

Beijing Forest Studio
北京理工大学信息系统及安全对抗实验中心



Using Sentiment Representation Learning to Enhance Gender Classification for User Profiling

Classification for user profiling
learning to enhance gender

刘宇 硕士

2018年12月02日

- 背景简介
- 算法原理
 - 原理框架
 - 数据预处理
 - 情感表征学习
 - 性别分类
- 实验结果
- 参考文献

- 预期收获
 - 1. 了解用户画像的基本概念
 - 2. 理解情感表征学习
 - 3. 理解迁移学习的应用

- 用户画像

- 用户信息标签化，利用机器学习等技术预测用户的基本属性（如人口统计学属性、兴趣属性等）
- 使用高度精炼的特征对用户进行标签化
- 用户画像是互联网时代实现精准化服务、营销和推荐的必经之路，在网络安全、管理和运营等领域也具有重要意义

- 性别标签

- 性别是区分用户的一个重要属性
- 个性化推荐产品，过滤不符性别的产品
- 推荐特定性别的相关内容



- 情感分析
 - 情感分析多用于公开意见分析以及政治倾向分析等任务
 - 不同性别之间存在着情感差异
 - 在社交网络平台上，女性通常比男性表现的更加积极且情感更加丰富
 - 女性更喜欢展示好心情，男性则更倾向于平白直述
 - 女性比男性具有更大的情感跨度
- 通过融合情感表征来增强对用户画像中性别属性的构建

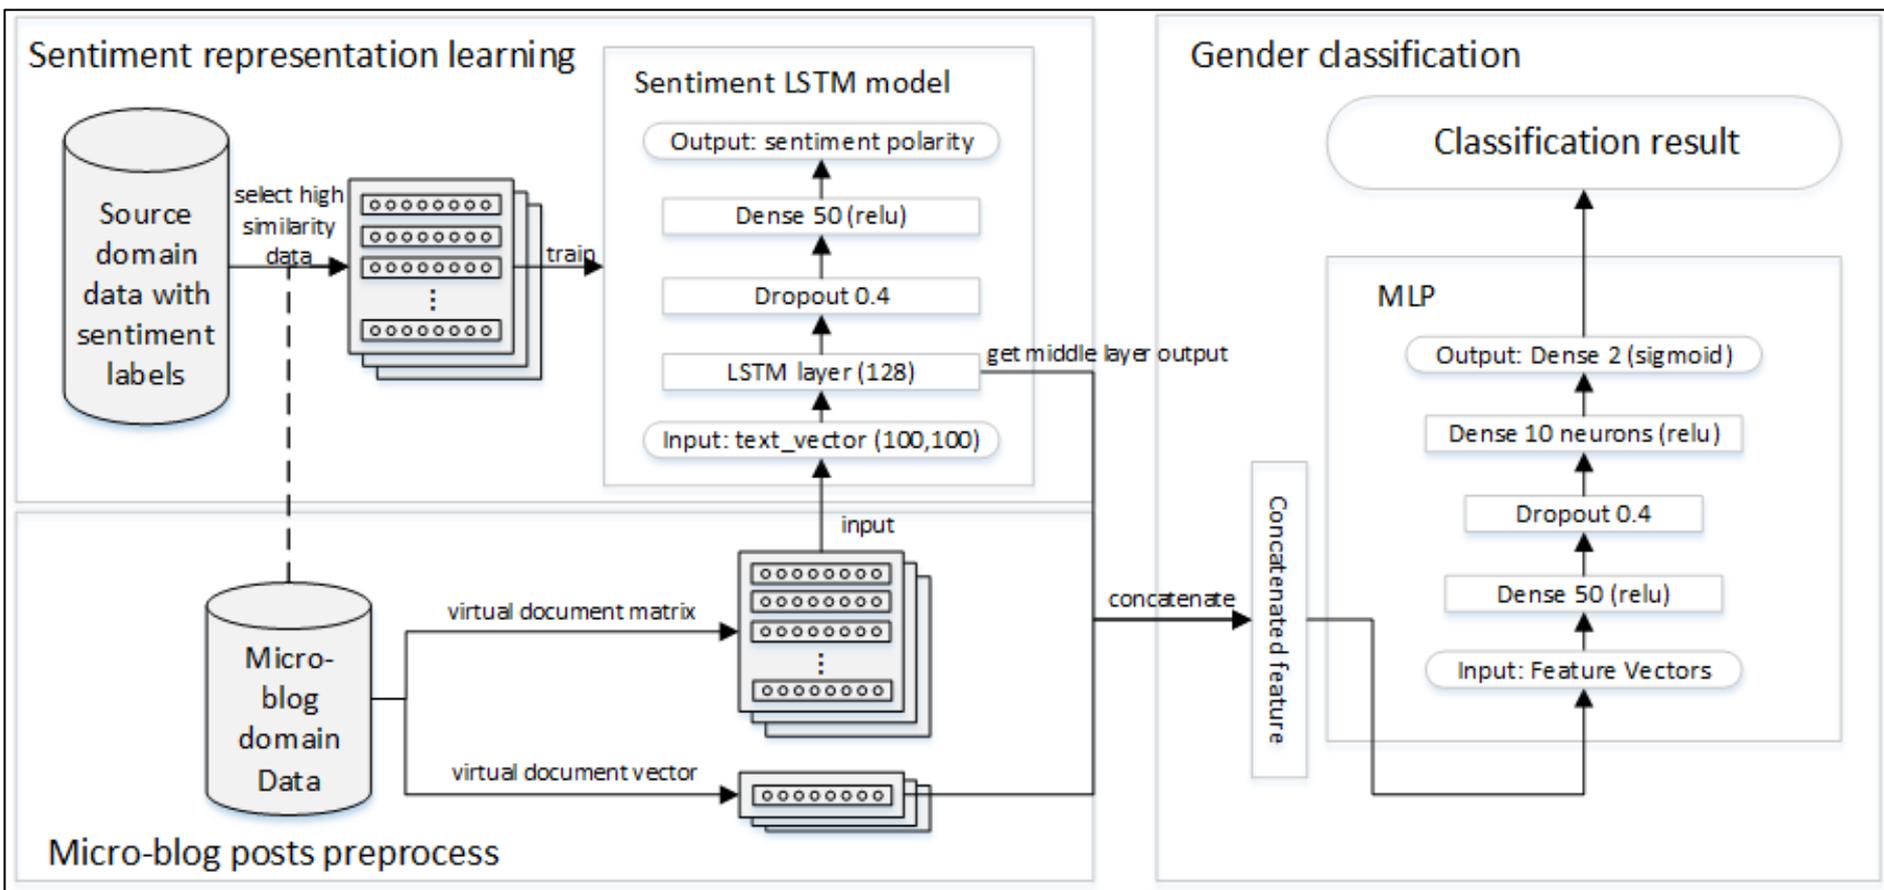




算法原理

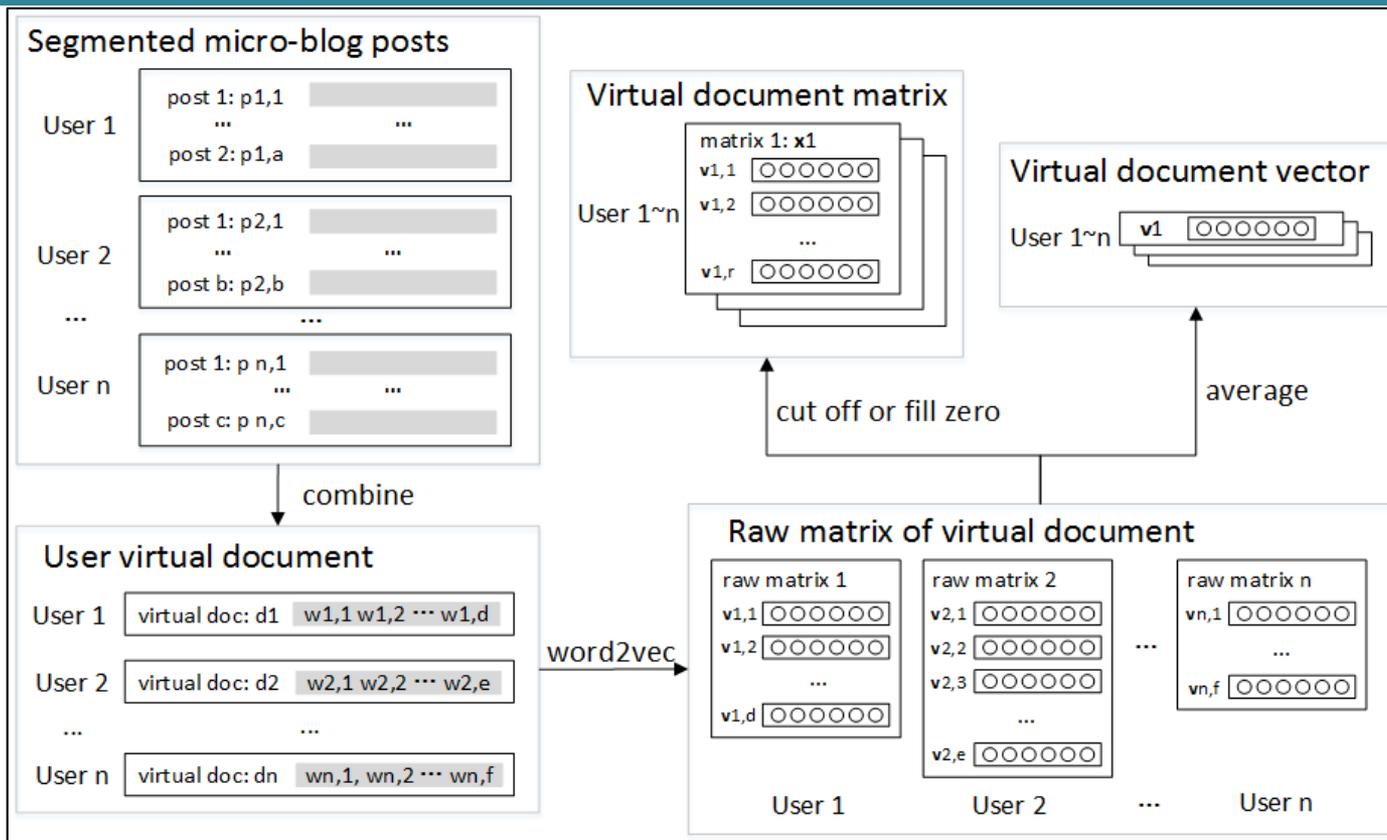
- 原理框架图

- 主要有三部分：数据预处理、情感表征学习、性别分类





- 每个用户的微博数量不同，每条微博的词数不同（上限140词），对于性别分类过短，同一用户的所有微博组合成一个虚拟文档，每个用户对应一个虚拟文档
- 文档表示
 - 虚拟文档矩阵
 - 虚拟文档向量



T	对微博语料进行预处理，使其符合后续模型的输入
I	用户的原始微博语料数据集
P	采用word2vec，将微博语料转换为向量
O	虚拟文档矩阵、虚拟文档向量



- 如何获得社交媒体数据中准确的情感标签？
 - 手工标记：成本高，不切实际
 - 迁移学习：利用与目标域数据相近的带标签源域数据构建一个情感表征模型，通过该模型得到目标域数据的情感标签
- 源域数据的选择
 - 商品评论通常具有短文本特性，且带有1~5星的打分可以用于表征用户情感（积极、消极）

- 提高源域与目标域数据的相似度

- 筛选源域数据中与目标域数据具有高相似度的数据，需要计算相似度

$$D_S \leftarrow \left\{ x_k, y_k \mid \frac{1}{n} \sum_{i=1}^n SIM(v_k, v_i) > z, z \in (0, 1) \right\}$$

- 将部分目标域数据进行手动标记，然后将其添加到源域数据

$$D_S \leftarrow \left\{ x_{mlt}, y_{mlt} \mid x_{mlt} \in D_t \right\}$$

- 情感表征

- 深度神经网络中特征是可迁移的
- 源域和目标域模型的参数是共享的
- 除了最终的情感极性结果，还可以将模型的中间层作为情感表征

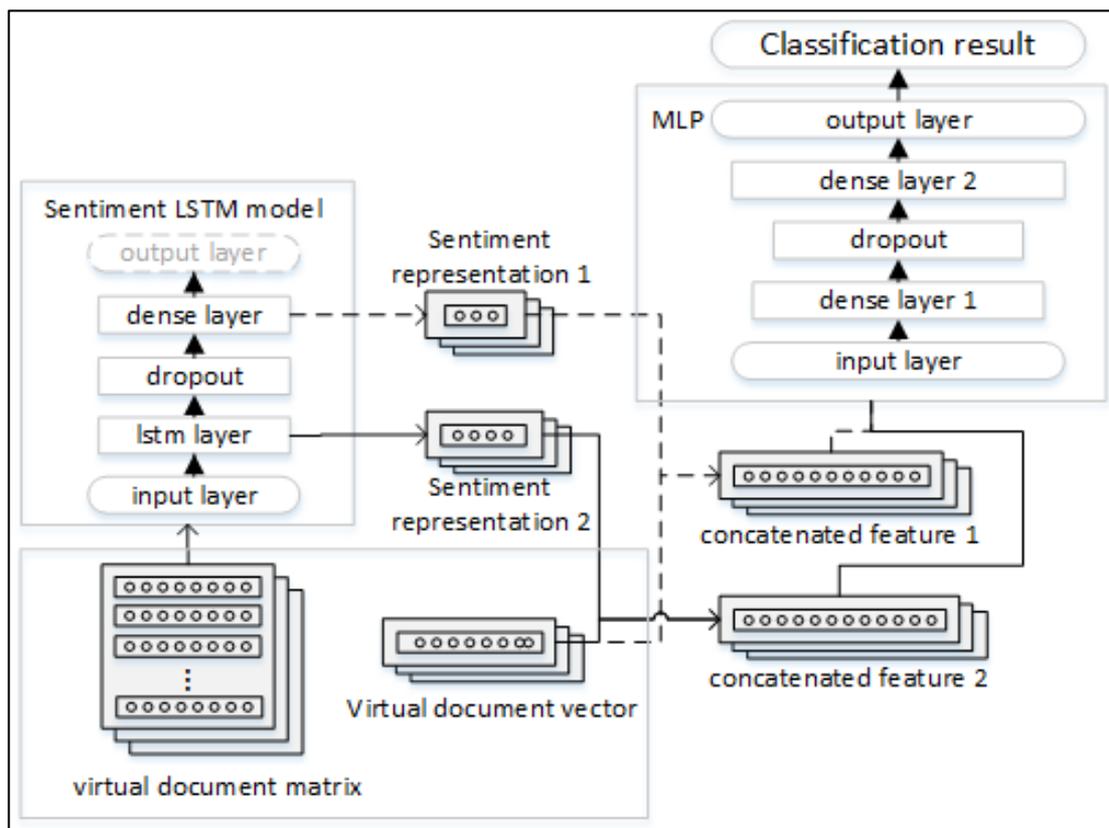
- 模型训练

T	基于有标签评论数据，获得一个情感表征模型
I	与目标域数据高度相似的商品评论数据集
P	采用LSTM算法构建一个情感表征模型
O	文本情感表征模型

- 情感表征

T	基于无标签微博数据，获得对应的情感特征
I	经过预处理的用户虚拟文档矩阵
P	利用上面训练的模型，获取用户的情感特征
O	用户对应的情感特征向量

T	对微博用户进行性别分类
I	用户虚拟文档向量与情感表征的级联
P	利用MLP模型，进行性别分类
O	微博用户的性别（0：男性，1：女性）



Algorithm 1 SRL-MLP

Input:

Segmented user micro-blog posts $p_{i,j} = \{w_{i,j}^{(1)}, w_{i,j}^{(2)}, \dots, w_{i,j}^{(c_{i,j})}\}, i=1,2,\dots,n;$

Segmented source domain documents $d_k = \{w_k^{(1)}, w_k^{(2)}, \dots, w_k^{(c_k)}\}, k=1,2,\dots,m;$

Output:

Output: Gender of user i , G_i .

1: Documents vector representation;

1.1 Assemble user posts to form user virtual document:

$$d'_i = \{p_{i,1}, p_{i,2}, \dots, p_{i,j}, \dots, p_{i,a}\}, i = 1, 2, \dots, n;$$

Regardless of which post the word comes from, renumber the word:

$$d_i = \{w_i^{(1)}, w_i^{(2)}, \dots, w_i^{(c_i)}\}, i = 1, 2, \dots, n;$$

1.2 Vectorize each word in virtual document to form raw matrix of document by word2vec[8][9], including micro-blog and source domain data.

$$\mathbf{x}'_i = \{\mathbf{v}_i^{(1)}, \mathbf{v}_i^{(2)}, \dots, \mathbf{v}_i^{(c_i)}\}, i = 1, 2, \dots, n; \mathbf{x}'_k = \{\mathbf{v}_k^{(1)}, \mathbf{v}_k^{(2)}, \dots, \mathbf{v}_k^{(c_k)}\}, k = 1, 2, \dots, m;$$

1.3 Make average micro-blog word vectors:

$$\mathbf{v}_i = \frac{1}{c_i}(\mathbf{v}_i^{(1)} + \mathbf{v}_i^{(2)} + \dots + \mathbf{v}_i^{(c_i)}); \mathbf{v}_k = \frac{1}{c_k}(\mathbf{v}_k^{(1)} + \mathbf{v}_k^{(2)} + \dots + \mathbf{v}_k^{(c_k)});$$

1.4 Cut off or fill zero to make document matrices having same shape $d \times r$:

$$\mathbf{x}_i = \{\mathbf{v}_i^{(1)}, \mathbf{v}_i^{(2)}, \dots, \mathbf{v}_i^{(r)}\}, i = 1, 2, \dots, n; \mathbf{x}_k = \{\mathbf{v}_k^{(1)}, \mathbf{v}_k^{(2)}, \dots, \mathbf{v}_k^{(r)}\}, k = 1, 2, \dots, m;$$

2: LSTM Sentiment representation learning;

2.1 Select high similarity source domain data to be new source domain data \mathcal{D}_s :

$$\mathcal{D}_s \leftarrow \{\mathbf{x}_k, y_k | \frac{1}{n} \sum_{i=1}^n SIM(\mathbf{x}_i, \mathbf{x}_k) > a, a \in (0, 1)\};$$

2.2 Using source domain data \mathcal{D}_s to train a LSTM sentiment model.

2.3 Put target domain data $\mathcal{D}_t = \{\mathbf{x}_i\}, i = 1, 2, \dots, n$, into LSTM, for each \mathbf{x}_i get its lstm layer output \mathbf{h}_i to be our target domain sentiment representation:

3: MLP gender classification;

3.1 Concatenate \mathbf{v}_i and \mathbf{h}_i to be final features \mathbf{f}_i :

$$\mathbf{f}_i = (\mathbf{v}_i^T, \mathbf{h}_i^T)^T;$$

3.2 Input \mathbf{f}_i to MLP, get G_i :

$$G_i = f(W\mathbf{f}_i + b);$$

4: return G_i ;



实验结果

- 评价指标
 - 准确率，正确分类的样本占总样本的比例

- 实验一：文档表示方式的对比

Word representation	Accuracy(%)
TF-IDF	82.71
Keywords TF-IDF	80.49
LDA	79.15
Average word2vec	84.20
Average word2vec + LDA	84.01

- 实验二：性别分类器的对比

Classifiers	Accuracy(%)
Logistic Regression	67.06
Random Forest	72.15
Support Vector Machine	76.34
MLP	84.20
CNN	74.21
LSTM	73.67

- 实验三：融合情感表征

train LSTM on	added features	accuracy(%)
entire JD reviews	frozen lstm	88.09
	frozen dense	87.98
	finetuned lstm	86.95
high similarity JD reviews	frozen lstm	89.73
	frozen dense	88.45
	finetuned lstm	87.38
entire JD reviews and manually labeled micro-blog	frozen lstm	88.87
	frozen dense	88.13
	finetuned lstm	86.75
high similarity JD reviews and manually labeled micro-blog	frozen lstm	89.31
	frozen dense	89.26
	finetuned lstm	87.22



参考文献

- **Using Sentiment Representation Learning to Enhance Gender Classification for User Profiling**
 - <https://arxiv.org/abs/1810.06645>

上善若水。水善利万物而不争，处众人之所恶，故几於道。居善地，心善渊与善仁，言善信，正善治，事善能，动善时。夫唯不争，故无尤。

谢谢！



- 情感表征模型构建代码

```
print('Build model...')
model = Sequential()
model.add(Embedding(len(dict)+1, 256))
model.add(LSTM(128)) # try using a GRU instead, for fun
model.add(Dropout(0.5))
model.add(Dense(1))
model.add(Activation('sigmoid'))

model.compile(loss='binary_crossentropy', optimizer='adam', metrics=['accuracy'])

model.fit(x, y, batch_size=16, nb_epoch=10) #训练时间为若干个小时

classes = model.predict_classes(xt)
acc = np_utils.accuracy(classes, yt)
print('Test accuracy:', acc)
```