

基于层次化注意力的语义融合文本分类增强方法

陈建忠¹ 陈 琴¹

CHEN Jianzhong CHEN Qin

摘 要

针对传统 TextCNN 模型在文本特征提取能力相对有限的问题,文章提出了一种基于层次化注意力增强的语义融合 TextCNN (HA-SF-TextCNN) 文本分类方法。通过引入双层注意力机制,在词级和句级分别构建注意力模块,用于捕获文本的局部和全局语义信息;同时,设计了语义融合模块,将预训练词向量与上下文语义特征有机结合,增强模型对复杂文本的表达能力。实验结果表明,相比传统 TextCNN 模型,HA-SF-TextCNN 模型在分类准确率和 F_1 评分提升较大。在长文本和多义词处理方面有着更强的特征表达能力,为深度学习文本分类技术提供了新的思路。

关键词

文本分类; 层次化注意力机制; 语义融合; TextCNN

doi: 10.3969/j.issn.1672-9528.2025.12.012

0 引言

随着互联网和社交媒体的不断发展,文本分类作为自然语言处理的基础任务,在舆情分析、智能客服、内容推荐等领域具有广泛应用价值^[1]。其中基于卷积神经网络(CNN)的 TextCNN 模型^[2]因其强大的特征提取能力和较高的计算效率,成为文本分类领域的经典模型之一。然而,在处理复杂文本时仍面临一些关键挑战,如对词序和句法结构的敏感性不足和多义词和上下文语义的理解有限,容易导致语义偏差,模型对不同层次特征的融合不够充分,影响分类性能^[3-4]。针对这些问题,本文提出了一种基于层次化注意力增强的语义融合文本分类方法(HA-SF-TextCNN),通过层次化注意力机制,包含词级和句级两个层次,使模型能够自适应地关注文本中的关键词和关键句,从而捕获更细粒度的语义信息;提出了语义融合模块,将预训练词向量与上下文语义特征进行有机结合,增强模型对复杂文本的表达能力。

1 研究背景

1.1 文本分类方法

传统的文本分类方法主要依赖于手工特征工程和浅层机器学习算法。早期研究多采用词袋模型(bag-of-words, BoW)或 TF-IDF (term frequency-inverse document frequency) 等方法将文本表示为向量,结合支持向量机(SVM)、朴素贝叶斯等分类器进行文本分类^[5-6]。这类方法虽然简单直观,但忽略了词序和语义信息,难以捕获文本的深层语义特征,且对领域知识和人工特征选择依赖较大。随着研究的深入,主题模

型(如 LDA)^[7]和基于词向量的方法(如 Word2Vec)^[8]被引入文本分类,在一定程度上提升了模型的性能,但仍难以满足复杂场景下的分类需求。

基于深度学习的文本分类方法可以自动学习文本的特征表示,无需人工设计特征,具有更强的表达能力和学习能力。Kim 首次将 CNN 应用于文本分类,提出了 TextCNN 模型,通过多通道卷积核捕获不同粒度的 n-gram 特征,取得了显著成效。此后,研究者对 TextCNN 进行了多方面改进,如 Zhang 等^[9]提出了字符级 CNN,直接对字符序列进行卷积操作;Wang 等^[10]引入词序信息增强了 CNN 的表示能力;Alshubaily^[11]和 Zhang 等^[9]将注意力机制与 TextCNN 结合,提高了模型对关键特征的捕获能力。

基于 RNN 的方法,循环神经网络(RNN)及其变体 LSTM、GRU 等因能够处理序列数据和捕获长距离依赖关系,被广泛应用于文本分类^[12-13]。Chen 等^[14]提出了基于 LSTM 的语义增强文本表示方法,显著提升了分类性能。近年来,以 BERT、RoBERTa 为代表的预训练语言模型因其强大的上下文建模能力,在文本分类任务上取得了突破性进展^[15-16]。这类方法通过大规模语料预训练和下游任务微调,能够学习到更丰富的语义信息。为兼顾不同模型的优势,研究者提出了多种混合模型。如 Zhou 等^[17]将 CNN 与 RNN 结合,同时捕获局部和全局特征;王华伟等^[18]将注意力机制与不同类型的神经网络整合,形成了更强大的文本分类框架。

1.2 注意力机制在文本分类中的应用

注意力机制最初源于计算机视觉领域,后被成功引入自然语言处理,极大提升了模型的性能^[19]。在文本分类中,注意力机制能够帮助模型自适应地关注文本中的关键部分,过

滤无关信息，从而增强模型的表达能力。Yang 等^[13]提出了层次化注意力网络（HAN），通过词级和句级两个层次的注意力机制，实现了对文档的更细粒度理解。Liu 等^[20]设计了多头自注意力机制，捕获词与词之间的复杂关系。朱艳辉等^[21]提出了一种动态上下文感知的注意力机制，根据上下文动态调整注意力权重。本文在借鉴上述研究的基础上，提出了一种层次化注意力增强的语义融合 TextCNN 模型，旨在解决传统 TextCNN 在长文本理解和语义表达方面的不足，提高文本分类的准确性和稳定性。

2 方法

2.1 模型整体架构

本文提出的基于层次化注意力增强的语义融合 TextCNN（HA-SF-TextCNN）模型整体架构如图 1 所示。该模型主要包括四个部分：嵌入层、语义融合层、层次化注意力卷积层和输出层。嵌入层将输入文本转换为词向量表示；语义融合层融合预训练词向量和上下文语义信息；层次化注意力卷积层通过词级和句级注意力机制与多尺度卷积操作提取文本特征；输出层则进行最终的分类预测。




图 1 HA-SF-TextCNN 模型整体架构

嵌入层的目的是将文本转换为神经网络可处理的向量表示。对于输入文本序列 $S = \{w_1, w_2, \dots, w_n\}$ ，其中 n 为序列长度，首先通过查表操作将每个词 w_i 映射为 d 维的词向量 $e_i \in \mathbb{R}^d$ 。本文采用预训练的 GloVe 词向量^[22]进行初始化，并在训练过程中进行微调。语义融合层为增强模型对文本语义的理解能力，本文将预训练词向量与上下文语义特征进行融合。利用双向 GRU 网络捕获词的上下；然后利用语义门控单元，根据原始词向量和上下文语义信息的重要性动态调整其权重。输出层采用全连接层将文档表示映射到类别空间，并使用 softmax 函数得到各类别的概率分布。

2.2 层次化注意力卷积层

层次化注意力卷积层通过词级和句级两个层次的注意力机制，结合多尺度卷积操作，提取文本的多层次特征。词级注意力机制旨在识别句子中的关键词，强化其表示。对于融

合后的词向量矩阵 $\tilde{E}$ ，来计算每个词的注意力权重。

$$u_i = \tanh(W_w \tilde{e}_i + b_w) \quad (1)$$

$$\alpha_i = \frac{\exp(u_i^T u_w)}{\sum_{j=1}^n \exp(u_j^T u_w)} \quad (2)$$

$$\tilde{E}' = [\alpha_1 \tilde{e}_1, \alpha_2 \tilde{e}_2, \dots, \alpha_n \tilde{e}_n] \quad (3)$$

式中： W_w 、 b_w 和 u_w 为可学习参数； α_i 为第 i 个词的注意力权重； $\tilde{E}'$ 为加权后的词向量矩阵。

为捕获不同粒度的文本特征，本文使用多尺度卷积操作，多个不同窗口大小的卷积核在 $\tilde{E}'$ 上进行卷积操作：

$$c_i^k = f(W_c^k \cdot \tilde{E}'_{i:i+h-1} + b_c^k) \quad (4)$$

式中： W_c^k 和 b_c^k 为第 k 个卷积核的参数； h 为卷积窗口大小； f 为 ReLU 激活函数； c_i^k 为卷积输出。

对于每个卷积核，采用最大池化操作提取最显著的特征，不同窗口大小的卷积核提取的特征形成特征图集合 $C = \{\hat{c}^1, \hat{c}^2, \dots, \hat{c}^m\}$ ，其中 m 为卷积核种类数。

句级注意力机制对不同卷积核提取的特征赋予不同的权重，突出关键特征的贡献：

$$v_k = \tanh(W_s \hat{c}^k + b_s) \quad (5)$$

$$\beta_k = \frac{\exp(v_k^T v_s)}{\sum_{j=1}^m \exp(v_j^T v_s)} \quad (6)$$

$$z = \sum_{k=1}^m \beta_k \hat{c}^k \quad (7)$$

式中： W_s 、 b_s 和 v_s 为可学习参数； β_k 为第 k 类特征的注意力权重； z 为融合后的文档表示。

3 实验结果

3.1 数据集与预处理

本文采用 News Category Dataset Version 3 数据集进行实验。该数据集包含了来自《赫芬顿邮报》2012—2022 年的约 21 万个新闻标题和摘要，分为 42 个类别。每条记录包含类别、标题、作者、链接、简短描述和发布日期等信息。接着对数据预处理，首先文本清洗和分词：去除 HTML 标签、特殊字符和停用词；接着对词向量初始化，对预训练的 GloVe 词向量（50 维、100 维和 200 维）进行初始化；数据集划分按 8:1:1 的比例将数据集划分为训练集、验证集和测试集。

3.2 实验设置

采用准确率（Accuracy）、精确率（Precision）、召回率（Recall）和 F_1 值作为评价指标。实验在 PyTorch 框架下实现，使用一台配备 NVIDIA RTX 3090 显卡、32 GB 内存的工作站进行。批处理大小为 128，训练轮数为 20，学习率初始值为 0.001。为防止过拟合，在训练过程中引入了 Dropout

和 L2 正则化技术。同时,采用 Adam 优化器自适应调整学习率,加速模型收敛。

3.3 实验结果与分析

表 1 展示了不同模型在 News Category Dataset 上的实验结果,不同模型在 News Category Dataset 上的性能比较:结果显示 TextCNN 的 200 维、100 维和 50 维预训练词向量验证 accuracy 为 0.591 999、0.583 201、0.565 463。可以看出,本文提出的 HA-SF-TextCNN 模型在训练和验证准确率上优于传统 TextCNN 模型,在准确率上均有提升。这表明本文提出的层次化注意力机制和语义融合模块能有效增强模型的表示能力和分类性能。

表 1 50、100、200 维度下的准确率

预训练词向量	维度	验证准确率 /%
glove.6B.50d	50 维	56.54
glove.6B.100d	100 维	58.32
glove.6B.200d	200 维	59.19
平均		58.01

图 2 展示了不同维度(50 维、100 维和 200 维) GloVe 预训练词向量对模型性能的影响。结果表明,200 维词向量能提供更丰富的语义信息,使模型性能达到最优。




图 2 不同维度准确率和 Loss 得分

4 结语

本文提出了一种基于层次化注意力增强的语义融合文本分类方法(HA-SF-TextCNN)。通过引入词级和句级双层注意力机制语义融合模块,整合预训练词向量与上下文语义信息,增强模型的表达能力。实验结果表明,本文提出的方法相比传统文本分类方法准确率和 F_1 值上分别提升较大,证明了其有效性和优越性。未来工作还将探索更高效的注意力机制和预训练语言模型,构建更先进的文本分类框架,进一步提升模型性能。

参考文献:

[1] 王志刚,刘挺,徐波.文本分类技术及其应用研究进展[J].计算机学报,2020,43(1):1-26.
[2] KIM Y. Convolutional neural networks for sentence classification[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Brussels: ACL, 2014: 1746-1751.

[3] 张学飞,李芳,张敏.深度学习在文本分类中的应用研究综述[J].计算机研究与发展,2022,59(3):451-471.
[4] 刘雪洋,张华平,刘群.基于神经网络的文本分类方法研究进展[J].中文信息学报,2021,35(5):11-21.
[5] MANNING C D, RAGHAVAN P, SCHÜTZE H. Introduction to information retrieval[M]. Cambridge: cambridge university press, 2008.
[6] 黄莹菁,宋柔.基于改进朴素贝叶斯的文本分类算法研究[J].计算机应用研究,2019,36(4):1022-1025.
[7] BLEI D M, NG A Y, JORDAN M I. Latent dirichlet allocation[J]. Journal of machine learning research, 2003, 3: 993-1022.
[8] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality[C]//NIPS'13: Proceedings of the 27th International Conference on Neural Information Processing Systems. New York: ACM, 2013: 3111-3119.
[9] ZHANG X, ZHAO J B, LECUN Y. Character-level convolutional networks for text classification[C]//NIPS'15: Proceedings of the 29th International Conference on Neural Information Processing Systems. New York: ACM, 2015: 649-657.
[10] WANG P, XU J M, XU B, et al. Semantic clustering and convolutional neural network for short text categorization[C]// Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 2: Short Papers). Brussels: ACL, 2015: 352-357.
[11] ALSHUBAILY I. TextCNN with attention for text classification[EB/OL].(2021-08-04)[2025-11-25]. <https://doi.org/10.48550/arXiv.2108.01921>.
[12] 朱靖波,何晓飞,张敏.基于 BiLSTM 和注意力机制的中文文本分类方法[J].计算机工程与应用,2022,58(17):120-127.
[13] YANG Z C, YANG D Y, DYER C, et al. Hierarchical attention networks for document classification[C]// Proceedings of the 2016 conference of the North American chapter of the association for computational linguistics: human language technologies. Brussels: ACL, 2016: 1480-1489.

(下转第 58 页)

表 2 通信效率对比分析

算法	通信轮次	数据传输量 /MB	收敛时间 /h
FedAvg	150	1 250	4.2
该平台	118	425	2.8

通信效率提升 34%，数据传输量减少 66%，训练时间缩短 33%。

4.3 实际应用场景验证

金融风控场景测试中该平台与某大型银行与两家金融科技合作构建了跨机构的信贷风险评估模型，在保护客户隐私的前提下联合建模的风险识别准确率达到 92.3%，比单独建模的 87.8% 提升 4.5 个百分点，假阳性率从 12.4% 降低至 8.1%，降幅 34.7%，实验验证了平台在金融领域的实用价值为跨机构数据协作提供了可行的技术方案。

5 结语

基于联邦学习的隐私保护型大数据分析平台通过创新的技术架构设计成功解决传统大数据分析中数据孤岛与隐私保护的矛盾问题，实验验证结果充分证明平台的技术先进性与实用价值，通信开销降低的性能表现解决了联邦学习面临的网络瓶颈问题，隐私保护强度提升为跨机构数据协作扫清了安全障碍。在金融风控与医疗诊断及智能制造等实际应用场

景中的成功验证展现了平台广阔的产业化前景，随着数字经济的快速发展与数据价值的日益凸显，跨机构数据协作需求将持续增长该平台为构建安全可信的数据共享生态体系提供了重要的技术支撑。

参考文献:

[1] 郝恩康, 范菁, 金亚东, 等. 联邦学习在隐私安全领域面临的威胁综述 [J/OL]. 计算机应用, 1-13[2025-10-17]. <https://link.cnki.net/urlid/51.1307.TP.20250526.1308.004>.
[2] 田天, 赵晗, 刘璐. 差分隐私加密结合人工智能优化大数据分析中的隐私保护研究 [J]. 中国宽带, 2025, 21(5): 49-51.
[3] 汪智. 面向医学影像的隐私保护型联邦学习模型研究 [D]. 徐州: 中国矿业大学, 2024.
[4] 刘小微. 面向非平衡数据的隐私保护联邦学习方法研究 [D]. 合肥: 中国科学技术大学, 2024.
[5] 党照群. 考虑隐私信息保护的虚拟电厂运营商交易方法研究 [D]. 沈阳: 沈阳工程学院, 2024.

【作者简介】

王建芳 (1978—), 女, 甘肃天水人, 本科, 副教授, 研究方向: 计算机软件设计与开发、大数据分析。
(收稿日期: 2025-06-20 修回日期: 2025-12-01)

(上接第 54 页)

[14] CHEN M G, JIN X M, SHEN D. Short text classification improved by learning multi-granularity topics[C]//IJCAI'11: Proceedings of the 22nd international joint conference on Artificial Intelligence - Volume Volume Three. New York: ACM, 2011: 1776 - 1781.
[15] 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, Volume 1 (Long and Short Papers). Brussels: ACL, 2019: 4171-4186.
[16] 曾泽凡, 王厚峰, 刘康. 基于预训练语言模型的知识增强文本分类研究综述 [J]. 软件学报, 2023, 34(1): 149-175.
[17] ZHOU C T, SUN C L, LIU Z Y, et al. A C-LSTM neural network for text classification[EB/OL]. (2015-11-30)[2025-11-03]. <https://doi.org/10.48550/arXiv.1511.08630>.
[18] 王华伟, 金澈清, 王素格. 融合注意力机制的卷积神经网络文本分类模型 [J]. 计算机科学, 2021, 48(5): 267-272.
[19] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is

all you need[C]//Advances in neural information processing systems. New York: ACM, 2017: 6000 - 6010.
[20] LIU Y H, OTT M, GOYAL N, et al. RoBERTa: A robustly optimized BERT pretraining approach[EB/OL]. (2019-07-26)[2025-11-22]. <https://doi.org/10.48550/arXiv.1907.11692>.
[21] 朱艳辉, 刘挺, 王东波. 基于动态上下文增强注意力机制的文本分类方法 [J]. 计算机研究与发展, 2022, 59(7): 1436-1447.
[22] MOSCHITTI A, PANG B, DAELEMANS W. GloVe: Global vectors for word representation[C]//Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP). Brussels: ACL, 2014: 1532-1543.

【作者简介】

陈建忠 (1999—), 男, 江西赣州人, 硕士研究生, 研究方向: 文本分类、知识图谱。
陈琴 (1998—), 女, 广西崇左人, 硕士研究生, 研究方向: 深度学习、教育机器人。
(收稿日期: 2025-09-09 修回日期: 2025-12-08)