

DOI: 10.19333/j.mfkj.20230400608

基于深度学习的快时尚服装产品销售预测模型构建

李鑫¹, 胡永仕¹, 邵博², 苏晓丽³

(1. 福建理工大学 交通运输学院, 福建 福州 350118; 2. 美国威斯康星大学麦迪逊分校 工程学院, 美国 麦迪逊 53706;
3. 福州大学 经济与管理学院, 福建 福州 350108)

摘要:为了准确预测快时尚服装产品销售量,捕捉在间歇性或异常峰值销量中的时间信息,基于深度自回归模型,引入时间注意力机制,改进其网络结构设计,构建全局时序模型对快时尚服装产品销售进行预测。研究发现:基于注意力机制的深度自回归模型,能够从所有销售数据中有效学习到服装产品销售正常值与间歇性或异常峰值的时间关联关系,能够识别复杂模式下产品销售量的短期波动与长期趋势,且性能优于其他经典模型,验证了基于深度学习构建快时尚服装产品销售预测模型的可行性。

关键词:深度学习;销售预测;数据驱动;快时尚;AT-DeepAR 模型

中图分类号:TS 941

文献标志码:A

Construction of fast fashion clothing sales prediction model based on deep learning

LI Xin¹, HU Yongshi¹, SHAO Bo², SU Xiaoli³

(1. School of Transportation, Fujian University of Technology, Fuzhou, Fujian 350108, China; 2. College of Engineering, University of Wisconsin-Madison, Madison 53706, USA; 3. School of Economics and Management, Fuzhou University, Fuzhou, Fujian 350108, China)

Abstract: In order to accurately predict the sales volume of fast fashion clothing products and capture the time information in the intermittent or abnormal peak sales volume, based on the deep autoregressive model, the time attention mechanism was introduced, the network structure design was improved, and the global timing model was constructed to predict the sales volume of fast fashion clothing products. The study found that the deep autoregressive model based on the attention mechanism can effectively learn the time correlation between the normal sales value of clothing products and the intermittent or abnormal peak value from all sales data, and can identify the long-term trend and short-term fluctuations of product sales under complex patterns, and its performance is better than other classical models. The feasibility of constructing fast fashion clothing sales forecasting model based on deep learning was verified.

Keywords: deep learning; sales prediction; data driven; fast fashion; AT-DeepAR model

销售预测是快时尚服装企业生产决策中的重要环节,根据快时尚服装产品销售预测制定合理的订货策略、降低库存水平,优化库存结构等,是快时尚服装企业在实际经营中的追求目标。随着互联网技

术的高速发展和广泛应用,网络平台实现了多边供需对接和即时交易,推动了服装行业多渠道零售的发展。在多渠道零售中,快时尚服装企业可以通过其网站、实体店以及不同平台或市场销售产品,即线

收稿日期:2023-04-05

基金项目:国家社会科学基金项目(20BGL112)

第一作者:李鑫,硕士生,主要研究方向为机器学习,E-mail:lx1592421854@163.com。

通信作者:苏晓丽,博士生,主要研究方向为机器学习和数据挖掘,E-mail:210710012@fzu.edu.cn。

上线下多渠道、多触点触达目标消费者,直接面对碎片化、个性化、多样化的订单需求。在这种复杂和需求不确定的销售环境下,传统的销售预测方法在企业实际经营中暴露出越来越多的问题,如无法快速响应需求波动、库存积压和库存周转率过高等。特别是在“双十一”“618”等促销期间,快时尚服装产品销售量变动趋势异常,与常规时期的销量存在较大偏差,存在间歇性或异常峰值的销量轨迹,这导致快时尚服装企业更加难以准确预测产品订单需求。

目前,国内外服装销售定量预测主要采用时间序列法^[1](Time Series Prediction Method, TSPM)、灰色预测模型(Grey Models, GM)^[2-3]和人工神经网络(Artificial Neural Network, ANN)^[4-5]等。这些预测方法简单易行,但受限于拟合能力和信息利用率,预测精度还待提升,尤其是多渠道销售环境下产品销售受各类复杂因素的影响,仅靠单一的历史销量时间特性很难实现精准的预测。因此,有学者采用循环神经网络(Recurrent Neural Network, RNN)等模型识别关键的影响因素,拟合复杂的非线性映射关系,并以此进行预测获得更精准的预测结果^[6-7]。然而,这些模型对于较长时间序列的预测仅依靠上一时刻的输出,忽略了编码阶段每个时刻的输出,存在记忆丢失和无法捕获长周期、季节等信息的问题,难以准确获取和权衡多渠道销售环境下常规销售与促销销售的时间关联性。

信息科学与计算机技术的不断进步,使得海量多源的企业销售数据得以收集存储,即可以应用大数据、深度学习等新技术对快时尚服装企业销售数据进行观测和分析^[8]。因此,本文基于深度学习提出了注意力深度自回归(Attention-based Autoregressive Recurrent Neuralnetwork, AT-DeepAR)销售预测模型,通过改进深度自回归模

型(Autoregressive Recurrent Neuralnetwork, DeepAR)网络结构设计,在解码层引入时间注意力机制(Attention Mechanism, AT),筛选出有效信息以增强当前使用的隐藏向量,从全局角度对不同时间步的时间序列向量进行自适应加权,以期增强预测间歇性和异常峰值等复杂情况的能力,为快时尚服装产品销售预测提供决策参考。

1 基于 AT-DeepAR 的快时尚服装销售预测模型构建

快时尚服装产品的销售受产品特征和销售季节影响,呈现不确定性特点。为提高预测精度,深度学习模型增加了产品数据输入维度,如收藏人数、客单价等,以捕捉产品自身潜在信息。然而,针对销售季节的不确定性,需要采用基于时间的服装产品特征协变量。为此,本文提出了一种嵌入注意力机制的 DeepAR 模型,用于快时尚服装产品销量预测。该模型量化了产品特征数据,融合了时间信息,并进行了概率分布输出。

1.1 嵌入注意力机制的 DeepAR 模型构建

DeepAR 模型由 Salinas 等^[9]学者提出。模型的目标是建立条件概率分布:

$$P(z_{i,t_0:T} | z_{i,1:t_0-1}, \mathbf{x}_{i,1:T}^p) \quad (1)$$

式中:定义第 i 个快时尚服装产品在时间 t 的销售值为 $z_{i,t}$,将整个时期 T 以 t_0 为划分时间点,得到联合条件概率分布 $P(z_{i,t_0:T} | z_{i,1:t_0-1}, \mathbf{x}_{i,1:T}^p)$,即根据快时尚服装产品历史销售数据 z_{i,t_0-1} 和服装产品特征协变量(产品 p 维属性特征) $\mathbf{x}_{i,1:T}^p$,对未来的服装产品销量 $z_{i,t_0:T}$ 进行建模。

AT-DeepAR 模型的基本结构框架如图 1 所示,其中长短期记忆神经网络(Long Short-Term Memory, LSTM)模型中 t 时刻的单元状态。

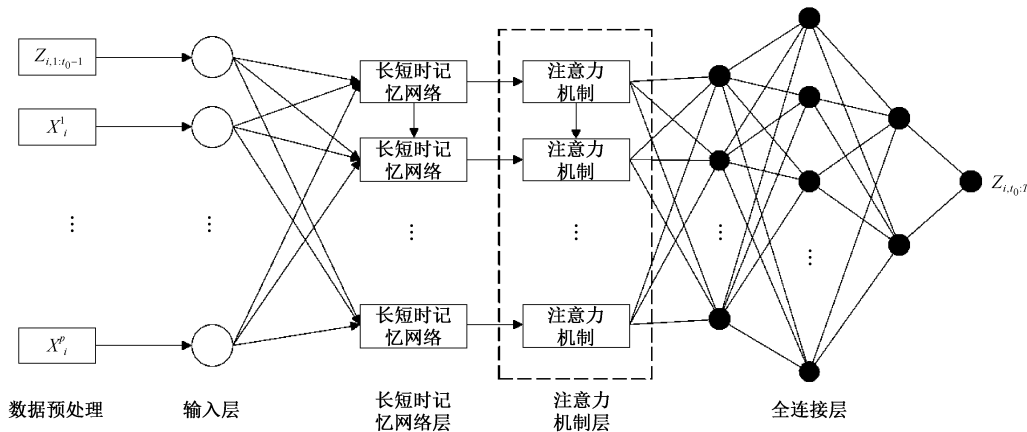


图 1 AT-DeepAR 模型结构框架

Fig. 1 Structure framework of AT-DeepAR model

图 1 中,本文构建的模型在 DeepAR 解码层上引入注意力机制(AT),改进其网络结构,使模型优先关注到对当前销售时刻影响较大的销售数据。在模型中,条件概率分布看成一系列时刻下似然因子的连乘:

$$Q_{\Theta}(z_{i,t_0:T} | z_{i,1:t_0-1}, \mathbf{x}_{i,1:T}^p) = \prod_{t=t_0}^T Q_{\Theta}(z_{i,t_0:T} | z_{i,1:t_0-1}, \mathbf{x}_{i,1:T}^p) = \prod_{t=t_0}^T \ell(z_{i,t} | \theta(\mathbf{A}h_{i,t}, \Theta)) \quad (2)$$

$$\mathbf{A}h_{i,t} = h(\mathbf{A}h_{i,t-1}, z_{i,t-1}, \mathbf{x}_{i,1:T}^p, \Theta) \quad (3)$$

式中: h 代表 LSTM 和注意力机制协同的循环网络; $\mathbf{A}h_{i,t}$ 是融合注意力机制的自回归循环网络的输出,表示不同时刻的快时尚服装产品历史销量及其特征协变量在预测输出时的重要性。而为了获取 t 时刻的 $\mathbf{A}h_{i,t}$,分别输入了网络在上一时刻的输出 $\mathbf{A}h_{i,t-1}$,上一时刻的服装产品历史销量 $z_{i,t-1}$,和当前时刻的服装产品特征协变量 $\mathbf{x}_{i,1:T}^p$ 和模型参数 Θ 。

似然函数 $\ell(z|\theta)$ 对模型噪声起作用,故选择适合数据统计性质的似然函数至关重要。本文收集的销量数据属于连续型数据,考虑使用高斯似然和负二项分布 2 个函数进行实验。

1.2 嵌入注意力机制的 DeepAR 网络设计

图 1 所示 DeepAR 模型的重要网络结构是 LSTM 算法,该算法由记忆细胞、更新门、遗忘门、输出单元构成,可解决时间循环神经网络的梯度爆炸和梯度消失问题,能够捕捉长期时间关联性^[10]。融合服装产品多特征的方式,能提高预测模型对历史销量数据的利用能力,达到学习长期依赖信息的效果,但同时也引发了一个不可忽略的问题:即使输入样本中不同历史时刻产品销量对当前销量的影响并不一致,但 LSTM 依然会对其同等对待。这个问题限制了窗口化数据作为模型输入的优势,而注意力机制通过评估事物重要性程度确定权重,以减少无关信息的干扰^[11]。因此,本文在对 DeepAR 模型的网络结构改进时,引入注意力机制,利用其优越的时间关联自学习能力,确定服装产品销量的时间重要性,对其重要时间节点分配权重,以期进一步提升服装产品销量预测的准确性。图 2 为融合注意力机制的 DeepAR 模型的循环网络结构,其中 $h_{i,t}$ 代表 LSTM 的输出值。

嵌入注意力机制的 DeepAR 模型的网络结构共为 2 部分:模型训练和模型预测。在模型训练过程中(见图 2(a)),服装产品历史销量都是已知的,利用注意力机制对服装产品销量及其特征数据进行时间权重分配,然后计算下一刻的似然函数,通过最大

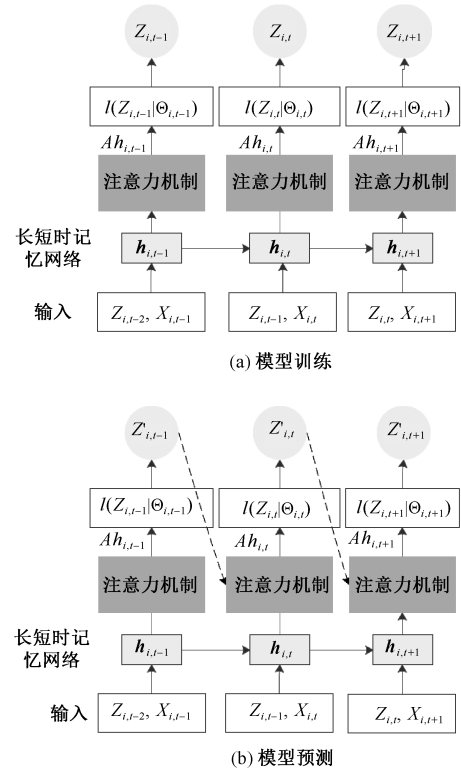


图 2 融合注意力机制的 DeepAR 模型的网络结构设计

Fig. 2 Network structure design of DeepAR model integrating AT mechanism. (a) Model training; (b) Model prediction

化似然函数来实现对模型参数的训练。在模型预测过程中(见图 2(b)),未来服装产品销量是未知的,因此采用注意力机制来整合服装产品抽样数据的权重学习结果,得到一个估计产品销量 $z'_{i,t-1}$,然后输入到下一时刻的注意力机制模块中,通过不断迭代得到预测结果。具体的工作原理如图 3 所示。




图 3 具体的工作原理

Fig. 3 Specific working principles

图 3 展示了注意力机制融合 DeepAR 模型的网络结构的工作原理,具体的操作步骤如下:

首先,将快时尚服装产品历史销量及其特征数据输入到编码器,然后输出到注意力机制中处理,对编码器的输出产品数据根据式(4)计算注意力权重向量 $e_{i,t}$ 。

$$e_{i,t} = \tanh(W_d [h_{i,t}; s_{i,t-1}] + b_d) \quad (4)$$

式中: W_d 是需要模型学习的权重矩阵; $h_{i,t}$ 是编码器的隐藏状态; $s_{i,t-1}$ 是上一个时刻编码器的单元状态; b_d 是全连接层的偏置向量。

模型经过多次训练之后,得到表示隐藏状态相关性的 $e_{i,t}$,通过式(5)中的 softmax 函数进行归一化,得到每个时刻的注意力概率 $\beta_{i,t}$ 。

$$\beta_{i,t} = \frac{\exp(e_{i,t})}{\sum_{i=1}^T \exp(e_{i,t})} \quad (5)$$

其次,在 t 时刻的上下文向量通过式(6)加权聚合,不同时刻的隐藏状态分配的权重大小不同,注意力层的输出最终进入解码层 LSTM 门控单元的向量 $Ah_{i,t}$:

$$Ah_{i,t} = \sum_t \beta_{i,t} h_{i,t} \quad (6)$$

最后,使用 LSTM 网络结构进行信息整合输出,具体地,在时刻 t ,LSTM 层的计算如公式(7)~(12)所示。遗忘门通过 Sigmoid 函数 σ 决定从记忆细胞 $C_{i,t}$ 中是否丢弃某些信息,通过接受来自输入 $Ah_{i,t}$ 和上一层隐含状态 $h_{i,t-1}$ 的值进行合并后加权计算生产系数 $f_{i,t}$ 。输入门决定当前输入 $Ah_{i,t}$ 是否丢弃某些信息,生成系数 $i_{i,t}$ 。神经元更新生成当前时刻的状态 C_t ,其中需要使用 tanh 函数计算记忆细胞的候选值 $C'_{i,t}$, \otimes 为乘操作。输出门基于 C_t 决定新的记忆是否丢弃某些信息后输出隐含状态 $h_{i,t}$, W 和 b 分别表示权重矩阵和偏置向量。

$$f_{i,t} = \sigma(W_f^* [h_{i,t-1}, Ah_{i,t}] + b_f) \quad (7)$$

$$i_{i,t} = \sigma(W_i^* [h_{i,t-1}, Ah_{i,t}] + b_i) \quad (8)$$

$$C'_{i,t} = \tanh(W_c^* [h_{i,t-1}, Ah_{i,t}] + b_c) \quad (9)$$

$$C_{i,t} = f_{i,t} \otimes c_{i,t-1} + i_{i,t} \otimes C'_{i,t} \quad (10)$$

$$o_{i,t} = \sigma(W_o [h_{i,t-1}, Ah_{i,t}] + b_o) \quad (11)$$

$$h_{i,t} = o_{i,t} \otimes \tanh(C_{i,t}) \quad (12)$$

2 基于 AT-DeepAR 的快时尚服装销售预测模型应用

2.1 快时尚服装销售数据的采集与预处理

本文利用某快时尚服装企业产品的日销售量、收藏人数等销售数据,对采集到的历史数据进行分析 and 预处理。如检查服装产品数据中是否存在缺失

值、剔除因记录错误产生的数据、对产品特征中不同品类进行特征编码、统一产品特征单位等操作,然后对预处理后的数据进行探索性数据分析,先从不同时间维度探索分析店铺的日销量,再从多特征角度观察特征对销量的影响。通过上述操作,得到 2021 年 4 月 4 日—2022 年 6 月 20 日(即 $T = 443$) 的实验样本数据,销量数据整体情况如图 4 所示。为了验证 AT-DeepAR 模型对异常情况的预测能力,选择复杂模式下存在异常峰值的期间(2022 年 5 月 21 日—2022 年 6 月 21 日)作为测试集进行销售预测。表 1 是产品相关数据的统计性描述。




图 4 产品销量数据的趋势

Fig. 4 Trends in product sales data

表 1 产品数据的特征及其描述

Tab. 1 Characteristics of product data and description

名称	描述	示例
日期	产品销售的日期	2021-04-04
交易金额	产品的交易总金额	188
访问人数	全店各页面的访问人数	21
搜索人数	搜索此关键词的人数	2
加购人数	产品加入购物车里的件数	1
客单价	顾客平均购买产品的金额	187.81
UV 价值	淘宝中的访问价值	13
直通车访客人数	直通车的访问人数	2
直通车花费	直通车充值使用	0
销售量	当天产品销售量	1
收藏人数	用户点击收藏的数量	2 636

2.2 快时尚服装销售预测模型的设计

①模型设计。构建 AT-DeepAR 销量预测模型,首先初步设置神经网络显隐层节点数、隐藏层状态、隐层层数等参数,得出 LSTM 的输出销量值;其

次将 LSTM 结果加权聚合得到注意力层的输出销量向量,实现数据信息的时间关注程度的权重和学习;再次通过聚合输出 LSTM 的结果,同时得到最大似然函数;最后建立未来服装产品销量的条件概率分布。

②模型实现步骤。首先,将预处理后的数据划分为训练集和测试集,使用训练数据训练模型,进行销量概率预测输出;然后测试集测试训练好的模型,根据测试结果微调模型的参数,以提高模型的预测精度;最后将模型预测结果和真实数据进行误差对比,检查模型预测效果是否达到最佳,如达到最佳则输出预测结果,否则需要返回重新对模型内部结构参数进行调节,同时观察预测结果的变化,直到达到预测效果的最佳值。

2.3 快时尚服装销售预测模型评价指标的选取

为了客观评价复杂模式下特定时期的销售预测模型性能,选用 2022 年“618”预售促销期间的销售预测作为验证对象(其他“双十一”“双十二”等具有类似的特征,不再赘述)。将 2021 年 4 月 4 日—2022 年 5 月 20 日的销量数据(即 $t_0 = 412$)作为训练集,2022 年 5 月 21 日—2022 年 6 月 21 日(即 $T - t_0 = 31$)为测试集,从 3 个维度对各个模型进行评估。

①确定性评价指标。考虑到真实销售量中存在零销售量的情况,故采用均方根误差(Root Mean Squared Error, $RMSE$)^[12]、平均绝对误差(Mean Absolute Error, MAE)^[13]和均方误差(Mean Squared Error, MSE)^[14]进行评估,公式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (13)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (14)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (15)$$

式中:假设 \hat{y}_i 表示时间 i 的服装销量预测值(AT-DeepAR 模型和 DeepAR 模型中表示销量预测值的中位数), y_i 表示时间 i 的真实销售量, N 表示预测总天数。

②概率性评价指标。预测区间覆盖概率(Prediction Interval Coverage Probability, $PICP$)、预测区间归一化平均宽度(Prediction Interval Normalized Average Width, $PINAW$)和覆盖宽度标准(Coverage Width Criterion, CWC)^[15]。

$$PICP = \frac{1}{N} \sum_{i=1}^N I_i \times 100\% \quad (16)$$

$$I_i = \begin{cases} 1, & y_i \in [W_{t,1}, W_{t,z}] \\ 0, & y_i \notin [W_{t,1}, W_{t,z}] \end{cases} \quad (17)$$

式中: $[W_{t,1}, W_{t,z}]$ 是预定覆盖范围内的上下区间, I_i 为布尔量当第 t 个时刻的实际值在预测区间内时, I_i 赋值为 1,反之 I_i 赋值为 0。 $PICP$ 越大,表示真实值落在预测区间的概率越大。除了评估可靠性外,还需要 $PINAW$ 评估区间预测的不确定性,公式如下:

$$PINAW = \sum_{i=1}^N \frac{W_{t,z} - W_{t,1}}{ND} \quad (18)$$

式中: $PINAW$ 为目标销量值的最大值与最小值之间的差值, $PINAW$ 越小,预测宽度越小,得出结果避免不确定性风险的能力更强。

为了综合考虑预测区间的覆盖率和狭窄程度,采用 CWC 全面评估预测区间的准确性。

$$CWC = PINAW(1 + \gamma e^{-\eta(PICP - \mu)}) \quad (19)$$

$$\gamma = \begin{cases} 0 & PICP \geq \mu \\ 1 & PICP < \mu \end{cases} \quad (20)$$

式中: η 和 μ 是决定惩罚程度的参数, $\eta = 50$, μ 由置信区间决定,本文采用 90% 置信区间,故 $\mu = 0.9$; γ 为布尔量,当 $PICP$ 不低于 μ 时表示 CWC 由 $PINAW$ 决定,反之,由于惩罚因子 η 的存在导致 CWC 变大, CWC 越大,模型效果越差。

3 结果与分析

3.1 多特征对预测精度的影响

为快速检测到产品销售的异常波动,提高对销售预测的长期趋势与短期特征的敏感度,对产品输入协变量信息(产品本身特征数据)进行分析。图 5 示出皮尔逊相关系数的热力图,旨在分析特征对需求的相关性。其中,对于产品需求而言,受影响最大的特征变量为加购人数,相关系数高达 93%,而客单价却呈现出负相关的趋势。为了进一步验证单特征与多特征、正相关与负相关对需求的影响程度,设计 3 个实验组进行实验,分别为选择相关系数最大的支付人数作为单特征变量、剔除负相关变量作为正相关特征变量和全部特征作为多特征变量。对比分析 AT-DeepAR 模型在 3 个实验中预测性能的差异,根据 2.3 节所述的 3 种误差测量指标对预测结果进行评估,全面阐述特征变量对于需求的影响效果,分析融合多源信息的必要性。

表 2 示出 AT-DeepAR 模型对单特征、正相关特征和多特征输入的误差对比,对于确定性预测结果来说,多特征模型取得最佳效果,其 $RMSE$ 误差率相对于单特征输入模型降低 44.03%,充分证明产品特征对预测精度存在较大影响,故挖掘产品数据




图 5 服装产品需求相关性矩阵热力图
Fig. 5 Thermal map of correlation matrix of demand for apparel products

的协变量信息,提高产品数据的使用程度,对提高模型的预测精度具有正向作用。但是只使用正相关的特征进行预测的误差结果显示,并不是所有正相关的变量叠加到一起,结果是最佳的。对于概率预测结果来说,使用相关系数最大的单特征模型和多特征输入的模型都取得了 93.75% 的覆盖率。但是使用多特征输入的模型取得了最小的概率宽度,得到的综合概率指标是最佳的,在规避不确定风险的同时,提高了预测精度。但是反观正相关特征变量模型的结果依然不尽如人意,在取得最大概率宽度的情况下,才取得 90.63% 的覆盖率,较其他 2 个模型减少了 3.12% 的覆盖率,最终的综合评价指标最差。

表 2 多特征与单特征输入对 AT-DeepAR 的预测结果对比

评价指标	RMSE	MAE	MSE	PICP	PINAW	CWC
单特征	5.11	4.00	26.12	93.75%	0.54	0.545
正相关	10.95	8.76	120.00	90.63%	1.07	1.070
多特征	2.86	1.63	8.20	93.75%	0.29	0.290

3.2 感知时间权重对预测精度的影响

为了评估本文提出的注意力机制模块结合产品多特征输入对模型预测精度的影响,本文将 2.3 节所述的 3 种误差测量对 DeepAR 模型与 AT-DeepAR 模型的预测结果分别进行比较,根据参数指标对模型的有效性进行检验。2 个模型最后都预测未来一个月的销售量,概率预测默认输出 90% 置信区间的预测结果。

本文提出的销售量预测模型的最佳参数如下。模型似然函数选择高斯似然函数 (Gaussian

likelihood), LSTM 共包含 3 层隐层结构,每层神经元数量各为 50 个。训练次数 (epoches) 为 300,每次训练步数 (step) 为 3。确定最佳参数训练模型,以 2022 年“618”期间的需求预测作为验证对象,并与真实值进行对比,结果如图 6 所示,具体评价指标见表 3。

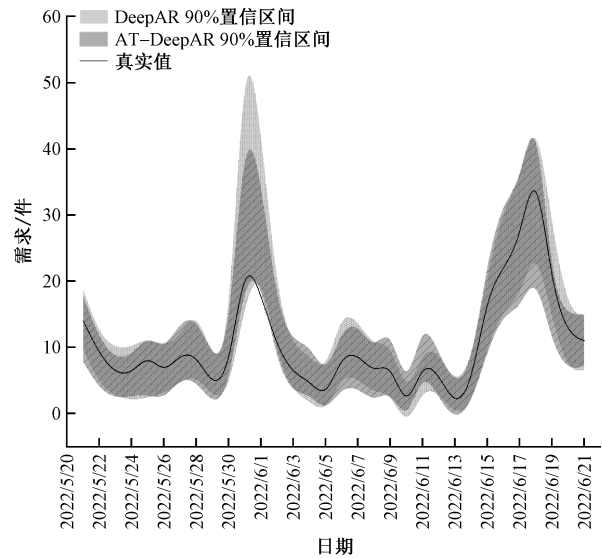


图 6 有无注意力机制的 DeepAR 的预测结果
Fig. 6 Prediction results of DeepAR with and without AT mechanism

表 3 多特征输入下有无注意力机制的预测结果对比
Tab. 3 Comparison of prediction results with and without AT mechanism under multi-feature input

评价指标	RMSE	MAE	MSE	PICP	PINAW	CWC
DeepAR	4.10	1.86	16.82	80.65%	0.25	21.73
AT-DeepAR	2.86	1.63	8.20	93.75%	0.29	0.29

由图 6 看出,2 个模型的大部分实际值均落在 90% 置信区间内,改进的模型覆盖率比未改进时提高 13.10%,有效识别到异常峰值回落坡度较陡的预测(图中小图为放大后效果),也由于 PINAW 值较大,使得 PICP 值增大,但观察综合指标 CWC,发现改进后的模型在总体效果上,较未改进模型评估不确定风险的能力更强。表 3 展示了 AT-DeepAR 模型对需求预测的长期趋势与短期特征敏感,无论是确定性评价指标还是概率性评价指标,其预测精度均优于 DeepAR,可见本文提出的注意力机制模块可行、有效。

3.3 AT-DeepAR 与经典模型的精度比较

为了凸显模型把握长期趋势和短期波动优势,本文将提出的 AT-DeepAR 与 DeepAR 以及较为经典的 LSTM 和 Holt-Winters 模型利用 2.3 节的评价指标对预测结果进行评估。所有模型均使用

2022 年“618”期间的需求预测作为验证对象,均采用 2.3 节的参数指标,预测结果如图 7 所示,具体评价指标见表 4。

由图 7 和表 4 可以看出,本文提出的 AT-DeepAR 模型在“618”销售量的预测效果均优于 DeepAR、LSTM 模型和 Holt-Winters 模型。可见,对于“618”销售量这种具备长期趋势与短期波动的销售数据,Holt-Winters 模型仅对单一时间序列进行预测,尽管它能够准确刻画短期内的细节波动,然而在长期趋势上存在明显的滞后,当出现波动较大时,无法准确拟合。如果使用 LSTM 建模,结合产品多特征输入进行预测,虽然对趋势拟合优于 Holt-Winters 模型,但在多步预测上存在误差累积,对于异常峰值的预测仍有提升空间。而本文提出的预测方法 AT-DeepAR 模型,同样结合产品自身多特征进行预测,能够兼顾趋势预测与细节波动,输出为概率分布,可以评估出预测的不确定性和相关的风险。与经典模型相比,该模型有更好的鲁棒性,预测精度更高。

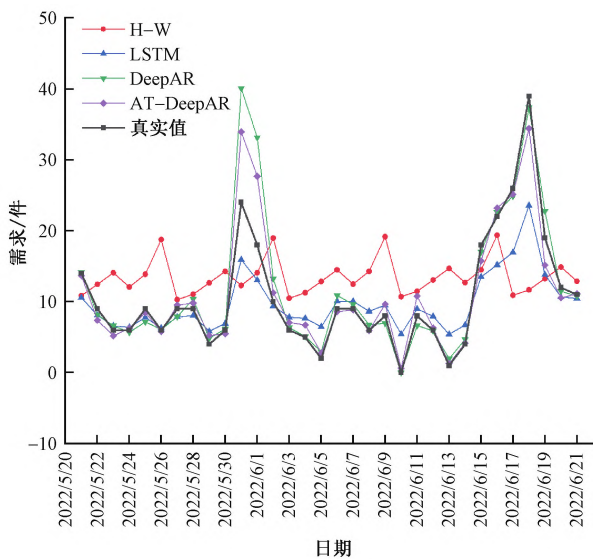


图 7 各个模型预测结果

Fig. 7 Prediction results of each model

表 4 各个预测模型的预测性能评估

Tab. 4 Evaluation of the forecasting performance of each forecasting model

评价模型	RMSE	MAE	MSE
AT-DeepAR	2.86	1.63	8.20
DeepAR	4.10	1.86	16.82
LSTM	4.43	3.09	19.63
Holt-Winters	8.99	7.38	80.83

4 结束语

本文旨在优化深度自回归模型(DeepAR)的网

络结构,构建一种新型的快时尚服装企业销量预测模型。该模型引入基于时间权重的注意力机制,此机制能够有效识别并学习时间序列数据中各隐藏状态之间的时间关联性。为了提升模型对历史销售数据的分析深度和广度,选取包含多种解释性变量的产品特征数据作为输入,这一做法特别针对间歇性波动或异常销售峰值等复杂情况下的数据捕捉和处理。最后,模型能够准确预测特定时间段内的销量概率分布,评估出快时尚服装企业销售的不确定性和相关的风险。在实证研究中,使用快时尚服装企业的销售数据进行模型验证。验证结果显示,若忽略产品特征的影响,对需求突增的趋势将产生滞后,对于波动检测不灵敏。相反,在产品销售多特征输入的情况下,模型能够更好的拟合产品销售的突变情况,其预测精度相比仅依赖单一特征输入的传统模型有显著提升。然而,在处理正相关变量时,模型对于正相关变量的权重分配不均衡,仍有改进空间。值得一提的是,基于注意力机制的 DeepAR 模型具有优越的时间关联自学习能力,在预测促销时期需求时表现优异,预测精度均高于经典的 DeepAR 模型、LSTM 模型和 Holt-Winters 模型,具有一定的实际应用价值。未来工作可以考虑融入用户评论因素等相关控制变量,增高输入维度并探讨特征质量对于预测效果的影响机理。

参考文献:

[1] ISSAO C G, MARIA M L M. Time series models: an analysis of demand forecast accuracy for a product line in a clothing company[J]. Revista Gestão da Produção Operaçõe e Sistemas, 2020, 15(4): 219-251.

[2] 王昕彤,王秀敏,郭瑞良,等. 基于灰色理论的服装企业销售预测模型[J]. 丝绸, 2020, 57(2):55-60. WANG Xintong, WANG Xiumin, GUO Ruiliang, et al. Sales prediction model of clothing enterprises based on grey theory[J]. Journal of Silk, 2020, 57(2): 55-60.

[3] 黄鸿云,刘卫校,丁佐华. 基于多维灰色模型及神经网络的销售预测[J]. 软件学报, 2019, 30(4): 1031-1044. HUANG Hongyun, LIU Weixiao, DING Zuohua. Sales forecasting based on multi-dimensional grey model and neural network [J]. Journal of Software, 2019, 30(4): 1031-1044.

[4] 圣文顺,赵翰驰,孙艳文. 基于改进遗传算法优化 BP 神经网络的销售预测模型[J]. 计算机系统应用, 2019,28(12):200-204. SHENG Wenshun, ZHAO Hanchi, SUN Yanwen. Sales forecasting model based on BP neural network optimized by improved genetic algorithms [J]. Computer Systems & Applications, 2019, 28(12): 200-204.

[5] 汪芸芳,史意,陈丽华. 基于 BP 神经网络及灰色 GM(1,1)模型的服装供应链第三方库存预测应用研究[J]. 数学的实践与认识, 2020, 50(3): 277-285.

- WANG Yunfang, SHI Yi, CHEN Lihua. Third-party inventory forecasting application research of apparel supply chain based on BP neural network and grey GM(1,1) model [J]. *Mathematics in Practice and Theory*, 2020, 50(3): 277-285.
- [6] LIU P, MING W, HU B. Sales forecasting in rapid market changes using a minimum description length neural net-work [J]. *Neural Computing and Applications*, 2021, 33(3): 937-948.
- [7] CHANDRIAH K K, NARAGANAHALLI R V. RNN/LSTM with modi-fied adam optimizer in deep learning approach for automo-bile spare parts demand forecasting [J]. *Multimedia Tools and Applications*, 2021, 80(17): 26145-26159.
- [8] 朱君然,王保鲁. 基于 BP 神经网络的跨境电商买手平台选品模型构建 [J]. *毛纺科技*, 2021, 49(6): 80-83.
- ZHU Junran, WANG Baolu. Construction of product selection system for cross-border buyer platform based on BP neural network [J]. *Wool Textile Journal*, 2021, 49(6): 80-83.
- [9] SALINAS D, FLUNKERT V, GASTHAUS J, et al. DeepAR: probabilis-tic forecasting with autoregressive recurrent networks [J]. *International Journal of Forecasting*, 2020, 36(3): 1181-1191.
- [10] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9 (8): 1735-1780.
- [11] 陈海涵,吴国栋,李景霞,等. 基于注意力机制的深度学习推荐研究进展 [J]. *计算机工程与科学*, 2021, 43(2):370-380.
- CHEN Haihan, WU Guodong, LI Jingxia, et al. Research advances on deep learning recommendation based on attention mechanism [J]. *Computer Engineering and Science*, 2021, 43(2):370-380.
- [12] HONF J K. LSTM-based sales forecasting model [J]. *KSII Transactions on Internet and Information Systems (TIIS)*, 2021, 15(4): 1232-1245.
- [13] LI Y, YANG Y, ZHU K, et al. Clothing sale forecasting by a composite GRU-prophet model with an attention mechanism [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(12):8335-8344.
- [14] DELLINO G, LAUDADIO T, MARI R, et al. Microforecasting methods for fresh food supply chain management: a computational study [J]. *Mathematics and Computers in Simulation*, 2018, 147: 100-120.
- [15] SAEED A, LI C, DANISH M, et al. Hybrid bidirectional LSTM model for short-term wind speed interval prediction [J]. *IEEE Access*, 2020, 8: 182283-182294.