

基于多任务学习的正逆向情绪分值回归方法

高晓雅¹, 李逸薇², 张璐¹, 李寿山¹

(1. 苏州大学 计算机科学与技术学院 江苏 苏州 215006;

2. 香港理工大学 中文及双语系 香港 999077)

摘要: 提出一种基于多任务学习的情绪分值回归方法。首先,针对每一种情绪分值设计了正向打分和逆向打分;其次,将每一种分值的回归任务分为正向打分回归子任务和逆向打分回归子任务;最后,提出一种多任务学习方法用于主任务(正向打分回归子任务)和辅助任务(逆向打分回归子任务)的共同学习。该方法通过 3 种不同的共享机制实现中间特征信息共享,从而提升主任务的性能。结果表明,所提出的多任务学习方法能比基准方法获得更好的回归性能。

关键词: 情绪回归; 多任务学习; 正逆向分值; 长短期记忆网络模型

中图分类号: TP391

文献标志码: A

文章编号: 1671-6841(2020)01-0060-06

DOI: 10.13705/j.issn.1671-6841.2019042

0 引言

随着互联网的高速发展,人们在网络平台上共享信息的同时,越来越习惯于在网络上发表自己的评论及看法。如何对大量包含情感的文本进行情绪分析,挖掘具有潜在价值的信息成为目前自然语言处理领域中的一个热点问题^[1]。早期的情绪分析研究主要对评论进行粗粒度的情绪分类,即关注评论的情绪极性(正面、中性、负面)。随着相关研究的深入,文献[2-3]将注意力转移到细粒度情绪分类任务中,对文本进行了更细致的剖析。

与情绪分类不同,情绪回归注重于分析情绪的连续性。文献[4-5]从心理学角度将情绪映射到三维空间,坐标值范围均为 1.0~5.0,3 个维度分别为极性程度、唤醒度和可控度,其中极性程度表示情绪从消极到积极的程度,唤醒度表示情绪从冷静到激动的程度,可控度表示情绪的控制程度。传统的情绪回归方法,例如长短期记忆网络模型(LSTM)^[6]和卷积神经网络(CNN)^[7]均只对客观的情绪分值进行回归,回归结果偏差较大。例如,语句“Alonso would be happy to retire with three titles”中,极性程度分值受到词“happy”的影响,模型输出的分值为 4.0,但是从词“would be”和词“retire”可以看出情绪有消极的部分。如果从消极的方向出发回归极性程度分值,结果仍可得到 4.0,但是由于两种分值的总和始终为 6.0。因此,如何利用从消极方向出发回归得到的极性程度分值修正客观的极性程度分值,使得客观的极性程度分值接近于实际的分值 3.4,成为本文的挑战。基于此,本文提出一种基于多任务学习的情绪分值回归方法,针对每种分值设计正向和逆向两种打分方式,规定正向为情绪的积极、激动和受控,逆向为情绪的消极、冷静和失控,利用多任务学习方法联合正向打分的情绪回归主任务和逆向打分的情绪回归辅助任务,在多任务学习中通过 3 种不同的共享机制实现中间特征信息共享,改善了主任务的性能。

1 相关工作

情绪回归是一种情绪分析任务。与情绪分类相比,由于情绪回归缺乏大规模的语料库,因此出现了一些与情绪回归语料库构建相关的研究。文献[8]通过多个在线资源,构建了一个包含 2 009 个文本的中文情绪

收稿日期: 2019-02-23

基金项目: 国家自然科学基金项目(61331011, 61375073)。

作者简介: 高晓雅(1995—),女,江苏镇江人,硕士研究生,主要从事自然语言处理研究,E-mail: 570814569@qq.com; 通信作者: 李寿山(1980—),男,江苏扬州人,教授,主要从事情感分析、自然语言处理研究,E-mail: lishoushan@suda.edu.cn。

回归语料库。文献[9]从 Facebook 收集用户信息,建立了一个包含 2 895 个文本的英语情绪回归语料库。文献[1]构建了 EmoBank 大型情绪回归语料库,其中包含 10 000 多个英文文本。文献[10]提出一种基于区域卷积模型和 LSTM 的情绪回归方法 RCL,对文本的极性程度分值和唤醒度分值进行了回归。文献[11]通过多任务学习实现了基于二维连续空间(极性程度分值和唤醒度分值)的情感识别。文献[12]在基于循环神经网络的多任务学习框架中,将情绪三元分类和五元分类视为相关任务,通过联合学习改善细粒度情绪分类问题。

与上述研究不同的是,本文从 2 个方向定义情绪分值,利用多任务学习方法联合正逆向情绪回归任务,并通过 3 种不同的共享机制提升正向情绪回归任务的性能。

2 多任务学习方法

本文提出一种基于多任务学习的正逆向情绪分值回归方法。为了便于理解,将回归任务抽象为 4 层:输入层、编码层、解码层、输出层。在编码层中将不同的学习模型抽象为不同的密钥,通过更换模型可以得到不同的回归方法。

2.1 基于编码层共享的多任务学习方法

共享编码层的多任务学习框架如图 1 所示。

输入数据 X ,分别经过主任务的编码层和辅助任务的共享编码层,得到中间特征信息 h_{Main1} 、 h_{Main2} 、 h_{Aux} ,可以表示为

$$\begin{aligned} h_{Main1} &= \text{Encoder}_{Main}(X), \\ h_{Main2} &= \text{Encoder}_{Aux}(X), \\ h_{Aux} &= \text{Encoder}_{Aux}(X). \end{aligned}$$

将中间特征信息 h_{Main1} 和 h_{Main2} 拼接后共同输入到主任务的解码层中,再通过解码层得到主任务回归的正向情绪分值 r_{Main} ,可以表示为

$$\begin{aligned} h'_{Main} &= h_{Main1} \oplus h_{Main2}, \\ r_{Main} &= \text{Decoder}_{Main}(h'_{Main}). \end{aligned}$$

定义一个代价函数来线性连接主任务和辅助任务,可以表示为

$$\begin{aligned} loss_{Multi} &= \lambda \cdot \frac{1}{2m} \sum_{i=1}^m (r_{Main}^{[i]} - y_{Main}^{[i]})^2 + (1 - \lambda) \cdot \\ &\frac{1}{2m} \sum_{i=1}^m (r_{Aux}^{[i]} - y_{Aux}^{[i]})^2 + \frac{l}{2} \|\theta\|_2^2, \end{aligned} \quad (1)$$

式中: $y_{Main}^{[i]}$ 为主任务中第 i 个样本的真实值; $y_{Aux}^{[i]}$ 为辅助任务中第 i 个样本的真实值; m 为样本总数; λ 为衡量主任务和辅助任务损失度的权重参数;使用 L2 正则化参数 θ 。

2.2 基于解码层共享的多任务学习方法

共享解码层的多任务学习框架如图 2 所示。

输入数据 X ,分别经过 2 个任务的编码层,得到中间特征信息 h_{Main} 、 h_{Aux} ,可以表示为

$$\begin{aligned} h_{Main} &= \text{Encoder}_{Main}(X), \\ h_{Aux} &= \text{Encoder}_{Aux}(X). \end{aligned}$$

将中间特征信息 h_{Main} 、 h_{Aux} 分别通过主任务解码层和辅助任务解码层,并将 h_{Main} 共享到辅助任务的解码层,可以表示为

$$\begin{aligned} r'_{Main1} &= \text{Decoder}_{Main}(h_{Main}), \\ r'_{Main2} &= \text{Decoder}_{Aux}(h_{Main}). \end{aligned}$$

将主任务解码层输出的 r'_{Main1} 和辅助任务解码层输出的 r'_{Main2} ,通过线性加权得到最终的正向情绪分值 r_{Main} ,可以表示为

$$r_{Main} = W' \cdot [r'_{Main1} \ r'_{Main2}] + b'.$$

共享解码层的多任务学习框架的 $loss$ 函数如式(1)所示。

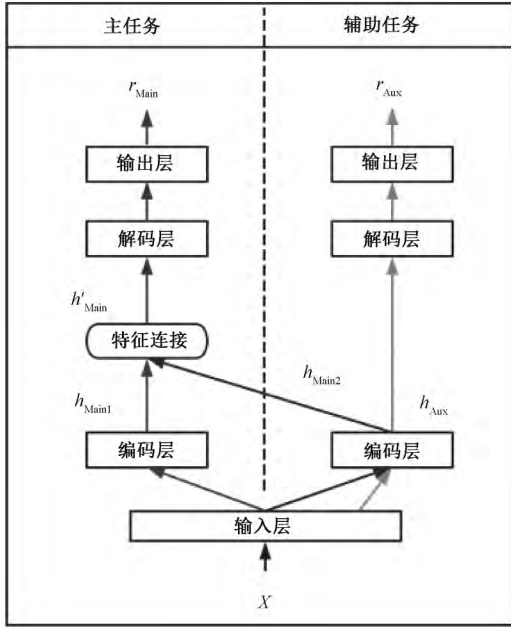


图 1 共享编码层的多任务学习框架

Figure 1 Multi-task learning framework of encoder-sharing layer

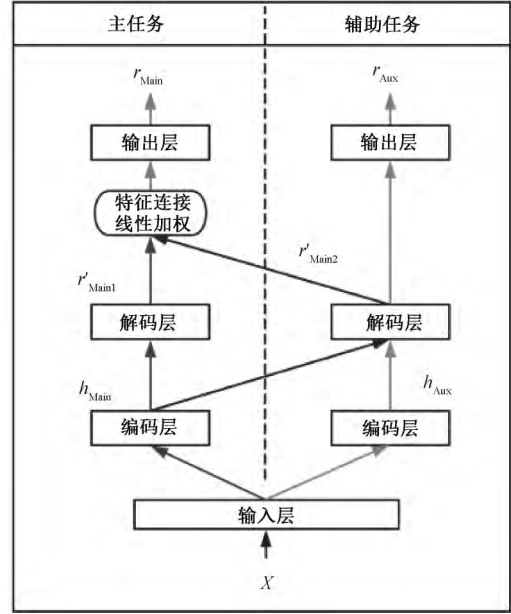


图 2 共享解码层的多任务学习框架

Figure 2 Multi-task learning framework of decoder-sharing layer

2.3 基于编、解码层同时共享的多任务学习方法

共享编、解码层的多任务学习框架如图 3 所示,此框架是由上述两种框架相结合产生的。

输入数据 X , 分别经过主任任务的编码层和辅助任务的共享编码层, 得到中间特征信息 h_{Main1} 、 h_{Main2} 、 h_{Aux} , 可以表示为

$$h_{Main1} = \text{Encoder}_{Main}(X),$$

$$h_{Main2} = \text{Encoder}_{Aux}(X),$$

$$h_{Aux} = \text{Encoder}_{Aux}(X)。$$

将中间特征信息 h_{Main1} 和 h_{Main2} 拼接后得到 h'_{Main} , 可以表示为

$$h'_{Main} = h_{Main1} \oplus h_{Main2}。$$

将中间特征信息 h'_{Main} 、 h_{Aux} 分别通过主任任务的解码层和辅助任务的解码层, 并将 h'_{Main} 共享到辅助任务的解码层, 表示为

$$r'_{Main1} = \text{Decoder}_{Main}(h'_{Main}),$$

$$r'_{Main2} = \text{Decoder}_{Aux}(h'_{Main})。$$

将主任任务解码层输出的 r'_{Main1} 和辅助任务解码层输出的 r'_{Main2} , 通过线性加权得到正向情绪分值 r_{Main} , 可以表示为

$$r_{Main} = W' \cdot [r'_{Main1} \ r'_{Main2}] + b'。$$

共享编、解码层的多任务学习框架的 $loss$ 函数如式 (1) 所示。

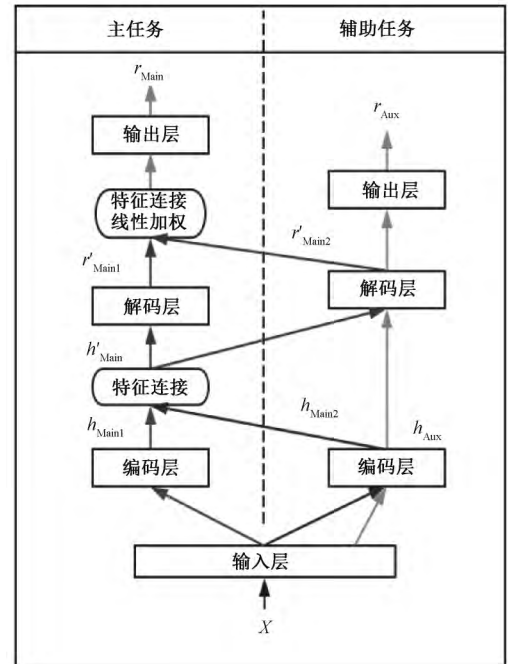


图 3 共享编、解码层的多任务学习框架

Figure 3 Multi-task learning framework of encoder-sharing and decoder-sharing layer

3 实验部分

3.1 实验设置

3.1.1 数据设置 使用文献 [1] 提供的 EmoBank 作为语料库, 此语料库可以从贡献者的 Github (<https://github.com/JULIELab/EmoBank>) 中下载得到。语料共包含 6 个领域 (News、Letters、Essays、Travel Guides、

Blogs、Fictions) ,且细分为读者情绪标注和写者情绪标注。将数据集的 70%设置为训练集,10%设置为验证集,20%设置为测试集,训练集用于训练构建模型,验证集用于调整模型的超参,测试集用于测试模型的回归性能。

使用斯坦福大学公开的词向量模型(下载网址为 <https://nlp.stanford.edu/projects/glove/>) 来表示每一条文本的词语。

3.1.2 参数设置 在实验中使用 LSTM 模型作为多任务学习中的编码器和解码器,对拟合唤醒度分值、可控度分值、极性程度分值分别使用了不同的模型参数。词向量维度 Embedding 均为 100 维,编码层输出 LSTM_output_dim 分别为 32 维、16 维、16 维,解码层输出 Dense_hidden_dim 同编码层输出 LSTM_output_dim 一致。

在训练过程中,最大迭代轮数 LSTM_epoch 分别为 100 轮、100 轮、300 轮,均使用 Adagrad 优化器且学习率 learning_rate 为 0.02。

3.1.3 评估指标 使用均方误差(MSE) 和相关系数(r) 来衡量模型拟合的情绪分值和实际标注的情绪分值之间的差异,较低的 MSE 或较高的 r 表示更好的回归性能。

MSE 和 r 的计算公式可以表示为

$$MSE(y, \hat{y}) = \frac{1}{m} \sqrt{(y - \hat{y})^2}, \quad (2)$$

$$r(y, \hat{y}) = \sqrt{1 - \frac{\sum (y - \hat{y})^2}{\sum (y - \bar{y})^2}}, \quad (3)$$

式中: \hat{y} 表示模型拟合的值; \bar{y} 表示实际值的平均值; m 表示测试样本的数量。

3.2 实验结果与分析

3.2.1 基准方法 首先实现了单任务的正向情绪分值回归方法,分别使用了以下 3 种模型。

1) SVR 模型。SVR 模型即支持向量回归模型,是情绪回归任务中最常见的基准方法之一^[13],本文实验中应用词袋(BoW) 作为其输入特征。

2) LSTM 模型^[6]。LSTM 模型通过引入“门”的机制来决定信息“遗忘”还是“保留”,以解决循环神经网络中的梯度爆炸或梯度消失的问题。LSTM 模型具有强大的文本建模能力,广泛应用于自然语言处理领域中。

3) RCL 模型^[10]。RCL 模型将文本按句子划分为多个区域,通过 CNN 模型提取区域特征,再由 LSTM 模型拟合出结果,是比较新颖的情绪回归任务的基准方法之一。

基于单任务学习的情绪分值回归方法的性能如表 1 所示。可以看出,神经网络方法即 LSTM 模型和 RCL 模型,通常优于机器学习方法 SVR。由于本文使用的 EmoBank 语料库中的文本大多为单一短小的句子,RCL 模型相较于 LSTM 模型无明显优势。因此,在下面的实验中,将使用单任务学习的 LSTM 模型作为本文的基准方法。

表 1 基于单任务学习的情绪分值回归方法的性能

Table 1 Performances of single-task learning approaches to emotion regression

| 情绪 | 方法 | 唤醒度分值 | | 可控度分值 | | 极性程度分值 | |
|------|-----------|---------|---------|---------|---------|---------|---------|
| | | r | MSE | r | MSE | r | MSE |
| 读者情绪 | SVR(BoW) | 0.057 0 | 0.418 9 | 0.042 3 | 0.376 9 | 0.213 4 | 0.478 0 |
| | RCL | 0.315 1 | 0.102 0 | 0.204 2 | 0.079 9 | 0.527 9 | 0.138 4 |
| | LSTM | 0.318 1 | 0.102 5 | 0.163 5 | 0.083 8 | 0.536 9 | 0.132 6 |
| 写者情绪 | SVR(BoW) | 0.075 3 | 0.178 1 | 0.040 9 | 0.130 2 | 0.211 9 | 0.179 4 |
| | RCL | 0.222 3 | 0.091 5 | 0.121 3 | 0.066 6 | 0.479 0 | 0.093 0 |
| | LSTM | 0.231 0 | 0.092 6 | 0.107 5 | 0.067 6 | 0.481 4 | 0.091 3 |

3.2.2 多任务学习方法 根据不同的共享机制,多任务学习方法可以细分为基于编码层共享方法、基于解码层共享方法和基于编、解码层同时共享方法 3 种,使用这 3 种方法分别拟合读者、写者情绪标注文本的情

绪分值。

基于多任务学习的情绪分值回归方法的性能如表 2 所示。可以看出,无论选择何种共享机制,基于多任务学习的方法始终优于本文的基准方法(LSTM 单任务方法),并且也优于 RCL 单任务方法,从而验证了本文所提出的多任务学习方法的有效性。显著性检验结果表明,本文的多任务学习方法相对于基准方法的改进效果是显著的($P < 0.05$)。

表 2 基于多任务学习的情绪分值回归方法的性能

Table 2 Performances of multi-task learning approaches to emotion regression

| 情绪 | 方法 | 唤醒度分值 | | 可控度分值 | | 极性程度分值 | |
|------|-----------|---------|---------|---------|---------|---------|---------|
| | | r | MSE | r | MSE | r | MSE |
| 读者情绪 | LSTM(单任务) | 0.318 1 | 0.102 5 | 0.163 5 | 0.083 8 | 0.536 9 | 0.132 6 |
| | 编码层共享 | 0.345 7 | 0.100 0 | 0.231 7 | 0.079 0 | 0.575 9 | 0.124 5 |
| | 解码层共享 | 0.341 5 | 0.100 4 | 0.200 2 | 0.079 9 | 0.557 3 | 0.129 0 |
| | 编、解码层共享 | 0.347 9 | 0.100 2 | 0.234 6 | 0.078 9 | 0.577 7 | 0.124 3 |
| 写者情绪 | LSTM(单任务) | 0.231 0 | 0.092 6 | 0.107 5 | 0.067 6 | 0.481 4 | 0.091 2 |
| | 编码层共享 | 0.244 9 | 0.092 6 | 0.132 2 | 0.067 1 | 0.498 3 | 0.089 5 |
| | 解码层共享 | 0.251 5 | 0.092 4 | 0.131 8 | 0.067 2 | 0.474 0 | 0.092 0 |
| | 编、解码层共享 | 0.252 1 | 0.092 5 | 0.159 5 | 0.066 8 | 0.500 5 | 0.089 6 |

此外,本文的多任务学习方法在所有领域(语料融合了 6 个领域)的表现均比单任务学习方法更佳,其中编、解码层同时共享的多任务学习方法表现最佳。显著性检验结果表明,编、解码层同时共享的方法相对于仅共享编码层或仅共享解码层的方法,改进效果是显著的($P < 0.05$)。

为了更好地理解多任务学习方法的有效性,对结果文件进行了分析,发现基准方法拟合出的结果往往会超过情绪分值的最大值,而使用多任务学习方法时,正向分值受到逆向分值的影响,结果均小于情绪分值的最大值。

4 结论

本文提出了一种基于多任务学习的正逆向情绪分值回归方法,对 EmoBank 语料库中情绪的三维分值进行拟合。针对每种分值设计正向和逆向 2 种打分方式,利用多任务学习方法联合学习正向打分的情绪回归主任务和逆向打分的情绪回归辅助任务,在多任务学习中通过 3 种不同的共享机制实现中间特征信息共享。实验结果表明,这种基于多任务学习的方法比单任务学习的方法效果更佳;在多任务学习方法中,基于编、解码层同时共享的方法比仅基于编码层或解码层的方法获得了更好的回归性能。在未来的研究工作中,将考虑在编码层中尝试一些新的模型,以及探索语料库中读者和写者情绪之间的一些关联性,扩大多任务学习的范围,以进一步提高回归性能。

参考文献:

- [1] BUECHEL S, HAHN U. EmoBank: studying the impact of annotation perspective and representation format on dimensional emotion analysis[C]//Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics. Valencia, 2017: 578-585.
- [2] STRAPPARAVA C, MIHALCEA R. SemEval-2007 task 14: affective text[C]//Proceedings of the 4th International Workshop on Semantic Evaluations. Prague, 2007: 70-74.
- [3] EKMAN P. An argument for basic emotions[J]. Cognition and emotion, 1992, 6(3/4): 169-200.
- [4] STRAPPARAVA C. Emotions and NLP: future directions[C]//Proceedings of the 7th Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis. San Diego, 2016: 180-187.
- [5] RUSSELL J A, MEHRABIAN A. Evidence for a three-factor theory of emotions[J]. Journal of research in personality, 1977, 11(3): 273-294.
- [6] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural computation, 1997, 9(8): 1735-1780.

- [7] KRIZHEVSKY A , SUTSKEVER I , HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM , 2017 , 60(6) : 84–90.
- [8] YU L , LEE L , HAO S , et al. Building Chinese affective resources in valence–arousal dimensions [C] // Proceedings of the 15th Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. San Diego , 2016: 540–545.
- [9] PREOTIUC-PIETRO D , SCHWARTZ H A , PARK G , et al. Modelling valence and arousal in facebook posts [C] // Proceedings of the 7th Workshop on Computational Approaches to Subjectivity , Sentiment and Social Media Analysis. San Diego , 2016: 9–15.
- [10] WANG J , YU L , LAI K R , et al. Dimensional sentiment analysis using a regional CNN–LSTM model [C] // Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics. Berlin , 2016: 225–230.
- [11] XIA R , LIU Y. A multi–task learning framework for emotion recognition using 2D continuous space [J]. IEEE transactions on affective computing , 2017 , 8(1) : 3–14.
- [12] BALIKAS G , MOURA S , AMINI M. Multitask learning for fine–grained twitter sentiment analysis [C] // Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. Shinjuku , 2017: 1005–1008.
- [13] SMOLA A J , SCHÖLKOPF B. A tutorial on support vector regression [J]. Statistics and computing , 2004 , 14(3) : 199–222.

Emotion Regression Approach with Both Forward and Reverse Values Based on Multi-task Learning

GAO Xiaoya¹ , LEE Sophia Yat Mei² , ZHANG Lu¹ , LI Shoushan¹

(1. School of Computer Science and Technology , Soochow University , Suzhou 215006 , China;

2. Department of Chinese & Bilingual Studies , Hong Kong Polytechnic University , Hongkong 999077 , China)

Abstract: An emotion values regression approach based on multi-task learning was proposed. Firstly , forward score and reverse score were designed for each dimension of emotion. Secondly , the regression task was divided into the forward score regression subtask and the reverse score regression subtask. Finally , a multi-task learning approach was proposed to jointly learn both the main task (forward score regression subtask) and the auxiliary task (reverse score regression subtask) . In order to improve the performance of the main task , three sharing models were designed to share different kinds of information between the main and auxiliary tasks. The results showed that the proposed multi-task learning method achieved better regression performance than the baseline.

Key words: emotion regression; multi-task learning; forward and reverse value; LSTM

(责任编辑: 孔 薇)