

深度学习的互联网金融投诉文本分类研究

邢智毅

大连理工大学城市学院, 辽宁 大连 116600

摘要: 本文提出一种基于深度学习的分类算法。该方法结合多标签注意力机制和图神经网络, 精细提取文本特征并建模标签间关系, 提升了尾部低频标签的识别能力。同时, 通过非对称损失函数优化模型, 缓解正负样本不平衡问题, 显著提高了少量投诉类别的召回率。实验结果表明, 本文方法在所有标签和尾部标签的宏观 F1 值上分别较传统方法提升 3.1% 和 6.9%, 在互联网金融投诉分类中具有较高的应用价值。

关键词: 互联网金融; 投诉文本; 多标签分类; 深度学习; 图神经网络

Research on Text Classification of Internet Financial Complaints Based on Deep Learning

Xing,Zhiyi

City Institute, Dalian University of Technology, Dalian, Liaoning, 116600, China

Abstract: This paper proposes a classification algorithm based on deep learning. This method combines multi-tag attention mechanism and graph neural network to extract text features and model the relationship between tags, which improves the recognition ability of tail low-frequency tags. At the same time, through the asymmetric loss function optimization model, the imbalance between positive and negative samples is alleviated, and the recall rate of a small number of complaint categories is significantly improved. The experimental results show that the macro F1 values of all tags and tail tags are improved by 3.1% and 6.9% respectively compared with the traditional method, which has high application value in the classification of Internet financial complaints.

Keywords: Internet finance; Complaint text; Multi-label classification; Deep learning; Graph neural network

DOI: 10.62639/ssp13.20250203

结合双向门控循环网络 (BiGRU) 与标签注意力机制提取文本语义特征, 通过构建标签关联图并引入门控图神经网络 (GGNN) 建模标签间关系, 同时采用非对称损失函数缓解尾部标签不平衡问题^[1]。该方法在互联网金融投诉场景中显著提升了分类性能, 尤其对低频标签的识别能力, 能有效辅助金融风险监控和投诉分析。

一、问题定义

给定一条互联网金融投诉文本 d , 在对其进行分词、去除停用词及符号化等预处理后, 得到序列形式的输入 $d = [w_1, w_2, \dots, w_m]$, 其中 w_i 表示文本中的第 i 个词或字符, m 为该文本的长度。定义标签空间为 $\{l_1, l_2, \dots, l_L\}$, 其中 L 为标签总数。实际场景中, 一条投诉文本往往关联多个问题类别或风险点, 故其标签集合可记为 $C \subseteq \{l_1, \dots, l_L\}$, 有时 $|C| > 1$ 。

多标签分类任务的目标在于学习一个映射函数 $f(\cdot): d \rightarrow C$, 使得模型能够根据输入文本 d 输出最匹配的标签集合 C 。由于采样自互联网金融投诉数据, 标签通常带有一定的主题关联, 如“利率问题”与“暴力催收”常常一同出现, 而“保险拒赔”可能与“逾期催收”并无直接

关联。本文将在训练阶段显式建模这类标签之间的复杂依赖关系。

二、基于图深度学习的互联网金融投诉文本分类算法

本节详细介绍基于图深度学习的互联网金融投诉文本分类算法 FMLC (Financial-complaint Multi-Label Classification)。符号定义与方法流程与多标签分类模型类似, 但针对互联网金融投诉场景做了改进。

(一) 模型框架

FMLC 模型主要包括以下几个部分:

1. 文本编码层: 使用预训练词向量和双向门控循环网络, 对文本序列进行上下文语义建模;

2. 多标签注意力层: 为每个标签分配一个可训练的注意力向量, 从而提取与该标签最相关的文本信息;

3. 标签关联图构建: 基于训练数据中标签的共现情况构建标签关联图, 并计算边权;

4. 图语义交互层: 在标签关联图上使用门控图神经网络进行特征交互, 使标签间的依赖关系融入文本表示;

5. 输出层及损失函数: 对标签进行二分类

(稿件编号: IS-25-3-1015)

作者简介: 邢智毅 (1972-), 男, 汉族, 辽宁省大连市人, 硕士, 大连理工大学城市学院教授, 主要研究方向: 数据分析与数据挖掘。

预测,并在训练过程中引入非对称损失函数应对严重不平衡问题^[2]。

(二) 上下文语义编码

互联网金融投诉文本往往存在大量专业名词和口语化表达,使用预训练向量能使模型在训练初期获得更稳定的表示。若将预处理得到的词序列表示为 $H = \text{lang}h_1, h_2, \dots, h_m, \text{quad}h_i \in \mathbb{R}^{d_{init}}$, 其中 d_{init} 表示预训练词向量的维度。

为了进一步建模上下文信息并捕捉长距离依赖,本文选用双向门控循环网络(BiGRU)对序列 H 进行编码,得到 $\text{lang}h_1^c, h_2^c, \dots, h_m^c, \text{quad}h_i^c \in \mathbb{R}^{d_c}$, 其中 d_c 为上下文编码后的特征维度, h_i^c 能有效融合该位置前后文的信息,适用于捕捉互联网金融投诉中较长的依赖关系(如连贯的事实描述、事件流程等)。

(三) 多标签注意力层

考虑到不同标签关注的文本信息往往不同,例如“利率争议”关注“利率”“费用”等词,“暴力催收”则更关注“骚扰”“爆通讯录”等措辞。因此,在多标签分类场景下,需要针对每个标签提取其最相关的文本特征^[3]。

设标签空间为 $\{l_1, \dots, l_L\}$ 并为每个标签定义一个可训练的注意力向量 $q_i \in \mathbb{R}^{d_c}$ 。对于文本的上下文编码表示 $\{h_j^c\}_{j=1}^m$, 计算第 i 个标签的注意力权重: $\alpha_{ij} = \frac{\exp(q_i^T h_j^c)}{\sum_{k=1}^m \exp(q_i^T h_k^c)}$, 并得到该标签对应的文本特征向量 $f_i^a = \sum_{j=1}^m \alpha_{ij} h_j^c$, 重复上述操作可得到 $\{f_1^a, f_2^a, \dots, f_L^a\}$, 其中 f_i^a 代表与标签 l_i 最相关的文本语义。该过程与文献[1,3,5]

提出的多标签注意力网络思路一致,但我们在词表构建与训练细节上针对互联网金融投诉文本进行了优化。

(四) 输出层与非对称损失函数

在获取所有标签节点的最终表示 $f_1, \dots, f_L$ 后,为每个标签训练一个二分类器,以确定文本是否属于该标签。第 i 个标签的输出概率为 $\hat{p}_i = \sigma(w_i^T f_i^a + b_i)$, 其中 w_i, b_i 为可训练参数, σ 表示 Sigmoid 函数。

由于互联网金融投诉场景中尾部标签的正负样本极度失衡,本文选用非对称损失函数(AsymmetricLoss)作为优化目标,以降低负样本在总体损失中的权重。对于标签 l_i 的真实值 $p_i \in \{0,1\}$ 与预测概率 $\hat{p}_i$, 非对称损失函数定义为 $L_{\text{asym}}(\hat{p}_i, p_i) = \bullet [p_i \cdot \ln(\hat{p}_i) + (1 - p_i) \cdot \ln(1 - \tilde{p}_i) \cdot \gamma]$, 其中 $\tilde{p}_i = \max(\hat{p}_i - m, 0)$, γ 为衰减因子,用于减小易分负样本的梯度权重; m 为置信度阈值,用于忽略置信度较高的负样本的损失,从而缓解类别不均衡问题。最后,将所有标签的损失

累加得到总损失。

三、实验与结果分析

本节在真实的互联网金融投诉数据集上,对所提 FMLC 模型进行实验,验证算法的有效性,并从多角度对结果进行了分析。

(一) 数据集与预处理

实验数据来自某互联网金融平台和监管部门的联合投诉系统,涵盖在线贷款、消费金融、第三方支付、保险理赔等多个业务场景,共收集到约 120,000 条用户文本投诉样本。每条投诉同时关联了 1~5 个标签,标签总数为 135 个,平均每条投诉文本长约 60 个分词(去除标点符号后),最长达 200 词左右。

针对数据集中出现次数少于 100 次的标签,记为尾部标签(占标签总数的 15% 左右),它们每个仅在几十条样本中出现。该尾部标签问题是互联网金融投诉数据的显著特征,也最能体现模型在不平衡场景下的表现。将整体数据划分为训练集、验证集和测试集,比例为 70%:15%:15%。文本分词使用结巴分词(jieba),去除停用词并保留出现频率较高的核心词构建词表。预训练词向量采用 word2vec,在全部投诉语料上进行无监督训练,词向量维度设置为 $d_{init} = 100$ 。

(二) 对比算法

为全面评估 FMLC 算法的性能,选择下列多标签文本分类算法作为对比对象:

1. CAML: 基于卷积网络和标签注意力的多标签分类模型;
2. BiGRU-LWAN: 用双向 GRU 替代 CNN,并引入标签级注意力;
3. ZACNN: 在 CAML 基础上,进一步融合标签名称的外部先验信息;
4. FMLC/BCE: 表示本模型在损失函数上仅使用常规二元交叉熵(BinaryCrossEntropy);
5. FMLC/ASL: 表示本模型使用非对称损失函数(AsymmetricLoss)进行优化。

(三) 训练设置

特征维度与超参数:双向 GRU 的隐藏层维度 d_c 设为 300,门控图神经网络各层维度同为 300,更新层数 K 取 2~3 层,最终根据验证集表现选择 2 层。非对称损失函数中的衰减因子 γ 取 2,阈值 m 取 0.05。

正则化:所有模型在词嵌入层和注意力层均采用 0.2 的 Dropout,并在图神经网络中对节点特征进行 0.1 的 Dropout。

优化器:使用 Adam,初始学习率 $1e-4$ 。全部模型在相同硬件环境下训练,对于 BiGRU-LWAN 与 FMLC 训练 10 轮, CAML 与 ZACNN 训练 30 轮后收敛。

评价指标:采用微观和宏观的 Precision、Recall、F1 值进行评估,并特别关注在尾部标签上的召回率与 F1 值。

（四）实验结果与分析

根据模型在全部标签与尾部标签上的性能比较分析可见：

- 1. ZACNN 在互联网金融投诉场景中表现最差，因为该算法对标签名称进行字符级嵌入平均后得到标签向量，但投诉标签通常是短语或较专业的词汇，与文本语义存在较大鸿沟；
- 2. BiGRU-LWAN 相比 CAML 有明显提升，说明在篇幅更长、表达更口语化的投诉文本中，使用循环网络捕捉上下文依赖比固定大小卷积核更有效；
- 3. FMLC/BCE 在所有标签和尾部标签上均优于上述对比算法，充分说明建模标签之间的依赖对提升多标签分类性能的重要性；
- 4. FMLC/ASL 进一步将损失替换为非对称损失，在不均衡标签上取得更高的召回率和 F1 值，说明在互联网金融投诉场景下，负样本冗余带来的影响更大，通过抑制易分负样本的梯度可以显著提高尾部类别的识别效果。

（五）测试示例分析

下表 1 列举了若干来自测试集的实际投诉示例，以对比 BiGRU-LWAN 与 FMLC/ASL 的预测结果。可以看出，FMLC/ASL 能识别出更完整、更加精准的标签集合。例如，示例 1 投诉中出现了“逾期费用不合理”和“强制收取高额违约金”等描述，但 BiGRU-LWAN 仅捕捉到“逾期费用”标签，漏掉了“违约金”相关标签。而 FMLC/ASL 则借助标签图中“逾期费用”与“违约金计算”常共现的关联，正确做出了完整预测。

表 1 部分投诉文本的预测结果

投诉文本（摘录）	BiGRU-LWAN 预测	FMLC/ASL 预测
示例 1:		
贷款逾期几天后利息高得离谱，且强制要求缴纳一笔所谓“违约金”，这个金额明显超出合理范畴……	逾期费用	逾期费用，违约金计算
示例 2:		
我在这家支付平台提现两天都不到账，客服电话一直打不通，投诉好几次没人理……	提现到账问题	提现到账问题，客服推诿
示例 3:		
保险公司拒赔理由含糊，说我资料不全，但我已提供齐全材料，明显推卸责任……	拒赔争议	拒赔争议

可见，由于 FMLC/ASL 显式建模了标签关联与文本关联，能够更全面地捕捉多标签投诉中的隐含问题，提高模型的召回率与准确率，对于金融监管部门定位风险点、完善监管措施

具有重要意义。

（六）消融实验

为进一步验证图神经网络和非对称损失函数在模型中的贡献，分别进行了两组消融实验：

- 1. 将图神经网络的邻接矩阵替换为单位矩阵，取消标签间的差异化边权，只保留门控更新机制，模拟标签之间没有显式依赖的情况。实验结果显示，模型的分类性能出现显著下降，尤其是在捕捉标签间的复杂关联方面表现较差。这表明，在多标签分类任务中，显式建模标签之间的依赖关系对于准确分类具有关键作用，尤其是在互联网金融投诉文本中，标签之间的关联特性对准确分类不可或缺；
- 2. 将模型中的非对称损失函数替换为常规交叉熵损失函数，比较了改动前后模型在尾部标签上的表现。结果表明，使用常规交叉熵后，尾部标签的召回率和 F1 值显著下降，模型对少量类别的识别能力减弱。这进一步验证了非对称损失函数的有效性，通过降低易分负样本的权重和抑制其梯度对模型的影响，有效缓解了互联网金融投诉场景中正负样本数量严重不均衡的问题，从而提升了尾部标签的分类性能。两组实验结果共同强调了图神经网络和非对称损失函数在提高模型性能和适应复杂场景中的重要作用。

四、结束语

本文面向互联网金融投诉场景，提出了一种基于深度学习与图神经网络的多标签文本分类算法 FMLC。通过对大规模真实投诉文本数据的分析，发现多标签关联以及类别分布不均衡是影响分类效果的关键问题。基于此，本文将门控图神经网络引入标签特征交互，显式地建模标签之间的统计关联，并利用非对称损失函数缓解尾部标签正负样本严重失衡的影响。实验结果表明，FMLC 在所有标签和尾部标签的宏观 F1 值上相比已有方法最高取得 3.1% 和 6.9% 的提升。

参考文献：

[1] 高军，陈见飞，杨世军，王耀坤，狄广义. 基于半监督协同训练的多标签文本分类模型[J]. 信息与电脑（理论版），2023，35（22）：170-174.

[2] 张莉，王颖，赵阳，崔涵翔，刘娟. 基于分级信息融合模型的电力投诉工单分类研究[J]. 微型电脑应用，2023，39（11）：87-90.

[3] 梁浩玮，王石，曹存根. 非完美多分类标签体系下的领域短文本分类方法研究[J]. 计算机科学，2023，50（01）：185-193.