

4-12-2023

## Cross-domain Text Sentiment Classification Based on Auxiliary Classification Networks

Na Ma

*1.School of Business Administration, Liaoning Technical University, Huludao 125105, China;;  
vicky070708@163.com*

Tingxin Wen

*1.School of Business Administration, Liaoning Technical University, Huludao 125105, China;*

Xu Jia

*2.School of Electronics and Information Engineering, Liaoning University of Technology, Jinzhou 121001, China;*

Xiaohui Li

*2.School of Electronics and Information Engineering, Liaoning University of Technology, Jinzhou 121001, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Cross-domain Text Sentiment Classification Based on Auxiliary Classification Networks

## Abstract

**Abstract:** To align exactly the texts with same sentiment polarities of source and target domains, and to enlarge the feature difference of different sentiment texts as much as possible, a domain adaptation model with weighted adversarial networks is proposed. *A new structured classification network consisting of a main classification network and an auxiliary classification network is proposed, in which the main classification network is used to perform supervised learning on the labeled texts of the source domain, and the auxiliary classification network is used to improve the distinguishability of the text features. A calculation method of multiple adversarial network weights is proposed to realize the exact alignment of same class samples of different domains.* Experimental results show that, for Amazon dataset, the average recognition accuracy for the texts of target domains can reach 84.22%, which is 2.07% higher than the compared models. The optimized feature extractor and the feature classifier can be applied to the source and target domains simultaneously on the proposed model, and can provide reliable data for the simulation and modeling of text analysis in different fields.

## Keywords

text sentiment classification, domain adaptation, adversarial network, auxiliary classification network

## Recommended Citation

Na Ma, Tingxin Wen, Xu Jia, Xiaohui Li. Cross-domain Text Sentiment Classification Based on Auxiliary Classification Networks[J]. Journal of System Simulation, 2023, 35(4): 721-733.

# 基于辅助分类网络的跨领域文本情感分类

马娜<sup>1</sup>, 温廷新<sup>1</sup>, 贾旭<sup>2</sup>, 李晓会<sup>2</sup>

(1. 辽宁工程技术大学 工商管理学院, 辽宁 葫芦岛 125105; 2. 辽宁工业大学 电子与信息工程学院, 辽宁 锦州 121001)

**摘要:** 为了使源域与目标域中同类情感文本准确对齐, 且尽可能增大不同情感文本特征差异, 提出了一种具有加权对抗网络的域适应模型。提出了一种主分类网络与辅助分类网络相结合的网络结构, 主分类网络用于对源域文本进行有监督学习, 辅助分类网络用来提高文本特征的可区分度; 提出了一种多对抗网络权重计算方法, 实现域间同类样本的准确对齐。实验结果表明: 对于 Amazon 数据集, 提出的模型对于目标域中文本的平均识别准确率可达 84.22%, 对比模型提升了 2.07%, 说明该模型可将优化得到的特征提取器与特征分类器同时较好的适用于源域与目标域中, 从而对不同领域文本分析仿真建模提供了可靠的数据。

**关键词:** 文本情感分类; 域适应; 对抗网络; 辅助分类网络

中图分类号: TP391.4 文献标志码: A 文章编号: 1004-731X(2023)04-0721-13

DOI: 10.16182/j.issn1004731x.joss.21-1283

**引用格式:** 马娜, 温廷新, 贾旭, 等. 基于辅助分类网络的跨领域文本情感分类[J]. 系统仿真学报, 2023, 35(4): 721-733.

**Reference format:** Ma Na, Wen Tingxin, Jia Xu, et al. Cross-domain Text Sentiment Classification Based on Auxiliary Classification Networks[J]. Journal of System Simulation, 2023, 35(4): 721-733.

## Cross-domain Text Sentiment Classification Based on Auxiliary Classification Networks

Ma Na<sup>1</sup>, Wen Tingxin<sup>1</sup>, Jia Xu<sup>2</sup>, Li Xiaohui<sup>2</sup>

(1. School of Business Administration, Liaoning Technical University, Huludao 125105, China;

2. School of Electronics and Information Engineering, Liaoning University of Technology, Jinzhou 121001, China)

**Abstract:** To align exactly the texts with same sentiment polarities of source and target domains, and to enlarge the feature difference of different sentiment texts as much as possible, a domain adaptation model with weighted adversarial networks is proposed. A new structured classification network consisting of a main classification network and an auxiliary classification network is proposed, in which the main classification network is used to perform supervised learning on the labeled texts of the source domain, and the auxiliary classification network is used to improve the distinguishability of the text features. A calculation method of multiple adversarial network weights is proposed to realize the exact alignment of same class samples of different domains. Experimental results show that, for Amazon dataset, the average recognition accuracy for the texts of target domains can reach 84.22%, which is 2.07% higher than the compared models. The optimized feature extractor and the feature classifier can be applied to the source and target domains simultaneously on the proposed model, and can provide reliable data for the simulation and modeling of text analysis in different fields.

**Keywords:** text sentiment classification; domain adaptation; adversarial network; auxiliary classification network

收稿日期: 2021-12-13 修回日期: 2022-02-26

基金项目: 国家自然科学基金(61806121); 辽宁省教育厅基本科研项目青年项目(LJKQZ2021142)

第一作者: 马娜(1985-), 女, 讲师, 博士生, 研究方向为机器学习与智能决策。E-mail: vicky070708@163.com

## 0 引言

随着电子商务规模不断扩大,产生了大规模的数据信息,而用户与商家很难对这些大规模数据进行浏览与分析,因此,通过对大规模数据分析进行仿真建模,从而向商家提供有效的经营策略,向消费者提供感兴趣的物品信息已成为研究热点。当前,这种仿真建模所依赖的数据大多仍为用户对商家的评分信息,但评分具有一定的随意性,如“不评论则默认5星好评”等,而文本评论情感信息则相对更能表达消费者的真实感受,因此,准确判断文本的情感信息将会进一步提升数据分析仿真结果的可信度。

传统的对单一领域文本进行情感分类通常采用对该领域大量标注样本有监督学习的方式进行,例如,若要判断某一条“手机”文本评论的情感,需要对大量“手机”评论样本进行情感类别标注,并在有监督学习后获得评论情感分类规则;同样,如果要判断“书籍”文本评论的情感,也同样需要样本标注与有监督学习2个阶段。然而,电子商务网站通常包含多种领域的的数据,对每一领域都进行大量样本标注将是十分耗费人力的,如果采用带有标签的“手机”领域(源域)样本和无标签的“书籍”领域(目标域)样本,便可以通过机器学习获取2种领域的公共知识,从而实现将源域有监督学习获得的知识跨领域应用到目标域文本情感分类中,这种跨领域文本情感分类的研究将具有重要的理论价值。

## 1 相关工作

目前,关于跨领域文本情感分类方法主要包含以下6类<sup>[1]</sup>: ①基于实例的域适应,即选择源域中关键的样本作为训练数据。例如,Robert等将源域与目标域样本Kullback-Leibler距离较小的样本作为关键样本<sup>[2]</sup>; Xia等采用PU(positive-unlabeled)学习获得的高概率样本作为训练数据<sup>[3]</sup>; Giacomo等则通过马尔可夫模型结合迁移学习思

想,将对情感依赖较高的样本作为关键样本<sup>[4]</sup>。②基于特征的域适应,即通过枢纽特征实现知识的迁移。例如,John等将具有较高领域互信息的特征作为枢轴特征,并通过枢轴特征实现不同域间非枢轴特征的关联<sup>[5]</sup>; Yftah等采用了一层隐藏层的神经网络结构,通过学习非枢轴特征与枢轴特征之间的映射关系,获得有效的文本特征<sup>[6]</sup>; Wang等提出了一种情感关联索引思想,对不同词语进行了关联性分析<sup>[7]</sup>; Tareq等基于信息熵、比值比、卡方检验3种特征选择方式,实现了文本的跨领域分类<sup>[8]</sup>。③基于模型的域适应,即通过共享模型参数实现知识的共享。例如,Zhu等采用了SVD(singular value decomposition)分解结合神经网络实现了特征对齐<sup>[9]</sup>; Ganin等将对抗的思想引入到了域适应方法中,降低了源域与目标域特征分布差异<sup>[10]</sup>。基于对抗思想,许多学者对模型做了进一步的改进,如Li基于注意力机制获得了枢轴特征,并采用对抗网络建立了端对端的域适应模型<sup>[11]</sup>; Qu等通过让样本特征远离决策边界,进一步提高了同类样本的对齐程度与不同类样本的可区分程度<sup>[12]</sup>; He等在使用对抗网络的同时,将熵最小化与自集成引导作为正则项<sup>[13]</sup>; Zhao等采用了双向门控循环单元特征提取和卷积神经网络参数共享的模式,实现了跨领域文本分类<sup>[14]</sup>; Li等提出了一种枢轴特征选择器与可转移变换器相结合的方式,进一步提升了跨领域文本分类精度<sup>[15]</sup>。④基于词典的域适应,即利用不同域中通用的词典实现跨领域识别。例如,Mao等提出了一种联合情感词典<sup>[16]</sup>; Dolores等引入了领域独立的词典为跨领域文本情感分析服务<sup>[17]</sup>。⑤联合情感方法,即以无监督学习方式挖掘语义结构。例如,Huang等提出了主题相关适应性框架,对跨领域文本情感分类起到了积极的作用<sup>[18]</sup>; Zhou等基于主题的一致性,进一步降低了领域间样本的差异性<sup>[19]</sup>。⑥基于图的迁移方法,即通过构建传播图实现知识传递。例如,Giacomo等以文本语料表示为图,在词与词之间构建马尔可夫转移矩

阵对其进行关联<sup>[20]</sup>; Nelakurthi 等提出的用户-文本-特征三部曲较好地解决了知识的负迁移<sup>[21]</sup>。以上算法从不同角度针对跨领域文本情感分类问题进行了分析, 并在不同程度取得了较好的效果。

目前, 已有的大多基于对抗网络的算法仅仅考虑了源域与目标域数据的整体对齐, 但实际上, 不同情感文本的对齐是没有意义的, 而且还会引起知识的负迁移; 此外, 在模型训练过程中, 除考虑文本情感分类的准确性以外, 还应尽可能增大不同情感文本特征之间的差异, 进一步提高模型分类的可靠性。基于以上分析, 本文提出一种基于辅助分类网络的无监督域适应 (auxiliary classification networks based unsupervised domain adaptation, ACNUDA) 模型。该模型提出了主分类器与辅助分类器相结合的结构, 进一步增大了不同情感文本之间的差异性; 提出了加权多对抗网络结构, 从而实现不同域相同情感文本能够更为准确的对齐。

## 2 基于对抗的域适应模型

一些基于对抗思想的域适应模型在跨领域文本情感分类问题被更多的采用, 其中具有代表性的模型为 Ganin 提出的 DANN 模型<sup>[10]</sup> (domain-adversarial training of neural networks, DANN), 该模型采用特征提取网络、特征分类网络、域鉴别网络相结合的结构, 其中, 特征提取网络与特征分类网络用于实现源域样本的有监督学习, 而域鉴别网络用于降低源域与目标域样本之间的特征差异, 模型结构如图 1 所示。

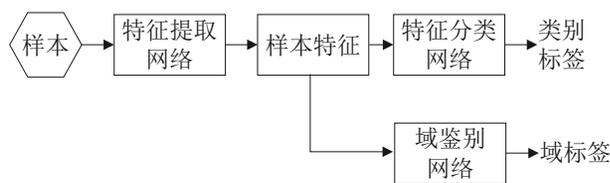


图 1 DANN 模型结构  
Fig. 1 DANN model structure

此外, 同样基于该思想的一些改进模型也相继被提出<sup>[11-12]</sup>。然而, 尽管通过实验验证了这些模

型的合理性和有效性, 但仍存在一定的问题, 例如, 不同域中的同类样本是否被分别准确的对齐, 不同类别样本之间是否具有足够的可区分性。针对以上问题, 本文将提出一种具有多对抗网络的域适应模型, 实现跨领域文本情感的准确分类。

## 3 ACNUDA 模型

### 3.1 模型参数定义

在 ACNUDA 模型中, 涉及的符号有: 源域为  $D_s = \{(x_i^s, y_i^s)\}_{i=1}^{n_s}$ , 域标签为  $d_i^s = [1, 0]^T$ , 其中,  $x_i^s$  与  $y_i^s$  分别为源域中的样本和对应的类别标签,  $n_s$  为源域中样本的个数; 目标域  $D_t = \{(x_i^t)\}_{i=1}^{n_t}$ , 域标签为  $d_i^t = [0, 1]^T$ , 其中,  $x_i^t$  为目标域中样本,  $n_t$  为目标域中样本的个数, 这里, 目标域样本是不包含标签信息的。

### 3.2 模型设计结构与目标

ACNUDA 模型由 4 类网络组成, 分别为特征提取器  $G_f$ , 特征分类器  $G_y$ , 辅助分类器  $G_y^{(c)}$ ,  $c=1, 2$ , 域鉴别器  $G_d^{(k)}$ ,  $k=1, 2, \dots, K$ , 其中,  $K$  为文本情感类别数目, 而 4 类网络的参数分别为  $\theta_f, \theta_y, \theta_y^{(c)}, \theta_d^{(k)}$ ,  $k=1, 2, \dots, K, c=1, 2$ 。这里, ACNUDA 模型结构如图 2 所示。

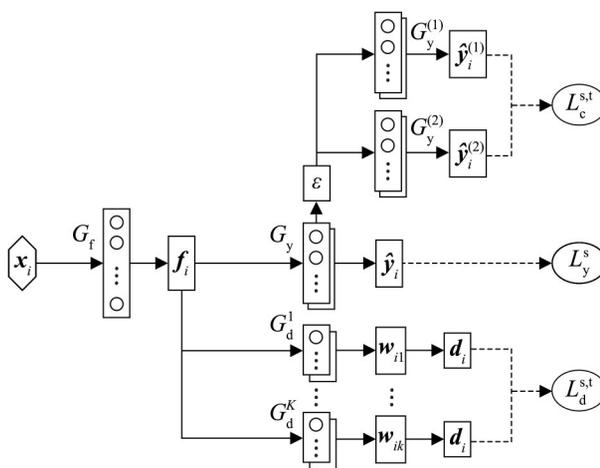


图 2 ACNUDA 模型的结构  
Fig. 2 Structure of ACNUDA model

图中,  $\hat{y}_i$ ,  $\hat{y}_i^{(c)}$ ,  $w_{ik}$  分别为使用特征分类器时输出的样本分类结果, 使用第  $c$  个辅助分类器时输出的样本分类结果, 域鉴别器权重, 而  $\varepsilon$  为主分类网络生成辅助分类网络所需的参数。

提出该模型的目的在于: 通过训练获得有效的特征提取器  $f_i = G_f(x_i)$  与特征分类器  $y_i = G_y(f_i)$ , 使其同时适用于源域与目标域, 得到源域和目标域文本  $x_i$  的正确情感分类结果  $y_i$ 。

### 3.3 模型设计与改进思想

为进一步提高源域与目标域同类样本的对齐程度和不同类样本之间的可区分性, ACNUDA 模型从2个方面对 DANN 思想的模型进行重新构造。

(1) 辅助分类网络的设计。传统的基于神经网络通常采用交叉熵作为学习的损失函数, 然而, 该损失函数仅从识别的准确率角度进行了约束, 并未考虑不同类别样本特征之间是否具有足够的可区分性。基于以上分析, 提出了一种特征分类网络与辅助分类网络相结合的结构。

在 ACNUDA 模型中, 采用全连接结构分类网络作为主分类网络, 目的是实现对源域样本分类的有监督学习, 采用交叉熵作为分类损失函数:

$$L_y^s = -\frac{1}{n_s} \sum_{i=1}^{n_s} \sum_{k=1}^K y_{ik}^s \text{lb} \hat{y}_{ik}^s \quad (1)$$

式中:  $y_{ik}^s$  为源域中第  $i$  个样本真实标签向量  $y_i^s$  的第  $k$  个分量,  $y_i^s = [y_{i1}^s, y_{i2}^s, \dots, y_{iK}^s]^T$ ;  $\hat{y}_{ik}^s$  为该样本使用主分类网络预测的标签向量  $\hat{y}_i^s$  的第  $k$  个分量,  $\hat{y}_i^s = [\hat{y}_{i1}^s, \hat{y}_{i2}^s, \dots, \hat{y}_{iK}^s]^T$ ;  $K$  为样本的文本情感类别数目。

除主分类网络外, 模型还采用了一种辅助分类网络, 其目的是尽可能增大不同类别样本之间的差异, 提高分类结果的可靠性。

将主分类网络模型中的所有偏置项权重进行缩放, 即  $b_{lj} \rightarrow \{(1+\varepsilon)b_{lj}, (1-\varepsilon)b_{lj}\}$ ,  $l=1, 2, \dots, L-1$ ,  $j=1, 2, \dots, n_l$ , 其中,  $b_{lj}$  为主分类网络第  $l$  层网络第  $j$  个偏置项权重;  $n_l$  为第  $l$  层网络偏置项数目;  $\varepsilon$  为缩放系数,  $0 \leq \varepsilon \leq 0.5$ ;  $L$  为主分类网络的层数。

这样改进的思想在于: 通过对每一层偏置项

权重的调整, 构成了类似于2个用于辅助分类的超平面, 如果样本在辅助分类网络与主分类网络的分类结果能够保持较好的一致性, 则说明提取的样本特征与主分类器的分类面具有足够远的距离, 也就表示不同类别样本之间具有较大的差异性, 如图3(a)所示; 否则, 如果样本在辅助分类网络与主分类网络的分类结果不一致, 则说明2类样本特征之间的可区分度不高, 如图3(b)所示。

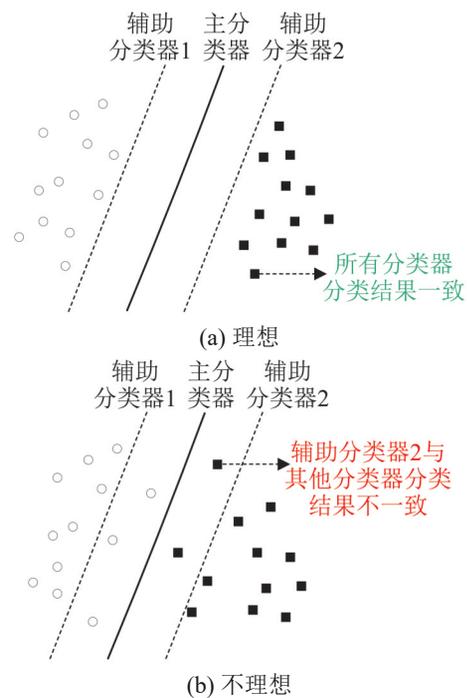


图3 不同分类效果

Fig. 3 Different classification effects

图中, ‘○’ 与 ‘■’ 分别为两类不同情感文本的特征。

基于以上分析, 辅助分类网络的损失函数为

$$L_c^{s,t} = -\frac{1}{2(n_s + n_t)} \sum_{c=1}^2 \sum_{i=1}^{n_s+n_t} \sum_{k=1}^K \hat{y}_{ik}^{(c)} \text{lb} \hat{y}_{ik} \quad (2)$$

式中:  $\hat{y}_{ik}^{(c)}$  为第  $i$  个样本采用第  $c$  个辅助分类网络时的分类结果,  $\hat{y}_i^{(c)} = [\hat{y}_{i1}^{(c)}, \hat{y}_{i2}^{(c)}, \dots, \hat{y}_{iK}^{(c)}]^T$ ;  $c=1$  为偏置项权重变化  $b_{lj} \rightarrow (1+\varepsilon)b_{lj}$  时得到的辅助分类器, 而  $c=2$  为偏置项权重变化  $b_{lj} \rightarrow (1-\varepsilon)b_{lj}$  时得到的辅助分类器。

(2) 加权域鉴别网络的设计。大多基于对抗的域鉴别网络仍采用降低源域与目标域总体特征分

布差异的思想, 忽略了样本的类别信息, 而实际上源域与目标域中不同类别样本的对齐是没有意义的。基于以上分析可知, 降低源域与目标域同类样本特征之间的差异才具有更重要的意义, 因此, 模型将针对每一类样本分别采用结构相同的域鉴别网络, 并让每一类样本作为该类域鉴别网络的训练样本, 进行网络参数训练, 从而提升同类样本之间的相似性。

由于源域中的样本是带有标签信息的, 所以在训练过程中, 可依据该样本真实标签将其指定到对应类别的域鉴别网络中进行训练; 而目标域中的样本是无标签的, 在训练过程中无法将其一次性准确地指定到对应的域鉴别网络中。针对该问题, MADA(multi-adversarial domain adaptation)模型<sup>[22]</sup>采用目标域样本的分类结果作为其伪标签向量, 并将该向量 $\hat{y}_i^t$ 中每一元素分别对应作为每一域鉴别网络损失的权重, 即 $\hat{y}_i^t = w_i$ ,  $\hat{y}_i^t = [\hat{y}_{i1}^t, \hat{y}_{i2}^t, \dots, \hat{y}_{iK}^t]^T$ ,  $w_i = [w_{i1}, w_{i2}, \dots, w_{iK}]^T$ 。然而, 在模型训练初期, 样本分类结果的准确性是很难得到保证的, 这会让目标域样本很有可能被指定到错误的域鉴别网络中去训练, 从而导致不同类样本错误对齐。

基于以上分析, 提出了一种基于分类标签相似性向量与分类标签向量相融合的域鉴别网络权重计算方法。在训练初期无论目标域样本分类结果是否准确, 该样本的分类结果会与源域中同类样本的分类结果具有较好的相似性, 而源域样本的标签是真实的, 这样便可以根据分类结果的相似性来初步估计出目标域样本的类别情况:

$$\hat{y}_{ik}^t - \text{similar} = \frac{\langle \frac{1}{N_{C_k}} \sum_{x_j^s \in C_k} \hat{y}_j^s, \hat{y}_i^t \rangle}{\left| \frac{1}{N_{C_k}} \sum_{x_j^s \in C_k} \hat{y}_j^s \right| \cdot |\hat{y}_i^t|} \quad (3)$$

式中:  $C_k$  为每一次迭代时包含的源域中第  $k$  类样本的集合;  $N_{C_k}$  为该次迭代源域中第  $k$  类样本个数,  $k = 1, 2, \dots, K$ 。而后, 通过 Softmax 函数处理, 获得该样本分类标签相似性向量:

$$\hat{y}_{i-s}^t = \left[ \frac{e^{\hat{y}_{i1}^t - \text{similar}}}{\sum_{j=k}^K e^{\hat{y}_{jk}^t - \text{similar}}}, \frac{e^{\hat{y}_{i2}^t - \text{similar}}}{\sum_{j=k}^K e^{\hat{y}_{jk}^t - \text{similar}}}, \dots, \frac{e^{\hat{y}_{iK}^t - \text{similar}}}{\sum_{j=k}^K e^{\hat{y}_{jk}^t - \text{similar}}} \right]^T \quad (4)$$

而随着训练迭代次数的增加, 目标域样本的分类结果 $\hat{y}_i^t$ 将会越来越趋于稳定和准确, 因此, 目标域样本分类结果在伪标签计算上逐渐将被赋予更大的权重, 基于以上分析, 提出了一种新的不同域鉴别器权重算法方法:

$$w_i = \frac{(N_{epoch} - n_{epoch})}{N_{epoch}} \hat{y}_{i-s}^t + \frac{n_{epoch}}{N_{epoch}} \hat{y}_i^t \quad (5)$$

式中:  $N_{epoch}$  为训练设定的  $epoch$  数目;  $n_{epoch}$  为当前的训练  $epoch$  次数;  $w_i = [w_{i1}, w_{i2}, \dots, w_{iK}]^T$ 。

相反, 如果样本来自于源域  $w_i = y_i^s$ , 即样本真实标签向量等同于域鉴别网络权重向量。

基于以上分析, 模型的域鉴别网络损失函数为

$$L_d^{s,t} = \frac{1}{n_s + n_t} \sum_{i=1}^{n_s+n_t} \sum_{k=1}^K [w_{ik} L_c(G_d^k(G_f(x_i)), d_i)] \quad (6)$$

式中:  $L_c$  为交叉熵损失函数。

综上, ACNUDA 模型结构如图 1 所示, 模型损失函数可由主分类损失  $L_y^s$ , 辅助分类损失  $L_c^{s,t}$ , 域鉴别损失  $L_d^{s,t}$  加权获得:

$$L(\theta_f, \theta_y, \theta_d^k) = L_y^s + \lambda_c L_c^{s,t} + \lambda_d L_d^{s,t} \quad (7)$$

式中:  $\lambda_c$  与  $\lambda_d$  为平衡因子, 通过实验优化获得。

### 3.4 模型参数优化求解

基于对模型设计结构及思想的分析, 可以得到模型参数  $\theta_f$ ,  $\theta_y$ ,  $\theta_d^k$  的优化求解可以分为 2 个步骤:

(1) 采用梯度下降方法调整特征提取器参数  $\theta_f$  与特征分类器参数  $\theta_y$ , 最小化损失函数  $L(\theta_f, \theta_y, \theta_d^k)$ , 如训练过程中的 step 5 所示, 目的是实现对源域目标的有监督学习, 降低特征分类器  $G_y$  与域鉴别器  $G_d^k$  的错误率,  $k = 1, 2, \dots, K$ 。此外, 通过最小化辅助分类器损失, 提升不同类别文本特征之间的差异性:

$$\theta_f^*, \theta_y^* = \arg \min_{\theta_f, \theta_y} L(\theta_f, \theta_y, \theta_d^k), k = 1, 2, \dots, K \quad (8)$$

(2) 采用梯度翻转方法, 即在计算  $\theta_d^k$  导数后添加一层梯度翻转层 (gradient reversal layer, GRL), 来调整域鉴别器参数  $\theta_d^k$ ,  $k=1, 2, \dots, K$ , 最大化损失函数  $L(\theta_f, \theta_y, \theta_d^k)$ , 如训练过程中的 step 6 所示, 从而提高源域与目标域同类目标特征之间的相似性:

$$\theta_d^{k*} = \arg \max_{\theta_d^k} L(\theta_f, \theta_y, \theta_d^k), k=1, 2, \dots, K \quad (9)$$

训练过程可用伪代码表示:

step 1: 源域数据  $D_s = \{(\mathbf{x}_i^s, \mathbf{y}_i^s)\}_{i=1}^{n_s}$ , 目标域数据  $D_t = \{(\mathbf{x}_i^t)\}_{i=1}^{n_t}$ , 平衡因子  $\lambda_d$  与  $\lambda_c$ 。

step 2: 初始化参数  $\theta_y^{(0)}$ ,  $\theta_f^{(0)}$  与  $\theta_d^{k(0)}$ , 其中,  $k=1, 2, \dots, K$ , 计数器  $r=0$ ;

step 3: for  $epoch=1, 2, \dots, N_{epoch}$  do

step 4: for  $batch=1, 2, \dots, n_{batch}$  do

$$\text{step 5: } \theta_f^{(r+1)} \leftarrow \theta_f^{(r)} - \eta \frac{\partial L^{(r)}}{\partial \theta_f}, \theta_y^{(r+1)} \leftarrow \theta_y^{(r)} - \eta \frac{\partial L^{(r)}}{\partial \theta_y};$$

$$\text{step 6: } \theta_d^{k(r+1)} \leftarrow \theta_d^{k(r)} + \eta \frac{\partial L^{(r)}}{\partial \theta_d^k}, k=1, 2, \dots, K,$$

$$r=r+1;$$

step 7: end for;

step 8: end for;

step 9: 输出最优的参数  $\theta_y^*$ ,  $\theta_f^*$ ,  $\theta_d^{k*}$ , 其中,  $k=1, 2, \dots, K$ 。

## 4 实验结果及分析

### 4.1 实验数据集

本实验采用 Amazon 数据集<sup>[23]</sup>, 该数据包含 4 个域, 分别为 Book(**B**), DVDs(**D**), Electronics(**E**), Kitchen (**K**), 每个域包含样本数目与样本示例如表 1 所示。

### 4.2 模型参数设定

本实验文本的原始特征设定为 mSDA 特征<sup>[24]</sup>, 特征分类器与每个域鉴别器分别设为定全连接网络结构<sup>[25]</sup>。确定了网络的结构后, 需要对参数  $\varepsilon$ , 超参数  $\lambda_d$  与  $\lambda_c$  进行选取。其中  $\varepsilon$  在 0~0.5 之间随机选取, 这里以  $\varepsilon=0.25$  为例; 而选取  $\lambda_d$  与  $\lambda_c$  的准则为目标域获得最大平均识别准确率的参数组合即为最优参数, 这里, 目标域平均识别准确率  $A_{ave}$  计算方法为

$$A_{ave} = \frac{1}{N_{transfer}} \sum_{D_s, D_t \in \{B, D, E, K\}} A_{D_s \rightarrow D_t} \quad (10)$$

式中:  $D_s$  和  $D_t$  分别为源域和目标域;  $A_{D_s \rightarrow D_t}$  为  $D_s \rightarrow D_t$  迁移条件下目标域样本识别准确率,  $N_{transfer}$  为源域与目标域组合方式数目。不同参数条件下的目标域平均识别准确率如表 2 所示。

表 1 数据集中部分样本  
Table 1 Some samples in dataset

域	样本数目	正样本示例	负样本示例
<b>B</b>	4 465	这是一本非常棒的书, 老少皆宜, 它以一种有趣的方式展示了为什么我们需要一种通用的测量形式	这本书传达了一个很好的信息, 可能会对我产生持久的影响, 但情节非常乏味, 书的中间部分基因和鳍鱼的关系似乎与书的其余部分不相适应, 不推荐
<b>D</b>	3 586	如果你没有这张 DVD, 你需要把它添加到你的收藏中。在我看来, 这是有史以来最好的美国动画电影	对于那些对这部电影赞不绝口的人来说, 你一定是在另一个维度或别的什么地方
<b>E</b>	5 681	我非常喜欢它, 我把它用在野外狩猎的户外小径相机里, 它能拍几张照片, 在各种天气的相机里, 我还会再买金斯顿	我最近刚买了这个, 当我安装它时, 诺顿在安装光盘上捕获了 2 个病毒
<b>K</b>	5 945	我很喜欢用这个铸造锅, 它煮得很好吃, 容量很大	绝对的劣质产品, 不要浪费你的钱, 当你磨任何东西的时候, 它都不会固定住, 这个产品肯定会让你发脾气

表 2 不同参数下的识别结果  
Table 2 Recognition results under different parameters

$\lambda_d$	$\lambda_c$				
	0.1	0.5	1.0	5.0	10.0
0.1	0.774	0.795	0.821	0.814	0.769
0.5	0.814	0.826	<b>0.832</b>	0.792	0.788
1.0	0.768	0.796	0.812	0.785	0.772
5.0	0.744	0.785	0.776	0.765	0.748
10.0	0.759	0.779	0.751	0.771	0.749

由表 2 可以看出, 当  $\lambda_c=1$ ,  $\lambda_d=0.5$  时, 可以获得最高的目标域样本平均识别准确率。此外, 训练时, 源域中选用 2 000 个样本, 包括 1 000 个正样本和 1 000 个负样本, 其中 1 800 个作为训练样本, 200 个作为验证样本, 目标域中所有的样本作为测试样本,  $n_{batch}=10$ , 每一个 *batch* 中正样本与负样本比例均为 1:1, 学习率  $\eta$  设置为 0.001, *epoch* 数目  $N_{epoch}=20$ 。

### 4.3 模型改进前后的实验结果及分析

为验证模型改进之处的有效性, 这里分别将改进前后的模型进行了实验对比。

模型 1: DANN。将文献[10]中 DANN 领域适应神经网络模型结构作为基线模型, 该模型采用单域鉴别网络实现样本的域分类, 损失函数为

$$L_1=L_y^s+\frac{\lambda_d}{n_s+n_t}\sum_{i=1}^{n_s+n_t}L_c(G_d(G_f(x_i)),d_i) \quad (11)$$

模型 2: DANN+ACN(auxiliary classification network)。该模型在 DANN 模型的基础上, 添加了辅助分类网络, 并仍然采用单域鉴别器实现域分类, 该模型的损失函数为

$$L_2=L_y^s+\lambda_cL_c^{s,t}+\frac{\lambda_d}{n_s+n_t}\sum_{i=1}^{n_s+n_t}L_c(G_d(G_f(x_i)),d_i) \quad (12)$$

模型 3: DANN+ACN+MAN(multi-adversarial network)。该模型在 DANN+ACN 模型的基础上, 添加了多对抗域鉴别网络结构, 目标域样本在进行训练时, 不同域鉴别网络损失的权重为样本预测的标签向量  $\hat{y}_i^t$ , 模型损失函数为

$$L_3=L_y^s+\lambda_cL_y^{s,t}+\frac{1}{n_s+n_t}\sum_{i=1}^{n_s+n_t}\sum_{k=1}^K[\hat{y}_{ik}L_c(G_d^k(G_f(x_i)),d_i)] \quad (13)$$

模型 4: ACNUDA Model。该模型在 DANN+ACN+MAN 模型的基础上, 域鉴别网络损失的权重由提出的计算方法获得, 如式(5)所示, 该模型的损失函数如式(7)所示。

模型 2 相对于模型 1 增加了辅助分类网络结构, 验证了“辅助分类网络”的有效性; 而模型 4 相对于模型 3 改进了域鉴别器权重计算方法, 验证了“改进加权域鉴别网络”的有效性。

#### 4.3.1 辅助分类网络有效性分析

为了验证提出的辅助分类网络结构的有效性, 这里将对 DANN 模型与 DANN+ACN 模型进行对比。提出辅助分类网络的目的在于对齐源域与目标域样本的同时, 进一步提高不同类别样本特征之间的可区分程度, 因此, 这里采用源域与目标域样本之间的代理 A 距离测量函数(proxy A-distance, PAD)来衡量源域与目标域样本的对齐程度, 采用正负测试样本平均特征的距离测量函数(feature average distance, FAD)来衡量不同类别样本特征之间的区分度。其中, PAD 计算式为

$$d_A(D_s,D_t)=2\left(1-2\min_{\eta\in H}\left[\frac{1}{n_s+n_t}\left(\sum_{x_i\in D_s}I[\eta(x_i)=0]+\sum_{x_j\in D_t}I[\eta(x_j)=1]\right)\right]\right) \quad (14)$$

式中:  $D_s$  与  $D_t$  分别为源域与目标域样本集合;  $n_s$  与  $n_t$  分别为源域目标域样本数量;  $\eta$  为域分类器函数, 这里选用支持向量机线性分类器;  $H$  为不同松弛变量条件下的线性分类器集合。可以看出, 当式(14)函数值越大, 表示 2 个域之间的样本分布差异性就越大, 相似性越小; 反之, 表示 2 个域之间的样本分布相似性越大, 差异性越小。而 FAD 计算式为

$$d_F(\Omega_{\text{Pos}}, \Omega_{\text{Neg}}) = \left\| \frac{1}{n_{\text{Pos}}} \sum_{x_i \in \Omega_{\text{Pos}}} f(x_i) - \frac{1}{n_{\text{Neg}}} \sum_{x_j \in \Omega_{\text{Neg}}} f(x_j) \right\|_2 \quad (15)$$

式中： $f(x_i)$ 为 $x_i$ 经过特征提取器 $G_f$ 处理后得到的特征向量； $\Omega_{\text{Pos}}$ 与 $\Omega_{\text{Neg}}$ 分别为目标域中正样本和负样本集合， $n_{\text{Pos}}$ 与 $n_{\text{Neg}}$ 分别为正负样本的数量。可以看出，当式(15)函数值越大，表示正负样本之间的差异性就越大；反之，表示正负样本之间的差异性就越小。

这里，DANN模型与DANN+ACN模型的PAD与FAD结果如图4-5所示。

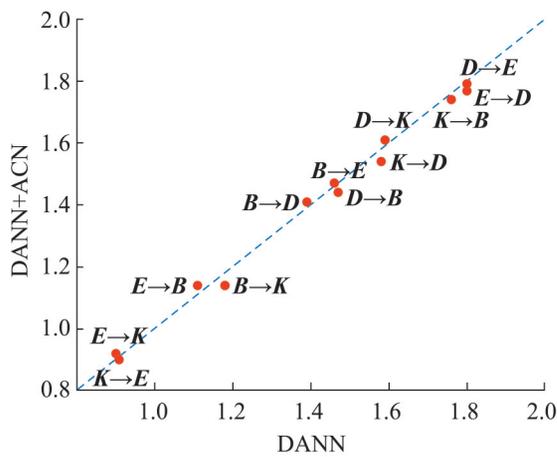


图4 源域与目标域样本之间的PAD值

Fig. 4 PAD values of samples of source and target domains

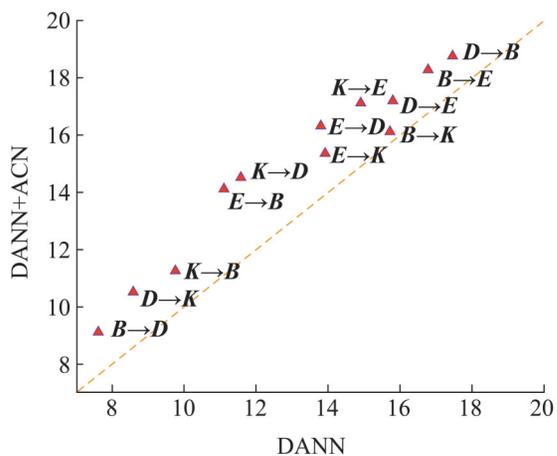


图5 正负测试样本之间的FAD值

Fig. 5 FAD values of positive and negative testing samples

由图4可知，在DANN模型上添加了辅助分类网络后，所有迁移条件下的平均PAD值由原来的1.41变为1.4，可见样本的域鉴别结果变化不大，源域与目标域样本仍保持了较好的特征分布相似性。

由图5可知，DANN+ACN模型在保持源域与目标域样本总体特征分布相似性的同时，不同迁移条件下的FAD值有了一定的提高，平均FAD值由原来的13.08提升为14.89，增大了不同类别样本之间的差异性，即正负样本提取的特征具有更强的可区分性，从而更有利于样本的准确识别。除此之外，2个模型在目标域的识别准确率比较结果如图6所示。

由图6可以看出，添加了辅助分类网络后，不同迁移条件下的目标域识别准确率均有了一定程度的提高，平均识别率由原来的80.27%提升为81.85%，从而可以证明提出的辅助分类网络结构是有效的。

#### 4.3.2 改进加权对抗网络有效性分析

为了验证加权对抗网络中提出的权重值计算方法的有效性，这里将对DANN+ACN+MAN模型与ACNUDA模型进行对比。改进对抗网络权重系数计算方法目的在于更准确地对齐源域与目标域同类样本特征分布，因此，这里采用同类训练和测试样本特征的PAD来衡量域适应后同类样本对齐程度，采用t-SNE视图来观察源域与目标域同类样本特征的具体分布情况。这里，PAD结果如图7所示，以 $E \rightarrow K$ 为例的t-SNE视图如图8所示。

由图7可以看出，不同迁移条件下，ACNUDA模型得到的所有同类样本特征的PAD值均大于DANN+ACN+MAN模型得到的PAD值，其中，正样本特征的平均PAD值由原来的1.49提升至1.5704，负样本特征的平均PAD值由原来的1.5708提升至1.6397，说明ACNUDA模型能够让源域与目标域中的同类样本实现更为准确的对齐。

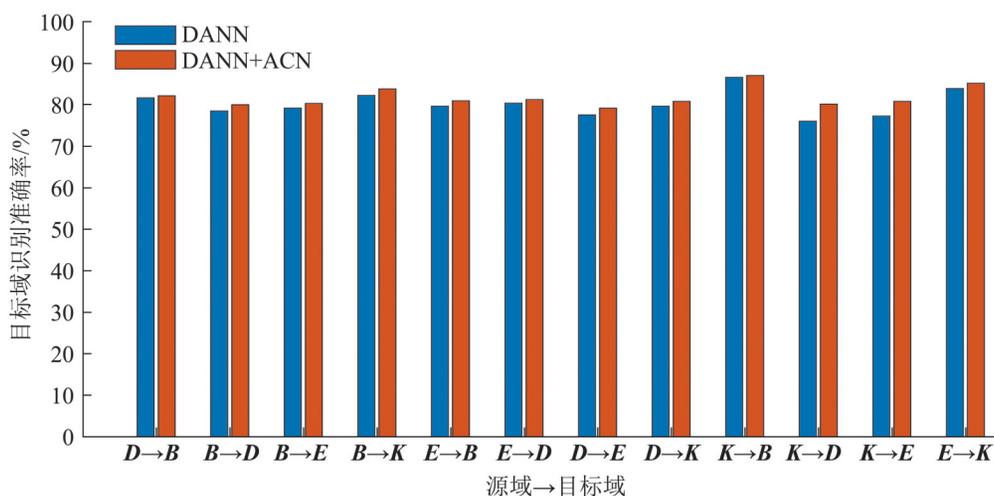
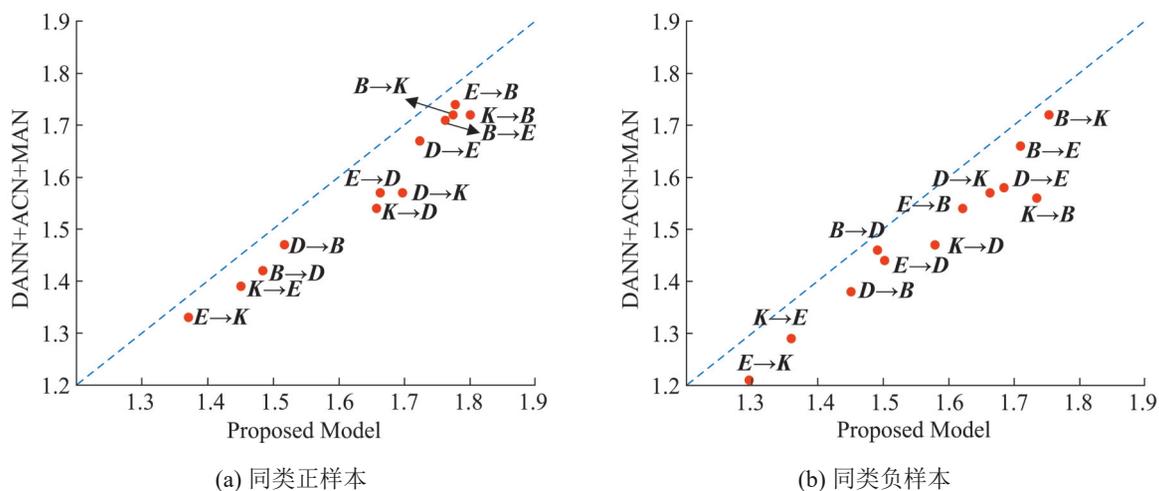


图 6 DANN 模型与 DANN + ACN 模型在目标域中识别准确率比较结果

Fig. 6 Comparison results of recognition accuracies in target domain between DANN model and DANN + ACN model

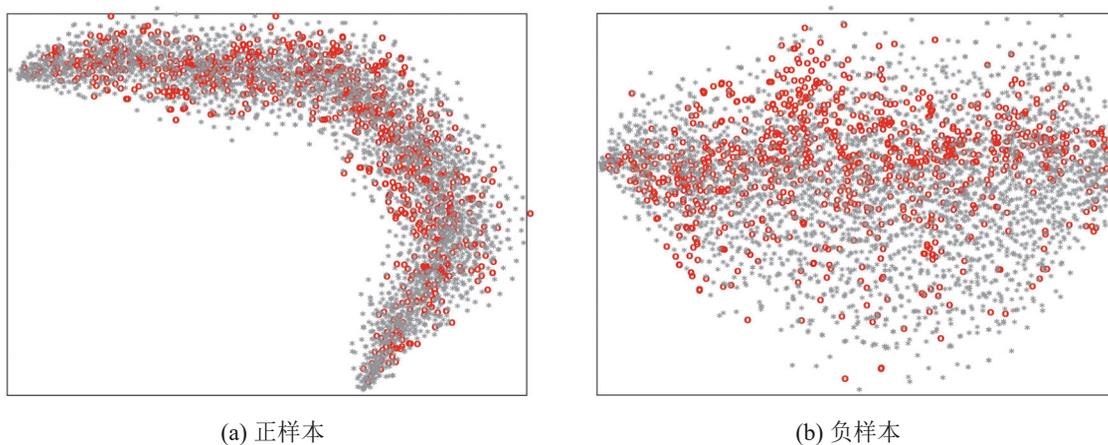


(a) 同类正样本

(b) 同类负样本

图 7 源域与目标域中同类样本之间的 PAD 值

Fig. 7 PAD values of samples of same classes of source and target domains



(a) 正样本

(b) 负样本

图 8 源域为 E、目标域为 K 时同类样本特征分布的 t-SNE 视图

Fig. 8 T-SNE views of sample features of same classes when source and target domains are E and K

而在图 8 中, 不同形状的点表示不同类别的文本, 其中, 红色圆圈点表示源域样本, 灰色星型点表示目标域样本。可以直观地看出, 源域与目标域中正样本特征和负样本特征的分布都具有较好的一致性, 从而验证了源域中获得的特征提取器与特征分类器能够良好地适用于目标域的结论。此外, 2 种模型在目标域的认可准确率比较结果如图 9 所示。可以看出, 采用了提出的加权对抗网络结构后, 目标域的认可准确率有了一定程度的提高, 可以证明提出的对抗网络结构与权重

计算方法是有效的。

#### 4.4 不同跨领域文本情感分析算法的比较及分析

为验证提出模型的先进性, 这里基于 Amazon 评论数据集, 将 ACNUDA 模型与部分已有的经典跨领域文本情感分类模型进行比较, 包括 SVM(support vector machine)模型、AuxNN 模型<sup>[26]</sup>, DANN 模型<sup>[10]</sup>、PBLM 模型<sup>[27]</sup>、DAS 模型<sup>[28]</sup>、ACAN 模型<sup>[12]</sup>。对比的指标为 Amazon 数据集中所有迁移条件下目标域样本识别的准确率, 结果如表 3 所示。

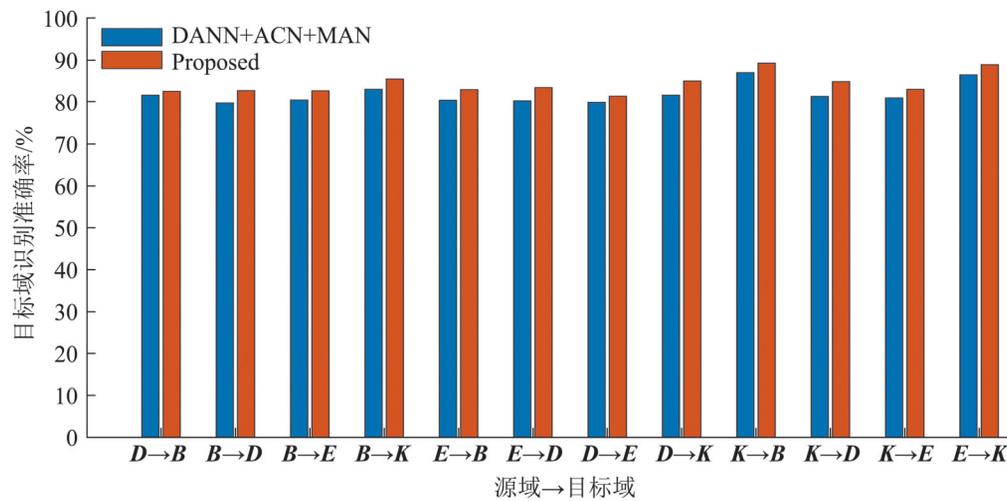


图 9 DANN + ACN + MAN 模型与 ACNUDA 模型在目标域中识别准确率比较结果

Fig. 9 Comparison results of recognition accuracies of target domain between DANN + ACN + MAN model and ACNUDA model

表 3 不同算法在目标域识别结果

源域→目标域	SVM	AuxNN	DANN	PBLM	DAS	ACAN	本文
D→B	75.20	80.80	81.70	<b>82.50</b>	82.05	82.35	82.41
E→B	68.85	78.00	78.55	71.40	80.00	79.75	<b>82.57</b>
K→B	70.00	77.85	79.25	74.20	80.05	80.80	<b>82.54</b>
B→D	77.15	81.75	82.30	84.20	82.75	83.45	<b>85.36</b>
E→D	69.50	80.65	79.70	75.00	80.15	81.75	<b>82.82</b>
K→D	71.40	78.90	80.45	79.80	81.40	82.10	<b>83.32</b>
B→E	72.15	76.40	77.60	77.60	81.15	<b>81.30</b>	81.26
D→E	71.65	77.55	79.70	79.60	81.55	82.80	<b>84.88</b>
K→E	79.75	84.05	86.65	87.10	85.80	86.60	<b>89.13</b>
B→K	73.50	78.10	76.10	82.50	82.25	83.05	<b>84.72</b>
D→K	72.00	80.05	77.35	<b>83.20</b>	81.50	78.60	82.89
E→K	82.80	84.15	83.95	87.80	84.85	83.35	<b>88.76</b>
平均值	73.66	79.85	80.29	80.40	81.96	82.15	<b>84.22</b>

由表 3 可以看出, 当源域与目标域分别选择  $E \rightarrow B, K \rightarrow B, B \rightarrow D, E \rightarrow D, K \rightarrow D, D \rightarrow E, K \rightarrow E, B \rightarrow K, E \rightarrow K$  时, ACNUDA 模型对目标域中的样本可以获得更高识别准确率  $F_{acc}$ , 这是因为 ACNUDA 模型通过多对抗网络较好地实现了源域与目标域每一类别情感文本的分别对齐, 并且在对齐的同时增大了不同类别文本之间的差异性, 从而让文本尽可能远离最优分类面, 降低了文本情感分类的歧义性。

$$F_{acc} = n_{acc} / n_t \quad (16)$$

式中:  $n_t$  为目标域样本个数;  $n_{acc}$  为目标域样本被正确分类的个数。而在所有迁移条件下, 平均识别准确率可以达到 84.22%, 相对于最好的对比模型可以提升 2.07%。因此, 可以得出在目标域样本没有被标注的情况下, 提出的域适应模型能够更好地将源域中获得的知识迁移到目标域中, 即特征提取器  $G_f$  与特征分类器  $G_y$ 。

### 5 文本情感对建模的数据支撑分析

文本数据相比非文本数据具有更为丰富的语义信息, 而文本的情感在不同主体的决策过程中扮演着十分重要的角色。例如, 在电子商务中, 大规模带有情感的文本将对用户兴趣信息挖掘仿真模型  $r(u, i)$  的建立提供了重要的数据支撑, 其中,  $u$  和  $i$  分别表示“用户”和“物品”,  $r(u, i)$  为  $u$  对  $i$  的兴趣度。而大多用户对商品兴趣度的建模通常依赖于用户对商品的评分信息, 并采用基于内容或基于协同过滤思想实现对用户的商品兴趣估计, 如图 10 所示。

由图 10 可以看出, 由于用户  $u_1$  与  $u_2$  对物品  $i_1$ ,

$i_2, i_3$  的评分信息有较强的相似性, 可以估计出用户  $u_1$  与用户  $u_2$  具有相似的兴趣偏好, 他们对物品  $i_4$  与  $i_5$  的评价也较大概率相似, 从而得出用户  $u_2$  对物品  $i_4$  具有较高的兴趣度, 对物品  $i_5$  具有较低的兴趣度。

然而, 用户对物品评分特征反映的用户意图较为有限, 而用户的评论文本相对于评分来说属于细粒度特征, 更能表达用户的真实意图。因此, 这里除图 10 中的评分信息外, 增加了用户对物品的评论文本信息, 如表 4 所示。

尽管用户  $u_1$  与  $u_2$  对物品  $i_1, i_2, i_3$  的评分信息具有较强的相似性, 但用户  $u_1$  与  $u_2$  对物品的关注点是不一致的, 例如, 用户  $u_1$  对“手机”与“台式机”更关注其性能, 从而大概率对“游戏笔记本”有更高的兴趣度; 相对而言, 用户  $u_2$  更关注稳定性与续航能力, 而这正是“商务笔记本”具有的特点, 从而说明用户  $u_2$  对  $i_5$  具有更高的兴趣度。因此, 基于文本情感的方法将会得到与基于评分的方法相反的结果, 估计出更加合理的用户兴趣。

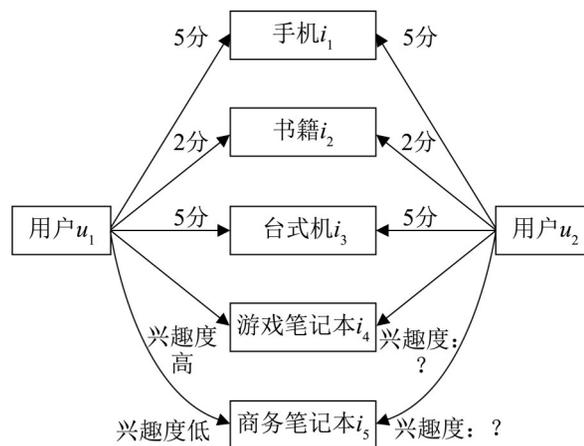


图 10 基于评分信息的用户-物品兴趣分析

Fig. 10 User-item interest analysis based on rating information

表 4 基于评论文本的用户-物品兴趣分析  
Table 4 User-item interest analysis based on review text

物品	$u_1$	$u_2$
手机 $i_1$ 评论文本	打游戏不卡顿, 画面流畅	手机续航能力强
书籍 $i_2$ 评论文本	章节安排不是很合理	存在错别字, 图印刷不清晰
台式机 $i_3$ 评论文本	处理器与显卡性能好	系统运行非常稳定, 从不死机
游戏笔记本 $i_4$ 兴趣度	高	?
商务笔记本 $i_5$ 兴趣度	低	?

跨领域的文本情感分析能够在有限标注样本的条件下,对多个领域中的文本进行情感分类,而从以上分析可知,这些对不同视角下带有情感的文本将对用户兴趣挖掘<sup>[29]</sup>、网络舆情监控<sup>[30]</sup>、信息预测评估<sup>[31]</sup>等领域的仿真建模提供了重要依据与支撑。

## 6 结论

为了将含有标签样本的源域中的知识能够跨领域应用在包含无标签样本的目标域中,实现源域与目标域中文本情感的准确分类,提出了一种基于加权多对抗网络的域适应模型。

该模型的贡献在于:

(1) 提出了一种辅助分类网络,使得训练过程中不仅可以保证源域样本正确分类,而且还会使不同类别的文本之间具有更大的差异性。

(2) 提出了一种对抗网络权重计算方法,实现了源域与目标域中相同类别样本分别准确对齐。本文模型更重要的意义在于通过某一领域有限的标注样本获得多个领域内文本的情感信息,从而为电子商务、网络舆情等领域数据分析的仿真建模提供重要的数据基础。

## 参考文献:

- [1] 赵传君,王素格,李德玉.跨领域文本情感分类研究进展[J].软件学报,2020,31(6):1723-1726.  
Zhao Chuanjun, Wang Suge, Li Deyu. Research Progress on Cross-Domain Text Sentiment Classification[J]. Journal of Software, 2020, 31(6): 1723-1746.
- [2] Robert R. Domain Adaptation Using Domain Similarity and Domain Complexity-based Instance Selection for Cross-Domain Sentiment Analysis[C]//IEEE 12th International Conference on Data Mining Workshops. Piscataway: IEEE, 2012: 717-723.
- [3] Xia R, Zong C Q, Hu X L, et al. Feature Ensemble Plus Sample Selection: Domain Adaptation for Sentiment Classification[J]. IEEE Intelligent Systems(S1541-1672), 2013, 28(3): 10-18.
- [4] Giacomo D, Gianluca M, Andrea P. Cross-Domain Sentiment Classification via Polarity-Driven State Transitions in a Markov Model[C]//International Joint

- Conference on Knowledge Discovery, Knowledge Engineering, and Knowledge Management. Berlin: Springer, 2015: 118-138.
- [5] John B, Ryan T M, Fernando P. Domain Adaptation with Structural Correspondence Learning[C]//Conference on Empirical Methods in Natural Language Processing. New York: ACM, 2006: 120-128.
- [6] Yftah Z, Roi R. Neural Structural Correspondence Learning for Domain Adaptation[C]//21st Conference on Computational Natural Language Learning. Stroudsburg: ACL, 2017: 400-410.
- [7] Wang L, Niu J W, Song H B, et al. SentiRelated: A Cross-Domain Sentiment Classification Algorithm for Short Texts through Sentiment Related Index[J]. Journal of Network and Computer Applications(S1084-8045), 2018, 101: 111-119.
- [8] Tareq A M, Nazlia O, Mohammed A, et al. Feature Transfer through New Statistical Association Measure for Cross-Domain Sentiment Analysis[J]. Journal of Engineering and Applied Sciences(S1816-949X), 2017, 12(1): 164-170.
- [9] Zhu E D, Huang G Y, Mo B Y, et al. Features Extraction Based on Neural Network for Cross-Domain Sentiment Classification[C]//International Conference on Database Systems for Advanced Applications. Berlin: Springer, 2016: 81-88.
- [10] Ganin Y, Lempitsky V. Unsupervised Domain Adaptation by Backpropagation[C]//32nd International Conference on Machine Learning. Cambridge: MIT Press, 2015: 1180-1189.
- [11] Li Z, Zhang Y, Wu Y X, et al. End-to-End Adversarial Memory Network for Cross-Domain Sentiment Classification[C]//International Joint Conference on Artificial Intelligence. New York: ACM, 2017: 2237-2243.
- [12] Qu X Y, Zou Z K, Cheng Y, et al. Adversarial Category Alignment Network for Cross-Domain Sentiment Classification[C]//2019 Conference of the North American Chapter of the Association for Computational Linguistics. Stroudsburg: ACL, 2019: 2496-2508.
- [13] He R D, Wee S L, Hwee T N, et al. Adaptive Semi-Supervised Learning for Cross-Domain Sentiment Classification[C]//2018 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2018: 3467-3476.
- [14] Zhao C J, Wang S G, Li D Y. Multi-Source Domain Adaptation with Joint Learning for Cross-Domain Sentiment Classification[J]. Knowledge-Based Systems (S0950-7051), 2020, 191: 105254.
- [15] Li L, Ye W R, Long M S, et al. Simultaneous Learning of

- Pivots and Representations for Cross-Domain Sentiment Classification[C]//AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2020: 8220-8227.
- [16] Mao K L, Niu J W, Wang X J, et al. Cross-Domain Sentiment Analysis of Product Reviews by Combining Lexicon-Based and Learn-Based Techniques[C]//IEEE 17th International Conference on High Performance Computing and Communications. Piscataway: IEEE, 2015: 351-356.
- [17] Dolores M G, Eugenio M C, Teresa M V, et al. Cross-Domain Sentiment Analysis Using Spanish Opinionated Words[C]//International Conference on Applications of Natural Language to Data Bases/Information Systems. Berlin: Springer, 2014: 214-219.
- [18] Huang X C, Rao Y H, Xie H R, et al. Cross-Domain Sentiment Classification via Topic-Related TrAdaBoost [C]//Thirty-First AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2017: 4939-4940.
- [19] Zhou G Y, Zhou Y, Guo X Y, et al. Cross-Domain Sentiment Classification via Topical Correspondence Transfer[J]. *Neurocomputing*(S0925-2312), 2015, 159: 298-305.
- [20] Giacomo D, Gianluca M, Andrea P, et al. Markov Chain Based Method for In-Domain and Cross-Domain Sentiment Classification[C]//7th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management. Piscataway: IEEE, 2015: 127-137.
- [21] Nelakurthi A R, Tong H h, Maciejewski R, et al. User-Guided Cross-Domain Sentiment Classification[C]//2017 SIAM International Conference on Data Mining. Bethesda: SIAM, 2017: 471-479.
- [22] Pei Z Y, Cao Z J, Long M S, et al. Multi-Adversarial Domain Adaptation[C]//Thirty-second AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2018: 3934-3941.
- [23] John B, Mark D, Fernando P. Biographies, Bollywood, Boom-Boxes and Blenders: Domain Adaptation for Sentiment Classification[C]//The 45th Annual Meeting of the Association of Computational Linguistics. Stroudsburg: ACL, 2007: 440-447.
- [24] Chen M M, Xu Z X, Kilian Q W, et al. Marginalized Denoising Autoencoders for Domain Adaptation[C]//29th International Conference on International Conference on Machine Learning. New York: ACM, 2012: 1627-1634.
- [25] Ganin Y, Ustinova E, Lempitsky V, et al. Domain-Adversarial Training of Neural Networks[J]. *Journal of Machine Learning Research*(S1532-4435), 2016, 17: 1-35.
- [26] Yu J F, Jiang J. Learning Sentence Embeddings with Auxiliary Tasks for Cross-Domain Sentiment Classification[C]//2016 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2016: 236-246.
- [27] Yftah Z, Roi R. Pivot Based Language Modeling for Improved Neural Domain Adaptation[C]//2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg: ACL, 2018: 1241-1251.
- [28] He R D, Lee W S, Hwee T N, et al. Adaptive Semi-Supervised Learning for Cross-Domain Sentiment Classification[C]//2018 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2018: 3467-3476.
- [29] 刘群, 孙红涛, 纪良浩. 一种融合文本语义和情感分析的好友推荐方法[J]. *系统仿真学报*, 2016, 28(11): 2852-2859.  
Liu Qun, Sun Hongtao, Ji Lianghao. Friend Recommendation Based on Analysis of Users' Emotions and Text Semantics[J]. *Journal of System Simulation*, 2016, 28(11): 2852-2859.
- [30] 庄穆妮, 李勇, 谭旭, 等. 基于BERT-LDA模型的新冠肺炎疫情网络舆情演化仿真[J]. *系统仿真学报*, 2021, 33(1): 24-36.  
Zhuang Muni, Li Yong, Tan Xu, et al. Evolutionary Simulation of Online Public Opinion Based on the BERT-LDA Model under COVID-19[J]. *Journal of System Simulation*, 2021, 33(1): 24-36.
- [31] Gao K, Anandhan P, Kumar R. Analysis and Evaluation of the Regional Air Quality Index Forecasting Based on Web-Text Sentiment Analysis Method[J]. *Environmental Impact Assessment Review*(S0915-9255), 2021, 87: 106514.