

基于BERT-BiLSTM-ATT的大宗商品新闻情感分析

柳标良, 谷晓燕

(北京信息科技大学 计算机学院, 北京 102200)

摘要: 为了实现对大宗商品新闻的情感分析, 针对传统方法未联系上下文语义关系, 且忽略了文本中的重要信息, 以及BERT难以处理长文本的问题, 提出一种基于完整句分割的BERT-BiLSTM-ATT情感分析模型。首先, 按照完整句的分割模式将新闻文本分割成多个部分; 其次, 使用BERT模型获取大宗商品新闻文本的特征表示; 再次, 将获取的文本特征最大池化后输入到BiLSTM, 提取新闻的情感特征, 在BiLSTM输出前增加注意力层提高分类精度; 最后, 使用Softmax分类器对提取的特征进行分类。实验结果表明, 该模型的F1指标相较于BERT-LSTM、BERT-BiLSTM、BERT-BiLSTM-ATT分别提高了5.4%、3.4%、2.2%, 证明了该方法在情感分析中的有效性。

关键词: 大宗商品新闻; 情感分析; 长文本处理; 完整句分割

DOI: 10.11907/rjtk.241069

中图分类号: TP391.1

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2025)005-0035-05



Sentiment Analysis of Commodity News Based on the BERT-BiLSTM-ATT Model

LIU Biaoliang, GU Xiaoyan

(School of Computer Science, Beijing Information Science and Technology University, Beijing 102200, China)

Abstract: To achieve sentiment analysis of commodity news, this article proposes an sentiment analysis method based on the complete sentence segmentation BERT-BiLSTM-ATT model to address the issues of traditional methods that lack contextual semantic relationships and ignore important information in text, as well as the difficulty of BERT in handling long texts. Firstly, the news text is divided into multiple parts according to the segmentation mode of the complete sentence, and then the BERT model is used to obtain the feature representation of the commodity news text, and then the obtained text features are pooled and input to BiLSTM to extract the emotional features of the news, add the attention layer before the output of BiLSTM to improve the classification accuracy, and finally use the Softmax classifier to classify the extracted features. The experimental results show that the F1 index is increased by 5.4%, 3.4% and 2.2% compared with BERT-LSTM, BERT-BiLSTM and BERT-BiLSTM-ATT, respectively, which proves the effectiveness of the proposed method in sentiment analysis.

Key Words: commodity news; sentiment analysis; long text processing; complete sentence segmentation

0 引言

大宗商品新闻中包含许多市场交易信息, 如果对交易各方产生的海量信息不及时进行分析处理, 就会导致风险事件难以早预警、早干预。因此, 挖掘交易信息中所蕴含的情感对于指导投资者决策、规避风险具有重大意义^[1]。

情感分析方法主要分为3类: 基于情感词典的方法、

基于传统机器学习的方法和基于深度学习的方法。

基于情感词典的方法是情感分析中最简单、传统的方法。Jia等^[2]利用现有的情感词典改进了不同类别的情绪强度计算方法, 颜明阳等^[3]提出一种领域特定的情感词典生成扩展方法, Xu等^[4]提出一种将扎根理论与半自动方法相结合的方法。然而, 情感词典中同一情感词在不同时间、领域所表达的含义是不一样的, 因此其适用性一般。

基于机器学习的情感分析方法主要分为3类: 有监

收稿日期: 2024-01-23

扫描二维码阅读全文:

基金项目: 国家自然科学基金项目(71701020)

作者简介: 柳标良(1997-), 男, 北京信息科技大学计算机学院硕士研究生, 研究方向为自然语言处理; 谷晓燕(1980-), 女, 博士, 北京信息科技大学计算机学院副教授, 研究方向为大数据分析、智能决策、风险管理。本文通讯作者: 谷晓燕。



督、半监督和无监督的方法。朱亚军等^[5]通过SVM算法对藏文进行情感分析,实验结果表明,对实义词语进行抽取后,准确率相比一般的情感词典方法有所提升。然而,传统的机器学习方法不能充分结合上下文的语义关系,从而影响到分类的准确性。

随着深度学习技术的发展,越来越多的深度学习模型被应用于情感分析中。Shadrina等^[6]使用循环神经网络(Recurrent Neural Network, RNN)、Kim等^[7]使用卷积神经网络(Convolutional Neural Network, CNN)对巴黎评论进行情感分析,发现其性能优于递归神经网络。Xu等^[8]采用词频—逆文档频率(Term Frequency - Inverse Document Frequency, TF-IDF)算法和双向长短期记忆网络(Bi-directional Long Short-Term Memory, BiLSTM),发现其效果优于RNN和CNN。但是,随着BERT(Bidirectional Encoder Representations From Transformers)模型的提出,其得到了更广泛的应用^[9]。Cai等^[10]提出变压器双向编码器(BERT)和双向长短期记忆(BiLSTM)相结合的方法,刘博等^[11]提出一种基于BERT和集合神经网络的长文本分类模型,何晓霞等^[12]提出一种结合BERT词嵌入和BiLSTM的微博谣言持续检测模型,以上方法相较于之前的基础方法取得了更好的效果。随着近年来注意力机制引入到自然语言处理领域,各种改进模型也应运而生。周晓雯等^[13]提出一种基于注意力编码机制和情感词位置的交互感知网络,曾莉等^[14]提出一种融合主题模型和情感分析的LDA-Attention-BiLSTM模型,张仰森等^[15]提出一种将情感符号和深度学习模型相结合的微博情感分析方法,以上融合注意力机制的方法都取得了更好的情感分析与分类效果,但其大多针对短文本领域。大宗商品新闻因具有文本长度较长、情感信息分布较分散等特点,因此需要解决长文本的向量表示及重点信息聚焦等问题。

本文在加入注意力机制的基础上,采用完整句分割的方式并结合BERT预训练模型,能够有效地将文本向量化,同时联系上下文语境,提出一种基于完整句分割的BERT-BiLSTM-ATT大宗商品新闻情感分析模型。

1 模型构建

为了提高对大宗商品新闻情感分析的准确性,本文提出一种基于完整句分割的BERT-BiLSTM-ATT模型对大宗商品新闻情感进行分析。BERT的最大编码长度为512,但新闻中的文本长度一般超过了512。Sun等^[16]通过直接截断文本的方式保留了512个文本长度,但会导致数据丢失或者失去上下文的联系。本文首先基于完整句分割方式,在保证全文文本句子完整的前提下,每次在长度不超过512的前提下分割出句子,将新闻分成4部分。其次,逐步输入到BERT模型,得到新闻的文本特征表示。再次,将同新闻段的特征矩阵通过池化层最大池化方法拼接在一

起输入到BiLSTM网络,提取大宗新闻的情感特征。同时,在正常BiLSTM模型的输出层之前增加一个注意力机制,进一步提高分类精度。最后,结合Softmax分类器对提取的特征进行分类。本文方法的具体流程如图1所示。




Fig. 1 The sentiment analysis process of BERT-BiLSTM-ATT based on complete sentence segmentation

图1 基于完整句分割的BERT-BiLSTM-ATT情感分析流程

1.1 基于完整句分割的BERT文本表示层

在文本分类任务中,文本的编码技术是最基本的。Mikolov等^[17]在Word2Vec模型中提出了向量词训练,并将其应用于文本分类。该方法有许多优点,比如可以联系词语上下文的关系,维度较少,速度较快,通用性很强,可以用于各种自然语言处理任务中。但是也有明显缺点,比如由于词和向量是一一对应的关系,所以无法解释一词多义。BERT模型解决了一词多义的问题。BERT是由多层的双向Transformer结构组成,其中“双向”的意义就在于可以根据上下文的语义关系来处理单词,让其在具体环境中表达出具体语义。但是,由于BERT最多只能接受512个token的输入,所以需要对文本进行分割。具体分割方法及编码过程如图2所示。

本文选择的分割段落数为4段,主要从3个因素出发。第一点从数据集长度出发,通过对文章数据集长度进行整理总结发现,超过90%的新闻文本长度都在2 040以下。根据BERT的最大处理长度,将其分割成4个部分。第二点从文本的段落结构和连贯性出发,新闻的段落数大致为2~6段。与分割成2段相比,该方法没有失去太多文本内容;与分割成8段相比,分割成4段能更好地保持文章段落的联系性。若分段过多,出现问题的概率则会提高。第三点从模型性能和资源消耗出发,增加分段量,会导致计算量呈指数增长。为此,必须减小输入的batch数,因而导致




Fig. 2 Structure of the BERT model based on complete sentence segmentation

图2 基于完整句分割BERT模型结构

训练时间大大提升。对于不同的数据源而言,分割的段落数是有区别的。从上述3个角度出发,选择合适的分段数,既能达到较高的准确率,又能节省资源消耗。

具体分割与编码流程如下:假设有 m 个原始新闻,将每个新闻分割成4段放入一个batch中,然后输入到BERT中,其训练后所表达出来的特征向量为: $W=(W^1, W^2, \dots, W^{4m})$, $W^i=(T_1^i, T_2^i, \dots, T_n^i)$ 。其中, W^i 表示第 i 个新闻片段的向量矩阵, T_n^i 表示每个单词的特征表示, n 表示段落的最大长度。原始新闻的长度大部分不超过2 040,超过2 040的部分在输入时会直接被切割掉。每个新闻分割成4个片段,每个片段的最大长度限制为510,多余的2个长度分别为SEP和CLS标志位。如果未达到4个片段数,则用空片段填满。将分割完的新闻片段输入到BERT后,得到的输出维度为 $(4m, 768)$,之后需要把这 $4m$ 个新闻片段分组。取同新闻的4个片段为一组,此时的维度由 $(4m, 768)$ 变为 $(m, 4, 768)$ 。最后对同一组的向量进行池化操作,得出每个新闻的表征向量,此时的向量维度由 $(m, 4, 768)$ 变为 $(m, 768)$ 。一般模型的池化方法包括最大池化和平均池化,本文选取的是最大池化。因为最大池化可以选择保留显著的特征,平均池化一般情况下会把特征值拉平,而保留显著的特征更具有代表性。

1.2 双向语义捕获的BiLSTM层

当文本编码完成后,将同一新闻的编码融合在一起传递给BiLSTM结构。LSTM是一种特殊的RNN,将一个常规的RNN模型节点替换成一个单元格,由此解决了当相关信息和当前预测位置的间隔非常大时,RNN会丧失学习连接很远信息能力的问题。前向的LSTM与后向的LSTM结合成BiLSTM,可以更好地捕获双向语义特征。如图3所示,前向的LSTM依次输入 x_1, x_2, x_3, x_4 得到4个向量 $\{h_1, h_2, h_3, h_4\}$,后向的LSTM依次输入 x_4, x_3, x_2, x_1 得到4个向量 $\{h_4^*, h_3^*, h_2^*, h_1^*\}$ 。最后将前向与后向的隐向量拼接在一起得到 $\{[h_1, h_1^*], [h_2, h_2^*], [h_3, h_3^*], [h_4, h_4^*]\}$ 。




Fig. 3 Structure of the BiLSTM model

图3 BiLSTM模型结构

该模型的计算和输出公式如式(1)一式(3)所示。其中, y_n 为 n 个时间BiLSTM的输出, W 为权重, h 为偏置, H 为隐藏单位数量。

前向的LSTM更新公式为:

$$h_n^1 = H(W_{xh^1} x_n + W_{h^1 h^1} h_{n-1}^1 + b_{h^1}) \quad (1)$$

后向的LSTM更新公式为:

$$h_n^2 = H(W_{xh^2} x_n + W_{h^2 h^2} h_{n-1}^2 + b_{h^2}) \quad (2)$$

前向与后向的LSTM叠加输出公式为:

$$y_n = W_{h^1 y} h_n^1 + W_{h^2 y} h_n^2 + b_y \quad (3)$$

1.3 特征聚焦的ATT层

在大宗新闻文本中,文本的长度较长,一些单词对语句的表达并没有产生影响或者影响很小,更需要关注的是那些重要的部分。因此,本文引入注意力机制,有选择性地忽略无用信息,并增强对重要部分的关注度。通过对文本的不同部分分配不同权重,可以关注到更重要的部分,以进一步提高分类的准确度。

该方法的基本原理是对经过BiLSTM训练得出的 H_t 都乘以矩阵 W_g 得到 u_t ,用激活函数 $\tanh$ 对 u_t 去线性化;然后进行权重计算,得出权重值 α_t ;最后将每个时间步的输出与对应权重相乘,并将各个时间加权后的输出数据全部相加,即得到注意力特征表示数 R 。具体原理如式(4)一式(6)所示。

$$u_t = \tanh(W_g H_t + b_g) \quad (4)$$

$$\alpha_i = \frac{\exp(u_i)}{\sum_i \exp(u_i)} \quad (5)$$

$$R = \sum_i \alpha_i H_i \quad (6)$$

其中, H_i 为在 t 时刻 BiLSTM 层的输出, W_g 、 b_g 分别为参数向量和偏置, $\exp()$ 为指数函数。

1.4 特征输出层

将获取的特征矩阵 H 输出到全连接层进行情感倾向预测, 并通过 Softmax 函数获得句子的情感分布 P_R 。其原理如式(7)所示。其中, W_s 、 b_s 分别表示参数向量和偏置。

$$P_R = \text{Softmax}(W_s R + b_s) \quad (7)$$

2 实验与分析

2.1 数据集

该实验数据是通过东方财富网、新浪财经、纺织网、同花顺财经等网站爬取下来的, 总共爬取的新闻数量为 8 000 条。如表 1 所示, 通过对其长度进行排序发现, 大部分长度都在 2 000 以下。因此, 本文选取的文本处理长度为 2 040。

Table 1 News length table

表 1 新闻长度表

长度范围	数量
0 ~ 500	1 043
500 ~ 1000	3 338
1 000 ~ 1 500	2 503
1 500 ~ 2 000	820
2 000 以上	296

数据预处理是机器学习模型的重要步骤之一。首先对获取的数据进行预处理和规范化, 去除重复和缺失的数据。获取的文本中有些数据存在缺失或者为空的情况, 会导致程序运行出现问题。同时, 模型的训练和测试结果也会受到文本中重复值的影响。由于删除停用词能够减少干扰, 因此通过人工标注其中一些具有明显情感倾向的新闻, 删除一些不太具有情感倾向的新闻。具体标注规则为: 文本中出现明显上涨趋势的词被认为是正向极性, 比如上涨、猛增、回暖等; 文本中出现明显下跌趋势的词被认为是负向极性, 比如下跌、回调、低开等。文本长度超过 2 040 的新闻在输入时会自动切割掉超过的部分, 因为文本长度过长会导致显存不够。剩下的 2 000 条数据, 将负面新闻标作 0, 正面新闻标作 1。之后通过随机抽样, 将总数据按 8:1:1 的比例分为训练集、验证集和测试集, 并保证每个集合里正、负新闻的比例相同。每条数据包括两部分: 新闻内容和类别编号。

数据训练具体流程如下: 首先, 使用训练集对模型进行训练, 并通过验证集评估模型, 通过损失函数的变化不断调整模型参数, 直到找到最佳参数; 其次使用测试集对模型进行测试, 得到具有较强泛化能力的模型。

2.2 参数与评价指标

实验平台搭建完毕后, 实验参数设置如表 2 所示。

Table 2 Experimental parameter settings

表 2 实验参数设置

Parameter name	Parameter value
Epoch	20
Batch size	2
Learning rate	2E-5
Embedding size	510
Hidden size	768
Hidden activate	Relu
Dropout	0.5
Optimizer	Adam

本文为了验证模型的有效性, 利用测试数据集对模型进行评估。针对不同模型所得出的结果, 使用 3 个评价指标来评价模型效果, 分别为准确率 A (Accuracy)、召回率 R (Recall)、 $F1$ 值 (F -score), 并采用时间 T (Time) 来衡量模型的复杂度和计算时间。准确率是指所有预测正确的正例和负例占新闻文本总量的比例; 召回率是指预测正确的正例占实际是正例的比例; $F1$ 值为召回率和精确率的调和平均数; 时间 T 是指训练一个 epoch 所需的时间。评价指标计算公式如下:

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \quad (8)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (9)$$

$$F1 = \frac{2 * P * R}{P + R} \quad (10)$$

在该实验中, 正类文本为积极类别, 负类文本为消极类别。式中, TP 、 TN 分别为正类样本和负类样本预测正确的数量; FP 、 FN 分别为正类样本和负类样本预测错误的数量。

2.3 模型对比实验

为了验证本文模型有效性, 首先将 Word2vec、GloVe、BERT 3 种不同的预训练模型进行对比。由表 3 的实验结果得出, BERT 具有更强大的文本表征能力。因此, 选用 BERT 作为预训练模型。

Table 3 Comparison experimental results of pre-trained models

表 3 预训练模型对比实验结果 (%)

Model	Acc	Recall	F1
Word2vec	73.3	70.3	73.0
GloVe	75.6	72.1	75.3
BERT	77.1	74.8	77.2

直接截断方法作为文本的基础处理方法, 使用 BERT-LSTM、BERT-BiLSTM、BERT-BiLSTM-ATT 以及基于完整句分割的 BERT-BiLSTM-ATT 将文本分别分割成 2 段、4 段与 8 段进行对比。实验结果如表 4 所示。

2.4 实验结果分析

表 4 给出了不同模型针对大宗商品新闻的准确率、召回率以及 $F1$ 值。其中, BERT-BiLSTM 模型的实验结果优

Table 4 Experimental results of the comparison model
表 4 对比模型实验结果

Model	Acc/%	Recall/%	F1/%	Time/min
BERT-LSTM	78.3	76.3	78.3	4.11
BERT-BiLSTM	80.6	80.3	80.3	5.04
BERT-BiLSTM-ATT	82.0	81.8	81.5	5.40
分割 2 段的基于完整句分割的 BERT-BiLSTM-ATT	82.1	82.9	82.3	8.19
分割成 4 段的基于完整句分割的 BERT-BiLSTM-ATT	83.5	84.4	83.7	12.31
分割成 8 段的基于完整句分割的 BERT-BiLSTM-ATT	82.7	83.6	82.9	19.71

于 BERT-LSTM 模型,证明 BiLSTM 相比 LSTM 具有更强的对文本上下文特征的学习能力,有利于提取更多上下文信息。加入 ATT 机制后,准确率与 F1 值分别提高了 1.5% 和 1.2%,证明 ATT 机制有助于捕捉重要的文本特征。最后分割 4 段的基于完整句分割的 BERT-BiLSTM-ATT 模型的准确率和 F1 值相比采用直接截断方法的 BERT-BiLSTM-ATT 模型都有所提升,证明该方法有助于提高情感分类的准确性。

通过分析得到,分割成 2 段的方法虽比直接截断的方法增加了文本长度,但是同样存在信息丢失问题,而且比分割成 4 段的效果更差。分割成 8 段的方法在保持原有 batch 数的情况下,显存不够。为此减小 batch 数,并且增加分段数,会更容易丧失段落之间的联系性,出现问题的概率也会增加。虽说其略优于分割成 2 段,但比分割成 4 段的效果差,并且训练时间大幅提升。在 F1 和准确率相差不大的情况下,训练时间也是需要考虑的一个重要因素。

3 结语

本文提出一种基于完整句分割的 BERT-BiLSTM-ATT 大宗商品新闻情感分析模型。首先,针对 BERT 不能处理长文本的问题,将大宗商品新闻文本分割成 4 部分。其次,使用 BERT 得到 4 部分的文本特征。再次,将同新闻段的 4 个特征部分拼接在一起输入到 BiLSTM 网络,提取大宗新闻的情感特征。为进一步提高分类精度,还增加了一个注意力机制。最后,结合 Softmax 分类器对提取的特征进行分类。实验结果表明,本文模型的性能优于传统模型。在后续工作中,还可以继续扩大数据来源,加入中性的判断,并且进一步优化算法,以期达到更好的效果。

参考文献:

[1] FAN R B. Discussion on how to strengthen risk control of bulk commodity trading enterprises[J]. Public Investment Guide, 2023(15): 77-79.
范瑞斌. 探讨大宗商品贸易企业如何强化风险控制[J]. 大众投资指南, 2023(15): 77-79.

[2] JIA K L, LI Z N. Chinese micro-blog sentiment classification based on emotion dictionary and semantic rules [C]//2020 International Conference on Computer Information and Big Data Applications, 2020: 309-312.

[3] YAN M Y, YAN G L, LI M L. Application of domain-specific sentiment

dictionary extension method in sentiment classification [J]. Computer Applications and Software, 2022, 39(6): 176-182.

颜明阳, 闫国梁, 李明兰. 领域特定情感词典扩展方法 在情感分类中的应用 [J]. 计算机应用与软件, 2022, 39(6): 176-182.

[4] XU L, LI L J, JIANG Z H, et al. A novel emotion lexicon for Chinese emotional expression analysis on Weibo: using grounded theory and semi-automatic methods [J]. IEEE Access, 2021, 9: 92757-92768.

[5] ZHU Y J, CI Q, YONG C. Research on sentiment analysis of Tibetan microblog based on SVM algorithm [J]. Computer Simulation, 2022, 39(8): 226-229.

朱亚军, 次曲, 拥措. 基于 SVM 算法的藏文微博情感分析研究 [J]. 计算机仿真, 2022, 39(8): 226-229.

[6] SHADRINA N K, SUTOYO E, WIDARTHA V P. Sentiment analysis in reviews about beaches in Bali on tripadvisor using recurrent neural network (RNN) [C]//2021 IEEE 7th Information Technology International Seminar, 2021: 1-6.

[7] KIM Y. Convolutional neural networks for sentence classification [C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing, 2014: 1746-1751.

[8] XU G X, MENG Y T, QIU X Y, et al. Sentiment analysis of comment texts based on BiLSTM [J]. IEEE Access, 2019, 7: 51522-51532.

[9] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bi-directional transformers for language understanding [C]//Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2019: 4171-4186.

[10] CAI R, QIN B, CHEN Y K, et al. Sentiment analysis about investors and consumers in energy market based on BERT-BiLSTM [J]. IEEE Access, 2020, 8: 171408-171415.

[11] LIU B, PU Y F. Long text classification method based on BERT [J]. Journal of Sichuan University (Natural Science Edition), 2023, 60(2): 81-88.

刘博, 蒲亦非. 基于 BERT 的长文本分类方法 [J]. 四川大学学报 (自然科学版), 2023, 60(2): 81-88.

[12] HE X X, GULANBAIER T E H, MAIRIDAN W S E, et al. Continuous detection model of microblog rumor based on BERT word embedding and BiLSTM [J]. Journal of Northeast Normal University (Natural Science Edition), 2023, 55(1): 65-71.

何晓霞, 古兰拜尔·吐尔洪, 买日旦·吾守尔, 等. 融合 BERT 词嵌入和 BiLSTM 的微博谣言持续检测模型 [J]. 东北师大学报 (自然科学版), 2023, 55(1): 65-71.

[13] ZHOU X W, WANG X Y, SUN J Q, et al. Sentiment analysis fusing attention mechanism and affective word position [J]. Computer Applications and Software, 2022, 39(12): 180-186, 194.

周晓雯, 王晓晔, 孙嘉琪, 等. 融合注意力机制和情感词位置的情感分析 [J]. 计算机应用与软件, 2022, 39(12): 180-186, 194.

[14] ZENG L, YANG T B, ZHOU H. Microblog public opinion analysis model based on LDA and attention mechanism BiLSTM [J]. Journal of Nanjing University of Science and Technology, 2022, 46(6): 742-748.

曾莉, 杨添宝, 周慧. 基于 LDA 与注意力机制 BiLSTM 的微博舆情分析模型 [J]. 南京理工大学学报, 2022, 46(6): 742-748.

[15] ZHANG Y S, ZHENG J, HUANG G J, et al. Microblog sentiment analysis method based on dual attention model [J]. Journal of Tsinghua University (Natural Science Edition), 2018, 58(2): 122-130.

张仰森, 邢佳, 黄改娟, 等. 基于双重注意力模型的微博情感分析方法 [J]. 清华大学学报 (自然科学版), 2018, 58(2): 122-130.

[16] SUN C, QIU X. How to fine-tune BERT for text classification? [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020: 9049-9056.

[17] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space [C]//2013 IEEE International Conference on Acoustics, Speech and Signal Processing, 2013: 6645-6649.

(责任编辑:黄健)