说　　明　　书

基于持续预训练的语言模型训练方法和装置

技术领域

本说明书实施例通常涉及计算机技术领域，尤其涉及基于持续预训练的语言模型训练方法和装置。

背景技术

预训练语言模型通常指在大规模语料库上进行无监督训练的语言模型（Language Models），它通过学习语言的通用特征，在各种自然语言处理（Language Models，NLP）任务，如文本分类、信息检索、命名实体识别、机器翻译、问答系统上都取得了突破性的成功。但预训练语言模型通常需要大量的训练语料，并拥有庞大的参数规模，传统的学习方法在面对新的数据时，需要从头重新训练模型，开销昂贵，无法有效实施。因此，如何使已有模型能够在学习新数据的同时保证预训练语言模型的泛化性且不遗忘过往知识成为需要解决的问题。

发明内容

鉴于上述，本说明书实施例提供了一种基于持续预训练的语言模型训练方法和装置。利用该方法、装置，可以实现有效提升预训练语言模型的训练效果。

根据本说明书的实施例的一个方面，提供一种基于持续预训练的语言模型训练方法，包括：利用当前领域的训练样本集循环执行下述模型训练过程，直到满足当前领域的训练结束条件，所述训练样本集中的每个训练样本包括文本数据：将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的软提示特征；将当前训练样本集中的各个文本数据和对应的软提示特征提供给当前语言模型，得到各个文本数据对应于当前领域的隐特征，其中，初始当前语言模型基于上一领域的训练样本集训练得到；基于所得到的各个文本数据对应于当前领域的隐特征与相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征之间的差异，确定跨域损失值；以及响应于不满足当前领域的训练结束条件，根据所述跨域损失值调整当前软提示生成模型和当前语言模型的模型参数，其中，经过模

型参数调整后的软提示生成模型和语言模型充当下一模型训练过程的当前软提示生成模型和当前语言模型；响应于满足所述当前领域的训练结束条件，继续利用下一领域的训练样本集重复执行上述利用该领域的训练样本集的模型训练过程，直至满足持续预训练的训练结束条件。

根据本说明书的实施例的另一个方面，提供一种语言处理模型的微调方法，所述语言处理模型包括微调软提示生成模型、微调语言模型和当前预测模型，所述方法包括：利用微调训练样本集循环执行下述模型微调过程，直到满足微调结束条件，所述微调训练样本集中的每个训练样本包括文本数据和与微调任务相关的标签数据：将所述当前微调训练样本集中的各个文本数据对应的文本隐特征提供给当前微调软提示生成模型，得到与各个当前训练样本对应的微调软提示特征；将当前微调训练样本集中的各个文本数据和对应的微调软提示特征提供给当前微调语言模型，得到各个文本数据对应的微调隐特征，其中，初始当前微调软提示生成模型和初始当前微调语言模型通过如上述的语言模型训练方法训练得到；将各个文本数据对应的微调隐特征提供给与微调任务相关的当前预测模型，得到各个文本数据对应的预测结果；基于所得到的各个文本数据对应的预测结果与标签数据之间的差异，确定当前模型微调过程的预测损失值；以及响应于不满足微调结束条件，根据所述预测损失值调整当前微调语言模型和当前预测模型的模型参数，其中，经过模型参数调整后的微调语言模型和预测模型充当下一模型训练过程的当前微调语言模型和当前预测模型。

根据本说明书的实施例的又一个方面，提供一种基于持续预训练的语言模型训练装置，所述语言模型训练装置被配置为由训练单元利用当前领域的训练样本集循环执行模型训练过程，直到满足当前领域的训练结束条件，训练样本集中的每个训练样本包括文本数据，所述训练单元在满足所述当前领域的训练结束条件的情况下继续利用下一领域的训练样本集重复执行模型训练过程，直至满足持续预训练的训练结束条件，所述训练单元包括：软提示生成模块，被配置为将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的软提示特征；隐特征生成模块，被配置为将当前训练样本集中的各个文本数据和对应的软提示特征提供给当前语言模型，得到各个文本数据对应于当前领域的隐特征，其中，初始当前语言模型基于上一领域的训练样本集训练得到；损失确定模块，被配置为基于所得到的各个文本数据对应于当前领域的隐特征与相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征之间的差异，确定跨域损失值；以及所述语言模型训练

装置还包括：参数调整单元，被配置为响应于不满足当前领域的训练结束条件，根据所述跨域损失值调整当前软提示生成模型和当前语言模型的模型参数，其中，经过模型参数调整后的软提示生成模型和语言模型充当下一模型训练过程的当前软提示生成模型和当前语言模型。

根据本说明书的实施例的再一个方面，提供一种语言处理模型的微调装置，其中，所述语言处理模型包括微调软提示生成模型、微调语言模型和当前预测模型，所述微调装置被配置为由训练单元利用微调训练样本集循环执行模型微调过程，直到满足微调结束条件，所述微调训练样本集中的每个训练样本包括文本数据和与微调任务相关的标签数据，所述训练单元包括：微调特征生成模块，被配置为将所述当前微调训练样本集中的各个文本数据对应的文本隐特征提供给当前微调软提示生成模型，得到与各个当前训练样本对应的微调软提示特征；将当前微调训练样本集中的各个文本数据和对应的微调软提示特征提供给当前微调语言模型，得到各个文本数据对应的微调隐特征，其中，初始当前微调软提示生成模型和初始当前微调语言模型通过如上述的语言模型训练方法训练得到；预测损失确定模块，被配置为将各个文本数据对应的微调隐特征提供给与微调任务相关的当前预测模型，得到各个文本数据对应的预测结果；基于所得到的各个文本数据对应的预测结果与标签数据之间的差异，确定当前模型微调过程的预测损失值；以及所述微调装置还包括：参数微调单元，被配置为响应于不满足微调结束条件，根据所述预测损失值调整当前微调语言模型和当前预测模型的模型参数，其中，经过模型参数调整后的微调语言模型和预测模型充当下一模型训练过程的当前微调语言模型和当前预测模型。

根据本说明书的实施例的另一方面，提供一种基于持续预训练的语言模型训练装置，包括：至少一个处理器，以及与所述至少一个处理器耦合的存储器，所述存储器存储指令，当所述指令被所述至少一个处理器执行时，使得所述至少一个处理器执行如上所述的基于持续预训练的语言模型训练方法。

根据本说明书的实施例的另一方面，提供一种语言处理模型的微调装置，包括：至少一个处理器，以及与所述至少一个处理器耦合的存储器，所述存储器存储指令，当所述指令被所述至少一个处理器执行时，使得所述至少一个处理器执行如上所述的语言处理模型的微调方法。

根据本说明书的实施例的另一方面，提供一种计算机可读存储介质，其存储有计算机程序，所述计算机程序被处理器执行时实现如上所述的基于持续预训练的语言模型训

练方法和/或语言处理模型的微调方法。

根据本说明书的实施例的另一方面，提供一种计算机程序产品，包括计算机程序，所述计算机程序被处理器执行来实现如上所述的基于持续预训练的语言模型训练方法和/或语言处理模型的微调方法。

附图说明

通过参照下面的附图，可以实现对于本说明书内容的本质和优点的进一步理解。在附图中，类似组件或特征可以具有相同的附图标记。

图 1 示出了根据本说明书的实施例的持续预训练方法的一个示例的示意图。

图 2 示出了根据本说明书的实施例的基于持续预训练的语言模型训练方法和装置的示例性架构。

图 3 示出了根据本说明书的实施例的基于持续预训练的语言模型训练方法的一个示例的流程图。

图 4 示出了根据本说明书的实施例的软提示特征的生成过程的一个示例的流程图。

图 5 示出了根据本说明书的实施例的权重向量的生成过程的一个示例的示意图。

图 6 示出了根据本说明书的实施例的跨域损失值的生成过程的一个示例的示意图。

图 7 示出了根据本说明书的实施例的跨域损失值的生成过程的又一个示例的示意图。

图 8 示出了根据本说明书的实施例的语言模型的微调方法的一个示例的流程图。

图 9 示出了根据本说明书的实施例的基于持续预训练的语言模型训练装置的一个示例的方框图。

图 10 示出了根据本说明书的实施例的语言处理模型的微调装置的一个示例的方框图。

图 11 示出了根据本说明书的实施例的基于持续预训练的语言模型训练装置的一个示例的方框图。

图 12 示出了根据本说明书的实施例的语言处理模型的微调装置的一个示例的方框图。

具体实施方式

以下将参考示例实施方式讨论本文描述的主题。应该理解，讨论这些实施方式只是

为了使得本领域技术人员能够更好地理解从而实现本文描述的主题，并非是对权利要求书中所阐述的保护范围、适用性或者示例的限制。可以在不脱离本说明书实施例内容的保护范围的情况下，对所讨论的元素的功能和排列进行改变。各个示例可以根据需要，省略、替代或者添加各种过程或组件。另外，相对一些示例所描述的特征在其它例子中也可以进行组合。

如本文中使用的，术语“包括”及其变型表示开放的术语，含义是“包括但不限于”。术语“基于”表示“至少部分地基于”。术语“一个实施例”和“一实施例”表示“至少一个实施例”。术语“另一个实施例”表示“至少一个其他实施例”。术语“第一”、“第二”等可以指代不同的或相同的对象。下面可以包括其他的定义，无论是明确的还是隐含的。除非上下文中明确地指明，否则一个术语的定义在整个说明书中是一致的。

在本说明书中，术语“持续预训练（Continual-Pre-training）”可以指一种训练方法。它通过使语言模型在一系列新增领域的文本数据上进行顺序地预训练来对模型进行高效更新，消除对过往数据的重复训练代价。

图 1 示出了根据本说明书的实施例的持续预训练方法的一个示例的示意图 100。如图 1 所示，假设从 T 个领域（如医疗领域、金融领域和新闻领域）中依次收集一个语料库构成一个训练样本集流：$\{C_1, C_2, \cdots, C_T\}$。初始语言模型 B^0 例如可以利用通用语料库 C_0 训练得到。接下来，可以利用第 1 个领域的训练样本集 C_1 在初始语言模型 B^0 的基础上继续训练，得到学习到第 1 个领域的知识的语言模型 B^1。依此类推，最终可以得到学习到第 1~T 个领域的知识的语言模型 B^T。可以理解，对于第 t 个阶段的语言模型 B^t，除了可以利用当前领域的有标签数据集（例如 D_t）检验当前语言模型 B^t 对当前领域知识的学习能力，还可以利用已学习的领域的有标签数据集（例如 D_{t-1}, D_{t-2}）等检验当前语言模型 B^t 避免遗忘的能力，也可以利用未学习的领域的有标签数据集（例如 D_{t+1}, D_{t+2}）等检验当前语言模型 B^t 的泛化能力。

下面将结合附图来详细描述根据本说明书实施例的基于持续预训练的语言模型训练方法和装置。

图 2 示出了根据本说明书实施例的基于持续预训练的语言模型训练方法和装置的示例性架构 200。

在图 2 中，网络 210 被应用于在终端设备 220 和应用服务器 230 之间进行互连。

网络 210 可以是能够对网络实体进行互连的任何类型的网络。网络 210 可以是单

个网络或各种网络的组合。在覆盖范围方面，网络 210 可以是局域网（LAN）、广域网（WAN）等。在承载介质方面，网络 210 可以是有线网络、无线网络等。在数据交换技术方面，网络 210 可以是电路交换网络、分组交换网络等。

终端设备 220 可以是能够连接到网络 210、访问网络 210 上的服务器或网站、处理数据或信号等的任何类型的电子计算设备。例如，终端设备 220 可以是台式计算机、笔记本电脑、平板电脑、智能电话等。尽管在图 2 中仅示出了一个终端设备，但是应当理解，可以有不同数量的终端设备连接到网络 210。

在一种实施方式中，终端设备 220 可以由用户使用。终端设备 220 可以包括可为用户提供各种基于自然语言处理的服务（例如文本分类、信息检索、命名实体识别、机器翻译、问答系统）的应用客户端（例如应用客户端 221）。在一些情况下，应用客户端 221 可以与应用服务器 230 进行交互。例如，应用客户端 221 可以将用户输入的消息传送到应用服务器 230，并且从应用服务器 230 接收与上述消息相关联的响应。然而，应当理解，在其它情况下，应用客户端 221 也可以在本地生成对用户输入的消息的响应，而不是与应用服务器 230 进行交互。在本文中，“消息”可以指任何输入信息，例如来自用户输入的文本数据等。

应用服务器 230 可以存储有训练完成的语言处理模型。上述语言处理模型可以包括语言模型、提示生成模型和预测模型。应用服务器 230 可以与模型训练服务器 240 连接。其中，模型训练服务器 240 可以用来根据数据库服务器 250 存储的训练样本集训练得到上述语言模型、提示生成模型和预测模型。在一个示例中，上述训练样本集可以包括各个领域的文本数据。在一个示例中，上述训练样本集可以包括与自然语言处理任务相匹配的有标签数据。从而，上述应用服务器 230 可以提供相应的基于自然语言处理的服务。然而，应当理解，在其它情况下，应用服务器 230 也可以在本地训练得到上述语言模型、提示生成模型和预测模型，而不是与模型训练服务器 240 进行交互。

应当理解，图 2 中所示的所有网络实体都是示例性的，根据具体的应用需求，架构 200 中可以涉及任何其它网络实体。

继续参考图 3，图 3 示出了根据本说明书的实施例的基于持续预训练的语言模型训练方法 300 的一个示例的流程图。

如图 3 所示，在 310，利用当前领域的训练样本集循环执行下述步骤 320-350，直到满足当前领域的训练结束条件。

在本实施例中，上述训练样本集中的每个训练样本可以包括文本数据。在一个示例

中，当前领域的训练样本集（例如可以用 C_i 来表示）中的每个训练样本所包括的文本数据通常属于同一领域（例如第 i 个领域），其可以是体育领域、金融领域、数码领域等。

在 320，将当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的软提示特征。

在本实施例中，软提示特征可以用于指示所学习到的跨领域知识。上述当前训练样本集可以基于当前领域的训练样本集选取得到。在一个示例中，当前训练样本集可以指在当前迭代过程（iteration）从上述当前领域的训练样本集中选取的一批（batch）文本数据。当前训练样本集所包含的文本数据的数目可以与预定的批大小（batchsize）相当。在一个示例中，基于当前领域的训练样本集选取得到的当前训练样本集所包括的 n 个训练样本可以用$[\mathbf{x}^1, \mathbf{x}^2, \cdots, \mathbf{x}^n]$来表示。

在本实施例中，文本隐特征可以包括文本的上下文特征（contextual embedding），其可以捕捉整个文本和隐含的文本所属的领域的信息。在一个示例中，可以通过各种预先训练的可用于自然语言处理的模型（例如，基于 transformer 的编码层，长短期记忆网络等）得到对应的文本隐特征。可选地，上述用以生成文本隐特征的模型的模型参数也可以随着模型训练过程而调整。上述软提示生成模型可以包括各种用于向量转换的模型，例如基于 transformer 的编码模型等。上述当前软提示生成模型的模型参数可以随着模型训练过程的推进而调整。在一个示例中，第 i 个文本数据对应的软提示特征可以表示为 $\mathbf{P}^i = \mathrm{F}(\hat{\mathbf{h}}^i) = \mathrm{F}(\mathrm{E}(\mathbf{x}^i))$。其中，上述 $\hat{\mathbf{h}}^i$ 可以用于表示第 i 个文本数据对应的文本隐特征。$\mathrm{E}(\bullet)$ 和 $\mathrm{F}(\bullet)$可以分别用于表示用以生成文本隐特征的模型和当前软提示生成模型。

可选地，继续参见图 4，图 4 示出了根据本说明书的实施例的软提示特征的生成过程 400 的一个示例的流程图。

在 410，将当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的权重向量。

在本实施例中，软提示生成模型可以用于指示从文本隐特征到权重向量的映射。在一个示例中，权重向量通常对应有作为基向量的预定软提示特征分量。例如，权重向量 $\boldsymbol{\alpha} \in \square^M$ 可以对应有 M 个预定软提示特征分量，每个预定软提示特征分量 $\mathbf{V}_m \in \square^{L \times d}$。

可选地，继续参见图 5，图 5 示出了根据本说明书的实施例的权重向量的生成过程 500 的一个示例的示意图。

如图 5 所示，当前软提示生成模型可以包括当前特征编码子模型和当前投影（projection）子模型。在一个示例中，上述特征编码子模型可以包括 6 层 transformer 结

构。可以将当前领域的当前训练样本集中的各个文本数据对应的文本隐特征 510 提供给当前特征编码子模型 520，得到与各个当前训练样本对应的编码特征 530。再对所得到的各个当前训练样本对应的编码特征 530 进行池化（pool），得到对应的池化后特征 540。之后再将与各个当前训练样本对应的池化后编码特征提供给当前投影子模型 550，得到与各个当前训练样本对应的权重向量 560。可以理解，上述特征编码子模型 520 和投影子模型 550 的模型参数可以随着模型训练过程的推进而调整。

基于此，本方案提供了生成权重向量的具体实现网络，更适用于对权重向量的学习。

回到图 4，在 420，将所得到的各个当前训练样本对应的权重向量与预定软提示特征分量对应相乘，得到与各个当前训练样本对应的软提示特征。

在一个示例中，当前训练样本 i 对应的软提示特征可以表示为 $\mathbf{P}^i = \sum_{m=1}^{M} \alpha_m \cdot \mathbf{V}_m$。其中，上述 α_m 可以用于表示与第 m 个预定软提示特征分量 $\mathbf{V}_m$ 对应的权重。

基于此，本方案可以通过生成与所设置的预定软提示特征分量对应的权重向量来合成最终的软提示特征，相比于直接生成软提示特征，可以减少模型的参数，并通过将学习整个特征表征转移到仅需学习权重向量来减轻遗忘。

回到图 3，在 330，将当前训练样本集中的各个文本数据和对应的软提示特征提供给当前语言模型，得到各个文本数据对应于当前领域的隐特征。

在一个示例中，文本数据 $\mathbf{x}^i$ 对应于当前领域的隐特征可以表示为 $\mathbf{h}^i = \mathrm{B}^t(\mathbf{P}^i, \boldsymbol{e}^i)$。其中，$\mathrm{B}^t$ 可以用于表示当前语言模型。$\boldsymbol{e}^i$ 可以用于表示文本数据 $\mathbf{x}^i=[x_1{}^i, x_2{}^i, \ldots, x_\mathrm{T}{}^i]$ 经过用于文本向量化的嵌入（embedding）层所得到的文本编码，例如 $\boldsymbol{e}^i=[\boldsymbol{e}_1{}^i, \boldsymbol{e}_2{}^i, \ldots, \boldsymbol{e}_\mathrm{T}{}^i]$。上述 $\boldsymbol{e}_\mathrm{T}{}^i$ 中的 T 可以用于表示文本数据所包含的词符（token）的数目。上述嵌入层的参数通常可以随着当前语言模型的参数调整而调整。可选地，上述嵌入层的参数也可以预先训练得到。在一个示例中，可以将对应于同一文本数据的文本编码和软提示特征进行组合，再提供给上述当前语言模型。

需要说明的是，持续预训练方法通常依次训练第 1~T 个领域的知识的语言模型。在首次从第 t 个领域的训练样本集中选取当前训练样本集时，对应的当前语言模型为初始当前语言模型。其模型参数可以基于上一领域（即第 t-1 个领域）的训练样本集训练得到，例如与利用第 t-1 个领域的训练样本集训练完成的语言模型 B^{t-1} 的模型参数一致。

在 340，基于所得到的各个文本数据对应于当前领域的隐特征与相应基于初始当前语言模型而得到的对应于上一领域的隐特征之间的差异，确定跨域损失值。

在本实施例中，上述跨域损失值可以用于指示所得到的各个文本数据对应于当前

领域的隐特征与相应基于初始当前语言模型而得到的对应于上一领域的隐特征之间的差异程度。上述隐特征可以通过如前述的方式得到。

可选地，继续参见图 6，图 6 示出了根据本说明书的实施例的跨域损失值的生成过程 600 的一个示例的示意图。

如图 6 所示，相应基于初始当前语言模型而得到的各个文本数据对应于上一领域的隐特征可以通过将当前训练样本集中的各个文本数据和对应的上一领域软提示特征提供给初始当前语言模型而得到。上述对应的上一领域软提示特征可以通过将当前训练样本集中的各个文本数据对应的文本隐特征提供给与上述初始当前语言模型对应的软提示生成模型而得到。在一个示例中，文本数据 $\mathbf{x}^1$ 对应的文本编码可以如图 6 中 611 和 621 所示。可以理解，当嵌入层的参数随着训练过程而调整时，611 和 621 通常不同。当嵌入层的参数不随训练过程而调整时，611 和 621 通常相同。文本数据 $\mathbf{x}^1$ 对应的上一领域软提示特征$\tilde{\mathrm{P}}$可以如图 6 中 612 所示，其可以通过如前述的$\tilde{\mathrm{P}}^1 = \mathrm{F}_{t\text{-}1}(\tilde{\mathrm{h}}^1) = \mathrm{F}_{t\text{-}1}(\mathrm{E}(\mathbf{x}^1))$。$\mathrm{F}_{t\text{-}1}(\bullet)$可以用于表示与上述初始当前语言模型对应的（即上一领域训练得到的）软提示生成模型。同理，文本数据 $\mathbf{x}^1$ 对应的当前领域的软提示特征 $\mathbf{P}^1$（如图 6 中 622 所示）可以参考前述步骤 320 的描述得到。分别利用初始当前语言模型 $\mathrm{B}^{t\text{-}1}$（如图 6 中 630 所示）和当前语言模型 B^{t}（如图 6 中 640 所示），得到各个文本数据对应于上一领域的隐特征（如图 6 中 650 所示）和对应于当前领域的隐特征（如图 6 中 660 所示）。而后，可以以最大化隐特征 650 和隐特征 660 之间的差异为目标，确定当前模型训练过程的跨域对抗损失值。在一个示例中，跨域对抗损失值可以表示为 $\mathcal{L}_{\mathrm{da}}(\mathbf{x}, \mathcal{W}, \Theta) = \mathcal{A}(\mathrm{B}^{t\text{-}1}(\mathbf{x}, \mathrm{F}_{t\text{-}1}(\mathbf{x})), \mathrm{B}^{t}{}_{\mathcal{W}}(\mathbf{x}, \mathrm{F}_{\Theta}(\mathbf{x})))$。其中，$\mathcal{W}$和 Θ 可以分别用于表示当前领域的当前语言模型和对应的当前软提示生成模型的模型参数。$\mathbf{x}$ 可以用于表示当前训练样本集中的各个文本数据。$\mathcal{A}(\bullet,\bullet)$可以用于表示相似度矩阵，例如可以包括正交约束、带有 softmax 函数的用以计算相似度的基于多层感知机（Multilayer Perceptron, MLP）、KL 散度的相反数等。在一个示例中，$\mathcal{A}_{ortho}(\mathbf{X},\mathbf{Y})=\|\mathbf{X}\bullet\mathbf{Y}^{\mathrm{T}}\text{-}\mathrm{I}\|$。

基于此，本方案可以通过设计最小化一致性度量来推开前后两个领域的软提示的隐藏状态，训练包含软提示的语言模型最大程度地不同意先前（例如上一领域）语言模型的输出。从而通过这种对抗损失来提高每个领域所生成的表征的丰富性。

可选地，继续参见图 7，图 7 示出了根据本说明书的实施例的跨域损失值的生成过

程 700 的又一个示例的示意图。

如图 7 所示，可以将当前训练样本集中的各个文本数据和对应的预定软提示特征分别提供给当前语言模型和初始当前语言模型，分别得到各个文本数据对应于当前领域的预定提示隐特征和对应于上一领域的预定提示隐特征。在一个示例中，文本数据 $\mathbf{x}^1$ 对应的文本编码$[\boldsymbol{e}_1^1, \boldsymbol{e}_2^1, \ldots, \boldsymbol{e}_T^1]$可以如图 7 中 710 所示。对应的预定软提示特征 $\mathbf{P}_r^1$ 可以如图 7 中 720 所示。其中，各个文本数据对应的文本编码预定软提示特征可以相同，也可以不同。可选地，预定软提示特征可以随机生成。在一个示例中，可以将文本数据 $\mathbf{x}^1$ 对应的文本编码 710 和预定软提示特征 720 分别提供给当前语言模型 B^t（如图 7 中 730 所示）和初始当前语言模型 B^{t-1}（如图 7 中 740 所示），分别得到各个文本数据对应于当前领域的预定提示隐特征（如图 7 中 750 所示）和对应于上一领域的预定提示隐特征（如图 7 中 760 所示）。而后，可以以最小化所得到的预定提示隐特征 750 和预定提示隐特征 760 之间的差异为目标，确定当前模型训练过程的跨域对齐损失值。在一个示例中，跨域对齐损失值可以表示为 $\mathcal{L}_a(\mathbf{x},\mathcal{W}) = \mathcal{KL}(\mathrm{B}^{t-1}(\mathbf{x}, \mathbf{P}_r) \,\|\, \mathrm{B}^t{}_{\mathcal{W}}(\mathbf{x}, \mathbf{P}_r))$。其中，$\mathcal{KL}$ 可以用于表示 KL 散度。可以理解，上述 KL 散度也可以替换为其他表征向量之间的差异程度的度量。其他符号的含义可以参考前述。

基于此，本方案可以通过初始化随机提示 $\mathbf{P}_r$ 来模拟激活语言模型中已有知识的领域，随后通过设计跨域对齐损失在多个随机条件上强制执行一致性来拉近使用当前语言模型 B^t 和之前的语言模型 B^{t-1} 在上述随机提示基础上所生成的隐特征之间的距离，从而有效防止模型的遗忘，并通过维持以其他提示为条件的模型容量来保留新域的可塑性。

在 350，判断是否满足当前领域的训练结束条件。

在一个示例中，可以通过判断迭代次数是否达到当前领域的预设次数、训练时长是否达到当前领域的预设时长、损失值是否收敛等确定是否满足训练结束条件。

若判断为否，在 360，根据跨域损失值调整当前软提示生成模型和当前语言模型的模型参数。

在本实施例中，经过模型参数调整后的软提示生成模型和语言模型可以充当下一模型训练过程的当前软提示生成模型和当前语言模型。之后，可以利用上述当前领域的训练样本集重新确定当前领域的当前训练样本集，继续执行模型训练过程 320-350，直到满足当前领域的训练结束条件。

可选地，若判断为否，可以根据跨域损失值和跨域对齐损失值调整当前软提示生成

模型和当前语言模型的模型参数。

可选地，上述跨域损失值还可以与其他适用于语言模型训练的各种损失值相结合，例如常用于预训练的屏蔽语言建模(masked language modeling, MLM)损失、可用于各种下游任务的、基于样本标签作为期望输出而得到的预测损失。

在一个示例中，总损失值可以表示为 $\mathcal{L}=\sum_{i=1}^{N}\mathcal{L}_{mlm}+\lambda_1\cdot\mathcal{L}_a+\lambda_2\cdot\mathcal{L}_{da}$。其中，上述 $\mathcal{L}_{mlm}$ 可以用来表示屏蔽语言建模损失，λ_1 和 λ_2 可以用来表示预设的权重。基于此，本方案可以结合跨域损失值和跨域对齐损失值来调整当前软提示生成模型和当前语言模型的模型参数，从而进一步提升模型的训练效果。

若判断为是，继续利用下一领域的训练样本集重复执行上述利用当前领域的模型训练过程 310-360，直至满足持续预训练的训练结束条件。

在本实施例中，持续预训练的训练结束条件可以包括在一个示例中，可以通过判断迭代次数是否达到持续预训练的预设次数、训练时长是否达到持续预训练的预设时长、各个领域的训练样本集是否使用完毕，损失值是否收敛等确定是否满足训练结束条件。

利用图 1-图 7 中公开的基于持续预训练的语言模型训练方法，可以通过增加领域相关的软提示特征的方式，使得模型在持续学习过程中学习新增领域的知识，在达到良好效果的同时，模型增加的参数规模可以忽略不计。并且，还通过基于在相邻领域对应的隐特征之间的差异设计的跨域损失函数，来为新增领域提供了足够的泛化性。

图 8 示出了根据本说明书的实施例的语言处理模型的微调方法 800 的一个示例的流程图。

如图 8 所示，在 810，利用微调训练样本集循环执行下述步骤 820-860，直到满足微调结束条件。

在本实施例中，上述微调训练样本集中的每个训练样本可以包括文本数据和与微调任务相关的标签数据。上述语言处理模型可以包括微调软提示生成模型、微调语言模型和当前预测模型。在一个示例中，微调任务可以包括文本分类任务，相关的标签数据可以包括所属分类。在一个示例中，文本数据可以包括文本对数据，微调任务可以包括文本语义一致性判定任务，相关的标签数据可以用于表示文本对的语义是否一致。

在 820，将当前微调训练样本集中的各个文本数据对应的文本隐特征提供给当前微调软提示生成模型，得到与各个当前训练样本对应的微调软提示特征。

在本实施例中，当前微调训练样本集可以基于上述微调训练样本集选取得到。在一

个示例中，当前微调训练样本集可以指在当前迭代过程从上述微调训练样本集中选取的一批训练样本。当前微调训练样本集所包含的训练样本的数目可以与预定的批大小相当。

在 830，将当前微调训练样本集中的各个文本数据和对应的微调软提示特征提供给当前微调语言模型，得到各个文本数据对应的微调隐特征。

在本实施例中，上述初始当前微调软提示生成模型和初始当前微调语言模型可以通过如前述的图 3-图 7 所描述的语言模型训练方法训练得到。在一个示例中，在首次从上述微调训练样本集中选取当前微调训练样本集时，对应的当前微调软提示生成模型和当前微调语言模型即为初始当前微调软提示生成模型和初始当前微调语言模型。

在 840，将各个文本数据对应的微调隐特征提供给与微调任务相关的当前预测模型，得到各个文本数据对应的预测结果。

在本实施例中，与微调任务相关的预测模型可以包括各种机器学习模型。在一个示例中，上述预测模型可以包括文本分类模型、文本语 义一致性判定模型等。

在 850，基于所得到的各个文本数据对应的预测结果与标签数据之间的差异，确定当前模型微调过程的预测损失值。

在本实施例中，预测损失值可以根据适用于监督学习方式的损失函数来计算。在一个示例中，预测损失值可以采用交叉熵来计算。

在 860，判断是否满足微调结束条件。

在一个示例中，可以通过判断迭代次数是否达到预设微调次数、训练时长是否达到预设微调时长、损失值是否收敛等确定是否满足训练结束条件。

若判断为否，在 870，根据预测损失值调整当前微调语言模型和当前预测模型的模型参数。

在本实施例中，经过模型参数调整后的微调语言模型和预测模型充当下一模型训练过程的当前微调语言模型和当前预测模型。

可选地，若判断为否，可以根据预测损失值调整当前微调软提示生成模型、当前微调语言模型和当前预测模型的模型参数。其中，经过模型参数调整后的微调软提示生成模型、微调语言模型和预测模型充当下一模型训练过程的当前微调软提示生成模型、当前微调语言模型和当前预测模型。

若判断为是，可以将当前微调软提示生成模型、当前微调语言模型和当前预测模型确定为训练完成的语言处理模型。从而可以利用训练完成的语言处理模型所包括的微调软提示生成模型、微调语言模型和预测模型型得到与输入的文本对应的预测结果（例如

文本所属分类、语义一致性预测结果等）。

基于上述，提供了可以在上述基于持续预训练的语言模型训练方法的基础上进行微调（fine-tune）的方法，从而不但可以进一步优化用于得到文本隐特征的微调语言模型，还可以与具体下游微调任务相结合，实现相应的文本处理任务。

下面参考图9，图9示出了根据本说明书的实施例的基于持续预训练的语言模型训练装置900的一个示例的方框图。该装置实施例可以与图2-图7所示的方法实施例相对应，该装置具体可以应用于各种电子设备中。

如图9所示，基于持续预训练的语言模型训练装置900可以被配置为由训练单元910利用当前领域的训练样本集循环执行模型训练过程，直到满足当前领域的训练结束条件。训练样本集中的每个训练样本可以包括文本数据。所述训练单元910在满足所述当前领域的训练结束条件的情况下继续利用下一领域的训练样本集重复执行模型训练过程，直至满足持续预训练的训练结束条件。训练单元910可以包括：软提示生成模块911、隐特征生成模块912和损失确定模块913。

软提示生成模块911，被配置为将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的软提示特征。

在一个示例中，软提示生成模块911，可以进一步被配置为：将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的权重向量；将所得到的各个当前训练样本对应的权重向量与预定软提示特征分量对应相乘，得到与各个当前训练样本对应的软提示特征。

在一个示例中，当前软提示生成模型包括当前特征编码子模型和当前投影子模型。软提示生成模块911，可以进一步被配置为： 将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前特征编码子模型，得到与各个当前训练样本对应的编码特征；对所得到的各个当前训练样本对应的编码特征进行池化，得到对应的池化后特征；将与各个当前训练样本对应的池化后编码特征提供给当前投影子模型，得到与各个当前训练样本对应的权重向量。

隐特征生成模块912，被配置为将当前训练样本集中的各个文本数据和对应的软提示特征提供给当前语言模型，得到各个文本数据对应于当前领域的隐特征，其中，初始当前语言模型基于上一领域的训练样本集训练得到。

损失确定模块913，被配置为基于所得到的各个文本数据对应于当前领域的隐特征

与相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征之间的差异，确定跨域损失值。

在一个示例中，所述相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征通过将当前训练样本集中的各个文本数据和对应的上一领域软提示特征提供给所述初始当前语言模型而得到，所述对应的上一领域软提示特征通过将当前训练样本集中的各个文本数据对应的文本隐特征提供给与所述初始当前语言模型对应的软提示生成模型而得到。损失确定模块 913，可以进一步被配置为以最大化所得到的各个文本数据对应于当前领域的隐特征与相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征之间的差异为目标，确定跨域对抗损失值。

在一个示例中，损失确定模块 913，可以进一步被配置为将当前训练样本集中的各个文本数据和对应的预定软提示特征分别提供给当前语言模型和所述初始当前语言模型，分别得到各个文本数据对应于当前领域的预定提示隐特征和对应于上一领域的预定提示隐特征；以最小化所得到的各个文本数据对应于当前领域的预定提示隐特征与对应于上一领域的预定提示隐特征之间的差异为目标，确定当前模型训练过程的跨域对齐损失值。

上述基于持续预训练的语言模型训练装置 900 还可以包括：参数调整单元 920，被配置为响应于不满足当前领域的训练结束条件，根据所述跨域损失值调整当前软提示生成模型和当前语言模型的模型参数，其中，经过模型参数调整后的软提示生成模型和语言模型充当下一模型训练过程的当前软提示生成模型和当前语言模型。

在一个示例中，参数调整单元 920，可以进一步被配置为根据所述跨域损失值和跨域对齐损失值调整当前软提示生成模型和当前语言模型的模型参数。

上述训练单元 910 所包括的软提示生成模块 911、隐特征生成模块 912 和损失确定模块 913 以及参数调整单元 920 的具体操作可以参考前述图 3-图 7 实施例中相应步骤的具体描述，此处不再赘述。

继续参考图 10，图 10 示出了根据本说明书的实施例的语言处理模型的微调装置 1000 的一个示例的方框图。该装置实施例可以与图 8 所示的方法实施例相对应，该装置具体可以应用于各种电子设备中。所述语言处理模型可以包括微调软提示生成模型、微调语言模型和当前预测模型。

如图 10 所示，语言处理模型的微调装置 1000 可以被配置为由训练单元 1010 利用微调训练样本集循环执行模型微调过程，直到满足微调结束条件。所述微调训练样本集

中的每个训练样本可以包括文本数据和与微调任务相关的标签数据。训练单元 1010 可以包括：微调特征生成模块 1011 和预测损失确定模块 1012。

微调特征生成模块 1011，被配置为将所述当前微调训练样本集中的各个文本数据对应的文本隐特征提供给当前微调软提示生成模型，得到与各个当前训练样本对应的微调软提示特征；将当前微调训练样本集中的各个文本数据和对应的微调软提示特征提供给当前微调语言模型，得到各个文本数据对应的微调隐特征，其中，初始当前微调软提示生成模型和初始当前微调语言模型通过如前所述的语言模型训练方法训练得到。

预测损失确定模块 1012，被配置为将各个文本数据对应的微调隐特征提供给与微调任务相关的当前预测模型，得到各个文本数据对应的预测结果；基于所得到的各个文本数据对应的预测结果与标签数据之间的差异，确定当前模型微调过程的预测损失值。

上述语言处理模型的微调装置 1000 还可以包括：参数微调单元 1020，被配置为响应于不满足微调结束条件，根据所述预测损失值调整当前微调语言模型和当前预测模型的模型参数，其中，经过模型参数调整后的微调语言模型和预测模型充当下一模型训练过程的当前微调语言模型和当前预测模型。

在一个示例中，参数微调单元 1020，可以进一步被配置为根据所述预测损失值调整当前微调软提示生成模型、当前微调语言模型和当前预测模型的模型参数，其中，经过模型参数调整后的微调软提示生成模型、微调语言模型和预测模型充当下一模型训练过程的当前微调软提示生成模型、当前微调语言模型和当前预测模型。

上述训练单元 1010 所包括的微调特征生成模块 1011 和预测损失确定模块 1012 以及参数微调单元 1020 的具体操作可以参考前述图 8 实施例中相应步骤的具体描述，此处不再赘述。

以上参照图 1 到图 10，对根据本说明书实施例的基于持续预训练的语言模型训练方法和装置、以及语言处理模型的微调方法和装置的实施例进行了描述。

本说明书实施例的基于持续预训练的语言模型训练装置和语言处理模型的微调装置可以采用硬件实现，也可以采用软件或者硬件和软件的组合来实现。以软件实现为例，作为一个逻辑意义上的装置，是通过其所在设备的处理器将存储器中对应的计算机程序指令读取到内存中运行形成的。在本说明书实施例中，基于持续预训练的语言模型训练装置和语言处理模型的微调装置例如可以利用电子设备实现。

图 11 示出了本说明书的实施例的基于持续预训练的语言模型训练装置 1100 的示意图。

如图 11 所示，基于持续预训练的语言模型训练装置 1100 可以包括至少一个处理器 1110、存储器（例如，非易失性存储器）1120、内存 1130 和通信接口 1140，并且至少一个处理器 1110、存储器 1120、内存 1130 和通信接口 1140 经由总线 1150 连接在一起。至少一个处理器 1110 执行在存储器中存储或编码的至少一个计算机可读指令（即，上述以软件形式实现的元素）。

在一个实施例中，在存储器中存储计算机可执行指令，其当执行时使得至少一个处理器 1110：执行如前所述的基于持续预训练的语言模型训练方法。

应该理解，在存储器中存储的计算机可执行指令当执行时使得至少一个处理器 1110 进行本说明书的各个实施例中以上结合图 1-图 8 描述的各种操作和功能。

图 12 示出了本说明书的实施例的语言处理模型的微调装置 1200 的示意图。

如图 12 所示，语言处理模型的微调装置 1200 可以包括至少一个处理器 1210、存储器（例如，非易失性存储器）1220、内存 1230 和通信接口 1240，并且至少一个处理器 1210、存储器 1220、内存 1230 和通信接口 1240 经由总线 1250 连接在一起。至少一个处理器 1210 执行在存储器中存储或编码的至少一个计算机可读指令（即，上述以软件形式实现的元素）。

在一个实施例中，在存储器中存储计算机可执行指令，其当执行时使得至少一个处理器 1210：执行如前所述的语言处理模型的微调方法。

应该理解，在存储器中存储的计算机可执行指令当执行时使得至少一个处理器 1210 进行本说明书的各个实施例中以上结合图 8 描述的各种操作和功能。

根据一个实施例，提供了一种例如计算机可读介质的程序产品。计算机可读介质可以具有指令（即，上述以软件形式实现的元素），该指令当被计算机执行时，使得计算机执行本说明书的各个实施例中以上结合图 1-图 8 描述的各种操作和功能。

具体地，可以提供配有可读存储介质的系统或者装置，在该可读存储介质上存储着实现上述实施例中任一实施例的功能的软件程序代码，且使该系统或者装置的计算机或处理器读出并执行存储在该可读存储介质中的指令。

在这种情况下，从可读介质读取的程序代码本身可实现上述实施例中任何一项实施例的功能，因此机器可读代码和存储机器可读代码的可读存储介质构成了本发明的一部分。

本说明书各部分操作所需的计算机程序代码可以用任意一种或多种程序语言编写，包括面向对象编程语言，如 Java、Scala、Smalltalk、Eiffel、JADE、Emerald、C++、C#、

VB、NET 以及 Python 等，常规程序化编程语言如 C 语言、Visual Basic 2003、Perl、COBOL 2002、PHP 以及 ABAP，动态编程语言如 Python、Ruby 和 Groovy，或者其他编程语言等。该程序编码可以在用户计算机上运行，或者作为独立的软件包在用户计算机上运行，或者部分在用户计算机上运行另一部分在远程计算机运行，或者全部在远程计算机或服务器上运行。在后一种情况下，远程计算机可以通过任何网络形式与用户计算机连接，比如局域网（LAN）或广域网（WAN），或连接至外部计算机（例如通过因特网），或者在云计算环境中，或者作为服务使用，比如软件即服务（SaaS）。

可读存储介质的实施例包括软盘、硬盘、磁光盘、光盘（如 CD-ROM、CD-R、CD-RW、DVD-ROM、DVD-RAM、DVD-RW、DVD-RW）、磁带、非易失性存储卡和 ROM。可选择地，可以由通信网络从服务器计算机上或云上下载程序代码。

上述对本说明书特定实施例进行了描述。其它实施例在所附权利要求书的范围内。在一些情况下，在权利要求书中记载的动作或步骤可以按照不同于实施例中的顺序来执行并且仍然可以实现期望的结果。另外，在附图中描绘的过程不一定要求示出的特定顺序或者连续顺序才能实现期望的结果。在某些实施方式中，多任务处理和并行处理也是可以的或者可能是有利的。

上述各流程和各系统结构图中不是所有的步骤和单元都是必须的，可以根据实际的需要忽略某些步骤或单元。各步骤的执行顺序不是固定的，可以根据需要进行确定。上述各实施例中描述的装置结构可以是物理结构，也可以是逻辑结构，即，有些单元可能由同一物理实体实现，或者，有些单元可能分由多个物理实体实现，或者，可以由多个独立设备中的某些部件共同实现。

在整个本说明书中使用的术语“示例性”意味着“用作示例、实例或例示”，并不意味着比其它实施例“优选”或“具有优势”。出于提供对所描述技术的理解的目的，具体实施方式包括具体细节。然而，可以在没有这些具体细节的情况下实施这些技术。在一些实例中，为了避免对所描述的实施例的概念造成难以理解，公知的结构和装置以框图形式示出。

以上结合附图详细描述了本说明书的实施例的可选实施方式，但是，本说明书的实施例并不限于上述实施方式中的具体细节，在本说明书的实施例的技术构思范围内，可以对本说明书的实施例的技术方案进行多种简单变型，这些简单变型均属于本说明书的实施例的保护范围。

本说明书内容的上述描述被提供来使得本领域任何普通技术人员能够实现或者使

用本说明书内容。对于本领域普通技术人员来说，对本说明书内容进行的各种修改是显而易见的，并且，也可以在不脱离本说明书内容的保护范围的情况下，将本文所定义的一般性原理应用于其它变型。因此，本说明书内容并不限于本文所描述的示例和设计，而是与符合本文公开的原理和新颖性特征的最广范围相一致。

权 利 要 求 书

1、一种基于持续预训练的语言模型训练方法，包括：

利用当前领域的训练样本集循环执行下述模型训练过程，直到满足当前领域的训练结束条件，所述训练样本集中的每个训练样本包括文本数据：

将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的软提示特征；

将当前训练样本集中的各个文本数据和对应的软提示特征提供给当前语言模型，得到各个文本数据对应于当前领域的隐特征，其中，初始当前语言模型基于上一领域的训练样本集训练得到；

基于所得到的各个文本数据对应于当前领域的隐特征与相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征之间的差异，确定跨域损失值；以及

响应于不满足当前领域的训练结束条件，根据所述跨域损失值调整当前软提示生成模型和当前语言模型的模型参数，其中，经过模型参数调整后的软提示生成模型和语言模型充当下一模型训练过程的当前软提示生成模型和当前语言模型；以及

响应于满足所述当前领域的训练结束条件，继续利用下一领域的训练样本集重复执行上述利用该领域的训练样本集的模型训练过程，直至满足持续预训练的训练结束条件。

2、如权利要求 1 所述的语言模型训练方法，其中，所述相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征通过将当前训练样本集中的各个文本数据和对应的上一领域软提示特征提供给所述初始当前语言模型而得到，所述对应的上一领域软提示特征通过将当前训练样本集中的各个文本数据对应的文本隐特征提供给与所述初始当前语言模型对应的软提示生成模型而得到，

所述基于所得到的各个文本数据对应于当前领域的隐特征与相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征之间的差异，确定跨域损失值包括：

以最大化所得到的各个文本数据对应于当前领域的隐特征与相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征之间的差异为目标，确定跨域对抗损失值。

3、如权利要求 2 所述的语言模型训练方法，其中，在所述根据所述跨域对抗损失值得到跨域对抗损失值之前，所述模型训练过程还包括：

将当前训练样本集中的各个文本数据和对应的预定软提示特征分别提供给当前语言模型和所述初始当前语言模型，分别得到各个文本数据对应于当前领域的预定提示隐特征和对应于上一领域的预定提示隐特征；以及

以最小化所得到的各个文本数据对应于当前领域的预定提示隐特征与对应于上一领域的预定提示隐特征之间的差异为目标，确定当前模型训练过程的跨域对齐损失值。

4、如权利要求 3 所述的语言模型训练方法，其中，所述根据所述跨域损失值调整当前软提示生成模型和当前语言模型的模型参数包括：

根据所述跨域损失值和跨域对齐损失值调整当前软提示生成模型和当前语言模型的模型参数。

5、如权利要求 1 到 4 中任一所述的语言模型训练方法，其中，所述将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的软提示特征包括：

将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的权重向量；以及

将所得到的各个当前训练样本对应的权重向量与预定软提示特征分量对应相乘，得到与各个当前训练样本对应的软提示特征。

6、如权利要求 5 所述的语言模型训练方法，其中，当前软提示生成模型包括当前特征编码子模型和当前投影子模型，

所述将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的权重向量包括：

将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前特征编码子模型，得到与各个当前训练样本对应的编码特征；

对所得到的各个当前训练样本对应的编码特征进行池化，得到对应的池化后特征；以及

将与各个当前训练样本对应的池化后编码特征提供给当前投影子模型，得到与各个当前训练样本对应的权重向量。

7、一种语言处理模型的微调方法，其中，所述语言处理模型包括微调软提示生成模型、微调语言模型和当前预测模型，所述方法包括：

利用微调训练样本集循环执行下述模型微调过程，直到满足微调结束条件，所述微调训练样本集中的每个训练样本包括文本数据和与微调任务相关的标签数据：

将所述当前微调训练样本集中的各个文本数据对应的文本隐特征提供给当前微调软提示生成模型，得到与各个当前训练样本对应的微调软提示特征；

将当前微调训练样本集中的各个文本数据和对应的微调软提示特征提供给当前微调语言模型，得到各个文本数据对应的微调隐特征，其中，初始当前微调软提示生成模型和初始当前微调语言模型通过如权利要求 1 到 6 中任一所述的语言模型训练方法训练得到；

将各个文本数据对应的微调隐特征提供给与微调任务相关的当前预测模型，得到各个文本数据对应的预测结果；

基于所得到的各个文本数据对应的预测结果与标签数据之间的差异，确定当前模型微调过程的预测损失值；以及

响应于不满足微调结束条件，根据所述预测损失值调整当前微调语言模型和当前预测模型的模型参数，其中，经过模型参数调整后的微调语言模型和预测模型充当下一模型训练过程的当前微调语言模型和当前预测模型。

8、如权利要求 7 所述的微调方法，其中，所述根据所述预测损失值调整当前微调语言模型和当前预测模型的模型参数包括：

根据所述预测损失值调整当前微调软提示生成模型、当前微调语言模型和当前预测模型的模型参数，其中，经过模型参数调整后的微调软提示生成模型、微调语言模型和预测模型充当下一模型训练过程的当前微调软提示生成模型、当前微调语言模型和当前预测模型。

9、一种基于持续预训练的语言模型训练装置，其中，所述语言模型训练装置被配置为由训练单元利用当前领域的训练样本集循环执行模型训练过程，直到满足当前领域的训练结束条件，训练样本集中的每个训练样本包括文本数据，所述训练单元在满足所述当前领域的训练结束条件的情况下继续利用下一领域的训练样本集重复执行模型训练过程，直至满足持续预训练的训练结束条件，所述训练单元包括：

软提示生成模块，被配置为将所述当前领域的当前训练样本集中的各个文本数据对应的文本隐特征提供给当前软提示生成模型，得到与各个当前训练样本对应的软提示特征；

隐特征生成模块，被配置为将当前训练样本集中的各个文本数据和对应的软提示特征提供给当前语言模型，得到各个文本数据对应于当前领域的隐特征，其中，初始当前语言模型基于上一领域的训练样本集训练得到；

损失确定模块，被配置为基于所得到的各个文本数据对应于当前领域的隐特征与相应基于所述初始当前语言模型而得到的对应于上一领域的隐特征之间的差异，确定跨域损失值；以及

所述语言模型训练装置还包括：

参数调整单元，被配置为响应于不满足当前领域的训练结束条件，根据所述跨域损失值调整当前软提示生成模型和当前语言模型的模型参数，其中，经过模型参数调整后的软提示生成模型和语言模型充当下一模型训练过程的当前软提示生成模型和当前语言模型。

10、一种语言处理模型的微调装置，其中，所述语言处理模型包括微调软提示生成模型、微调语言模型和当前预测模型，所述微调装置被配置为由训练单元利用微调训练样本集循环执行模型微调过程，直到满足微调结束条件，所述微调训练样本集中的每个训练样本包括文本数据和与微调任务相关的标签数据，所述训练单元包括：

微调特征生成模块，被配置为将所述当前微调训练样本集中的各个文本数据对应的文本隐特征提供给当前微调软提示生成模型，得到与各个当前训练样本对应的微调软提示特征；将当前微调训练样本集中的各个文本数据和对应的微调软提示特征提供给当前微调语言模型，得到各个文本数据对应的微调隐特征，其中，初始当前微调软提示生成模型和初始当前微调语言模型通过如权利要求1到6中任一所述的语言模型训练方法训练得到；

预测损失确定模块，被配置为将各个文本数据对应的微调隐特征提供给与微调任务相关的当前预测模型，得到各个文本数据对应的预测结果；基于所得到的各个文本数据对应的预测结果与标签数据之间的差异，确定当前模型微调过程的预测损失值；以及

所述微调装置还包括：

参数微调单元，被配置为响应于不满足微调结束条件，根据所述预测损失值调整当

前微调语言模型和当前预测模型的模型参数，其中，经过模型参数调整后的微调语言模型和预测模型充当下一模型训练过程的当前微调语言模型和当前预测模型。

11、一种基于持续预训练的语言模型训练装置，包括：至少一个处理器，与所述至少一个处理器耦合的存储器，以及存储在所述存储器上的计算机程序，所述至少一个处理器执行所述计算机程序来实现如权利要求1至6中任一所述的基于持续预训练的语言模型训练方法。

12、一种语言处理模型的微调装置，包括：至少一个处理器，与所述至少一个处理器耦合的存储器，以及存储在所述存储器上的计算机程序，所述至少一个处理器执行所述计算机程序来实现如权利要求7或8所述的语言处理模型的微调方法。