

城市高质量发展对经济增长的影响及预测

胡洁聆

(四川大学公共管理学院, 成都 610065)

摘要: 为了评估城市的发展状况及其对经济增长的影响, 结合创新、协调、绿色、开放和共享五大新发展理念构建城市高质量发展评价指标体系, 通过最小二乘法(OLS)对指标进行筛选, 采用深度学习的方法探究城市高质量发展对经济增长的影响及预测效果, 研究对比了多变量 LSTM(long short-term memory)神经网络模型和改进的多变量 LSTM 神经网络模型的预测结果和精度, 结果发现融合了注意力机制的多变量 LSTM 神经网络模型的预测效果更好, 模型的均方根误差 RMSE 减少 25%, 决定系数 R^2 达到 0.9856。

关键词: 城市高质量发展; 深度学习; LSTM 模型; 注意力机制; 经济增长

中图分类号: TP183; F127 **文献标志码:** A **文章编号:** 1671-1807(2025)08-0313-08

立足于“十四五”规划, 城市作为经济、政治、文化、社会、生态发展的重要载体、核心引擎以及有效衡量评估单位, 聚集了重要的区域劳动人口以及产业资源, 城市的高质量发展通过优化城乡结构、提高配置效率、完善基础设施等方面影响着地区整体的经济增长。由于中国在世界经济发展中不可忽视的国际地位, 新常态下的经济增长情况将受到全世界的关注, 因此预测未来各城市经济增长的模型构建是学术界亟须研究的领域。

1 文献综述

对于经济增长的预测方法主要分为两个类型, 一是从宏观经济建模角度进行经济增长的预测, 如通过非线性的生产函数^[1]、宏观经济周期分析^[2]、实证分析法^[3]、投入产出法、专家分析法^[4]等方法预测经济未来增长趋势。二是从微观数据建模角度来分析预测, 如灰色预测模型^[5]、ARIMA(autoregressive integrated moving average) 时间序列预测模型^[6]、BP 神经网络^[7]等。除了传统的模型, 近些年机器学习的方法例如支持向量机、贝叶斯算法、神经网络等方法逐渐应用于 GDP 预测领域^[8]。在深度学习方法上, 肖争艳等学者发现使用长短期记忆(long short term memory, LSTM)神经网络模型可以提高宏观经济预测的精度^[9], 深度学习未来在该领域仍有发展的空间。

金磊^[10]从经济学角度研究得出高质量发展是可以从经济结构发展方式、社会结构和动力状态三个方面都能满足人民持续增长的美好生活需要的

发展。康艳青等^[11]采用熵值法和锡尔系数分析法整体评估了黄河流域各等级城市群的高质量发展状况。张跃胜等^[12]认为城市的高质量发展是未来经济社会发展的重中之重, 是社会经济发展的重要核心动力源泉。

城市高质量发展对于经济增长存在显著的影响, 本文依据新发展理念构建城市高质量发展评价指标体系, 构建预测城市经济增长的模型并进行城市 GDP 预测, 通过预测误差和模型拟合优度 R^2 等指标来衡量模型的准确性, 并得出相关研究结论。

2 研究方法

2.1 LSTM 模型

Garves 和 Schmidhuber^[13]提出的 LSTM(long short-term memory)模型和通过特殊的记忆单元以及“三个门”结构——输入门、遗忘门和输出门, 使得信息有选择的被“记忆”或被“遗忘”, 实现对于具有短期和长期依赖数据的精准筛选。LSTM 模型的核心思想是引入称为“记忆单元”的结构, 这些单元可以在长时间范围内存储信息, 并通过门控机制来控制信息的输入、输出和遗忘。

遗忘门(forget gate): 用于决定模型要从记忆单元中删除哪些信息。结合前一时间的输出和当前时间的输入, 通过 Sigmoid 函数的非线性映射, 输出介于 0 和 1 之间的值, 1 表示记住了重要的信息, 0 表示忘记了不重要的信息。

输入门(input gate): 用于决定模型要将当前输入中的哪些信息添加到记忆单元中。

收稿日期: 2024-10-20

作者简介: 胡洁聆(2002—), 重庆人, 硕士研究生, 研究方向为经济情报。

输出门(output gate): 用于决定模型将从记忆单元中输出哪些信息。

采用多变量输入单变量输出的 LSTM 模型, LSTM 神经网络结构如图 1 所示, 在这个模型中, 每个输入数据是包含多列特征和多行数据的矩阵数据, LSTM 单元会处理输入信号并进行生成隐藏状态, 最终经过全连接层, 生成相应的输出。

(1)输入门:

$$i_t = \sigma(W_{i_i} x_t + b_{i_i} + W_{h_i} h_{t-1} + b_{h_i}) \quad (1)$$

式中: i_t 为输入门的激活值; W_{i_i} 为输入门权重矩阵, 用于输入向量 x_t ; x_t 为时间 t 的输入向量; b_{i_i} 为输入的偏置向量; W_{h_i} 为输入门权重矩阵, 用于前一隐藏状态 h_{t-1} ; h_{t-1} 为时间 $t-1$ 的隐藏状态; b_{h_i} 为输入门偏置向量。

(2)遗忘门:

$$f_t = \sigma(W_{f_i} x_t + b_{f_i} + W_{h_f} h_{t-1} + b_{h_f}) \quad (2)$$

式中: f_t 为遗忘门的激活值; W_{f_i} 为遗忘门权重矩阵, 用于输入向量 x_t ; b_{f_i} 为遗忘门权重矩阵, 用于前一隐藏状态 h_{t-1} ; b_{h_f} 为遗忘门偏置向量。

(3)细胞状态更新:

$$\tilde{c}_t = \tanh(W_{i_g} x_t + b_{i_g} + W_{h_g} h_{t-1} + b_{h_g}) \quad (3)$$

式中: \tilde{c}_t 为候选细胞状态; W_{i_g} 为细胞状态更新矩阵, 用于输入向量 x_t ; b_{i_g} 为细胞状态更新偏置向量; W_{h_g} 为细胞状态更新权重矩阵, 用于前一隐藏状态 h_{t-1} ; b_{h_g} 为细胞状态更新偏置向量。

$$c_t = f_t c_{t-1} + i_t \tilde{c}_t \quad (4)$$

式中: c_t 为当前时间步的细胞状态; c_{t-1} 为前一时间步的细胞状态。

(4)输出门:

$$o_t = \sigma(W_{o_i} x_t + b_{o_i} + W_{o_h} h_{t-1} + b_{o_h}) \quad (5)$$

式中: O_t 为输出门的激活值; W_{o_i} 为输出门权重矩阵, 用于输入向量 x_t ; b_{o_i} 为输出门偏置向量; W_{o_h} 为输出门权重矩阵, 用于前一隐藏状态 h_{t-1} ; b_{o_h} 为输出门偏置向量。

(5)多变量 LSTM 模型在 t 时刻的输出:

$$h_t = o_t \tanh c_t \quad (6)$$

式中: h_t 为当前时间步 t 的隐藏状态。

2.2 基于注意力机制的 LSTM 模型

人脑在接受文字或图片信息时, 会自动注意到信息的重要部分, 完成对信息的自动筛选过程。注意力机制是一种模仿人类自身注意力分配的模型, 对于输入数据给予不同程度的注意度并用权重来表示, 通过加权的方法获得概率分布向量^[14]。近年来有学者通过使用注意力机制来构建改进的 LSTM 模型, 通过地铁客流特征和过往的客流量和客流承载数据, 预测站点的客流数据^[15]预测站点的客流数据。基于注意力机制的 LSTM 模型在提高数据的利用率的同时, 优化输出向量从而提高预测精度, 并且由于注意力机制的相对固定性使得其与 LSTM 模型结合可以有效地得出 Attention 进行权重分配^[16]。注意力机制框架如图 2 所示, 构建的融合注意力机制的多变量 LSTM 模型如图 3 所示。

3 指标构建和筛选

3.1 控制变量

由于在现实情况中城市的经济增长情况受到城市地区发展情况等多方面的影响, 为了消除此类因素对于研究的影响, 提高模型预测的准确性, 引入户籍人口、地方财政一般预算支出、地区产业结构、人均流动资产控制变量。




图 2 注意力机制框架

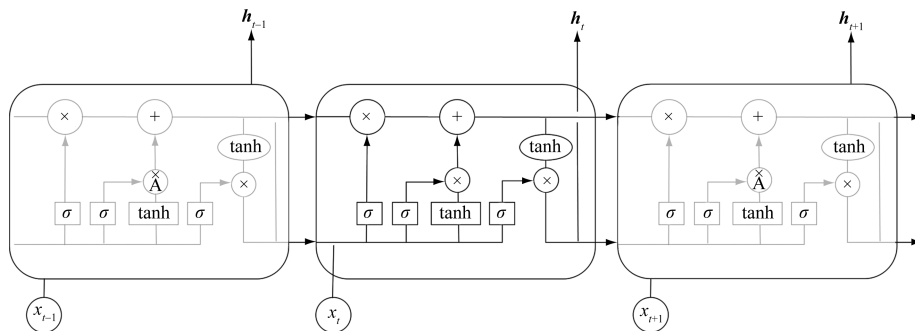


图 1 LSTM 神经网络结构




图3 融合注意力机制的多变量LSTM模型

3.2 城市高质量发展评价指标体系构建

创新是推动社会进步的决定要素，是城市高质量发展的核心动力。协调是城市高质量发展的内在要求，在高质量发展过程中要以区域产业现状为基础，注重解决城市发展短板、发展不平衡等问题。绿色发展是社会可持续长远发展的必要路径。开放是构建世界命运共同体的首要条件，有利于经济和谐稳定发展。共享有利于解决社会公平问题，是社会主义的基本目标，人民充分享受到城市的发展成果对于促进城市高质量发展有着深刻的影响。

细分13个二级指标构建的城市高质量发展评价指标体系如表1所示。

4 模型构建

4.1 样本获取

数据来源于《中国城市统计年鉴》《中国能源统计年鉴》《中国金融统计年鉴》、国家知识产权局、地方统计局、统计公报，北京大学数据金融研究中心等，统计2011—2020年286个城市围绕五大发展理念的相关城市数据作为构建城市高质量发展评价指标体系的数据，由于国内生产总值(GDP)是反映国内经济增长发展水平的重要指标，本文以城市的地区生产总值数据作为衡量城市经济增长的指标。

4.2 指标特征选择

构建体系主要参考已有文献和指标含义，因此为了模型更加精准且简化，通过最小二乘法(OLS)进行指标回归，筛选出对于城市经济增长有较显著影响的指标，对输入深度学习模型的数据指标进行简化，表2是各指标的显著情况。

经过筛选，最终确定输入深度学习模型的数据指标如表3所示。

表1 城市高质量发展评价指标体系

一级指标	二级指标	三级指标	衡量方法
创新发展	创新成果	数字技术创新	数字经济专利申请数
		绿色发明创新	绿色发明申请数
	创新投入	绿色实用新型专利创新	绿色实用新型专利申请数
		R&D经费支持强度	R&D经费支出/GDP
协调发展	产业协调	科学投入强度	科学投入/财政投入
		产业结构	第三产业生产总值/GDP
	城乡协调	产业结构高级化指数	第三产业/第二产业增加值
		人口城镇化水平	城镇化率
绿色发展	绿色金融	城镇登记失业率	城镇登记失业人口/户籍人口
		绿色信贷	环保项目信贷占比
		绿色投资	环境污染治理投资占比
		绿色保险	环境责任保险推广程度
		绿色债券	绿色债券发展程度
	绿色支持	财政环境保护支出占比	
城市污染	工业固体回收	一般工业固体废物综合利用率	
	工业废水排放	工业废水排放量	
	污水处理率	污水处理厂集中处理率	
绿化覆盖	绿化覆盖率	建成区绿化覆盖率	
开放发展	外商直接投资水平	实际利用外资/GDP	
	外资企业	外资企业个数	
	国际互联网	国际互联网率	每百人拥有国际互联网用户数
共享发展	基础设施	互联网相关产出	人均电信业务总量
		移动互联网用户数	每百人移动电话用户数
		数字金融普惠指数	数字金融普惠指数
		公路客运	公路客运量占总人口比例
	教育投入	教育支出	人均教育支出
	医疗保险	医疗保险参保水平	城镇基本医疗保险参保率
个人储蓄	城乡居民储蓄	城乡居民储蓄年末余额	

表2 变量指标回归显著情况

指标	P	指标	P
数字技术创新	0.160	绿色发明创新	0.008**
绿色实用新型专利创新	0.000***	R&D经费支持强度	0.123
科技投入强度	0.000***	产业结构	0.252
产业结构高级化	0.000***	人口城镇化	0.000***
城镇登记失业率	0.104	绿色信贷	0.000***
绿色投资	0.000***	绿色保险	0.610
绿色债券	0.000***	绿色支持	0.000***
工业固体回收	0.000***	工业废水排放	0.000***
污水处理率	0.011*	绿化覆盖率	0.219
外商直接投资水平	0.040*	外资企业	0.000***
国际互联网率	0.418	互联网相关产出	0.001***
移动互联网用户数	0.131	数字金融普惠指数	0.000***
公路客运率	0.626	教育支出	0.848
医疗保险参保水平	0.004**	城乡居民储蓄	0.000***
户籍人口	0.000***	地方财政一般预算支出	0.000***
职工平均工资	0.093	人均流动资产	0.000***

注：*、**、***分别表示10%、5%、1%的显著性水平。

表 3 最终选定变量结果

一级指标	二级指标	三级指标
创新发展	创新成果	数字技术创新
		绿色发明创新
		绿色实用新型专利创新
	创新投入	R&D 经费支持强度
		科学投入强度
协调发展	产业协调	产业结构
		产业结构高级化指数
	城乡协调	人口城镇化水平
		城镇登记失业率
绿色发展	绿色金融	绿色信贷
		绿色投资
		绿色债券
		绿色支持
	城市污染	工业固体回收
		工业废水排放
开放发展	外资水平	外商直接投资水平
		外资企业
		互联网相关产出
共享发展	基础设施	移动互联网用户数
		数字金融普惠指数
	医疗保险	医疗保险参保水平

4.3 数据预处理

4.3.1 数据清洗

数据的质量对于模型训练的准确性有较为重要的影响,在收集完各地级市的指标数据之后对异常值进行删除处理,对空值采用线性插值法处理,最终获得 2 860 条完整有效的数据。

4.3.2 数据滑动窗口

本文收集的数据结构为面板结构,涵盖全国 286 个城市 2011—2020 年的数据,因此采用特殊的滑动窗口方法(图 4)对数据进行预处理,依

据已有数据维度将滑动窗口大小定为 3,滑动步长定为 1,滑动窗口只在同城市的数据集内滑动。例如:以北京 2011—2013 年的多项指标数据作为输入指标,2014 年的 GDP 数据作为模型的输出指标。

经计算,每个城市经过滑动窗口处理后会产生 7 条数据,以 2019 年、2020 年城市 GDP 为测试数据,按照 5:2 的比例划分训练集和测试集,确保每个城市都有相同数量的训练集和测试集,共计 1 430 条训练数据和 572 条测试数据。

4.3.3 数据标准化和反标准化

研究数据来源各异且度量单位差异较大,因此对数据进行归一化处理,统一数据的量纲和数值范围,可以加快模型的收敛速度,提高模型的泛化能力和精确度。采用最大值、最小值归一化的方法,将各特征数据按照一定尺度比例缩放至 0~1,计算公式为

$$x' = \frac{x - \min_value}{\max_value - \min_value} \quad (7)$$

式中: x' 为归一化后的值; x 为原始值; \min_value 为该特征原始数据的最小值; \max_value 为该特征原始数据的最大值。

为了最终 GDP 预测数据的可对比性,同时使用反标准化来对预测数据进行处理,使得模型预测结果回归到原始数据范围内,计算公式为

$$x'' = x'(\max_value - \min_value) + \min_value \quad (8)$$

式中: x'' 为反归一化后的值。

4.4 模型评估指标

对于预测模型的评价问题,学术界通常采用将

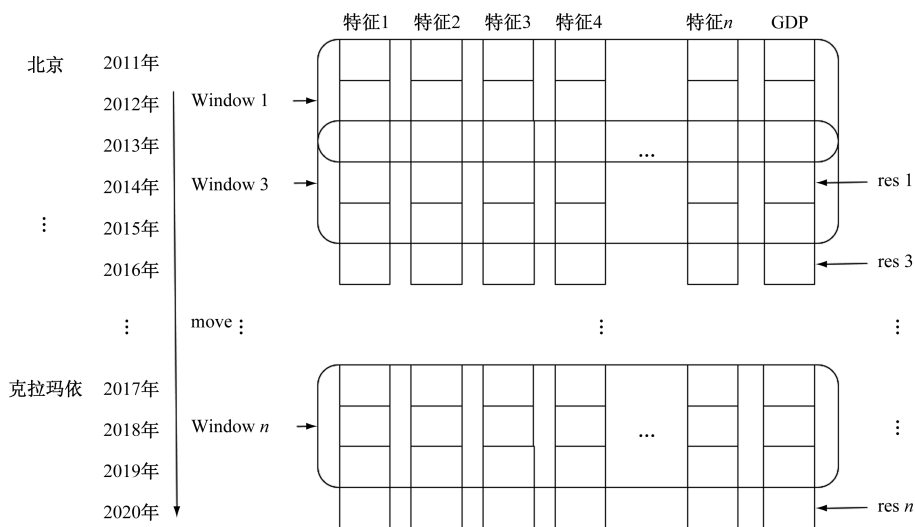


图 4 滑动窗口示意图

预测值和真实值进行对比计算的方法来评价模型的优劣,主要的方法有平均绝对误差(MAE),MAE是指预测值和真实值误差绝对值的均值;均方误差(MSE),MSE是预测误差平方和的平均值;均方根误差(RMSE),RMSE是MSE的平方根,可以衡量预测误差的波动程度;决定系数(R^2), R^2 可以用于评价模型的拟合优度,衡量该模型的拟合精度。采用均方根误差RMSE和决定系数 R^2 共同对模型拟合效果进行评估。

4.5 多变量 LSTM 模型

4.5.1 多变量 LSTM 模型参数设定

根据 OLS 回归的结果,输入变量包括前三年的数字技术创新、产业结构、数字金融指数、GDP 数据等 27 个指标,输出变量为后一年 GDP 数据。经过多次实验对照,最终构建两层 LSTM 结构,每层中包含 50 个神经元,每层 LSTM 结构都使用 L2 正则化项以此减小模型过拟合的风险,损失函数采用平均绝对误差(MAE),使用 Adam 优化器进行编译,将 72 个样本数据打包为一批次进行训练,共训练 40 次,同时使用测试数据进行验证。

4.5.2 多变量 LSTM 模型训练结果

训练完成后,绘制训练集和测试集的损失函数如图 5 所示,发现损失函数快速下降最终趋于收敛,说明模型设置较为合理。

图 6 绘制了所有测试数据集中真实值与预测值的对比情况,为了便于查看更为细致的预测结果与真实值对比,还绘制了局部的真实值和预测值的对比图 7。




图 5 多变量 LSTM 神经网络模型损失值




图 6 多变量 LSTM 神经网络模型真实值和预测值对比




图 7 多变量 LSTM 神经网络模型真实值和预测值局部对比

图 6 所展示的预测结果对比显示对某些 GDP 较高的一线城市的 GDP 预测存在着预测结果与真实 GDP 数据差距较大的情况,且此类的预测值往往大于其真实值。在图 7 的局部对比中可以明显看到对于一般城市大部分通过多变量 LSTM 模型得出的预测值小于真实值。经过预测数据反归一化后与原始 GDP 数据进行对比,测试集在多变量 LSTM 神经网络模型上的均方根误差 RMSE 为 762,拟合优度 R^2 为 0.974 4,模型拟合情况较好,对于各城市 2019 年、2020 年 GDP 的数据的预测效果比较良好。

4.6 基于注意力机制的多变量 LSTM 模型

4.6.1 基于注意力机制的多变量 LSTM 模型参数设定

注意力机制可以帮助多变量时间序列的特征在处理多维度数据时更关注较为重要的信息,使模型更加灵活,可以在每个时间步中动态调整对信息的关注程度,增强模型对输入数据序列的泛化能力。在多变量 LSTM 神经网络模型的基础上引入注意力机制,将 LSTM 层的输出作为注意力机制的输入,再把注意力机制的输出与原始 LSTM 层的输出在最后一个维度上连接,形成新的张量。随后添

加展平层和全连接层匹配输出数据维度,模型的 LSTM 结构和原始的多变量 LSTM 模型参数设定相同,使用 Adam 优化器和均方误差损失来编译模型。如图 8 所示,经过 40 次迭代模型的损失值快速下降并趋于收敛,说明此预测模型设置合理。

4.6.2 基于注意力机制的多变量 LSTM 模型预测结果

绘制该模型的预测对比如图 9 所示,并对与上述多变量 LSTM 模型预测的相同城市数据进行放大如图 10 所示。




图 8 基于注意力机制的多变量 LSTM 神经网络模型损失值




图 9 基于注意力机制的多变量 LSTM 神经网络模型真实值和预测值对比




图 10 基于注意力机制的多变量 LSTM 神经网络模型真实值和预测值局部对比

图9为基于注意力机制的多变量LSTM模型对于城市GDP的预测结果与真实值对比,在对于个别极端GDP数据的预测中,该模型的预测准确度较高,预测值与真实值的差距较多样本LSTM模型明显缩小。2019年末及2020年正遭遇突发性的新冠疫情,各城市2020年的经济发展受到突发的社会因素影响,GDP数据的增速较过往几年有一定减弱。从图10的局部对比中发现预测结果出现与多变量LSTM模型相反的结果,该模型的预测值大部分高于真实值。经过预测数据反归一化后与原始GDP数据进行对比,如表4所示测试集在基于注意力机制的多变量LSTM神经网络模型上的均方根误差RMSE为569,较多样本LSTM神经网络模型减少20%,拟合优度 R^2 为0.9849。对比两个模型发现,基于注意力机制的多变量LSTM模型对于GDP数据的预测效果更好。

表4 两种模型RMSE和 R^2 对比

模型	RMSE	R^2
多变量LSTM神经网络模型	762	0.9744
基于注意力机制的多变量LSTM神经网络模型	569	0.9856

5 结论与建议

5.1 结论

本文构建一个较为全面的用以衡量城市高质量发展的评价指标体系,通过城市高质量发展对于经济增长进行预测在现实中的作用主要有:①高质量发展风险预警:构建的城市高质量发展体系中包含了高质量发展的风险因素,通过建立风险预警机制能够对经济结构、环境污染等方面进行早期预警,帮助政府预估未来城市发展风险点,做好城市各行业布局和决策。②优化资源配置:通过构建城市高质量发展对经济增长的预测,为城市规划和管理提供数据支持,使得决策者能够精准地配置城市资源,从投资、人才、技术等多方面引进优质资源,实现城市发展最大效益化。

多变量LSTM神经网络模型的输入的变量较多,因此在原多变量LSTM神经网络模型的基础上引入注意力机制对于多输入变量进行注意力的权重分配。结果显示,引入注意力机制的多变量LSTM模型均方根误差更低,模型拟合优度更高,预测GDP数据的效果更好。

5.2 建议

(1)推进产业结构优化升级。鼓励发展高附加值、高科技含量的产业,特别是与数字经济、绿色能源等相关的产业。通过政策扶持和资源倾斜的方

式,减少对传统资源密集型产业的依赖,以推动经济的高质量增长。

(2)加强基础设施智能化建设。除了基本的城市设施建设,结合智能化技术提升城市基础设施建设水平,包括交通、物流、能源供应等领域,能更好地适应现代经济发展需求,为经济增长提供强有力的基础支撑。

(3)推动创新进步和人才培养。技术创新是重中之重,加大对创新和技术研发的支持力度,特别是人工智能、大数据和区块链等前沿技术,以实现产业升级和创新效率提升。同时,完善教育和人才培养机制,提升地区劳动力素质,出台人才引进政策,吸引高端人才就业落户,实现城市稳定发展。

参考文献

- [1] 程毛林. 基于生产函数的我国经济增长预测模型[J]. 统计与决策, 2010(20): 34-36.
- [2] 刘晓光, 刘元春, 闫衍, 等. 夯实复苏基础的中国宏观经济[J]. 经济理论与经济管理, 2023, 43(9): 18-38.
- [3] 刘萍, 赵洪进, 李钦. 基于PMI指数对我国经济增长进行预测的实证研究[J]. 科技和产业, 2017, 17(2): 173-176.
- [4] 陈锡康, 杨翠红, 祝坤福, 等. 2023年中国经济增长速度的预测分析与政策建议[J]. 中国科学院院刊, 2023, 38(1): 81-90.
- [5] 吴卓立, 覃正, 王魁恒, 等. GM(1, 1)扩展方法在经济增长预测中的应用及检验[J]. 情报杂志, 2005(11): 13-14.
- [6] 张梓. 基于ARIMA模型的贵州省GDP分析与预测[J]. 国土与自然资源研究, 2022(5): 39-41.
- [7] 王旭. Caputo分数阶导数模型和BP神经网络模型在中国GDP增长预测中的应用[D]. 贵阳: 贵州大学, 2023.
- [8] 马静雯, 李树青, 夏瑶瑶. 机器学习在GDP预测中的应用研究述评[J]. 科技情报研究, 2022, 4(3): 73-94.
- [9] 肖争艳, 刘玲君, 赵廷蓉, 等. 深度学习神经网络能改进GDP的预测能力吗? [J]. 经济与管理研究, 2020, 41(7): 3-17.
- [10] 金磊. 关于“高质量发展”的经济学研究[J]. 中国工业经济, 2018(4): 5-18.
- [11] 康艳青, 李春荷, 朱永明. 黄河流域城市群高质量发展评估与空间分异研究[J]. 生态经济, 2023, 39(2): 86-91.
- [12] 张跃胜, 李思蕊, 李朝鹏. 为城市发展定标: 城市高质量发展评价研究综述[J]. 管理学报, 2021, 34(1): 27-42.
- [13] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005, 18(5/6): 602-610.
- [14] 高广尚. 深度学习推荐模型中的注意力机制研究综述[J]. 计算机工程与应用, 2022, 58(9): 9-18.
- [15] 李树青. 基于注意力机制的改进LSTM模型的地铁客流预测研究[J]. 工业控制计算机, 2023, 36(11): 124-125.
- [16] 穆家荣. 基于LSTM模型的天然气期货价格预测研究[D]. 桂林: 桂林电子科技大学, 2023.

Impact and Forecast of High-quality Urban Development on Economic Growth

HU Jieliang

(School of Public Administration, Sichuan University, Chengdu 610065, China)

Abstract: In order to evaluate the development status of cities and their impact on economic growth, combined with the five new development concepts of innovation, coordination, green, openness and sharing, the evaluation index system of urban high-quality development was constructed, the indicators were screened by OLS least squares method, the impact of high-quality urban development on economic growth and the prediction effect the explored by deep learning method, and the prediction results and accuracy of the multivariate LSTM neural network model and the improved multivariate LSTM neural network model were compared. The results show that the multivariate LSTM neural network model with attention mechanism has better prediction effect, the root mean square error RMSE of the model is reduced by 25%, and the coefficient of determination R^2 reaches 0.9856.

Keywords: high-quality urban development; deep learning; LSTM model; attention mechanisms; economic growth