

【工业设计】

基于深度循环神经网络的社交网络用户情感研究

王晓慧, 覃京燕

(北京科技大学, 北京 100083)

摘要: **目的** 将深度学习与社交网络、情感计算相结合, 探索利用深度神经网络进行社交网络用户情感研究的新方法和新技术, 探索模型在用户需求分析和推荐上的应用。 **方法** 自动筛选和挖掘海量社交网络数据, 研究具有长时记忆的非先验情感预测方法, 对网络中海量的用户数据、人与人之间关系进行建模, 为关联时间序列创建 LSTM 模型, 并结合其相互关系融入统一的大型深度循环网络中。具体包括: 基于注意力模型的社交网络异构数据处理; 基于深度 LSTM 的长时记忆建模, 研究子网络选取、深度 LSTM 设计, 以及针对社交网络的大型网络结构设计; 基于社交网络情感模型和强化学习的推荐算法。 **结果** 提高了分析的准确度, 降低了对先验假设的依赖, 减轻了人工情感模型的工作量和偏差, 增强了对不同网络数据的普适性; 供深度模型使用。 **结论** 研究成果促进了深度学习与情感计算的结合, 可推动网络用户行为分析和预测的研究, 可用于个性化推荐、定向广告等领域, 具有广泛的学术意义和应用前景。

关键词: 社交网络; 情感计算; 循环神经网络; 深度学习; 推荐系统

中图分类号: TB472 **文献标识码:** A **文章编号:** 1001-3563(2021)04-0077-06

DOI: 10.19554/j.cnki.1001-3563.2021.04.009

Affective Modeling of Social Networks Based on Deep Recurrent Neural Networks

WANG Xiao-hui, QIN Jing-yan

(University of Science and Technology Beijing, Beijing 100083, China)

ABSTRACT: The work aims to combine deep learning with social networks and affective computing and explore new methods and new technologies to establish the affective model of social networks by deep neural networks, to explore the application of the model in user demand analysis and recommendation. The automatic filtering and mining of social network data were carried out. Affective prediction technique with long-term memory and no prior knowledge was studied to model vast amounts of user data and interpersonal relationship data, to establish the LSTM model for time series and integrate them into a uniform large deep recurrent network in combination with their interrelation. The main contents included: heterogeneous data processing of social networks based on attention model; long-term memory model based on deep LSTM, which studied the sub-network selection, deep LSTM structure and large network structure of social networks in allusion to social networks; recommendation algorithm based on the established affective model and reinforcement learning. This research reduced dependence on priori assumptions, improved the analysis accuracy, lightened the workload and bias of the artificial affective model and enhanced the universality of all kinds of different network data. It can be used for deep model. The research results contribute the combination of deep learning and affective computing and promote the research on user behavior analysis and prediction, can be used in personalized recommendation and targeted advertising. It has the wide academic meaning and application prospect.

KEY WORDS: social network; affective computing; recurrent neural networks; deep learning; recommendation system

收稿日期: 2020-11-20

基金项目: 中央高校基本科研业务费 (FRF-TP-18-007A3, FRF-IDRY-19-030); 佛山市人民政府科技创新专项资金项目 (BK20AF002); 佛山市促进高校科技成果服务产业发展扶持项目 (2020DZXX05)

作者简介: 王晓慧 (1987—), 女, 山东人, 博士, 北京科技大学副教授, 主要研究方向为计算机科学与设计学交叉。

通信作者: 覃京燕 (1976—), 女, 四川人, 博士, 北京科技大学教授, 主要研究方向为人工智能与创新设计。

随着互联网的发展,通过社交网络理解人的情感已成为当前社会学、心理学和计算机科学等多学科的研究热点,也是情感计算的核心问题,有着重要的研究意义。媒体选择在社交网络上推送包括新闻资讯在内的各种信息,如果能准确地分析与理解人的情感,就可以通过社交平台实现精准的个性化智能推荐。因此,社交网络情感研究有着重要的实用价值。

深度学习近年来取得了突飞猛进的进展。深度学习相比于以往的浅层学习,其突出特点在于可以用相对统一的结构处理各类异构数据,输入输出形式灵活,并且无需人工进行特征筛选。上层层级之间的隐变量可以向不同空间映射,也就是说,针对某类任务训练好的神经网络可以方便地适配到相似任务中。深度神经网络的特点决定其适合处理社交网络中各类异构数据,从而实现各类异构数据到情感的建模。

以社交网络的情感认知为出发点,通过研究适用于社交网络情感分析的深度学习方法,建立基于循环神经网络(Recurrent Neural Network, RNN)的社交网络情感分析模型,摆脱对人工假定和建模的依赖,研究基本的网络结构单元选取和构建,提升网络性能,并考察模型在各类情感空间中的适配性。不依附于特定的情感空间,在切换情感空间或增加新情感类型场合时,不需要重新训练,减少开销。此外,直接利用情感空间处理多类情感问题,无需拆分成多个二分类情感问题间接处理。最后,将社交网络的情感模型应用到用户需求分析和个性化推荐中。

1 国内外研究现状

1.1 情感计算

情感计算的研究过程可以概括为三方面:如何描述情感,即情感量化;如何描述研究对象,即特征;如何建立情感模型。关于情感的量化,目前的研究思路大体分为“范畴观”和“维度观”两类。范畴观划分如文本分类的正性、负性和中性^[1]、Ekman 的六类基本情感^[2]。维度观划分如 PAD 模型^[3]。

特征和情感计算模型根据研究对象来确定。社交网络中的内容主要包含文本和图像,文本情感分类是自然语言处理中的重要研究内容之一。早期图像的情感计算使用图像单一特征,如颜色或纹理,建立其与情感的映射关系^[4]。进而使用图像的综合特征建立情感模型^[3]。随着社交网络的发展,社交网络的情感模型成为研究热点。在构建社交网络用户情感模型时,应考虑社交网络的如下特性:(1)动态性,网络结构和内容随时间动态变化;(2)异构性,包含文本、图像和网络结构等多种数据源。

1.2 社交网络用户情感的研究

已有研究根据社交网络中用户的行为,如微博、

地理位置、电话记录等分析用户情感状态^[5];根据社交网络的结构和用户行为预测用户个性^[6]。一项基于 Facebook 上数据的研究表明,社交网络上用户的情感与他们的社交活动和相互影响密切相关^[7]。社会学研究表明,人的同理心(Instinctive Empathy)使情感具有群体性,即人们的感受取决于接触到的。已有研究者根据互联网上的用户标注、微博、发表的文章等建立影响模型,以及影响的传播模型^[8]。

基于概率图模型的情感对情感的变化有过多的假设(人工经验公式),如果假设在数据集上有偏差,则很难达到良好效果,并且建模过程往往每次只处理二分类情感问题,在多分类的问题上会差一些^[9]。同时,这些研究都没有给出自身心理、情感、外界影响和行为之间全面系统的量化模型。

1.3 神经网络和深度学习

神经网络是机器学习发展的主流方向。除了传统的静态神经网络以外,近年来循环神经网络受到越来越多的关注。与静态神经网络相比,循环神经网络增加了循环回馈的部分,即状态记忆功能。在处理当前输入时,将历史状态作为输入,即对历史信息进行“记忆”,行为模式更加接近人脑。然而传统的循环神经网络在处理长期记忆依赖时显得力不从心,例如自然语言中某位置出现某词的概率与若干词之前息息相关。长短期记忆(Long Short-Term Memory, LSTM)^[10]的出现解决了这个问题,它是循环神经网络的一种,通过精心设计的单元状态传递,有效解决了这个问题。

已有研究用神经网络处理音视频情感,如利用深度学习处理视频中的情感变化^[11],但只是在传统的分类情感识别基础上考虑帧间关系,利用深度学习对其中某些步骤进行补充。在多种特征基础上,直接采用经典 LSTM 进行情感建模^[12],其模型结构相对单一,需要手工提取各种特征。相对于社交网络,单纯的音视频数据较为规整,分析需要考虑的因素较少。

从 2006 年 Geoffrey Hinton 和他的学生 Simon Osindero 提出新的深度信念网络训练方法^[13]开始,深度学习的飞速发展就拉开了序幕。与之前浅层学习器相比,深度学习具有更加优异的特征学习能力,对数据有更本质的刻画,可以学到更复杂的概念。很多之前需要人工编码的特征提取步骤,在深度学习中被同构的网络完全取代,使得针对特定任务开发新算法的难度大大降低。有研究表明,只要训练足够,深度神经网络经常能提取出比人工精心设计得更好的特征表示^[14]。深度学习的研究在学术界持续升温,谷歌、微软等大型企业的加入为其推波助澜,如著名的 Google Brain,微软 152 层残差网络^[15]等。DeepMind 公司(被 Google 收购)^[16]利用深度神经网络建模 AI,能自动

学习玩视频游戏，输入原始像素，无需人工标注，最终超越了人类玩家。AlphaGo 更是利用深度网络实现了高质量围棋 AI，以 5 : 0 战胜了欧洲冠军，大大挑战了围棋这一传统上认为电脑不可能战胜人类的领域^[17]。

2 基于深度循环神经网络的社交网络用户情感研究框架

基于深度循环神经网络的社交网络用户情感研究框架见图 1。

注意力模型（Attention Model）是近年来深度学习研究的新热点。传统深度学习需要输入数据的所有部分，如一张图片的所有像素，而注意力模型充分模拟人类的视觉特点，即只聚焦在重要部分，提高模型效率，节省计算资源。例如，利用注意力模型识别图像关键部分，大大提升了识别效率^[18]；利用注意力模型每次聚焦在图片的不同位置为其生成文本描述^[19]。

传统学习框架往往用静态数据训练；而在社交网络中，所有数据都是不断变化的；其次，社交网络中的各类信息数量巨大，因计算、网络、存储等方面限制无法全部抓取利用。根据需求，利用注意力模型对海量数据进行预筛选和挖掘，择优抓取重要数据使用，大大节省计算资源和提高模型效率。根据当前状态，使用注意力模型确定每个数据对情感的影响程度，利用重要性采样筛选其中关联性大的数据。然后参照词向量空间方法，为文本、视频、音频、图像等数据建立标准化向量空间，原始数据通过映射得到其数值表达。

具体操作如下：利用用户情感向量结合数据粗略表示，如标签、标题、缩略图等向量化表示，基于深层网络建模生成所有数据上的重要性分布，并进行稀疏采样。此外，对于图片、视频等大的媒体数据，通过重要性分布选择性跳过部分内容，从而节省资源。对这些信息进行向量化处理，并拼接成紧凑向量表示。例如对图片等用自编码方法（Auto Encoder）；音频用基于 LSTM 的自编码，生成紧凑向量；视频先

用自编码处理单张图片，再用类音频方法处理；文字则用词向量表示。

3 基于深度 LSTM 的长时记忆建模

社交网络情感建模的核心是情感、情感影响及变化的建模，以及这几者和观测数据间的相互关系建模。人的情感与情感之间的影响是典型的时间序列，其先后相关性很大。用 LSTM 等长效性循环神经网络模型进行建模是理想选择。本文基于深度神经网络研究 LSTM 模型，提出深度 LSTM 模型对人类情感、情感影响及其变化的长时记忆建模。

静态子网络（对固定输入给出固定输出，可用函数表示）是循环神经网络的基本组成单元，对整个网络的性能起着举足轻重的作用。对于社交网络等复杂的异构数据来说，选取合适的神经网络并对其建模，是至关重要的。无论是残差学习，还是经典 LSTM 网络，都有一个低阻碍的数据通路，借鉴该思想，提出推广的残差模型，提高表达能力的同时增强泛化能力。

LSTM 是循环神经网络模型的核心模块，研究基于推广残差模型的深度 LSTM，在传统 LSTM 模型的基础上简化状态传递过程，使用推广残差模型代替原有线性模型，确保复杂长期记忆影响沿时间顺利传递，同时避免训练中梯度消失的问题。社交网络结构错综复杂，数据繁多，无法用单一的 LSTM 来建模。研究将社交网络中海量个体情感 LSTM，个体间情感影响 LSTM 融入一个大型循环神经网络中，用统一模型处理完整的社交网络数据。

与传统的社交网络情感研究相比，使用的深度学习模型不依赖于人工假定和影响因子建模，去除了先验依赖，从理论上说对各类数据有更强的普适性，情感空间的迁移也更加容易。此外，该神经网络规模更大，实质上是若干个传统神经网络的有机组合，从而实现对社交网络中海量的个体情感、个体间复杂影响力关系的建模。

3.1 推广的深度神经网络残差模型

基础深度神经网络是所有结构单元的基础。深度




图 1 基于深度循环神经网络的社交网络用户情感研究框架

Fig.1 Affective modeling of social networks based on deep recurrent neural networks




图2 深度神经网络结构单元

Fig.2 Deep neural network structure unit

神经网络结构单元见图2。常用的深度神经网络的结构,由若干卷积层(CONV)、激活层(RELU)、全连接层等交替连接构成。已有工作提出,可以用残差学习提高网络的学习效率^[15],将一个网络层的输入输

出端进行短接,由对函数的学习转化成对残差的学习,大大提高了深层网络的学习效率。这类网络本质上增加了从输入端直接到内部节点的直接通路,从而减轻了层级累积误差。据此思想,设计出更为灵活的数据通路,在原深层网络的基础上对任意部分短接,形成实验研究中间隐藏层的布局及短接边放置方案。实验表明,优化的短接边连接可以取得比规则短接边更强的表达能力,有效避免训练时梯度消失的问题。

3.2 深度 LSTM 模型

用户情感变化,影响变化关系等核心模块为整个时序网络的基础,结合 LSTM 长时间关联性和易于训练的优势,以及深度网络表达能力强的特点,设计深度 LSTM 模块,见图3,各变量传递关系:

$$z_{t+1} = f_{deep}^1(H_t, X_{t+1}, R_{t+1}) \quad (1)$$

$$r_{t+1} = f_{deep}^2(H_t, X_{t+1}, R_{t+1}) \quad (2)$$

$$\widetilde{H}_{t+1} = f_{deep}^3(H_t \cdot r_{t+1}, X_{t+1}, R_{t+1}) \quad (3)$$

$$H_{t+1} = (1 - z_{t+1}) \cdot H_t + z_{t+1} \cdot \widetilde{H}_{t+1} \quad (4)$$

其中: f_{deep}^1 , f_{deep}^2 , f_{deep}^3 为深度神经网络,其设计采用短接模块形式。 f_{deep}^1 , f_{deep}^2 为激活函数,其结果取值为[0,1]。和经典 LSTM 相比,线性部分被替换成深度残差神经网络,状态更为紧凑。输入, R_{t+1} (处理后观测数据),以及上个状态的,经过 f_{deep}^1 , f_{deep}^2 成为两个激活量 z_{t+1} , r_{t+1} ,分别用来调制状态对新中间状态 $\widetilde{H}_{t+1}$ (由深度网络 f_{deep}^3 生成)的影响,以及新中间状态 $\widetilde{H}_{t+1}$ 、状态 H_t 对最终新状态的贡献

3.3 融合多 LSTM 模型的深度递归神经网络

基于循环神经网络的社交网络情感模型,以用户 i ,以及与好友 j 的关系为例,见图4,采用经典循环神经网络时序数据流表示。其中情感时序模型,影响关联模型时序模型核心函数分别是 f_H , f_A ,用深度




图3 深度 LSTM 模型

Fig.3 Deep LSTM model




图 4 基于循环神经网络的社交网络情感模型

Fig.4 Affective model of social networks based on RNN

LSTM 模型实现。图 4 展示了 t 和 $t+1$ 两个相邻时刻数据流的传递关系。原始数据经过提取和整合，输入情感时序模型和影响关联模型进行时序建模，同时这两个模型也依赖对方状态作为输入。

X, I 表示观测数据及其加工后数据； H, A, R 等表示状态变量； f 表示各类映射函数； θ 为模型参数。 $X_{u_i, d_m, t}$ 表示用户 i 在 t 时刻的 d_m 类观测数据，如上传的图片、文字、视频等； $X_{u_i, t}$ 表示对用户 i 在 t 时刻观测结果的汇总向量，由 f_{AT} 输出； $I_{u_j, u_i, t}$ 为 t 时刻用户 j 与 i 的互动行为，例如 j 给 i 留言。

$H_{u_i, t}$ 为用户 i 在 t 时刻的情感状态向量，可用输出层映射成喜怒哀乐等可被理解的信息 $H'_{u_i, t}$ ，该过程用函数 $f_Y(\theta_Y): H_{u_i, t} \rightarrow H'_{u_i, t}$ 表示，用残差网络实现；远比 $H'_{u_i, t}$ 信息丰富，某些情况下，甚至将 $\{H'_{u_i, t'} | t' < t\}$ 信息蕴含其中； $A_{u_j, u_i, t}$ 为 t 时刻用户 j 对 i 的影响向量，和类似， $A_{u_j, u_i, t}$ 也可以保存丰富的信息，除了包含当前时刻影响强度以外，还可编码之前的影响； $R_{u_i, t}$ 表示 t 时刻用户 i 所受到朋友影响的聚合向量。

$f_A(\theta_A): (H_{u_i, t}, H_{u_j, t}, I_{u_j, u_i, t}, A_{u_j, u_i, t}) \rightarrow A_{u_j, u_i, t+1}$ 为对社交网络用户行为影响建模的深度网络。即 $f_A(\theta_A)$ 根据过去两人影响状态，以及当前时刻两人情感、互动状态，推测下一刻两人间影响状态。 $f_{AT}(\theta_{AT}): (\{X_{u_i, d_m, t}^n | m, n\}, H_{u_i, t}) \rightarrow X_{u_i, t}$ 为注意力模型， $H_{u_i, t}$ 配合其进行信息筛选。通过 $f_G(\theta_G): \{H_{u_j, t-1}, A_{u_j, u_i, t} | u_j \in \text{Nei}(u_i)\} \rightarrow$

$R_{u_i, t}$ ，将用户 i 受其他用户的影响进行整合，其中 $\text{Nei}(u_i)$ 表示用户 i 在社交网络中的关联用户。 $f_H(\theta_H): (H_{u_i, t}, X_{u_i, t}, R_{u_i, t}) \rightarrow H_{u_i, t+1}$ 是整个网络中的核心部分，输入用户 i 的当前情感向量、当前的行为观测向量和受其他用户影响向量，预测其下个时刻的情感向量。

4 基于情感模型和强化学习的推荐算法研究

将上面得到的社交网络情感模型应用于推荐系统，实现用户的个性化推荐和广告精准投放，具有广泛的应用前景。研究基于社交网络情感模型和强化学习的推荐算法，使用强化学习 (Reinforcement Learning) 建立情感模型与用户的互动模型，向用户主动传递系统认为有价值的信息，同时吸取用户的反馈（例如是否点击了推荐的条目）并总结信息，改进推荐结果。

强化学习的核心是学习在用户特定的情感状态下，向其推荐某些物体的收益。使用深度学习算法对该函数进行建模，研究优化能量的选取，以及改进的 Q-learning 算法通过在线学习优化参数。

传统的强化学习假定系统和环境之间的交互模型是静态的类矩阵形式，对于行为和状态几乎无限的实际情况几乎无能为力。使用深度神经网络对人类情感和行为关系建模，降低了对状态和行为复杂度的限制，更加接近人脑的思维过程。和传统的推荐算法不同，结合用户的情绪向其进行推荐，并使用强化学习时刻更新模型，理论上有很好的针对性和实时性。




图5 基于情感模型和强化学习的推荐系统

Fig.5 Recommendation system based on affective model and reinforcement learning

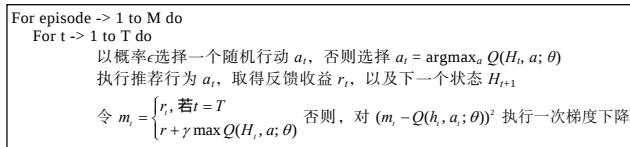


图6 具体示意

Fig.6 Specific steps

基于情感模型和强化学习的推荐系统见图5。由深度神经网络残差模型，输出用户在每个时刻的状态 H 。推荐系统根据当前的状态 H ，给出推荐行为 a ，并从用户接收反馈 r （是否点击了推荐的物品等）。从强化学习的观点看，关键在于学习权重函数 $Q(H, a)$ ，即在用户状态 H 下，给出推荐行为 a ，系统所获得的最大回馈。这样在用户状态 H 时，最优行为可以用 $\arg\max_a Q(H, a)$ 表达。这里用一个深度网络对进行建模。学习过程以经典 Q-learning 为基础，将其中 Q 函数学习改为神经网络训练，具体示意见图6。

5 结语

将社交网络、情感计算和深度学习、记忆神经网络、关注模型、加强学习、推荐算法等有机结合起来。和已有的大部分关于社交网络情感的研究工作不同，不需要人工建立情感变化和影响模型，避免了诸多先验假设，在对数据的普适性和准确率上，有着天然的优势。对深度 LSTM 长时记忆模型进行的情感及情感影响建模，解决了以往情感建模过程中人工模型工作量大、普适性差、系统误差大等问题；推广的残差模型作为各计算模块的基础，使得网络在层数更深的前提下避免过拟合，表达力更强；社交网络注意力模型对海量数据进行自动提取、筛选和挖掘，能克服带宽、存储、计算等方面的瓶颈，理论上能在资源受限的情况下取得更好的效果。社交网络推荐强化学习模型结合情感模型进行个性化推荐，利用用户反馈不断学习改进。

参考文献:

- [1] MELVILLE P, GRYC W, LAURENCE R D. Sentiment Analysis of Blogs by Combining Lexical Knowledge with Text Classification[J]. ACM SIGKDD, 2009: 1275-1284.
- [2] EKMAN P. An Argument for Basic Emotions[J]. Cognition & Emotion, 1992, 6(3-4): 169-200.
- [3] MEHRABIAN A. Pleasure-Arousal-Dominance: a Gen-

eral Framework for Describing and Measuring Individual Differences in Temperament. Current Psychology[J]. Developmental, Learning, Personality, Social, 1996, 14(4): 261-292.

- [4] VALDEZ P, MEHRABIAN A. Effects of Color on Emotions[J]. Journal of Experimental Psychology: General, 1994, 123(4): 394-409.
- [5] TANG J, ZHANG Y, SUN J, et al: Quantitative Study of Individual Emotional States in Social Networks[J]. IEEE Transactions on Affective Computing, 2012, 3(2): 132-144.
- [6] STAIANO J, LEPRI B, AHARONY N, et al: Friends Don't Lie: Inferring Personality Traits from Social Network Structure[J]. ACM Conference on Ubiquitous Computing, 2012: 321-330.
- [7] KRAMER A D, GUILLORY I J E, HANCOCK J T. Experimental Evidence of Massive-Scale Emotional Contagion through Social Networks[J]. Proceedings of the National Academy of Sciences, 2014, 111(24): 8788-8790.
- [8] ANAGNOSTOPOULOS A, KUMAR R, MAHDIAN M. Influence and Correlation in Social Networks[J]. ACM SIGKDD, 2008: 7-15.
- [9] WANG Xiao-hui, JIA Jia, TANG Jie, et al. Modeling Emotion Influence in Image Social Networks[J]. IEEE Transactions on Affective Computing, 2015, 6(3): 286-297.
- [10] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [11] KAHOU S E, BOUTHILLIER X, LAMBLIN P, et al. EmoNets: Multimodal Deep Learning Approaches for Emotion Recognition in Video[J]. Journal on Multimodal User Interfaces, 2015, 10(2): 55-59.
- [12] CHEN Shi-zhe, QIN Jin: Multi-modal Dimensional Emotion Recognition Using Recurrent Neural Networks[J]. International Workshop on Audio/Visual Emotion Challenge, 2015: 49-56.
- [13] GEOFFREY E H, OSINDERO S, TEH Y H. A Fast Learning Algorithm for Deep Belief Nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet Classification with Deep Convolutional Neural Networks[J]. NIPS, 2012.
- [15] HE Kai-ming, ZHANG Xiang-yu, REN Shao-qing, et al. Deep Residual Learning for Image Recognition[J]. Computer Science, 2015.
- [16] MNIH V, KAVUKCUOGLU K, SILVER D, et al. Playing Atari with Deep Reinforcement Learning[J]. Computer Ence, 2013.
- [17] SILVER D, HUANG A, MADDISON C J, et al: Mastering the Game of Go with Deep Neural Networks and Tree Search[J]. Nature, 2016, 529(7587): 484-489.
- [18] MNIH V, HEES N, GRAVES A, et al: Recurrent Models of Visual Attention[J]. NIPS, 2014.
- [19] XU K, BA J, KIROS R, et al: Show, Attend and Tell: Neural Image Caption Generation with Visual Attention [J]. Computer Science, 2015.