

文章编号: 2095-2163(2020)05-0118-04

中图分类号: TP399; TP18

文献标志码: A

旅游需求量预测算法研究

王雷雪

(西安石油大学 计算机学院, 西安 710065)

摘要: 空置的酒店房间、未售出的活动门票和未被消费的商品等代表了不必要的成本和未实现收入, 政府需要准确的对旅游需求量加以预测, 以便在基础设施开发和住宿场地规划等问题上做出明智的决策, 因此准确预测旅游需求量变得至关重要。随着人工智能的迅速发展, 神经网络和 SVR 等人工智能模型在旅游需求量预测中得到了成功的应用。本文将对 SVR, BP 神经网络, LSTM 三种旅游需求量预测模型的训练过程、应用和特点进行研究, 对其中实际难点进行了分析, 总结和展望了旅游需求量预测模型在实际生活中的应用。

关键词: 旅游需求量; SVR; BP 神经网络; LSTM

Research on tourism demand prediction algorithm

WANG Leixue

(School of Computer Science, Xi'an Shiyou University, Xi'an 710065, China)

[Abstract] Empty hotel rooms, unsold event tickets and unconsumed goods represent unnecessary costs and unrealized revenues, and accurate forecasts of travel demand are essential for governments to make informed decisions on issues such as infrastructure development and accommodation planning. With the rapid development of artificial intelligence, artificial intelligence models such as neural network and SVR have been successfully applied in the prediction of tourism demand. In this paper, the training process, application and characteristics of SVR, BP neural network and LSTM tourism demand prediction models are studied, and the practical difficulties are analyzed, and the application of tourism demand prediction models in real life is summarized and prospected.

[Key words] Tourism demand; SVR; BP neural network; LSTM

0 引言

随着时代的发展, 旅游业已经成为当今世界重要的经济产业, 旅游已经成为现代人日常生活中不可缺少的组成部分。许多旅游和酒店产品无法储存起来供未来使用, 例如空置的酒店房间、未售出的活动门票和未被消费的商品。准确的旅游需求量预测可以帮助制定与旅游发展相关的策略, 以便在基础设施开发和住宿场地规划等问题上做出明智的决策。因此, 准确的旅游需求预测对旅游经济的发展是至关重要的。

以往针对旅游需求预测问题, 多数采用时间序列和计量经济学模型^[1]。这类方法本质上是一种线性建模方法, 没有考虑旅游需求量的周期性变化特点, 局限性很明显。2006年, PF Pai 等人^[2]提出了将支持向量模型(SVR)用于旅游预测中, SVR 是一种小样本预测问题的建模, 具有神经网络的良好预测性能, 同时能克服过拟合的不足。张峰等人^[3]提出将 BP 神经网络应用到旅游预测中。BP 神经网络采用多层误差逆传播的训练算法, 有较好的准确性及鲁棒性。LSTM 是一种特殊的 RNN 网络, 由

Hochreiter & Schmidhuber^[4]引入, 可以成功地训练架构比较复杂的深度学习模型, 2018年, YiFei Li 等人^[5]首次将 LSTM 神经网络应用于旅游预测中。2019年, Rob Law 等人^[6]提出了一种基于 LSTM 和注意机制的旅游预测模型, 验证了深度学习在旅游预测中的能力。

1 旅游需求量预测算法

1.1 SVR

支持向量机(SVM)由 Vapnik^[7]针对分类问题提出, 通过找到一个分类平面, 将数据分隔在平面两侧, 从而达到分类的目的。如图 1 所示, 一个点距离超平面的远近可以表示为分类预测的准确程度, SVM 就是要最大化这个间隔值, 在虚线上的点便叫做支持向量 Support Vector。

SVR 全称 support vector regression, 是 SVM 对回归问题的一种应用, Drucker H^[8]等人首次用 SVR 来解决非线性回归预测。对于非线性模型, SVR 与 SVM 一样使用核函数(kernel function)映射到特征空间, 再进行回归。

作者简介: 王雷雪(1996-), 女, 硕士研究生, 主要研究方向: 自然语言处理。

收稿日期: 2020-03-16

1.2 BP 神经网络

BP (back propagation) 神经网络由 Rumelhart 和 McClelland 等人^[9]提出, 训练原理是多层误差逆传递, 是深层次的, 上层神经元与下层神经元完全连接。当向 BP 神经网络提供学习样本时, 样本从输入层通过中间层传播到输出层, 输出层的神经元可以得到神经网络的输入响应, 连接权值沿着减少预测输出和实际输出之间的误差方向不断调整, 也就是说, 连接权值不断从输出层调整到每个中间层, 最终调整到输入层。随着反向传播的不断修正, 误差不断减小, 从而得到最优训练模型。BP 算法有明确的学习规则, 具有识别非线性模式的能力, 适用于计算方法清晰, 步骤明确的学习。只含有一个隐含层的 BP 网络称为三层 BP 神经网络, 如图 2 所示。




图 1 SVM 算法原理图

Fig. 1 SVM Algorithm schematic




图 2 BP 神经网络结构图

Fig. 2 BP Neural network structure diagram

BP 神经网络有以下局限性:

- (1) BP 算法优化的本质原理是梯度下降, 由于优化函数过于复杂使得学习算法收敛速度较慢。
- (2) 某些问题的本质是非线性优化, 不可避免的存在局部极值, 不能得到问题的最佳解。
- (3) 选择隐层神经元的数量没有严格的理论依据, 基于经验的选择使得算法很难得到最优解。
- (4) BP 算法要求每个样本的特征数相同。

1.3 LSTM

RNN (Recurrent Neural Network) 是一类用于处理序列数据的神经网络。序列数据的特点是前后数据有关联。RNN 的工作原理是在处理数据时有选

择地跨时间步长传递信息, 这一特性对于旅游需求预测应用非常重要。图 3 为 RNN 结构。




图 3 RNN 结构图

Fig. 3 RNN structure

如图 3 所示, RNN 的输入和输出是时间序列数据, 也可以是单个数据点, RNN 将其记忆保存在固定大小的隐层神经元中, 隐层神经元负责捕获所有之前处理过的信息。通过网络中的反馈回路, 根据当前的输入和前一隐层神经元的状态, 生成神经元的输出。RNN 可以循环对元素序列之间的依赖关系进行建模。由于 RNN 梯度消失, 只能有短期记忆, 由此引入了 LSTM (long short-term memory), 其实是 RNN 的一种特殊变体, 可以学习长期依赖信息, 见图 4 LSTM 结构^[11]。




图 4 LSTM 结构图

Fig. 4 LSTM structure

LSTM 核心思想是在每个时间步长中, 使用三个门来控制序列信息, 从而精准地捕获任何远程依赖, 以时间序列作为输入, LSTM 将其编码成一个隐藏状态序列 y , 在每一个时间步长 T 中, 隐藏状态 h^t 在同一时刻被 x^t 更新, 隐藏层的前一个状态为 h^{t-1} , 输入门 i^t , 忘记门 f^t , 输出门 o^t 及一个存储单元 c^t , 关系方程如公式 (1) ~ (5) 所示:

$$i^t = \sigma(w^i x^t + v^i h^{t-1} + b^i), \tag{1}$$

$$f^t = \sigma(w^f x^t + v^f h^{t-1} + b^f), \tag{2}$$

$$o^t = \sigma(w^o x^t + v^o h^{t-1} + b^o), \tag{3}$$

$$c^t = f^t \times c^{t-1} + i^t \times \tanh(w^c x^t + v^c h^{t-1} + b^c), \tag{4}$$

$$h^t = o^t \times \tanh(c^t). \tag{5}$$

其中 σ 和 \tanh 是激活函数, 是矩阵元素对应相乘 (element-wise multiplication), w 和 b 是在模型中

训练学习的参数。用 $\bar{y}_i = w^r h_i^t$ 来预测线性回归层的输出, w^r 为线性回归层的权重。

2 应用

2.1 旅游需求量预测研究的难点

旅游需求预测研究大致分为定性和定量两类方法。其中,定性的方法,如 Delphi 预测方法和共识法^[13],往往依赖于对特定旅游市场的直觉、经验及洞察力,这些方法是艺术性的,泛化能力较差。定量方法是根据旅游要素及客流量来构建模型,预测未来的旅游量。定量方法通常使用两种策略来提高模型精准度。第一种策略是纳入更多可能影响旅客旅游动机的相关因素,第二种策略是采用更复杂的模型。

构建模型主要依赖输入因素,根据输入特征直接或间接反映旅游需求,将旅游相关因素分为决定因素和其他因素。决定因素又分为定性经济因素和定量经济因素,因为定性经济因素如收入、广告等难以量化,所以预测模型多采用定量经济因素。旅游需求是由经济理论中的决定因素决定的,为了提高预测精度,一些被认为是次要因素的指标也被纳入模型中^[14]。随着网络技术的发展,多数游客通过搜索引擎查找旅游相关的信息,来选择目的地,预定机票、住宿、景点门票等。SII (Search Intensity Indices) 数据被认为是旅游数据的有效指标^[15-16],被引入到各种旅游预测模型中^[6,17]。

旅游预测目前有两大难点,第一是模型数据的有效选择及处理,例如在 SII 数据中有大量特征的搜索强度较 1 小。旅游预测模型使用历史时间序列来预测未来一段时间的状况。然而,这些模型不具备从复杂时间序列中自动提取潜在特征的能力。第二是时间序列数据可能具有不平稳性,会导致旅游预测不准确。

2.2 算法对比

综合探讨三种旅游需求预测算法的起源及原理,三种算法的对比如表 1 所示。BP 神经网络属于 ANN(人工神经网络)。SVR 适用于小数据集,是基于现有信息下的目标最优解,在逼近小样本非线性预测问题方面具有独特的优势,但是由于其参数设置的自由性,其应用比较有限。在处理旅游预测问题时,使用核函数代替在高维空间中计算,克服维数灾难问题,加快了训练速度。LSTM 是基于 RNN 的模型,RNN 理论可以记忆任意长的序列,但由于梯度消失并不能处理长序列问题,所以引进了 LSTM。LSTM 由于 cell state 的传递解决了梯度消失问题,

可以处理长序列,但是不能解决超长序列问题。

表 1 三种需求预测模型对比

Tab. 1 Comparison of three demand forecasting models

模型	优点	缺点	适用
SVR	泛化能力好,克服维数灾难问题,训练速度较快	对大规模训练样本难以实施,过分依赖历史数据	小数数据集
BP 神经网络	步骤明确,良好的自学习能力,自适应能力,泛化能力	容易受数据复杂性影响,收敛速度慢	大小数据集
LSTM	能够处理变长序列,解决梯度消失问题	计算复杂度高,计算费时,不能解决超长序列问题	大数据集

3 结束语

随着经济全球化和社会的不断发展,旅游业是经济增长,外汇收入和创造就业机会的重要来源。准确的旅游预测为旅游从业者和研究人员提供了重要的信息,帮助他们就旅游相关活动做出决策,确定潜在风险,因此准确的旅游预测有着重要的意义。论文综合探讨了 SVR, BP 神经网络, LSTM 这 3 个模型的基本原理,对比了 3 个模型的性能,同时对旅游需求量预测研究中的实际难点进行了分析。人工智能方法虽然在旅游预测中取得了较好的预测效果,但其研究和应用还有待进一步发展。

参考文献

- [1] DEMAND F T. Methods and Strategies [J]. 2001.
- [2] PAI P F, WEI - CHIANG H, PING - TENG C, et al. The application of support vector machines to forecast tourist arrivals in Barbados: An empirical study [J]. International Journal of Management, 2006, 23(2): 375.
- [3] 张峰, 柳炳祥, 张月. 一种基于 BP 神经网络算法的旅游人数预测方法 [J]. 信息与电脑 (理论版), 2019 (3): 26.
- [4] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural computation, 1997, 9(8): 1735-1780.
- [5] LI Y F, CAO H. Prediction for tourism flow based on LSTM neural network [J]. Procedia Computer Science, 2018, 129: 277-283.
- [6] LAW R, LI G, FONG D K C, et al. Tourism demand forecasting: A deep learning approach [J]. Annals of Tourism Research, 2019, 75: 410-423.
- [7] VAPNIK V. The nature of statistical learning theory [M]. Springer science & business media, 2013.
- [8] DRUCKER H, BURGESS C J C, KAUFMAN L, et al. Support vector regression machines [C]//Advances in neural information processing systems. 1997: 155-161.
- [9] BROADBENT D. A question of levels; Comment on McClelland and Rumelhart [J]. 1985.
- [10] LI Z, LEI Q, KOUYING X, et al. A novel BP neural network model for traffic prediction of next generation network [C]//2009 Fifth International Conference on Natural Computation. IEEE, 2009, 1: 32-38.

(下转第 124 页)