

基于十字绣单元与多任务学习的人格预测方法

王春东^{1,2,3}, 韩璐^{1,2,3}, 林浩^{1,2,3}

(1. 天津理工大学 计算机科学与工程学院; 2. 天津理工大学 计算机病毒防治技术国家工程实验室;
3. 天津理工大学 智能计算及软件新技术天津市重点实验室, 天津 300384)

摘要: 人格特征反映了人类在行为、思维和情感等方面表现出来的特点,在各行各业都有着极大的应用价值。但是目前人格预测领域的数据集数量较少,传统单任务人格预测方法达到的效果有限,而多任务学习方法可通过基于不同数据集的任务之间的数据交流,充分利用数据集信息。因此,提出一个基于十字绣单元和不确定性的层次多任务学习方法。通过BERT、混合神经网络和注意力提取特定任务特征,利用十字绣单元进行任务间的数据交流,并使用不确定性平衡两个任务间的权重,并且确保模型不会出现过拟合。在Essays数据集和Kaggle_mbt数据集上的实验结果表明,该模型在Essays数据集上的准确率和F1值分别达到了84.23%、84.76%,在Kaggle_mbt数据集上的准确率和F1值分别达到了82.18%、86.13%,说明该模型的性能优于目前最新的方法。

关键词: 人格预测;十字绣单元;多任务学习;不确定性;层次注意力结构;深度学习

DOI: 10.11907/rj.241916

扫描二维码阅读全文:

中图分类号: TP183

文献标识码: A

文章编号: 1672-7800(2026)002-0058-07



A Personality Prediction Approach Based on Cross-stitch Unit and Multi-Task Learning

WANG Chundong^{1,2,3}, HAN Lu^{1,2,3}, LIN Hao^{1,2,3}

(1. School of Computer Science and Engineering, Tianjin University of Technology; 2. National Engineering Laboratory for Computer Virus Prevention and Control Technology, Tianjin University of Technology; 3. Tianjin Key Laboratory of Intelligence Computing and Novel Software Technology, Tianjin University of Technology, Tianjin 300384, China)

Abstract: Personality traits reflect the characteristics that human beings exhibit in terms of behaviour, thinking and emotions. They have great application value in various industries. However, the number of datasets in the field of personality prediction is relatively small at present. Furthermore, traditional single-task personality prediction methods achieve limited results. In contrast, multi-task learning methods can make full use of dataset information through data exchange between tasks based on different datasets. In light of the aforementioned limitations, this paper proposes a hierarchical multi-task learning method based on cross stitch networks and uncertainty. This method involves extracting task-specific features through BERT, hybrid neural networks and attention, utilising cross stitch networks for data exchange between tasks, and employing uncertainty to balance the weights between the two tasks and to prevent overfitting. The experiments conducted on the Essays dataset and the Kaggle_mbt dataset demonstrate that the proposed model attains an accuracy and F1 score of 84.23% and 84.76%, respectively, on the Essays dataset and an accuracy and F1 score of 82.18% and 86.13%, respectively, on the Kaggle_mbt dataset, which evinces a commendable state-of-the-art performance.

Key Words: personality prediction; cross-stitch units; multi-task learning; uncertainty; hierarchical attention mechanism; deep learning

0 引言

人格特征是指人类个体在行为、思维和情感方面表现

出来的特点,是一种可以说明人的行为多样性的心理构造。目前人格预测领域数据集稀缺,传统单任务人格预测方法可利用的数据有限,难以准确判断人格倾向。多任务学习方法能够同时利用多个相关任务的信息,任务之间相

收稿日期: 2024-12-03

基金项目: 国家重点研发计划项目(2023YFB2703900)

作者简介: 王春东(1969-),男,博士,CCF会员,天津理工大学计算机科学与工程学院教授、博士生导师,研究方向为网络信息安全、智能计算、区块链等;韩璐(2000-),女,天津理工大学计算机科学与工程学院硕士研究生,研究方向为人格识别、网络安全等;林浩(1995-),男,天津理工大学计算机科学与工程学院博士研究生,研究方向为人格识别、网络安全、数据挖掘等。本文通讯作者: 王春东。

互交流补充,从而充分发挥有限数据的最大作用。但在人格预测领域,目前只有少数方法可以同时预测多个人格体系,且这些方法对数据集的要求极高。而目前人格预测领域多数数据集只包含一个人格体系,如果要使用来自多个数据源的任务进行多任务学习,目前的方法尚无法实现。

同时,多任务学习的结果严重依赖不同任务之间的相对权重,但是手动调节权重的成本很高,这也是多任务学习难以在人格预测领域得到大量实践的原因。

针对上述问题,本文提出一种基于不确定性和十字绣单元的层次多任务人格预测模型(Hierarchical Multi-tasking Personality Prediction Model Based on Uncertainty Theory and Cross-stitch Units, UCS),实现了使用不同数据源的多任务人格预测。该模型学习两个不同的人格体系特征,分别学习两个任务的特定特征和交叉特征。UCS模型通过预训练语言模型BERT(Bidirectional Encoder Representations from Transformers)和神经网络加强学习任务特定特征的能力,又通过十字绣单元共享特征,学习交叉特征,促进两个任务相互学习。最后,模型使用不确定性构建损失函数,平衡两个任务,避免出现过拟合。本文的主要贡献如下:

(1)针对人格预测领域数据集稀少的问题,提出使用不同数据源进行层次多任务人格预测的方法。该方法充分利用多个数据源的数据,通过十字绣单元融合了数据信息,同时通过层次模型捕捉更深层次的多任务人格信息。

(2)针对多任务模型任务权重调节困难的问题,利用均方差不确定性构建损失函数以自动调节任务权重,使两个任务达到平衡。

(3)在真实数据集上的实验结果证明,UCS模型的结果优于目前最先进的模型。

1 相关工作

人格在社会科学应用中变得越来越重要。例如,Preo-tiuc-Pietro等^[1]发现利用人格特征可以很好地预测抑郁症和创伤后应激障碍(Post-Traumatic Stress Disorder, PTSD)的发生概率;Anglim等^[2]发现人格特征与智力有着高相关性。同时,人格在情感分析和欺诈检测中也是一个重要影响因素^[3-4]。

人格预测最初采用心理测试量表和特征提取等方法,但是这类方法的效果有限。之后,随着深度学习的发展,研究人员通过使用CNN和LSTM等神经网络进行特征提取,证实了深度学习方法的有效性^[5-7]。但是深度学习方法的效果仍然有限。为此,Mehta等^[8]在Essays和Kaggle_mbtI数据集上使用了两个预训练BERT模型(BERT-base和BERT-large),Christian等^[9]利用BERT、RoBERTa和XLNet 3个模型的平均值进行预测,El-Demerdash等^[10]采用Elmo、ULMFit和BERT模型融合的方法。以上方法都

证明了预训练语言模型相较于神经网络更为有效。

近年来,研究人员发现,来源于文档分类的分层注意力模型对人格预测是有效的。Lynn等^[11]的研究表明,使用双层基于消息的方法相比单层基于单词的方法更有效。Zhou等^[12]同样使用分层注意力网络,结合表情符号信息,基于用户生成内容进行预测,证实了分层注意力网络的有效性。

Elourajini等^[13]利用预训练的Electra模型,通过多任务学习方法同时预测大五人格特质和MBTI,预测效果得到了明显提升,证明了多任务学习对人格预测的有效性。但是该方法是基于一个包含多人格的数据集进行的,而目前人格预测数据集多数只包含一个人格体系。因此,本文将设计一个层次多任务人格预测方法,使模型能够在两个数据集上进行操作。

2 模型结构

UCS模型主要由多任务模型框架和损失函数两部分组成,图1为模型整体架构。该模型通过特征提取层和信息共享层提取对应的人格特征,并且构建基于同方差不确定性的损失函数来平衡两个任务,以获得最佳结果。




Fig. 1 Overall framework of the model

图1 模型整体架构

模型使用两个特征提取层构建层次注意力提取用户特征,信息共享层进行两个任务的特征共享,人格预测层进行人格标签分类。

2.1 多任务模型框架

2.1.1 特征提取

特征提取部分采用层次注意力结构,第一层使用BERT模型提取句子级特征,第二层使用混合神经网络和

注意力提取用户级特征。

第一层特征提取中的 BERT 是一个预训练语言模型,用于自然语言处理,其使用多头注意力的双向变换器结构^[14]。在 UCS 模型中,BERT 的注意力机制被视为单词级注意力,可提取句子级特征。输入句子经 BERT 处理后,每个单词生成词嵌入,之后通过线性变换得到查询(Q)、键(K)和值(V)向量,用于计算注意力分数并捕捉单词间关系。具体如公式(1)所示:

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1)$$

其中, d_k 表示查询和键的维度大小。BERT 通过多个隐藏层处理后,最终输出[CLS]标记的隐藏状态作为句子的语义表示,其中包含丰富的语法、语义和上下文特征。

混合神经网络结构如图 2 所示。其中,左边通过 Bi-GRU 和注意力提取上下文特征,右边通过 textCNN 和注意力提取局部特征。




Fig. 2 Hybrid neural network structure

图 2 混合神经网络结构

如图 2 所示,在第二层的特征提取中,混合神经网络由双向门控循环单元(Bidirectional Gated Recurrent Unit, Bi-GRU)和文本卷积网络(Text Convolutional Network, textCNN)组成,Bi-GRU 用于提取上下文特征,textCNN 用于提取局部静态特征。将两个神经网络的结果分别输入注意力机制中,以突出关键信息,最后将其连接获得用户级表示。

Bi-GRU 由两个方向相反的单向 GRU 层组成,可同时利用输入序列的前向和后向信息。通过连接前向和后向隐藏层的输出,汇总上下文信息,其输出如公式(2)所示:

$$H_i = [\overrightarrow{GRU} \oplus \overleftarrow{GRU}] \quad (2)$$

对于给定的句子序列矩阵 s ,textCNN 通过不同卷积核的卷积操作实现特征提取,如公式(3)所示:

$$p = \text{textCNN}(s) \quad (3)$$

UCS 模型使用注意力机制突出对预测用户人格更关键的句子级表示,如图 2 所示。以 Bi-GRU 为例, $H = [H_1, H_2, H_3, \dots, H_i]$ 表示注意力层的输入, y 表示注意力层的输出。具体计算公式如下:

$$M = \tanh(H) \quad (4)$$

$$\beta = \text{softmax}(w^T M) \quad (5)$$

$$A = H\beta^T \quad (6)$$

其中, $\beta = [\beta_1, \beta_2, \beta_3, \dots, \beta_n]$ 是注意力权重,代表每个句子级表示在用户级表示中的重要性。

2.1.2 信息共享

该层用于在大五人格分类任务和 MBTI 分类任务之间进行信息共享,互相补充信息,以帮助模型更好地理解人格特征,提高性能。

该部分采用十字绣单元进行不同任务之间的连接。在十字绣单元中有一个参数 α ,该参数被用来调节各个方向的信息流。十字绣单元结构如图 3 所示。




Fig. 3 Cross-stitch unit structure

图 3 十字绣单元结构

大五分类采用 A_b 作为特征表示,MBTI 分类采用 A_m 作为特征表示。信息共享计算公式如下:

$$F_b = \alpha_{bb} A_b + \alpha_{mb} A_m \quad (7)$$

$$F_m = \alpha_{mm} A_m + \alpha_{bm} A_b \quad (8)$$

在初始化时, $\alpha_{bb} = \alpha_{mm} = 0.9, \alpha_{bm} = \alpha_{mb} = 0.1$,其在训练过程中会被不断优化。UCS 模型分别在第一层 BERT 提取句子级特征和第二层提取用户特征后使用了十字绣单元,使信息共享更完整。

2.2 多任务损失函数

多任务学习在设计损失函数时,常见方法是对每个任务的损失函数进行加权线性求和,如公式(9)所示:

$$Loss_{total} = \sum W_i L_i \quad (9)$$

多数任务对权重比较敏感,很难找到最佳权重。同时,设置权重时每次调整权重的成本较高,需要花费大量时间。因此,需要一个能够自动调优并确定最佳权重的损失函数。

受 Kendall 等^[15]的研究启发,本文采用同方差不确定性作为学习多任务损失函数的基础。设 $f^W(x)$ 是输入为 x 、权重为 W 的神经网络的输出,因为两个分类任务均采用二分类方法,所以使用 *sigmoid* 函数将输出转化为概率值,如公式(10)所示:

$$p(y|f^W(x)) = \text{sigmoid}(f^W(x)) \quad (10)$$

在多任务学习中,由于有多个模型输出,通常通过因式分解输出得到最终结果,如公式(11)所示:

$$p(y_1, y_2 | f^W(x)) = p(y_1 | f^W(x)) \cdot p(y_2 | f^W(x)) \quad (11)$$

其中, y_1, y_2 分别是 大五人格分类和 MBTI 人格分类任务的输出。

在本文的分类任务中,通过 *sigmoid* 函数调整分类似然来压缩模型输出的缩放版本,如公式(12)所示:

$$p(y|f^W(x), \sigma) = \text{sigmoid}\left(\frac{1}{\sigma^2} f^W(x)\right) \quad (12)$$

其中,有一个值为正的标量 σ ,该参数的大小决定了

离散分布的均匀程度。这与其具备的不确定性有关,不确定性用熵来衡量。该输出的对数似然如公式(13)所示:

$$\log p(y = 0|f^w(x), \sigma) = -\frac{1}{\sigma^2} f^w(x) - \log\left(1 + \exp\left(-\frac{1}{\sigma^2} f^w(x)\right)\right) \quad (13)$$

输出模型的最小化目标也即模型的损失函数如公式(14)所示:

$$\begin{aligned} L(W, \sigma_1, \sigma_2) &= -\log p(y_1 = 0, y_2 = 0|f^w(x)) \\ &= \frac{1}{\sigma_1^2} f^w(x) + \log\left(1 + \exp\left(-\frac{1}{\sigma_1^2} f^w(x)\right)\right) \\ &\quad + \frac{1}{\sigma_2^2} f^w(x) + \log\left(1 + \exp\left(-\frac{1}{\sigma_2^2} f^w(x)\right)\right) \end{aligned} \quad (14)$$

其中, $L_1(W) = f^w(x) + \log(1 + \exp(-f^w(x)))$ 表示 y_1 的二进制交叉损失熵。 $L_2(W)$ 和 $L_1(W)$ 相同。因此,进一步推导可得损失函数,如公式(15)所示:

$$\begin{aligned} L(W, \sigma_1, \sigma_2) &= \frac{1}{\sigma_1^2} L_1(W) + \log \frac{1 + \exp\left(-\frac{1}{\sigma_1^2} f^w(x)\right)}{(1 + \exp(-f^w(x)))^{\frac{1}{\sigma_1^2}}} \\ &\quad + \frac{1}{\sigma_2^2} L_2(W) + \log \frac{1 + \exp\left(-\frac{1}{\sigma_2^2} f^w(x)\right)}{(1 + \exp(-f^w(x)))^{\frac{1}{\sigma_2^2}}} \end{aligned} \quad (15)$$

接下来对 W 以及 σ_1, σ_2 进行优化,此处引入显式简化假设,即 $\frac{1}{\sigma_1} (1 + \exp(-\frac{1}{\sigma_1^2} f^w(x))) \approx (1 + \exp(-f^w(x)))^{\frac{1}{\sigma_1^2}}$ 。当 $\sigma_1 \rightarrow 1$ 时,两个式子相等。 σ_2 的优化与 σ_1 相同,优化后的结果如公式(16)所示:

$$L(W, \sigma_1, \sigma_2) \approx \frac{1}{\sigma_1^2} L_1(W) + \frac{1}{\sigma_2^2} L_2(W) + \log \sigma_1 + \log \sigma_2 \quad (16)$$

由公式(16)可以发现,该公式在学习 L_1 和 L_2 的相对权重。随着参数 σ 的增大,权重减小。参数 σ 的大小是由等式的最后一项决定的。当设置的参数 σ 过大时,目标会受到惩罚。

在真实的实验中,UCS模型预测对数方差 $s: = \log \sigma^2$,其在数值上比回归方差(σ^2)更稳定,避免了任何除以零的情况。

3 实验与结果分析

3.1 数据集介绍

本文共使用了两个数据集,分别是 Essays 和 Kaggle_mbti 数据集。Essays 数据集是只包含大五人格标签的数据集,其是人格测试领域的黄金标准。该数据集由 2 468 个学生的论文组成,这些学生通过填写测试量表确定了自己的大五人格特征。

Kaggle_mbti 数据集是在 PersonalityCafe 论坛收集的,其收集了 8 000 余名用户在论坛上发表的推文,所有用户都通过自测量表测试了 MBTI 人格。该数据集包含了每个用户最新发布的 50 条信息。

3.2 实验设置

首先,对 Essays 数据集进行过采样,使两个数据集的数据量保持一致。其次,两个数据集分别进行大写字母小写化、删除符号数字等操作。最后,计算每个句子单词数的平均数 M 和每个用户的句子数 N ,并对数据进行划分。将数量多于 M 和 N 的部分删除,不足的部分用 [PAD] 填充。

在训练过程中,实验将 80% 的数据作为训练集,20% 的数据作为测试集。同时,对训练集 80% 的数据进行训练,20% 的数据进行验证。BERT 的特征为 768 维, Bi-GRU 和 textCNN 的隐藏层大小为 512。模型使用 Adam 进行调优,设置学习率为 $2e-7$,损失函数为 BCE, batch-size 为 64。模型在 A40 显卡上的训练时间约为 30 min,在 Geforce RTX4060 显卡上的训练时间约为 1.5 h。

本文的评价指标使用最常用的准确率 (Accuracy) 和 F1-score。准确率直观衡量了模型的整体表现, F1-score 则是统计学中用来衡量二分类模型精确率的指标。

3.3 对比实验

为了验证本文方法的有效性,将本文方法与目前最新的方法进行对比。包括:

BERT: 该方法使用 BERT-base 和 BERT-large 两个模型分别提取特征^[8]。

RoBERT: 该方法使用 BoBERT 提取特征,分别在两个数据集上进行实验^[16]。

BERT-fusion: 该方法使用 Elmo、ULMFiT 和 BERT 3 种模型融合来提取特征^[10]。

CNN-AdaBoost: 该方法使用不同滤波器的 CNN 提取特征,然后将特征放到 AdaBoost 模型中进行分类^[17]。

LSTM-RMSprop: 该方法使用基于 RMSprop 优化器的 LSTM 模型来提取特征^[18]。

Transformer-MD: 该方法是一个多文档 Transformer 模型,该模型提出维度注意力机制,用于获得多特质人格检测的特质特异性表示^[19]。

IDGWOFs: 该方法使用改进的分布式灰狼优化算法对特征进行筛选^[20]。

实验结果如表 1、表 2 所示。从表中可以看到,UCS 模型在大五分类任务上的性能得到了显著提高。与目前最新的方法相比,UCS 的准确率最多提升了 13.01%, 平均提升了 9.15%, F1-score 平均提升了 15.11%。在 Kaggle_mbti 数据集上,UCS 在 I/E (Introversion/Extroversion)、N/S (Intuition/Sensing) 两个维度的结果得到了提升。其中,准确率分别提升了 0.54% 和 0.61%, F1-score 则分别提升了 9.74% 和 6.57%。

Table 1 Results of big five personality classification experiment on Essays dataset**表1 Essays数据集上大五人格分类实验结果**

(%)

模型	Accuracy						F1					
	EXT	NEU	AGR	CON	OPN	Average	EXT	NEU	AGR	CON	OPN	Average
BERT	60.00	60.50	58.80	59.20	64.60	60.62	58.00	56.21	56.14	57.03	58.20	57.12
RoBERT	60.62	61.07	59.72	58.55	65.86	61.16	58.40	56.37	56.87	56.20	59.00	57.37
CNN-AdaBoost	61.85	62.08	59.92	64.93	60.56	61.87	60.80	61.40	60.20	64.20	60.70	61.46
BERT-fusion	61.15	62.20	60.80	59.52	65.60	61.85	61.03	59.50	58.37	59.45	61.78	60.02
IDGWOFs	75.97	71.74	73.17	76.77	77.74	75.07	69.79	67.89	69.84	70.90	69.86	69.65
UCS	84.65	84.75	84.45	83.05	84.25	84.23	84.31	85.36	84.67	84.34	85.64	84.76

Table 2 Results of MBTI classification experiment results on Kaggle dataset**表2 Kaggle数据集上MBTI分类实验结果**

(%)

模型	Accuracy					F1				
	I/E	N/S	T/F	P/J	Average	I/E	N/S	T/F	P/J	Average
LSTM-RMSprop	77.35	86.34	72.85	66.28	75.71	61.24	67.68	68.21	58.79	63.98
BERT	78.80	86.30	76.10	67.20	77.10	68.05	79.35	66.10	55.73	67.31
RoBERT	77.73	86.42	73.71	63.24	75.28	58.33	53.88	69.36	60.88	60.61
Transformer-MD	76.69	86.45	78.21	67.98	77.33	66.08	69.10	79.19	67.50	70.47
UCS	77.23	87.06	73.82	62.49	75.15	86.43	93.02	73.07	70.83	80.85

3.4 消融实验

本文针对UCS模型进行消融实验,结果如表3、表4所示。其中,w/o表示删除某个部件。

首先,验证了混合神经网络的有效性。分别删除Bi-GRU和textCNN后可以观察到,无论删除哪一部分,模型性能均不如完整的混合神经网络,说明Bi-GRU与textCNN结合能够更好地提升分类效果。

其次,验证了双层信息共享的必要性。使用FCN(First-Cross-stitch unit-Network)表示第一层使用十字绣

单元,SCN(Second-Cross-stitch unit-Network)表示第二层使用十字绣单元。从实验结果可以看出,单独在第一层或第二层进行信息共享的效果不佳,在第一层的效果最差。而两层均共享信息时,任务间的信息交互更充分,效果最好。

最后,验证了多任务学习方法的有效性。结果显示,无论是单独的MBTI分类任务还是大五人格分类任务,其性能均不如UCS模型。说明多任务学习丰富了任务特征,促进了模型性能的提升。

Table 3 Results of the big five personality classification ablation experiment**表3 大五人格分类消融实验结果**

(%)

模型	Accuracy						F1					
	EXT	NEU	AGR	CON	OPN	average	EXT	NEU	AGR	CON	OPN	average
UCS	84.65	84.75	84.45	83.05	84.25	84.23	84.31	85.36	84.67	84.34	85.64	84.76
w/o textCNN	82.75	78.54	81.04	82.15	85.26	81.95	82.41	80.29	81.84	83.52	86.33	82.88
w/o Bi-GRU	58.48	56.17	55.87	57.47	59.38	57.47	60.19	64.38	61.47	63.00	63.61	62.53
w/o SCN	82.95	72.42	72.52	71.31	81.04	76.05	83.17	76.60	76.01	73.57	80.66	78.00
w/o FCN	83.85	84.75	83.25	83.35	85.26	84.09	83.32	85.47	83.61	84.99	86.09	84.70
MBTI分类	-	-	-	-	-	-	-	-	-	-	-	-
大五分类	55.56	59.40	54.27	58.55	61.54	57.86	52.29	64.42	58.04	59.41	66.91	60.22

Table 4 Results of MBTI classification ablation experiments**表4 MBTI分类消融实验结果**

(%)

模型	Accuracy					F1				
	I/E	N/S	T/F	P/J	Average	I/E	N/S	T/F	P/J	Average
UCS	77.23	87.06	73.82	62.49	75.15	86.43	93.02	73.07	70.83	80.85
w/o textCNN	75.33	86.96	73.22	60.68	74.05	85.29	93.03	72.56	66.61	79.37
w/o Bi-GRU	74.12	87.06	76.53	61.38	74.77	84.27	93.08	76.36	73.10	81.70
w/o SCN	75.43	86.86	69.81	51.86	70.99	85.90	92.95	63.52	39.85	70.55
w/o FCN	75.03	86.96	73.42	57.07	73.12	85.22	93.03	72.25	63.23	78.43
MBTI分类	76.03	87.06	74.22	62.59	74.97	85.93	93.08	70.96	71.72	80.42
大五分类	-	-	-	-	-	-	-	-	-	-

3.5 权重比较

该部分验证了基于不确定性的损失函数的可行性,将该方法与多任务学习方法中的常见损失函数构造方法进

行对比。常见损失函数构造方法如公式(17)所示:

$$Loss = \alpha * Loss_{bigfive} + (1 - \alpha) * Loss_{mbti} \quad (17)$$

其中, α 表示大五分类任务的权重,范围为 $\{0.1 \cdots 0.9\}$,

结果如图 4 所示。

从图 4 可以看出, 公式 (17) 中的权重变化导致两个分类任务的结果出现较大震荡。相比之下, 采用不确定性自动调节的结果整体表现最佳, 说明手动调节虽能优化单个

任务, 但难以平衡整体性能。

总体而言, 采用同方差不确定性的多任务方法综合考虑两个任务来调节权重, 可对两个任务进行平衡, 使其得到整体最佳的结果。




Fig. 4 Comparison of results with different weight

图 4 不同权重结果比较

3.6 注意力可视化分析

为了更清晰地展示注意力机制的实现过程, 对注意力权重进行了可视化处理, 如图 5 所示。其中, 第二列表示句子级注意力权重, 第三列表示单词级注意力权重, 颜色深浅反映了权重大小。从图中可以观察到, 具有 OPN (Openness) 特质的人更倾向于使用哲学类词汇 (如 economics 和 material), 而具有 AGR (Agreeableness) 特质的人

更偏好使用包含脏话的词汇 (如 damn)。通过这一直观的可视化可以发现, 注意力机制能够有效地突出与人格特征更相关的单词和句子, 从而引导模型更关注与人格预测密切相关的内容。

3.7 模型验证

考虑到 UCS 中 MBTI 的分类结果一般, 为了验证本文方法对 MBTI 分类任务的有效性, 本文又构造了一个单层多任务学习模型。该模型在 UCS 的基础上删除混合神经网络, 使用 BERT 提取特征, 通过十字绣单元进行信息共享, 同时利用均方差不确定性构造损失函数。单层模型和 UCS 模型的 MBTI 分类结果对比如表 5 所示。

从表中可以看到, 相较于 UCS, 单层模型中 MBTI 分类结果得到了明显提升, 准确率提升了 7.03%, F1 分数提升



Fig. 5 Attention weights visualization

图 5 注意力权重可视化

Table 5 Comparison of MBTI classification results on the Kaggle dataset

特征	UCS		Single structure	
	Accuracy	F1	Accuracy	F1
I/E	77.23	86.43	82.42	89.41
N/S	87.06	93.02	89.74	94.22
T/F	73.82	73.07	80.23	78.89
P/J	62.49	70.83	76.31	81.98
Average	75.15	80.85	82.18	86.13

了 5.28%, 进一步说明了本文采用的数据共享方法和使用不确定性构造多任务损失函数方法的有效性。

3.8 泛化能力实验

为了全面评估模型的泛化能力, 采用五折交叉验证方式, 并将实验中的最佳结果作为最终的实验结果。具体数值如表 6 所示。

从实验结果来看, 尽管引入了交叉验证, 模型的性能依然保持在较高水平。这表明模型在不同数据划分条件下依然表现稳健, 进一步验证了其优越的泛化能力。

Table 6 Five-fold cross-validation comparison

表 6 五折交叉验证对比 (%)

人格体系	UCS		Five-fold	
	Accuracy	F1	Accuracy	F1
大五人格	84.23	84.75	83.90	84.60
MBTI	75.15	80.85	74.83	80.71

4 结语

本文提出基于不确定性和十字绣单元的多任务人格预测方法。该模型使用 BERT、混合神经网络和注意力机制深入提取用户特征, 并使用十字绣单元进行信息共享, 基于不确定性构造损失函数。最终的实验结果证明了本文提出的 UCS 模型的有效性。

UCS 模型验证了多任务人格预测在整合不同数据源方面的有效性, 但其仍面临一些亟待解决的问题。首先, 受到数据集稀缺的限制, 模型的验证深度和广度尚不足, 未来可以探索更高效的数据共享机制, 并积极构建多样化的人格数据集以支持进一步研究。此外, 现有数据集集中于大五人格和 MBTI 两种体系, 难以判断模型在其他人格类型上的适用性。随着新的人格体系数据的出现, 多任务预测的研究范围有望进一步拓展。同时, 研究当前仅在单一语言的数据集上展开, 缺乏多语言和跨领域的的支持, 模型的泛化能力尚需验证。最后, 实时跟踪个体人格变化是人格预测的最终目标, 但是隐私政策等限制使长期监测难以实现。随着技术与法规的不断进步, 这一目标有望成为现实, 人格预测研究将具有更广阔的前景。

参考文献:

- [1] PREOTIUC-PIETRO D, EICHSTAEDT J, PARK G, et al. The role of personality, age, and gender in tweeting about mental illness [C]//Proceedings of the 2nd Workshop on computational Linguistics and Clinical Psychology: From Linguistic Signal to Clinical Reality, 2015: 21-30.
- [2] ANGLIM J, DUNLOP P D, WEE S, et al. Personality and intelligence: a meta-analysis[J]. Psychological Bulletin, 2022, 148: 301-336.
- [3] LI Y, KAZEMEINI A, MEHTA Y, et al. Multitask learning for emotion and personality traits detection [J]. Neurocomputing, 2022, 493: 340-350.
- [4] AN G, LEVITAN S I, HIRSCHBERG J, et al. Deep personality recognition for deception detection [C]//19th Annual Conference of the International Speech Communication Association, Interspeech, 2018: 421-425.
- [5] MAJUMDER N, PORIA S, GELBUKH A, et al. Deep learning-based document modeling for personality detection from text [J]. IEEE Intelligent Systems, 2017, 32(2): 74-79.
- [6] ZHAO J, ZENG D, XIAO Y, et al. User personality prediction based on topic preference and sentiment analysis using LSTM model [J]. Pattern Recognition Letters, 2020, 138: 397-402.
- [7] KAMPMAN O, BAREZI E J, BERTERO D, et al. Investigating audio, visual, and text fusion methods for end-to-end automatic personality prediction [C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, 2018: 606-611.
- [8] MEHTA Y, FATEHI S, KAZAMEINI A, et al. Bottom-up and top-down: predicting personality with psycholinguistic and language model features [C]//2020 IEEE International Conference on Data Mining, 2020: 1184-1189.
- [9] CHRISTIAN H, SUHARTONO D, CHOWANDA A, et al. Text based personality prediction from multiple social media data sources using pre-trained language model and model averaging [J]. Journal of Big Data, 2021, 8(1): 68.
- [10] EL-DEMERDASH K, EL-KHORIBI R A, SHOMAN M A I, et al. Deep learning based fusion strategies for personality prediction [J]. Egyptian Informatics Journal, 2022, 23(1): 47-53.
- [11] LYNN V, BALASUBRAMANIAN N, SCHWARTZ H A. Hierarchical modeling for user personality prediction: the role of message-level attention [C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020: 5306-5316.
- [12] ZHOU L, ZHANG Z, ZHAO L, et al. Attention-based BiLSTM models for personality recognition from user-generated content [J]. Information Sciences, 2022, 596: 460-471.
- [13] ELOURAJINI F, AIMEUR E. AWS-EP: a multi-task prediction approach for MBTI/Big5 personality tests [C]//2022 IEEE International Conference on Data Mining Workshops, 2022: 1-8.
- [14] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 6000-6010.
- [15] KENDALL A, GAL Y, CIPOLLA R. Multi-task learning using uncertainty to weigh losses for scene geometry and semantics [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7482-7491.
- [16] JIANG H, ZHANG X, CHOI J D. Automatic text-based personality recognition on monologues and multiparty dialogues using attentive networks and contextual embeddings (student abstract) [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020: 13821-13822.
- [17] MOHADES D F, SADR H, TARKHAN M. Contextualized multidimensional personality recognition using combination of deep neural network and ensemble learning [J]. Neural Processing Letters, 2022, 54(5): 3811-3828.
- [18] MAULIDAH M, PARDEDE H F. Prediction of Myers-Briggs type indicator personality using long short-term memory [J]. Jurnal Elektronika Dan Telekomunikasi, 2021, 21(2): 104-111.
- [19] YANG F, QUAN X, YANG Y, et al. Multi-document transformer for personality detection [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2021: 14221-14229.
- [20] LIN H, WANG C, HAO Q. A novel personality detection method based on high-dimensional psycholinguistic features and improved distributed gray wolf optimizer for feature selection [J]. Information Processing & Management, 2023, 60(2): 103217.

(责任编辑: 黄健)