

基于多指标的BP神经网络产品进退模型设计

李璐,何利力

(浙江理工大学 信息学院,浙江 杭州 310018)

摘要:在大数据背景下,企业管理思维和营销思维发生转变,企业为促进自身发展,重视产品进退与市场营销结合带来的影响,若能准确地把握产品在市场上的投放或退出,有助于提高企业整体营销思想,能够为企业带来良好的经济效益,但产品进退与市场营销的结合蕴含着潜在的市场风险,因此在企业产品管理中还需讲究一定的科学策略。基于此背景,该文主要针对如何运用产品进退将企业管理与市场营销相结合,根据影响产品进退的多维指标:上柜率、再购率、同价类销量比、商业存销比、订足率、销售年限、是否进入衰退期,提出在大数据环境下多维指标结合改进BP神经网络与AHP分析算法,建立市场产品进退预测模型,判断市场是否接收产品的投放或退出,并与BP神经网络模型、SVM模型进行对比。实验表明,结合多维指标的改进BP神经网络预测模型的精度明显优于其他两类,为大数据下产品进退预测提供了方法。

关键词:产品进退;多维指标;BP神经网络;AHP层次分析法;大数据

中图分类号:TP391.1

文献标识码:A

文章编号:1673-629X(2021)12-0039-06

doi:10.3969/j.issn.1673-629X.2021.12.007

Design of BP Neural Network Product Launch and Withdrawal Model Based on Multidimensional Indicators

LI Lu, HE Li-li

(School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: Under the background of big data, the corporation thinking of management and marketing has changed. In order to promote its own development, enterprises attach importance to the impact of the combination of product's launch and withdrawal and marketing. If the enterprise can accurately grasp the product launch or withdrawal in the market, it will help improve the overall marketing thinking of the enterprise and bring good economic benefits to the enterprise. However, the combination of product's launch and withdrawal and marketing contains potential market risks, so certain scientific strategies need to be paid attention to enterprise product management. Based on this background, we mainly focus on how to use product's launch and withdrawal to combine corporate management with marketing. According to the multi-dimensional indicators that affect product's launch and withdrawal: product listing rate, repurchase rate, sales ratio of the same price category, commercial stock-to-sales ratio, subscription rate, sales period and whether entering a recession, we propose to combine multi-dimensional indicators to improve BP neural network and AHP analysis algorithm in the big data environment, establish market product advance and retreat prediction model, and judge whether the market accepts product launch or withdrawal. Compared with the BP neural network model and the SVM model, it is showed that the accuracy of the improved BP neural network prediction model combined with multi-dimensional indicators is significantly better than the other two types, which provides a method for predicting product advance and retreat under the big data background.

Key words: product's launch and withdrawal; multidimensional indicators; BP neural network; AHP analytic hierarchy process; big data

0 引言

随着市场规模的扩大,市场上的产品种类繁多,企业管理任务繁重。由于市场环境复杂,产品规格进退在企业营销策略的重要作用日益突显,对产品营销产生的影响越来越大。产品生命周期分为引入期、成长

期、成熟期和衰退期^[1-2]。

在市场很多产品可以选择的时候,每个市场都会根据自身的需要进行品牌的引入和退出设计。企业分析市场空缺,对消费者需求进行判断,挑选适合产品进入市场弥补空缺,达到产品体系完整的目的^[3];同样也

收稿日期:2020-12-24

修回日期:2021-04-27

基金项目:国家重点研发计划(2018YFB1700702)

作者简介:李璐(1996-),女,硕士研究生,研究方向为智能软件与数据处理;通讯作者:何利力(1966-),男,博士,教授,博导,研究方向为数据分析、企业智能。

会对已在市场的产品进行综合评测,根据产品的寿命周期、需求的调整以及该产品的企业边际利润等对产品结构进行调整,保持整个产品体系的活力。

针对大数据下的产品营销问题,众多学者进行了全面研究。何喜军等^[4]提出基于多维指标融合的电商产品销量预测模型,该模型利用了逻辑回归函数和正则修正项,结合贪心算法构建基于 Xgboost 的产品销量预测模型,为短销售周期销售预测提供了思路;Ren S^[5]提出利用 AHP 分析快速时尚产品模型预测系统,对预测系统进行排名;张艳辉等^[6]提出基于在线评论有用性的影响因素对产品类型的调节;G. Di Pillo^[7]提出利用 SVM(支持向量机)来对销售数据进行建模,评估在促销营销下销售预测模型的好处,并与其他算法进行对比;圣文顺等^[8]提出结合 BP 神经网络与时间序列的 BP 神经网络预测模型,可解决输入数据的非线性不完整性。

综上,对产品的营销问题都是基于市场分析的,且都是预测产品销量,忽略产品的自身特性和市场的固有属性相关性^[9]。因此,该文针对产品的自身特性和市场的固有属性,结合大数据信息、市场规则,提出在大数据环境下结合改进 BP 神经网络与 AHP 分析算法建立市场产品进退预测模型。为企业在向市场投入/退出产品的决策中提供参考,避免决策失误。

1 AHP 层次分析法

在实际的市场环境中,产品的进退趋势往往是多种因素共同作用的结果,而且不同因素对产品进退趋势的影响是不同的,在预测之前,需要从这些众多的因素中找到对产品进退趋势影响较大的因素,并对这些因素进行权重赋值。AHP 可以帮助找到对产品进退影响较大的因素^[10]。

对于产品进退领域来说,往往需要处理的数据量巨大,结构杂乱和噪声大且通常不服从特定的概率分布,采用常用的方法难以实现有效的筛选,而 AHP 层次分析的优点在于建立所有要素层级,清楚呈现各层、各规则与各要素的关系^[11];资料不全或者数据缺失都能求得各要素的权值。因此,该文采用 AHP 来确定各个因素对产品进退的影响程度大小。由于该文考虑的是准则层对目标层的影响程度,不需要进行层次总排序。

AHP 层次分析法主要分为以下几个步骤:

第一步:建立层次模型结构。

决策的目标 $T = \{t_1, t_2, \dots, t_n\}$ 、考虑的因素(决策准则) $Z = \{z_1, z_2, \dots, z_n\}$ 和决策对象 $O = \{o_1, o_2, \dots, o_n\}$ 按 T, Z, O 之间的相互关系分成最高层、中间层和最低层^[12],见图 1。




图 1 层次模型

第二步:构造判断(成对比较)矩阵。

在确定层次间各因素之间的权重时,利用一致矩阵法,即两两比较,采用相对尺度,减少性质不同的因素因相互比较而带来的困难,提高比较的准确性。成对比较矩阵表示本层的因素与上一层(准则或目标)某一个因素的相对重要性的比值,成对比较矩阵的元素 z_{ij} 表示的是第 i 个因素相对于第 j 个因素的比值,使用的是 Santy 标度方法。第二层因素对目标层影响对比矩阵 Z 为:

$$Z = \begin{bmatrix} z_{11} & z_{12} & \dots & z_{1n} \\ z_{21} & z_{22} & \dots & z_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ z_{n1} & z_{n2} & \dots & z_{nn} \end{bmatrix} \quad (1)$$

第三步:层次单排序及一致性检验。

W 为成对矩阵 Z 的最大特征根的特征向量,即同一层次因素对于上一层次某因素相对重要性的排序权值,判断层次单排序,需要通过一致性检验。一致性检验是指对成对比较矩阵 Z 在确定不一致的允许范围^[13]。一致性指标计算公式如式(2)~式(4):

$$CI = \frac{\lambda - n}{n - 1} \quad (2)$$

$$CR = \frac{CI}{RI} \quad (3)$$

$$RI = \frac{\sum_{i=1}^m CI_i}{m} \quad (4)$$

其中, λ 为成对矩阵的最大特征值, n 为成对矩阵大小, CI 为 0 时,说明具有完全一致性, CI 接近于 0,有合格的一致性, CI 越大,不一致性越严重。当 $CR < 0.1$ 时,说明矩阵 Z 的不一致程度在允许的范围内,若 CR 值过大,则需要重新构造成对比较矩阵 Z ,对 z_{ij} 加以调整。 λ 对应的 W 即为准则层对目标层的影响权重,通过对 W 进行归一化处理,得到影响产品进退因素的权重 T 。

2 BP 神经网络

AHP 的局限性主要包括要素间的对比困难,要素

过多,一致性检验可能无法通过,未考虑要素之间相关性等。为解决上述问题,引入 BP 神经网络,优化要素之间的相关性,降低误差,提高预测准确度。

BP 神经网络是一个万能模型和误差修正函数的结合^[14],根据每次训练出的结果与预期值进行运算,再进行误差分析,按照误差反向传播修正权值直至误差达到阈值或迭代结束。BP 神经网络模型如图 2 所示。




图 2 BP 神经网络模型

图中 x_1, x_2, \dots, x_n 为输入层神经元的输入, w_{ij} 为连接输入层和隐含层的权值调节各个输入量的占比, 隐含层的输入计算公式如式(5)和式(6):

$$b_j = \sum_{i=1}^m w_{ij} \times x_i \quad (5)$$

$$\alpha_j = f(b_j - \theta_j) \quad (6)$$

其中, θ_j 为隐含层神经元的阈值, 当隐含层神经元接收到信息 b_j , 将 b_m 和 θ_j 进行比较, 然后通过激活函数 (该文选用 Tanh) f 处理产生神经元的输出 α_j 。

同理, y_i 的计算公式与 α_j 一致, γ_i 为输出层的阈值, 如式(7):

$$y_i = f\left(\sum_{j=1}^n v_{ij} \alpha_j - \gamma_i\right) \quad (7)$$

神经网络的训练输出 y_i , 与预期结果 E_i 之间的误差, 如式(8):

$$\text{cost} = \frac{1}{2} \sum_{i=1}^n (y_i - E_i)^2 \quad (8)$$

根据计算出的误差调整 w_{ij} 、 v_{ij} 的值, 利用梯度下降法, 对每个需要调整的参数求偏导, 若偏导数 > 0 , 则按照偏导数相反的方向变化; 如果偏导数 < 0 , 则按照此方向变化即可, 同时设置一个学习率 ε , 学习率过大会得到局部最优解, 学习率过小, 则下降速率太慢。参数调整公式如式(9):

$$\Delta \text{Param} = -\varepsilon \frac{\partial \text{cost}}{\partial \text{Param}} \quad (9)$$

3 产品进退预测模型

该文从七个维度构建产品进退预测模型。其中:

上柜率是指在指定市场中销售该产品的零售户与本市场所有零售户的比值 d_1 , 该指标可反映该产品被购买的机会或可能性, 上柜率与市场占有率成正比关系, 当然, 上柜率也与零售户经销态度有关; 再购率是指累计购进多次的零售户与本市场订购该产品的零售户总数的比值 d_2 , 再购率反映市场需求情况, 可以了解消费市场的反应和终端的最终动销情况; 同价类销量比指该产品销量与市场同价类产品销量的比值 d_3 , 该指标反映该产品在同类产品中的竞争优势; 商业存销比是指该产品在一定周期的库存与一定周期的销量的比值 d_4 , 该指标反映周转率, 存销比越小, 说明越畅销; 订足率是指零售户的订货数量与零售户的投放限额之间的比值 d_5 , 该指标反映该产品零售户定额是否用足指标, 是否仍有余力放量采购; 销售年限是指该产品在指定市场销售的时间 d_6 , 销售时间越长, 则说明该产品的活力越大; 是否进入衰退期是指该产品的销量指标下降到某一个阈值 d_7 , 若达到某一个阈值, 则说明该产品有衰退风险即退出风险。通过分析市场大数据的七个维度来衡量某产品在市场的表现, 并且对维度之间的相关性进行计算, 控制产品市场上投放和退出。

表 1 为文中模型所用的符号以及对应说明。

表 1 产品进退预测模型符号及说明

符号	说明
d_1	上柜率
d_2	再购率(累计购入 3 次以上包括 3 次)
d_3	同价位销量比
d_4	商业存销比
d_5	订足率
d_6	销售年限
d_7	衰退期(取值为 0、1, 1 为衰退期)
dp_{ij}	产品 i 的第 j 个维度指标
P, D, R	产品集合, 指标集合, AHP 目标集合
T, λ, Z	指标 D 的 AHP 输出特征矩阵即 BP 神经网络隐含层阈值, 最大特征值, 成对比较矩阵
CR, CI, RI	一致性比值, 一致性指标, 一致性值
w_{ij}, θ_j	输入神经元 i 与隐含神经元 j 之间的权值, 隐含层的输出
v_{jh}	隐含神经元 j 与输出神经元 h 之间的权值
Y	神经网络输出集合
E	神经网络预期输出集合
$\text{cost}_i, \varepsilon$	输出误差, 学习率

该文提出融合 BP 神经网络与 AHP 层次分析法,通过数据处理得到序列,该序列作为神经网络的输入层,该序列和 BP 神经网络的初始权值进行计算后得到的新序列作为 AHP 的对象层和准则层。AHP 层次分析作为 BP 神经网络的隐含层的阈值,即 AHP 层

次分析中层次总排序的最大特征值对应的特征向量,通过 BP 神经网络的反向误差调整机制对整个网络中权值进行调整^[15],避免忽视影响因素即维度之间的相关性,当误差稳定且符合要求,即模型训练结束。模型结构如图 3 所示。

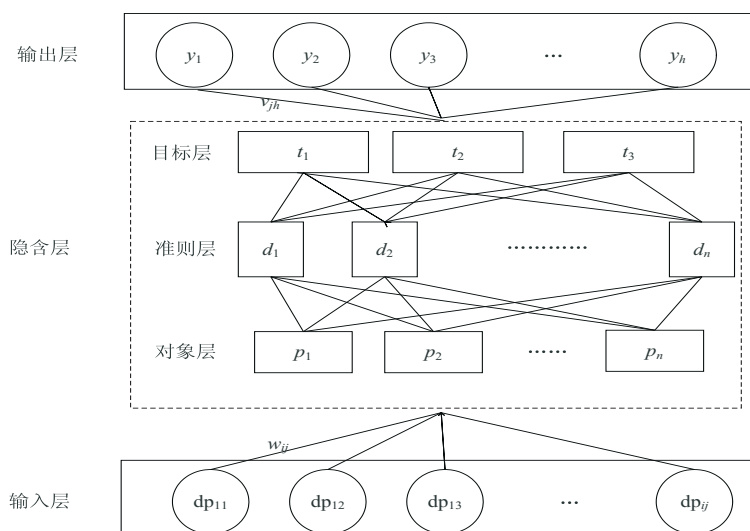


图 3 产品进退预测模型结构

下面对整个混合算法模型的工作流程进行具体描述。

第一步:分析产品 i 的七个维度得到序列 $DP_i = \{dp_{i1}, dp_{i2}, \dots, dp_{i7}\}$, 作为 BP 神经网络的输入层的输入序列,在输入层向隐含层过渡时, DP_i 与 w_{ij} 相乘,得到新的序列 DP_i 。

第二步:构建目标层和准则层层次单排序的成对比较矩阵 Z ,对 Z 进行一致性检验,获得 CR, CI, RI 三个参数,若 CR 的数值处于合适的区间,则通过一致性检验,若 CR 过大,则重新构造 Z ,使得 Z 通过一致性检验。

第三步:根据第二步得出的序列 T ,作为隐含层的阈值,与 DP_i 进行计算,通过激活函数得到隐含层的输出 θ_j , θ_j 与 v_{jh} 相乘得到序列 y ,与输入层的阈值计算,计算结果通过激活函数的作用得到序列 Y ,序列 Y 与输出预期 E 相减得到误差 $cost$ 。

第四步:根据第三步获得的误差 $cost$,利用 BP 反向传播原理结合学习率 ε ,对神经网络中的 w_{ij} 、 v_{jh} 进行修改,直至迭代结束或者误差 $cost$ 达到最小。

4 实验分析

该文以某公司的产品销售数据、库存数据、订单数据、零售户数据作为原始数据,对原始数据加工处理成实验数据,并按照 7:3 分为训练数据和测试数据,利用传统 BP 神经网络, SVM 算法和文中融合 BP 神经网络与 AHP 算法进行预测,并用不同的误差方面评定方式对各种算法的预测结果进行比较。

4.1 数据处理

产品进退预测受许多因素影响,例如产品销售数据、产品库存数据、产品订单数据、产品零售户数据、产品基本数据等,原始数据过于粗糙,需要对原始数据进行加工,符合模型输入要求。同样原始数据存在许多异常数据,数据噪声会使输入数据存在误差,最终导致预测结果产生偏差。

4.1.1 产品指标处理

由于文中模型是从上柜率、再购率、同价类销量比、商业存销比、订足率、销售年限、是否进入衰退期这个七个维度入手,则需要数据从这七个方面进行处理。

上柜率 d_1 反映该产品被购买的机会或可能性,上柜率计算公式如下:

$$d_1 = \frac{\text{销售该产品的零售户}}{\text{所有零售户}} \quad (10)$$

再购率 d_2 反映市场需求情况,再购率计算公式如下:

$$d_2 = \frac{\text{购进 3 次以上的零售户}}{\text{销售该产品的零售户}} \quad (11)$$

同价类销量比 d_3 反映该产品在同类的竞争优势,同价类销量比计算公式如下:

$$d_3 = \frac{\text{该产品市场销量}}{\text{所属价类所有销量}} \quad (12)$$

商业存销比 d_4 反映周转率,存销比越小,说明越是畅销,商业存销比计算公式如下:

$$d_4 = \frac{\text{库存}}{\text{销量}} \quad (13)$$

订足率 d_5 反映该产品零售户定额是否用足指标, 是否仍有余力放量采购, 机构率计算公式如下:

$$d_5 = \frac{\text{订货数量}}{\text{投放限额}} \quad (14)$$

销售年限 d_6 反映销售时间越长, 则说明该产品的活力越大, 销售年限计算公式如下:

$$d_6 = 1 - \frac{1}{\text{年限}} \quad (15)$$

是否进入衰退期反映产品有衰退风险, 若 d_7 为 -1, 则代表该产品有衰退风险, 若 d_7 为 0, 则代表该产品没有衰退风险。

4.1.2 建立判断矩阵

通过专家判定对该七个影响元素进行 Santy 赋值,

形成成对判断矩阵即判断矩阵。Santy 标度表如表 2, 判断矩阵如表 3。

表 2 Santy 标度表

标度	含义
1	表示两个因素相比, 具有同样重要性
3	表示两个因素相比, 前者比后者稍重要
5	表示两个因素相比, 前者比后者明显重要
7	表示两个因素相比, 前者比后者强烈重要
9	表示两个因素相比, 前者比后者极端重要
2, 4, 6, 8	表示上述相邻判断的中间值
倒数	若因素 i 与因素 j 的重要性为 z_{ij} , 那么因素 j 与因素 i 的重要性为 $1/z_{ij}$

表 3 判断矩阵 Z

z_{ij}	上柜率	再购率	同价类销量比	商业存销比	订足率	销售年限	是否进入衰退期
上柜率	1	3	5	2	3	5	7
再购率	1/3	1	3	1	3	7	5
同价类销量比	1/5	1	1	2	2	2	2
商业存销比	1/2	1	1/2	1	3	3	5
订足率	1/3	1/3	1/2	1/3	1	2	1
销售年限	1/5	1/7	1/2	1/3	1/2	1	1
是否进入衰退期	1/7	1/5	1/2	1/5	1	1	1

4.2 实验结果

通过判断矩阵 Z 进行一致性检验, 发现 $CR > 0.1$, 表示一致性检验没有通过, 则需要对该矩阵进行调整, 调整公式如下:

$$z_{ij}^k = z_{ik} \times z_{kj} \quad k = 1, 2, \dots, \text{且 } k \neq i, j \quad (16)$$

$$\beta_{ij} = \sum_{\substack{k=1 \\ k \neq i, j}}^n (z_{ij} - z_{ij}^k) / (z_{ij})^2 \quad (17)$$

定义专家判断矩阵中, 针对任意两个影响因素 i, j 的相对重要性判断信息为 z_{ij}^k , 则对于判断矩阵中每一个元素 z_{ij} , 存在 $n - 2$ 个 z_{ij}^k 逻辑判断信息, 分别表示根据专家对因素 i 与因素 j 与其他因素的相对重要性判断结果, 导出的因素 i 与因素 j 的相对重要性。 β_{ij} 为每一个因素 z_{ij} 的偏移度指标, 找出 $\max\{\beta_{ij}\}$ 所对应的 z_{ij} , z_{ij} 是判断矩阵中逻辑关系最矛盾的因素。通过下式对逻辑关系最矛盾的因素进行替换, 替换后重新进入一致性判断, 直至 $CR < 0.1$ 。

$$z_{ij} = n - 2 \sqrt{\prod_{\substack{k=1 \\ k \neq i, j}}^n z_{ik} \times z_{kj}} \quad (18)$$

通过上述公式调整判断矩阵, 并归一化得到影响因素影响权重向量, 如式 (19):

$$T = [0.34, 0.21, 0.13, 0.15, 0.07, 0.05, 0.05] \quad (19)$$

将上述得出的权重向量 T 带入 BP 神经网络中隐含层, T 与随机定义的长度为 3 的向量相加作为隐含层的阈值^[16-17], 每一次反向迭代修正不改变 T , 只改变随机序列, 经过 BP 神经网络的训练最优参数 w_{ij} , v_{jk} , 预测产品进退结果并与实际结果进行比对, 得出准确率, 并将文中模型预测结果与传统 BP 神经网络、SVM 的预测结果进行对比。




图 4 不同迭代次数下的准确率

如图 4 所示, 随着迭代次数的增加, 模型的准确率同样增加并趋于平缓。在不同的迭代次数下, 文中模型算法要优于传统 BP 神经网络、SVM 算法, 在较小的迭代次数下, 获得了较高的准确率, 在有限的时间内获得了最优结果。如图 5 所示, 随着样本容量的增加, 模

型预测准确率也不断增加并趋于平缓。在不同的训练样本容量下,文中模型算法要优于传统 BP 神经网络、SVM 算法,在小样本下也有较高的准确率,解决有限样本预测结果较差的问题。




图 5 不同样本容量下的准确率

5 结束语

文章首先利用 AHP 对影响产品进退的相关因素进行权重赋值,不同的影响因素经过专家判定和一致性检验,得出最终的影响因素权重值;再把得出的影响因素权重值运用到 BP 神经网络,考虑因素之间的相关性,通过不断迭代次数和改变训练样本容量计算出最优参数,建立起产品引入与退出预测模型,并实际应用于某数据集。实验表明,该预测模型在提高了预测准确度和收敛速度的同时,也简化了 BP 反向传播的计算,缩小了预测误差,避免陷入局部最优解。由于该模型依赖专家判定,不同的专家判定的侧重点都有所不同,可能导致网络训练情况具有一定的误差,达到的准确度有偏差。若未来需要深入研究,可考虑在现有算法基础上减小专家判定带来的影响。

参考文献:

- [1] 王鸿鹭,蒋 炜,魏 来,等. 基于物联网的产品全生命周期质量管理的模式创新与展望[J]. 系统工程理论与实践, 2021, 41(2): 475-482.
- [2] 赵 静,贾建浩. 药品产品组合的生命周期管理策略研究[J]. 价格理论与实践, 2020(6): 142-145.
- [3] 岳未祯,索玮岚,陈 锐. 存在中间产品退出的混合型生产系统效率测度与分解研究[J]. 数学的实践与认识, 2019, 49(4): 66-75.
- [4] 何喜军,马 珊,武玉英,等. 小样本下多维指标融合的电商产品销量预测[J]. 计算机工程与应用, 2019, 55(15): 177-184.
- [5] REN S, CHAN H L, RAM P. A comparative study on fashion demand forecasting models with multiple sources of uncertainty[J]. Annals of Operations Research, 2017, 257: 335-355.
- [6] 张艳辉,李宗伟. 在线评论有用性的影响因素研究: 基于产品类型的调节效应[J]. 管理评论, 2016, 28(10): 123-132.
- [7] DI PILLOW G, LAZORE V, LUCIDI S, et al. An application of support vector machines to sales forecasting under promotions[J]. 4OR, 2016, 14(3): 309-325.
- [8] 圣文顺,赵翰驰,孙艳文. 基于优化 BP 神经网络的销售预测模型研究[J]. 辽宁工业大学学报: 自然科学版, 2020, 40(2): 117-120.
- [9] IZADIKHAH M, TAVANA M, DI CAPRIO D, et al. A novel two-stage DEA production model with freely distributed initial inputs and shared intermediate outputs[J]. Expert Systems with Applications, 2018, 99: 213-230.
- [10] 李春林,徐 好,吴琳拥. 基于层次分析法的雷达仙波信号检测与抑制方法[J]. 电子科技大学学报, 2020, 49(6): 843-847.
- [11] 王国华,熊 立,董 雨,等. AHP 中专家判断信息的提取及一致性调整的方法[J]. 运筹与管理, 2004, 13(6): 41-44.
- [12] 周业付. 基于 AHP-FCE 模型的农产品供应链绩效评价[J]. 统计与决策, 2020, 36(23): 178-180.
- [13] 汪科任,罗世辉,陈晓昊,等. 基于 AHP 分析法的磁浮系统车轨耦合振动抑制方法[J]. 铁道学报, 2020, 42(11): 29-35.
- [14] 董志贵,王福林,宋庆凤,等. 基于 BP 神经网络的无约束优化方法[J]. 统计与决策, 2019, 35(1): 79-82.
- [15] 姚景瑜,孟海洋,杨 京,等. 基于 BP 人工神经网络的轴流风扇气动噪声预测[J]. 南京大学学报: 自然科学, 2020, 56(6): 900-908.
- [16] FENG Yongqiang, LIU Yuzhuang, WANG Xin, et al. Performance prediction and optimization of an organic Rankine cycle (ORC) for waste heat recovery using back propagation neural network[J]. Energy Conversion and Management, 2020, 226: 113552.
- [17] CHENG Yanming, LIU Cheng, WU Jing, et al. A back propagation neural network with double learning rate for PID controller in phase-shifted full-bridge soft-switching power supply[J]. Journal of Electrical Engineering & Technology, 2020, 15(6): 2811-2822.