

基于 LSTM 模型的恐怖袭击事件发生时间预测

罗澜峻¹, 祁超^{1*}, 王红卫¹, 王雷²

(1. 华中科技大学管理学院, 湖北 武汉 430074;

2. 中国刑事警察学院治安学系, 辽宁 沈阳 110854)

摘要: 针对部分地区恐怖袭击短期内频发的问题, 提出了基于长短期记忆(LSTM)神经网络模型的恐怖袭击事件发生时间预测方法. 首先, 建立了恐怖袭击事件演化模型, 对局部地区存在的恐怖袭击事件短期内数量剧增现象进行了分析. 其次, 以演化模型为基础从全球恐怖主义数据库(GTD)中提取出 17 项代表恐怖袭击事件特性的指标, 并构建了用于预测的 LSTM 模型. 采用伊拉克 2001 年 9 月至 2016 年底的恐怖袭击事件数据进行实验分析. 结果表明, 基于 LSTM 的预测方法能够较准确的预测短期内恐怖袭击事件的发生时间.

关键词: 恐怖袭击事件; 预测; 长短期记忆; 神经网络

中图分类号: X913.4/TP183

文献标识码: A

文章编号: 1000-5781(2020)02-0163-10

doi: 10.13383/j.cnki.jse.2020.02.003

Prediction of terrorist attack events time based on LSTM model

Luo Lanjun¹, Qi Chao^{1*}, Wang Hongwei¹, Wang Lei²

(1. School of Management, Huazhong University of Science and Technology, Wuhan 430074, China ;

2. Department of Public Security, China Criminal Police College, Shenyang 110854, China)

Abstract: In view of frequent occurrence of terrorist attacks in some areas, this paper proposes a time prediction method for terrorist attack events based on long short-term memory (LSTM) neural network models. Firstly, it proposes an evolution model of terrorist attack events, and analyzes the phenomenon of the short-term rapid increase of terrorist attack events in some local areas. Secondly, based on this evolution model, the paper extracts 17 indicators representing the characteristics of terrorist attacks from the global terrorism database and builds a LSTM model for prediction. An experimental analysis is conducted using the data of terrorist attacks in Iraq from September 2001 to the end of 2016. The experimental results verify the performance of the proposed LSTM-based prediction method on short-term prediction of the occurrence times of terrorist attack events.

Key words: terrorist attack events; prediction; long short-term memory; neural network

1 引言

恐怖袭击是一类意图通过反人道的暴力方式制造大范围恐慌并达成激进政治、经济、社会或宗教目的的突发社会安全事件^[1]. 恐怖袭击事件在发生时通常比普通的刑事犯罪案件更具突发性与破坏性, 造成巨大的生命和财产损失, 带来严重的社会负面影响. 同时, 恐怖袭击事件还存在一定程度的自激现象^[2], 袭击造

收稿日期: 2018-07-30; 修订日期: 2019-04-08.

基金项目: 国家重点研发计划资助项目(2017YFC0803300); 国家自然科学基金资助项目(71974067); 辽宁省社会科学基金重点资助项目(L18AGL003); 辽宁省重点研发计划资助项目(2017231005).

* 通信作者

成的创伤性后果会对恐怖分子产生正反馈^[3]并诱惑其再次作案,进而出现短期内恐怖袭击频发的现象.以伊拉克为例,根据全球恐怖主义数据库(Global Terrorism Database, GTD)^[4]的记录,2011年~2012年该国月均发生恐怖袭击事件100起左右,而2013年底至2014年初此数值已攀升超过400.因此,如果能对恐怖袭击事件的时间进行较为精细的预测,并在实际中开展情报及反恐处突工作加以配合,就可以在事先遏制案件的发生或疏散人群,切断恐怖袭击的反馈回路,避免恐怖袭击活动的进一步蔓延.

目前,国内外相关研究已从不同视角对恐怖袭击预测问题进行探索.例如,Brown等^[5]提出了一种在城市环境中进行恐怖事件空间预测的方法,该方法将基于环境特征的空间似然建模技术与基于人口统计特征的Logistic回归模型相结合,对自杀式炸弹袭击者的空间选择(spatial choice)行为做出预测;Sachan等^[6]利用历史数据分析了不同恐怖组织作案的袭击地点(location)、目标(target)、手法(attack type)、武器(weapon type)等信息,建立了恐怖组织预测模型以预测可能参与特定恐怖袭击的组织;Onat等^[7]利用地理信息系统(Geographic Information System, GIS),结合历史案件中的作案动机、袭击目标等信息对伊斯坦布尔进行了风险地形建模;Ding等^[8]利用国家距离公海的距离、吸毒率等数据,使用支持向量机、随机森林等机器学习方法对全球恐怖主义进行逐年风险预测;项寅^[9]使用BP神经网络结合遗传算法以年为单位对恐怖袭击的不同种类目标进行了风险评估.然而以上工作是在较大的时空尺度上进行研究,对伊拉克这类国家短期内恐怖袭击频发现象的解释力度不够,对具体的情报侦察、安防巡逻等实践工作支撑不足.同时虽然部分研究明确考虑了恐怖袭击的地点、目标、武器和意图等信息对预测的重要性,但是并未系统阐释这些因素如何参与到恐怖袭击反馈演化的过程中,缺乏对恐怖袭击机制的理解,存在用于预测的指标合理性不足的问题^[10].

除上述直接的预测工作以外,还有一部分研究以时间序列分析为基础,对恐怖袭击事件的可预测性进行了讨论.其中Enders等^[11]在2000年的工作中提出,没有伤亡的恐怖袭击无明显周期性,而造成伤亡的跨国恐怖袭击通常具有中期(medium-term)和长期(long-term)的周期,并指出时间序列分析虽然能对恐怖袭击的时间进行估计,却并不能预测恐怖袭击将要发生的地点;其后续的工作^[12]在考虑重大政策和政治干预措施的基础上,进一步对伤亡性恐怖袭击进行了分析并验证了门限自回归模型(threshold autoregressive, TAR)对恐怖袭击时间序列预测问题的适用性;Weimann等^[13]在分析恐怖袭击事件的季节性、周期性等特征的基础上,利用Box-Jenkins模型对恐怖袭击事件的发生及受害率进行了时间序列分析,发现恐怖袭击存在稳定的以月为单位的周期,一阶移动平均模型(first-order moving average model)可以对其充分表示.这部分工作在对时序特征充分把握的基础上,将恐怖袭击预测研究的时间尺度缩小到了月的级别,说明了沿用时间序列预测的思路有利于进一步精确预测未来恐怖袭击的时间.

因此,基于以上工作,本文将结合机器学习和时间序列预测两类工作的优点,提出一种基于长短时记忆(long short-term memory, LSTM)神经网络的恐怖袭击发生时间预测方法,通过时间序列预测的思路尝试对部分国家存在的短期内恐怖袭击频发现象进行解释与把握.长短时记忆神经网络最初由Hochreiter等^[14]提出,是一种特殊的递归神经网络(recurrent neural networks, RNN),主要为解决传统RNN的梯度消失问题而设计,目前已在多种时间序列预测工作中被证明有效性^[15-17].为验证基于LSTM的恐怖袭击发生时间预测方法的效果,本文首先建立了恐怖袭击事件演化模型,对局部地区存在的恐怖袭击事件短期内数量剧增现象进行分析,对预测输入指标的合理性问题进行了尝试性的回应;其次,本文将伊拉克2001年9月后的恐怖袭击数据按照其国家政治状态划分为3个对照数据集,在1步、3步和10步三种预测环境下分别设计对照试验,并利用三种误差衡量指标将LSTM模型与MLP, KNN, Adaboost和SVR四种常用机器学习算法进行对比.结果显示, LSTM模型在9组对照试验的误差对比中最优率为86.7%,体现了良好的问题适用性及泛化能力.

2 恐怖袭击事件演化模型

机器学习算法使用历史数据进行监督学习及预测,其核心任务之一是确保输入指标的合理性.正如前文提到的,目前恐怖袭击预测领域这一部分较薄弱.为给出一个定性的逻辑关系描述,本文选择基于领域经

验,对之前恐怖袭击活动的时间、地点和武器等信息,如何影响下一次恐怖袭击以及作为预测算法的输入做出一个简要说明。

反恐专家通常将恐怖袭击事件从策划到发生的过程描述为多阶段的活动,例如 Nance^[18]将恐怖袭击描述为决策期,情报收集期,目标选择期,后勤部署期,最终评估期,目标接触期,恐怖袭击行动阶段,战术收缩阶段,整合重组期以及总结期等十个阶段。然而这样的阶段划分过于依赖领域经验且难以获得定量的形式化表达。因此,本文在此基础上构建了恐怖袭击事件演化模型,如图1所示。




图1 恐怖袭击事件演化模型

Fig. 1 Evolution model of terrorist attacks events

模型将恐怖袭击全过程分解为激进化,袭击准备,行动和后果评估及反馈四个阶段。恐怖袭击事件的根源因素在本模型中考虑政治畸形,人权缺失,贫富差距,经济萧条,宗教冲突及文化分歧等六项。其导致的激进化具体表现在个人和群体两个不同层面上。个人层面,部分激进化的公民选择成为独狼(Lone-wolf)恐怖分子,独自作案。此类个体行动相对恐怖组织更隐秘,同时结合枪械、炸药等武器之后会表现出极强的危害性,典型案例是众多的美国校园枪击案。群体层面,部分激进化的公民会选择加入现存的恐怖组织或成立新的恐怖组织,例如 ISIS、塔利班等。相比独狼恐怖分子,恐怖组织通常额外存在独立于恐怖袭击的盈利性活动,如毒品生产与走私行为。

值得注意的是,对于恐怖分子而言,制造恐怖袭击并不是常态。大部分时间他们都处于蛰伏的状态,保证自己处于不对称战争的优势地位。在决定进行恐怖袭击之前,通常会有类似催化剂的事件发生,例如,煽动性的政治演讲、部分剧烈的宗教冲突、局部战争的爆发与扩大等。这些催化剂彻底激活了恐怖分子的隐秘活动,进入袭击准备阶段。

在袭击准备阶段,恐怖分子需要完成充分的准备工作,例如:选定特定袭击目标,包括政要、平民、军事机构、基础设施、非政府盈利组织和医院等;选定特定日期,如传统节日、重大纪念日和周末等人流较为集中,能使袭击造成的伤亡更惨重的时间。相较于独狼恐怖分子,恐怖组织在准备阶段的筹备更全面,会进一步筛选适合进行袭击的人员,并进行分工;建立后勤供应链,方便资金、武器的传输及人员调度;同时恐怖组织的领导人会根据准备过程的状态,制定袭击的具体方案并评估可行性。以上步骤通常是差异化的,不存在明显的先后顺序,因此会对反恐工作造成极大的干扰。

在进入行动阶段之前,部分恐怖分子会选择事先发出袭击声明,主要通过邮件、网络视频和广播等方式,意图挑衅及制造平民恐慌。此后,恐怖分子发动袭击,正式展开行动。一次成功的恐怖袭击通常会造成大量人员伤亡及财产损失,这两方面也是相关部门用于评估恐怖袭击后果的主要因素。但不仅政府会进行后果评估,恐怖组织作为始作俑者也会评估自己的“残忍艺术”。由于现代互联网的即时性、便捷性,恐怖袭击的惨烈后果、平民示威游行通常诱使媒体会对恐怖袭击做出过度反应,铺天盖地的海量报道,对于受害者的特写镜头等,都极大的助长了恐怖分子短期内继续发动袭击的欲望。恐怖袭击发生之后的多因素糅合,通常会使得某些致使恐怖主义滋生的根源矛盾进一步滋生,如宗教冲突进一步扩大、经济持续陷入低迷、政治争端加剧等,导致新的催化剂,进一步诱使原本出于蛰伏以及战略收缩状态的恐怖组织加快下一次恐怖袭击的进度安排,加大袭击力度,购买、生产更多的武器等,进而使得恐怖袭击事件的数量在短期内呈现异常增长。

恐怖袭击事件演化模型为提取恐怖袭击事件的特征指标提供了依据。

3 恐怖袭击事件特征指标提取

本文基于恐怖袭击事件演化模型筛选 17 项描述性的特征指标. 由于篇幅限制, 只针对模型中“催化剂事件”所对应的 3 项指标进行详细阐述. 催化剂事件本身是经验的, 任意两项催化剂事件在细节上都差异甚大, 难以在数据上对每一次催化剂事件进行记录, 更无法进行分类. 因此, 只能针对恐怖袭击发生后所体现出来的作案目标对其特定的催化剂进行反映. 本文使用全球恐怖袭击数据库中的 crit1, crit2 和 crit3 三项指标的数据作为催化剂的代替描述, 其中 crit1 记录恐怖袭击事件是否是以达成政治、经济、宗教或社会目标为目的, 这项指标主要反映引发恐怖袭击的催化剂事件的性质; crit2 记录恐怖袭击事件是否意图胁迫、恐吓或煽动更多的群众, 这一点不仅能够反映催化剂事件的来源, 同时能反映其部分意图; crit3 记录恐怖袭击事件是否超出国际人道主义法律, 即日内瓦公约的范围. 目前以政治性、宗教性为主的催化剂事件都能被 crit1, crit2 和 crit3 三种因素的排列组合较充分表达. 在综合考虑之后, 本文从 GTD 数据库中筛选 17 个事件指标用于预测工作. 这些指标分别代表恐怖袭击的时间、地理和目标等 6 个特性, 对应恐怖袭击事件短期演化模型中准备阶段、行动阶段和反馈阶段的关键步骤.

表 1 恐怖袭击事件时间预测模型指标

Table 1 Indicators for the prediction model of terrorist attacks events time

指标	指标具体含义	对应恐怖袭击事件阶段	对应恐怖袭击事件特性
iyear	恐怖袭击事发年份	选取特定日期	时间特性
imonth	恐怖袭击事发月份		
iday	恐怖袭击事发日		
latitude	纬度	选取特定地点	地理特性
longitude	经度		
specificity	地理识别特性		
vicinity	是否在城市附近地区		
crit1	政治、经济、宗教或社会目标	催化剂事件	意图特性
crit2	意图胁迫、恐吓更多的群众		
crit3	超出国际人道主义法律		
targetype1	袭击的目标类型	具体袭击方案	目标特性
attacktype1	袭击方式		武器特性
weaptype1	武器类型		
nkill	死亡人数	造成人员伤亡、财产损失	后果特性
nwound	受伤人数		
propextent	财产损失级别		
success	是否成功		

通过恐怖袭击事件演化模型及恐怖袭击事件特征提取工作不难看出, 新的恐怖袭击并不是独立的, 其必然受到之前的恐怖袭击事件的影响, 这与恐怖袭击的自激现象是相呼应的. 在实际案例研究中, 尤其是以炭疽病毒袭击^[19]、伪装平民跨国袭击^[20]为例的并行、连锁发生的恐怖袭击, 自激过程通常是复杂的, 无法明确新的恐怖袭击的具体催化剂事件, 也无法确定具体是上一次或是多次恐怖袭击引发了新的事件, 这给预测工作带来了极大的挑战. 因此, 必须针对恐怖袭击事件的特殊性定制神经网络结构进行处理.

4 LSTM 模型构建

作为一种改进模型, LSTM 的神经元相比普通的 RNN 新增了输入门(input gate)、遗忘门(forget gate)及输出门(output gate)三种结构. 本文基于 Olah^[21]的可视化工作, 绘制 LSTM 神经元结构如图 2 所示, 其中 t

表示序列索引位置的时刻, 对于恐怖袭击事件序列而言, t 同时也代表被记录的第 t 次恐怖袭击, $X(t)$ 表示 t 时刻的输入, $H(t)$ 表示神经元第 t 时刻的隐藏状态与输出, $C(t)$ 表示神经元第 t 时刻的细胞状态, A 为遗忘门, B 为输入门, C 为输出门, σ (通常为 sigmoid) 与 $\tanh$ 是两项激活函数。




图 2 LSTM 的神经元结构

Fig. 2 The neuron structure of LSTM

LSTM 单元的简要工作原理如下: 首先通过遗忘门以一定概率选择是否遗忘上一层的隐藏细胞状态 $H(t-1)$; 其后, 输入门将 $H(t-1)$ 和 $X(t)$ 通过激活函数与乘法单元计算之后, 与遗忘门的输出结果共同更新细胞状态 $C(t)$, 最后通过输出门输出新的隐藏状态 $H(t)$. 值得注意的是, 作为输出的 $H(t)$ 与隐藏状态 $H(t)$ 是相同的. LSTM 的结构能保证由其构成的神经网络层能够充分利用相邻神经元的信息, 以恐怖袭击事件为例, 虽然每个时刻 t 仅输入一次恐怖袭击事件的信息, 但是在神经网络层的长期记忆中, 之前恐怖袭击事件的信息已经被充分保留在各 LSTM 神经元的细胞状态与隐藏状态之中. 即对新一次恐怖袭击事件的预测不仅利用了输入的前一次恐怖袭击事件信息, 同时考虑了较长时间以来的多次恐怖袭击事件的综合作用, 恰恰符合恐怖袭击事件序列的特性. 由于篇幅限制, 本文不对 LSTM 具体的计算公式与传播算法进行详细推导.

本文构建的基于 LSTM 的恐怖袭击事件发生时间预测模型如图 3 所示.




图 3 基于 LSTM 的恐怖袭击事件发生时间预测模型

Fig. 3 Time prediction model for terrorist attacks events based on LSTM

模型主要包含 5 层隐含层, 分为两层 LSTM 层, 两层全连接(Dense)层, 以及一层 Batch normalization

层^[22]. 图 3 中以单步长预测为例, 对模型的输入输出信息做出说明. LSTM1 为输入层, Dense 2 为输出层, 其中 $X(t)$ 为输入的第 t_0 次恐怖袭击事件信息, $Y(t)$ 为当次神经网络输出结果, 即预测的第 t_1 次恐怖袭击事件的日期. 图中各时刻间 LSTM1 与 LSTM2 层之间的连线代表传递的多个 LSTM 神经元的细胞状态与隐含状态, 具体表现为神经网络对于多次恐怖袭击事件之间复杂作用的“记忆”功能.

5 实验分析

5.1 实验流程

本文将恐怖袭击事件发生时间预测转化为事件日期的时间序列回归预测问题. 每次恐怖袭击事件提取前文所提出的 17 项指标的数据, 预测目标为随后恐怖袭击的日期(day). 实验从 GTD 数据库中选取 2001-09-11 至今伊拉克恐怖袭击事件的数据来验证方法的有效性.

实验流程如图 4, 首先采取监督学习的思路将数据划分为训练集和测试集, 训练集为模型已知数据, 利用残差反向传播的算法对模型进行训练及优化, 测试集为模型未知的数据, 模型达到最优拟合效果之后, 对测试集进行预测, 将测试集中的真实日期与预测结果进行对比可以检验模型可靠性.




图 4 恐怖袭击事件时间预测的实验流程

Fig. 4 Experimental procedure for time prediction of terrorist attacks events

实验中的数据划分及统计特征见表 2.

表 2 数据集划分及统计特征

Table 2 Characteristics of the three extracted datasets to perform comparisons

数据集	TrainBegin	TrainEnd	TestBegin	TestEnd	TrainN	TestN	TrainMean	TestMean	TrainStd	TestStd
DS1	2002-04-03	2010-06-22	2010-06-22	2011-11-25	5 545	1 849	15.027	15.544	8.678	8.714
DS2	2011-11-26	2014-02-22	2014-02-22	2014-06-30	5 145	1 716	16.226	16.121	8.830	8.644
DS3	2014-07-01	2016-05-29	2016-05-29	2016-12-31	5 682	1 895	15.663	15.726	8.723	9.044

为测试模型的泛化能力, 将所选的伊拉克恐怖袭击事件数据划分为表 2 中的三个数据集, DS1, DS2, DS3. DS1 包括 2011-12-15 前美军尚未从伊拉克撤军时期的恐怖袭击数据, DS2 涵盖美国撤军之后至 2014-06 ISIS 入侵之前的数据, DS3 包括 ISIS 入侵后至今的数据. 三个数据集分别代表伊拉克不同的当代政治阶段, 虽然各自时长不同, 但在恐怖袭击事件总数上相近, 说明恐怖袭击频率在三个数据集上有明显差异, 可以对模型的有效性进行充分衡量. 每个数据集内分为训练集及测试集, 划分比例为训练集占全部数据的前 75%, 测试集占后 25%. 其中, TrainBegin, TrainEnd, TestBegin 和 TestEnd 四项分别描述训练集、测试集中恐怖袭击事件的起止日期. 例如, DS1 训练集为 2002-04-03~2010-06-22 的数据, 测试集为 2010-06-22~2011-11-25 的数据. TrainN 和 TestN 代表样本量, TrainMean, TestMean, TrainStd 和 TestStd 分别代表训练和测试集中恐怖袭击实际发生日期的平均值和方差. 在确定数据集后, 为减少指标本身量纲

不同、数据缺失等问题,实验进行了数据预处理,细节在 5.2 节进行展示。

本文考虑三种不同的步长进行恐怖袭击事件发生时间预测,即 1 步、3 步和 10 步预测。其中 1 步预测为利用上一次恐怖袭击事件信息预测下一次袭击的日期,也称单步长(single step)预测,3、10 两种步长为用过去 t_{-n} 至 t_{-1} 次的恐怖袭击的信息预测 t_0 至 t_{n-1} 次($n = 3, 10$)的恐怖袭击的日期。这种多步长(multi-step)预测的方式借鉴了 LSTM 模型被用于自然语言学习中进行序列到序列(sequence to sequence)学习^[23]的思路。不同步长的设置,符合 LSTM 本身长期-短期记忆的特性,能更好地评估模型性能及灵敏度。

为横向检验 LSTM 模型性能,本文采用多层感知机(multi-layer perception, MLP)、支持向量回归(support vector regression, SVR)、 k 近邻回归(k-nearest neighbor, KNN)以及 AdaBoost 回归等四种经典的机器学习模型进行对比。具体参数设置如下: LSTM 和 MLP 模型的批尺寸(batch size)为 500, 批次(epoch)为 200, MLP 的隐含层设置为与 LSTM 一样的 2 层 Dense 层,均使用 RMSprop 作为优化器(optimizer)。SVR 核函数借鉴王晓辉等^[24]的工作设置为径向基函数(radial basis function, RBF), AdaBoost 设置为使用 50 个决策树, KNN 的近邻(neighbor)数量设置为 5。

实验利用平均绝对误差(mean absolute error, MAE)作为损失函数对神经网络模型进行训练。除 MAE 外,模型评估阶段另采用均方误差(mean squared error, MSE)和中值绝对误差(median absolute error, MedAE)作为衡量模型预测精度的指标,误差值越小,说明模型预测精度越高。其中 MSE 通常用于评价数据的变化程度; MAE 相比更加直观且可以简单评估整体错误,但对离群点(outlier)敏感不足;而 MedAE 对离群点极为敏感,通过三项误差指标对比能较全面的反映模型预测性能。三种误差计算公式如下:

$$\text{MSE}(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (1)$$

$$\text{MAE}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (2)$$

$$\text{MedAE} = \text{median}(|y_i - \hat{y}_i|), \quad (3)$$

其中 n 为样本总量, y_i 为实际值, $\hat{y}_i$ 为预测值。

5.2 数据预处理

预处理部分主要包括缺失值补全、数据归一化与异常事件删除三项。其中异常事件删除主要对 GTD 记录不明确的恐怖袭击事件数据予以删除,本文在此不做赘述,仅介绍前两项。

5.2.1 缺失值补全

由于 GTD 数据库记录方式的原因,表 1 中的 17 个指标中存在缺失值的是 nkill, nwound 和 propextent 三项,即部分恐怖袭击事件的死亡人数,受伤人数以及财产损失级别。同时死亡人数、受伤人数的数据以数值方式记录,存在大量离群值,不利于预测工作的顺利开展。本文采用国务院《特别重大、重大突发公共事件分级标准》(2010)对以上三项数据进行处理,将死亡人数、受伤人数分为 $[-1, 4]$ 五类,即数据缺失、伤亡人数不明的恐怖袭击事件对应“-1, 不详”类;未造成任何人员伤亡的恐怖袭击事件对应“0, 无伤亡”类;造成 3 人以下死亡,或者 10 人以下受伤失的恐怖袭击事件对应“1, 一般伤亡”类;造成 3 人以上 10 人以下死亡,或者 10 人以上 50 人以下受伤对应“2, 较大伤亡”类;造成 10 人以上 30 人以下死亡,或者 50 人以上 100 人以下受伤对应“3, 重大伤亡”类;造成 30 人以上死亡,或者 100 人以上受伤对应“4, 特别重大伤亡”类。通过上述方式,使 nkill 和 nwound 两项指标完成缺失值补全及异常值处理工作。针对 propextent 指标,即财产损失类型,主要问题是存在大量缺失值,同时其本身已使用类型值“4”代表财产损失未知。本文为保证缺失值补全工作不对数据本身记录产生干扰,故将缺失值补充为“-1, 不详”类,而非直接添加为“未知”类,最大程度保证数据

的真实、可靠性. 最终使得 propextent 指标分为 $[-1, 4]$ 五类, 与 nkill 和 nwound 两项指标相同.

5.2.2 数据标准化

伴随记录方式及数据本身的含义不同, 17 项量纲差距过大, 必须对数据进行标准化处理. 本文出于最大限度保留数据特性的目的, 对数据进行线性放缩, 即用 min-max 方法进行归一化, 具体公式如下

$$\hat{x} = (x - \min)/(\max - \min), \quad (4)$$

其中 max 和 min 分别为该指标的数据最大值和最小值, 归一化之后所有指标取值分布在 $[0, 1]$ 区间上.

5.3 实验结果分析

根据数据集和预测步长的组合形式, 本文共进行 3×3 组对照实验, 每组实验中均包括五种模型的训练及预测工作. 为保证对比的清晰, 实验结果将各模型在 3、10 两种步长中对 t_0 恐怖袭击事件日期的预测结果与 1 步预测结果进行对比, 在 3 步预测中对 $t_1 \sim t_2$, 10 步预测中 $t_1 \sim t_9$ 恐怖袭击事件日期的预测结果取算术平均值进行对比, 以 $\text{Avg}(t_1, t_{n-1})$ 的形式代替. 完整预测结果如表 3 所示.

表 3 对照试验下各模型预测误差结果

Table 3 Prediction error results for different models in experimental study

观测对象	步长	模型	DS1			DS2			DS3		
			MAE	MEAE	MSE	MAE	MEAE	MSE	MAE	MEAE	MSE
t_0	1步	LSTM	0.904	0.500	9.043	0.673	0.526	3.750	0.426	0.145	3.866
		MLP	2.284	2.030	12.157	1.049	0.897	4.042	1.367	1.284	5.457
		SVR	1.659	1.358	9.723	1.370	1.248	4.765	1.503	1.245	5.666
		KNN	2.193	1.400	14.242	2.187	1.600	10.470	2.122	1.600	10.169
		AdaBoost	2.433	1.127	15.612	1.868	1.138	8.883	2.295	1.414	12.366
	3步	LSTM	0.861	0.401	8.832	1.070	0.974	4.180	0.905	0.753	4.815
		MLP	1.734	1.450	12.096	1.343	1.138	5.837	1.789	1.609	8.651
		SVR	1.661	1.366	9.664	1.324	1.173	4.603	1.440	1.190	5.507
		KNN	3.197	2.400	21.105	3.105	2.600	16.475	3.750	3.000	24.017
		AdaBoost	2.121	1.118	14.407	1.618	0.912	7.612	2.143	1.297	11.183
	10步	LSTM	1.001	0.669	9.434	0.716	0.864	4.058	0.611	0.417	4.103
		MLP	1.778	1.180	12.907	2.390	2.110	11.618	2.754	2.443	13.112
		SVR	1.775	1.432	10.025	1.380	1.198	4.852	1.570	1.345	6.403
		KNN	3.604	2.600	27.799	3.136	2.400	18.323	3.773	2.800	27.235
		AdaBoost	2.261	1.063	15.154	1.970	1.224	9.934	2.377	1.353	13.592
$\text{Avg}(t_1, t_2)$	3步	LSTM	1.589	0.782	20.011	0.931	0.697	6.906	0.950	0.537	10.116
		MLP	1.808	1.009	24.069	1.972	1.689	10.459	1.735	1.413	12.988
		SVR	2.004	1.298	18.891	1.468	1.224	7.214	1.629	1.166	9.759
		KNN	3.756	2.600	30.961	3.300	2.600	19.551	3.893	3.000	27.604
		AdaBoost	2.755	1.455	20.234	1.798	0.929	10.251	1.858	1.039	11.202
$\text{Avg}(t_1, t_9)$	10步	LSTM	2.634	1.007	44.276	1.678	1.212	16.227	1.442	0.712	20.068
		MLP	3.648	2.114	46.669	1.960	1.358	17.522	3.273	2.534	27.477
		SVR	3.061	1.621	37.240	1.765	1.311	13.096	2.060	1.288	19.567
		KNN	5.147	3.600	52.250	3.480	2.577	25.556	4.253	2.911	37.409
		AdaBoost	3.413	1.986	26.511	2.290	1.346	14.943	2.416	1.522	15.939

注: 加粗的数据表示每组对比结果中的误差最小项.

表 3 将每组对比结果中误差最小项加粗标注, 如观测对象为 t_0 , 在 DS1 数据集上进行单步预测时, LSMT 模型的三种误差检验值分别为 0.904、0.501 和 9.043, 在与其它算法的横向对比中均为最优. 如表 3 所示, 在 45 次误差对比中, LSTM 模型仅有 6 次不是最优, 分别是在 DS2 数据集上进行 3 步预测时, 对 t_0 恐怖袭击事件日期预测的 MEAE 值作为次优出现, 比 AdabBootst 略高 6.7%, 对于 t_1 和 t_2 两项事件日期预测的 MSE 值同样是次优, 分别比 SVR 的误差值高 1.1% 和 3.7%. 以及在 10 步预测时, LSTM 模型对 t_1 和 t_9

恐怖袭击事件日期预测的 MSE 误差, 在三个数据集上均不是最优, 说明其预测结果波动相对偏大。

同时值得注意的是, 所有模型在预测步长增加时, 均出现了误差变大的情况, 不论观测对象时 t_0 还是其它预测结果. 可以认为, 这是由于恐怖袭击事件日期的波动随着步长增加而变大, 已发生的袭击与之后的序列关联关系变弱, 因此造成误差增大以及长期记忆出色的 LSTM 模型反而表现变差的现象. 总的来说, 与其它算法横向对比时接近 87% 的最优率, 体现出 LSTM 模型相比传统机器学习模型更好的预测能力。

为了更好的评估 LSTM 模型的可靠性, 继续绘制出 LSTM 模型在 9 组实验中的训练集与测试集的损失(loss)曲线如图 5 所示. 图 5(a)为 LSTM 模型在 DS1 上单步预测的损失曲线, 图 5(b)为在 DS2 上单步预测的损失曲线, 依次类推. 可以看出, 随着步长的增加, 测试集的曲线波动明显变大, 且在 10 步预测任务批次为 35 左右时, 出现了明显的过拟合现象, 损失随着批次的增加及数据的更新才逐步减小. 9 组训练-测试的损失曲线均在批次超过 100 以后, 逐步收敛在 0.05 以下, 在不同的数据库及预测步长的组合下均表现稳定, 说明 LSTM 模型对问题的适用性极好, 泛化能力可靠. 此外, 结合表 2 来看, LSTM 模型在 DS1 上的 MSE 误差值均大于 DS2 和 DS3, 这与 DS1 本身时空跨度大且数据相比 DS2 和 DS3 更稀疏的特性是相符的。




图 5 LSTM 模型训练-测试损失曲线

Fig. 5 The train-test loss curves of LSTM model

6 结束语

本文提出了一种基于长短时记忆神经网络的恐怖袭击事件时间预测方法. 通过对恐怖袭击事件特性的

分析,建立了恐怖袭击事件演化模型,对恐怖袭击短期内数量剧增的现象进行了分析,然后筛选了代表恐怖袭击事件特性的指标,并构建长短时记忆模型对恐怖袭击事件的发生时间进行了预测.实验结果表明,本文提出的基于长短时记忆神经网络的恐怖袭击事件时间预测方法是可靠的,预测准确性与传统的机器学习方法相比更优,能为实际反恐工作提供有效支撑.

后续的研究工作主要从以下方面开展:1)扩展恐怖袭击事件演化模型,提取更多的恐怖袭击事件特征指标.2)从定量分析的角度,对预测指标的合理性做出进一步讨论.3)采用门控循环单元(gated recurrent unit, GRU)等较新的神经网络结构,提升恐怖袭击事件时间预测的精度.

参考文献:

- [1] Fortna V P. Do terrorists win: Rebels' use of terrorism and civil war outcomes. *International Organization*, 2015, 69(3): 519–556.
- [2] Lewis E, Mohler G, Brantingham P J, et al. Self-exciting point process models of civilian deaths in Iraq. *Security Journal*, 2012, 25(3): 244–264.
- [3] Douglas M, Mars G. Terrorism: A positive feedback game. *Human Relations*, 2003, 56(7): 763–786.
- [4] LaFree G, Dugan L. Introducing the global terrorism database. *Terrorism and Political Violence*, 2007, 19(2): 181–204.
- [5] Brown D, Dalton J, Hoyle H. Spatial forecast methods for terrorist events in urban environments // *International Conference on Intelligence and Security Informatics*. Berlin: Springer, 2004: 426–435.
- [6] Sachan A, Roy D. TGPM: Terrorist group prediction model for counter terrorism. *International Journal of Computer Applications*, 2012, 44(10): 49–52.
- [7] Onat I, Gul Z. Terrorism risk forecasting by ideology. *European Journal on Criminal Policy and Research*, 2018, 24(4): 1–17.
- [8] Ding F, Ge Q, Jiang D, et al. Understanding the dynamics of terrorism events with multiple-discipline datasets and machine learning approach. *PloS One*, 2017, 12(6): 1–11.
- [9] 项寅. 基于改进神经网络的恐怖袭击风险预警系统. *灾害学*, 2018, 33(1): 183–189.
Xiang Y. Warning system of terrorist attacks based on improved neural network. *Journal of Catastrophology*, 2018, 33(1): 183–189. (in Chinese)
- [10] Bakker E. Forecasting terrorism: The need for a more systematic approach. *Journal of Strategic Security*, 2012, 5(4): 10.
- [11] Enders W, Sandler T. Is transnational terrorism becoming more threatening: A time-series investigation. *Journal of Conflict Resolution*, 2000, 44(3): 307–332.
- [12] Enders W, Sandler T. Patterns of transnational terrorism, 1970—1999: Alternative time-series estimates. *International Studies Quarterly*, 2002, 46(2): 145–165.
- [13] Weimann G, Brosius H B. The predictability of international terrorism: A time-series analysis. *Studies in Conflict & Terrorism*, 1988, 11(6): 491–502.
- [14] Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, 9(8): 1735–1780.
- [15] 陈亮, 王震, 王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用. *电力信息与通信技术*, 2017, 15(5): 8–11.
Chen L, Wang Z, Wang G. Application of LSTM networks in short-term power load forecasting under the deep learning framework. *Electric Power Information and Communication Technology*, 2017, 15(5): 8–11. (in Chinese)
- [16] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测. *北京航空航天大学学报*, 2018, 44(4): 772–784.
Wang X, Wu J, Liu C, et al. Exploring LSTM based recurrent neural network for failure time series prediction. *Journal of Beijing University of Aeronautics and Astronautics*, 2018, 44(4): 772–784. (in Chinese)
- [17] Duan Y, Lü Y, Wang F Y. Travel time prediction with LSTM neural network // *IEEE 19th International Conference on Intelligent Transportation Systems*. IEEE, 2016: 1053–1058.
- [18] Nance M W. *Terrorist Recognition Handbook: A Practitioner's Manual for Predicting and Identifying Terrorist Activities*. New York: CRC Press, 2013.
- [19] Dougall A L, Hayward M C, Baum A. Media exposure to bioterrorism: stress and the anthrax attacks. *Psychiatry: Interpersonal and Biological Processes*, 2005, 68(1): 28–42.
- [20] 柴瑞瑞, 刘德海, 陈静锋. 恐怖分子跨国潜入的反恐安检资源配置研究. *系统工程学报*, 2017, 32(03): 335–345.
Chai R R, Liu D H, Chen J F. Study of anti-terrorism security resource allocation in transnational terrorism. *Journal of Systems Engineering*, 2017, 32(3): 335–345. (in Chinese)