

基于特征级注意力的方面级情感分类模型研究

杨嘉佳¹,熊仁都¹,刘金¹,唐球¹,左娇²

(1.华北计算机系统工程研究所,北京 100083;2.中国长城科技集团股份有限公司,广东 深圳 518057)

摘要:近年来大数据、自然语言处理等技术得到了飞速发展。情感分析作为自然语言处理细分领域的前沿技术之一,得到了极大的重视。然而,低参数量、高精度依然是制约情感分析的关键因素之一。为实现模型参数少、模型分类精度高的情感分析需求,通过改进特征级注意力机制的输入向量,以及前馈神经网络与注意力编码的前后位置关系,得到可复位特征级注意力机制,并基于该机制提出了基于可复位特征级注意力方面级情感分类模型(RFWA)和基于可复位特征级自注意力方面级情感分类模型(RFWSA),实现了高精度的方面级情感分析效果。在公开数据集上的实验结果表明,相比现有的主流情感分析方法,所提出的模型有明显的优势,尤其是在取得相当分类效果的情况下,模型的参数量仅为最新 AOA 网络的 1/4。

关键词:情感分析;方面级;特征级;自注意力

中图分类号: TP391.41

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.200559

中文引用格式: 杨嘉佳,熊仁都,刘金,等. 基于特征级注意力的方面级情感分类模型研究[J]. 电子技术应用, 2021, 47(7): 78-82.

英文引用格式: Yang Jiajia, Xiong Rendou, Liu Jin, et al. Research on aspect level sentiment classification model based on feature level attention[J]. Application of Electronic Technique, 2021, 47(7): 78-82.

Research on aspect level sentiment classification model based on feature level attention

Yang Jiajia¹, Xiong Rendou¹, Liu Jin¹, Tang Qiu¹, Zuo Jiao²

(1. National Computer System Engineering Research Institute of China, Beijing 100083, China;

2. China Greatwall Technology Group Co., Ltd., Shenzhen 518057, China)

Abstract: In recent years, big data, natural language processing and other technologies have been developed rapidly. As one of the cutting-edge technologies in the field of natural language processing, emotion analysis has received great attention. However, High precision and high performance are still the key factors restricting emotional analysis. In order to achieve high-precision emotion analysis, based on the feature-level neural network, this paper improves the reset feature level attention mechanism, and proposes an aspect level emotion classification model based on the reset feature level attention(RFWA) and an aspect level emotion classification model based on the reset feature level self-attention(RFWSA). Finally, combined with Bi-LSTM-CRF, high quality aspect level emotion analysis is realized by aspect level phrase extraction in the network. The experimental results show that compared with the existing mainstream emotion analysis model, the model proposed in this paper has obvious advantages. Especially when the classification effect is quite good, the parameters of the model are only 1/4 of the AOA Network.

Key words: emotion analysis; aspect level; feature level; self attention

0 引言

在信息化时代背景下,各行业产生了大量的多源异构数据。对这些数据的情感倾向进行分析,衍生出很多基于传统行业的新实践和新业务模式。情感分析是当下人工智能的一个热门应用,是自然语言处理领域的一个重要分支,根据文本研究对象细粒程度的区别,研究者主要在3个层次级别上研究情感分析:文档级、语句级和方面级(aspect level)。情感分析的粒度越细,则精确度越高,也就能更好地发现情感极性。方面级情感分析技术^[1]主要用于解决情感极性问题,与文档级、语句级情

感分类相比,方面级情感分析因为基于 aspect 实体,使得情感分析更加精细化。

当前情感分类精度效果较好的研究,主要基于深度学习、注意力机制而开展^[2-9]。但是基于深度学习的方面级情感分析模型主要依赖卷积神经网络、门控循环神经网络进行上下文的编码与特征变换等,这些网络在捕捉长距离依赖上有一定的局限性。此外,尽管基于自注意力机制的 Transformer 提供了一种创新思路,但许多研究表明,在浅层网络和训练数据较少的情况下,自注意力网络的网络特征抽取能力不如 LSTM 等经典网络,其

中一个重要原因是注意力得分针对的是整个向量,灵活性差,复杂度低,当网络层数较少时无法捕捉到深层的语义信息。

针对模型分类高精度化、少参数化的情感分析应用需求,本文提出基于可复位特征级注意力的方面级情感分类模型和基于可复位特征级自注意力的方面级情感分类模型。实验结果表明,在取得与 AOA 网络^[2]相当分类精度的情况下,两个模型参数量分别为 19 万、27 万,仅仅为 AOA 参数量(109 万)的 17%、25%。

1 相关工作

近年来基于深度学习的方面级情感分类技术得到了广泛研究。这些研究主要围绕循环神经网络、注意力网络而开展。

VO D T 和 ZHANG Y^[3]首次利用三段 LSTM 对目标词和目标词前后上下文进行分别建模之后用于分类。TANG D 等人^[4]提出了 target-dependent 的 LSTM 模型(TD-LSTM)和 target-connection LSTM(TC-LSTM)来扩展经典的 LSTM 结构用于将方面特征纳入模型运算,其主要使用两个 LSTM 分别对目标词左右的文本序列进行建模,之后将左右语句特征集合进行分类。KIM Y 等人^[5]首次提出了一个结合方面词嵌入的基于注意力机制的 LSTM 模型,证明能够很好地捕捉与方面词汇相关的上下文信息,并在当时取得了 SOTA(state-of-the-art)的表现。交互型注意力模型如 IAN^[6]、AOA^[2]、MGAN^[7]将方面词(target)对上下文(context)的注意力、上下文对关键词的注意力融入到模型,是目前具有最优表现的 RNN 结构模型。VASWANI A 等人^[8]提出了基于多头自注意力的 Transformer 模型对序列文本进行编码,摆脱了对 RNN 等传统网络的依赖,自注意力机制不依赖序列顺序,能同时针对整个上下文进行特征提取,解决了循环神经网络无法捕捉长期依赖的问题。SONG Y 等人^[9]通过使用基于自注意力的网络构建了 Attentional Encoder Network 来进行语句上下文特征抽取,以及与目标词进行注意力交互。

尽管基于循环神经网络、注意力网络的方面级情感分析模型在分类准确率、模型参数量都得到了极大改善,但依然还有提升的空间。

2 可复位特征级注意力情感分类模型(RFWA)

实验发现,直接参照多头自注意力模型^[8]将自注意力模块替换成特征级自注意力模块时,模型的性能表现并没有提升,反而使得网络变得非常难以训练,最终拟合效果也不如传统自注意力网络。然而,在进一步观察实验过程中的各个变量变化时,注意到在一部分样本上模型对缺省(文本批量化训练时候的补全向量,使得所有输入句子的长度一致)向量的注意力打分远高于真正的文本。据此,本文提出了可复位特征级注意力机制。

2.1 可复位

通常使用批训练技术加速神经网络训练速度,即每

次传入一组训练样本,将得到的梯度更新量平均作用于网络参数上。文本任务相较于图像任务,每次训练的输入序列长短不一,而图像可以方便地缩放到统一大小,这就导致在序列并行化过程中需要通过补全的方式,通过在短文本末尾添加如全 0 向量作为缺省向量,使得每一批样本中所有输入语句长度一样,从而使得输入的数据维度在训练过程中保持一致,方便并行处理。但是,添加的缺省向量会导致神经网络在训练初始阶段过多地关注到这些无关的没有实际意义的数据,减缓了网络收敛速度。注意力掩码技术则在很大程度上解决了这一问题。

为解决这个问题,研究人员提出了注意力掩码技术:输入样本时,真实词汇标记为 1,缺省向量标记为 0,该标记作为掩码传入神经网络。在计算注意力时候通常有两种校正策略。

(1)在计算注意力得分之后,softmax 归一化之前,对标记为 1 的词汇注意力得分加 1,标记为 0 的则不作处理。而在特征及注意力模型中,由于得分是针对特征而言,注意力修正需要从向量转化为宽度等于词嵌入维度为 e 的矩阵,设输入文本长度为 4,网络可接收的最大文本长度为 n ,则注意力得分修正过程为:

获取注意力掩码:

$$\text{mask}_{\text{word}} = [1, 1, 1, 1, 0, \dots, 0]_{1 \times n} \quad (1)$$

转化成注意力掩码矩阵:

$$\text{mask}_{\text{feature}} = \begin{bmatrix} 1 & 1 & 1 & 1 & 0 & \cdots & 0 \\ 1 & 1 & 1 & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & 1 & 1 & 0 & \cdots & 0 \end{bmatrix}_{e \times n} \quad (2)$$

修正注意力得分 scores,其中向量 X 是上下文句子,向量 q 是句子中的一个词:

$$\text{scores} = \text{softmax}(f(X, q) + \text{mask}_{\text{feature}}) \quad (3)$$

(2)与上述过程相似,不同之处:对标记为 1 的词汇不作处理,对标记为 0 的词汇得分加上负无穷 $-\text{inf}$,得:

$$\text{mask}_{\text{feature}} = \begin{bmatrix} 0 & 0 & 0 & 0 & -\text{inf} & \cdots & -\text{inf} \\ 0 & 0 & 0 & 0 & -\text{inf} & \cdots & -\text{inf} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & -\text{inf} \\ 0 & 0 & 0 & 0 & -\text{inf} & \cdots & -\text{inf} \end{bmatrix}_{e \times n} \quad (4)$$

以上两种策略都有助于注意力机制更好地关注到真实的输入数据,使真实词汇的打分偏高,对应的缺省向量的打分会变低。

通过使用注意力掩码技术可以让注意力网络关注到真正的输入上而非缺省向量上,但本文在实验中发现,网络针对相当一部分样本打分时,即使加上了注意力掩码偏置,网络依然对缺省向量打出比真实文本更高的分数,这说明在某些情况下特征级注意力网络需要输出的特征为 0,而不是任何输入文本特征的和。

传统的特征级注意力机制通过打分函数得到相容

性得分,然后使用 softmax 对得分进行归一化,最后直接对全部输入词向量进行加权求和。可以发现在这个过程中,难以满足单层自注意力神经网络丢弃一个特定维度特征而使得输出为 0 的要求。

因此本文在模型计算注意力得分之前,构造了一个全为 0(可复位)的键向量,其对应的值向量也全为 0。该项量与输入样本序列拼接并赋予相同的掩码值 1,当注意力机制认为原始输入值上没有重要的特征时,只需提高 0 向量的注意力得分即可,即将注意力转移到了一个空向量上。经过实验发现此方法可以显著提高模型的表现效果。

2.2 前置 Position-Wise 前馈神经网络

传统自注意力网络,例如在 Transformer 模型中^[8],Position-Wise 前馈神经网络发生在自注意力编码之后。受 LSTM 的启发,本文将 Position-Wise 前馈神经网络放置在注意力编码之前,将非线性变换的结果作为词向量的 value,而原始的 embedding 作为 key 和 query。从而得到如下式子,其中 V 相当于对上下文 X 中的每一个词向量进行了一次非线性变换后的结果, W_V 、 b_V 分别表示权重矩阵和偏置矩阵。

$$V = \tanh(W_V \cdot X + b_V) \quad (5)$$

用 V 替换 X ,得到模型对输入得编码结果 s :

$$s = \text{softmax}(f(X, q) + \text{mask}_{\text{feature}}) \cdot V^T \quad (6)$$

实验发现,经过改进,特征级注意力模型的表现得到了提升。

2.3 可复位特征级注意力情感分类模型

在 2.1 节、2.2 节特征级注意力机制的基础上,可以得到可复位特征级注意力网络。RFWA 使用一层可复位特征级注意力网络完成方面词汇与上下文之间的交互,从而得到方面级词汇的基于上下文的表示。之后,使用均值池化方法处理超过一个词长度的方面词,通过一个全连接层和 softmax 得到分类结果,模型架构如图 1 所示。本模型使用 Glove^[10]预训练模型的词嵌入作为原始输入。

3 可复位特征级自注意力情感分类模型(RFWSA)

3.1 可复位特征级自注意力网络

(1)基于 2.1 节的实验发现,在模型计算注意力得分之前,构造了一个全为 0 的键向量;(2)基于 2.2 节的实验发现,将 Position-Wise 前馈神经网络调整放置在注意力编码前;(3)通过将特征级注意力机制的 query 变量设置成输入向量,可得到特征级自注意力机制。结合以上 3 方面,最终得到了一个改进后的可复位特征级自注意力网络。

其注意力得分计算原理如图 2 所示,在原始文本向量结合补全向量的基础之上添加复位向量作为输入,应用特征级自注意力机制计算自注意力得分,利用可复位注意力掩码修正注意力得分之后,使用行序 softmax 得到可复位特征级自注意力权重矩阵。

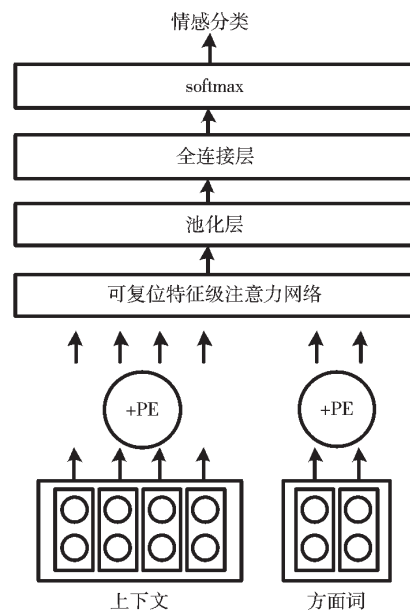


图 1 可复位特征级注意力情感分类模型

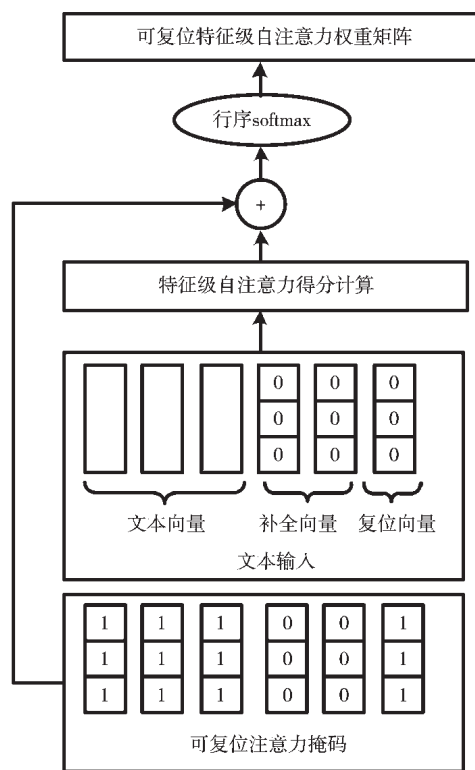


图 2 可复位特征级自注意力得分计算

3.2 可复位特征级自注意力情感分类模型

如图 3 所示,RFWSA 使用位置编码、上下文特征级自注意力网络对上下文进行编码。同时,使用位置编码对方面词进行编码。然后再使用一层自注意力网络完成上下文与方面词的交互,之后通过池化层、全连接层和 softmax 完成情感分类。其中,上下文特征级自注意力网络为 3.1 节提出的可复位特征级自注意力网络模块。

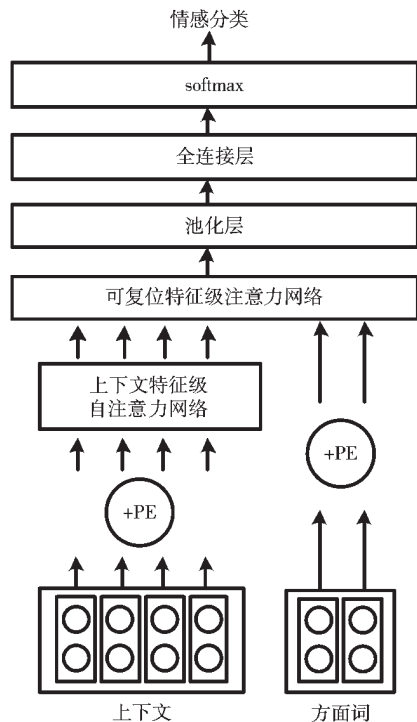


图3 可复位特征级自注意力情感分类模型

4 实验及分析

4.1 实验设置

(1) 数据集

使用 SemEval 2014^[11]方面级情感分析数据集进行训练和验证算法,该数据集分为两个子集,分别是 Laptop 在线评论数据、Restaurant 在线评论数据,每个数据集又被分为训练集和测试集,每条数据包括 3 类人工标注好的标签。此外,还引入文献[12]中的 Twitter 数据集作为测试。数据组成如表 1 所示。

表 1 实验数据统计表

(条)

数据集	积极	中性	消极
Laptop-训练	994	464	870
Laptop-测试	341	169	128
Restaurant-训练	2 164	637	807
Restaurant-测试	728	196	196
Twitter	692	2 244	263

(2) 实验环境

使用 Google Colaboratory 云计算 GPU 进行训练,GPU 型号为 K80,12 GB 显存。

(3) 超参数设置

为了防止网络的过拟合,添加了 L2 正则化因子,通过 L2 正则因子修正损失函数,将网络权重限制在一个较小的值,减小了梯度消失和梯度爆炸的可能。使用 Adam 算法进行梯度更新,学习率为 0.01。Batch-size 为 25。使用 Glove 27B 300d 词嵌入初始化词向量,非词典词依正

态分布为随机值。添加了 Dropout 层,keep-rate 设置为 0.8,L2 正则参数为 10^{-4} ,注意力计算层隐层大小设置为 200 维,输入非线性变换层为 150 维。所有代码基于 Pytorch 实现。

4.2 实验结果与分析

实验结果如表 2 所示。通过结果发现,RFWA、RFWSA 在方面级情感分类的表现上与现有主流模型相当。其中 RFWSA 在 Restaurant 数据集上准确率为 0.819,在 Laptop 数据集上准确率为 0.746,分别超过表现第 2 好的 AOA 模型 0.7 个百分点和 0.1 个百分点,但在 Twitter 数据集上低于 MGAN 模型 1.3 个百分点。

表 2 实验结果对比

(准确率)

算法	Restaurant 数据集	Laptop 数据集	Twitter 数据集
TD-LSTM ^[4]	0.756	0.681	0.666
ATAE-LSTM ^[13]	0.772	0.687	-
IAN ^[6]	0.786	0.721	-
MGAN ^[7]	0.810	0.736	0.725
RAM ^[14]	0.802	0.744	0.698
AOA-LSTM ^[2]	0.812	0.745	-
RFWA	0.814	0.742	0.704
RFWSA	0.819	0.746	0.712

为了更好地比较模型在不同维度上的表现,本文统计了主要模型的参数量,如表 3 所示。

表 3 相关模型参数量对比

(万)

算法	参数量
LSTM	140
MAN	200
AOA	108
RFWA	19
RFWSA	27

从表 3 中可以看出,RFWA 模型仅使用 19 万参数,而其在 Restaurant 数据集上的分类准确率依然超过 AOA 模型 0.2 个百分点。在参数使用量方面,RFWA 使用了 19 万参数,RFWSA 使用了 27 万参数,相比其他方面级情感分析模型优势明显。

5 结论

针对情感分析高精度、低参数化的要求,本文通过对基本特征级注意力模型进行改进,提出了基于可复位特征级注意力的方面级情感分类模型,得到 RFWA 和 RFWSA 两个模型。在方面级情感分析公开数据集 SemEval 2014、Twitter 上进行测试后,实验结果表明,两个模型在取得与现有主流模型相当分类效果的情况下,在参数利用率上具有明显的优势。

参考文献

- [1] ZHANG M, ZHANG Y, VO D T. Gated neural networks for targeted sentiment analysis[C]. 2016 30th Conference on Artificial Intelligence (AAAI), 2016 : 3087–3093.
- [2] HUANG B, OU Y, CARLEY K M. Aspect level sentiment classification with attention-over-attention neural networks[C]. Lecture Notes in Computer Science, 2018 : 197–206.
- [3] VO D T, ZHANG Y. Target-dependent twitter sentiment classification with rich automatic features[C]. International Joint Conference on Artificial Intelligence (IJCAI), 2015 : 1347–1353.
- [4] TANG D, QIN B, FENG X, et al. Effective LSTMs for target-dependent sentiment classification[C]. 2016 26th International Conference on Computational Linguistics (COLING), 2016 : 3298–3307.
- [5] KIM Y. Convolutional neural networks for sentence classification[J]. ArXiv preprint : 1408.5882, 2014.
- [6] MA D, LI S, ZHANG X, et al. Interactive attention networks for aspect-level sentiment classification[C]. 2018 10th International Conference on Knowledge and Systems Engineering (KSE), 2018 : 25–30.
- [7] FAN F, FENG Y, ZHAO D. Multi-grained attention network for aspect-level sentiment classification[C]. Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018 : 3433–3442.
- [8] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. arXiv : 1706.03762, 2017.
- [9] SONG Y, WANG J, JIANG T, et al. Attentional encoder network for targeted sentiment classification[J]. arXiv : 1908.09314, 2019.

- [10] PENNINGTON J, SOCHERR, MANNING C D. GloVe : Global vectors for word representation[C]. Conference on Empirical Methods in Natural Language Processing(EMNLP), 2014 : 1532–1543.
- [11] PONTIKI M, GALANIS D, PAVLOPOULOS J, et al. SemEval 2014 Task 4 : aspect based sentiment analysis annotation guidelines[C]. 2015 9th International Workshop on Semantic Evaluation (SemEval), 2015 : 486–495.
- [12] DONG L, WEI F, TAN C, et al. Adaptive recursive neural network for target-dependent twitter sentiment classification[C]. Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, 2014, 2 : 49–54.
- [13] WANG Y, HUANG M, ZHU X, et al. Attention-based LSTM for aspect-level sentiment classification[C]. Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2016 : 606–615.
- [14] LI C, GUO X, MEI Q. Deep memory networks for attitude identification[C]. Proceedings of the Tenth ACM International Conference on Web Search and Data Mining(ICWSDM), 2017 : 671–680.

(收稿日期:2020-06-27)

作者简介：

杨嘉佳(1988-),男,博士,工程师,主要研究方向:社交网络、网络安全。

刘金(1990-),女,硕士,工程师,主要研究方向:社交网络、网络安全。

唐球(1985-),通信作者,男,博士,高级工程师,主要研究方向:社交网络、网络安全,E-mail:tangqiu@ncse.com.cn。



扫码下载电子文档

(上接第 77 页)

- 1226-1238.
- [9] QU G, HARIRI S, YOUSIF M. A new dependency and correlation analysis for features[J]. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(9): 1199-1207.
- [10] 沙丽瓦尔·阿里木, 努尔布力, 吾守尔·斯拉木. 改进的 Re-FCBF 算法在入侵检测中的应用[J]. 计算机工程与设计, 2016, 37(11): 2956-2960.
- [11] 郭佳靖, 姜宏, 章翔峰, 等. 基于 MRMD 的滚动轴承损伤程度识别方法研究[J]. 组合机床与自动化加工技术, 2019(3): 98-102.
- [12] SPOLAOR N, CHERMAN E A, MONARD M C, et al. ReliefF for multi-label feature selection[C]. 2013 Brazilian Conference on Intelligent Systems, 2013: 6-11.
- [13] 杨志伟, 努尔布力, 贾雪, 等. 基于 ReliefF 的入侵特征选择方法[J]. 吉林大学学报(理学版), 2015, 53(3): 505-510.
- [14] DEISY C, SUBBULAKSHMI B, BASKAR S, et al. Efficient

dimensionality reduction approaches for feature selection[C]. International Conference on Computational Intelligence and Multimedia Applications.IEEE, 2008.

- [15] 黄晓娟.面向特征选择的Relief 算法研究[D].苏州:苏州大学,2018.
- [16] QAMAR A M, GAUSSIER E. Similarity learning in nearest neighbor and RELIEF algorithm[C]. Ninth International Conference on Machine Learning & Applications. IEEE, 2011.

(收稿日期:2020-06-19)

作者简介：

邵琪(1995-),女,硕士研究生,主要研究方向:信号处理、非侵入式负荷监测。

包永强(1978-),男,博士,教授,主要研究方向:信号处理、非侵入式负荷监测等。

姜家辉(1995-),男,硕士研究生,主要研究方向:信号处理、非侵入式负荷监测。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所