

基于 LSTM-DA 神经网络的农产品价格指数短期预测模型

贾宁 郑纯军

(大连东软信息学院 辽宁 大连 116023)

摘要 农产品价格一直是维持社会经济生活安定的重点关注领域,由于农产品预测价格与影响因素之间存在非线性关系,递归神经网络虽然适用于时间序列的预测,但是针对长时间的跨度,其预测效果有限。基于此,根据农产品价格特点,设计了一种 LSTM-DA(Long Short-Term Memory-Double Attention,双重注意力机制与长短期记忆网络融合)神经网络模型。它将卷积注意力网络(Convolutional Neural Networks,CNN)、长短期记忆网络(Long Short-Term Memory,LSTM)和注意力机制相结合,针对不同成分的影响因子通过卷积注意力网络进行特征提取,调节其对应的权重并馈送至长短期记忆网络模型中以呈现时间序列的影响,在此基础上,将结果再次送入注意力机制进行权重调节,最终将得到的结果用于农产品价格指数的短期预测。实验前,采用多线程机制从多个农业信息平台中爬取海量的价格、天气等相关数据,在对其进行解析和清洗的基础上,将其存入分布式文件系统(Hadoop Distributed File System, HDFS)中;实验时,采用长短期记忆网络作为基线。实验结果表明,与传统的单一模型相比,此模型不仅可以提升预测精度,而且预测的农产品价格指数可以准确地描述未来一周内蔬菜类产品的整体趋势。

关键词 卷积注意力网络,长短期记忆网络,注意力机制,网络数据爬取,价格预测

中图分类号 TP183 **文献标识码** A

Short-term Forecasting Model of Agricultural Product Price Index Based on LSTM-DA Neural Network

JIA Ning ZHENG Chun-jun

(Dalian Neusoft University of Information, Dalian, Liaoning 116023, China)

Abstract The price of agricultural products has always been the key area for maintaining social and economic life. Due to the non-linear relationship between predicted prices and influencing factors of agricultural products, recurrent neural networks are suitable for time series prediction. However, for long-term span, its prediction effect is limited. According to the price characteristics of agricultural products, a neural network model of LSTM-DA (Long Short-Term Memory-Double Attention) was designed. It combines the convolutional attention network, the Long Short-Term Memory network and the attention mechanism. The attention factors of different components are extracted by the convolutional attention network, and the corresponding weights are adjusted and fed into the Long Short-Term Memory network model. Based on the influence of the time series, the results are sent to the attention mechanism for weight adjustment, and finally the results are used for short-term prediction of agricultural product price index. Before the experiment, the multi-threading mechanism is used to crawl a large number of agricultural information platforms to collect a large amount of price, weather and other related data. Based on the analysis and cleaning, they are stored in a Hadoop Distributed File System. In the experiment, the Long Short-Term Memory network is used as the baseline. Compared with the traditional single model, this model can improve the prediction accuracy, and the predicted price index can accurately describe the overall trend of vegetable products in the next week.

Keywords Convolutional attention network, Long short-term memory, Attention mechanism, Network data crawler, Price forecasting

1 引言

由于受到季节波动、供给关系、人均收入、产品流通等多种因素的影响,我国农产品价格时常出现较大的周期性波动,呈现非线性变化的特点^[1]。农产品价格的波动,除了影响农产品的生产、流通和农民的收入之外,还会对社会的稳定产生较大的影响。基于此,对农产品的价格进行短期预测,可以帮

助农民在最快的时间内调节商品量,规避市场风险,从而保证市场的有序与稳定^[2]。

现今,国内外学者均提出大量有效的机制来进行农产品价格的拟合与预测。例如,刘海清等^[3]针对海南省芒果价格,建立了指数平滑模型,有效地对海南省芒果价格曲线进行拟合和预测。刘峰^[4]利用农产品价格时间序列的当前值和过去值准确预报未来值,可以实现农产品流通和农业生产的有效引导。

然而,采用传统的计量型模型无法完美拟合非线性时间序列,同时,对现有数据的要求较高。神经网络由于具有自学习能力与适应性较强、容错性与准确度较高等特点^[5],可依托多个农业信息平台上发布的海量、多种形式的数,在对数据进行解析和清洗的基础上,提取有效的海量信息^[6],选择成熟的深度学习模型进行短期价格指数预测^[7]。然而,采用标准的神经网络模型无法完美地解决此问题,基于此,本文提出了一种 LSTM-DA 神经网络模型进行短期蔬菜类价格指数预测,该模型将卷积注意力网络、长短期记忆网络和注意力机制有效地结合在一起。为了验证预测价格的准确性,本文采用 LSTM 模型作为基线,对 4 个模型进行对比实验,实验结果验证了该模型的有效性。

2 相关工作

本文主要涉及卷积神经网络、长短期记忆网络以及注意力机制,本节将重点介绍相关模型的研究现状。

作为深度学习的一种最常见的网络模型,CNN 仿造 Visual Perception 机制进行构建,可以进行有监督学习和非监督学习,目前,已被广泛用于图像识别^[8]、自然语言处理^[9]等领域。

作为神经网络的一种常见变异网络,递归神经网络(Recurrent Neural Networks,RNN)以及 LSTM 已被广泛应用于文本、图像、视频、语音识别等人工智能领域,由于其能够有效地利用数据序列中的部分长期数据,因此在回归问题上的适用性能较好。例如,陈卫华等^[10]利用 LSTM 对股市波动率进行精准预测,其预测效果明显优于其他对比模型。王国栋等^[11]使用 LSTM 对舰船的运动姿态进行短期预测,而且精确度较高。陆泽楠等^[12]使用 LSTM,结合近年的钢铁交易价格走势,对钢铁价格进行预测。

为了提升结构化预测的效果,目前已经涌现出一批 LSTM 的相关模型,例如,Cao 等^[13]使用双向 LSTM 的神经网络预测蛋白质残基的相互作用力,同时考虑了全局因素的影响。Kong 等^[14]提出时空嵌入式 LSTM 用于挖掘用户的行为轨迹,完成实时轨迹预测。Neil 等^[15]提出了一种分阶段 LSTM,通过添加时间门来扩展 LSTM 单元,从而达到处理异步信息的目的。

在现有的深度学习框架中,除了应用传统的模型之外,还增添了许多流行机制,例如迁移学习、注意力机制、增强学习等。根据本课题的时间序列特征,选择注意力机制进行特征融合。目前,注意力机制已被广泛应用于很多领域,例如,Huang 等^[16]将 CNN 与注意力机制相结合,实现了对音乐中富有情绪化部分的内容高亮。Persio 等^[17]将注意力集中在 LSTM,获得了一种能量负荷预测的新方法,建立了一种有效的能源管理策略。Mirsamadi 等^[18]将本地注意力机制加入 RNN 中,通过集中提取与情感相关的短时帧级声学特征,以实现对话者情绪的自动识别。在现有的工作中,根据应用场景的复杂程度,对注意力模型中的有效特征进行分析与提取,已达到最佳的偏重效果。

本文将 CNN、注意力网络、LSTM 与注意力机制相结合,构建了一个对蔬菜类农产品价格进行预测的模型。图 1 是蔬菜类农产品价格预测的全流程示意图。

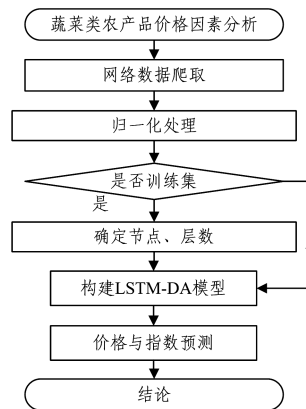


图 1 农产品价格指数的预测流程

3 蔬菜类农产品数据的预处理

3.1 数据准备

针对海量农产品价格数据,本文采用的策略是在规定范围内的农业网站中爬取相关的数据,在对其进行数据检查、解析处理的基础上,完成数据存储。数据爬取过程是基于 Hadoop 框架实施的,在已知 URL 路径地址的情况下,判断网页内容的分类方式,在此基础上爬取海量数据。值得注意的是,必须在爬取过程中确保数据的完备性与正确性,从而避免因网站服务器的不稳定因素而导致的数据获取失败。基于此,每次向服务器发起请求时,应确保获取成功的应答信息,以确保请求被识别。此外,使用正则表达式进行网页数据的分析,并将分析结果保存到 HDFS 中。

在数据准备环节,如何设计爬取策略显得尤为关键。常见的策略主要有深度优先和广度优先等。针对列表形式的农产品价格信息,可采用深度优先的形式爬取页面,网站中的内部链接较少,但是类别较多,针对不同的类别,可以利用多线程的方式进行数据抓取。反之,若网站中的内部链接较多,则可以采用广度优先的爬取策略。

本文采用深度优先的形式获取数据,依照此种策略,在爬取时首先需要总结网站 URL 地址的规律,从中提取部分差异性的路径,将其页面拆分为多组子页面,并放入不同的线程中。以全国农产品商务信息公共服务平台为例,该平台中当前城市可利用的蔬菜数据约 40 万条,页面约 4 万个,利用 URL 地址中的参数,设置查询数据的区间范围,由于网站中限制搜索范围为 90 天,因此针对每个城市、每个批发中心、每种蔬菜的 3 年价格数据,需要至少 12 个子任务才可获得数据,而每个子任务还需访问其 10 个列表。将列表放入不同的线程中执行,发起 GET 请求后解析网站中的数据。除了获取当地蔬菜数据,还需要采用相似的形式,爬取当前城市的天气信息,包括温度、湿度、节气等,这是由于气温、节气等因素会对蔬菜类农产品的产量产生巨大的影响,从而造成农产品的价格浮动。

在解析网站数据时,可以使用各自的标签对进行目标数据的提取。由于不同网站之间的架构存在一定的差异性,针对不同的网站,设计具有特色的解析规则,即提供不同的正则表达式模板,在锁定标签对所包含的数据范围后,对其进行数据拆分,解析目标信息。此部分工作冗余性较强,因此解析规则显得格外重要。解析后统一的数据格式为:品名、价格、城

市、批发单位、日期、温度、湿度、季节、节假日等。

最终,将解析后的数据存入 HDFS 中,并自动完成多次备份操作,此处设置为 3 个副本,便于后续数据的存储与查询。图 2 为网络数据爬取的基本流程。




图2 数据爬取流程

3.2 数据的归一化处理

由于爬取数据的计量单位不同,而且数值差异性较大,因此需要对价格进行归一化处理,将其统一到一定范围内,而不改变数据之间的基本关联。

常见的归一化方法有小数定标标准化、Z-score 标准化和最大-最小值标准化等。本文采用最大-最小值标准化方法进行归一化处理,即对数据进行线性变化,最终将全体数据集映射到 $[0,1]$ 内部空间中,具体计算公式如式(1)所示。

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

其中, X 为原始数据, X' 为归一化后的数据, X_{\max} 和 X_{\min} 分别代表样本数据的最大值和最小值。

4 LSTM-DA 神经网络

本文设计了一个基于 LSTM 网络构建的双注意力机制神经网络,其包含 5 个部分:价格主因素与辅因素输入、CNN 注意力网络、LSTM 层、注意力层和预测层。网络模型的整体框图如图 3 所示。




图3 LSTM-DA 神经网络的整体框

4.1 价格主因素与辅因素层

本文提取的价格主因素特征主要包含与时间序列相关的特征和价格相关的特征,辅因素为其他影响因素的特征。

本文提取的价格主因素特征,主要包含近 3 年的 10 种蔬菜的相关数据,包括年,月,日,星期几,一年中的第几周,上月本日价格,上月本日均值,上月本日方差,去年同月价格,去年同月均值,去年同月同周价格的均值,去年同月方差,上月同周价格的均值,上月同周价格的方差,前 1 天、7 天和 14 天的价格。

辅因素主要包括当日气温、前 7 天气温及其平均值、后两周气温及其平均值、当日湿度、前 7 天湿度及其平均湿度、后两周湿度及其湿度平均值、季节、节假日等信息。

4.2 CNN 注意力网络

CNN 注意力网络是 CNN 与注意力机制的融合。CNN 的概念由日本学者福岛邦彦(Kunihiko Fukushima)在 1980 年提出,随着深度学习理念的提出,卷积神经网络获得了飞速的发展。图 3 所示的 CNN 注意力网络由两组三个单独的卷积神经网络与注意力机制叠加组成,用于计算价格主因素与辅因素互相关性的关注矩阵。为了避免主因素涉及过多的特征而对预测结果产生负面影响,本文模型拟采用 3 年内价格变化幅度最高的前 10 种蔬菜的前 7 天价格来预测后 7 天的价格,价格主因素共 $17 * 10 * 3 * 7$ 维,价格辅因素共 $50 * 3 * 7$ 维。

4.3 LSTM 层

传统的 RNN 中添加了与时间结点有关的自我连接形式,以“环”的形式体现,下一个时间步会受到本次的影响,从而彰显了其对于时间序列的建模能力,这种形式与农产品价格随时间变化的走势预测十分吻合。然而,若隐藏层数量较多,在自我循环的过程中,传统的 RNN 易产生梯度消失或梯度爆炸问题,因此在其基础上,Hochreiter 等^[19]在 1997 年提出了 LSTM 模型,即增加了存储长期有效数据的单元,从而克服了梯度问题,提升了预测的能力。

作为一种强大的 RNN 模型,LSTM 引入了长时间信息有效性的机制,这些信息有选择性地被控制并保存下来。LSTM 采用的策略是,在每个神经元内部增加输入门、输出门和忘记门。本文选用误差函数反馈权重。通过忘记门决定记忆单位是否被清除。默认的 LSTM 结构如式(2)所示。

$$\begin{aligned} f_t &= \sigma(W_f[h_{t-1}, x_t] + b_f) \\ i_t &= \sigma(W_i[h_{t-1}, x_t] + b_i) \\ \tilde{C}_t &= \tanh(W_c[h_{t-1}, x_t] + b_c) \\ C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t \\ o_t &= \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t &= o_t * \tanh(C_t) \end{aligned} \quad (2)$$

其中, W_f, W_i, W_c, W_o 是权重参数; b_f, b_i, b_c, b_o 是偏置; x_t 作为输入序列,结合上一个隐藏层 h_{t-1} 的状态,通过激活函数构成忘记门 f_t ;输入门层 i_t 和输出门 o_t 也由 x_t 和 h_{t-1} 计算;忘记门 f_t 与前单元状态 C_{t-1} 联合以确定是否丢弃信息。

4.4 注意力层

考虑到人类大脑对事物的感知是一个有选择性的集中注意力的过程,这种注意力机制可以被应用于深度学习领域,注意力可以被描述为用于分配有限信息处理能力的“选择机制”,它有助于快速分析目标数据,配合信息筛选和权重设置机制,提升模型的计算能力。

对于输入 x 的序列中的每个向量 x_i ,可以按照式(3)计算注意力权重 a_i ,其中 $f(x_i)$ 是评分函数。

$$a_i = \frac{\exp(f(x_i))}{\sum_j \exp(f(x_j))} \quad (3)$$

注意力层的输出,即 $attentive_x$,是输入序列的加权之和,如式(4)所示。

$$attentive_x = \sum_i a_i x_i \quad (4)$$

本文引入两处注意力机制,为了实现对价格主因素与辅因素的特征进行提取,第一个注意力机制用于找出两种因素之间的相似关系,从而进一步提取主、辅特征之间的高层信息;在 LSTM 之后引入第二个注意力机制,可以实现价格预测结果与特征输出每一项的对应关系。

4.5 预测层

本文中网络的输出层为预测层,通过输入前 7 天的主因素与辅因素的相关数据,输出 10 种蔬菜后 7 天的预测价格。

5 实验及结果分析

5.1 数据集

本文涉及的数据均从相关的网站中爬取,经过完备性检查、数据解析与清洗之后,将有效的数据存储至 HDFS 中。获取的数据主要来源于以下几个网站:农产品信息公共服务平台¹⁾,农产品网²⁾,农产品市场信息平台³⁾,中国天气网⁴⁾。其中,前 3 个网站主要涉及价格相关等主因素特征,中国天气网主要涉及气温等辅因素特征。

5.2 模型参数设置

CNN 模型的卷积核采用 $5 * 5, 3 * 3, 1 * 1$ 的大小。采用 3 个隐藏层,而且每层有 70 个隐藏层神经元。采用单向 LSTM 模式,其预测时间为 7 天, batch_size 为 150, 最大 epoch 为 10000。学习速率为 0.001。Dropout 为 0.5。初始化权重方法为 RandomUniform。神经元激活函数为双切正切函数(Tanh)。优化器为 RMSProp。损失函数为均方误差(MSE)。

5.3 结果分析

本文使用 Tensorflow 框架进行网络模型结构的搭建,对数据进行农产品价格指数的预测。以原始数据+传统的 LSTM 模型(模型 1)作为基线,对照模型分别为:1)注意力网络+传统的 LSTM(模型 2);2)原始数据+传统的 LSTM+注意力机制(模型 3);3)当前系统(模型 4)。分别计算其预测相对误差,计算公式如式(5)所示:

$$R_{mse} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - t_i)^2} \quad (5)$$

其中, R_{mse} 代表所有蔬菜预测价格与真实价格之间的均方根, y_i 为预测值, t_i 为期望值。

图 4 为未来 7 天价格指数预测值与真实值的统计数据。由图 4 可知,预测值与真实值之间的差异较小。




图 4 价格指数预测值与真实值的统计数据

表 1 为经过实验验证后,不同模型的预测结果的均方根误差。

表 1 实验结果

	(单位:%)				
误差	价格指数	马铃薯	生姜	白菜	大蒜
模型 1	5.55	6.02	4.89	5.20	4.50
模型 2	5.30	5.87	4.70	4.80	4.10
模型 3	5.25	5.65	4.54	4.62	4.15
模型 4	4.89	5.40	4.50	4.20	4.02

由表 1 可知,本文提出的策略在所有模型中的价格指数和大部分农产品预测的表现最好,拥有最优的准确率。其次是带有注意力网络或者注意力机制的模型,而基线的准确度最低。由此可以确定添加注意力机制的位置与数量均对预测模型产生了较大的影响。

结束语 针对蔬菜类农产品价格指数预测问题,本文设计数据采集、清洗、处理、转存、大数据分析、预测等环节,形成了一套完整的回归问题解决方案。其中,采用深度优先的形式爬取海量农产品相关的数据(含主因素和辅因素数据),最终将其存放至 HDFS 中,再结合 CNN 注意力网络、LSTM 和注意力机制,对蔬菜类农产品的价格指数进行预测,同时预测未来一周内的涨幅最高的 10 类蔬菜的价格。通过实验验证,本文提出的模型的准确度较高,而且均方误差值易于收敛。

在未来的工作中,我们将进一步对农产品的数据进行爬取与转存,获得更为权威的数据,并设立自己的农产品价格数据库,并对外提供相应的接口;同时,针对现有的神经网络进一步完成模型优化,以降低预测数据与真实值之间的误差。

参考文献

- [1] 许世卫,李哲敏,董晓霞,等. 中国农产品在产销间价格传导机制研究[J]. 资源科学,2010,32(11):2092-2099.
- [2] 刘瑶. 我国农产品价格波动机制研究——基于 SVAR 模型[J]. 山东社会科学,2017(4):146-151.
- [3] 刘海清,方佳. 基于指数平滑模型的海南省芒果价格预测[J]. 热带农业科学,2010,30(1):79-81.
- [4] 刘峰,王儒敬,李传席. ARIMA 模型在农产品价格预测中的应用[J]. 计算机工程与应用,2009(25):242-243,252.
- [5] CHOI H K. Stock Price Correlation Coefficient Prediction with ARIMA-LSTM Hybrid Model[C]// Computational Engineering, Finance, and Science. 2018.
- [6] LI D Y, XIE L Y, QIAN S Y, et al. Design and Implementation of Distributed Crawler System Based on Scrapy[J]. Journal of Hubei University for Nationalities (Natural Science Edition), 2017(3).
- [7] KIM H Y, CHANG H W. Forecasting the Volatility of Stock Price Index: A Hybrid Model Integrating LSTM with Multiple GARCH-Type Models[J]. Expert Systems with Applications, 2018, 103: S0957417418301416.
- [8] YUE W, SUN Y, LIU Z, et al. Dynamic Graph CNN for Learning on Point Clouds[C]// Computer Vision and Pattern Recognition. 2018.
- [9] LOPEZ M M, KALITA J. Deep Learning applied to NLP[J]. Computation and Language, 2017.

(下转第 71 页)

¹⁾ nc.mofcom.gov.cn

²⁾ www.zgncpw.com

³⁾ zdscxx.moa.gov.cn:8080

⁴⁾ www.weather.com.cn

文所提方法具有较好的有效性和可行性。

本文从短文本特征词之间的依赖度出发,基于贝叶斯网进行短文本特征扩展。如何将此方法用于不同领域的短文本是以后要开展的工作。

参 考 文 献

- [1] SEVERYN A, MOSCHITTI A. Learning to Rank Short Text Pairs with Convolutional Deep Neural Networks[C]// The International ACM SIGIR Conference. 2015:373-382.
 - [2] ZHANG W, XUE G R, XUE G R, et al. Advertising Keywords Recommendation for Short-Text Web Pages Using Wikipedia [J]. *Acm Transactions on Intelligent Systems & Technology*, 2012, 3(2):36:1-36:25.
 - [3] NGUYEN T H, GRISHMAN R. Relation Extraction: Perspective from Convolutional Neural Networks[C]// The Workshop on Vector Space Modeling for Natural Language Processing. 2015:39-48.
 - [4] MA H, JI Y, LI X, et al. A Microblog Hot Topic Detection Algorithm Based on Discrete Particle Swarm Optimization[C]// Pacific Rim International Conference on Trends in Artificial Intelligence. 2016:271-282.
 - [5] MA J L, LIU J L, YU C H. An efficient algorithm for Chinese text clustering [J]. *Computer Engineering & Science*, 2013, 35(2):103-108.
 - [6] 高永兵, 钟振华, 王宇, 等. 基于混合方法的中文微博自动摘要技术研究[J]. *计算机工程与科学*, 2016, 38(6):1257-1261.
 - [7] 王仲远, 程健鹏, 王海勋, 等. 短文本理解研究[J]. *计算机研究与发展*, 2016, 53(2):262-269.
 - [8] YU Z, WANG H, LIN X, et al. Understanding short texts through semantic enrichment and hashing [J]. *IEEE Transactions on Knowledge & Data Engineering*, 2016, 28(2):566-579.
 - [9] WANG Y, HUANG H, FENG C. Query Expansion Based on a Feedback Concept Model for Microblog Retrieval[C]// International Conference on World Wide Web. 2017:559-568.
 - [10] 崔婉秋, 杜军平, 寇菲菲, 等. 面向微博短文本的社交与概念化语义扩展搜索方法[J]. *计算机研究与发展*, 2018, 55(8):1641-1652.
 - [11] 吕超镇, 姬东鸿, 吴飞飞. 基于 LDA 特征扩展的短文本分类[J]. *计算机工程与应用*, 2015, 51(4):123-127.
 - [12] XU K, FENG Y, HUANG S, et al. Semantic Relation Classification via Convolutional Neural Networks with Simple Negative Sampling[J]. *Computer Science*, 2015, 71(7):941-949.
 - [13] SRIRAM B, FUHRY D, DEMIR E, et al. Short text classification in twitter to improve information filtering[C]// International ACM SIGIR Conference on Research and Development in Information Retrieval. 2010:841-842.
 - [14] ZHANG W, XU W, CHEN G, et al. A Feature Extraction Method Based on Word Embedding for Word Similarity Computing [J]. *Communications in Computer & Information Science*, 2014, 496:160-167.
 - [15] 袁满, 欧阳元新, 熊璋, 等. 一种基于频繁词集的短文本特征扩展方法[J]. *东南大学学报(自然科学版)*, 2014, 44(2):256-260.
 - [16] 郭永辉. 面向短文本分类的特征扩展方法[D]. 哈尔滨:哈尔滨工业大学, 2013.
 - [17] MENDES E. Introduction to Bayesian Networks[J]. *Medical Imaging Technology*, 2014, 21(2):1-5.
 - [18] PEARL J. Probabilistic Reasoning in Intelligent Systems[M]. Morgan Kaufmann Publishers, 1988:1022-1027.
 - [19] YI Z H, WEI W L, XI C Y, et al. Research Progress of Probabilistic Graphical Models: A Survey [J]. *Journal of Software*, 2013, 24(11):2476-2497.
 - [20] TANG B, KAY S, HE H. Toward Optimal Feature Selection in Naive Bayes for Text Categorization[J]. *IEEE Transactions on Knowledge & Data Engineering*, 2016, 28(9):2508-2521.
 - [21] 陈为, 朱标, 张宏鑫. BN-Mapping: 基于贝叶斯网络的地理空间数据可视分析[J]. *计算机学报*, 2016(7):1281-1293.
 - [22] 王双成, 高端, 杜瑞杰. 具有超父结点时间序列贝叶斯网络集成回归模型[J]. *计算机学报*, 2017, 40(12):2748-2761.
 - [23] HECKERMAN D, DAN G, CHICKERING D M. Learning Bayesian networks: The combination of knowledge and statistical data[J]. *Machine Learning*, 1995, 20(3):197-243.
 - [24] BLITZER J, DREDZE M, PEREIRA F. Biographies, Bollywood, Boom-boxes and Blenders: Domain Adaptation for Sentiment Classification[C]// Proceedings of ACL'07. 2007.
-
- (上接第 65 页)
- [10] 陈卫华, 徐国祥. 基于深度学习和股票论坛数据的股市波动率预测精度研究[J]. *管理世界*, 2018(1):180-181.
 - [11] 王国栋, 韩斌, 孙文赞. 基于 LSTM 的舰船运动姿态短期预测 [J]. *舰船科学技术*, 2017(7):69-72.
 - [12] 陆泽楠, 商玉林. 基于 LSTM 神经网络模型的钢铁价格预测 [J]. *科技视界*, 2017(13):116-117.
 - [13] CAO C Y, LV Q. Using Bidirectional LSTM Deep Neural Network for Protein Residue Contact Prediction [J]. *Journal of Chinese Computer Systems*, 2017(3):531-535.
 - [14] KONG D J, TANG S L, WU Fei. Location Prediction via Generative Adversarial Network with Spatial Temporal Embedding [J]. *Pattern Recognition and Artificial Intelligence*, 2018(1):49-60.
 - [15] NEIL D, PFEIFFER M, LIU S C. Phased LSTM: Accelerating Recurrent Network Training for Long or Event-based Sequences [C]// Advances in Neural Information Processing Systems 29 (NIPS 2016). 2016.
 - [16] HUANG Y S, CHOU S Y, YANG Y H. Pop Music Highlighter: Marking the Emotion Keypoints[J]. *Transactions of the International Society for Music Information Retrieval*, 2018, 1(1):68-78.
 - [17] PERSIO L D, HONCHAR O. Analysis of recurrent neural networks for short-term energy load forecasting[C]// American Institute of Physics Conference Series. 2017.
 - [18] MIRSAMADI S, BARSOUM E, ZHANG C. Automatic Speech Emotion Recognition Using Recurrent Neural Networks with Local Attention[C]// ICASSP. IEEE, 2017.
 - [19] HOCHREITER S, SCHMIDHUBER J. Long Short-term Memory [J]. *Neural Computation*, 1997, 9(8):1735-1780.