

# 基于神经网络和象元理论的轮毂形态设计研究

孙利, 覃忠志, 张硕, 姜伟, 赵剑, 吴俭涛  
(燕山大学 艺术与设计学院, 河北 秦皇岛 066000)

**摘要:** **目的** 为实现在满足用户偏好前提下的产品形态创新设计, 以保证新形态的市场接受度和降低产品开发风险, 从而探索一种神经网络算法和象元理论相结合的轮毂形态设计方法。**方法** 首先运用 KJ 法建立目标轮毂样本库, 并采用李克特量表和三角模糊法, 对样本的用户模糊偏好值进行量化, 其次引入象元理论中的本体象元对轮毂形态特征因子进行提取和归类, 构建轮毂形态本体象元空间, 并进行轮毂本体象元组合编码处理; 再次通过 BP 神经网络算法探析轮毂形态本体象元组合编码和用户模糊偏好值之间的映射关系, 用于预测和输出用户模糊偏好值最佳的本体象元组合方案; 最后对最佳本体象元组合方案进行拓展, 构建喻体象元空间, 并运用形状文法规则对最佳本体象元组合方案进行形态创新设计。**结论** BP 神经模型测试结果显示 MSE 为 0.005 5, 表明模型精度良好, 且最终 4 个设计方案的实际评价价值和预测值的 MSE 为 0.005 3, 验证了该设计方法的有效性, 能够为相关设计人员提供了一定的理论参考。

**关键词:** 用户偏好; BP 神经网络; 象元理论; 形态创新; 轮毂设计

**中图分类号:** TB472 **文献标识码:** A **文章编号:** 1001-3563(2023)16-0198-12

**DOI:** 10.19554/j.cnki.1001-3563.2023.16.020

## Hub Form Design Based on Neural Network and Pixel Theory

SUN Li, QIN Zhong-zhi, ZHANG Shuo, JIANG Wei, ZHAO Jian, WU Jian-tao  
(School of Art and Design, Yanshan University, Hebei Qinhuangdao 066000, China)

**ABSTRACT:** The work aims to explore a hub form design method combining neural network algorithm and pixel theory, so as to realize the innovative design of product form under the premise of satisfying user's preference, ensure the market acceptance of the new form, and reduce the risk of product development. Firstly, the KJ method was used to establish the target hub sample library, and the Likert scale and the triangular fuzzy method were used to quantify the user's fuzzy preference value of the sample. Secondly, the ontology pixel in the pixel theory was introduced to extract and classify the morphological characteristic factors of the hub, construct the hub form ontology pixel space, and process the hub ontology pixel combination code. Then, the BP neural network algorithm was adopted to analyze the mapping relationship between the hub form ontology pixel combination code and the user's fuzzy preference value, which was used to predict and output the optimal ontology pixel combination scheme of the user's fuzzy preference value. Finally, the optimal ontology combination scheme was expanded to construct a metaphorical element space, and the optimal ontology pixel combination scheme was subject to innovative design of form by the rules of shape grammar. The test results of the BP neural model show that the MSE is 0.005 5, indicating that the model has good accuracy, and the MSE of the actual evaluation value and predicted value of the final four design schemes is 0.005 3, which verifies the effectiveness of the design method and can provide relevant designers with certain theoretical reference.

**KEY WORDS:** user's preference; BP neural network; pixel theory; form innovation; hub design

收稿日期: 2023-03-06

基金项目: 国家社会科学基金艺术学项目 (22BG125)

作者简介: 孙利 (1973—), 男, 博士, 教授, 主要研究方向为机械装备产品智能定制设计理论与方法、康养辅具创新设计。

通信作者: 吴俭涛 (1976—), 女, 博士, 教授, 主要研究方向为工业产品智能设计方法创新。

汽车轮毂形态作为汽车整体形态的重要表征之一,其形态特征直接影响用户偏好,进而影响用户的消费选择。因此,对企业而言,如何提升新设计成功率和规避产品开发风险是企业生存和发展的关键,这使如何在满足用户偏好前提下的产品形态创新设计成为设计热点问题<sup>[1-2]</sup>。目前关于产品形态的用户偏好研究主要集中于产品形态特征与意象或用户偏好的匹配关联,程永胜、徐晓琪<sup>[3]</sup>运用 BP 神经网络构建了电动汽车造型意象预测模型,该模型运用统计学方法,结合 BP 神经网络对电动汽车造型特征和感性意象的隐性关联进行研究,提升了造型意象预测能力。尹磊、黄黎清<sup>[4]</sup>针对电动汽车中前大灯造型意象问题,采用 BP 神经网络分析设计要素与用户情感之间的相关性。陈世斌、杨双建<sup>[5]</sup>等采用双 BP 神经网络训练的思路,建立小轿车外观设计元素与感性意象间的对应关系,得到设计方案的感性意象预测模型,达到了设计方案与用户感性意象目标的趋同。杨冬梅、李竹一<sup>[6]</sup>等采用 PSO-BP 神经网络解决工业装备造型元素特征与用户感性认知间的映射问题,实现了工业装备造型优化设计。王欢欢、初胜男<sup>[7]</sup>等采用 BP 神经网络技术,在 MATLAB 中搭建汽车造型轮廓与意象语义之间的关系模型,实现对汽车侧面造型风格的快速判断。候康宇、吕健<sup>[8]</sup>等则应用卷积神经网络对特定意象风格下的苗族图案进行特征提取,实现了意象风格与特征元素的映射关联。上述文献均通过提取产品设计元素因子与偏好因子,然后运用神经网络技术构建了产品设计元素与用户偏好之间的映射关系,实现了对若干个产品形态特征组合方案的感性偏好值预测,从而满足了用户偏好。然而在方案设计阶段往往只是将已收集提取的设计元素因子进行重新排列组合,其组合输出的结果创新程度有限,难以有效满足用户的形态创新需求。象元理论是由吴俭涛<sup>[9]</sup>于 2018 年提出的一种以本体-喻体象元为核心的形态设计方法,首先通过本体象元以模块化的方式实现产品形态归类,即产品形态特征因子的提取和分类;然后通过喻体象元以联想关联的方式实现产品形态的拓展,即产品形态特征因子的拓展和衍生,丰富设计元素。通过本体-喻体象元的相互结合,可以有效

地对产品形态进行关联性创新,保证产品形态的继承性和创新性,进而有利于保证新方案与初始方案在用户偏好方面的一致性和形态方面的创新性。因此,本文将尝试提出一种基于神经网络和象元理论的轮毂形态设计方法,通过 BP 神经网络预测和输出用户偏好最佳的设计组合,然后通过象元理论对该设计组合进行形态创新设计,用于解决满足用户偏好前提下的产品形态创新设计问题。

## 1 研究思路

满足用户偏好前提下的产品形态创新设计研究思路主要包含产品形态与用户偏好的匹配过程和形态创新设计过程。其核心思路为:根据用户主观感受获取目标产品形态的用户模糊偏好值,通过建立数理模型使产品形态与用户模糊偏好之间取得耦合平衡,并基于此种平衡状态进行下一步形态创新设计。具体的研究框架可分述为 4 个阶段,见图 1。

### 1.1 建立目标产品样本库

目标产品样本库是指在产品形态共性和个性方面具有代表性和概括性的产品,它主要由符合国家、企业标准的常见产品、热门产品和经典产品组成。常见产品是指当前市场中最为常见和普遍的产品,它代表了该类产品的基本型;热门产品是指当前市场中销量偏高和受欢迎程度偏高的产品,它代表了该类产品的期望型;经典产品指在整个市场历史中的某一阶段最具代表性的产品。三者可以通过相关企业官网、期刊和书籍及在线商城等渠道进行初步搜集,然后运用 KJ 法和专家小组对产品进行分类筛选,剔除相似形态和模糊形态,最终建立目标产品样本库。

### 1.2 建立产品形态本体象元空间

参考已建立的目标产品样本库,利用象元理论对产品形态进行模块化拆解,构建产品形态本体象元空间。象元<sup>[10]</sup>作为产品形态的特征基因,决定了产品形态的呈现与变化,因此不同产品形态也对应着不同形式和数量的具体象元。在象元理论中将产品基本象元分为五大类<sup>[11]</sup>,

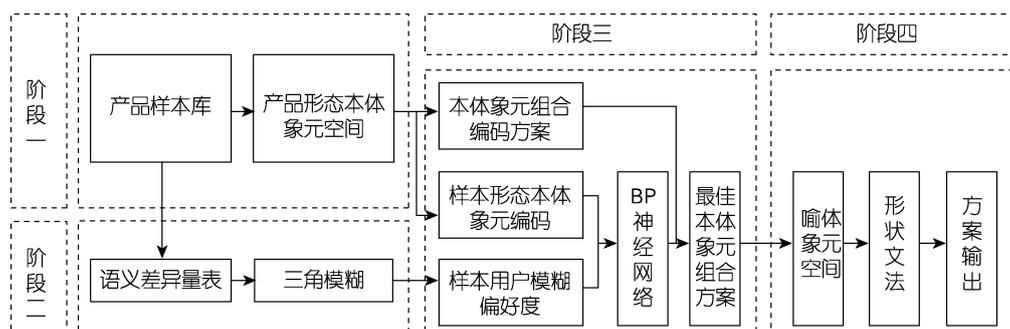


图 1 研究思路  
Fig.1 Research ideas

分别是表达产品基本结构特征和尺寸特征的骨——面象元；表达产品运动状态特征的动——静象元；表达产品形态数量特征和形态变化趋势特征的量——势象元；表达产品种类特征和局部细节特征的共——个象元，以及表达产品具体形态特征和根据产品形

态而产生联想的自体——喻体象元，五类象元具体关系见图2。因此，本文将通过骨——面象元、共——个象元、动——静象元和量——势象元等本体象元对目标产品形态进行模块化归类，建立产品形态本体象元空间。

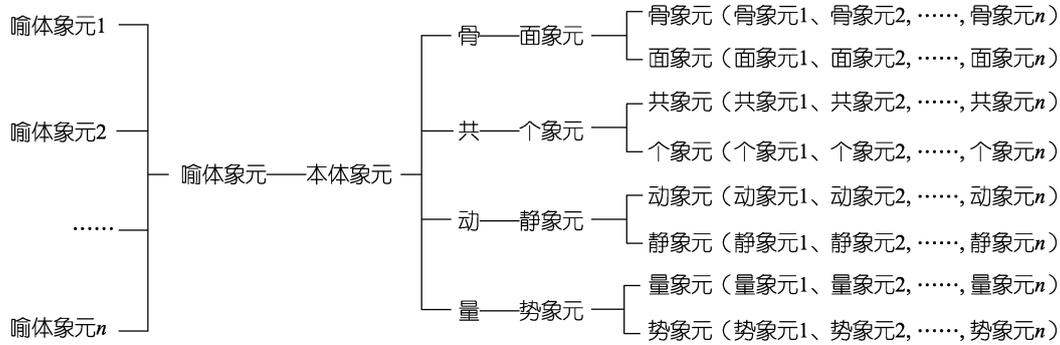


图2 五大象元关系  
Fig.2 Five-pixel relationship

### 1.3 获取用户模糊偏好值

满足用户偏好是产品在市场上成功的关键，准确获取用户偏好程度则是产品设计的第一关键。目前，通过李克特量表获取用户对产品主观感受的量化评价是常用技术手段，以{-3、-2、-1、0、1、2、3}的7级特表为例，传统的李克特量表通常以1个单位为评价增量，然而由于用户偏好的模糊性和主观性，用户的偏好评价结果通常不能被准确地描述<sup>[12]</sup>。而三角模糊作为一种模糊数计算方法，能够有效地进一步将模糊的用户偏好评价转换为定量数值，有效提升用户的评价效果且便于操作和运算。因此，本文将李克特量表和三角模糊法相结合，采用7级李克特量表对样本进行评价，将样本评价均值转化为三角模糊数，从而对样本的用户模糊偏好值进行量化处理。假设  $n$  位评价者关于  $j$  个样本的用户偏好程度进行评价，测试者对其评价可视为模糊评价价值，转化为三角模糊数，表示为：

$$Z_p^u = (a_p^u, b_p^u, c_p^u) \tag{1}$$

其中： $p=1,2,3,\dots,g$ ； $u=1,2,3,\dots,t$ ； $Z_p^u$  为第  $u$  个用户关于第  $p$  个样本的三角模糊数； $a_p^u$  为第  $u$  个用户关于第  $p$  个样本的模糊数的下限； $b_p^u$  为第  $u$  个用户关于第  $p$  个样本的模糊数可能性最大的值； $c_p^u$  为第  $u$  个用户关于第  $p$  个样本的模糊数的上限； $g$  为样本数量； $t$  为测试人员数量。

构建  $t$  位测试者关于  $g$  个样本的模糊评价矩阵，并将其表示为：

$$Z = \begin{bmatrix} Z_1^1 & Z_1^2 & \dots & Z_1^t \\ Z_2^1 & Z_2^2 & \dots & Z_2^t \\ \dots & \dots & \dots & \dots \\ Z_g^1 & Z_g^2 & \dots & Z_g^t \end{bmatrix} \tag{2}$$

假设测试者的重要模糊权重记为  $W$ ，则  $n$  位测试者的模糊权重向量可表示为：

$$W = (W^1, W^2, \dots, W^t) \tag{3}$$

$t$  个测试者对样本  $p$  的用户偏好综合模糊评价集为  $D$ ，则：

$$D = (D_1, D_2, \dots, D_p) \tag{4}$$

$$D_p = (A_p, M_p, F_p) \tag{5}$$

$$A_p = \sum_{u=1}^t a_p^u \cdot w^u \tag{6}$$

$$M_p = \sum_{u=1}^t b_p^u \cdot w^u \tag{7}$$

$$F_p = \sum_{u=1}^t c_p^u \cdot w^u \tag{8}$$

$$D_p = (A_p + 2M_p + F_p) / 4 \tag{9}$$

其中： $p=1,2,3,\dots,g$ ； $u=1,2,3,\dots,t$ ； $D_p$  为  $t$  个测试者对第  $p$  个样本的综合模糊偏好值； $A_p$  为  $t$  个测试者对第  $p$  个样本模糊数的下限和； $M_p$  为  $t$  个测试者对第  $p$  个样本模糊数可能性最大的值之和； $F_p$  为的  $t$  个测试者对第  $p$  个样本的模糊数的上限和。最后根据式(9)将用户偏好度的三角模糊数进行去模糊化处理，实现用户模糊偏好值的定量计算。

### 1.4 构建 BP 网络模型

BP 是一种按误差逆传播算法训练的多层前馈网络，它具有学习和存贮大量的输入—输出模式映射关系，且无需事前揭示描述这种映射关系的数学方程的特点，是目前应用最广泛的神经网络模型之一。BP 算法的学习过程由信号的正向传播与误差逆向传播两个过程组成。算法开始后，设定学习次数上限和误差阈值和学习系数  $\eta$ 。并对连接权值和阈值赋予小的随机数，一般在[-1,1]。输入样本数据，网络正向传播，得到隐含层与输出层的值。然后比较输出层的值

与期待值的误差, 若误差大于阈值, 则转入误差的逆向传播阶段, 将输出误差按照某种形式, 通过隐含层向输入层返回, 从而获得各层单元的参考误差或误差信号, 作为修改各个单元权值的依据, 进而对中间层和输出层权值和阈值进行更新, 更新的算法为  $\delta$  学习规则。其具体的数学定义为: 输入层向量为  $\mathbf{X} = (x_1, x_2, x_3, \dots, x_n)^T$ ,  $x_i$  代表输入层第  $i$  个神经元的值,  $n$  代表输入层神经元数量; 隐含层向量为  $\mathbf{Y} = (y_1, y_2, y_3, \dots, y_m)^T$ ,  $y_j$  代表隐含层第  $j$  个神经元的值,  $m$  代表隐含层神经元数量; 输出层向量为  $\mathbf{O} = (o_1, o_2, o_3, \dots, o_l)^T$ ,  $o_k$  代表输出层第  $k$  个神经元的值,  $l$  代表输出层神经元数量; 期望输出向量为  $\mathbf{D} = (d_1, d_2, d_3, \dots, d_l)^T$ ,  $d_k$  代表输出层第  $k$  个神经元的期望值,  $l$  代表输出层神经元数量。

将输出层到隐含层的权值连接矩阵定义为  $\mathbf{V}$ 。

$$\mathbf{V} = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1m} \\ v_{21} & v_{22} & \dots & v_{2m} \\ \dots & \dots & \dots & \dots \\ v_{n1} & v_{n2} & \dots & v_{nm} \end{bmatrix} \quad (10)$$

其中:  $v_{nm}$  代表隐含层第  $m$  个神经元时对应的输入层第  $n$  个神经元的权值。

将隐含层到输出层的权值连接矩阵定义为  $\mathbf{W}$ 。

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1l} \\ w_{21} & w_{22} & \dots & w_{2l} \\ \dots & \dots & \dots & \dots \\ w_{m1} & w_{m2} & \dots & w_{ml} \end{bmatrix} \quad (11)$$

其中:  $w_{ml}$  代表输出层第  $l$  个神经元时对应的隐含层第  $m$  个神经元的权值。

对输出层, 有  $o_k = f(H_k)$ ,

$$H_k = \sum_{j=0}^m w_{jk} y_j, k = 1, 2, 3, \dots, l, \quad (12)$$

对隐含层, 有

$$y_j = f(H_j), H_j = \sum_{i=0}^n v_{ij} x_i, j = 1, 2, 3, \dots, m, \quad (13)$$

同时转移函数法  $f(x)$  采用单极性 *Sigmoid* 函数:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (14)$$

该函数具有连续可导的特点, 且具有:

$$f'(x) = f(x)[1 - f(x)] \quad (15)$$

定义输出层实际值和预测值的误差为  $E$ ,

$$E = \frac{1}{2} (D - O)^2 = \frac{1}{2} \sum_{k=1}^l (d_k - o_k)^2 \quad (16)$$

通过式 (10) 将误差  $E$  展开到隐含层为:

$$E = \frac{1}{2} (D - O)^2 = \frac{1}{2} \sum_{k=1}^l (d_k - o_k)^2 = \frac{1}{2} \sum_{k=1}^l (d_k - f(H_k))^2 = \frac{1}{2} \sum_{k=1}^l \left( d_k - f \left( \sum_{j=0}^m w_{jk} y_j \right) \right)^2 \quad (17)$$

通过式 (11) 误差  $E$  展开到输入层为:

$$E = \frac{1}{2} \sum_{k=1}^l \left( d_k - f \left( \sum_{j=0}^m w_{jk} f(H_j) \right) \right)^2 = \frac{1}{2} \sum_{k=1}^l \left( d_k - f \left( \sum_{j=0}^m w_{jk} f \left( \sum_{i=0}^n v_{ij} x_i \right) \right) \right)^2 \quad (18)$$

对输出层和隐含层分别各自定义一个误差信号  $P_k^o$  与  $P_j^y$

对输出层的权值调整量可写为:

$$\Delta w_{jk} = \eta \cdot P_k^o \cdot y_j, j = 0, 1, 2, 3, \dots, m; k = 1, 2, 3, \dots, l \quad (19)$$

对隐含层的权值调整量可写为:

$$\Delta v_{ij} = \eta \cdot P_j^y \cdot x_i, i = 0, 1, 2, 3, \dots; j = 1, 2, 3, \dots, m \quad (20)$$

通过链式求导和偏导处理, 最终可将权值调整量分别写为:

$$\Delta w_{jk} = \eta \cdot P_k^o \cdot y_j = \eta \cdot (d_k - o_k) \cdot o_k \cdot (1 - o_k) \cdot y_j \quad (21)$$

$$\Delta v_{ij} = \eta \cdot P_j^y \cdot x_i = \eta \cdot \sum_{k=1}^l P_k^o \cdot y_j \cdot (1 - y_j) \cdot x_i \quad (22)$$

更新权值和阈值后, 再次将样本数据作为输入, 得到中间层与输出层的值, 计算误差是否满足, 学习次数是否达到指定值, 如果达到, 则学习结束。

本文拟通过计算机模拟智能算法。采用 *matlab* 软件调用相关函数包来建立用户偏好度预测模型。基于上述阶段所获取的产品形态象元空间和用户模糊偏好值, 利用 BP 神经网络算法探析产品形态象元组合编码和用户模糊偏好值之间的映射关系, 通过建立样本数据集来进行 BP 神经网络训练和测试, 最后预测和输出用户模糊偏好值最佳的本体象元组合方案, 具体见图 3。

### 1.5 建立喻体象元空间

基于上文预测模型输出的用户模糊偏好值最佳的本体象元组合方案, 对该方案中的本体象元形态进行联想发散, 选取联想结果中与本体象元相似度较高的事物来建立喻体象元空间<sup>[13]</sup>, 如图 4 所示。由于喻体象元与本体象元之间的相似性, 一方面保留了本体象元组合的基本特征, 保证了前后两者形态之间的继承性, 有利于保证用户偏好值的稳定性和延续性; 另一方面对本体象元组合的基本形态进行了拓展和衍生, 取代初始的本体象元, 丰富了设计要素, 提供了形态创新动力, 保证了形态的创新性。假设最佳本体象元组合方案 A 由若干个本体象元构成, 将方案 A 记为  $A = \{X_1, X_2, X_3, X_n\}$ ,  $X_h$  代表第  $h$  个本体象元; 每一个本体象元对应联想产生的喻体象元记为  $S_h = \{S_{h1}, S_{h2}, S_{h3}, S_{hq}\}$ ,  $S_{hq}$  代表第  $h$  个本体象元的第  $q$  个喻体象元, 其喻体象元空间矩阵记为  $\mathbf{Y}$ , 则得:

$$\mathbf{Y} = \begin{bmatrix} S_{11} & S_{12} & \dots & S_{1q} \\ S_{21} & S_{22} & \dots & S_{2q} \\ \dots & \dots & \dots & \dots \\ S_{h1} & S_{h2} & \dots & S_{hq} \end{bmatrix} \quad (23)$$

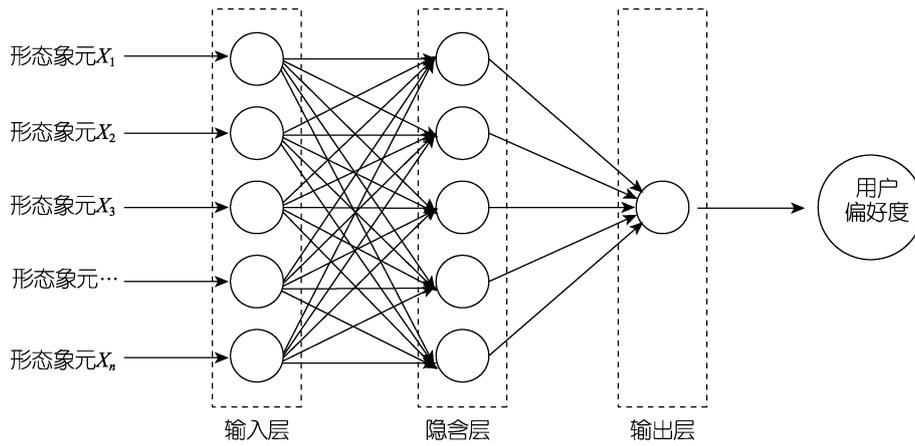


图3 BP网络结构  
Fig.3 BP network structure



图4 喻体象元空间示例  
Fig.4 Example of metaphorical pixel space

### 1.5 形态创新设计

结合上述的喻体象元空间,运用形状文法对用户模糊偏好值最佳的本体象元组合方案和喻体象元进行形态融合创新设计。形状文法作为一种跨学科应用的造型设计方法<sup>[14-15]</sup>,被广泛应用于产品造型创新中,通过利用形状文法的推演规则重构初始形态空间和结构,不仅可以生成新的产品形态,还能实现产品特点的继承性与创新性,其基本表达为:

$$G = (S, L, R, I) \quad (24)$$

其中:  $G$  指变化衍生后的形状集,  $S$  指形状集合,  $L$  指符号集合,  $R$  指形状规则集合,  $I$  是初始形状<sup>[16-17]</sup>。其形状规则  $R$  主要包含修改性规则和生成性规则,见表1。本研究将BP神经网络预测输出的用户模糊偏好值最佳的本体象元组合方案作为初始形态  $I$ ,并结

表1 形状文法推演规则  
Tab.1 Shape grammar deduction rules

规则名称	方法	适用范围
R1=置换	使用其他形态代替部分或全部初始形态	形态替代性
R2=增删	增加或删除部分初始形态	创新
R3=旋转	对初始形态进行角度变换	
R4=缩放	缩小或放大初始形态的部分或整体	
R5=平移	对初始形态的部分进行直线移动	
R6=错切	对初始形态的部分或整体按比例向相反方向移动	形态变异性创新
R7=复制	对初始形态进行复制	
R8=拉伸	沿某一方向对部分初始形态比例进行修改	

合喻体象元空间,将喻体象元空间中的形状作为  $L$ ,使初始形态  $I$  在形状文法推演规则作用下得到新的形态  $S$ ,达到在满足用户偏好的初始产品形态基础上进行创新设计的目的,以生成用户偏好良好且创新性强的方案。

## 2 设计实例

为验证上述方法的有效性,以汽车轮毂形态设计为例,结合BP神经网络算法和象元理论对汽车轮毂进行满足用户偏好前提下的产品形态创新设计。

### 2.1 构建产品样本库

通过相关企业官网、期刊和书籍及在线商城等渠道进行初步搜集,分别选取各大品牌各系列基础版汽车及各大汽车品牌官网近年来销售量前5的车型,并提取其轮毂作为产品样本。同时选取各品牌历史上的经典汽车并提取其轮毂作为样本,共收集到216幅轮毂图片。剔除相似形态图片和模糊形态图片后得到162幅轮毂图片,并建立了产品样本库。由于篇幅有限仅展示部分,见图5。



图5 轮毂样本库图片  
Fig.5 Image of hub sample library

### 2.2 构建产品形态本体象元空间

基于前文建立的产品样本库,采用贝塞尔曲线对

图片中的轮毂轮廓进行提取, 以用于描述轮毂形态特征。通过专家咨询和象元理论中的骨——面象元、共——一个象元、动——静象元和量——势象元等本体象元概念对样本轮毂形态进行模块化拆解和分类。根据轮毂基本结构特征分别将骨面象元划分为辐条式、盘面式、网状式; 根据轮毂辐条形态的种类特征将共象元划分为矩形、V 形、I 形、L 形、Y 形、多边形、双线形、S 形、扇形; 根据轮毂局部细节特征将个象元划分为描边式、镂空式、沟壑式; 根据轮毂辐条形态的运动状态将动静象元划分为稳定式、旋转式、放射式; 根据轮毂中辐条的数量所呈现出 3、4、5、7 的倍数特征, 将量象元划分为 3 幅、4 幅、5 幅、7 幅; 根据轮毂辐条的形态变化趋势将势象元划分为内缩式和外扩式, 最终获得轮毂形态本体象元空间, 共计 24 个象元, 见表 2。

### 2.3 获取用户模糊偏好值

基于前文建立的 162 个轮毂样本库, 结合李克特

量表建成 7 级用户偏好量评价表, 评价集  $Q = \{\text{非常喜欢, 很喜欢, 喜欢, 一般, 不喜欢, 很不喜欢, 非常不喜欢}\}$ 。邀请 8 位汽车深度爱好者作为测试人员, 其中男性 6 名, 女性 2 名。为了保证评价结果的有效性和客观性, 首先为排除色彩、材质对用户评价的干扰, 对所有图片进行去色相处理; 其次为了避免长时间浏览图片后产生的视觉疲劳和生理疲劳对评价结果的影响, 将 162 个轮毂样本划分为 8 个单元, 每个单元平均分配 20 张图片, 最后一个单元为 22 张图片, 要求用户在评价过程中, 每两个单元之间设置 10 分钟的休息时间; 再次邀请上述的 8 名被测人员在观察 162 个轮毂样本后分别对其进行用户偏好评价, 以获取每个样本的用户偏好值; 最后参考文献[19]给出的数据模糊转换实施方法, 按照表 3 进行三角模糊数置换, 计算得出用户模糊偏好值, 由于篇幅有限仅展示部分, 见表 4。

表 2 轮毂本体象元空间  
Tab.2 Pixel space of hub ontology

类别	子类别	示例				
骨——面象元	辐条式					
	共象元					
	共——一个象元					
个象元						
动——静象元	稳定式					
	量象元					
势——量象元	势象元					
	内缩式					

表3 模糊转换等级  
Tab.3 Fuzzy conversion level

量表分值	语义等级	三角模糊数
1	非常不喜欢	(0, 0, 0.1)
2	很不喜欢	(0, 0.1, 0.25)
3	不喜欢	(0.15, 0.3, 0.45)
4	一般	(0.35, 0.5, 0.65)
5	喜欢	(0.55, 0.7, 0.85)
6	非常喜欢	(0.75, 0.9, 1)
7	很不喜欢	(0.9,1,1)

由于上述邀请的8位测评者具有相近的汽车爱好背景,故可将他们对样本的指标权重视作相同,即 $W=1/8$ 。再按照式(5)~(8),计算得到用户模糊偏好值。由于篇幅有限仅展示部分,见表5。

## 2.4 构建BP神经网络模型

### 2.4.1 本体象元组合编码处理

通过计算机研究产品形态象元与用户偏好之间的预测模型,首先应将设计变量转换为计算机可识别

的信息数据。用户综合模糊评价作为输出变量,通过量化评价和模糊处理后,已经实现了数据化,可直接作为输出数据集并被计算机识别。然而轮毂形态的本体象元作为一种非数据的特殊信息形式,作为输入变量需对其进行编码处理,根据前文已构建的轮毂本体象元空间,对样本轮毂的本体象元组合进行编码处理,若该样本轮毂形态中存在该本体象元时,则记为“1”,若不存在该本体象元,则记为“0”。由图6可知,共有24个本体象元,则一个轮毂样本的编码共计为24位,如100100000000100010010000。按照上述方法,将162个样本依次进行编码处理,编码整理汇总,见表6。

### 2.4.2 神经网络参数设置

本文基于Matlab R2016a软件构建BP神经网络结构,采用经典的3层神经网络结构进行构建,输入层的神经元节点数量由产品形态的本体象元数量决定,输出层神经元节点数量由用户偏好值数量决定,产品形态由24个本体象元编码组成,即输入层节点数量为24,1个用户偏好值输出,即输出层节点数量为1。

表4 用户三角模糊评价价值  
Tab.4 User's triangle fuzzy evaluation value

样本	用户评价三角模糊数												
	用户1		用户2		...	用户7		用户8					
样本1	0	0.1	0.25	0.35	0.5	0.65	...	0.55	0.7	0.85	0.35	0.5	0.65
样本2	0.35	0.5	0.65	0.55	0.7	0.85	...	0.55	0.7	0.85	0.55	0.7	0.85
样本3	0.55	0.7	0.85	0.15	0.3	0.45	...	0.35	0.5	0.65	0.55	0.7	0.85
样本4	0.15	0.3	0.45	0.35	0.5	0.65	...	0.55	0.7	0.85	0.15	0.3	0.45
样本5	0.9	1	1	0.75	0.9	1	...	0.55	0.7	0.85	0.9	1	1
样本6	0.35	0.5	0.65	0.35	0.5	0.65	...	0.55	0.7	0.85	0.55	0.7	0.85
样本7	0.35	0.5	0.65	0.15	0.3	0.45	...	0.35	0.5	0.65	0.15	0.3	0.45
样本8	0.35	0.5	0.65	0.35	0.5	0.65	...	0.55	0.7	0.85	0.55	0.7	0.85
样本9	0.15	0.3	0.45	0.15	0.3	0.45	...	0.35	0.5	0.65	0.55	0.7	0.85
样本10	0.15	0.3	0.45	0.15	0.3	0.45	...	0.55	0.7	0.85	0.15	0.3	0.45

表5 用户综合模糊偏好值  
Tab.5 User's comprehensive fuzzy preference value

样本	用户评价三角模糊数												用户模糊偏好值	
	用户1		用户2		...	用户7		用户8						
样本1	0	0.1	0.25	0.35	0.5	0.65	...	0.55	0.7	0.85	0.35	0.5	0.65	0.4859
样本2	0.35	0.5	0.65	0.55	0.7	0.85	...	0.55	0.7	0.85	0.55	0.7	0.85	0.6594
样本3	0.55	0.7	0.85	0.15	0.3	0.45	...	0.35	0.5	0.65	0.55	0.7	0.85	0.5609
样本4	0.15	0.3	0.45	0.35	0.5	0.65	...	0.55	0.7	0.85	0.15	0.3	0.45	0.4109
样本5	0.9	1	1	0.75	0.9	1	...	0.55	0.7	0.85	0.9	1	1	0.8500
样本6	0.35	0.5	0.65	0.35	0.5	0.65	...	0.55	0.7	0.85	0.55	0.7	0.85	0.5844
样本7	0.35	0.5	0.65	0.15	0.3	0.45	...	0.35	0.5	0.65	0.15	0.3	0.45	0.4250
样本8	0.35	0.5	0.65	0.35	0.5	0.65	...	0.55	0.7	0.85	0.55	0.7	0.85	0.4859
样本9	0.15	0.3	0.45	0.15	0.3	0.45	...	0.35	0.5	0.65	0.55	0.7	0.85	0.5344
样本10	0.15	0.3	0.45	0.15	0.3	0.45	...	0.55	0.7	0.85	0.15	0.3	0.45	0.4469

表 6 样本本体象元编码  
Tab.6 Sample ontology pixel code

样本	本体象元编码过程												样本本体象元编码								
	$X_1$	$X_2$	$X_3$	$X_4$	$X_5$	$X_6$	$X_7$	$X_8$	$X_9$	$X_{10}$	$X_{11}$	$X_{12}$									
样本 1	1	0	0	1	0	...	0	0	1	0	0	0	1	0	0	1	0	0	0	0	100100000000100010010000
样本 2	1	0	0	0	0	...	0	0	0	0	0	1	0	0	0	0	1	0	0	0	100000010000000100001000
样本 3	1	0	0	1	0	...	0	0	1	0	0	0	0	1	0	0	1	0	0	0	100100000000100001001000
样本 4	1	0	0	0	1	...	0	0	1	0	0	1	0	0	0	0	1	0	0	0	100010000000100100001000
样本 5	0	1	0	0	0	...	0	0	1	0	0	1	0	0	0	1	0	0	0	0	010000000100100100010000
样本 6	1	0	0	1	0	...	0	0	0	1	0	0	1	1	0	0	1	0	0	0	100100100000010011001000
样本 7	1	0	0	1	0	...	0	0	0	0	0	0	1	0	0	0	1	0	0	0	100100100000010011001000
样本 8	1	0	0	0	1	...	0	0	0	0	0	1	0	0	0	0	1	0	0	0	100010000000000100001000
样本 9	1	0	0	1	0	...	0	0	0	0	0	1	0	1	0	0	1	0	0	0	100100100000000101001000
样本 10	1	0	0	1	0	...	0	0	1	0	0	1	0	0	0	0	1	0	0	0	100100100000100100001000

然而隐含层神经元节点数量的确定缺乏固定计算公式和规则, 一般需要根据具体问题和实际操作经验来确定。合理的隐含层神经元节点不仅能提升非线性函数的拟合精度, 还能缩短神经网络的训练时间, 故采用式 (23) 确定神经元节点数范围, 再利用试凑法确定具体数值, 即在满足精度要求下, 测试每一个取值下的结果, 并取最佳结果对应的取值为最终值。

$$P \leq \sqrt{n \times (q + 3)} \quad (23)$$

其中:  $P$  为隐含层节点数量,  $n$  为输入层节点数量,  $q$  为输出层节点数量。

通过逐次试验, 发现当  $P$  值为 4 时, 该网络结构的输出误差值最小, 最终确定神经网络结构为 24, 4, 1, 具体结构见图 6。

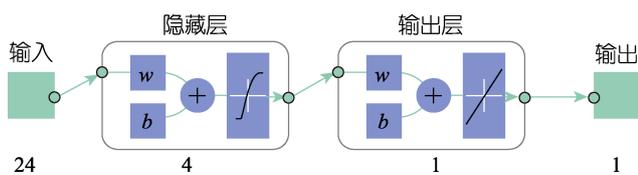


图 6 神经网络结构  
Fig.6 Neural network structure

### 2.4.3 神经网络训练与测试

此外, 分别设置 Log-sigmoid 函数为激活函数, purelin 函数为传递函数, 网络学习次数为 5 000 次, 误差目标值为 0.01, 将预测值与实际值的均方误差作为衡量模型精度的标准。将采集到的 162 组数据集进行随机排列, 按照排列序号将其划分为训练集和测试集, 其中训练集包含 140 组数据, 测试集包含 22 组数据。通过上述数据集进行训练和测试, 训练结果如图 7 所示。

由上图结果分析可知, 测试输出的用户偏好预测值与实际值的均方误差值 MSE 为 0.005 5, 小于 0.01,

在误差要求范围之内, 表明该神经网络模型达到精度要求且精度良好, 验证了模型的有效性, 可用于轮毂形态方案的用户模糊偏好值预测。

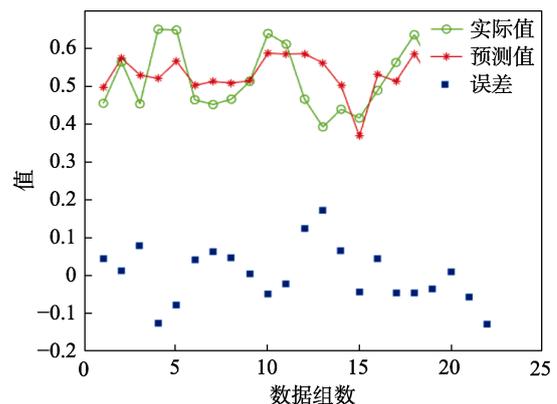


图 7 偏好度预测值和实际值误差对比  
Fig.7 Comparison of the error between the predicted value and the actual value of preference

## 3 用户模糊偏好度预测

利用上述训练好的 BP 神经网络模型对新方案的用户模糊偏好值进行预测。由前文建立的产品形态本体象元空间可知, 利用其中的本体象元可以重构组合产生  $3 \times 3 \times 9 \times 3 \times 3 \times 4 \times 2$  共计 1 944 个新方案。对组合产生的 1 944 个新方案进行编码处理并作为输入层数据, 将整理后的数据输入神经网络进行预测, 得到所有方案的用户模糊偏好值, 见表 7。由表 7 可知, 用户模糊偏好值最高的本体象元组合方案为 100010000000010001100001, 依据表 2 对该方案进行解码处理, 其对应的本体象元依次为幅条式、I 形式、描边式、稳定式、三幅式、外扩式, 将其组合作为下一步形态创新的初始形态, 见图 8。

表7 组合方案编码  
Tab.7 Combination scheme code

方案	组合方案编码	预测值
方案1	100010000000010001100001	0.792 2
方案2	100000001000100001100001	0.792 1
方案3	010000000100100001100001	0.791 3
方案4	100000001000100001100010	0.790 7
方案5	010010000000100001100001	0.786 5
方案6	100010000000100001100001	0.784 3
方案7	100000000100100001100001	0.783 8
方案8	100100000000100001100010	0.778 1
方案9	100010000000100001100010	0.771 9
方案10	010000001000100001100001	0.768 9

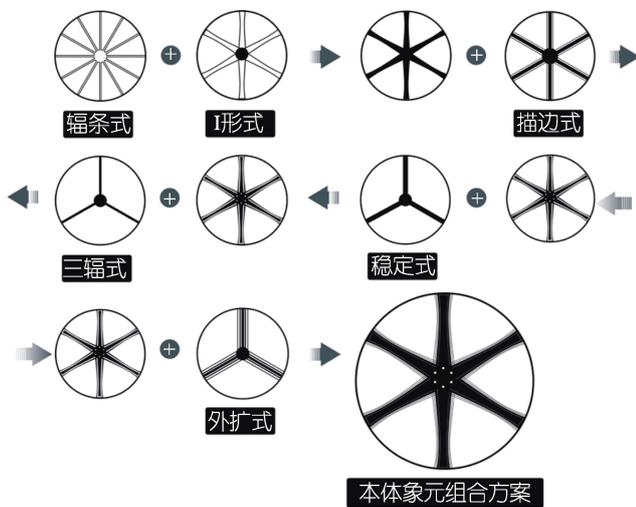


图8 本体象元组合过程  
Fig.8 Ontology pixel combination process

## 4 形态创新设计

### 4.1 喻体象元空间构建

选取用户模糊偏好值最高的方案组合作为最佳本体象元组合, 并对其进行拓展和衍生。由于轮毂产品具有重复的特性<sup>[18]</sup>, 辐条形态作为轮毂形态的主要特点, 因此只需将单个轮辐辐条的形状进行提取并加以创新即可。为了构建喻体象元空间, 首先从最佳本体象元组合方案的辐条组合方案中提取单个轮辐形态, 然后要求上述8名被测人员在观察上述方案中的辐条本体象元后进行联想发散, 将各自所联想发散后的关联物进行收集汇总, 再由8名被测人员经过多轮反复的讨论和信息交流, 选取得票率较高的关联物作为喻体象元, 最后得到喻体象元空间, 见图9。

### 4.2 形态创新过程

通过计算机绘图软件 Adobe Illustrator 进行形状文法的形状推演。由于篇幅有限, 此处仅展示其中一个喻体与本体的创新融合过程。本文采用曲线控制法, 使用贝塞尔曲线提取最佳本体象元组合方案中辐条本体象元的基本轮廓作为初始形态 Q, 并将其设置为6个控制节点 A、B、C、D、E、F, 然后依次提取出辐条喻体象元空间中的4个喻体象元的基本轮廓 Q1、Q2、Q3、Q4, 见图10。由前文可知, 最佳本体象元组合方案依次为条幅式、I形式、描边式、稳定式、三幅式、外扩式, 由于初始形态 Q 本身已具备辐条式、I形式和稳定式等三个本体象元的特征, 因此在形态创新过程中只需要满足描边式、三幅式和外扩式的本体象元特征。根据前文提到的形状文法推演



图9 喻体象元空间  
Fig.9 Metaphor pixel space

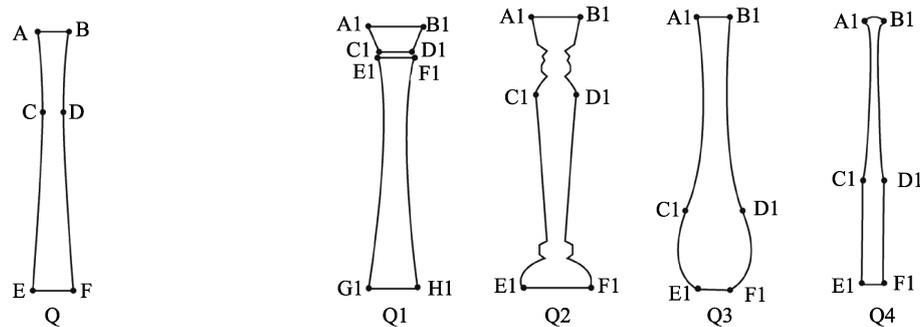


图10 辐条本体-辐条喻体轮廓控制点  
Fig.10 Ontology of spoke-control points of spoke contour

规则, 将推演规则分别表示为: R1=置换, R2=增删, R3=旋转, R4=缩放, R5=平移, R6=错切, R7=复制, R8=拉伸, 然后依次对辐条本体象元轮廓 Q 与辐条喻体象元轮廓 Q1、Q2、Q3、Q4 进行形态创新设计。由于篇幅有限, 此处只展示辐条本体象元 Q 与辐条喻体象元 Q1 之间的演变过程, 其具体流程如下: 将 Q1 执行形状文法规则, 首先执行置换规则, 将本体象元置换成为喻体象元; 其次为体现描边象元, 将生成的新

图形执行复制和向内缩放规则; 再次为体现外扩象元, 将图形连续执行复制和向外缩放规则; 最后为了体现三幅象元, 将得到的图形连续执行 6 次复制和旋转规则, 从而得到最终的轮辐图形, 见图 11。同理可以得到其余 3 个的轮廓形态创新设计方案。

将推演产生的新形态导入 Rhino6.0 软件进行三维模型构建, 并将建好的模型导入 KEYSHT10.0 软件进行渲染, 得到最终档案 3D 效果, 见图 12。

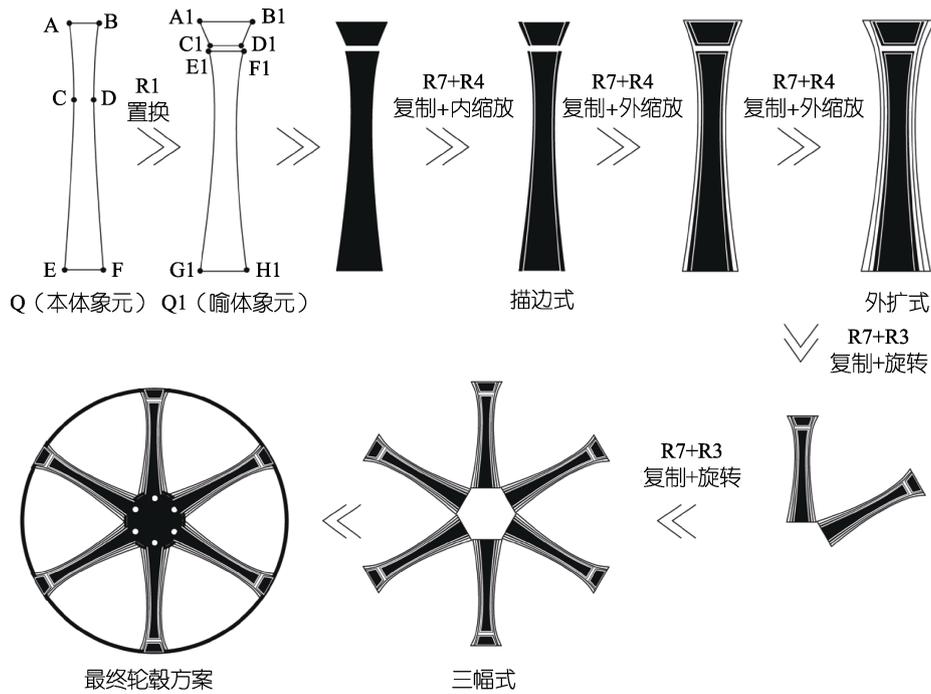


图 11 轮辐创新推演过程  
Fig.11 Innovation deduction process of wheel spoke



图 12 最终方案效果  
Fig.12 Rendering of the final scheme

### 4.3 评价与验证

为验证上述设计方法的有效性, 采用 7 级李克特量表, 要求前文的 8 位被测人员在浏览 4 个设计方案后进行评价。并将评价值通过公式 (5) — (8) 进行

三角模糊转化后得到用户模糊偏好值, 然后分别将其与 BP 神经网络中对应的预测值和样本库中辐条相似且排名前 3 的样本的用户模糊偏好值进行对比, 见表 8。由表 8

表8 评价结果对比表  
Tab.8 Comparison of evaluation results

序号	评价结果对比								评价值
	用户1	用户2	用户3	用户4	用户5	用户6	用户7	用户8	
样本 104	5	5	2	5	5	5	4	6	0.659
样本 162	6	5	2	4	5	5	4	5	0.634
样本 130	6	5	1	4	3	4	5	5	0.561
方案 1	7	6	4	6	7	6	5	7	0.870
方案 2	7	5	5	4	4	6	4	6	0.753
方案 3	7	5	5	4	4	6	4	6	0.852
方案 4	5	5	3	6	6	4	4	6	0.692
方案预测值									0.792

数据可知, 4 个设计方案的用户模糊偏好值均高于 3 个样本用户模糊偏好值, 计算上述 4 个设计方案与预测值的均方误差, 得到 MSE 为 0.005 3, 表示上述设计方案的用户偏好值与预测值基本一致, 实现了满足用户偏好的前提, 且设计方案形态多样, 实现了产品形态创新性, 表明了上述设计方法的可行性。

## 5 结语

为实现在满足用户偏好的前提下的产品形态创新设计, 本文提出一种基于神经网络和象元理论的轮毂形态设计方法。首先通过对样本的收集、筛选与评价, 计算得到用户模糊偏好值, 并利用象元理论中的本体象元对汽车轮毂特征进行模块化拆解归类, 建立了轮毂本体象元空间; 然后运用 BP 神经网络建立了轮毂本体象元组合编码与用户模糊偏好值的映射模型, 通过该模型成功预测和输出用户模糊偏好值最佳的本体象元组合方案; 最后在该方案基础上构建喻体象元空间, 并利用形状文法对该方案进行形态创新推演, 得出多个新方案。评价结果显示新方案的用户偏好值良好, 表明方法能够有效输出满足用户偏好前提下的形态创新设计方案。然而尽管本文中 BP 网络精度 MSE 值为 0.005 5, 但仍存在整体数据中部分的预测值与实际值的离散度过大的问题。因此, 在下一步研究中有待进一步优化, 以便更全面地为设计人员提供理论参考。

## 参考文献:

- [1] 苏建宁, 康亚君, 张书涛, 等. 面向认知主体的产品意象造型创新设计方法[J]. 现代制造工程, 2018(6): 108-113.  
SU Jian-ning, KANG Ya-jun, ZHANG Shu-tao, et al. Innovative Design Method of Product Image Styling Oriented to Cognitive Subject[J]. Modern Manufacturing Engineering, 2018(6): 108-113.
- [2] 苏建宁, 陈肖, 张书涛, 等. 基于进化算法的产品造型创新设计方法研究[J]. 工程设计学报, 2016, 23(2): 136-142.  
SU Jian-ning, CHEN Xiao, ZHANG Shu-tao, et al. Product Styling Innovative Design Method Based on Evolutionary Algorithm[J]. Chinese Journal of Engineering Design, 2016, 23(2): 136-142.
- [3] 程永胜, 徐骁琪, 陈国强, 等. 基于神经网络的电动汽车造型意象预测模型[J]. 计算机集成制造系统, 2021, 27(4): 1135-1145.  
CHENG Yong-sheng, XU Xiao-qi, CHEN Guo-qiang, et al. Image Prediction Model of Electric Vehicle Based on Neural Network[J]. Computer Integrated Manufacturing Systems, 2021, 27(4): 1135-1145.
- [4] 尹磊, 黄黎清, 李明珠. 基于人工神经网络的电动汽车前大灯意象造型设计研究[J]. 包装工程, 2021, 42(20): 159-166.  
YIN Lei, HUANG Li-qing, LI Ming-zhu. Image Modeling Design of Electric Vehicle Headlight Based on Artificial Neural Network[J]. Packaging Engineering, 2021, 42(20): 159-166.
- [5] 陈世斌, 杨双建, 朱蕾, 等. 基于 BP 神经网络的轿车造型意象设计与量化预测模型建立[J]. 包装工程, 2019, 40(16): 128-133.  
CHEN Shi-bin, YANG Shuang-jian, ZHU Lei, et al. Design and Quantification of Cars Modeling Imagery Based on BP Neural Network[J]. Packaging Engineering, 2019, 40(16): 128-133.
- [6] 杨冬梅, 李竹一, 张健楠, 等. 基于 PSO-BP 神经网络的工业装备造型设计研究[J]. 机械设计, 2021, 38(7): 126-132.  
YANG Dong-mei, LI Zhu-yi, ZHANG Jian-nan, et al. Research on Modeling Design of Industrial Equipment Based on PSO-BP Neural Network[J]. Journal of Machine Design, 2021, 38(7): 126-132.
- [7] 王欢欢, 初胜男, 顾经纬. 基于神经网络的汽车侧面造型评价方法[J]. 图学学报, 2021, 42(4): 688-695.  
WANG Huan-huan, CHU Sheng-nan, GU Jing-wei. Evaluation Method of Vehicle Side Modeling Based on Neural Network[J]. Journal of Graphics, 2021, 42(4): 688-695.

- [8] 侯宇康, 吕健, 刘翔, 等. 基于神经风格迁移网络的民族图案创新方法[J]. 图学学报, 2020, 41(4): 606-613.  
HOU Yu-kang, LV Jian, LIU Xiang, et al. Innovative Method of Ethnic Pattern Based on Neural Style Transfer Network[J]. Journal of Graphics, 2020, 41(4): 606-613.
- [9] 吴俭涛, 袁放, 孙利. 基于象元运算的轮毂形态设计方法研究[J]. 包装工程, 2018, 39(24): 163-171.  
WU Jian-tao, YUAN Fang, SUN Li. Method of Wheel Form Design Based on Operation of Meta Symbol[J]. Packaging Engineering, 2018, 39(24): 163-171.
- [10] 丁满, 李紫君, 裴卉宁, 等. 可适应布局形式变化的产品色彩设计研究[J]. 包装工程, 2021, 42(16): 103-112.  
DING Man, LI Zi-jun, PEI Hui-ning, et al. Product Color Design Adapting to the Change of Layout Form[J]. Packaging Engineering, 2021, 42(16): 103-112.
- [11] 吴俭涛. 基于象元的形态设计方法及其应用研究[D]. 秦皇岛: 燕山大学, 2016.  
WU Jian-tao. Morphological Design Method Based on Pixel and Its Application[D]. Qinhuangdao: Yanshan University, 2016.
- [12] 高倩. 基于意象关联的轮毂造型个性化定制设计[D]. 秦皇岛: 燕山大学, 2019.  
GAO Qian. Personalized Customized Design of Wheel Hub Modeling Based on Image Correlation[D]. Qinhuangdao: Yanshan University, 2019.
- [13] 刘芮葭, 章辉, 李旭杰. 基于模糊偏好与期望相似性的产品设计方案优选研究[J]. 制造业自动化, 2021, 43(8): 32-38.  
LIU Rui-jia, ZHANG Hui, LI Xu-jie. Research on Product Design Scheme Optimization Based on Fuzzy Preference and Expectation Similarity[J]. Manufacturing Automation, 2021, 43(8): 32-38.
- [14] 冯青, 吴婧璇, 田禹, 等. 基于形状文法的食用瓷器形态设计与研究[J]. 中国陶瓷, 2019, 55(4): 77-82.  
FENG Qing, WU Jing-xuan, TIAN Yu, et al. Research for Form Design of Diet Porcelain Based on Shape Grammar[J]. China Ceramics, 2019, 55(4): 77-82.
- [15] 李阳, 许占民. 产品造型创新设计的文法化推演研究[J]. 机械设计, 2017, 34(6): 124-128.  
LI Yang, XU Zhan-min. Research on Grammar Deductive of Product Form Innovation Design[J]. Journal of Machine Design, 2017, 34(6): 124-128.
- [16] 孙志学, 杜鹤民. 基于形状文法的多因素驱动应急通信车造型设计[J]. 机械设计, 2014, 31(10): 97-101.  
SUN Zhi-xue, DU He-min. Modeling Design of Emergency Communication Vehicle Based on Multiple Factors Driven Shape Grammar[J]. Journal of Machine Design, 2014, 31(10): 97-101.
- [17] 荣歆, 董石羽, 肖江浩. 基于形状文法与地域文化的地铁车辆外观造型设计[J]. 包装工程, 2020, 41(16): 230-235.  
RONG Xin, DONG Shi-yu, XIAO Jiang-hao. Metro Exterior Design Based on Shape Grammar & Regional Culture[J]. Packaging Engineering, 2020, 41(16): 230-235.
- [18] 袁放. 五辐轮毂的象元库构建与应用研究[D]. 秦皇岛: 燕山大学, 2018.  
YUAN Fang. Study on the Construction and Application of Pixel Library of Five-Spoke Hub[D]. Qinhuangdao: Yanshan University, 2018.
- [19] 廖勇. 基于三角模糊数的铁路客运站选址方案评价方法[J]. 中国铁道科学, 2009, 30(6): 119-125.  
LIAO Yong. Evaluation Method for the Location Selection of Railway Passenger Station Based on Triangular Fuzzy Number[J]. China Railway Science, 2009, 30(6): 119-125.

责任编辑: 陈作