

杨英,唐平. VAE_LSTM 算法在时间序列预测模型中的研究[J]. 湖南科技大学学报(自然科学版), 2020, 35(3):93-101.
doi:10.13582/j.cnki.1672-9102.2020.03.014

Yang Y, Tang P. Research of VAE_LSTM Algorithm in Time Series Prediction Model [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2020, 35(3):93-101. doi:10.13582/j.cnki.1672-9102.2020.03.014

VAE_LSTM 算法在时间序列预测模型中的研究

杨英¹, 唐平^{2*}

(1. 广东交通职业技术学院 信息学院, 广东 广州 510080;
2. 广东工业大学 自动化学院, 广东 广州 510000)

摘要:针对长短期记忆网络(LSTM)算法对时间序列预测存在的不足,考虑到样本序列如果包含线性关系或含有噪音时 LSTM 算法预测将不准确,同时分析了变分自编码器(VAE)对异常样本修复的原理,提出了一种改进的 LSTM 时间序列预测算法 VAE_LSTM,将 VAE 网络修复样本的思想加入到传统的 LSTM 网络,对样本序列进行修复后再输入 LSTM 神经网络训练,最终建立了时间序列预测模型.阐述了模型建立的方法与步骤,详细分析了模型的原理.使用长江汉口历史水文数据序列进行仿真实验,结果表明:VAE_LSTM 算法预测模型在时间序列预测方面有较好表现,满足预测精度要求,比传统 LSTM 时间序列预测模型的预测准确性高,尤其是短期预测更为准确;对比实验同时表明此模型准确性高于 ARIMA, RNN 等预测模型.

关键词:时间序列;预测模型;神经网络;长短期记忆网络;变分自编码器

中图分类号:TP301.6 **文献标志码:**A **文章编号:**1672-9102(2020)03-0093-09

Research of VAE_LSTM Algorithm in Time Series Prediction Model

Yang Ying¹, Tang Ping²

(1. School of Information, Guangdong Communication Polytechnic, Guangzhou 510080, China;
2. School of Automation, Guangdong University of Technology, Guangzhou 510000, China)

Abstract: In view of the shortcomings of long short term memory (LSTM) algorithm in time series prediction, if the sample sequence contains linear relationship or noise, the LSTM algorithm prediction will not be accurate, and considering that the principle of VAE to repair abnormal samples, an improved LSTM time series prediction algorithm VAE_LSTM was proposed. The idea of repairing samples was added to the traditional LSTM network. The sample sequence was input the LSTM neural network for training after repaired, and finally established the time series prediction model. The method and steps of model building were described, and the principle of model was analyzed in detail. Using the historical hydrological data series of Hankou of the Yangtze River for simulation experiments, the results show that the VAE_LSTM algorithm prediction model has better performance in time series prediction, meets the prediction accuracy requirements, and is more accurate than the traditional LSTM time series prediction model, especially in the short and medium term; the comparative experiments also show that the accuracy of this model is higher than ARIMA, RNN and other prediction models.

Keywords: time series; prediction model; neural network; LSTM; VAE

收稿日期:2020-02-16

基金项目:广东高校省级重点平台和重大科研项目资助(2017GKTSCX0)

* 通信作者, E-mail: rachelatang7@163.com

对事物未来发展的趋势与走向进行预测是统计学与人工智能方面研究的热点之一.由一段时间内的状况预测未来某段时间的状况,需要收集过去一个时段内的某类信息,并按时间产生序列,将它们输入事先设计好的预测模型,由此模型输出未来某个时间的预测值.在统计学中,差分自回归移动平均(Autoregressive Integrated Moving Average model, ARIMA) 以及其改进的系列算法被认为是进行时序预测的好方法^[1-3],然而随着深度学习的发展,使用深度学习算法训练预测模型的研究与应用越来越多,如康国华等提出了使用卷积神经网络(Convolutional Neural Network, CNN)对组合航天器模型预测^[4],宋亚等提出自编码神经网络与双向 LSTM(Long Short-Term Memory, LSTM)神经网络结合方式预测模型^[5],朱炜玉在对水质进行预测时提出了基于自回归模型(Autoregressive, AR)和孤立森林算法^[6],薛晔等提出了一种多变量模糊时间序列模型^[7]等等.

在深度学习的各类算法中, LSTM 算法被证明在预测方面表现优良,如文献[8-12]中使用 LSTM 算法对各类预测都取得了良好的性能.当然, LSTM 算法在预测方面同样存在不足^[12-15],如学习的准确度、时间消耗、各类因素的相关性学习不足等.所学习的样本序列若包含线性关系或含有噪音时, LSTM 算法会造成网络过拟合从而影响预测精度,考虑到这个缺点,本文提出了一种改进的 LSTM 算法——VAE_LSTM 算法,从时序样本入手,先利用变分自编码器(Variational Auto-encoder, VAE)神经网络思想,修复不平稳样本,再使用长短记忆的循环神经网络建立最终预测模型.本文使用长江汉口流量数据库的水流量数据作了仿真实验,实验表明了 VAE_LSTM 算法模型极大地提高了时间序列预测的准确度.

1 相关工作

1.1 LSTM 神经网络

LSTM 网络是从循环神经网络(Recurrent Neural Network, RNN)发展而来的,简单 RNN 网络具有记忆功能,但同时存在长时期依赖问题(Long Term Dependency), LSTM 模型致力于解决了长时期依赖问题^[16],它的基本思路是引入了门控装置来处理记忆单元的内存/遗忘、输入程度、输出程度的问题.通过一定的学习,可以学到何时对各个门开启到何种程度,因为门控也是神经网络,这样通过门控中神经网络参数的学习就可以让机器知道何时应该记住某个信息,而何时应该抛弃某个信息.图 1 为标准 LSTM 隐含层细胞结构,其中 x_t, C_t, h_t 分别为 t 时刻的输入单元、细胞状态、输出单元, C_{t-1}, h_{t-1} 分别为 $t-1$ 时刻细胞的状态和输出单元, φ_1 为 sigmoid 函数, φ_2 为 tanh 函数.

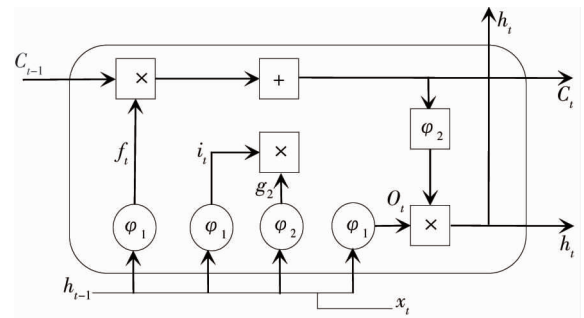


图 1 标准 LSTM 隐含层细胞结构

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

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

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c); \quad (3)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_{t-1}] + b_o); \quad (4)$$

$$h_t = O_t \tanh(C_t). \quad (5)$$

式中: W_f, W_i, W_o, W_c 分别为遗忘门、输入门、输出门、输入单元状态权重矩阵; b_f, b_i, b_o, b_c 分别为遗忘门、输入门、输出门、输入单元状态偏置项; y_t 为输出层最后输出.

$$y_t = W_y \cdot h_t. \quad (6)$$

传统的 LSTM 算法将样本组成的时间序列直接作为输入序列送入网络的输入层,未能消除异常样本带来的干扰,比如采集数据时传感器工作状态的不稳定、网络传输时的问题,或者几类因素之间也可能相互干扰而产生“噪音”,因此某些数据成了“不合格数据”,如果不消除这种干扰,那么预测结果就可能不准确.深度学习中大量神经元参与运算时将这此“噪音”当成正确样本学习会因为过拟合而降低网络的泛化

能力.

1.2 VAE 算法原理

VAE 是一种无监督的生成网络模型,由编码器和解码器两部分组成.编码器用来学习训练数据的分布并生成训练数据的压缩值,解码器对压缩后的数据进行重构,重建高质量数据去干扰样本^[17-18].

图2和图3是VAE的图模型,我们能观测到的数据是 x, z 由隐变量产生,由 $x \rightarrow z$ 是识别模型(recognition model) $q_\phi(z|x)$,类似于自编码器的编码器,如式(7)所示;由 $z \rightarrow x$ 是生成模型 $p_\theta(x|z)$,从自编码器(auto-encoder)的角度来看,就是解码器,如式(8)所示.

$$z \sim \text{Enc}(x) = q_\phi(z|x); \quad (7)$$

$$x \sim \text{Dec}(z) = p_\theta(x|z). \quad (8)$$

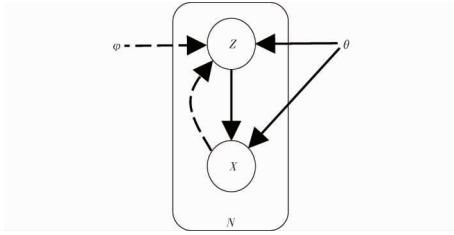


图2 VAE 原理架构

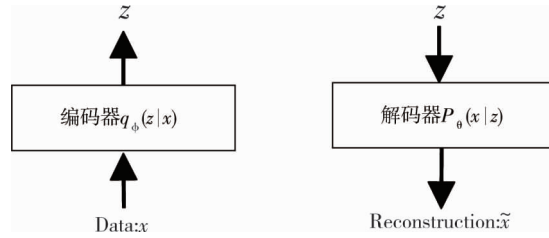


图3 VAE 中编码器与解码器原理

编码器学习输入数据的分布,将输入数据映射为数据分布的平均值 μ 及标准差 σ ,并在标准正态分布中采样 ε ,以生成潜在变量 Z .

$$Z = \mu + \sigma \odot \varepsilon. \quad (9)$$

式中: \odot 为Hadamard 乘积.解码器对潜在变量 Z 进行解码重构,生成重构样本.

在VAE中,通过最大化证据下限函数 $L_b(*)$ 来优化网络:

$$L_b = Eq_\phi(z|x) \log p_\theta(x|z) - D_{KL}(q_\phi(z|x) | p_\theta(z)); \quad (10)$$

式中: $Eq_\phi(z|x)$ 为关于 x 的后验概率的对数似然估计,表示重建质量; $D_{KL}(*)$ 为KL散度,用于度量近似后验分布与单位高斯分布的差异^[19].

式(9)表示VAE在重构样本时加入 ε ,可以看成在标准的正态分布参数中加入了“适当噪音”^[17-18].而式(10)表示VAE神经网络损失函数通过约束参数 Φ 和 θ ,一方面使原始输入与输出尽量相似,另一方面,又通过KL散度适当增加了噪音,前者使输出尽量拟合输入,后者作为惩罚保持输出与输入存在一定差异从而防止过拟合.如:输入样本序列中一组固定值“ABCD”,数据的生成过程近似地决定了我们想要生成“ABCD”,通过最大化证据下限函数 $L_b(*)$,神经网络将往期望值方向学习,但为了不每次都生成“ABCD”,就在潜在空间中添加一些随机噪声,所以在重构样本时,使用了标准差(σ)和一些随机误差(ε)稍微进行修改,通过解码器网络将其传递出去,最终输出样本变得跟输入相似但又不相同,假设输入样本服从多元的高斯分布,那么输出在整体上保持了采用后的结果服从这组多元的高斯分布.综上所述,可以认为VAE算法从两方面修复样本:(1)利用多元高斯分布函数平滑样本;(2)利用增加“高斯噪音”方法增加鲁棒性.

2 VAE_LSTM 神经网络的时序预测方法

2.1 VAE_LSTM 时序预测模型建立流程

如前文分析,传统的LSTM神经网络虽然通过门控装置提升了网络预测准确度,但忽视了对样本之间的线性关系以及“噪音”考虑,从而降低模型预测性能;同时,VAE算法通过对样本的编码、解码重构过程能不断地“消除”或者“分解”样本中“不合格数据”,所以本文组合两类算法设计了改进的时序预测算法VAE_LSTM及其模型.模型建立具体流程:

第1步:对训练样本通过观察移动平均和移动均方差随时间的变化图,观察数据有无明显随时间上升

或下降趋势.有明显随时间上升或下降趋势的样本认为不合理^[20],重新采用样本,重复第一步;

第2步:使用扩张的 Dickey - Fuller 检测 (Augmented Dickey - Fuller Test, ADF)^[21] 进行样本平稳性分析,数据完全符合参数要求,转第4步;

第3步:对样本进行修复,得到重构样本序列;

第4步:将“合格样本”序列作为预测神经网络的输入数据进行预测模型训练,直到满足损失函数要求;

第5步:使用测试样本输入模型,得到预测输出序列.比较结果,在接受的准确度范围内转下步;否则调整参数,转第4步;

第6步:输出 VAE_LSTM 模型.

综上所述,VAE_LSTM 时序预测模型建立流程如图4所示.

2.2 VAE_LSTM 算法模型

为获得有效的基于 VAE_LSTM 算法预测模型,此处通过数据准备、样本的修复再训练样本数据方法来生成 VAE_LSTM 算法模型.

2.2.1 获取数据

本文中所使用的时间序列数据来自 DataMarket 的时间序列数据库,此处选用在汉口测量的长江每月流量数据作为实例,该数据集按月连续记录了历史上 1 000 多个长江流量数据.选取其中若干数据形成训练数据与测试数据 2 组,训练数据组成序列 $X = \{X_1, X_2, \dots, X_n\}$, n 为训练样本总数.

2.2.2 数据平稳性分析

时间序列如果稳定性不佳,接下来的数据分析会使得分析结果无效,也就不能准确地对未来进行预测.数据平稳性能的分析时先通过观察移动平均和移动均方差随时间的变化图波动的幅度,再用 ADF 进行校验来实现.

2.2.3 修复样本

ADF 校验后认为显著性合格的序列是不用进行样本序列的修复,然而现实是这样的序列非常少,大部分序列是需要经过一定修复的,VAE 对样本的修复可以看出成是将原始样本 $X = \{X_1, X_2, \dots, X_m\}$ (其中 $m = n/p$, p 为样本分批数量),编码为 $Z = \{Z_1, Z_2, \dots, Z_m\}$,然后再解码为 $\hat{X} = \{\hat{X}_1, \hat{X}_2, \dots, \hat{X}_m\}$ 的过程.

1) 编码 (encode) 过程

首先认为训练数据序列是由多个高斯分布函数组成: $X = \{X_1, \dots, X_k, \dots, X_m\}$, 定义编码后需得到序列 $Z = \{Z_1, \dots, Z_k, \dots, Z_m\}$, 通过 2 类神经网络训练分别训练均值与方差 (u_k 和 σ_k^2) 数列, 式(11)和式(12)中 f_1, f_2 是编码器中的要拟合的非线性函数,它表示要得到的子序列均为高斯分布.

$$u_k = f_1(x_k); \quad (11)$$

$$\log \sigma_k^2 = f_2(x_k). \quad (12)$$

此部分编码产生的隐变量 Z_k 实际是一组成对出现的均值与方差.

2) 解码 (decode) 过程

从隐变量 Z 生成修复后的样本序列 \hat{X} , 实际是经过这个解码器得到 $\hat{X} = \{\hat{X}_1, \hat{X}_2, \dots, \hat{X}_m\}$, 使 X 与 \hat{X} 的距离 $D(\hat{X}, X)^2$ 最小.前面提到用 $q_\phi(z|x_i)$ 去拟合 $p_\theta(x_i|z)$, 编码器要做的是生成这些高斯分布的参数 $\{(u_1, \sigma_1^2), (u_2, \sigma_2^2), \dots, (u_m, \sigma_m^2)\}$, 之后我们从条件分布中 $q_\phi(z|x_i)$ 取样, 而解码器的网络就可以生成

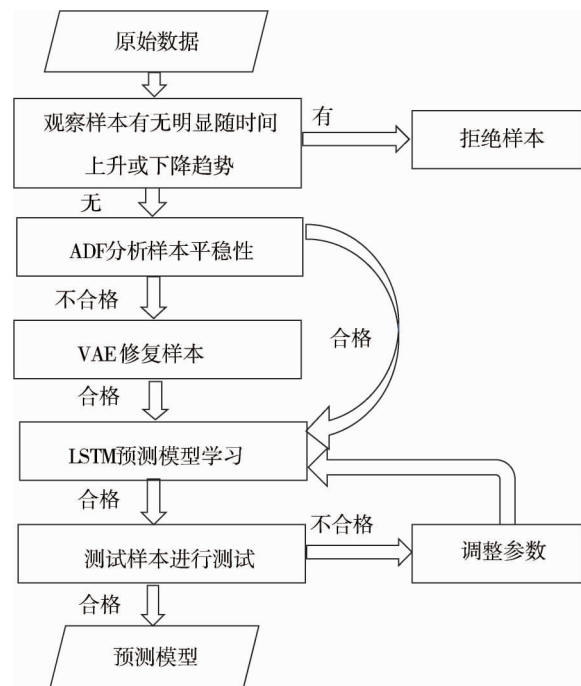


图4 预测模型建立流程

新的样本 \hat{X} , 如果说前面编码器部分是 g 函数完成, 解码器则是增加一个非线性逆变换 g^{-1} , 由这个函数完成编码. 神经网络到解码器部分反过来优化均值与方差, 为了找到合适的可修改的值来按照网络梯度下降方向学习, 这里改为对采样结果求导来完成梯度下降, 通过参数变换得式 (13).

$$\frac{1}{\sqrt{2\pi}\sigma^2} \exp\left(-\frac{(z-u)^2}{2\sigma^2}\right) dz = \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left(\frac{z-u}{\sigma}\right)^2\right] d\left(\frac{z-u}{\sigma}\right). \quad (13)$$

说明 $(z-\mu)/\sigma = \varepsilon$ 是服从均值为 0, 方差为 1 的标准正态分布的, 从 $N(\mu, \sigma^2)$ 中采样一个 z , 相当于从 $N(0, 1)$ 中采样一个 ε , 然后让 $z = \mu + \varepsilon \times \sigma$, 这样在神经网络梯度下降中改变 ε 的取值, 即可指导网络朝着最优的均值与方差去学习^[22]. 最后在 VAE 的编码器部分通过对 (μ, σ^2) 的又一次学习, 找到了 $\hat{X} = g(Z)$, 从而得到最终修复后的序列.

2.2.4 训练修复后样本

设计 LSTM 网络输入层、隐藏层与输出层. 修复后的序列 $\hat{X} = \{\hat{X}_1, \hat{X}_2, \dots, \hat{X}_n\}$ 处理成 LSTM 模型输入序列格式输入 LSTM 输入层, 隐层层数确定为 2 层, 神经元数量、训练代数根据问题规模而适当调整, 模型优化方面使用 Adam 法, 样本数据归一化处理时采用 min-max 标准化 (min-max normalization) 线性变换原始数据, 使结果值映射到 $[0, 1]$ 之上, 目标函数为均方根误差 RMSE (Root Mean Squared Error).

最终, VAE_LSTM 时序预测模型如图 5 所示.

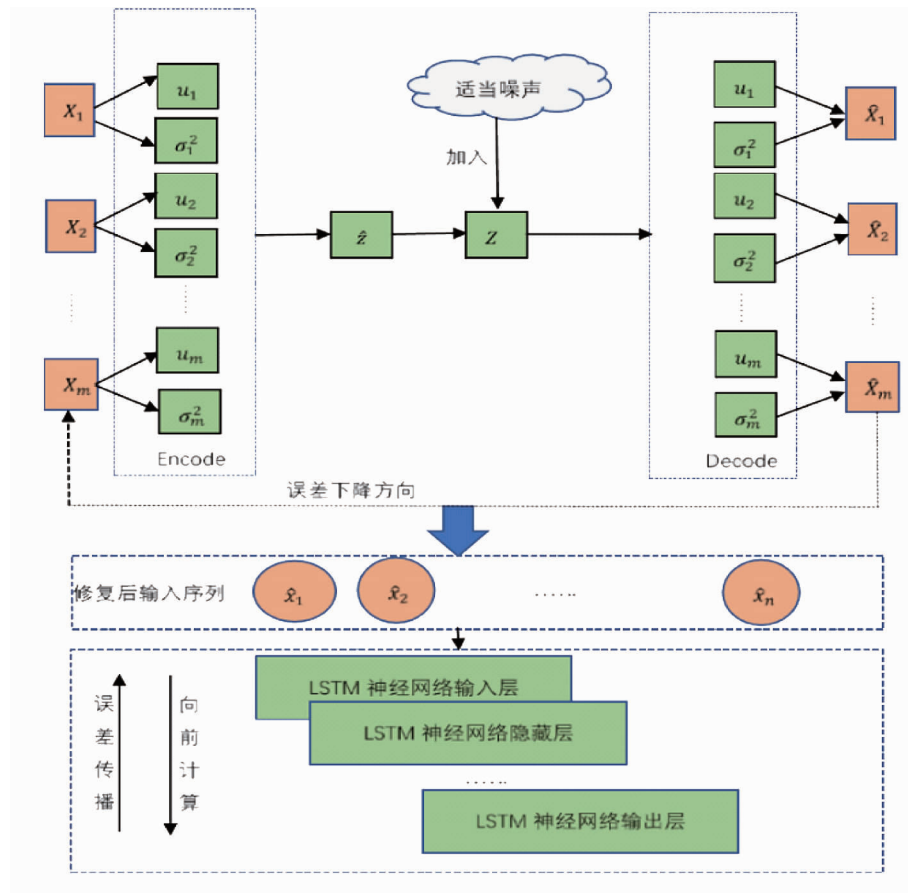


图5 VAE_LSTM 时序预测模型

2.2.5 测试模型性能

训练好 VAE_LSTM 模型后, 使用测试样本对模型性能进行测试. 本文用前 60 个月数据对未来 12 个月数据做预测, 将数据集中连续 6 a 72 个数据作为测试样本. 测试算法中长期预测准确度时, 算法中训练与测试样本长度做其他切割方式、神经单元个数做适当调整, 以使模型性能达到要求. 通过平均绝对百分比

MAPE(Mean Absolute Percentage Error)分析预测准确度.

3 实验仿真与结果分析

3.1 数据准备

选取数据集中 16 a 连续 192 个数据观察,预留后面一部分数据做测试数据.以 5 a 预测未来 1~2 a 实验来说,前 168 个数据做训练样本,后 24 个数据可作为测试样本,这时需要回看前 60 个时间点,所以测试时需输入连续的 72 和 84 个数据.

首先样本数据归一化处理,此处采用 min-max 标准化线性变换原始数据,使结果值映射到 $[0,1]$ 之上;接着计算出了其移动平均值、移动均方差值随时间的变化,计算时移动窗口数设置为 12,如图 6 所示,其中黑色的粗线条曲线为归一化后的原始数据序列、浅灰色的细线条曲线为移动平均数据序列、深灰色的细线条曲线为移动均方差序列.对数据做 ADF 检测,结果如表 1“样本修复前”一列所示,ADF 检验中 p -值表示序列有单根的概率,它的值越小则拒绝原假设(假设序列不平稳)的概率越高.从图 6 可以看到样本无时间上升或下降趋势,但移动均值与移动方差还有所波动,结合表 1“样本修复前”数据中所示: p -值约为 0.04,此处 p -值尽管不大,但仍然代表数据的平稳性可进一步改善..

为了预测得更准确,使用 VAE 算法对样本进行修复.原始样本序列与修复后样本序列如曲线图 7 所示,其中黑色曲线为修复后的效果.样本修复后再次进行数据平稳性分析,结果如图 8 与表 1“样本修复后”一列所示.图 8 与图 6 比,曲线的移动平均值、移动均方差的波动状态都相对平稳;表 1 右边两列数据比, p -值由 0.04 下降到 0.03 左右,可以认为数据序列更趋平稳.此样本作为输入预测模型的样本进行预测训练.

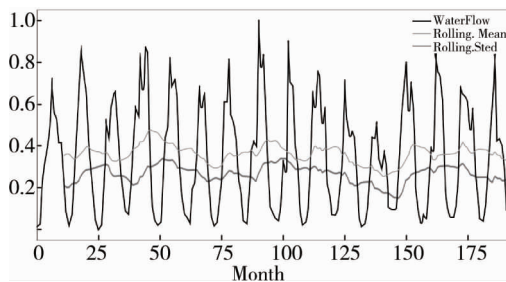


图 6 原始样本输出

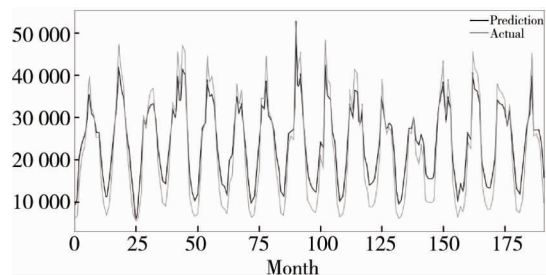


图 7 原始样本序列与修复后样本序列曲线

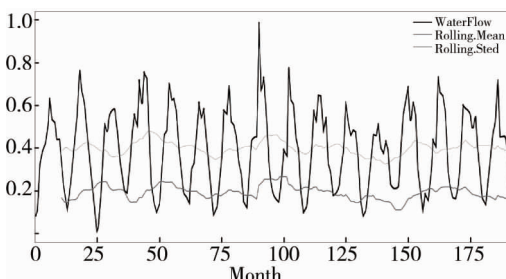


图 8 样本修复后的输出曲线

表 1 ADF 检验结果对比表

统计值	样本修复前	样本修复后
统计量	-2.94	-3.00
p -值	0.04	0.03
滞后量	12.00	12.00
观测值数量	179.00	179.00
临界值(1%)	-3.47	-3.47
临界值(5%)	-2.88	-2.88
临界值(10%)	-2.58	-2.58

3.2 VAE_LSTM 预测实验结果

3.2.1 有效性验证实验

为证明本文提出的 VAE_LSTM 算法的有效性,在实验平台上编写算法程序进行验证.将前面所重构的样本输入网络,使用 48 个神经元,迭代 40 次,用前 5 a 数据预测后 1 a 数据进行训练,用训练好的模型使用测试数据进行验证,结果如图 9 所示;接着使用前 5 a 数据预测后 2 a 数据进行训练,再用训练好的模型使用测试数据进行验证,结果如图 10 所示;最后使用前 6 a 样本预测后 3 a,结果如图 11 所示.

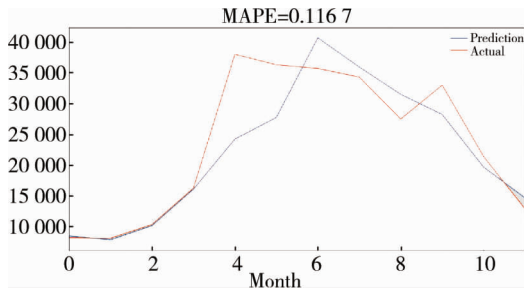


图9 5 a 预测 1 a 实验结果

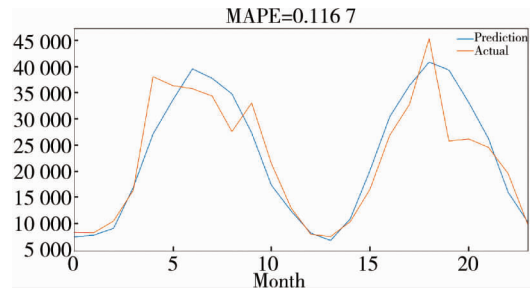


图10 5 a 预测 2 a 实验结果

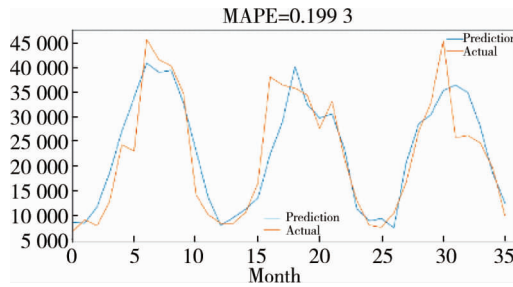


图11 6 a 预测 3 a 实验结果

从图9~图11所示3个实验不难看出,拟合的曲线效果良好,尤其在数据有明显波动的地方均拟合到,平均绝对百分比误差 MAPE 也显示出 VAE_LSTM 算法对于时间序列预测准确度较高。

3.2.2 对比性实验

1) 将 VAE_LSTM 与 LSTM 算法进行比较

选用前 5 a 60 个数据预测后 1 a 12 个数据,因为在其他结构都相同的情况下,循环神经元(LSTM cell)中隐层神经元个数的多少是产生时间消耗差异的主要原因,同时神经元越多产生过拟合现象就越明显,为了对比在相近时间消耗上 VAE_LSTM 与 LSTM 算法预测准确率,本文分别在两类算法中使 20, 40, 100 个隐层神经元进行实验, LSTM 实验结果分别如图 12 所示, VAE_LSTM 算法结果分别如图 13 所示。

从以上对比实验中不难看出,使用 VAE_LSTM 算法对测试样本拟合所得的 MAPE 分别为 0.146 8, 0.116 7, 0.111 2, 比原始的 LSTM 的 0.154 0, 0.152 1, 0.155 3 都有相应降低,从而证明了此算法提高了原 LSTM 算法预测的准确率。

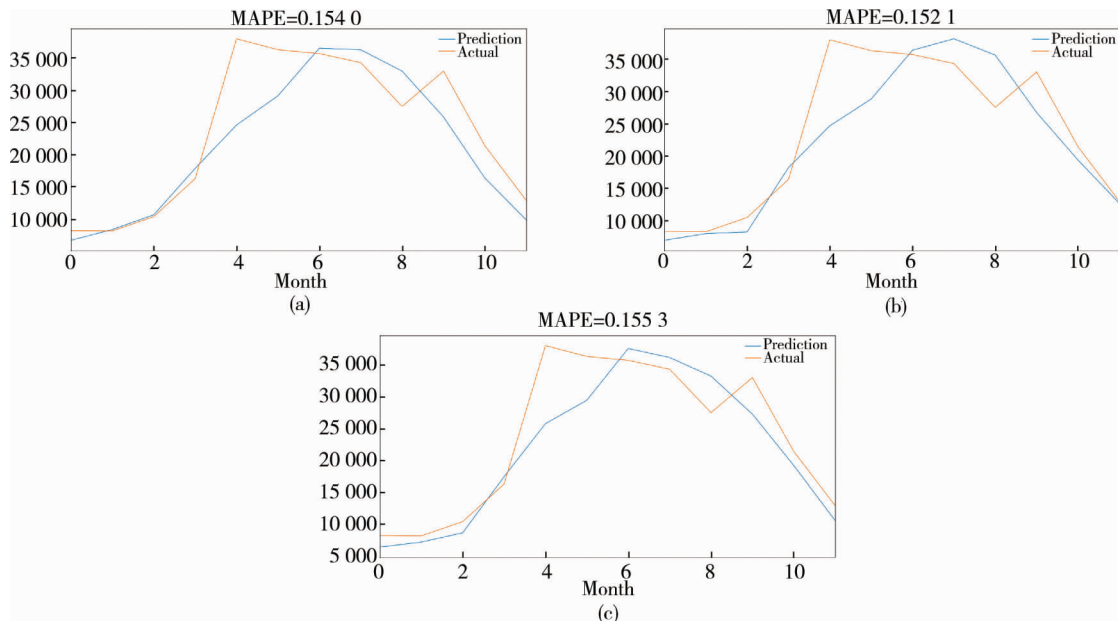


图12 LSTM 拟合曲线

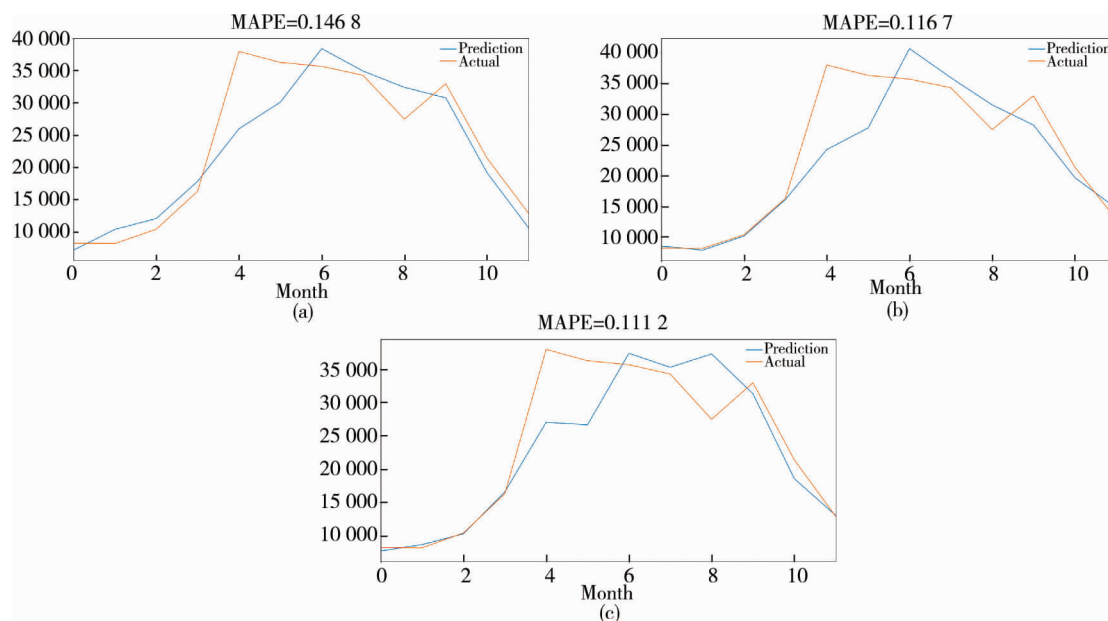


图 13 VAE_LSTM 拟合曲线

2) ARMAI, RNN, LSTM 与 VAE_LSTM 对比实验

使用 ARMAI, RNN, LSTM 与 VAE_LSTM 算法对同样数据进行学习, 然后测试模型预测效果. 第一组实验分别用不同模型预测 1 a, 第二组实验分别用不同模型预测 2 a, 第三组实验分别用不同模型预测 3 a, 表 2 是各算法结果.

从表 2 可以看出, VAE_LSTM 算法在 1, 2, 3 a 预测准确度方面均高于其他 3 类算法, 尤其是短期内的预测的优势更加明显.

3.3 实验结果分析

从图 7 中黑色曲线与灰色曲线看, 样本修复时拟合的曲线尽量保持了原始样本分布规律, 同时又修复其中存在的异常样本, 这是因为损失函数一部分鼓励概率分布密度的相似度, 另一部分则鼓励增加适当噪音, 所以修复后序列跟原序列很接近, 同时又保持了一定差异.

表 2 不同算法的预测结果比较

实验编号	ARMAI		RNN		LSTM		VAE_LSTM	
	MAPE	RSME	MAPE	RSME	MAPE	RSME	MAPE	RSME
第一组	0.303 4	5 355.72	0.301 5	7 843.20	0.156 4	4 932.18	0.116 7	4 523.76
第二组	0.298 0	5 828.153	0.353 6	7 743.06	0.175 5	5 955.08	0.142 1	4 864.74
第三组	0.316 0	6 179.135	0.311 6	6 674.32	0.243 4	5 331.38	0.199 3	5 321.83

有效性验证实验部分的结果来看, 序列的趋势与变化基本预测出来. 不论短期、中期和较长期的预测本算法都具备一定能力, 短期的预测效果更好, MAPE 能达到 0.11 左右, 算法的准确性高.

对比性实验证明, VAE_LSTM 算法提高原始 LSTM 算法的预测准确率. 原始的 LSTM 算法在两方面受限制, 第一是神经元数量的增加虽然时间成本增加, 但网络性能未有改善, 甚至会因为精确学习到“噪音”产生过拟合现象反而降低网络预测准确度, 如图 12c 所示; 第二是在神经元增加到一定程度后 (如 40 个以后) 拟合曲线仍然比较平坦, 未能在曲线出现激烈转变时学习到这个变化. VAE_LSTM 算法在这两个方面明显有改善. 其他如 ARMAI, RNN 等算法准确度亦不如本文提出的算法, 分析其原因: 初始样本中的不稳数据未经修复直接用于对未来趋势的预测, 会带来一定的误差, 正如前文所描述样本中包含了“不合格数据”, 而用 VAE 算法在神经网络中实现多元高斯分布来重构样本, 在一定程度上修复了“不合格数据”, 从而使得预测更为准确.

4 结论

1) 结合 VAE 对样本数据的修复能力与 LSTM 算法对时间序列的预测能力提出了 VAE_LSTM 算法并

建立了模型,对传统的 LSTM 算法模型进行改进,能有效地对时间序列做出预测。

2) VAE_LSTM 算法预测准确度高于 ARMAI, RNN, LSTM 等经典的序列预测算法。

3) 相对于其他算法本文提出的 VAE_LSTM 在短期内的预测能力比长期预测能力优势更明显。

参考文献:

- [1] 沈彭,魏峰.ARIMA 季节乘积模型在新疆地区细菌性痢疾发病率预测中的应用[J].重庆科技学院学报(自然科学版), 2019,21(6):99-104.
- [2] 芮少权,匡安乐.高速公路月度交通量 ARIMA 预测模型[J].长安大学学报(自然科学版),2010,30(4):82-85.
- [3] 余天伦.基于 Piotroski 方法和 ARIMA-SVR 模型的股票投资策略研究[D].广州:华南理工大学,2016.
- [4] 康国华,金晨迪,郭玉洁,等.基于深度学习的组合体航天器模型预测控制[J].宇航学报,2019,40(11):1322-1331.
- [5] 宋亚,夏唐斌,郑宇,等.基于 Autoencoder-BLSTM 的涡扇发动机剩余寿命预测[J].计算机集成制造系统,2019,25(7):1611-1619.
- [6] 朱炜玉,史斌,姜继平,等.基于水质时间序列异常检测的动态预警方法[J].环境科学与技术,2018,41(12):131-137.
- [7] 薛晔,李肖肖,付恒春.基于正态信息扩散的新多变量模糊时间序列模型研究[J].统计与决策,2018,34(24):20-24.
- [8] 李冬辉,尹海燕,郑博文,等.改进的 LSTM 方法在冷水机组传感器故障检测中的应用[J].电工技术学报,2019,34(11):2324-2332.
- [9] 彭建良,丁怡越,左晓琴.中国公路物流运价指数预测研究——基于 ARIMA-Adam-LSTM 模型的分析[J].价格理论与实践,2019(6):99-102.
- [10] 潘仲赢.基于机器学习算法的犯罪预警系统设计与实现[D].成都:电子科技大学,2019.
- [11] 熊有成,赵鸿.长短期记忆网络预测混沌时间序列[J].中国科学:物理学 力学 天文学,2019,49(12):92-99.
- [12] Khan S A, Chang H T. Comparative analysis on Facebook post interaction using DNN, ELM and LSTM[J]. PLoS ONE, 2019, 14(11):e0224452-.
- [13] 李冬辉,尹海燕,郑博文,等.改进的 LSTM 方法在冷水机组传感器故障检测中的应用[J].电工技术学报,2019,34(11):2324-2332.
- [14] 彭建良,丁怡越,左晓琴.中国公路物流运价指数预测研究——基于 ARIMA-Adam-LSTM 模型的分析[J].价格理论与实践,2019(6):99-102.
- [15] 黄娜,何经沙,孙靖超,等.基于改进 LSTM 网络的犯罪态势预测方法[J].北京工业大学学报,2019,45(8):742-748.
- [16] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [17] Kingma D P, Welling M. Auto-encoding variational Bayes[J]. stat, 2014, 1050: 10.
- [18] DOERSCH C. Tutorial on variational autoencoders[J]. stat, 2016, 1050: 13.
- [19] 郭敏,曾颖明,于然,等.基于对抗训练和 VAE 样本修复的对抗攻击防御技术研究[J].信息安全,2019(9):66-70.
- [20] Hamilton J D. Time series analysis[M]. New Jersey: Princeton University Press, 1994.
- [21] 左秀霞.单位根检验的理论及应用研究[D].武汉:华中科技大学,2012.
- [22] 苏剑林.变分自编码器(一):原来是这么一回事[EB/OL]. [2018-03-18].<https://spaces.ac.cn/archives/5253>.
- [23] KINGMA D P, BA J. Adam: A Method for stochastic optimization[J]. Computer Science, 2014.
- [24] Kannan S, Yengera G, Mutter D, et al. Future-state predicting LSTM for early surgery type recognition[J]. IEEE Transactions on Medical Imaging, 2019,39(3): 556-566..
- [25] Li Y, Zhu Z F, Kong D, et al. EA-LSTM: Evolutionary attention-based LSTM for time series prediction[J]. Knowledge-Based Systems, 2019,181: 104785.
- [26] Şahin A, Sayimlar A D, Teksan Z M, et al. A Markovian approach for time series prediction for quality control[J]. IFAC PapersOnLine, 2019,52(13): 1902-1907.