

文章编号: 2095-2163(2019)05-0087-05

中图分类号: TP391.1

文献标志码: A

基于深度学习的自适应游戏剧情生成系统研究

吴宇晗¹, 朱峙成¹, 王荣杰¹, 刘佳玮², 陈丽芳¹

(1 华北理工大学 理学院, 河北 唐山 063210; 2 华北理工大学 信息学院, 河北 唐山 063210)

摘要: 为了使游戏玩家从拥有固定文本的文字游戏中体验新鲜感, 提出采用深度学习 Seq2Seq 模型, 根据已有文本产生新的符合剧情的文本, 增加游戏的趣味性和交互性。本文构建深度学习 Seq2Seq 模型, 并编写 Python 代码实现了文本生成模型的仿真, 对生成词与原文本之间的评价标准进行了对比分析, 以自创的游戏验证了该方法的有效性。该论文的研究成果, 是对自适应文本生成系统研究的有益尝试和补充, 具有一定的应用价值。

关键词: Seq2Seq; LSTM 神经网络; 深度学习; 文本生成

Research on adaptive game scenario generation system based on deep learning

WU Yuhan¹, ZHU Zhicheng¹, WANG Rongjie¹, LIU Jiawei², CHEN Lifang¹

(1 College of Science, North China University of Science and Technology, Tangshan Hebei 063210, China;

2 College of Information Engineering, North China University of Science and Technology, Tangshan Hebei 063210, China)

[Abstract] In order to make game players experience novelty from text games with fixed-text, a deep learning Seq2Seq model is put forward, which can generate new scenario text based on existing text to increase the interesting and interactive nature of the game. The paper constructs a deep learning Seq2Seq model and writes Python code to simulate the text generation model. Besides, the paper also compares and analyzes the evaluation criteria between the generated words and the original text. The effectiveness of the method is verified by the self-created game. The research result is a beneficial trial and supplement to the research of adaptive text generation system, which has certain application value.

[Key words] Seq2Seq; LSTM neural network; deep learning; text generation

0 引言

互联网的飞速发展使人类的学习、工作、生活更加丰富多彩,人们在忙碌的学习工作之余,就有相当一部分年轻人会将玩游戏作为娱乐休闲方式之一。在数以千计的手游中,大多存在着剧情重复、模式既成、套路固定等缺乏新意等问题,玩家逐渐摸索出一些固有套路后,就会对相似的游戏失去兴趣,虽然一些游戏进行了创新尝试,在游戏内部添加随机元素,但实际上仍然是程序事先设计好的“随机性”,因而也削弱了游戏的新奇挑战性。因此,如何根据游戏剧情、用户偏好、实时行为等多重属性,综合推出个性化服务,实现由面到点的智能精准推荐,实时生成新的剧情,使用户能真正体验到“不可预期”带来的游玩乐趣,是目前游戏设计中值得深入探讨的焦点问题。

鉴于此,本文提出基于深度学习的自适应剧情生成系统:以大数据、云计算、深度学习等技术作为理论支撑,运用网络爬虫获取原生故事,利用文本处理技术来处理爬取数据,利用深度学习自生成全新的故事,以游戏为窗口展现生成的故事。当用户开始游戏时,依据用户实时的行为建立用户画像,利用智能推荐技术根据所建立的用户画像产生剧情,用户每次对剧情的选择会影响用户画像的改变,从而变换出不同的剧情。整体构思如图 1 所示。

研究中,故事生成器如何产生新文本是整个技术的关键。本文拟利用深度学习 Seq2Seq 模型,根据已有文本数据进行新文本生成训练,从而产生新的剧情,实现游戏的自适应剧情生成系统设计,从游戏开发的角度,拓展了设计思维、提供了建模手段,是对游戏设计的一种有益尝试和补充。

基金项目: 华北理工大学校级大学生创新创业训练项目(201614930111)。

作者简介: 吴宇晗(1998-),男,本科生,主要研究方向:智能科学与技术;朱峙成(1998-),男,本科生,主要研究方向:智能科学与技术;王荣杰(1997-),女,本科生,主要研究方向:数据智能处理;刘佳玮(1998-),男,本科生,主要研究方向:信息科学与技术;陈丽芳(1973-),女,博士,教授,主要研究方向:数据挖掘与处理、神经网络建模、控制理论与控制工程。

通讯作者: 陈丽芳 Email: hblg_clf@163.com

收稿日期: 2019-07-26

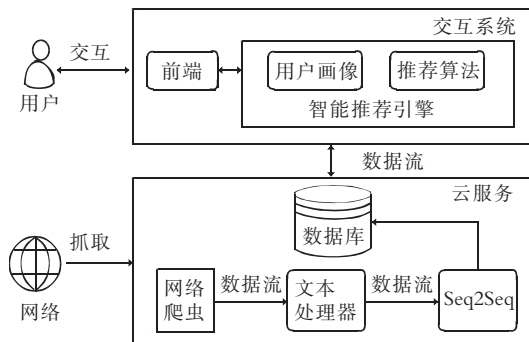


图1 自适应剧情生成系统结构图

Fig. 1 Structural diagram of adaptive story generation system

1 理论基础

1.1 智能推荐算法

基于协同过滤的推荐算法是目前国内外学者研究最多、在各个领域使用最广泛的推荐算法。其最大的优势是对于所要进行推荐的对象没有特殊的种类要求,能够使用与文本同样的方式处理音乐、电影等各类以非结构化形式表示的对象^[1]。Yoda 综合了基于内容的过滤和协同过滤推荐两种技术的优点^[2]。根据个性的游戏用户画像来准确地智能推荐相应的游戏剧情,给予玩家独特的游戏体验。

1.2 深度学习

近年来,深度学习中的递归自编码方法已成功应用于情感分析问题。文献[3]提出采用递归自编码方法来解决较为复杂的情感分析问题。文献[4]提出一种新颖的机器学习框架,是基于递归自编码方法对句子级别的情感分布的预测,从数据库中获取故事文本,并利用深度学习来判别故事的类,自动训练生成新颖的故事情节。对此可做研究论述如下。

1.2.1 长短时间记忆网络

长短时间记忆网络(LSTM)是一种基于递归神经网络模型(RNN)的改进,其原理如图2所示。由Hochreiter和Schmidhube于1997年提出^[5]。LSTM由一组特殊的记忆模块单元替换递归神经网络的隐藏层神经元,这些模块可以记忆隐藏层的任意时间状态,从而解决RNN梯度消失等问题。当使用长短时间记忆模型进行相应数据反向传递时,序列数据在循环神经网络中会经过很长一段时间的学习,从而保证信息进行远距离传递,将误差保持在更为恒定的水平。

通常,长短时间记忆单元模块包括输入门、输出门、遗忘门和记忆单元。根据门用进行保存和调节

存储单元和环境之间的相互作用,这样保证存储单元的状态从一个单元到另一个单元保持不变。LSTM网络通过递归方程更新网络单元,激活从输入 x 到输出 y 的映射^[6]。

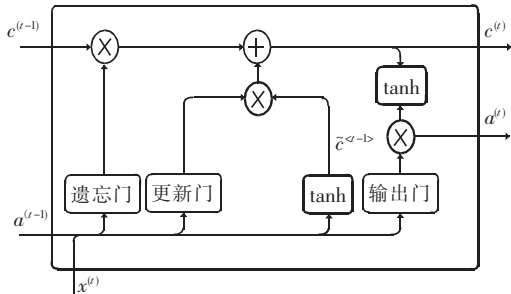


图2 LSTM原理图

Fig. 2 LSTM schematic

LSTM每个单元可用公式表示为:

$$\begin{cases} \tilde{c}^{<t>} = \tanh(W_c[a^{<t-1>}, x^{<t>}] + b_c); \\ i_u = \sigma(W_u[a^{<t-1>}, x^{<t>}] + b_u); \\ i_f = \sigma(W_f[a^{<t-1>}, x^{<t>}] + b_f); \\ i_o = \sigma(W_o[a^{<t-1>}, x^{<t>}] + b_o); \\ c^{<t>} = i_u * \tilde{c}^{<t>} + i_f * c^{<t-1>}; \\ a^{<t>} = i_o * \tanh c^{<t>}. \end{cases} \quad (1)$$

其中, W_u 、 W_f 、 W_o 分别为更新、遗忘和输出加权矩阵; b_u 、 b_f 、 b_o 分别为对更新门、遗忘门和输出门的转换进行参数化的偏差; σ 为 sigmoid 函数; $*$ 为矩阵对应元素相乘。

1.2.2 Seq2Seq 网络模型

LSTM网络存在处理固定长度序列数据的限制,为了解决不定长的序列数据,本文采用了Seq2Seq模型。该模型将一个序列作为输入映射到另一个输出序列时,主要涉及两个基本环节:编码输入与解码输出。其中,编码端根据输入序列数据进行编码,并在网络末端输出编码后的状态。解码端接收编码端最后的状态,将其作为初始状态,同时解码得到的每一步输出值是下一步的输入值。因此Seq2Seq模型训练过程能够更好地学习数据之间时序关系^[7]。

各类不同长度的输入序列 X 映射到高维特征空间后,通过编码器层传递将整个序列的输入层中的所有信息压缩为固定长度的特征向量 C 。向量 C 通常为RNN中的最后一个隐节点 h ,或是多个隐节点的加权总和,其数学计算公式可表示如下:

$$h_i = f(x_i, h_{i-1}); c = \Phi(\{h_1, \dots, h_{T_s}\}), \quad (2)$$

解码层采用此编码的特征向量,并生成标记的

输出序列。此层通常也用 RNN 架构(LSTM 或 RU) 构建, 计算公式如下:

$$S_t = f(y_{t-1}, S_{t-1}, C); p(y_t | y < t, X) = g(y_{t-1}, S_t, C), \quad (3)$$

当使用固定序列的情况下, 通过编码器-解码器框架进行整个模型的联合训练, 获得目标序列的概率最大化^[8]。但是由于固定长度编码的特征向量包含信息数量的限制, Seq2Seq 模型性能会随着源序列长度的增加而降低。为解决此问题, 使用关注机制。在关注机制中, 解码器试图在编码器序列中查找最重要信息所在的位置, 并使用该信息和以前解码的单词来预测序列中的下一个标记, 如图 3 所示。




图 3 Seq2Seq 原理图
Fig. 3 Seq2Seq schematic

在关注机制中, 源序列 $x = (x_1, x_2, \dots, x_t)$ 分别被正向与反向地输入在模型中, 进而得到了正反两层隐节点, 特征向量 C 由 RNN 中的隐节点 h 通过不同的权重 a 加权得到, 运算时将用到如下数学公式:

$$c_i = \sum_{j=1}^{T_x} a_{ij} h_j. \quad (4)$$

将隐藏向量序列按照权重相加, 每一个隐节点 h 都包含了对应的输入字符 X_i 以及其对上下文的联系, 并且当值 a_{ij} 越高, 表示第 i 个输出在第 j 个输入上的注意力越大。根据这一记忆特点, 该模型可以突破固定长度序列的限制, 通过不同长度的序列构建不同个数的隐节点, 调整网络模型输出结果。

1.3 用户画像

Alan Cooper 在早期就对用户个体画像进行了详细的分析, 并在研究中强调人物角色这个概念, 该概念主要是指一个创造出的虚拟用户^[9]。对用户

分析、画像, 主要是为顾客打上标签, 通过标签, 让计算机认识了解一个人, 方便信息处理。标签为研究者提供了一种把难以处理的信息进行量化的方法, 使计算机能够对繁琐的信息进行程序化处理, 根据玩家输入的信息, 对玩家进行个性化分析, 形成虚拟的用户画像, 方便利用智能推荐获取独特的游戏剧情。

1.4 云服务

云服务也可以称作为云模式服务, 是以数据的存储和管理为主要核心任务的云计算系统^[10]。主要用于存储原生故事以及数据交互, 提供深度学习文本的服务, 是游戏的一个核心部位。

2 文本预处理

文本彼此之间往往难以进行有效的计算, Word2vec 提供一种比较好的解决思路。Word2vec 实际上构建了一种映射关系, 利用浅层的神经网络对文本进行训练以获得文本向量, 本文采用此方式实现文本预处理。

3 模型构建

首先, 输入所需要的文本 $T = \{(t_k)\}_{k=1}^m$; 设定最大训练次数 $maxiter$ 、学习率 η 、新文本最大长度 n 、训练步长 $step$ 等参数。然后, 按照算法步骤进行训练, 初始化网络权重、循环迭代训练参数、计算网络梯度、更新网络权重, 直到达到最大的训练次数为止; 最后, 循环生成文本, 返回 $S = \{(S_k)\}_{k=1}^n$, 即训练结果。Seq2Seq 算法的设计伪代码详见如下。

算法 1 Seq2Seq2

输入: 文本 $T = \{(t_k)\}_{k=1}^m$; 最大训练次数 $maxiter$; 学习率 η , 新文本最大长度 n ; 训练步长 $step$

输出: 新文本 $S = \{(s_k)\}_{k=1}^n$

Function Seq2Seq($T, maxiter, \eta, n, step$)

训练

初始化网络权重

repeat

for $k = step \rightarrow m$ do

$y = x_k$

训练参数

计算网络梯度

更新网络权重

end for

until 到达最大训练次数 $maxiter$

生成

```

for k = step → n do
    生成单个字符 s
    S += s
end for
End function

```

4 模型仿真结果分析

4.1 数据集选取

本文实验用数据集有两个。其中,一个是小说文本数据,人工编写,共有 75 081 字,中文文本,分章节叙事,语言风格偏玄幻。另一个是公开数据集哈姆雷特,共有 32 067 词,英文文本,分章节叙事,莎士比亚风格。

4.2 度量标准

本文采用相似度的方法来衡量两者之间的关系,若相似度结果过高或者过低,就不符合预期,相似度过高会使文本丢失随机性;相似度过低会使结果偏向混沌不成语句,所以定义文本相似度在 0.3 ~ 0.7 之间的符合标准^[11]。文本相似度定义如下:

$$\cos\theta = \frac{a * b}{|a| * |b|} = \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} * \sqrt{\sum_{i=1}^n y_i^2}} \quad (5)$$

其中, x_i 表示文本 x 的词频向量, y_i 表示文本 y 的词频向量。

4.3 实验结果

自编小说所给的开始文本:“在新世纪的某处,一个村子里的能力觉醒仪式正在举行着,能力觉醒仪式在这里举行的时间或早或晚,这得看相关者的能力了,不是所有在新世纪的人都会有超能力”。本文模型产生新的文本:“墨泽说了,不过他还是自己人,好像没有伤到一个人,我也没有人家大,没有变解能力的。“嗯??你还是大步出去了。”“呃……你说的话不是,我们也不知道还是那个意外的事情,你怎么回事?”“你,你怎么还没有问题?我怎么会发现呢。”墨泽说道:“我还不是那么大”。

4.4 结果分析

经过对 7 万余字文本训练 20 000 次,循环输出生成新文本长度与原本的相似度,由图 4 可知,相似度是随着输出文本长度的增加而增加的,对于此文本来讲,新文本长度为 40 ~ 300 字之间最为合适,在合适的评价标准区间,由此生成的新文本有一部分并不是很通顺,但已经达到了符合剧情的新文本产生方式。

建模仿真表明,采用深度学习的 Seq2Seq 模型,根据已有文本剧情产生新文本是可行的,给定的原始文本长度越长,效果越好,但需要找到一个合适的临界值,让文本产生更有趣的变化。目前,产生文本符合评价标准最低的是 40 个词,在今后研究中,将在词量的缩减上展开后续的实验仿真,使本模型能够适应各种不同游戏剧情生成,进一步提升性能。




图 4 文本长度-相似度趋势图

Fig. 4 Text length-similarity trend map

5 结束语

本文提出利用深度学习 Seq2Seq 模型,根据已有文本数据进行新文本生成训练,从而产生新的剧情,实现游戏的自适应剧情生成系统设计,从游戏开发的角度,拓展了设计思维、提供了建模手段,是对游戏设计的一种有益尝试和补充。

参考文献

- [1] 石静. 基于混合模式的个性化推荐系统的应用研究[D]. 武汉: 武汉理工大学, 2010.
- [2] SHAHABI C, BANAEI-KASHANI F, CHEN YS, et al. Yoda: An accurate and scalable Web-based recommendation system [M]// BATINI C, GIUNCHIGLIA F, GIORGINI P, et al. Cooperative Information Systems. CoopIS 2001. Lecture Notes in Computer Science. Berlin/Heidelberg: Springer, 2001, 2172: 418-432.
- [3] FU Xianghua, LIU Wangwang, XU Yingying, et al. Combine HowNet lexicon to train phrase recursive autoencoder for sentence-level sentiment analysis[J]. Neurocomputing, 2017, 241: 18-27.
- [4] SOCHER R, PENNINGTON J, ERIC H H, et al. Semi-supervised recursive autoencoders for predicting sentiment distributions [C]//Proceedings of the 2011 Conference on Empirical Methods in Natural Language Processing, EMNLP. Edinburgh, UK: ACL, 2011: 151-161.
- [5] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [6] 李昭昱, 艾芊, 张宇帆, 等. 基于 attention 机制的 LSTM 神经网络超短期负荷预测方法[J]. 供用电, 2019, 36(1): 17-22.