

# 基于元学习实例权重法的跨领域深度文本匹配

李铂鑫<sup>1,2</sup>, 黄琪<sup>3</sup>, 鲁骁<sup>1</sup>, 张霄<sup>1</sup>, 王斌<sup>1</sup>

(1. 小米人工智能实验室, 北京 100085; 2. 中国科学院软件研究所 中文信息处理实验室, 北京 100190;  
3. 江西师范大学 计算机信息工程学院, 江西 南昌 330027)

**摘要:** 在低资源深度文本匹配场景中, 迁移学习利用资源丰富的源领域数据来缓解目标领域存在的数据饥荒问题; 当源领域数据与目标领域数据存在分布差异时, 源领域数据的不合理使用会发生负迁移现象。为此, 提出一种基于元学习实例权重法的跨领域深度文本匹配方法。首先, 通过最小化低资源目标领域中少量标注数据的损失, 自适应地为源领域中的数据分配合适的重要度权重, 以更好地拟合目标领域的分布; 其次, 为了减轻迁移过程中预训练语言模型可能发生的灾难性遗忘问题, 仅在预训练语言模型的分类器层进行元学习。实验表明, 在自然语言推理数据集 SciTail 上, RE2、ALBERT 相较于次优基线方法, F1 值分别提升 2.0%、1.5%; 在复述检测数据集 CQADupStack 上, RE2、ALBERT 相较于次优基线方法, F1 值分别最大平均提升 4.1%、1.7%。

**关键词:** 低资源; 文本匹配; 元学习; 迁移学习; 实例权重法

DOI: 10.11907/rjtk.241782

扫描二维码阅读全文:



中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2025)010-0065-08

## An Instance Weighting Method Based on Meta-Learning for Cross-Domain Deep Text Matching

LI Boxin<sup>1,2</sup>, HUANG Qi<sup>3</sup>, LU Xiao<sup>1</sup>, ZHANG Xiao<sup>1</sup>, WANG Bin<sup>1</sup>

(1. Xiaomi AI Lab, Beijing 100085, China;

2. Chinese Information Processing Laboratory, Institute of Software Chinese Academy of Sciences, Beijing 100190, China;

3. School of Computer and Information Engineering, Jiangxi Normal University, Nanchang 330027, China)

**Abstract:** In low resource deep text matching scenarios, transfer learning utilizes resource rich source domain data to alleviate the data famine problem in the target domain; When there is a distribution difference between the source domain data and the target domain data, the unreasonable use of the source domain data will result in negative transfer phenomenon. Therefore, a cross domain deep text matching method based on meta learning instance weighting method is proposed. Firstly, by minimizing the loss of a small amount of annotated data in the low resource target domain, appropriate importance weights are adaptively assigned to the data in the source domain to better fit the data distribution in the target domain; Secondly, in order to alleviate the catastrophic forgetting problem that may occur in the pre trained language model during the transfer process, meta learning is only performed at the classifier layer of the pre trained language model. Experiments have shown that on the natural language inference dataset SciTail, RE2 and ALBERT have improved F1 values by 2.0% and 1.5%, respectively, compared to the suboptimal baseline method; On the CQADupStack dataset for paraphrasing detection, RE2 and ALBERT showed a maximum average improvement of 4.1% and 1.7% in F1 values compared to the suboptimal baseline method, respectively.

**Key Words:** low-resource; text matching; meta-learning; transfer learning; instance weighting algorithm

收稿日期: 2024-09-11

基金项目: 国家自然科学基金项目(62466028)

**作者简介:** 李铂鑫(1989-), 男, 博士, CCF 会员, 小米人工智能实验室工程师, 研究方向为自然语言处理、深度学习; 黄琪(1993-), 男, 博士, 江西师范大学计算机信息工程学院讲师、硕士生导师, 研究方向为社交网络分析、谣言检测、图神经网络、自然语言处理、信息抽取; 鲁骁(1986-), 男, 博士, 小米人工智能实验室总监, 研究方向为信息检索、推荐系统和自然语言处理; 张霄(1983-), 女, 硕士, 小米人工智能实验室总监, 研究方向为深度学习、大模型和人工智能; 王斌(1972-), 男, 博士, 小米人工智能实验室主任、NLP 首席科学家、博士生导师, 研究方向为信息检索和自然语言处理。本文通讯作者: 李铂鑫。

## 0 引言

文本匹配作为自然语言处理中的一项重要任务,包括自然语言推理(Natural Language Inference, NLI)、复述检测(Paraphrase Identification, PI)等,现已进行了广泛研究,衍生出诸多方法<sup>[1-4]</sup>。新的实际场景通常会遇到标注数据不足的问题。Poerner等<sup>[5]</sup>在研究重复问题检测(复述检测的一种)时发现:在社区问答平台 StackExchange (<https://stackoverflow.com>)上,50%的论坛中用户标注的重复问题数不超过160个,在资源最少的25%的论坛中,用户标注的重复问题数甚至少于50个。小规模标注数据严重制约了深度文本匹配模型的性能,而为每个论坛都提供大量标注数据昂贵又耗时,会带来高额成本。为此,本文重点关注低资源场景下的深度文本匹配问题,即只有少量来自目标领域的标注数据可以使用。

针对上述问题,迁移学习提供了一种有效的手段,可利用资源丰富的源领域标注数据,缓解低资源目标领域上的数据饥荒问题<sup>[6-8]</sup>。Finetune作为迁移学习中的一种常见方法,首先,利用源领域上的所有标注数据训练模型;其次,利用目标领域上的少量标注微调数据,但容易导致负迁移问题,即在源领域上学到的知识对目标领域起到负作用。为了缓解负迁移问题,实例选择法利用多种度量指标从源领域中选取一部分对目标领域有用的标注数据,再对模型进行训练<sup>[6,9-11]</sup>。

目前,基于强化学习的实例选择方法,在多个深度文本匹配任务的迁移场景中取得了当前最佳效果<sup>[9-11]</sup>。具体地,这些方法利用强化数据选择器来提升模型在目标领域上的性能,以缓解负迁移问题。然而,基于强化学习的实例选择法将源领域上选择出来的部分样例赋予相同权重,使其难以准确拟合目标领域上的数据分布。更重要的是,强化数据选择模块的设计与训练需要耗费较多人力,例如数据选择器网络结构的设计、强化学习框架中的状态特征和奖励函数的选择、warm up等训练策略的精心设计,不可避免地会增加使用成本,难以推广到其他任务中。

为解决基于强化学习的实例选择方法的不足,本文提出一种基于元学习实例权重法的跨领域深度文本匹配方法。基于梯度下降优化算法,通过最小化目标领域上少量标注数据的损失,将不同权重自适应地分配给源领域上的标注数据,以更好地拟合目标领域上的数据分布。目标领域上的少量标注数据也称为参考数据,如图1所示。

本文方法包含实例加权阶段与模型训练阶段。第一阶段使用基于梯度的元优化器,在元学习框架下利用参考数据进行指导,重新计算源领域上标注数据的权重;第二阶段利用源领域上加权后的标注数据训练模型。综上,本文方法在整个过程中无需过多人工参与,因此很容易推广到其他应用场景中。




Fig. 1 Instance weighting method based on meta learning

图1 基于元学习的实例权重法

实验表明,在利用源领域上的目标数据更新预训练语言模型的所有参数(特征层参数与分类器层参数)时,会发生灾难性遗忘问题,即可能丢失对目标领域有潜在使用价值的语言学、语义学知识<sup>[3,4]</sup>。为了避免该问题,本文仅在最后的分类器层上进行元学习,即利用源领域上的标注数据进行训练来固定特征层参数,以获得更有利于目标领域的分类器层的初始化参数。同时,为了验证本文方法的泛化性能,在自然语言推理、复述检测这两个常见的文本匹配任务上进行广泛评估,实验表明本文方法优于其他基线方法。

综上,本文主要贡献为:①提出一种基于元学习实例权重法的跨领域深度文本匹配方法,在迁移学习过程中可自适应地为源领域上的样本赋予权重,既能更好地提升迁移效果,又能大幅度减少人工参与,便于推广到其他应用场景;②针对预训练语言模型提出一种适配策略,仅对模型分类器层的参数进行元学习,并保持其特征层参数不变,从而有效缓解迁移场景下预训练语言模型可能出现的灾难性遗忘问题;③在自然语言推理和复述检测数据集上,对有代表性的传统深度模型 RE2、预训练语言模型 ALBERT 进行广泛实验,以验证本文方法的有效性。

## 1 相关工作

从模型架构变迁的角度而言,文本匹配的研究趋势由传统深度学习模型逐步过渡到以 BERT 为代表的预训练语言模型<sup>[1-4,12-17]</sup>;从研究内容而言,主要集中在模型结构的创新、引入额外可用的辅助信息、利用生成模型扩充标注数据等方面<sup>[1,2,12,13,16-22]</sup>。

(1)模型结构创新旨在模型架构中引入新模块,分别建模文本的异同点及细粒度的特征等,该方法与本文方法存在互补关系,即在跨领域迁移的场景中,基座模型表征能力越强,大迁移效果越好<sup>[1,2,12,13,16-18]</sup>。

(2)本文引入额外可用的辅助信息,根据目标任务特点充分挖掘潜在的可用信息来丰富模型表示。例如,在重复问题检测任务中额外引入除问题对之外的答案信息<sup>[20]</sup>;对于社区问答重复问题检测任务中的编程子领域,融入文本特征与源码特征<sup>[21]</sup>;在复述检测任务时,利用复述检测与自然语言推断两个任务间标签逻辑上蕴含的关系,直接

复用自然语言推断任务上的标注数据<sup>[19]</sup>。引入额外可用的辅助信息方法与本文方法存在的互补关系,即使用特征越丰富的模型表征能力越强,在跨领域的迁移场景中效果更好,但仍需通过实验进行验证。

(3)利用生成模型扩充标注数据的方法得益于当下大语言模型强大的生成能力,可定向生成目标样本扩充训练集规模、提升训练集样本质量<sup>[22]</sup>。然而,该类方法存在的问题为:生成的样本与目标领域的样本之间可能存在分布偏差,有望通过本文方法进一步提升效果。

另一个与本文工作密切相关的是领域适配方法,基本思想是利用来自源领域的大量标注数据以提升模型在低资源目标领域中的效果。领域适配方法在多个实际场景中应用广泛,例如标签去噪、面向CT的肺炎分类、3D打印,以及在多个源领域的迁移场景中应用较多<sup>[23-27]</sup>。领域适配方法可分为基于特征的方法、基于实例的方法<sup>[6-11,28-31]</sup>。前者旨在使用神经网络层将两个领域中的数据映射到一个共同的隐空间,或采用对抗训练使目标领域中的数据表示趋近于源领域中的数据表示,以减少两者的数据分布偏差;后者则对源领域中的训练数据进行选择或重新加权,使所选或重新加权后的源数据与目标域数据具有相似分布<sup>[6-11,28-31]</sup>。

基于实例选择的方法,将所选源数据分配相等权重,难以准确拟合目标领域中的数据分布。其中,基于强化学习的深度神经网络实例选择方法因得益于端到端的训练模式,在文本匹配领域取得了较好的效果;基于强化学习的需人工设计、调整数据选择模块,增加了复现难度<sup>[6,9-11,28,31]</sup>。然而,本文方法采用元学习框架自适应地为源领域中的数据分配不同权重,可更好地拟合目标领域中的数据分布,无需人工参与、容易复现。

基于实例加权的方法借鉴了元学习思想,可自适应地调整源领域的权重,但会给部分源领域样本赋予负权重,从而导致学习过程不稳定且缺乏可解释性<sup>[30]</sup>。然而,本文方法综合考虑了源领域样本的非负性和自适应性,在取得良好效果的同时保持了学习过程的稳定性和可解释性。

## 2 本文方法

### 2.1 问题定义

文本匹配问题指的是由两个句子  $X_1^{(i)}$ 、 $X_2^{(i)}$  组成的实例  $X^{(i)}$ , 目标是学习一个参数为  $\theta$  的模型  $\phi$ , 以预测  $X_1^{(i)}$  与  $X_2^{(i)}$  之间的关系  $r^{(i)}$ , 亦即计算概率  $P_{\phi}(r^{(i)}|X^{(i)})$ 。针对低资源文本匹配问题(仅有少量标注数据  $D^{\text{tgt}} = \{(X^{(j)}, r^{(j)}), 1 \leq j \leq M\}$ ), 一种典型方法是借用资源丰富的源领域上的标注数据  $D^{\text{src}} = \{(X^{(i)}, r^{(i)}), 1 \leq i \leq N\}$ 。其中,  $M$  为目标领域上标注数据的数量;  $N$  为源领域上标注数据的数量,  $M \ll N$ 。

本文为了减轻负迁移的影响,旨在为源领域上的标注数据获取一组最优权重  $w = \{w^{(i)}, 1 \leq i \leq N\}$ , 使加权后源

领域上的数据分布能更好地拟合目标领域上的数据分布, 求解目标是使源领域上标注数据的加权经验风险, 确定最优权重  $w$ 。具体计算公式如式(1)所示。

$$\theta^*(w) = \arg \min_{\theta} \sum_{i=1}^N w^{(i)} l(\phi_{\theta}(X^{(i)}), r^{(i)}) = \arg \min_{\theta} \sum_{i=1}^N w^{(i)} f_i(\theta) \quad (1)$$

式中:  $l(\cdot)$  表示损失函数;  $f_i(\theta)$  代表源领域上第  $i$  个标注数据的损失;  $w^{(i)}$  为对应权重。

### 2.2 方法概览

本文受源领域上样本的最佳权重, 应使得目标领域上的参考数据损失最小的启发, 基于元学习的实例权重法区分源领域上标注样本的不同重要度<sup>[23]</sup>。具体地, 利用梯度下降算法, 在低资源文本匹配场景中最小化目标领域上的参考数据的损失, 以获得源领域上最佳的样本权重  $w$ 。

$$w^* = \arg \min_{w, w \geq 0} \frac{1}{M} \sum_{j=1}^M f_j^r(\theta^*(w)) \quad (2)$$

式中:  $f_j^r(\cdot)$  表示第  $j$  个参考数据的损失。

如图2所示, 在元学习框架下通过内、外两个迭代循环来更新模型参数。外循环通过式(2)的元目标函数求解源领域上样本的最佳权重; 内循环利用外循环得到的源领域上的加权样本训练模型。元学习结束后, 利用参考数据微调模型以取得更好的性能。




Fig. 2 Process of instance weighting method based on meta learning in low resource text matching scenarios

图2 低资源文本匹配场景下基于元学习的实例权重法流程

### 2.3 在线重加权策略

为了提升模型训练效率, 采用一种在线重加权策略, 通过单步梯度更新来求解式(2)的最优化问题。考虑到原始的SGD优化算法, mini-batch版本的模型参数更新过程可重新表述为式(3)、式(4)<sup>[23]</sup>。

$$f_{i,w}(\theta) = w^{(i)} f_i(\theta) \quad (3)$$

$$\theta_{t+1}(w) = \theta_t - \alpha \nabla \sum_{i=1}^n f_{i,w}(\theta) |_{\theta=\theta_t} \quad (4)$$

式中:  $n$  为 mini-batch 的大小;  $\alpha$  为学习率。

在第  $t$  步更新中, 可通过最小化参考数据上的损失来获得最佳权重  $w$ 。

$$w_t^* = \arg \min_w \frac{1}{m} \sum_{j=1}^m f_j^v(\theta_{t+1}(w)) \quad (5)$$

式中:  $m$  为参考数据的 mini-batch 的大小。

然后,通过单步梯度更新得到  $w_t^{(i)} = \{w_t^{(i)}, 1 \leq i \leq n\}$ , 如式(6)所示。

$$w_t^{(i)} = -\eta \frac{\partial}{\partial w_t^{(i)}} \frac{1}{m} \sum_{j=1}^m f_j^v(\theta_{t+1}(w)) \Big|_{w_t^{(i)}=0} \quad (6)$$

式中:每个权重参数的初始值均为0。

为了使权重  $w_t^{(i)}$  为非负值,保证训练过程的稳定性,以 L2RW 为代表的方法利用 Relu 函数,将所有负值转换为零,以此修正式(6)的输出<sup>[23]</sup>。

$$w_t^{(i)} = \max(w_t^{(i)}, 0) \quad (7)$$

尽管 L2RW 方法在高强度的标签噪声、类别分布极不平衡的分类问题上取得了巨大成功,利用 Relu 函数将许多样本的权重设置为0,但在低资源场景下的迁移学习中并非理想选择,原因在于采用近似求权重的方案很难保证参考数据的损失沿着梯度下降方向减小。

为此,本文设计了一种新颖的非负权重函数,旨在替代式(7)中的近似过程来准确计算权重,通过本文权重函数替换式(3)中的  $w^{(i)}$ ,以得到新的加权损失函数。

$$f_{i,\epsilon}(\theta) = \frac{2 * \text{sigmoid}(\beta \epsilon_i)}{n} f_i(\theta) \quad (8)$$

式中:  $\epsilon = \{\epsilon_i, 1 \leq i \leq n\}$  为可训练的参数;  $\beta$  为一个控制  $\epsilon_i$  对单步梯度更新的敏感性超参数。

同理,将式(4)一式(6)中的参数  $w^{(i)}$  替换为  $\epsilon$ ,以得到重新加权更新规则,如式(9)一式(11)所示。

$$\theta_{t+1}(\epsilon) = \theta_t - \alpha \nabla \sum_{i=1}^n f_{i,\epsilon}(\theta) \Big|_{\theta=\theta_t} \quad (9)$$

$$\epsilon_t^* = \arg \min_{\epsilon} \frac{1}{m} \sum_{j=1}^m f_j^v(\theta_{t+1}(\epsilon)) \quad (10)$$

$$\epsilon_t^{(i)} = -\eta \frac{\partial}{\partial \epsilon_t^{(i)}} \frac{1}{m} \sum_{j=1}^m f_j^v(\theta_{t+1}(\epsilon)) \Big|_{\epsilon_t^{(i)}=0} \quad (11)$$

最后,利用求得的最优权重参数  $\epsilon_t^*$  更新模型参数。

$$\theta_{t+1} = \theta_t - \alpha \nabla \sum_{i=1}^n f_{i,\epsilon_t^*}(\theta) \Big|_{\theta=\theta_t} \quad (12)$$

需要注意的是,本文源领域上标注数据的初始化权重均为  $\frac{1}{n}$ ,只需将式(8)中的权重因子  $\epsilon$  设置为0,利用基于梯度的元学习算法修正权重,使目标领域上参考数据的损失不断减少。

**算法 1** 低资源文本匹配场景下基于元学习的实例权重法

输入:源领域标注数据  $D^{\text{src}}$ ;目标领域参考数据  $D_{\text{ref}}^{\text{src}}$ ;目标领域验证集数据  $D_{\text{val}}^{\text{src}}$ ;模型  $\phi$  的参数  $\theta$ ;batch size 大小  $m, n$ ;元学习率  $\eta$ ;灵敏度参数  $\beta$ ;最大迭代轮数  $T$ 。

输出:  $\phi(\theta^*)$ 。

1.  $t = 1$ 。
2. WHILE  $t \leq T$ :
3. 从  $D^{\text{src}}$  中随机获取一个 mini-batch 的数据  $b_n^{\text{src}}$ ;
4. 从  $D_{\text{ref}}^{\text{src}}$  中随机获取一个 mini-batch 的数据  $b_m^{\text{ref}}$ ;
5. 利用  $b_n^{\text{src}}$  和  $b_m^{\text{ref}}$ ,根据式(10)、式(11)计算源领域上标注数

据的权重因子  $\epsilon^*$ ;

6. 根据式(12),利用计算出的  $\epsilon^*$  更新模型参数  $\phi(\theta)$ ;

7.  $t = t + 1$ ;

8. END

9. 利用参考数据  $D_{\text{ref}}^{\text{src}}$  对模型  $\phi(\theta)$  进行微调。

10. 返回在  $D_{\text{val}}^{\text{src}}$  上选出来的最佳模型  $\phi(\theta^*)$ 。

## 2.4 改进的预训练语言模型

针对预训练语言模型,当利用源领域上的标注数据更新模型全部参数(特征层参数+分类器层参数)时,有可能发生灾难性遗忘,即丢失对目标领域有用的语言学和语义学知识<sup>[4,14]</sup>。为此,在利用源领域上的标注数据训练模型的过程中,固定特征层参数,只在分类器层上进行元学习。主要原因为:预训练语言模型分类器层上初始化参数越好,对下游任务帮助越大。

Dodge 等<sup>[32]</sup>验证了上述结论,通过成百上千个不同的随机种子来改变 BERT 模型分类器层的初始化参数,以寻找最佳模型,其性能相较于之前报告的结果(模型相同,仅使用不同的随机种子)提升显著,甚至在部分 NLP 任务上的性能优于 XLNet 等 SOTA 模型<sup>[15]</sup>。

然而,上述方法需要大量实验,耗费了过多的训练时间和计算资源。为此,本文方法根据迁移学习思想,为预训练语言模型的分层获得更好的初始化参数,因此耗费的训练时间与计算资源更少。

## 3 实验结果与分析

### 3.1 评估集

为了评估本文方法,在两个常用的文本匹配任务上进行实验,分别为自然语言推理(Natural Language Inference, NLI)、复述检测(Paraphrase Identification, PI)。其中,自然语言推理任务评估集的处理方式遵循已有研究惯例,使用涵盖多种主题的 MultiNLI 数据集作为源领域数据,而将数据集 SciTail 作为目标领域数据,每个样本包含一个三元组(前提,假设,关系标签)<sup>[9,10,33,34]</sup>。具体地,本文从 SciTail 原始训练集中随机抽取少量实例来构建目标领域的训练集,而验证集与测试集的划分方式与原数据集相同,以模拟低资源场景。表 1 为自然语言推理任务的评估集统计信息。

**Table 1 Sample statistics of natural language reasoning task evaluation set**

| 领域   | 数据集      | 训练集     | 验证集   | 测试集   |
|------|----------|---------|-------|-------|
| 源领域  | MultiNLI | 261 799 | N/A   | N/A   |
| 目标领域 | SciTail  | 23 596  | 1 304 | 2 126 |

复述检测任务采用常用的社区问答、重复问题检测基准数据集 CQADupStack<sup>[35]</sup>。该数据集由 12 个论坛的标注数据组成,为了模拟低资源场景,对数据集进行重新划分,

选择最大的 3 个论坛(English、gaming 和 tex)作为源领域,其余 9 个论坛作为目标领域。表 2 给出了重新划分后的数据集统计信息。需要注意的是,源领域只有训练数据。

Table 2 Retelling detection task evaluation set sample statistics

表 2 复述检测任务评估集样本统计

| 领域   | 论文缩写 | 论坛           | 训练集   | 验证集 | 测试集   |
|------|------|--------------|-------|-----|-------|
| 源领域  | eng  | English      | 4 096 | N/A | N/A   |
|      | gam  | gaming       | 4 795 | N/A | N/A   |
|      | tex  | tex          | 6 906 | N/A | N/A   |
| 目标领域 | mat  | mathematical | 500   | 100 | 1 628 |
|      | wor  | wordpress    | 500   | 100 | 822   |
|      | pro  | programmers  | 500   | 100 | 2 211 |
|      | phy  | physics      | 500   | 100 | 2 551 |
|      | web  | webmasters   | 500   | 100 | 1 833 |
|      | sta  | stats        | 500   | 100 | 959   |
|      | uni  | unix         | 500   | 100 | 2 403 |
|      | and  | android      | 500   | 100 | 2 437 |
|      | gis  | gis          | 500   | 100 | 1 524 |

3.2 实验设置与评价指标

所有方法均基于 TensorFlow (https://www.tensorflow.org),在 Tesla K80 GPU 上进行训练。RE2 模型的隐藏层大小设为 150,block 数量设为 2,卷积编码器层数为 3,卷积核大小为 3,单个句子的最大长度设为 100,通过 300 维的 Glove 向量初始化词嵌入且在训练过程中保持不变,优化器使用 Adam,学习率固定为 1e-3。同时,为了提升实验效率,采用参数量为 12 MB 的 ALBERT 模型,优化器仍使用 Adam,学习率为 3e-5,最大序列长度为 128<sup>[2,4,36,37]</sup>。此外,所有实验中元学习的学习率固定为 0.01,灵敏度参数在目标领域的验证集数据上进行调节,可选择范围为 (1, 10, 50, 100)。

本文采用正确率(Accuracy, Acc)、F1 值和 AUC 值评估模型性能,先在目标领域的验证集上选择正确率最高的模型,再在目标领域的测试集上进行评估,每组实验进行 3 次,每次使用不同的随机种子,结果取均值。

3.3 基线方法

为了更全面地评价本文方法,选取两个具有代表性的基准模型:RE2 代表传统深度模型<sup>[2]</sup>;ALBERT 代表深层预训练语言模型<sup>[4]</sup>。基线方法为:①Src-only 是一种只使用源领域上的标注数据训练模型的方法;②Tgt-only 在模型训练过程中仅使用目标领域上的标注数据;③Finetune 是一种常用的迁移学习方法,先利用源领域上的标注数据进行训练,再利用目标领域上的标注数据微调模型;④L2RW 是一种基于元学习的实例权重法,最初用于解决标签噪声与类别分布不平衡的问题,本文将其应用在迁移学习中<sup>[23]</sup>。

3.4 实验结果

3.4.1 整体结果

本文参考数据规模为 300 条,整体实验结果如表 3、表

4 所示(最优用粗体表示、次优用下划线表示)。在自然语言推理任务上,本文两个基准模型取得了最优结果,基准模型 RE2 相较于次优基线方法,正确率、AUC 值和 F1 值分别提升 1.4%、1.1% 和 2.0%;基准模型 ALBERT 相较于次优基线方法,正确率、AUC 值和 F1 值分别提升 0.7%、0.2% 和 1.5%。在复述检测任务上,本文方法相较于基准模型 RE2,在 25 个(共 27 个)迁移场景中表现最佳,在 English、gaming 和 text 等 3 个源领域上相较于次优基线方法,平均分类正确率分别提升 1.6%、1.3% 和 1.5%;本文方法相较于基准模型 ALBERT,在 24 个(共 27 个)迁移场景中表现最佳,在 English、gaming 和 text 等 3 个源领域相较于次优基线方法,平均分类正确率分别提升 0.9%、0.8% 和 0.6%。

Finetune 作为常用的迁移学习基线方法,在两个基准模型 RE2、ALBERT 上分别带来了正向、负向收益。在以 RE2 为代表的普通神经网络模型中,Finetune 方法性能明显优于 Tgt-only、Src-only,原因为 Finetune 方法综合了两者优势:①利用丰富的源领域数据为模型学到了良好的表示;②利用目标领域的标注数据微调模型,使模型能更好地拟合目标领域上的数据分布。在以 ALBERT 为代表的深层预训练语言模型中,Finetune 方法表现并不好,甚至会出现明显的负迁移现象,即效果相较于基线方法 Tgt-only 更差,例如在迁移场景 English → statistics (PI)、gaming → webmasters (PI)、MultiNLI → SciTail (NLI)中,正确率分别下降 7.3%、0.7% 和 10.2%。

L2RW 与基线方法 Finetune 的效果接近,但在所有迁移场景中逊色于本文方法。同时,L2RW 方法在多个迁移场景下的效果远低于本文方法,例如在 gaming → word-press(PI)的迁移场景中,当基准模型为 RE2 时,L2RW 方法相较于本文方法的正确率下降 4.6%;在 English → android (PI)的迁移场景中,当基准模型为 ALBERT 时,L2RW 方法相较于本文方法正确率下降 3.1%。

Table 3 Experimental results of natural language reasoning tasks (reference data of 300)

表 3 自然语言推理任务上的实验结果(参考数据 300 条) (%)

| 模型     | 方法        | Acc         | AUC         | F1          |
|--------|-----------|-------------|-------------|-------------|
| RE2    | Tgt-only  | 60.0        | 72.3        | 61.2        |
|        | Src-only  | 63.9        | 69.7        | 60.6        |
|        | Fine-tune | 69.7        | 77.8        | <u>65.8</u> |
|        | L2RW      | <u>70.9</u> | <u>78.4</u> | <u>65.8</u> |
|        | Ours      | <b>72.3</b> | <b>79.5</b> | <b>67.8</b> |
|        | Tgt-only  | 87.9        | 94.8        | 84.4        |
| ALBERT | Src-only  | 78.8        | 87.2        | 69.4        |
|        | Fine-tune | 77.7        | 83.8        | 71.1        |
|        | L2RW      | <u>89.4</u> | <u>95.7</u> | <u>85.8</u> |
|        | Ours      | <b>90.1</b> | <b>95.9</b> | <b>87.3</b> |

3.4.2 灵敏度因子的影响

本文在 PI 任务上,验证灵敏度因子对所提方法的影响,超参数的可调节范围为 (1, 10, 50, 100),选取 English → physics (PI)、gaming → statistics (PI)这两个迁移场景对

Table 4 Experiment result of retelling detection tasks(300 reference data)

表4 复述检测任务上的实验结果(参考数据300条)

(%)

| 模型     | 源领域     | 方法          | 目标领域正确率     |             |             |             |             |             |             |             |             | 所有目标领域<br>平均值 |             |             |
|--------|---------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|---------------|-------------|-------------|
|        |         |             | mat         | wor         | pro         | phy         | web         | sta         | uni         | and         | gis         | Acc           | AUC         | F1          |
| RE2    | N/A     | Tgt-only    | 66.3        | 70.9        | 82.3        | 76.7        | 78.5        | 69.3        | 77.7        | 76.3        | 72.5        | 74.5          | 77.2        | 56.4        |
|        |         | Src-only    | 73.8        | 62.1        | 72.4        | 79.7        | 57.6        | 71.6        | 66.3        | 66.9        | 67.5        | 68.7          | 77.9        | 60.1        |
|        | english | Fine-tune   | <b>79.0</b> | 80.7        | 86.0        | <u>87.2</u> | <u>85.5</u> | <u>82.5</u> | 83.5        | 85.2        | 81.9        | <u>83.5</u>   | <u>88.3</u> | <u>74.6</u> |
|        |         | L2RW        | 77.7        | <u>81.6</u> | <u>86.7</u> | 85.9        | 84.7        | 82.4        | <u>84.3</u> | <u>85.6</u> | <u>82.3</u> | <u>83.5</u>   | 87.4        | 73.6        |
|        |         | <b>Ours</b> | <u>78.6</u> | <b>83.8</b> | <b>88.2</b> | <b>88.1</b> | <b>86.8</b> | <b>84.0</b> | <b>85.8</b> | <b>87.3</b> | <b>83.3</b> | <b>85.1</b>   | <b>89.6</b> | <b>77.3</b> |
|        |         | Src-only    | 76.5        | 78.4        | 85.3        | 83.2        | 77.8        | 78.1        | 79.4        | 82.9        | 76.0        | 79.7          | 85.8        | 72.1        |
|        | gaming  | Fine-tune   | 79.0        | <u>84.0</u> | <u>88.8</u> | <u>88.1</u> | <u>85.8</u> | <u>83.4</u> | 83.6        | <u>89.1</u> | <b>84.2</b> | <u>85.1</u>   | <u>89.6</u> | <u>77.3</u> |
|        |         | L2RW        | <u>80.1</u> | 80.2        | 88.1        | 86.6        | <u>85.8</u> | 82.4        | <u>84.0</u> | 88.0        | 80.5        | 84.0          | 88.1        | 75.3        |
|        |         | <b>Ours</b> | <b>80.9</b> | <b>84.8</b> | <b>90.3</b> | <b>88.3</b> | <b>87.4</b> | <b>85.5</b> | <b>86.0</b> | <b>90.5</b> | <u>83.6</u> | <b>86.4</b>   | <b>90.7</b> | <b>79.4</b> |
|        |         | Src-only    | 77.3        | 72.4        | 76.3        | 76.2        | 60.8        | 75.4        | 72.7        | 69.4        | 76.5        | 73.0          | 86.6        | 68.8        |
|        | tex     | Fine-tune   | <u>80.6</u> | <u>83.5</u> | 88.0        | <u>87.7</u> | <u>86.7</u> | <u>84.3</u> | 84.8        | <b>89.4</b> | <u>84.0</u> | <u>85.4</u>   | <u>90.6</u> | <u>78.4</u> |
|        |         | L2RW        | 78.3        | 83.4        | <u>88.5</u> | 86.4        | 86.3        | 83.4        | <u>84.9</u> | <u>89.1</u> | 81.1        | 84.6          | 89.0        | 76.6        |
|        |         | <b>Ours</b> | <b>81.5</b> | <b>86.3</b> | <b>89.5</b> | <b>88.6</b> | <b>87.9</b> | <b>85.4</b> | <b>86.6</b> | <b>89.4</b> | <b>86.5</b> | <b>86.9</b>   | <b>91.5</b> | <b>80.2</b> |
|        |         | Src-only    | 83.6        | 89.8        | 90.0        | 90.9        | 90.6        | 88.3        | 88.0        | 91.9        | 88.4        | 89.1          | 92.6        | 83.5        |
| ALBERT | N/A     | Tgt-only    | 78.2        | 71.2        | 81.6        | 85.3        | 75.3        | 78.5        | 77.7        | 77.7        | 72.9        | 77.6          | 89.8        | 73.0        |
|        |         | Src-only    | 83.9        | 89.7        | <u>91.7</u> | 90.4        | <u>91.2</u> | 81.0        | 80.6        | <u>91.3</u> | 88.3        | 87.6          | 89.5        | 77.7        |
|        | english | Fine-tune   | <u>84.2</u> | <u>91.2</u> | 91.2        | <u>91.5</u> | 90.9        | <u>88.6</u> | <u>88.0</u> | 89.1        | <u>89.0</u> | <u>89.3</u>   | <u>92.7</u> | <u>83.8</u> |
|        |         | L2RW        | <b>84.3</b> | <b>91.6</b> | <b>92.9</b> | <b>91.8</b> | <b>92.0</b> | <b>89.1</b> | <b>89.1</b> | <b>92.2</b> | <b>89.2</b> | <b>90.2</b>   | <b>93.7</b> | <b>85.4</b> |
|        |         | Src-only    | 82.9        | 85.9        | 87.6        | 88.3        | 86.2        | 84.6        | 86.8        | 89.2        | 88.5        | 86.3          | 91.6        | 79.9        |
|        | gaming  | Fine-tune   | <b>84.8</b> | 90.6        | 91.0        | 90.7        | 89.9        | <u>87.9</u> | 88.6        | <u>92.1</u> | 88.6        | <u>89.4</u>   | <u>92.9</u> | <u>83.7</u> |
|        |         | L2RW        | 82.5        | <u>90.7</u> | <u>91.8</u> | <u>91.3</u> | <u>91.5</u> | 86.6        | <u>88.9</u> | 90.8        | <u>89.0</u> | 89.2          | 92.8        | <u>83.7</u> |
|        |         | <b>Ours</b> | <u>83.9</u> | <b>90.8</b> | <b>92.5</b> | <b>92.0</b> | <b>91.8</b> | <b>89.5</b> | <b>89.0</b> | <b>92.3</b> | <b>90.2</b> | <b>90.2</b>   | <b>93.7</b> | <b>85.4</b> |
|        |         | Src-only    | 80.4        | 78.8        | 81.1        | 83.1        | 75.0        | 81.9        | 83.5        | 77.3        | 82.0        | 80.3          | 92.0        | 75.8        |
|        | tex     | Fine-tune   | <b>85.2</b> | <u>90.1</u> | 91.4        | 90.6        | <u>91.4</u> | 88.3        | <b>89.8</b> | <u>91.6</u> | <u>89.3</u> | <u>89.7</u>   | <u>93.2</u> | <u>84.4</u> |
|        |         | L2RW        | 83.1        | 89.9        | <u>92.2</u> | <u>91.1</u> | <u>91.4</u> | <u>88.8</u> | 88.5        | 90.4        | 87.6        | 89.2          | 92.9        | 84.6        |
|        |         | <b>Ours</b> | <u>85.1</u> | <b>91.1</b> | <b>92.3</b> | <b>91.6</b> | <b>91.8</b> | <b>89.5</b> | <u>89.6</u> | <b>92.4</b> | <b>89.4</b> | <b>90.3</b>   | <b>93.6</b> | <b>85.5</b> |

基准模型进行评估,实验结果如图3所示。其中,X轴表示灵敏度因子的值;Y轴表示目标领域上验证集的正确率。由此可见,基准模型RE2、ALBERT在两个迁移场景中趋势相似,当 $\beta = 50$ 或100时,本文方法在验证集上的分类正确率达到峰值,原因可能为适度的灵敏度因子能更方便地调整源领域数据的权重分布,更好地拟合目标领域的分布,以提升模型效果。

### 3.4.3 参考数据数量的影响

为了验证参考数据数量对本文方法的影响,将参考数据数量分别设置为100、300和500,两个基准模型RE2、ALBERT在不同迁移场景下的效果如图4所示(X轴表示参考数据数量;Y轴表示所有9个目标领域测试集上的平均正确率)。由此可见,当参考数据数量增加时,本文方法与基线方法的效果都得到了提升。同时,在所有的迁移场景中,对于基准模型RE2、ALBERT,本文方法在3个不同大小的参考数据上均取得了最好效果,进一步验证了本文方法的有效性。

### 3.4.4 预训练语言模型上的消融实验

针对预训练语言模型,为了检验元学习实例权重法与适配策略的有效性,额外构建了不使用元学习的方法(w/o





Fig. 3 Impact of sensitivity factor on RE2 and ALBERT in two migration scenarios of PI task

图3 灵敏度因子在PI任务的两个迁移场景中对RE2与ALBERT的影响

meta learning)和不使用适配策略的方法(w/o adaptation strategy)。当参考数据的规模为100时,每个源领域上所有9个迁移场景中的目标领域测试集的平均正确率如表5所示(最优结果用粗体表示,次优结果用下划线表示)。由



此可知, w/o adaptation strategy 方法会降低模型效果, 表明适配策略(即仅在预训练语言模型的分层器层上进行元学习)可有效缓解灾难性遗忘。

对于预训练语言模型而言, Finetune 方法使用源领域的标注数据更新所有参数, 而 w/o meta learning 方法使用了适配策略, 即仅利用源领域的标注数据更新分类器层参数, 期间保持特征层参数固定。实验表明, 本文方法显著优于 Tgt-only 基线方法, 在 English、gaming 和 tex 源领域上的平均正确率分别提升 1.5%、1.4% 和 1.4%, 验证了良好的初始化分类器层参数能提升预训练语言模型在下游任务上的效果。此外, w/o meta-learning 方法相较于本文方法的效果显著下降(源领域为 English 时, 效果下降 1.2%), 验证了元学习实例权重法可有效为源领域的标注数据自适应分配合适的权重。

Table 5 Ablation experiment based on ALBERT benchmark model

表 5 基于 ALBERT 基准模型的消融实验 (%)

| 方法                      | 源领域         |             |             |
|-------------------------|-------------|-------------|-------------|
|                         | english     | gaming      | tex         |
| Tgt-only                | 88.0        | 88.0        | 88.0        |
| Finetune                | 87.1        | 88.3        | 88.2        |
| <b>Ours</b>             | <b>89.5</b> | <b>89.4</b> | <b>89.4</b> |
| w/o meta-learning       | 88.3        | 88.7        | 88.5        |
| w/o adaptation strategy | 88.8        | 89.1        | 89.3        |

## 4 结语

本文针对低资源场景下的文本匹配问题, 提出一种基于元学习实例权重法的跨领域深度文本匹配方法。该方法利用梯度下降优化算法, 通过最小化目标领域上少量标注数据的损失, 将不同权重自适应地分配给源领域上的标注数据, 从而更好地拟合目标领域上的数据分布, 进而提升模型迁移效果。

为了将该方法更好地推广到预训练语言模型, 提出一种适配策略, 保持预训练语言模型的特征层参数固定, 只在分类器层执行元学习实例权重法, 不仅可缓解预训练语言模型在迁移场景下可能出现的灾难性遗忘问题, 还可显著提升预训练语言模型的训练效率。

同时, 将两个具有代表性的基准模型 RE2、ALBERT, 在两个常见的文本匹配任务自然语言推理和复述检测数据集上进行实验。实验表明, 在绝大多数迁移场景下本文方法都优于其他基线方法, 更重要的是当基准模型为预训练语言模型 ALBERT 时, 其他基线方法都会出现负迁移现象, 而本文方法始终优于只使用目标领域标注数据的 Tgt-only 基线方法, 可有效缓解负迁移问题。未来, 将利用主动学习挑选目标领域的参考数据, 将本文方法拓展到其他应用场景。

## 参考文献:

- [1] GONG Y, LUO H, ZHANG J. Natural language inference over interaction space[DB/OL]. <https://arxiv.org/pdf/1709.04348>.
- [2] YANG R, ZHANG J, GAO X, et al. Simple and effective text matching with richer alignment features[C]// Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019: 4699-4709.
- [3] DEVLIN J, CHANG M W, LEE K, et al. Bert: pre-training of deep bidirectional transformers for language understanding[C]// Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2019: 4171-4186.
- [4] LAN Z Z, CHEN M D, GOODMAN S, et al. Albert: a lite bert for self-supervised learning of language representations[DB/OL]. <https://www.arxiv.org/pdf/1909.11942>.
- [5] POERNER N, SCHÜTZE H. Multi-view domain adapted sentence embeddings for low-resource unsupervised duplicate question detection[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing, 2019: 1630-1641.
- [6] RUDER S, PLANK B. Learning to select data for transfer learning with bayesian optimization[C]// Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, 2017: 372-382.
- [7] SHEN J, QU Y, ZHANG W, et al. Wasserstein distance guided representation learning for domain adaptation[C]// Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence and Thirtieth Innovative Applications of Artificial Intelligence Conference and Eighth AAAI Symposium on Educational Advances in Artificial Intelligence, 2018: 4058-4065.
- [8] YU J, QIU M, JIANG J, et al. Modelling domain relationships for transfer learning on retrieval-based question answering systems in e-commerce[C]// Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining, 2018: 682-690.
- [9] QU C, JI F, QIU M, et al. Learning to selectively transfer: reinforced transfer learning for deep text matching[C]// Proceedings of the twelfth ACM International Conference on Web Search and Data Mining, 2019: 699-707.
- [10] WANG B, QIU M, WANG X, et al. A minimax game for instance based selective transfer learning[C]// Proceedings of the 25th ACM SIGKDD In-

- ternational Conference on Knowledge Discovery & Data Mining, 2019: 34–43.
- [11] FENG L, QIU M, LI Y, et al. Wasserstein selective transfer learning for cross-domain text mining[C]// Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing, 2021: 9772–9783.
- [12] TAY Y, TUAN L A, HUI S C. Co-stack residual affinity networks with multi-level attention refinement for matching text sequences[C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018: 4492–4502.
- [13] PENG S, CUI H, XIE N, et al. Enhanced-RCNN: an efficient method for learning sentence similarity[C]// Proceedings of the Web Conference, 2020: 2500–2506.
- [14] LIU Y, OTT M, GOYAL N, et al. Roberta: a robustly optimized Bert pretraining approach[DB/OL]. <https://arxiv.org/pdf/1907.11692>.
- [15] YANG Z L, DAI Z H, YANG Y M, et al. XINet: generalized autoregressive pretraining for language understanding[DB/OL]. <https://arxiv.org/pdf/1906.08237>.
- [16] WANG S, LIANG D, SONG J, et al. DABERT: dual attention enhanced bert for semantic matching[C]// Proceedings of the 29th International Conference on Computational Linguistics, 2022: 1645–1654.
- [17] LI L, LIAO Q, LAI M, et al. Local and global: text matching via syntax graph calibration[C]// IEEE International Conference on Acoustics, Speech and Signal Processing, 2024: 11571–11575.
- [18] XUE C, LIANG D, WANG S, et al. Dual path modeling for semantic matching by perceiving subtle conflicts[C]// IEEE International Conference on Acoustics, Speech and Signal Processing, 2023: 1–5.
- [19] SHI N, HAUER B, RILEY J, et al. Paraphrase identification via textual inference[C]// Proceedings of the 13th Joint Conference on Lexical and Computational Semantics, 2024: 133–141.
- [20] ZHAO X, HUANG J X. Bert-qaNet: Bert-encoded hierarchical question-answer cross-attention network for duplicate question detection[J]. Neurocomputing, 2022, 509: 68–74.
- [21] GAO W, WU J, XU G. Detecting duplicate questions in stack overflow via source code modeling[J]. International Journal of Software Engineering and Knowledge Engineering, 2022, 32(2): 227–255.
- [22] PENG R, JIN Z, HONG Y. GBT: generative boosting training approach for paraphrase identification[C]// Findings of the Association for Computational Linguistics, 2023: 6094–6103.
- [23] REN M, ZENG W, YANG B, et al. Learning to reweight examples for robust deep learning[C]// International Conference on Machine Learning, 2018: 4334–4343.
- [24] GAO J, ZHAO X, CHEN B, et al. Autotransfer: instance transfer for cross-domain recommendations[C]// Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2023: 1478–1487.
- [25] XIE P, ZHAO X, HE X. Improve the performance of CT-based pneumonia classification via source data reweighting[J]. Scientific Reports, 2023, 13(1): 9401.
- [26] TANG Y, RAHMANI D M, SAJADI P, et al. Selecting subsets of source data for transfer learning with applications in metal additive manufacturing[J]. Journal of Intelligent Manufacturing, 2024, 36: 3185–3206.
- [27] CUI Q, JIN X, DAI W, et al. Multi-source domain adaptation based on data selector with soft actor-critic[C]// International Workshop on Human Brain and Artificial Intelligence, 2022: 99–109.
- [28] XIE P, ZHAO X, HE X. Simultaneous selection and adaptation of source data via four-level optimization[J]. Transactions of the Association for Computational Linguistics, 2024, 12: 449–466.
- [29] HUAN Z, WANG Y, HE Y, et al. Learning to select instance: simultaneous transfer learning and clustering[C]// Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2021: 1950–1954.
- [30] ZHANG B, ZHANG C, MA F, et al. Adaptable text matching via meta-weight regulator[C]// Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2022: 870–879.
- [31] WANG J, CHEN Y. Instance weighting methods[M]. Berlin: Springer, 2022.
- [32] DODGE J, ILHARCO G, SCHWARTZ R, et al. Fine-tuning pretrained language models: weight initializations, data orders, and early stopping[DB/OL]. <https://arxiv.org/pdf/2002.06305>.
- [33] WILLIAMS A, NANGIA N, BOWMAN S. A broad-coverage challenge corpus for sentence understanding through inference[C]// Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2018: 1112–1122.
- [34] KHOT T, SABHARWAL A, CLARK P. Scitail: a textual entailment dataset from science question answering[C]// Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence and Thirtieth Innovative Applications of Artificial Intelligence Conference and Eighth AAAI Symposium on Educational Advances in Artificial Intelligence, 2018: 5189–5197.
- [35] HOOGEVEEN D, VERSPOOR K M, BALDWIN T. Cquadupstack: a benchmark data set for community question-answering research[C]// Proceedings of the 20th Australasian Document Computing Symposium, 2015: 1–8.
- [36] PENNINGTON J, SOCHER R, MANNING C D. Glove: global vectors for word representation[C]// Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, 2014: 1532–1543.
- [37] KINGMA D P, BA J L. Adam: a method for stochastic optimization[DB/OL]. <https://arxiv.org/pdf/1412.6980>.

(责任编辑:刘嘉文)