



## Social media based adverse drug reaction detection

---

Zhu Xiaoxu, Lin Hongfei and Zeng Zeyuan

EasyChair preprints are intended for rapid dissemination of research results and are integrated with the rest of EasyChair.

August 9, 2019

# 基于社交媒体的药物不良反应检测

## Social media based adverse drug reaction detection

朱晓旭 林鸿飞 曾泽渊

(大连理工大学 计算机科学与技术学院, 辽宁 大连 116024)

### 摘 要

随着互联网的飞速发展,人们都在用社交媒体来作为知识分享、传播以及情感交流的主要平台,因此在社交媒体的药物不良反应检测将会是关注当前人们用药情况的重要渠道。与此同时,传统的机器学习在构建特征时较为困难并且有着较弱的迁移性,而卷积神经网络(如CNN)在进行空间信息建模时又存在效率低和空间不敏感的缺点。针对以上问题,本文基于通用文本处理特征和生物医学的专属特征等,提出一种基于胶囊网络和长短时记忆神经网络结合的方法来检测在社交媒体中的药物不良反应事件,使用的语料集是2017年Third Social Media Mining for Health (SMM4H)共享任务语料集中的数据,对语料进行预处理后对药物不良反应进行标记,并且构造了分布式词向量特征、词性标记、字符级向量特征以及每句话中药物名和情感词作为模型的特征输入,形成对比实验。解决了在分类过程中特征之间空间关系缺失和构建模型效率低的问题,该实验结果与此前先进的结果相比F1值升高了4.2%,证明该方法在检测社交媒体的药物不良反应事件中是有效的并且具有良好的性能。

**关键词:** 社交媒体; 药物不良反应; 胶囊网络; 生物医学

## **Social media based adverse drug reaction detection**

Zhu Xiao-xu Lin Hong-fei Zeng ze-yuan

(Dalian University of Technology, Dalian 116024, Liaoning, China)

### **Abstract**

With the rapid development of the Internet, people are using social media as the main platform for knowledge sharing and emotional communication. Therefore, the detection of adverse drug reactions in social media will be an important way to pay attention to the current situation of people taking drugs. At the same time, traditional machine learning is difficult and weakly migrating when constructing features, and convolution neural networks (such as CNN) have the disadvantages of low efficiency and space insensitivity when constructing spatial information. Aiming at the above problems, this paper proposes a method based on capsule network and long-short memory neural network to detect adverse drug reaction events in social media based on general text processing features and biomedical proprietary features. We use the data which is the 2017 Third Social Media Mining for Health (SMM4H) shared task corpus. After the process of the corpus, marks the adverse drug reactions, and constructs distributed word vector features, part-of-speech tags, character-level vector features, and in every sentence, the drug name and the emotional word were input as the characteristics of the model. It solves the problem of the lack of spatial relationship between features and the low efficiency of the construction model in the classification process. The experimental results are compared with the previous advanced results, the F1 value is increased by 4.2%, which proves that the method is detecting the adverse drug reaction events of social media. Medium is effective and has good performance.

**Key Words:** Social media; adverse drug reactions; capsule network; biomedicine

## 0. 引言

目前，药品不良反应(adverse drug reactions,ADRs)已经成为美国第四高的死亡率，仅次于心脏病、糖尿病、艾滋病的疾病<sup>[1]</sup>。研究表明，由药物引起的不良反应同时带来了公共卫生问题，每年带来的死亡人数和住院人数以百万计，并且大约每年有七十五亿美元的相关费用<sup>[2-4]</sup>。药物不良反应作为生物医学界乃至社会关注的热点问题，已经引起世界的高度重视。但实际上在临床试验中不可能调查所有可以使用药物的条件和环境，因此进行药物不良反应的检测问题至关重要。

随着互联网的快速普及，像 Twitter 这样的社交媒体已经成为用户及患者之间进行分享知识和交流情感的主要平台。在这个平台上，使用者会讨论他们患病吃药物的相关经历和感受，其中包括处方药的使用、副作用以及治疗效果等，这为我们的检测提供了大量的数据。与传统的医学报告相比，社交媒体上的这些信息会更充分，更具有时效性而且传播更快。到目前为止，从社交媒体中进行药物不良反应的自动检测的相关研究还相对比较少。

2015 年，Sarker and Gonzalez<sup>[5]</sup>利用手动提取句子中单个单词的特征，然后通过机器学习算法支持向量机 (SVM) 进行药物不良反应实验，在实验结果中可以看出传统的机器学习算法在文本分类任务中存在一定局限。在 2016 年，Huynh 等人<sup>[6]</sup>利用卷积神经网络 (CNN) 提取局部序列窗口特征，在一定程度上增强对文本的分类结果，但是效果并不明显。在 2017 年的 Third Social Media Mining for Health (SMM4H) 共享任务评测中，许多参赛队伍都利用当前流行的 SVM 和 CNN 来实现药物不良反应的分类。虽然传统的神经卷积网络存在局部感知、权重共享和多卷积核的优点，但是其很容易丢失特征之间的空间位置关系以及不考虑任何单词或局部模式的顺序如何。

Hinton<sup>[7]</sup>提出的通过放射变换和动态路由协议的胶囊网络则有效地解决了这类问题，使得每个神经元的输出不再仅仅是一个标量值，而是一个向量包含特征的一些属性，每个胶囊的模长能够代表这个特征发生的概率。本文将会以上述方法作为基准，来评估提出的模型的有效性。因此，本文提出一种基于胶囊网络的深度学习算法，尽最大努力减少由于药物不良反应对社会造成的影响，同时也减少领域专家对存在药物不良反应的句子进行标注，从而为社会带来便利。

## 1 相关工作

早期,在进行文本分类时,通常使用词袋模型,TF-IDF 以及 N-gram 等特征作为机器学习模型的特征输入,其中常用的机器学习算法有支持向量机(SVM)<sup>[8]</sup>,逻辑回归模型(LR)<sup>[9]</sup>,朴素贝叶斯(NB)<sup>[10]</sup>等。但是,基于统计的机器学习方法有一个较为明显的弊端,通常需要依赖于费时费力的特征工程构建和较弱的适应性和迁移性。

深度神经网络的提出大大提高了在文本分类任务上的性能,例如卷积神经网络(CNN)和长短时记忆网络(LSTM)。2014年 Kim 提出多通道卷积神经网络进行句子分类<sup>[11]</sup>,该实验是将固定的预训练词向量和微调的词向量分别当作一个通道作为神经网络的输入,再经过池化和正则化得到最终的特征提取向量,该模型在4项任务中都提高了性能。2015年提出使用字符级神经网络(Convnets)进行文本分类,实验结果也优于传统方法<sup>[12]</sup>。在2016年 Joulin 等提出一种简单而且快速有效的分类方法 fastText,同时将 N-gram 模型融入特征中来提高效率<sup>[13]</sup>。虽然深度神经网络的提出比较传统的机器学习在实验性能上有所改善,但是存在特征空间关系缺失以及建模效率低的缺点<sup>[7]</sup>,原因是必须在大小随维数增加指数增长的复制检测器和以类似指数方式增加标记训练集的体积之间进行选择,同时不管任何单词或局部模式的顺序如何,使得神经网络方法在文本分类任务中有一定的局限性。

2017年 Hinton 提出了胶囊网络(Capsule Network),以神经元向量来代替传统神经网络中的神经元节点,用动态路由协议代替深度卷积网络中最大池化的方法训练全新的神经网络。与 CNN 中的最大池化不同,胶囊网络不会丢弃区域内实体之间的准确位置信息,在文本分类中保留了语义信息和各种特征之间的空间关系,同时致力于检测特征和它的各种变种。目前,胶囊网络的有效性已经在手写体 MNIST 数据集上已经得到了证实<sup>[7]</sup>,训练速度快而且准确率高。

## 2 问题及方法概述

本文研究的主要目的为从社交媒体中检测出具有药物不良反应的评论,该研究属于自然语言处理、文本挖掘领域的研究,采用的数据集是 Third Social Media Mining for Health (SMM4H)共享任务中的数据集,完成药物不良反应的检测任务。因此本文的系统主要包括三部分:数据获取模块、特征提取模块和分类器模块。具体如图1所示。

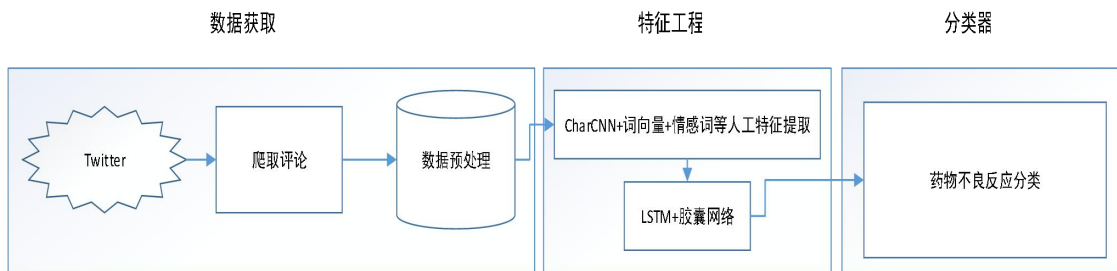


图 1 流程图

Fig.1 System flowchart

(1) 数据获取

本文基于 Scrapy 程序包搭建爬虫平台，根据 Third Social Media Mining for Health (SMM4H)共享任务中公布的 Twitter 中用户帖子的 ID 号进行获取对应的帖子，将爬下来的数据统一存储到.txt 文件中，存储的格式如表 1 所示。

表 1 数据存储格式

Table1 Data storage format

Twitter 评论	标签（存在药物不良反应为 1）
@ProfTimNoakes Tim pre diabetic and insulin resistant. My endocologist has prescribed Victoza injections.My appetite seems to be suppressed.	1
@bengoldacre I was asking because I take warfarin and keep an eye on new anticoags. B-MS Apixaban trials seem to be a bit too good.	0

(2) 特征工程

该部分手动提取自然语言处理任务中常用的词向量，POS 位置标记等特征，同时由于社交媒体中用户拼写错误以及表达不规范等问题，增加对 charCNN 特征的抽取。除此之外，考虑到本任务是对药物不良反应的分类任务，对药物名和情感词等特征主题词的标记会使实验性能有所提高，将这些特征进行融合和拼接得到最终的特征向量。将得到的特征向量输入到长短时记忆网络（LSTM）进行句子表示，然后再经过胶囊网络的动态路由协议迭代得到胶囊。其中每个胶囊代表一个高级特征，每个胶囊都输出一个向量，其大小对应该特征存在的概率值。

### (3) 分类器

经胶囊网络的扁平层输出输送到 softmax 激活函数进行分类，选择发生概率大的作为分类器的输出。即评论中若与药物副作用相关，则标签为 1；反之，标签则为 0，从而达到了通过提取的生物学特征以及文本挖掘特征进行药物不良反应检测的效果。

## 3 模型构建及算法介绍

### 3.1 模型构建

本文应用的模型由 Twitter 评论中的词特征表示和 Twitter 分类器两部分组成。其中第一部分由词向量，字符级向量，POS 特征，情感词等多种特征构成，第二部分由双向长短时记忆神经网络和胶囊网络组成，在一定程度上可以改善当前机器学习和卷积神经网络的不足，具体如图 2 所示。

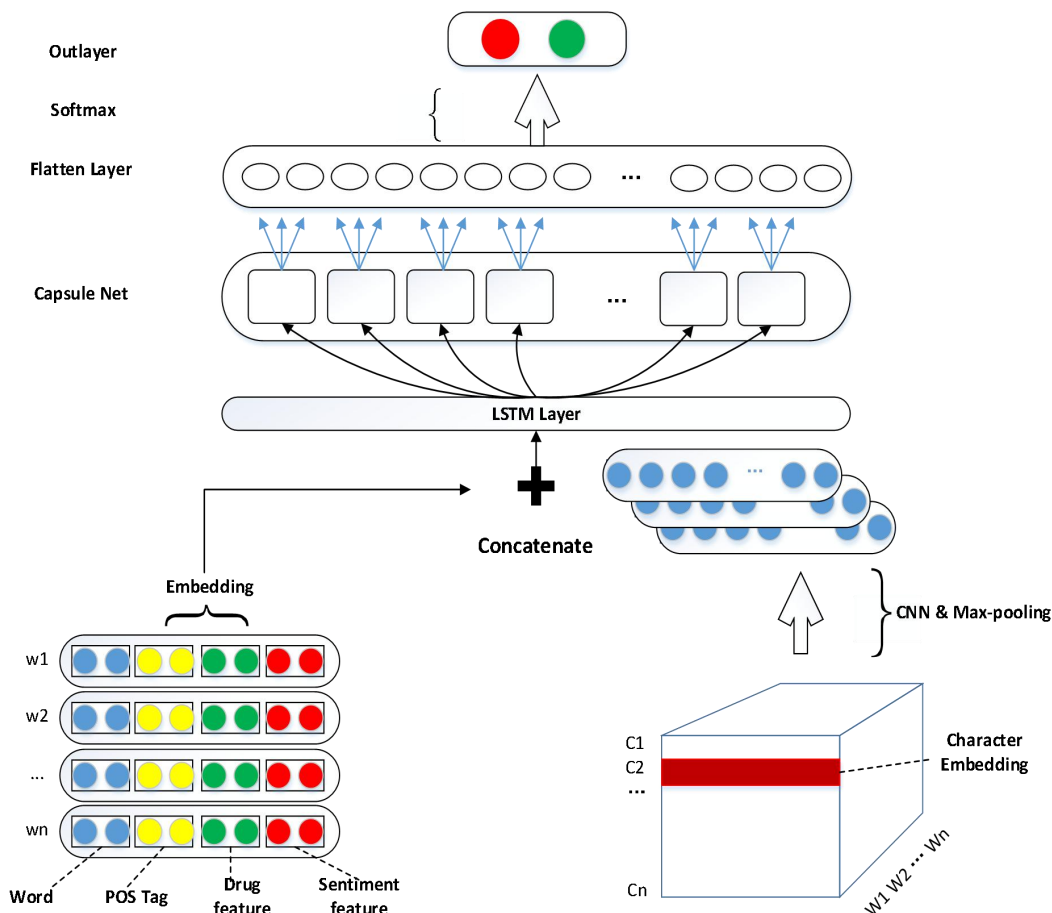


图 2 模型图

Fig.2 Model diagram

### 3.2 特征表示

该模型中的特征表示由 CharCNN、词向量、POS 标记、药物名称以及情感词特征联合组成，这为检测药物不良反应事件提供了较好的基础。我们将预处理后的 Twitter 评论存储在一个.txt 文件中，记作  $D$ 。

$$D = (T_1, T_2, T_3, \dots, T_n) \quad (1)$$

其中  $T_1, T_2 \dots T_n$  表示文件中的每一个 Twitter 评论，最终通过分类器判断该句子是不是含有药物不良反应的评论。

#### (1) 分布式文本表示

目前，在自然语言处理领域词向量的表示方法有两种，分别是传统的独热表示方法（one-hot representation）和分布式表示方法（Distributed Representation, Embedding）。其中第一种独热表示词向量方法由高维向量组成，但是存在的问题是忽略了单词之间是有语义关系和相似度的。分布式表示方法则是通过训练文本将语言中的每一个单词映射到固定长度的向量，然后将这些词向量形成一个词向量空间，通过词之间在该空间上的距离判断其相似度，如图 3 所示。

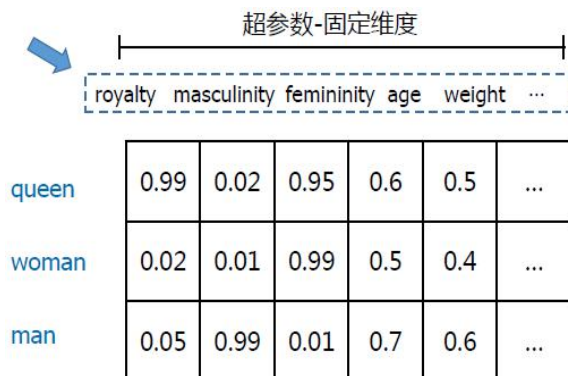


图 3 分布式词向量的表示方法

Fig.3 Distributed word vector representation

本文利用 Word2Vec<sup>[13]</sup>工具通过对 wiki 百科进行词向量的训练，Word2Vec 工具具有两种工作模式，分别是 Skip-gram 模型和连续的词袋模型（CBOW），文中利用 CBOW 模型进行训练，随机初始化，然后将单词或者字词映像到同一个坐标系下，利用神经网络模型进行特征学习，得到连续的数值向量，因此该向量蕴含了丰富的上下文语义信息，对文本分类任务起着重要作用，其在一定程度上决定分类任务的上限。具体公式如下所示。本次实验的窗口  $C$  取为 5，词汇表的大小为  $V$ ，则输入层可表示为  $\{x_1, x_2, x_3, x_4, x_5\}$ ，可以先计算出隐藏层的输出如公式 2 所示。

$$h = \frac{1}{C} W \cdot \left( \sum_{i=1}^C x_i \right) \quad (2)$$



该输出  $h$  是对输入向量作加权平均，其中  $W$  是输入层到隐藏层的权重矩阵。接着计算在输出层每个节点的输入，如公式 3 所示。

$$u_j = v_{wj}^T \cdot h \quad (3)$$

其中  $v_{wj}^T$  是输出权重矩阵  $W'$  的第  $j$  列。进而得到输出层输出  $y_{c,j}$ ，如公式 4 所示。

$$y_{c,j} = p(w_{y,j} | w_1, \dots, w_c) = \frac{\exp(u_j)}{\sum_j \exp(u_j)} \quad (4)$$

## (2) CharCNN

除了词向量以外，在自然语言处理问题上词向量的选择也同样重要。字符级别的特征对于在形态和语义信息上表示有着较大的优势，尤其面对 Twitter 上常常出现的缩写和拼写错误等，它起到可以纠正和识别作用。例如，前缀 `dis` 一通常在英文中是否定的意思，表示不赞同；后缀 `-ing` 通常是现在分词形式，表示正在或者将要发生的动作。在实验中首先构建由符号和字母组成的字母表，对应使用 `one-hot` 表示共统计了 87 个字符，当出现不存在的字符时候，另加全零向量表示。每个单词  $w_i$  用字符表示为  $w_i = (c_1, c_2, c_3, \dots, c_n)$ ，然后通过神经网络的卷积层和最大池化层进行训练优化参数，最终生成可供模型使用的字符级别的特征向量。

## (3) POS 标记

词性 (POS) 标记在药物不良反应的分类任务中也起着举足轻重的作用，通常描述一个词在上下文中的作用，同时词的特性和位置一定程度上蕴含了句子的信息。更重要的一点，在此任务中，药物名称和药物不良反应的表述通常有着自己特定的 POS 标记 (如名词)。在该模型中我们应用的是自然语言处理工具包 `nltk` 中的 `Tokenize` 进行分词和 `pos_tag` 来词性标记，然后将标记完的词性作为模型输入的特征之一，与其他特征进行串联拼接。

## (4) 药物名和情感词

说到药物不良反应，当然离不开药物，所以检测句子中是否含有药物名称是判断药物不良反应的关键因素，只有句子中出现相关的药物名称，才有可能和药物不良反应有关。此外，还需要关注情感词的出现，因为药物不良反应的评论中用户通常会表达出一定的不满或者悲伤甚至绝望的情感。例如，“`Metformin has made me very ill for a very long time. It feels good to be alive and not taking that fucking poison`”，我们可以很清楚地看到，发该帖子的用户一定被二甲双胍药物折磨的很痛苦。本文提出的模型应用 `SentiWordNet_3.0.0` 情感词典和 `SIDER 4.1` 医学药典来进行抽取 Twitter 中每句帖子的药物名和情感词，以此作为训练模型的另一个特征。

### 3.3 Twitter 分类器

药物不良反应的分类器由两部分组成，第一部分是双向长短时记忆网络，第二部分是胶囊网络。

#### (1) 长短时记忆网络

循环神经网络（RNN）是解决序列数据问题的一种有效的方法，主要分为三层，分别是输入层、隐层以及输出层，其工作核心为每个输入对应隐层节点，而在隐含层之间形成线型序列，但是循环神经网络由于在时间上参数共享，经常会出现梯度消失或者梯度爆炸问题。本文采用的是 LSTM 模型，它有效的解决了简单循环神经网络的梯度爆炸或者梯度消失问题，然而 LSTM 自循环的权重是不固定的，它是根据上下文来确定权重值，更好的处理了长距离依赖问题。

LSTM 引入了输入门、遗忘门和输出门，由输入门控制当前计算的新状态以多大程度更新到记忆单元中；遗忘门控制前一步记忆单元中的信息有多大程度被遗忘掉；输出门控制当前的输出有多大程度上取决于当前的记忆单元，进而实现了对较长序列的语义长期和短期记忆。具体公式如下：

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + V_i c_{t-1}) \quad (5)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + V_f c_{t-1}) \quad (6)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + V_o c_{t-1}) \quad (7)$$

$$c_t = f_t * c_{t-1} + i_t * \tanh(W_c x_t + U_c h_{t-1}) \quad (8)$$

$$h_t = o_t * \tanh(c_t) \quad (9)$$

其中， $i_t$  代表输入门， $f_t$  代表遗忘门， $o_t$  代表输出门， $h_t$  代表隐含层状态节点， $c_t$  代表记忆单元， $x_t$  是当前时刻  $t$  的输入， $\sigma$  是 logistic 激活函数， $W$ 、 $U$ 、 $V$  是权重矩阵，其中  $V_i$ 、 $V_f$ 、 $V_o$  是对角矩阵。

#### (2) 胶囊网络

针对于传统深度学习 CNN 中存在的易丢失特征之间的空间位置关系和建模效率低的问题，Hinton 在 2017 年提出胶囊网络。胶囊网络顾名思义就是有一系列的胶囊组成，每一个胶囊代表一种比较高级别的特征，输出是一个矢量，其幅度代表该高级特征存在的概率。实验中我们选用了 10 个胶囊，每个胶囊的维度设置为 16，并且把路由迭代的次数设置为 3。

首先通过 LSTM 输出的隐层状态  $h_i$  与权重矩阵  $W_{ij}$  的乘积得到预测向量  $\hat{u}_{ij}$ 。公式如式（10）所示。

$$\hat{\mathbf{u}}_{j|i} = W_{ij} \mathbf{h}_i \quad (10)$$

每一个胶囊  $s_j$  的总输入是对所有预测向量的加权求和得到, 这一步的关键是通过迭代动态路由找到耦合关系  $c_{ij}$ 。公式如式 (11) 所示。

$$\mathbf{s}_j = \sum_i c_{ij} \hat{\mathbf{u}}_{j|i} \quad (11)$$

与 CNN 中 ReLU 激活函数不同, 胶囊网络中用的是挤压函数 Squash, 作用是把这个  $s_j$  向量缩放到 0 到单位长度 1 之间。公式如式 (12) 所示。

$$\mathbf{v}_j = \frac{\|\mathbf{s}_j\|^2}{1 + \|\mathbf{s}_j\|^2} \frac{\mathbf{s}_j}{\|\mathbf{s}_j\|} \quad (12)$$

为了处理胶囊网络中胶囊之间的关系, Hinton 引入动态路由机制, 详细算法如图 4 所示。

Procedure Rounting algorithm	
1:	<b>Procedure</b> ROUNTING( $\mathbf{u}_{j i}, r, l$ )
2:	for all capsule $i$ in layer $l$ and capsule $j$ in layer( $l+1$ ): $b_{ij} \leftarrow 0$
3:	<b>for</b> $r$ iterations <b>do</b>
4:	for all capsule $i$ in layer $l$ : $c_j \leftarrow \text{soft max}(b_{ij})$
5:	for all capsule $j$ in layer ( $l+1$ ): $\mathbf{s}_j \leftarrow \sum_i c_{ij} \mathbf{u}_{j i}$
6:	for all capsule $j$ in layer ( $l+1$ ): $\mathbf{v}_j \leftarrow \text{squash}(\mathbf{s}_j)$
7:	for all capsule $i$ in layer $l$ and capsule $j$ in layer( $l+1$ ): $b_{ij} \leftarrow b_{ij} + \hat{\mathbf{u}}_{j i} \cdot \mathbf{v}_j$
	<b>return</b> $\mathbf{v}_j$

图 4 算法流程图

Fig4 Algorithm flowchart

其中在前向传播时,  $\mathbf{b}$  的初始值设置为 0。  $c_{ij}$  与  $\mathbf{b}$  的关系如公式 (13) 所示。

$$c_{ij} = \frac{\exp(b_{ij})}{\sum_k \exp(b_{ik})} \quad (13)$$

### (3) 分类器层

胶囊网络的扁平层 (C) 通过连接权重  $\mathbf{W}$  得到加权, 如公式 14 所示。

$$\mathbf{Y} = \mathbf{WC} \quad (14)$$

然后经过 softmax 激活函数进行分类, 选择较大的概率值作为分类结果。如公式 (15-16) 所示。

$$f_i = \frac{e^{-y_i}}{\sum_{y_i \in Y} e^{-y_i}} \quad (15)$$

$$output = \arg \max_i f_i \quad (16)$$

## 4 实验结果与分析

针对本文提出来的方法，本文进行了两个实验：实验一是以机器学习中的支持向量机 SVM 和传统深度学习中的 CNN 方法以及加了 self-attention 机制的模型为基线，从而说明本文提出来的基于词特征表示的胶囊网络模型可以有效的进行药物不良反应的检测；实验二是证明用于词表示的每一个特征都是有作用的，是缺一不可的。

### 4.1 实验结果评价指标

本文的研究内容是药物不良反应的检测任务，是自然语言处理中常见的分类任务，因此对于该系统性能我们可以用准确率（P）、召回率（R）两个参数进行评估，而 F1 值是对准确率和召回率的综合评价指标，本实验选择用 F1 值作为参数评估。其计算公式如公式（17-19）所示。

$$P = \frac{TP}{TP + FP} \quad (17)$$

$$R = \frac{TP}{TP + FN} \quad (18)$$

$$F1 = \frac{2PR}{P + R} \quad (19)$$

其中 TP 表示将药物不良反应正确分类的句子，FN 表示将含有药物不良反应预测为没有不良反应的句子，FP 表示将不含有不良反应的句子检测为药物不良反应的句子，TN 表示正确预测不含药物不良反应的句子。

### 4.2 药物不良反应识别结果

本次实验用的语料集在 2017 年的 Third Social Media Mining for Health (SMM4H)共享任务评测的数据集，在 2016 年的共享任务基础上扩展了训练集。但是由于其提供的是 Twitter 的 ID 号而且存在用户大量删帖现象，我们一共爬取得到 14881 条 Twitter 帖子。在做实验之前，首先对本次实验的数据集进行了详细的信息统计，如表 2 所示。

表 2 数据集统计

Table2 data set statistics

统计项目	训练集	验证集	测试集
Twitter 评论数	10000	2500	2381

为了验证论文中提出的方法的有效性，我们做了多个对比实验，并将实验结果与前人实验结果进行对比分析，表明了本文实验结果的可比性，其实验结果如表 3 所示。

表 3 实验结果对比  
Table3 Comparison of experimental results

Method	F 值 (ADR)
SVM	42.32
CNN	43.26
CNN+attention	44.29
LSTM+multi-head attention	46.16
Model <sup>[14]</sup>	43.50
<b>Our model</b>	<b>47.75</b>

通过对比实验，可以看出本文提出的基于胶囊网络的药物不良反应分类器相比于机器学习算法、传统深度学习算法均有助于提高分类性能，同时也要比 2017 年的 Third Social Media Mining for Health (SMM4H) 共享任务中最好的分类结果高 4.2 个百分点（表 3 中用 Model<sup>[14]</sup>表示）。因为卷积神经网络在对空间信息进行建模过程中，通常要要对特征检测器复制，这就会使模型的建模效率降低；其次，因为卷积神经网络往往对空间位置不敏感，因此对于文本句子中像位置信息，语义信息等难以有效地编码。而胶囊网络中以神经元向量来代替传统深度神经网络中的神经元节点，用动态路由协议代替深度卷积网络中最大池化的方法的特点，使得胶囊网络相比较于其他神经网络架构更容易找到特征之间的空间位置关系，并且可以更高效的建立模型，同时也增强模型的健壮性。

### 4.3 实验结果分析

本文的模型中应用的词表示特征由词向量、字符向量、POS 标记、药物名和情感词组成，实验一已经证明有效的提高了方法的性能。下面通过实验二来讨论这些特征的作用大小，我们做了这些特征有效性的对比测试，分别将如下特征输入到模型中，经过文中提出的 LSTM 和胶囊网络得到的实验结果具体如表 4 所示。

表 4 特征有效性对比  
Table4 Feature validity comparison

Feature	F 值
Word embedding	45.14
CharCNN	44.57
Word embedding+CharCNN	45.83
Word embedding+Sentiment+Drug	46.48
CharCNN+Sentiment+Drug	46.74
Word embedding+CharCNN+Sentiment+Drug	47.29
ALL	<b>47.75</b>

可见，一方面，这些特征缺一不可。当词特征仅仅是分布式词向量或者 CharCNN 时分类效果并不好，然而当与其他特征如 POS 特征、药物名以及情感词进行特征融合之后，可以看到效果要比只加一两个特征性能要好。另一方面，通过实验也可以看出，仅仅用分布式词向量特征要比单用 CharCNN 结果好，原因是词向量中包含有更多的语义信息，这是字符级特征向量所不具备的；但是当 CharCNN 和药物名、情感词进行特征融合时要比词向量和药物名、情感词的特征融合效果好，很重要的一个原因是在药物不良反应检测时，CharCNN 可以从 Twitter 中识别单词缩写和错误拼写，加上药物不良反应句子中负面的情感词因此可以达到很好的效果，而词向量中本来就带有丰富的情感，因此加上情感词特征性能并没有大的提高。总之，实验结果显示，将这些特征进行串联拼接之后可以使得模型的性能更好，对药物不良反应的检测更准确。

模型中先将提取到的特征经过长短时记忆神经网络，然后通过胶囊网络和 softmax 激活函数对药物不良反应句子进行分类。创新点在于针对传统机器学习模型和卷积神经网络模型存在的不足，提出胶囊网络来提高实验的性能。通过设置对比实验也证明本文提出丰富的词表示的动态路由机制的胶囊网络有助于解决多个特征之间的空间关系，因此可以有效地提高对药物不良反应的分类。

## 5 结论与展望

本文旨在传播更快，时效性更高的社交媒体上检测出含有药物不良反应的句子。由于该任务本身属于文本分类任务，从 2014 年开始，关于文本分类任务提出了很多方法，从支持向量机、朴素贝叶斯等经典机器学习模型，到卷积神经网络、循环神经网络等标准深度学习模型，分类性能都还不错。但是机器学习存在

特征工程难以提取和较弱的适应性,传统神经网络存在空间信息特征不明显以及建模效率较低的缺点,针对于这些这些缺点,本文提出基于长短时记忆网络和胶囊网络的药物不良反应检测模型,通过对含有丰富语义信息的词向量与字符级 CharCNN、词性特征、药物名以及情感词特征进行特征融合,使得模型可以进行更加准确的学习。

综上所述,以社交媒体作为载体,结合文本分类任务的特征表示和胶囊网络的研究,可以做到有效的药物不良反应检测,这对改善人类的健康水平有着至关重要的意义。实验结果虽然客观,但是基于社交媒体做药物不良反应的检测 F1 值普遍比较低,这与用户在帖子中表达的非正式性以及数据集的正负例不平衡性有很大关系,下一步的研究重点在于如何解决将用户表达标准化以及数据集正负例平衡问题,如何利用相关模型提高系统学习特征的能力等。

## 参 考 文 献:

- [1] Chee B W , Berlin R , Schatz B . Predicting adverse drug events from personal health messages. [J]. *Amia Annu Symp Proc*, 2011, 2011:217-226.
- [2] Lazarou J , Pomeranz B H , Corey P N . Incidence of Adverse Drug Reactions in Hospitalized Patients: A Meta-analysis of Prospective Studies[J]. *The Journal of the American Medical Association*, 279.
- [3] Ahmad S R. Adverse drug event monitoring at the Food and Drug Administration[J]. *Journal of General Internal Medicine*, 2010, 18(1):57-60.
- [4] Xu R , Wang Q Q . Large-scale combining signals from both biomedical literature and the FDA Adverse Event Reporting System (FAERS) to improve post-marketing drug safety signal detection[J]. *BMC Bioinformatics*, 2014, 15(1):17.
- [5] Sarker A , Gonzalez G . Portable automatic text classification for adverse drug reaction detection via multi-corpus training[J]. *Journal of Biomedical Informatics*, 2015, 53:196-207.
- [6] Trung Huynh, Yulan He, Alistair Willis, and Stefan Rueger. Adverse drug reaction classification with deep neural networks[J]. In *COLING Technical Papers*, 2016.
- [7] Sabour S , Frosst N , Hinton G E . Dynamic Routing Between Capsules[J]. 2017.
- [8] Joachims T. Text categorization with Support Vector Machines: Learning with many relevant features[C]// *Proc Conference on Machine Learning*. 1998.
- [9] Genkin A , Lewis D D , Madigan D . Large-Scale Bayesian Logistic Regression for Text Categorization[J]. *Technometrics*, 2007, 49(3):291-304.
- [10] Schneider K M . Techniques for improving the performance of naive Bayes for text classification[C]// *6th Annual Conference on Intelligent Text Processing and Computational*. 2005.
- [11] Kim Y . Convolutional Neural Networks for Sentence Classification[J]. *Eprint Arxiv*, 2014.
- [12] Xiang Zhang Junbo Zhao Yann LeCun.Character-level Convolutional Networks for Text Classification[J]. 2015.
- [13] Joulin A , Grave E , Bojanowski P , et al. Bag of Tricks for Efficient Text Classification[J]. 2016.
- [14] Sarker A , Belousov M , Friedrichs J , et al. Data and systems for medication-related text classification and concept normalization from Twitter: insights from the Social Media Mining for Health (SMM4H)-2017 shared task[J]. *Journal of the American Medical Informatics Association*, 2018.