



计算机科学

COMPUTER SCIENCE

基于 DE-LSTM 模型的教育统计数据预测研究

刘宝宝, 杨菁菁, 陶露, 王贺应

引用本文

刘宝宝, 杨菁菁, 陶露, 王贺应. 基于 DE-LSTM 模型的教育统计数据预测研究[J]. 计算机科学, 2022, 49(6A): 261-266.

LIU Bao-bao, YANG Jing-jing, TAO Lu, WANG He-ying. Study on Prediction of Educational Statistical Data Based on DE-LSTM Model[J]. Computer Science, 2022, 49(6A): 261-266.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

面向供应链风险评估的改进 BP 小波神经网络研究

Study on Improved BP Wavelet Neural Network for Supply Chain Risk Assessment

计算机科学, 2022, 49(6A): 654-660. <https://doi.org/10.11896/jsjcx.210800049>

基于螺旋进化萤火虫算法和 BP 神经网络的模型及其在 PPP 融资风险预测中的应用

Model Based on Spirally Evolution Glowworm Swarm Optimization and Back Propagation Neural Network and Its Application in PPP Financing Risk Prediction

计算机科学, 2022, 49(6A): 667-674. <https://doi.org/10.11896/jsjcx.210800088>

基于 BP 神经网络的智能云效能模型

Efficiency Model of Intelligent Cloud Based on BP Neural Network

计算机科学, 2022, 49(2): 353-367. <https://doi.org/10.11896/jsjcx.201100140>

基于变权组合的突发事件网络舆情趋势预测

Network Public Opinion Trend Prediction of Emergencies Based on Variable Weight Combination

计算机科学, 2021, 48(6A): 190-195. <https://doi.org/10.11896/jsjcx.200600094>

一种基于表面肌电信号的腕部肌力估计方法研究

Study on Method for Estimating Wrist Muscle Force Based on Surface EMG Signals

计算机科学, 2021, 48(6A): 317-320. <https://doi.org/10.11896/jsjcx.200600021>

基于 DE-LSTM 模型的教育统计数据预测研究

刘宝宝 杨菁菁 陶露 王贺应

西安工程大学计算机科学学院 西安 710000

(liubaobao1222@163.com)

摘要 当前,教育大数据呈现数据量大和数据类型多样的特点,准确有效地对教育统计数据进行分析和预测,对教育部门相关政策的制定和社会的发展具有重要的参考价值。文中以某市每年的招生人数为数据基础,提出了 DE-LSTM 模型,该模型通过差分进化算法(DE)对长短期记忆神经网络(LSTM)中的隐含层节点和学习率进行优化,使所提模型具有较好的预测性能,并与现有的 BP 神经网络预测模型、LSTM 神经网络预测模型进行了对比。实验结果表明,提出的 DE-LSTM 预测模型具有较高的预测精度。

关键词:教育统计数据;时间序列预测;BP 神经网络;长短期记忆网络;差分进化算法

中图分类号 TP183

Study on Prediction of Educational Statistical Data Based on DE-LSTM Model

LIU Bao-bao, YANG Jing-jing, TAO Lu and WANG He-ying

School of Computer Science, Xi'an Engineering University, Xi'an 710000, China

Abstract At present, educational data presents the characteristics of large amount of data and diverse data types. Accurate and effective analysis and prediction of educational statistical data, which has important reference value for the formulation of relevant policies in education sector and social development. In this paper, DE-LSTM model is proposed, which takes the annual enrollment of a city as the data basis. The proposed model uses differential evolution algorithm to optimize the hidden layer nodes and learning rate in the long-term and short-term memory neural network and has the better prediction performance in compared with the LSTM and BP models. Furthermore, effectiveness of the proposed DE-LSTM model is verified by a large number of simulation experiments.

Keywords Education Statistics, Time series prediction, BP neural network, Long and short term memory network, Differential evolution algorithm

1 引言

近年来,随着信息技术的深入发展和广泛应用,各行各业也逐步进入了信息化^[1]的时代,以人为本的教育领域也面临着教育信息化^[2]的挑战,教育大数据^[3]也应运而生。与传统教育数据^[4]相比,教育大数据呈现数据量大、形式多样的特点。通过对教育大数据进行统计分析和预测,可以挖掘出该教育数据背后所蕴含的社会、科研以及应用价值^[5]。从海量数据中提取需要的信息,对教育统计大数据进行精准分析和预测成为了教育大数据统计工作中需要解决的重要问题。

随着机器学习在教育数据方面的研究不断深入,针对如何提高教育统计数据预测模型的精准度的问题,国内外学者展开了大量的研究,提出了多种预测模型,如 BP 神经网络预测模型、长短期记忆神经网络(Long Short Term Memory, LSTM)预测模型,并取得了一定的效果。文献[6]提出基于 BP 神经网络预测模型对高校学生的成绩进行预测^[6],该模型对成绩预测具有较好的预测效果,但由于该模型非线性特征学习不充分,在数据波动强烈处预测性能不好^[7],因此研究学者

提出了多种改进 BP 神经网络预测模型的方法。文献[8]通过建立多指标粒子群算法优化 BP 神经网络预测模型,进行平流层风场短期快速预测^[8],该实验有效避免了传统 BP 神经网络易陷入局部最优,提高了预测精度^[9]。虽然这些方法在一定程度上解决了非线性问题,但针对长时间序列分析预测容易产生梯度消失或梯度爆炸。LSTM 神经网络模型实现简单^[10],具备长期记忆功能,模型泛化能力好,适用于与时间序列高度相关的问题^[11]。文献[13]通过构建 LSTM 网络^[12],对催化裂化装置 NO_x 的排放进行预测^[13],并与卷积神经网络模型^[14]、BP 神经网络模型进行对比,实验验证表明,LSTM 模型优于其他模型,但由于 LSTM 神经网络训练过程中,学习率和隐含层节点^[15]需要依据经验和尝试进行不断调整,耗费大量时间^[16]。近年来,随着智能算法的不断深入,神经网络模型优化已成为当前重要的研究方向^[17],采用智能优化算法对神经网络学习率、隐含层进行优化,对提高模型预测精度有至关重要的作用。

差分进化算法对于求解非线性函数优化问题有极强的稳健性^[18],在同样精度要求下,其具有算法收敛速度快、结构

简单、容易实现、鲁棒性强的特性。本文提出 DE-LSTM 教育数据预测模型,通过差分进化算法对 LSTM 神经网络中的隐含层节点和学习率进行优化,使本文模型具有较好的预测性能,为教育统计大数据的研究奠定一定的理论基础,同时为教育管理部门提供了决策依据。

2 DE 算法和 LSTM

2.1 DE 算法

差分进化算法(Differential Evolution Algorithm, DE)由 Storn 和 Price 提出,其流程图如图 1 所示。该算法保留了基于种群的全局搜索策略,简单易用,具有较强的全局收敛能力和鲁棒性,已在电力系统优化调度^[19]、配网重构^[20]等领域得到了广泛应用。

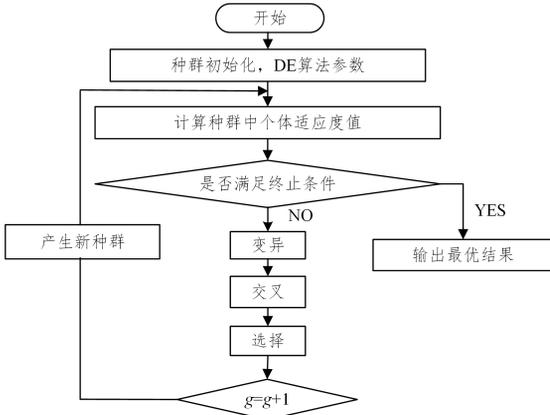


图 1 DE 算法流程图

Fig. 1 DE algorithm flow chart

该算法的基本思想是随机产生初始种群,以每个种群个体中的适应度值为最优个体评价标准^[21],其主要步骤包括变异、交叉、选择操作。该算法的具体步骤如下:

(1) 初始化

种群初始化,维数为 D ,种群规模为 N ,初始化操作如式(1)所示:

$$x_i = (x_{i,1}, x_{i,2}, \dots, x_{i,D}) \quad (1)$$

其中, $i=1, 2, \dots, N$ 。

(2) 变异操作

变异操作作用于产生新个体,从当前种群个体 $x_i(g)$ 中产生下一代目标个体 $v_i(g)$,其变异操作的方法如式(2)所示:

$$v_{i,G} = x_{r_1}(g) + F * (x_{r_2}(g) - x_{r_3}(g)) \quad (2)$$

其中, r_1, r_2, r_3 的取值范围为 $1 \sim N$,并且是 3 个互不相同的解, F 为变异因子^[22], g 为进化代数。

(3) 交叉(重组)操作

交叉操作作用于增加种群多样性,将变异个体 v_i 与父代个体 x_i 交叉生成实验个体 u_i 。其交叉操作如式(3)所示:

$$u_{i,j}(g) = \begin{cases} v_{i,j}(g), & rand \leq CR \text{ or } j = j_{rand} \\ x_{i,j}(g), & \text{otherwise} \end{cases} \quad (3)$$

其中, $j=1, 2, \dots, D$, $rand$ 为 $(0, 1)$ 区间均匀分布的随机整数, CR 为交叉算子,取值范围为 $(0, 1)$,用于平衡全局搜索和局部搜索能力^[23]。

(4) 选择操作

选择操作作用于选出最优个体。将第 g 代实验个体 u_i 与

第 g 代个体 x_i 进行比较,选择适应度值最小的作为下一代个体,其选择操作如式(4)所示:

$$x_i(g+1) = \begin{cases} u_i(g), & f(u_i(g)) \leq f(x_i(g)) \\ x_i(g), & f(u_i(g)) > f(x_i(g)) \end{cases} \quad (4)$$

其中, $x_i(g+1)$ 为下一代目标向量。

2.2 LSTM 长短时期记忆网络

长短时期记忆网络模型在时间序列问题上有广泛的应用,是一种循环神经网络(Recurrent Neural Network, RNN)的变体形式,通过门控机制进行数据处理。

LSTM 神经单元内的数据传递遵循以下公式:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (5)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (6)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (7)$$

$$h_t = o_t * \tanh(c_t) \quad (8)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c} \quad (9)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (10)$$

其中, W 和 b 为参数矩阵; x_t 为输入值; h_t 为 t 时刻的输出值; i_t 为 t 时刻输入门的输出; c_t 为 t 时刻单元状态的参数; f_t 为 t 时刻遗忘门的输出; o_t 为 t 时刻输出门的输出。

LSTM 模型的结构如图 2 所示, σ 表示 sigmoid 激活函数, \tanh 表示双曲正切函数。

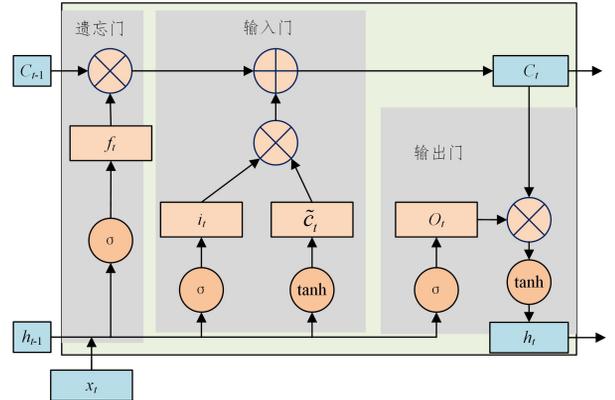


图 2 LSTM 网络结构单元

Fig. 2 LSTM network structure

3 DE-LSTM 模型

教育统计数据是一种时间序列数据,针对时序数据进行模型预测时,易受到多方面因素的影响,引起梯度消失或梯度爆炸,具有不稳定性,而 LSTM 神经网络模型是一种循环神经网络 RNN 的变体形式,在 RNN 结构的基础上增加了单元状态以及 3 个门,即遗忘门、输入门、输出门,在一定程度上避免了 RNN 模型不具备长期记忆功能,适用于处理与时间序列高度相关的问题。LSTM 神经网络模型参数中,学习率作为控制神经网络学习速度的参数,合适的参数选取对模型的收敛速度具有一定的作用,隐含层节点对神经网络的泛化能力具有一定的作用。学习率和隐含层节点的取值会影响网络训练的性能^[24]。当前在 LSTM 教育数据预测模型中,学习率和隐含层节点的调整需要根据经验和尝试才能确定,调参会耗费大量的时间^[25]。因此,本文选用 LSTM 模型,通过优化学习率和隐含层节点来构建时间序列数据预测模型。

差分进化算法是一种模拟生物进化的全局寻优算法^[26]。

在进化过程中,算法通过不断的迭代,选出适应度值最小的个体,不断引导搜索过程向全局最优解逼近。该算法对复杂函数具有较强的优化能力、全局收敛能力和鲁棒性^[27],且简单易用,因此采用差分进化算法来优化神经网络模型中的学习率和隐含层节点。

由于差分进化算法对复杂函数具有较强的优化能力,通过对 LSTM 神经网络中的学习率、隐含层节点数进行自动寻优,避免了人工调参耗费大量的时间以及容易陷入局部最优,使提出的 DE-LSTM 模型具有较好的预测性能。具体流程如图 3 所示,具体实现步骤如下:

Step 1 读取数据表,划分训练集、测试集,并进行归一化处理。

Step 2 建立 LSTM 模型,设置输入层节点数为 3,输出层节点数为 1,训练过程使用 Adam 优化器,迭代次数为 50,将学习率、隐含层节点数确定为寻优参数。

Step 3 对当前代数、最大迭代次数、种群规模、变异因子、交叉算子进行初始化。种群大小 N 设置为 6,变异因子 F 设置为 0.5,交叉算子 CR 设置为 0.1,最大进化代数设置为 10,另根据式(1)对种群进行初始化。

Step 4 判断是否达到迭代结束条件,即最大迭代次数。达到停止迭代的条件则输出最优个体,否则转 Step 5。

Step 5 按照 DE 的变异、交叉、选择操作产生下一代个体。

Step 6 重复执行 Step 5,得到下一代的种群。

Step 7 评价下一代种群的适应度值,最小适应度值即为全局极小值,对应的个体即为全局最优个体。

Step 8 满足最大的迭代次数,返回 Step 4。

Step 9 将优化后的隐含层节点和学习率值传入 LSTM 神经网络结构中,构建 DE-LSTM 预测模型。

Step 10 预测并依据评价指标进行分析和总结,选取预测精度效能最优的模型进行未来年份数据的预测。

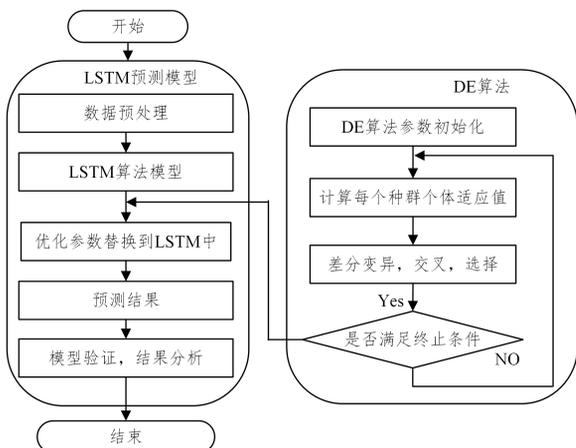


图 3 DE-LSTM 教育数据预测模型流程图

Fig. 3 Flow chart of DE-LSTM prediction model

4 仿真实验

本文以某区的年份招生人数作为输入数据,将提出的 DE-LSTM 教育数据预测模型与 BP 教育数据预测模型、LSTM 教育数据预测模型进行对比,验证 DE-LSTM 教育数据预测模型在教育数据预测中是否具有较好的预测性能。

实验平台是 Windows 10 64 位操作系统,设备使用的

处理器是英特尔 Core i5-8250U,显卡是 Radeon530,内存为 8.00 GB,实验通过 MATLAB R2021a 编程实现。

4.1 实验数据

本文中的实验数据集来自文献[28],本次实验采用某区 1987—1993,2001—2007,2010—2016 年的招生人数进行建模。1990—2007,2010—2013 年的招生人数为用于训练的训练数据,2014—2016 年的招生人数为验证的测试数据^[28]。具体数据如表 1 所列。

表 1 某区(县)部分年份招生人数^[28]

Table 1 Enrollment of a district(county) in some years^[28]

年份	招生人数	年份	招生人数
1987	578 038	2005	604 721
1988	594 028	2006	593 304
1989	609 234	2007	568 322
1990	618 716	2010	515 628
1991	641 856	2011	513 916
1992	676 181	2012	508 534
1993	719 733	2013	519 490
2001	745 124	2014	537 905
2002	707 825	2015	566 229
2003	667 804	2016	597 920
2004	637 474	—	—

4.2 实验评估指标

教育数据预测模型的精度表现将基于均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)进行评估。

RMSE 通过计算预测值和真实值的平方和与观测次数 T 比值的平方根,来衡量预测值与真实值之间的偏差,其定义如式(11)所示:

$$RMSE = \sqrt{\frac{\sum_{t=1}^T (y_t - f_t)^2}{T}} \quad (11)$$

MAE 通过绝对误差计算平均值来反映预测值误差的实际情况,其定义如式(12)所示:

$$MAE = \frac{\sum_{t=1}^T |y_t - f_t|}{T} \quad (12)$$

其中, f_t 和 y_t 分别表示 t 年份模型的预测值和真实值, T 为数据点个数。

4.3 实验参数

3 种教育数据预测模型的参数设置如下。

(1)BP 神经网络仿真参数选取。输入层节点数为 3,隐含层节点数为 7,输出层节点数为 1。选择 tansig 函数为隐含层的激活函数, purelin 函数为输出层的激活函数, trainlm 函数为训练函数,迭代次数为 50,均方误差为 0.0001,小于均方误差时算法性能达到收敛精度,训练结束。

(2)LSTM 神经网络仿真参数选取。输入层节点数为 3,隐藏层节点数为 30,输出层节点数为 1,损失函数使用均方误差,模型训练过程使用 Adam 优化器,学习率为 0.01,迭代次数为 50。

(3)DE-LSTM 预测模型中仿真参数选取。由 DE 算法和 LSTM 神经网络模型两部分组成。DE 算法参数设置如下:种群大小 N 设置为 6,变异因子 F 设置为 0.5,交叉算子 CR 设置为 0.1,最大进化代数设置为 10,将最终优化的参数学习率、隐含层节点数值传入 LSTM 神经网络中。其中,LSTM

参数选取输入层节点数为 3、输出层节点数为 1,在训练过程中使用 Adam 优化器,迭代次数为 50。

4.4 实验结果与分析

依据某区(县)部分年份招生数据^[28],采用 BP 教育数据预测模型、LSTM 教育数据预测模型、DE-LSTM 教育数据预测模型进行招生人数预测误差比较,选择出预测误差较小的模型进行未来数据的预测。

首先,选取 1987—1989 年这 3 年的数据作为输入,对 1990—1993,2010—2013 年招生人数进行预测,并与真实值进行对比。

BP 教育数据预测模型、LSTM 教育数据预测模型、DE-LSTM 教育数据预测模型这 3 种教育数据预测模型在训练后,模型的预测拟合曲线如图 4 所示,黑色线表示某区(县)1990—1993,2001—2013 年份的真实招生人数,红色线表示 DE-LSTM 教育数据模型预测拟合曲线,蓝色线表示 LSTM 教育数据模型预测拟合曲线,绿色线表示 BP 教育数据模型预测拟合曲线。从图中可以看出,DE-LSTM 预测拟合曲线与真实值曲线重合较高,效果较好,LSTM 预测拟合模型相比 BP 预测拟合模型的效果具有一定的优势。

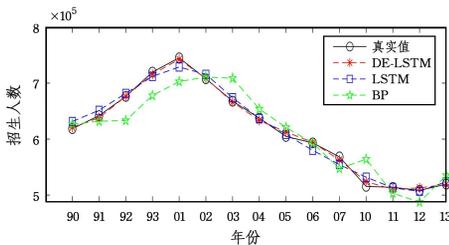


图 4 招生人数 1990—2013 年预测值(电子版为彩图)

Fig. 4 Enrollment forecast 1990—2013

图 5 是 BP 教育数据预测模型、LSTM 教育数据预测模型、DE-LSTM 教育数据预测模型对 1990—1993,2010—2013 年份招生人数的预测值与真实值之间的误差对比图。图 5 中,红色线表示 DE-LSTM 教育数据模型预测值与真实值之间的误差曲线,蓝色线表示 LSTM 教育数据模型预测值与真实值之间的误差曲线,绿色线表示 BP 教育数据模型预测值与真实值之间的误差曲线。从图中可以看出,BP 教育数据预测模型性能最差,这主要由于 BP 神经网络非线性特征学习不充分,在数据波动强烈处预测性能不好。其次预测性能较差的是 LSTM 教育数据预测模型,而 DE-LSTM 通过差分进化算法对 LSTM 神经网络中学习率和隐含层节点优化后取得了较好的预测效果。因此,DE-LSTM 教育数据预测模型误差曲线预测性能较好,对未来年份招生人数进行预测具有一定的优势。

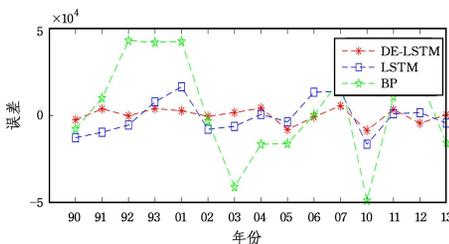


图 5 招生人数 1990—2013 年误差值(电子版为彩图)

Fig. 5 Enrollment 1990—2013 error

LSTM 教育数据预测模型,对 1990—1993,2010—2013 年份招生人数预测结果的衡量指标如表 2 所列。

表 2 1990—2013 预测结果对比

Table 2 Comparison of prediction results from 1990 to 2013

名称	RMSE	MAE
BP 教育数据预测模型	2.7517×10^4	2.2560×10^4
LSTM 教育数据预测模型	9.6275×10^3	8.0661×10^3
DE-LSTM 教育数据预测模型	4.2034×10^3	3.3842×10^3

从表 2 中可以看出,在招生人数预测中,DE-LSTM 教育数据预测模型在 RMSE,MAE 中值较小。相比传统 BP 神经网络,LSTM 神经网络增加了单元状态,用于保存长期状态,并引入了遗忘门、输入门、输出门、决定和更新单元状态的信息,适用于处理与时间序列高度相关的问题。采用差分进化算法对 LSTM 神经网络中学习率和隐含层结点数进行自动寻优,对 LSTM 神经网络结构起到优化作用。因此,DE-LSTM 教育数据预测模型对未来年份招生人数预测具有较好的预测性能。

图 6—图 8 描述了使用训练后的 BP 教育数据预测模型、LSTM 教育数据预测模型、DE-LSTM 教育数据预测模型对 2014—2016 年份的招生人数进行训练集的测试结果。图 6 给出了 BP 教育数据预测模型对 2014—2016 年的招生人数进行预测的结果,蓝色线为真实值曲线,红色线为测试预测值曲线,预测 2014—2016 年人数分别为 512475,509610,515575。

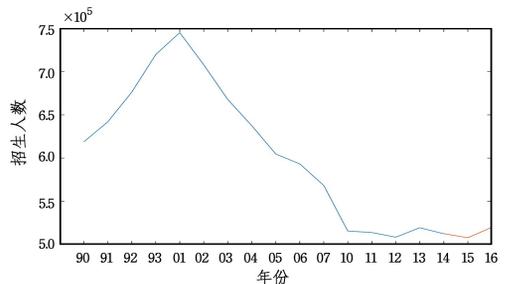


图 6 BP 模型 2014—2016 年预测值(电子版为彩图)

Fig. 6 BP model 2014—2016 forecast

图 7 是 LSTM 教育数据预测模型对 2014—2016 年的招生人数进行预测的数据,蓝色线表示真实值,红色线表示预测值,预测 2014—2016 年人数分别为 592180,620020,637200。

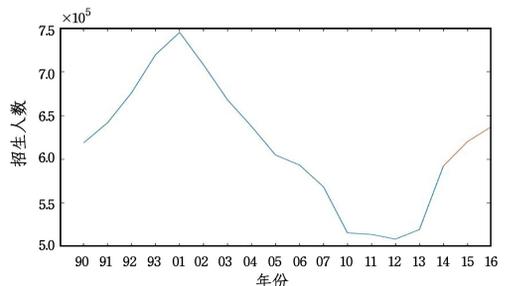


图 7 LSTM 模型 2014—2016 年预测值(电子版为彩图)

Fig. 7 LSTM model 2014—2016 forecast

图 8 是 DE-LSTM 教育数据预测模型对 2014—2016 年的招生人数进行预测的数据。图 8 中,蓝色线表示真实值,红色线表示预测值,预测 2014—2016 年的招生人数分别为 574140,592040,613310。

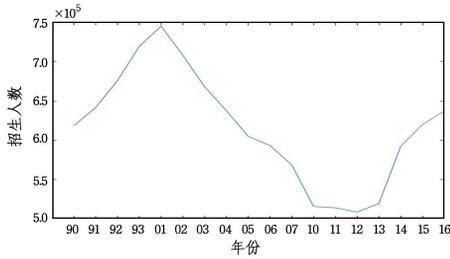


图 8 DE-LSTM 模型 2014—2016 年预测值(电子版为彩图)

Fig. 8 DE-LSTM model 2014—2016 forecast

BP 教育数据预测模型、LSTM 教育数据预测模型与 DE-LSTM 教育数据预测模型,对 2014—2016 年份招生人数预测结果的衡量指标如表 3 所列。

表 3 2014—2016 预测结果对比

Table 3 Comparison of 2014—2016 forecast results

名称	RMSE	MAE
BP 教育数据预测模型	9.0324×10^4	8.1584×10^4
LSTM 教育数据预测模型	7.8104×10^4	6.1002×10^4
DE-LSTM 教育数据预测模型	5.4869×10^4	3.0106×10^4

由表 3 可以看出,在招生人数预测中,DE-LSTM 教育数据预测模型在 RMSE,MAE 中值较小。与传统 BP 神经网络预测模型相比,增加单元长期保存状态和门控机制的 LSTM 模型在时序预测方面更具有优势。通过差分算法对 LSTM 中隐含层节点和学习率进行寻优,从而提高 LSTM 神经网络预测精度,进一步验证了所提模型具有较好的预测性能。因此,采用 DE-LSTM 教育数据预测模型对未来年份的招生人数进行预测。

采用 1990—2013 年份的实际招生人数作为输入,应用 DE-LSTM 教育数据预测模型对 2017—2022 年的招生人数进行预测,预测结果如图 9 所示。图 9 中蓝色线表示真实值,红色线表示预测值。2017—2022 年的预测招生人数分别是 612 390,622 940,628 860,632 210,633 890,634 700。

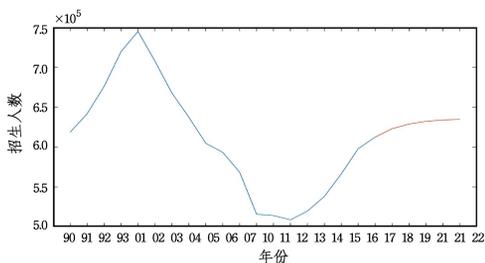


图 9 DE-LSTM 模型 2017—2022 年的预测值(电子版为彩图)

Fig. 9 DE-LSTM model 2017—2022 forecast

结束语 本文针对教育统计数据的预测问题,提出了基于差分进化算法优化长短时期记忆神经网络的预测模型。与 BP 神经网络预测模型和 LSTM 神经网络预测模型相比,该模型在教育数据预测上具有较好的预测性能。本文模型为教育统计大数据的研究提供了一定的理论基础,为教育管理部门提供了决策依据,同时本文模型也具有一定的工程应用价值。在下一步研究工作中,将进一步开展教育统计大数据的研究,探讨其所蕴含的社会价值、科研价值以及应用价值。

参考文献

[1] ZHENG Z Z. Reflections on people-oriented education in the

process of educational informatization [J]. Times Education, 2015(9):145-146.

- [2] QIZI S. Pedagogics of formation of future teachers social outlook in the conditions of informatization of education[J]. ACADEMICA an International Multidisciplinary Research Journal, 2021, 11(3):1257-1260.
- [3] MICHALIKP, ŠTOFA J, ZOLOTOVA I. Concept definition for Big Data architecture in the education system[C]// 2014 IEEE 12th International Symposium on Applied Machine Intelligence and Informatics(SAMI). IEEE, 2014:331-334.
- [4] DANG Z. Information construction of education management [J]. Business Culture, 2021(35):54-55.
- [5] NAN G, XIA Y F. Educational science research in the era of big data: possibility, risk and strategy [J]. Journal of Educational Science of Hunan Normal University, 2020, 19(4):87-94.
- [6] YAO M H, LI J S, WANG N. Prediction of College Students' achievement based on BP neural network [J]. Journal of Jilin University, 2021, 39(4):451-455.
- [7] CHEN Y D, LIU S, QIN S J, et al. Prediction of maximum deformation of single nail riveting based on BP neural network [J]. Journal of Xi'an University of Engineering, 2021, 35(6):90-95.
- [8] LONG Y, DENG X L, YANG X X, et al. Short term fast prediction of stratospheric wind field based on PSO-BP neural network [J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 3:1-13.
- [9] SONG L, GU L, DONG H, et al. Depth estimation of Optimized BP network in facial feature points [J]. Journal of Xi'an University of Engineering, 2017, 31(4):551-555.
- [10] LIU W, YIN F. A reservoir water level prediction method based on LSTM model [J]. Radio Engineering, 2022, 52(1):83-87.
- [11] PAN Y D, CAO L, LIU M. PM_{2.5} based on LSTM network 5 concentration prediction [J]. Journal of Jinling University of Science and Technology, 2021, 37(4):7-13.
- [12] DEY P, SAURABH K, KUMARC, et al. t-SNE and variational auto-encoder with a bi-LSTM neural network-based model for prediction of gas concentration in a sealed-off area of underground coal mines [J]. Soft Computing, 2021, 25(22):14183-14207.
- [13] HE W, TANG Z H, WUB, et al. No of catalytic cracking unit based on LSTM_ X emission prediction model and its application [J]. Journal of Xi'an University of Petroleum, 2020, 35(4):108-113.
- [14] SHI H X, ZHU J C, YAN J C, et al. Customer repurchase prediction method based on convolutional neural network and LSTM cyclic neural network [J]. High Tech Communication, 2021, 31(7):713-722.
- [15] MA X, TAO Z, WANG Y, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data [J]. Transportation Research Part C: Emerging Technologies, 2015, 54:187-197.
- [16] ZHANG B, LIU Y L, ZHANG W J, et al. Improved prediction method of derailment coefficient of LSTM [J]. Software Guide, 2022, 21(2):27-31.
- [17] LU S, LI Y S. Life prediction of Ni Cd battery based on BP neural network optimized by differentialevolution algorithm [J].

- Journal of Guangxi University of Science and Technology, 2020, 31(2):93-98.
- [18] ZHANG J, LIU M, ZHANG S, et al. AUV Path Planning Based on Differential Evolution with Environment Prediction[J]. Journal of Intelligent & Robotic Systems, 2022, 104(2):1-15.
- [19] ZHANG N Y, XIONG G J, CHEN J L, et al. Quantum discrete differential evolution method for unit commitment of wind power system [J]. Power Grid and Clean Energy, 2022, 38(1): 89-96.
- [20] HUANG J H, LI H, YI T, et al. Application of improved niche differential evolution algorithm in reactive power optimization of distribution network [J]. Power Grid and Clean Energy, 2015, 31(6):75-79.
- [21] WU Y K, JIANG H, WANG B. Research on Demolition Cost of high-rise Structure Based on DE-BP Algorithm [J]. Sichuan Building Materials, 2021, 47(1):224-225.
- [22] YAN F. Heating energy saving control system based on differential evolution algorithm [J]. Journal of Shenyang University of Technology, 2017, 39(3):328-332.
- [23] CHEN Y J, LIU S Y, ZHANG Z C. Excellent individual oriented Multi Strategy differential evolution algorithm [J]. Computer Engineering and Application, 2022, 58(2):137-144.
- [24] ZHANG B, LIU Y L, ZHANG W J, et al. Improved prediction method of derailment coefficient of LSTM [J]. Software Guide, 2022, 21(2):27-31.
- [25] LI H, QIN C, HE W. Improved predictive performance of cyanobacterial blooms using a hybrid statistical and deep-learning method [J]. Environmental Research Letters, 2021, 16(12): 12405.
- [26] WANG H, LIU Y N. Power transformer fault diagnosis based on Fuzzy Petri net optimized by differential evolution algorithm [J]. Power Science and Engineering, 2018, 34(12):32-36.
- [27] REN Z L, TIAN Y B, SUN F Y. Wind driven optimization algorithm with strong development ability [J]. Computer Science, 2016, 43(1):275-281.
- [28] ZHAO Z. Design and research of educational big data statistical analysis platform [D]. Xi'an: Xi'an University of Technology, 2019.



LIU Bao-bao, born in 1982, Ph.D, master supervisor, is a senior member of China Computer Federation. His main research interests include machine learning, deep learning, intelligent image processing and interpretation, education statistics and big data analysis.

(上接第 246 页)

更为复杂。在本文方法中,将所有特征都看成对判别结果有效的特征,没有特征筛选的过程。为此,后续的研究可以聚焦于如何筛选合理的特征作为输入特征。

参 考 文 献

- [1] MCCULLAGH P. Regression Models for Ordinal Data[J]. Journal of the Royal Statistical Society. Series B: Methodological, 1980, 42(2):109-127.
- [2] ENGEL J. Polytomous Logistic Regression[J]. Statistica Neerlandica, 2010, 42(4):233-252.
- [3] BENDER R, GROUVEN U. Using Binary Logistic Regression Models for Ordinal Data with Non-proportional Odds[J]. Journal of Clinical Epidemiology, 1998, 51(10):809-816.
- [4] WINSHIP C, MARE R D. Regression Models with Ordinal Variables[J]. American Sociological Review, 1984, 49(4):512-525.
- [5] WALTER S D, FEINSTEIN A R, WELLS C K. Coding ordinal independent variables in multiple regression analyses[J]. American Journal of Epidemiology, 1987, 125(2):319-323.
- [6] GAO G, HE L. Test of application conditions of Logistic regression for multiple categorical ordinal response variables [J]. China Health Statistics, 2003, 20(5):276-278.
- [7] GERTHEISS J, TUTZ G. Penalized Regression with Ordinal Predictors[J]. International Statistical Review, 2010, 77(3):345-365.
- [8] HONG H G, HE X. Prediction of functional status for the elderly based on a new ordinal regression model. Journal of the American Statistical Association, 2010, 105(491):930-941.
- [9] HONG H G, ZHOU J. A multi-index model for quantile regression with ordinal data[J]. Journal of Applied Statistics, 2013, 40(6):1231-1245.
- [10] RAHMAN M A. Bayesian quantile regression for ordinal models [J]. Bayesian Analysis, 2016, 11(1):1-24.
- [11] ALHAMZAWI R. Bayesian model selection in ordinal quantile regression[J]. Computational Statistics & Data Analysis, 2016, 103:68-78.
- [12] ALHAMZAWI R. Bayesian quantile regression for ordinal longitudinal data Non-proportional Odds [J]. Journal of Applied Statistics, 2017, 45(5):1-14.



WANG Wen-qiang, born in 1996, post-graduate. His main research interests include statistical theory and its application.



JIA Xing-xing, born in 1982, associated professor, master supervisor. Her main research interests include secret sharing, visual cryptography and data science.