

doi:10.16055/j.issn.1672-058X.2020.0001.012

基于神经网络研究人民币汇率对企债收益的影响

周 颖,沐年国

(上海理工大学 管理学院,上海 200093)

摘 要:为了研究企业债券市场,并针对汇率波动对企债市场的影响,提出建立 LSTM 和 GRU 两种神经网络模型;首先证明了它们对于企业债券市场收益的研究具有良好的拟合和预测效果,再将人民币兑美元的汇率数据作为神经网络的输入变量之一,验证人民币汇率对企债市场收益的影响,并比较两种模型的预测效果;结果显示:加入汇率指标后,两种模型不仅能捕捉收益趋势,同时都在数值上也更加精准可靠。实证研究表明,目前在研究我国企业债券市场时,人民币汇率是不可忽略的影响因素,并且相较而言 GRU 模型的结果更为精准。

关键词:汇率;上证企债指数;对数收益率;LSTM;GRU

中图分类号:TP183

文献标志码:A

文章编号:1672-058X(2020)01-0071-07

0 引 言

汇率作为经济市场上的重要角色对各大市场都具有一定影响力,例如,Satish Kumar^[1]研究了油价汇率和股价的关系;Zachary McGurk^[2]探究了房地产与汇率市场的联系等。自 2005 年起,我国开始实行以市场供求为基础的浮动汇率制度,为此,于同年 7 月 21 日中央银行宣布进行第一次汇改,导致人民币汇率整体开始趋于贬值,从汇改之前的 6.768 8 降低到 6.768 1,证券市场也迅速做出反应,上证 A 股指数从 3 398.418 降低到 3 931.177。2015 年的 8 月 11 日,国家再次突然宣布实行汇改政策,据数据统计,人民币兑美元汇率整体降幅达到 1.44%。与此同时,沪深 300 指数整体呈现出上升的态势。以上信息表明,人民币汇率对我国金融市场具有一定影响力。中国债券作为彭博巴克莱全球综合指数中的第四大计价货币债券^[3],汇率对

其的影响值得我们深入考量。杨炳铎等^[4]研究发现人民币实际汇率是债券收益预测的重要变量之一。近年来,企业债券市场经过不断地创新、改革与发展,现已成为公司融资的第二渠道,较其他渠道而言,企业债券具有融资规模大、期限长、成本低等优点。市场中现有债券余额规模达到 60 万亿,企业债券已经成为我国多层次资本市场上必不可少的融资工具之一。本文将人民币汇率的影响纳入企债收益的影响因素之中,深入研究汇率对企债收益波动影响。

目前,国内外学者提出了各种不同的模型对汇率与金融市场波动之间的关系进行了大量系统研究,且成果颇丰。国外的研究中 Dornbusch 和 Fisher^[5]从微观角度出发,提出了一个以流量为导向的模型,重点研究汇率对进出口贸易的影响,进而对股票价格的影响。Flavin 等^[6]利用马尔可夫变换模型研究了东亚地区股票市场与外汇市场的关系,发现在波动期间,股票市场与外汇市场的相互

收稿日期:2019-05-16;修回日期:2019-09-09.

作者简介:周颖(1994—),女,江苏南通人,博士研究生,从事经济统计研究.

影响具有明显的溢出效应。KOLLIAS 等^[7]利用基于欧洲美元汇率和欧洲股票综合指数数据的滚动分析方法研究了汇率与股票市场的关系,并证明了两两者之间的相互因果关系。国内的研究中,王红等^[8]利用 TVP-SV-VAR 实证研究汇率预期对资产价格的时变影响,得出预期汇率升值对中国股票价格具有抑制作用的结论。吴丽华等^[9]研究了人民币汇率、短期资本与股票价格之间的相互作用,发现三者之间的相互作用随时间的变化而变化。不止于此,还有不少研究都建立了金融市场与汇率的关系。但回顾多数研究,大多针对股票市场与汇率。陈卫华^[10]在高频波动率预测领域,首次运用深度学习对波动率进行样本外预测,并将预测结果与 19 种经典模型作对比。从对实际应用的贡献来说,深度学习可能是机器学习领域最近这 10 年来最成功的研究方向^[11]。随着智能时代来临以及金融数据分析需求提升,深度学习已经成为金融领域中的应用前沿^[12]。本文将人民币兑美元的汇率数据作为神经网络的输入变量之一,验证人民币汇率对企债市场收益的影响,并且比较 LSTM 和 GRU 两种神经网络的预测效果。

1 模型介绍

1.1 LSTM 神经网络模型

传统的 BP 神经网络原理较简单,虽然理论上它可以逼近任意的连续函数,但也存在信息单向流动、收敛速度慢、容易陷入局部极小值点等缺点^[13]。与 BP 神经网络相比,循环神经网络(RNN)添加了自连接隐藏层,隐藏层的反馈不仅参与当前时刻的输出还会成为下一时刻的隐藏层的一部分,如图 1 所示,理论上讲,RNN 可以完整地记住任何长序列的信息。然而,在实际操作中由于 RNN 存在梯度消失的问题,很难记住长距离的信息^[14]。为了解决这个问题,HOCHREITER 等^[15]提出了长短期记忆(LSTM),将 RNN 网络层中对信息处理的部分变得更加复杂、精细,如图 2 所示,LSTM 在挖掘序列数据长期依赖关系中极具优势^[16],建模精度方面要高

于 VAR 模型^[17]。它能在误差反向传播时,将后续时间计算出的误差选择性地反馈到更早的时间中,进行长时间的学习来调整网络,在股票价格趋势预测中取得了良好效果^[18]。




图 1 RNN 两个时刻展开图

Fig. 1 Two-time development of RNN




图 2 LSTM 内部结构图

Fig. 2 LSTM internal structure diagram

LSTM 同样由输入层、隐藏层和输出层组成。在隐藏层模块中,LSTM 增加了能够进行信息选择的“门”结构。一个 LSTM 神经元中包含了一个信息储藏单位、一个连接单元、遗忘门、输入门和输出门。在 t 时刻,遗忘门会读取 t 时刻的输入 x_t 以及上一时刻的输出 h_{t-1} 经过对应权重矩阵 W 处理后加上对应偏移向量 b ,通过 sigmoid 函数(σ),返回一个介于 0 和 1 之间的遗忘状态值 f_t (0 表示完全遗忘,1 表示完全保留)计算方式如下:

$$f_t = \sigma(W_i * [h_{t-1}, x_t] + b_f) \quad (1)$$

输入门同样包含 σ 函数,经过与以上类似的处理后生成一个输入状态值 i_t ,如式(2)所示,该值同

样处于 0 到 1 之间。

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2)$$

此时单元状态 C_{t-1} 仍然处于 $t-1$ 的时刻。遗忘状态值 f_t 将决定 C_{t-1} 的信息保留程度,同时将通过一个 \tanh 层生成新备选输入信息 \tilde{C}_t , 如式(3)所示。 t 时刻的单元状态由这两部分相加组成:

$$\tilde{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

输出门也包含 σ 函数计算得输出状态值 O_t , 用于决定输出什么值。具体过程如下所示, t 时刻输出值为 h_t 。

$$O_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t * \tanh(C_t) \quad (6)$$

1.2 GRU 神经网络模型

递归神经网络模型 (GRU), 在继承 RNN 对时间序列优秀记忆能力的前提下, GRU 克服了时间序列的长期依赖问题^[19]。与 LSTM 不同的是, 它不具备专门存储的记忆细胞, 并且将遗忘门与输入门结合形成新的“更新门”和“重置门”如图 3 所示。




图 3 GRU 内部结构图

Fig. 3 Internal structure of the GRU

信息的保留与通过程度同样由“门”决定, 当更新门 z_t 与重置门 r_t 数值趋向于 1 时表示保留信息越多, 趋向于 0 则相反, 其过程如下:

$$z_t = \sigma(W_{xz} x_t + W_{hz} h_{t-1} + b_z) \quad (7)$$

$$r_t = \sigma(W_{xr} x_t + W_{hr} h_{t-1} + b_r) \quad (8)$$

重置门的值产生后仍然会通过 \tanh 层产生一个值作为下一个时刻更新的备选状态 \tilde{h}_t , 最后通过更新门产生新的隐藏层状态 h_t , 如下:

$$\tilde{h}_t = \tanh(W x_t + U(r_t \odot h_{t-1}) + b_r) \quad (9)$$

$$h_t = z_t h_{t-1} + (1 - z_t) \tilde{h}_t \quad (10)$$

2 实证分析与比较

2.1 数据的获取与预处理

为了验证模型的有效性, 验证人民币汇率对我国企债市场的影响, 选取人民币兑美元自 2003 年 6 月 9 日开始到 2019 年 4 月 19 日的每日汇率数据, 变量包括收盘价、最高价、最低价、开盘价。同一时间段的上证企债指数数据包含收盘价、最高价、最低价、开盘价、前收盘、涨跌额、涨跌幅、成交量、成交金额 9 个变量。采用这些数据对模型进行验证。

将样本数据标准化处理, 使所有数据处于 (0, 1) 区间, 并服从标准正态分布。计算过程中采用对数收益率作为因变量。

2.2 特征选择

为了准确度量汇率变动对企业债市场是否具有影响, 降低噪声, 首先采用主成分分析法对汇率数据进行降维处理, 筛选出最具有代表性的汇率度量指标, 剔除不必要的因素, 将选出的汇率特征作为神经网络的输入变量之一融入模型中。主成分分析处理结果如表 1。

表 1 方差贡献表

Table 1 Variance contribution table

特征	方差贡献率
收盘价	0.999 962 380 058 006
开盘价	0.000 018 520 729 680 339 1
最高点	0.000 016 897 957 271 005 9
最低点	0.000 002 201 255 042 688

由表 1 不难看出, 人民币兑美元汇率的收盘价对方差的贡献率最高几乎接近于 1, 而其他 3 个特征方差贡献很小接近于 0, 因此, 在本次研究中将保留汇率数据的收盘价作为汇率的度量指标, 剔除其他 3 个变量以减少线性相关的可能并便于计算。

2.3 模型搭建

在实证研究过程中, 处理过后, 样本数据集共

3 858 条,整体分为 3 个部分:训练集大小为 3 000,验证集大小为 764,测试集大小为 5,并且设定时间延迟为 5 天。

在 Python 中的 Keras 框架下完成 LSTM 和 GRU 模型的搭建并计算。用平均绝对误差 (MAE) 作为度量函数来评价模型的预测性能;为估量预测值与真实值的差异,编译均方误差 (MSE) 当作损失函数;激活函数采用 tanh 函数;不同的训练次数会影响时间复杂度与预测的精确度,通过 100 次训练,每次样本个数为 90 个,通过损失函数值找出最合适的 epochs 值;此外,为防止模型过拟合,操作中给模型添加了正则项,设定输入层与隐藏层间的 dropout 值为 0.2,隐藏层与隐藏层间 dropout 值为 0.1。

$$P_{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (8)$$

$$P_{MSE} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (9)$$

其中, \hat{y}_i 代表预测值, y_i 代表真实值, N 代表预测值与真实值的对比次数。

2.4 对比及结果分析

为了能更鲜明地反映出汇率波动对企债市场的影响,先以上证企债指数中常见的 9 个变量作为两种模型的输入变量,其中包含变量收盘价、最高价、最低价、开盘价、前收盘、涨跌额、涨跌幅、成交量、成交金额数据预测企业债的对数收益率。验证集及损失函数结果如图 3—图 6 所示。

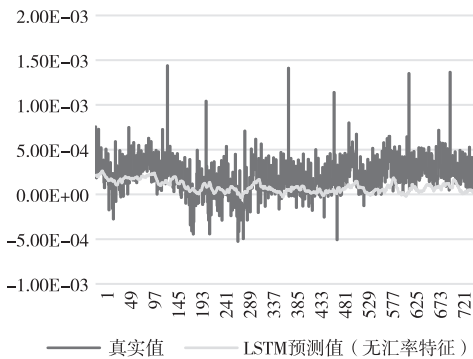


图 4 LSTM 验证集预测结果图

Fig. 4 LSTM validation set prediction results graph

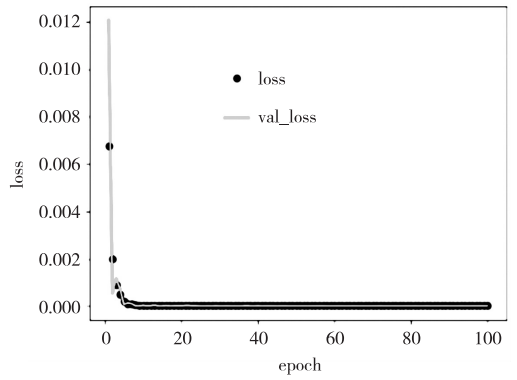


图 5 LSTM 损失与训练次数关系图

Fig. 5 Relationship between LSTM loss and training times




图 6 GRU 验证集预测结果图

Fig. 6 GRU verification set prediction result graph

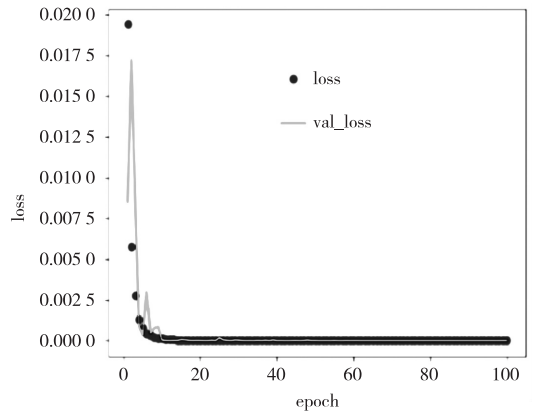


图 7 GRU 损失与训练次数关系图

Fig. 7 Relationship between GRU loss and training times

由图 5 和图 7 都可以看出在训练 20 次之后损失函数的波动幅度已经很小,几乎无明显变化,选择合适的训练次数:LSTM 为 92 次;GRU 为 87 次,得出验证集预测结果与真实值对比如图 4 和图 6 所示,可以看到两种模型都能捕捉到基本趋势,预测效果良好,GRU 模型的预测结果在数值上和走势上都更为拟合。

在如上所示的基础上,在原先的 9 个基础属性

变量里加入了汇率指标即与上证指数同一时期的汇率收盘价,再次对企业债券的对数收益率进行预测,获得结果如图 8—图 11 所示,100 次训练后同样设定合适的训练次数:LSTM 83 次,GRU 87 次。从图 8、图 9 可以明显看出无论是 LSTM 模型还是 GRU 模型加入汇率特征后,预测值的度都有了明显提高,在捕捉到趋势的同时在数值上也更加精准可靠。这也证明人民币汇率对我国企债市场具有一定影响作用。对比两种模型的预测结果,GRU 模型效果更优,加入汇率特征后 GRU 的拟合度提升效果也更加显著,GRU 的稳定性更高^[20]。




图 11 GRU 损失与训练次数关系图

Fig. 11 Relationship between GRU loss and training times

3 结束语

金融市场与日常生活息息相关,多年来,各界学者们对各大金融衍生品的预测模型研究更是多种多样。首先利用两种非参数神经网络模型 LSTM 和 GRU,研究了企业债券市场收益率的问题,并证明了两种模型的有效性,但相对而言 GRU 模型的精准度更高。进一步考虑了人民币汇率的影响后,通过主成分分析,在模型中加入了人民币兑美元汇率的每日收盘价作为汇率指标,结果显示,两种模型的预测误差都进一步缩小,GRU 模型预测误差降低更明显。这反映出目前在研究我国企业债券市场时,人民币汇率是不可忽略的影响因素;并且在企业债券市场未来研究中,非参数模型拟合效果出众,是不可或缺的重要方法之一,本文研究结果对金融研究中,神经网络模型的选择提供一定的参考,此外,需要扩展不同数据集,引入更多参量融入模型中使得该模型的稳定性和准确性大大提高,这对我国金融市场的发展具有重要参考价值。

参考文献 (References):

[1] KUMAR S. Asymmetric Impact of Oil Prices on Exchange Rate and Stock Prices [J]. Quarterly Review of Economics and Finance,2019,72

[2] MCGURK Z. US Real Estate Inflation Prediction: Exchange Rates and Net Foreign Assets [J]. Quarterly Review of Economics and Finance,2019




图 8 LSTM 验证集预测结果图 (加汇率特征)

Fig. 8 LSTM validation set prediction results graph (plus exchange rate characteristics)

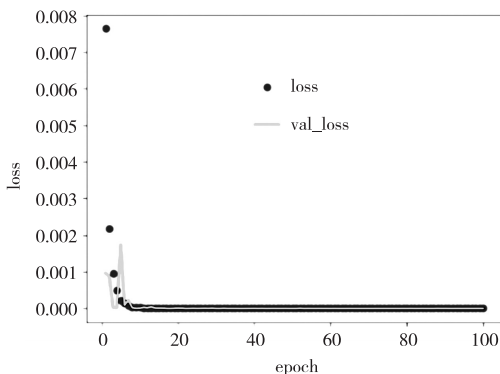


图 9 LSTM 损失与训练次数关系图

Fig. 9 Relationship between LSTM loss and training times




图 10 GRU 验证集预测结果图 (加汇率特征)

Fig. 10 GRU verification set forecast results chart (plus exchange rate characteristics)

- [3] 张国云. 清风明月还诗债——从企业债说起[J]. 中国发展观察, 2019(8): 37—39
ZHANG G Y. Poetry on Wind, Moon and Returning Debts—from the Perspective of Corporate Bonds [J]. China Development Watch, 2019 (8): 37—39 (in Chinese)
- [4] 杨炳铎, 汤教泉. 中国债券收益率的可预测性检验[J]. 系统工程理论与实践, 2019, 39(4): 970—985
YANG B Z, TANG J Q. Predictability Test of China Bond Yield [J]. Systems Engineering Theory and Practice, 2019, 39(4): 970—985 (in Chinese)
- [5] DORNBUSCH R, FISHER S. Exchange Rates and the Current Account[J]. American Economic Review, 1980 (70): 960—971
- [6] FLAVIN T J, PANOPOULOU E, UNALMIS D. On the Stability of Domestic Financial Market Linkages in the Presence of Time-varying Volatility[J]. Emerging Markets Review, 2008(9): 280—301
- [7] KOLLIAS C, MYLONIDIS N, PALEOLOGUO S M. The Nexus between Exchange Rates and Stock Markets: Evidence from the Euro-Dollar Rate and Composite European Stock Indices Using Rolling Analysis [J]. Journal of Economics and Finance, 2012, 36 (1): 136—147
- [8] 王红, 丁媛, 汪洋. 中美利差、汇率预期对资产价格的时变影响研究[J]. 武汉金融, 2017 (9): 9—16
WANG H, DING Y, WANG Y. Study on the Time-varying Impact of Sino-US Spread and Exchange Rate Expectation on Asset Prices[J]. Wuhan Finance, 2017 (9): 9—16
- [9] 吴丽华, 傅广敏. 人民币汇率、短期资本与股价互动[J]. 经济研究, 2014 (11): 72—86
WU L H, FU G M. Interaction between RMB Exchange Rate, Short-term Capital and Stock Price [J]. Economic Research, 2014 (11): 72—86 (in Chinese)
- [10] 陈卫华. 基于深度学习的上证综指波动率预测效果比较研究[J]. 统计与信息论坛, 2018, 33(5): 99—106
CHEN W H. Comparative Study on the Prediction of Volatility of Shanghai Composite Index Based on Deep Learning [J]. Journal of Statistics & Information Technology, 2018, 33(5): 99—106 (in Chinese)
- [11] 余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799—1804
YU K, JIA L, CHEN Y Q, et al. Yesterday, Today and Tomorrow of Deep Learning [J]. Computer Research and Development, 2013, 50(9): 1799—1804 (in Chinese)
- [12] 苏治, 卢曼, 李德轩. 深度学习的金融实证应用: 动态, 贡献与展望[J]. 金融研究, 2017 (5): 111—126
SU Z, LU M, LI D X. Financial Empirical Application of Deep Learning: Dynamics, Contribution and Prospect [J]. Journal of Finance Research, 2017 (5): 111—126 (in Chinese)
- [13] 陈骏, 傅成华, 郭辉. 智能优化算法优化 BP 神经网络的函数逼近能力研究[J]. 软件导刊, 2015, 14(4): 70—72
CHEN J, FU C H, GUO H. Study on the Function Approximation Capability of BP Neural Network Optimized by Intelligent Optimization Algorithm [J]. Software Guide, 2015, 14(4): 70—72 (in Chinese)
- [14] KOLEN J, KREMER S. Gradient Flow in Recurrent Nets: The Difficulty of Learning Long Term Dependencies [M]. Plano: Wiley-IEEE Press, 2001
- [15] Hochreiter S, Schmidhuber J. Long Short-term Memory [J]. Neural Computation, 1997, 12(9): 1735—1780
- [16] 杨青, 王晨蔚. 基于深度学习 LSTM 神经网络的全球股票指数预测研究[J]. 统计研究, 2019, 36(3): 65—77.
YANG Q, WANG C W. Global Stock Index Prediction Based on Deep Learning LSTM Neural Network [J]. Statistical Research, 2019, 36(3): 65—77 (in Chinese)
- [17] 金雪军, 曹赢. 美国扩张性货币政策对中国通胀的影响——基于深度长短期记忆神经网络的分析[J]. 上海金融, 2016 (3): 80—83
JIN X J, CAO Y. The Impact of American Expansionary Monetary Policy on China's Inflation——Based on the Analysis of Deep Long-term and Short-Term Memory Neural Networks [J]. Shanghai Finance, 2016 (3): 80—83 (in Chinese)
- [18] 邓凤欣, 王洪良. LSTM 神经网络在股票价格趋势预测中的应用——基于美港股票市场个股数据的研究[J]. 金融经济, 2018(14): 96—98

- DENG F X, WANG H L. The Application of LSTM Neural Network in Stock Price Trend Forecast: Based on the Research of Stock Market Data in US and Hong Kong Stock Market[J]. Financial Economy, 2018(14): 96—98 (in Chinese)
- [19] 张金磊, 罗玉玲, 付强. 基于门控循环单元神经网络的金融时间序列预测[J]. 广西师范大学学报(自然科学版), 2019, 37(2): 82—89.
- ZHANG J L, LUO Y L, FU Q. Financial Time Series Prediction Based on Neural Network of Gated Cycling Unit [J]. Journal of Guangxi Normal University (Natural Science Edition), 2019, 37(2): 82—89 (in Chinese)
- [20] 黎镭, 陈蔼祥, 李伟书, 等. GRU 递归神经网络对股票收盘价的预测研究[J]. 计算机与现代化, 2018(11): 103—108
- LI L, CHEN A X, LI W S, et al. Study on the Prediction of Stock Closing Price by GRU Recurrent Neural Network [J]. Computer and Modernization, 2018(11): 103—108 (in Chinese)

Study on the Influence of RMB Exchange Rate on Enterprise Bond Yield Based on Neural Network

ZHOU Ying¹, MU Nian-guo²

(School of Management, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: In order to study the corporate bond market and deal with the impact of exchange rate fluctuations on the corporate bond market, we propose to establish two neural network models of LSTM and GRU, first demonstrating that they have a good fit and prediction effect on the research of corporate bond market returns. Using the exchange rate data of RMB against the US dollar as one of the input variables of the neural network, we verify the impact of the RMB exchange rate on the corporate bond market returns and compare the prediction effects of the two models. The results show that after adding the exchange rate indicator, the two models can not only capture the yield trend, but also the value is more accurate and reliable. Empirical studies show that the RMB exchange rate is a non-negligible factor in the study of China's corporate bond market, and the results of the GRU model are more accurate.

Key words: exchange rate; SSE corporate bond index; logarithmic yield; LSTM; GRU

责任编辑: 罗姗姗

引用本文/Cite this paper:

周颖, 沐年国. 基于神经网络研究人民币汇率对企债收益的影响[J]. 重庆工商大学学报(自然科学版), 2020, 37(1): 71—77
 ZHOU Y, MU N G. Study on the Influence of RMB Exchange Rate on Enterprise Bond Yield Based on Neural Network[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2020, 37(1): 71—77