

基于极限学习机神经网络的买断制加盟模式订货决策

韩曙光^a, 于 森^b, 郭 瑞^b

(浙江理工大学, a. 理学院; b. 服装学院, 杭州 310018)

摘 要: 随着服装市场和服装品牌的不断成熟以及人们对服装需求的日益多样化,买断制加盟模式成为具有一定市场知名度的品牌服装的选择,这给加盟商订货决策带来了一定的风险。为了更好地完成订货采购任务,加盟商需根据自己店铺的历史销售数据进行预测,以确定订货会的订货量并制定采购预算。以预测某品牌加盟商夏季每月每个品类的销售量为出发点构建模型,采用极限学习机神经网络的方法进行销售预测,并将预测结果以图表的形式进行展示,为服装加盟商订货决策及采购预算的确定提供理论支持。

关键词: 订货决策; 服装销售预测; 极限学习机

中图分类号: F272.3 **文献标志码:** A

中国服装业自 20 世纪 90 年代以来得到迅猛发展,进入 21 世纪,品牌发展成为该产业发展的出路,品牌对中国消费者的吸引力和影响力也越来越重要。在国内,只有少数品牌服装采取自主经营的模式,大多数品牌服装都选用代理加盟制^[1]。加盟模式主要包括代理制和买断制,代理制加盟商只享有商品的销售权而无所有权,在商品售出之后按合约规定获得报酬。买断制加盟商通过买断商品的方式进行销售,且在整个销售过程中,生产商对加盟商所采购的服装除质量问题外一律不予退货^[2]。随着服装市场的不断成熟和人们对服装需求的日益多样化,实施“零风险”的代理制使服装生产企业越来越被动^[3],所以买断制加盟模式成为具有一定市场知名度的品牌服装的选择^[4]。在买断制的经营模式下,服装生产企业不再为加盟商的库存负责,将经营风险转嫁给了加盟商,这就给加盟商的订货决策带来一定的风险,即:货品订得好就会有利于店铺的经营;反之,就会产生库存过剩或供货不足,进而对店铺的经营产生不利影响。通过前文的分析可知,订货决策的优劣对买断制加盟商的影响较代理制加盟商要大,而加盟商的订货决策是根据历史数据对未

来某段时间销售情况进行预测而决定的。本文的主要研究内容是研究在买断制加盟模式下加盟商的服装销售预测。

由于在参加订货会之前,加盟商并未见到采购实物,故只能根据历年的销售数据进行预测。加盟商在订货会期间需要对整个销售季所要销售的货品进行采购,而在实际销售中,由于气候等原因,通常不会一次到货,而是分波段多批次到货,所以本文将预测周期细化到月。与此同时,发现在同一月份里,不同的品类的销售量也不同,所以将预测细化到品类。综上,本文主要预测在整个销售季中每个月每个品类的销售量。

销售预测的方法主要包括传统的数学方法和人工智能方法^[5]。传统的数学方法是历史销售数据拟合成一条曲线进行预测,由于影响服装销售的因素较多,各因素之间的关系不一定是线性的,所以此方法进行销售预测不能很好地反映服装的特点。人工智能方法的分支人工神经网络凭借着强大的泛化能力,近年来广泛应用于服装的销售预测中,其中,极限学习机神经网络作为单隐层前馈神经网络的一种,不仅具有人工神经网络可以对所有线性或非线

收稿日期: 2014-09-10

基金项目: 国家自然科学基金项目(11201428,11271324,11471286);浙江省自然科学基金项目(Y6110091);浙江省高校重中之重学科开放基金项目(2013KF19)

作者简介: 韩曙光(1977—),男,江苏建湖人,博士,副教授,主要从事服装供应链管理与优化、算法设计与分析方面的研究。

性函数进行逼近的能力,而且可以很好地避免传统人工神经网络训练速度慢、容易陷入局部最优值的缺点^[6-7],是一种有效的预测方法,故选择极限学习神经网络作为本文的预测方法。

为更好地说明极限学习神经网络性能的优越性,本文把BP(back propagation)神经网络和经遗传算法改进的BP神经网络作为参考对象;此外,为使模型更加具有真实性,本文采用了杭州某品牌服装加盟商夏季的销售数据进行实证检验。

一、极限学习机销售预测模型构建

(一)极限学习机

Huang 等^[6-7]最早提出极限学习机(extreme learning machine, ELM)理论,指出 ELM 神经网络的拓扑结构由输入层、隐含层和输出层构成,其每层都包含属于自己的节点(神经元),即输入节点、隐含节点和输出节点^[8],极限学习机神经网络模型如图 1 所示。

ELM 的隐含层神经元里存在着激活函数 $g(x)$ 和阈值 b ,其中激活函数 $g(x)$ 在模型训练前需根据实际情况确定,而阈值 b 是随机确定的。输入层与隐含层通过输入权矩阵 ω 连接,隐含层与输出层由输出权矩阵 β 连接。输入权矩阵 ω 与阈值 b 类似,是随机确定的。输出权矩阵 β 在确定激活函数 $g(x)$ 、输入权矩阵 ω 和阈值 b 后根据缪尔彭罗斯广义逆求得^[8]。




图 1 极限学习机神经网络模型

(二)用 ELM 神经网络进行服装销售预测的步骤

通过对 ELM 神经网络进行深入的研究,将用 ELM 神经网络进行服装销售预测的步骤总结如下:

第一步:根据问题的需要,确定进行服装销售预测的影响因子,并确定输入层节点的个数 n ,再从原始数据中提取有效的样本集 N ;

第二步:将样本集 N 分为训练集 N_p 和测试集 N_q ,这里 $N=N_p+N_q$;

第三步:将训练集 N_p 和测试集 N_q 进行标准化处理;

第四步:确定隐含层神经元个数 K 和激活函数 $g(x)$;

第五步:输入训练集 N_p 的输入变量 $x_i=1,2,\dots,p$,确定输出权矩阵 β ;

第六步:将测试集 N_q 的输入变量 $x_i=p+1,p+2,\dots,N$ 输入由第四步和第五步确定的模型中,输出测试集 N_q 的预测值 $y_i, i=p+1,p+2,\dots,N$ 和预测误差 δ 。

(三)网络拓扑结构构建

1. 影响因子及各层节点数确定

由于本文的研究内容是预测每个月每个品类的销售量,所以选取季节因子和品类因子作为 ELM 神经网络的影响因子;此外,节假日使人流量增加,会带来服装销售的高峰期,故本文也将节假日因子作为网络的影响因子。由于本文的预测是根据上一年同期该品类的销售量来预测下一年该品类的销售量,则上一年该月该品类的销售量应作为本文模型构建的一个输入节点。综上所述,本文选取季节因子、品类因子、节假日因子、上一年该月该品类的销售量作为输入变量,即本文 ELM 神经网络模型的输入节点个数为 4。

隐含层节点个数 K 的确定对 ELM 神经网络模型的构建非常重要,目前在神经网络的拓扑结构构建中,关于隐含层最佳节点个数的确定常采用“试凑法”。所谓“试凑法”是指先在网络中设置较少的隐含层节点数,然后逐渐增加节点数,并使用同一样本集重复操作多次,则输出误差最小时的隐含层的节点数即为网络的最佳隐含层节点数^[9]。从这个理论出发,本文在 1~30 的范围内选择隐含层最优节点个数。首先让 ELM 神经网络在隐含层节点个数为 1~30 内逐次运行,并分别计算误差,并将运行后所得误差中的最小值对应的隐含层节点数输出。其次,将此操作重复运行 100 次,并获得了 100 个误差最小时 ELM 神经网络的最优节点数。在输出的结果中,100 个输出值有 72 个是 4,进而可知当隐含层节点数为 4 时,ELM 神经网络的预测误差最小,即本文中 ELM 神经网络的隐含层节点数为 4。

由于本文研究的目的是预测在整个销售季中每个月每个品类的销售量,所以以该品类当年当月的销售量为目标输出,即本文的 ELM 神经网络的输出层节点数为 1。

2. 激活函数的确定

激活函数 $g(x)$ 在 ELM 神经网络的作用十分重要。常用的激活函数 $g(x)$ 包括阈值型转移函数、

线型转移函数和 S 型函数(sigmoid 函数)。由于 S 型激活函数能够较好地反映神经元的饱和特征,具有非线性放大系数的功能^[10],因此在前馈型神经网络中应用较多。本文采用 S 型函数,即 $g(x) = \frac{1}{1+e^{-x}}$,作为 ELM 神经网络的激活函数。

二、ELM 神经网络性能分析

本文以杭州某品牌服装加盟商 2008 年、2009 年、2010 年在杭州地区夏季 5 月、6 月、7 月、8 月、9 月 5 个月 4 种品类的销售数据为训练样本集 N_p ,以 2011 年在杭州地区夏季 5 月、6 月、7 月、8 月、9 月的销售数据为测试样本集 N_q ,故训练样本集 N_p 的样本个数为 40,测试样本集 N_q 的样本个数为 20。

此模型在 MATLAB 软件上实现,并将预测输出值 y_i 与实际值 t_i 以图表的形式绘出,运用相同的样本集随机运行模型两次,其预测结果如图 2、图 3 所示。




图 2 第一次随机使用 ELM 神经网络的预测结果




图 3 第二次随机使用 ELM 神经网络的预测结果

从图 2、图 3 中可以发现,预测输出值与实际值的走势趋向基本一致,所以运用 ELM 神经网络进行服装销售预测可以对整个销售季的销售趋势进行反映,且预测输出值基本上在实际值附近出现,与实

际值相差不大,故预测值较为精准,可以达到预测效果。图 2、图 3 中,7 月份 4 个品类的预测值集中在预测点 9 到预测点 12 之间出现,同时发现,每个品类在 7 月份的销售量都高于其他月份,这说明季节因子可以反映产品销售的季节性,即运用 ELM 神经网络进行服装销售预测,可以实现对服装销售季节性特点的模拟。

综上,运用 ELM 神经网络进行服装销售预测,能够反映服装销售的季节性和趋势性,基本上可以达到预测的效果。但是,从图 2、图 3 中可以发现,模型运行两次后的输出值存在一定的差异,模型性能不够稳定,故无法以单次运行的结果进行销售预测。为测试 ELM 的稳定性,本文引进了变异系数的概念。变异系数是衡量观测对象变异程度的一个统计量,是观测对象标准差与平均数之间的比值^[11]。

将 ELM 神经网络多次运行,且对于每一次运行,ELM 神经网络的拓扑结构、输入样本集 N_p 都是相同的,但输入权矩阵 ω 和阈值 b 是随机确定的。分别求出每次运行后 ELM 神经网络的输出值 y_i 与实际值 t_i 的误差 $mse_i, i=1, 2, \dots, k$,其次求出这个误差的标准差 δ ,再次求出这个误差的平均值 μ 。

由于变异系数 cv 越大,各观测值之间的差异就越大,即将 ELM 神经网络多次运行后,预测值 y_i 与实际值 t_i 的误差 mse_i 之间的变异系数 cv 越大,预测值之间的差异就越大,模型就越不稳定。为测量 ELM 神经网络的稳定性,本文将模型运行 100 次,即 $k=100$,其运行结果如表 1 所示。

表 1 ELM 神经网络运行 100 次的误差的标准差、均值和变异系数

标准差 δ	均值 μ	变异系数 cv
396.110 7	1 074.530 0	0.368 6

由表 1 可知,随机运行 ELM 神经网络 100 次后,误差间的变异系数较大,进而得出 ELM 神经网络的预测结果之间存在较大的偏差,ELM 神经网络的稳定性较差。

三、ELM 神经网络优化及性能检验

(一)ELM 神经网络优化

由于 ELM 神经网络的稳定性较差,本文引入了集成的理论进行优化。集成的原理是将相同结构的模型用相同的数据重复多次运行,并将多次运行后的输出值取平均,此平均值即为模型预测的最终值^[12]。但是,随着运行的次数增加,运算时间也将

变长。为兼顾运行时间与稳定性两方面的要求,将运行次数 L 定义在区间 $[100, 1000]$ 内。本文取 L 的值为 500,即将 ELM 神经网络随机运行 500 次后的输出值取平均后获得的值作为最终的预测值。

(二) 优化后的 ELM 神经网络模型的稳定性分析

采用与检验 ELM 神经网络性能相同的数据,并将模型在 MATLAB 软件上实现,将预测输出值 y_i 与实际值 t_i 以图表的形式绘出,将模型随机运行两次,运行的结果见图 4、图 5 中。




图4 第一次使用优化后的 ELM 神经网络的预测结果




图5 第二次使用优化后的 ELM 神经网络的预测结果

通过图 4、图 5 可以发现,随机两次运行优化后的 ELM 神经网络输出值基本相同,预测结果之间偏差较小,进而得出优化后的 ELM 神经网络性能稳定。

为比较优化后的 ELM 神经网络与普通 ELM 神经网络的稳定性,本文采用与检测 ELM 神经网络稳定性相同的方法以及相同的运行次数对优化后的 ELM 神经网络进行稳定性检测。将优化后的 ELM 神经网络模型随机运行 100 次,分别求出预测值 y_i 与实际值 t_i 的误差 mse_i ,进一步求出这 100 个误差 mse_i 的标准差 δ 以及这 100 个误差的平均值 μ ,从而求出这 100 个误差的变异系数 cv ,结果如表 2 所示。

表2 运行优化后的 ELM 神经网络 100 次的误差的标准差、均值和变异系数

标准差 δ	均值 μ	变异系数 cv
45.273 7	951.146 3	0.047 6

通过表 2 可以发现,随机运行优化后的 ELM 神经网络 100 次后,误差间的变异系数 cv 较小,进而可以得出模型的预测结果之间偏差较小,模型的稳定性较好。通过表 1 与表 2 的对比,可以发现优化后的 ELM 神经网络误差之间的变异系数远小于 ELM 神经网络误差之间的变异系数,进而可以得出优化后的 ELM 神经网络的稳定性优于 ELM 神经网络。

(三) 优化后的 ELM 神经网络预测性能分析

为说明优化后的 ELM 神经网络性能的优越性,本文在采用同样的学习样本 N_p 和预测样本 N_q 的基础上,与普通的 BP 神经网络及经遗传算法改进的 BP 神经网络进行比较,分别将预测结果 y_i 与实际值 t_i 的平均绝对误差 MAE、平方差 SSE、均方差 MSE 表示在表 3 中。

表3 模型性能比较

	普通 BP 网络	遗传 BP 网络	优化后的 ELM 模型
MAE	673.146 4	486.322 6	422.425 4
SSE	4.63×10^7	1.68×10^7	7.84×10^6
MSE	1.52×10^3	9.17×10^2	6.26×10^2

从表 3 可以发现,运用优化后的 ELM 神经网络进行服装销售预测较其他两种神经网络的精度要高,能够更加准确地预测服装的销售量,更加清楚地反映了实际的销售情况,能够为服装加盟商进行服装采购决策提供理论支持。

四、结 论

本文以解决买断制加盟模式下的服装加盟商采购决策问题为出发点,将问题缩聚到预测未来一段时间内加盟商每月每个品类的销售量,并选择 ELM 神经网络作为预测方法。本文以上年同月同品类的服装销售量、该月节假日因子、该月季节因子、该品类的品类因子为 ELM 神经网络的输入因子,以该服装品类当年当月的销售量为目标输出,以 S 型函数为激活函数,隐含层节点个数为 4 的网络参数进行的网络拓扑结构的构建。本文在证实 ELM 神经网络稳定性较差的基础上将模型进行优化,并与 BP 神经网络和经遗传算法改进的 BP 神经网络进行比较,通过比较可以发现,运用优化后的 ELM 神经网络进行销售预测基本上可以反映服装实际的销售情

况,达到了预测效果。

本文给出了运用 ELM 神经网络进行服装销售预测的方法,并通过 ELM 神经网络预测出未来某一段时间的销售量,为加盟商的采购决策提供理论支持。

参考文献:

- [1] 张 喆. 开店守则:降低库存提高进销比[J]. 服装销售与市场, 2005(9): 7.
- [2] 豆艳丽. 服务于加盟商的服装品牌订货会模式研究[D]. 上海: 东华大学, 2007.
- [3] 王海宁, 王厉冰. 品牌服饰连锁经营模式研究[J]. 江苏纺织, 2005(6): 46-48.
- [4] 郑春玲. 大众休闲品牌服装商品组合研究:以“以纯”的商品组合为例[D]. 杭州: 浙江理工大学, 2010.
- [5] Maria E N, Luca G, Luca P. Demand forecasting in the fashion industry: a review[J]. International Journal of Engineering Business Management, 2013(5): 1-6.
- [6] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: a new learning scheme of feedforward neural networks[J]. Neural Networks, 2004(2): 985-990.
- [7] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006(70): 489-501.
- [8] Xia M, Zhang Y C, Weng L G, et al. Fashion retailing forecasting based on extreme learning machine with adaptive metrics of inputs [J]. Knowledge-based Systems, 2012 (36): 253-259.
- [9] 马丽华. 基于 BP 神经网络的卷烟配送中心销售预测[D]. 济南: 山东大学, 2008.
- [10] 苏 晨. 基于遗传算法和 BP 神经网络的服装销售预测方法研究[D]. 杭州: 浙江理工大学, 2012.
- [11] 牛建涛, 许建梅. 生丝电子检验中线密度变异系数的分布[J]. 纺织学报, 2013, 34(10): 20-25.
- [12] Hansen L K, Salamon P. Neural network ensembles [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12(10): 993-1001.

Study on Ordering Decision under “Buyout” Franchise Mode Based on Extreme Learning Machine Neural Network

HAN Shu-guang^a, YU Miao^b, GUO Rui^b

(a. School of Science; b. School of Fashion Design and Engineering,
Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: As clothing market and fashion brands continue to be mature and demands for clothing are increasingly diversified, “buyout” franchise mode has become a selection for clothing brands that possess certain popularity and market share. This brings about certain risks for franchisees’ ordering decisions. To better accomplish the purchasing task, franchisees need to make predictions based on historical sales data of their own stores so as to determine ordering quantity in the order fair and make procurement budget. This paper starts from predicting monthly sales volume of each category of a brand in summer to construct a model and adopts extreme learning machine neural network for sales prediction. The prediction results are displayed in graph form to provide theoretical support for ordering decision and of clothing franchisees and confirmation of procurement budget.

Key words: ordering decision; clothing sales forecasting; extreme learning machine

(责任编辑: 陈和榜)