集中的样本设置置信度，所述置信度用于表示所述样本的偏置程度；基于所述有偏数据集、所述有偏数据集中的样本的置信度和所述无偏数据集，对第一神经网络进行训练，得到所述更新后的第一神经网络，且在对所述第一神经网络进行训练时所述样本包括输入特征作为所述第一神经网络的输入。

30

23、根据权利要求 19 所述的装置，其特征在于，所述第一蒸馏方式为基于所述无偏数据集所包括的样本的预测标签进行蒸馏，所述预测标签由更新后的第二神经网络针对所述无偏数据集中的样本输出，所述更新后的第二神经网络为使用所述无偏数据集对第二神经网络进行训练得到。

35

24、根据权利要求 23 所述的装置，其特征在于，所述样本集中还包括未观测数据集，

所述未观测数据集中包括多个未观测样本；

所述训练模块，具体用于：

通过所述有偏数据集对第一神经网络进行训练，得到训练后的第一神经网络，以及通过所述无偏数据集对第二神经网络进行训练，得到所述更新后的第二神经网络；

5 从所述样本集中采集多个样本，得到辅助数据集；

使用所述辅助数据集，以所述辅助数据集中样本的预测标签作为约束，更新所述训练后的第一神经网络，得到所述更新后的第一神经网络，所述辅助数据集中样本的预测标签包括所述更新后的第二神经网络输出的标签。

10 25、根据权利要求 23 所述的装置，其特征在于，所述训练模块，具体用于：

通过所述无偏数据集对第二神经网络进行训练，得到所述更新后的第二神经网络；

通过所述更新后的第二神经网络输出所述有偏数据集中样本的预测标签；

将样本的预测标签和样本的实际标签进行加权合并，得到所述样本的合并标签；

使用所述样本的合并标签训练所述第一神经网络，得到所述更新后的第一神经网络。

15 26、根据权利要求 20-25 中任一项所述的装置，其特征在于，所述样本集的数据特征包括所述第一比例，所述第一比例为所述无偏数据集的样本量和所述有偏数据集的样本量之间的比例；

所述决策模块，具体用于从多种蒸馏方式中选择与所述第一比例匹配的所述第一蒸馏方式。

20

27、根据权利要求 19 所述的装置，其特征在于，所述第一蒸馏方式包括：基于从所述无偏数据集中提取到的特征训练所述老师模型，得到训练后的所述老师模型，并通过训练后的所述老师模型以及所述有偏数据集对所述学生模型进行知识蒸馏。

25 28、根据权利要求 27 所述的装置，其特征在于，所述训练模块，具体用于：

通过深度全局平衡回归 DGBR 算法从所述无偏数据集中筛选出部分样本的输入特征；

根据所述部分样本的输入特征对第二神经网络进行训练，得到更新后的第二神经网络；

将所述第二神经网络作为所述老师模型，所述第一神经网络作为所述学生模型，使用所述有偏数据集对所述第一神经网络进行知识蒸馏，得到所述更新后的第一神经网络。

30

29、根据权利要求 27 或 28 所述的装置，其特征在于，所述样本集的数据特征包括所述样本集的特征维度数量，所述训练模块，具体用于：

从多种蒸馏方式中选择与所述特征维度数量匹配的所述第一蒸馏方式。

30、根据权利要求 19-29 中任一项所述的装置，其特征在于，

35 所述第一蒸馏方式是从预设的多种蒸馏方式中选择得到，所述多种蒸馏方式包括所述老师模型对所述学生模型的指导方式不相同的至少两种蒸馏方式。

31、一种推荐装置，其特征在于，包括：

获取单元，用于获取目标用户的信息和候选推荐对象的信息；

处理单元，用于将所述目标用户的信息和所述候选推荐对象的信息输入至推荐模型，预测所述目标用户对所述候选推荐对象有操作动作的概率；

5 其中，所述推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络进行训练得到，所述有偏数据集中包括有偏置的样本，所述无偏数据集中包括无偏置的样本，所述第一蒸馏方式是根据所述样本集的数据特征确定的，所述有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，所述无偏数据集中的样本的实际标签用于表示所述第一用户是否对所述第一推荐对象有操作动作，所述无偏数据集中的样本包括第二用户的信息和第二推荐对象的信息以及实际标签，所述无偏数据集中的样本的实际标签用于表示所述第二用户是否对所述第二推荐对象有操作动作。

32、如权利要求 31 所述的装置，其特征在于，所述无偏数据集是在候选推荐对象集中的所述候选推荐对象被展示的概率相同的情况下获得的，所述第二推荐对象为所述候选推荐对象集合中的一个候选推荐对象。

15 33、根据权利要求 32 所述的装置，其特征在于，所述无偏数据集是在候选推荐对象集中的所述候选推荐对象被展示的概率相同的情况下获得的，包括：

所述无偏数据集中的样本是在所述候选推荐对象集合中的候选推荐对象被随机展示给所述第二用户的情况下获得的；

20 或者所述无偏数据集中的样本是在所述第二用户搜索所述第二推荐对象的情况下获得的。

34、一种电子设备，其特征在于，包括：

25 显示单元，所述显示单元用于显示第一界面，所述第一界面包括至少一个应用程序的学习列表，所述该至少一个应用程序的学习列表中的第一应用程序的学习列表包括至少一个选项，所述至少一个选项中的选项关联一个应用程序；

处理单元，所述处理单元用于感知到用户在所述第一界面上的第一操作；

所述显示单元还用于响应于所述第一操作，打开或关闭所述第一应用程序在所述第一应用程序的学习列表中部分或全部选项所关联的应用程序中的跨域推荐功能。

30 35、根据权利要求 34 所述的电子设备，其特征在于，所述一个或多个推荐对象是通过将所述用户的信息和候选推荐对象的信息输入推荐模型中，预测所述用户对所述候选推荐对象有操作动作的概率确定的。

36、如权利要求 35 所述的电子设备，其特征在于，所述推荐模型是使用样本集中的有偏数据集和无偏数据集按照第一蒸馏方式对第一神经网络进行训练得到，所述有偏数据集中包括有偏置的样本，所述无偏数据集中包括无偏置的样本，所述第一蒸馏方式是根据所述样本集的数据特征确定的，所述有偏数据集中的样本包括第一用户的信息和第一推荐对象的信息以及实际标签，所述无偏数据集中的样本的实际标签用于表示所述第一用户是否对所述第一推荐对象有操作动作，所述无偏数据集中的样本包括第二用户的信息和第二推

荐对象的信息以及实际标签，所述无偏数据集中的样本的实际标签用于表示所述第二用户是否对所述第二推荐对象有操作动作。

37、一种神经网络蒸馏装置，其特征在于，包括处理器，所述处理器和存储器耦合，
5 所述存储器存储有程序，当所述存储器存储的程序指令被所述处理器执行时实现权利要求 1 至 12 中任一项所述的方法。

38、一种推荐装置，其特征在于，包括至少一个处理器和存储器，所述至少一个处理器与
所述存储器耦合，用于读取并执行所述存储器中的指令，以执行如权利要求 13-15 中任一项所述
的推荐方法。

10 39、一种电子设备，其特征在于，包括：处理器；存储器；所述存储器存储一个或多个
计算机程序，所述一个或多个计算机程序包括指令，当所述指令被所述一个或多个处理器
执行时，使得所述电子设备执行如权利要求 16-18 中任一项所述的方法。

40、一种计算机可读存储介质，包括程序，当其被处理单元所执行时，执行如权利要
15 求 1 至 12、13-15 或者 16-18 中任一项所述的方法。