

文章编号: 2095-2163(2024)03-0192-07

中图分类号: TP391

文献标志码: A

基于残差网络的汽车前脸情感化图像分类模型

刘保旗, 林 丽

(贵州大学 机械工程学院, 贵阳 550025)

摘要: 深度学习技术的发展为设计提供了新的方法。本文以汽车前脸作为研究载体,利用深度学习算法构建了情感化图像分类模型,来拟合人类对产品外观的情感认知。首先,经数据采集获取了大规模、高质量的汽车前脸图像数据集,经筛选和预处理获取了代表性样本数据集;其次,选取2个维度的情感标签,经专家评价法对数据集进行情感标注,获得了情感分类数据集;最后,利用 ResNet 构建了汽车前脸情感分类模型,并对比了不同深度的模型性能,获得了较优的汽车前脸情感化图像分类模型。实验证明,将图像分类模型应用至情感化分类,可有效拟合人类对产品的情感认知,为结合深度学习技术的产品情感化设计提供了可行性实践。通过情感图像分类模型的构建,可有效预测消费者对设计方案的情感化市场反应,进而提升研发效率以及面向市场的销售成功率。

关键词: 深度学习; 图像分类; 情感认知; 汽车前脸; 残差网络

Emotional image classification model of the car front face based on residual networks

LIU Baoqi, LIN Li

(School of Mechanical Engineering, Guizhou University, Guiyang 550025, China)

Abstract: The development of deep learning technology provides new methods for design. This article takes the front face of a car as the research carrier, uses deep learning algorithms to construct an emotional image classification model to fit the emotional cognition of humans to the appearance of the product. Firstly, a large-scale and high-quality car front face image dataset is obtained through data collection, and representative sample datasets are selected after screening and preprocessing. Secondly, two-dimensional emotional labels are selected, and the dataset is emotionally annotated through expert evaluation, resulting in an emotional classification dataset. Finally, using ResNet, a car front face emotional classification model is constructed, and the performance of models of different depth is compared, obtaining an optimal emotional image classification model for car front faces. The experiment proves that applying the image classification model to emotional classification can effectively fit the emotional cognition of humans to the product and provide a feasible practice for product emotional design combined with deep learning technology. By constructing an emotional image classification model, consumers' emotional market response to the design scheme can be effectively predicted, thereby improving research and development efficiency and sales success rate.

Key words: deep learning; image classification; emotional cognition; car front face; residual networks

0 引言

随着深度学习技术的不断发展,为汽车设计带来了新的启示。通过与计算机技术的结合,可以将极具主观属性的产品外观设计过程进行客观化图像分类模型构建,推动数据驱动的设计研发,降低设计师经验的主观依赖性,从而提高设计研发效率和标准化开发流程。

情感化是产品设计中重要设计原则。美国人类工效学家 Alphonse^[4]在 20 世纪中期提出了“人机工程”的概念,强调设计应该考虑人的认知、生理和心理特征。长町三生教授在 1995 年提出并总结了感性工学理论的概念^[2-5],将人的感性认知、情感和行为纳入到产品设计过程中,并提出了一套基于人的感性体验的设计方法和理论体系。在此基础上,感性工学理论逐渐发展起来,成为现代产品设计领域

基金项目: 国家自然科学基金(51865003); 贵州省科技厅项目(黔科合平台人才[2018]5781); 贵州省科技计划项目(黔科合基础-ZK[2021]重点 055); 贵州大学培育项目(贵大培育[2019]06)。

作者简介: 刘保旗(1997-),男,硕士研究生,主要研究方向:深度学习、感性工学。

通讯作者: 林 丽(1973-),女,博士,教授,博士生导师,主要研究方向:人机工程学、感性工学、计算机应用。Email:linlisongbai@163.com

收稿日期: 2023-04-19

中不可或缺的一部分^[6]。

汽车前脸是汽车品牌形象、产品个性、产品定位等方面的重要体现^[7],更是消费者购车决策的重要因素之一^[8]。传统的汽车设计方法主要依赖于设计师的个人经验和审美能力,这种方式存在着主观性强、效率低下、易受制于个人因素等诸多问题^[9]。利用深度学习算法,可以从海量的汽车图片数据中学习图片特征^[10],并挖掘出消费者对汽车前脸的情感认知行为,从而指导汽车前脸情感化设计。

深度学习是人工智能领域中的热门技术,近年来在各学科中均得到了广泛应用。其中,卷积神经网络(Convolutional Neural Network, CNN)是一种重要的网络结构,可用于处理图像和视频等二维数据,具有良好的特征提取能力和分类准确率^[11]。CNN采用卷积操作和池化操作等特殊神经网络结构,在保留原始图像信息的同时,大幅降低了参数数量和计算复杂度,可有效提取更高级图像特征并实现更加准确的分类、识别等任务^[12]。目前,图像分类模型主要针对客观化的类别标签进行识别^[13],并且取得了很好的效果,而将客观属性的图像分类模型应用至主观属性的情感化标签识别是一种新颖的应用尝试。

因此,本文旨在通过深度学习图像分类技术实现产品设计的情感化识别,以汽车前脸作为产品载体,构建情感化图像分类模型来拟合人类情感认知,进而预测消费者对汽车前脸的情感认知。深度学习技术在产品情感化设计中的应用,可提高汽车前脸情感化设计研发效率,为标准化、智能化的设计流程提供前期基础,从而推进汽车设计行业的发展。

1 研究方法

研究方法主要分为3个步骤:

(1) 经过数据采集和预处理,构建汽车前脸图




图1 ResNet-34网络结构示意图

Fig. 1 Schematic diagram of ResNet-34 network structure

该网络结构由7部分组成。第一部分不包含残差块,主要是对输入图像进行卷积、正则化、激活函数和最大池化的计算;第二至第五部分都包含残差

块,并且利用专家评价法对数据集进行情感标注,构建汽车前脸情感化图像分类数据集;

(2) 基于深度残差网络(Residual Network, ResNet)构建情感化图像分类模型;

(3) 对比不同深度网络结构模型性能,获取最优模型,并探讨消费者对汽车前脸的情感认知程度。

1.1 图像分类原理

图像分类的原理是利用网络结构中的卷积层、池化层等操作来提取图像的特征,然后通过全连接层等操作将这些特征映射到相应的类别标签上^[14]。具体而言,卷积层通过使用一组可学习的卷积核来对输入图像进行卷积操作,从而提取图像的局部特征,如边缘、角点、纹理等。池化层则可以对卷积层的输出进行下采样操作,减小数据的维度和计算量,同时还可以增强模型对平移、旋转等变换的不变性。在特征提取后,可以通过全连接层等操作将这些特征映射到相应的类别标签上。在全连接层中,通常会使用 *softmax* 函数将各类别的得分映射到概率分布上,然后根据概率分布进行分类决策。CNN 通过特征提取来进行图像分类的原理就是基于卷积核的共享权重和局部连接性等特点,能够有效地提取图像的局部特征,并且可以自动学习到具有判别性的特征表示,从而实现更加准确的图像分类^[15]。

1.2 残差网络结构

深度的 CNN 可以提取更高级的图像特征^[16],由于汽车前脸具有较为复杂的造型拓扑特征,因此利用了更深层的 CNN 作为基础构建汽车前脸情感分类模型。而随着网络深度的增加,梯度消失问题越来越严重,网络优化越来越困难^[17]。ResNet 的残差块设计,一定程度上解决了梯度消失问题,在加深网络深度的同时也具备良好的泛化性能^[18]。因此,本文采用 ResNet 构建汽车前脸情感分类模型。以 ResNet-34 为例,其网络结构如图 1 所示。

块,残差部分不改变卷积块的输出维度。残差部分都有 2 层卷积,因此该网络共有 $1+2\times(3+4+6+3)=33$ 个卷积层,加上第七部分的全连接层共有 34 层,

ResNet-34 名称由此而来。池化层将第五部分最后一层卷积层输出转化为一个特征向量,最后由全连接层分类器对特征向量进行计算并输出类别概率。

其它深度的 ResNet 与图 1 类似。其中, ResNet-18 和 ResNet-34 使用基本残差块, ResNet-50、ResNet-101、ResNet-152 采用了瓶颈式残差块。ResNet-50 共有 48 个残差部分的卷积层、1 个 conv1 卷积层和 1 个全连接层; ResNet-101 残差部分共有 99 个卷积层、1 个 conv1 卷积层和 1 个全连接层。

2 数据采集与预处理

2.1 图像数据集构建

大规模的产品样本获取是构建深度学习模型的首要步骤,数据集质量将直接影响模型训练效果。目前,已公开了多个大规模汽车图像数据集,如: Stanford Car Dataset、Compcars Dataset 等,常用于目标检测和图像分割等计算机视觉领域。但现有数据集均包含大量无关的图像信息,且难以筛选纯净的汽车前脸图像。因此,本研究自建了大规模汽车前脸高质量图像数据集。

通过调研,国内多个热门的汽车资讯平台均推出了“VR 全景看车”模块,其中的图片素材往往具有更高的图像质量。因此,本文构建了自动化数据采集爬虫脚本,针对网站“VR 全景看车”中的汽车正视图进行了数据采集。该方式获取到的汽车前脸图像剔除了无关的杂乱信息,并且在角度、透视等方面也具有高度的一致性。利用该脚本共获取 14 825 张样本图像,并对大规模前脸样本进行去重化处理。由于受到产品族设计特征的影响,在相同品牌或相同车型的设计迭代中,汽车外观普遍具有较高的相似性,因此对大批量样本图像进行了去重处理。采用“Duplicate Cleaner 5”软件基于像素信息去判别图像的一致性,采用“相似匹配”的方式进行图像相似度检测,删除了相似度过高的冗余图像,最终获得了品牌、车型各异的 9 248 张汽车前脸图像样本。最后,对大批量汽车前脸样本图像进行数据预处理,以适应图像分类模型输入。采用 Photoshop 软件对样本图像进行了批处理,原始图像为 1 200×800 分辨率、四通道的透明图像,对图像进行了各方向透明像素的裁剪,将画布大小设置为 500×500 分辨率,并且添加了纯白色背景图层,去除透明通道。经过图像预处理,完整的汽车前脸图像以最大程度充斥在了画布中,并减少了模型在透明通道上的冗余计算,图像预处理过程如图 2 所示。



图 2 图像预处理过程

Fig. 2 Image preprocessing process

为保证实验样本具备代表性,同时减少被试情感标注的样本量压力,取图像数量前十的品牌作为前脸数据集,对样本进行了均衡化处理。对样本数量较多的品牌样本再次进行了手动筛选,去除了相似度较大的图像;对样本数量较少的品牌样本通过平移、翻转、镜像等方式进行了数据增强,使得品牌类别下的样本数量相对均衡。为避免色彩因素产生实验偏差,选取了白色、黑色、灰色、红色、蓝色等主流色彩,同样通过上述方式对样本进行了均衡化处理。筛选后的代表性汽车前脸数据集共有 5 000 张样本图像,样本示例如图 3 所示。



图 3 代表性数据集样本示例

Fig. 3 Example of representative dataset samples

2.2 情感标签标注

情感化词汇的选择需要具备足够的代表性和重要性,这些代表性词汇应该是消费者最关注的情感认知感受。同时,情感化词汇应当是通俗易懂的,使被试者可以迅速反应并且准确做出评价。基于此,本节将以“年轻-普通”和“耐看-普通”等2个维度的认知感受作为代表性情感词汇进行标注。

由于深度学习模型的图像特征识别是一种客观性的从特征值到目标值的逐渐拟合过程,对于主观性的情感分类是一项颇具挑战性的任务,因此建立一种稳定、相对客观的情感分类标准,是构建汽车前脸情感分类数据集的重要思想。专家评价法是一种常用的数据标注方法,通常用于对主观性较强、难以量化的数据进行标注和分析^[19]。该方法通过邀请多位领域专家对数据进行评估和打分,并且综合考量多位专家的综合意见,从而得到相对客观、可靠的标注结果。在汽车前脸情感分类数据集构建中,采用专家评价法可以有效地避免因个人主观差异导致的标注不准确或者偏差过大等问题,从而提高数据标注的准确性和可信度。

本节采用专家评价法对5000张代表性汽车前

脸图像数据集进行人工标注,并且将数据集以添加随机序号重命名的方式打乱图像顺序,避免相同品牌或型号的车型对被试产生认知疲劳误差。实验招募了5名具有3年以上经验的设计师和5名具有购车意愿的普通消费者,通过观察高清的汽车前脸样本图片,根据视觉认知反馈的强烈主观感受,分别在“年轻-普通”和“耐看-普通”等2个维度上进行情感标注。为提升前脸情感标注效率,使用了图像分类标注软件 Labelimg,被试可通过快捷键实现汽车前脸情感标注以及跳转下一张图片,大批量的样本情感分类通过此操作可大幅提升标注效率。

在对数据集进行情感标注的过程中,专家考虑了多种因素,其中包括图片造型、细节、颜色、整体感觉等。标注完成后,经过专家意见对标注结果进行了细致的调整,最终汽车前脸情感分类数据集分布相对均衡。在5000张图片中,“年轻”的结果是2051张,与“年轻”相对的“普通”的结果是2949张;“耐看”的结果是2266张,与“耐看”相对的“普通”的结果是2734张,从而获得汽车前脸情感分类数据集,情感分类样本示例如图4所示。



图4 情感分类数据集样本示例

Fig. 4 Example of emotional classification dataset samples

3 情感图像分类模型构建

以 ResNet-34 网络结构(图1)为例,在汽车前脸情感分类模型训练过程中,数据经过预处理依次经过了第一部分的卷积池化层、第二至五部分的残差卷积层、第六部分的平均池化层以及第七部分的全连接层等。在数据预处理过程中,为减少模型训练的计算成本和内存占用,提高模型的训练速度和性能,将 RGB 三通道的输入图像尺寸压缩至224×

224 分辨率,该尺寸同时保证了前脸图像具有一定的细节完整性;并采用了 ImageNet 数据集中的均值和标准差,避免训练过程中可能出现的梯度爆炸或梯度消失等问题,保证模型的稳定性和收敛性。在第一部分中,输入图像在 conv1 卷积层经过了第一次特征提取,输出 112×112×64(图像尺寸×通道数)的卷积特征图;接着传入批标准化(Batch Normalization, BN)层,使得输入数据分布更加稳定,并且加速模型收敛速度和提高模型精度;然后传

入 $ReLU$ 激活函数层,引入非线性变换,使模型更加灵活,能够学习到更加复杂的特征表示,增强模型表达能力;BN 层和 $ReLU$ 层均不改变特征图尺寸;接着传入最大池化层,对特征图进行下采样,减小特征图的尺寸和参数量,输出 $56 \times 56 \times 64$ 的特征图。然后传入残差卷积部分,得到特征图形状分别是 $56 \times 56 \times 64$ 、 $28 \times 28 \times 128$ 、 $14 \times 14 \times 256$ 、 $7 \times 7 \times 512$;接着传入平均池化层,对特征图进行下采样,对输入张量执行自

适应平均池化,将特征图尺寸压缩至 1×1 ,同时保留通道数;最后经过全连接层进行分类,将学习到的特征映射到预测的类标签。

ResNet-34 情感识别分类实现原理如图 5 所示。其中,为便于展示图 5 的特征图,均以单通道灰度图的形式展示,实际特征图应是不同于原图像的彩色图像。

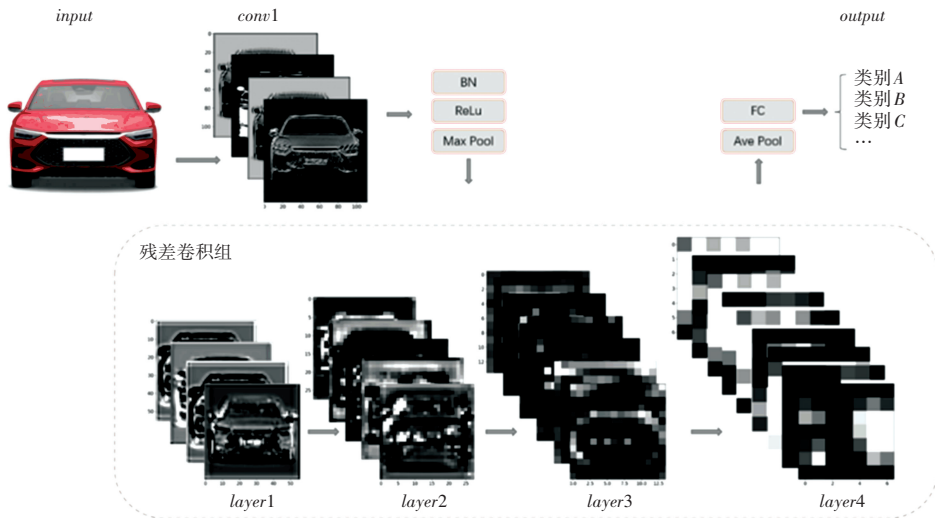


图 5 基于 ResNet-34 实现情感分类原理

Fig. 5 The principle of sentiment classification based on ResNet-34

对于不同深度的残差网络结构来说,特征提取及分类过程相同。ResNet-50 和 ResNet-101 卷积层特征图与 ResNet-34 特征图的分辨率一致,但通道数更多, $conv1$ 、 $layer1$ 、 $layer2$ 、 $layer3$ 、 $layer4$ 卷积层特征图尺寸分别是 $112 \times 112 \times 64$ 、 $56 \times 56 \times 256$ 、 $28 \times 28 \times 512$ 、 $14 \times 14 \times 1024$ 、 $7 \times 7 \times 2048$ 。

在模型训练过程中,损失函数采用了交叉熵损失函数(Cross-Entropy Loss),以测量预测类别概率和真实类别标签之间的差异。交叉熵损失函数是深度学习中常用的损失函数之一,常用于分类问题中。相比于均方误差(Mean Square Error, MSE) 损失函数,其优点在于,交叉熵损失函数对于错误分类的样本会产生更大的梯度值,因此可以更快地学习到正确的分类决策边界,从而避免了梯度消失问题^[20]。交叉熵损失函数计算过程见式(1):

$$\text{loss}(x, y) = -\frac{1}{N} \sum_{i=1}^N (y_i \log(x_i) + (1 - y_i) \log(1 - x_i)) \quad (1)$$

其中, x 为模型的输出结果; y 为真实标签; N 为样本数量。该损失函数用于计算每个样本的预测

值和真实值之间的交叉熵,并对所有样本的交叉熵求平均值作为最终的损失值。具体来说,对于每个样本,首先将模型的输出经过全连接层转化为一个概率分布,表示每个类别的概率值;然后,将该概率分布与真实标签进行比较,计算交叉熵,表示模型的输出结果与真实值之间的差异;最后,对所有样本的交叉熵求平均值作为最终的损失值。

在模型训练的反向传播过程中,优化器采用了随机梯度下降(Stochastic Gradient Descent, SGD) 优化算法,是通过迭代的方式来逐渐调整模型的参数,从而最小化损失函数。具体来说, SGD 在每次迭代中都需要计算当前参数关于损失函数的梯度,通过与学习率的乘积来确定下一步的更新方向和步长。由于每一次迭代所使用的样本都是随机选择的,因此被称为随机梯度下降^[21]。在 SGD 优化器中设置学习率为 $lr = 0.001$ 、动量参数 $momentum = 0.9$ 。其中,学习率控制每次更新权重时的步长大小,动量参数有助于加速收敛并减少震荡。 SGD 参数更新公式可写为:

$$\theta_{i+1} = \theta_i - \eta \nabla f_i(\theta_i) \quad (2)$$

其中, θ_t 表示当前的参数向量; η 表示学习率; $\nabla f_i(\theta_t)$ 表示损失函数关于当前参数 θ_t 的梯度。

此外, 还引入了动量参数 β 来加速收敛并减少震荡, 其更新方式具体如下:

$$\begin{cases} v_{t+1} = \beta v_t + (1 - \beta) \nabla f_i(\theta_t) \\ \theta_{t+1} = \theta_t - \eta v_{t+1} \end{cases} \quad (3)$$

其中, v_t 表示上一次迭代的动量向量。

4 情感图像分类模型验证

对网络结构及训练参数设置完毕后, 将汽车前脸情感分类数据集按照 7 : 2 : 1 的比例划分了训练集、验证集、测试集。其中, 训练集用于模型的训练;


验证集用于调整模型参数, 在模型训练过程中通过对验证集的评估调整到最佳的超参数组合, 以提高模型的泛化能力; 测试集用于评估模型的泛化能力。通过样本随机抽取的方式, 从已标注的汽车前脸情感分类数据集中获取相应比例的训练集、验证集和测试集。各数据集的样本数量统计见表 1。

为对比不同深度的网络模型在汽车前脸情感分类数据集上的模型性能, 分别采用 ResNet-34、ResNet-50、ResNet-101 等不同深度的网络模型, 对“年轻-普通”和“耐看-普通”等 2 个维度, 分别经过了 100 个 *epoch* 的模型训练, 2 个情感维度的训练损失变化及测试集的准确率分别如图 6 和图 7 所示。


表 1 情感分类模型的训练集、验证集、测试集样本统计

Table 1 Statistics of training, validation, and test samples for sentiment classification model

维度 1	训练集	验证集	测试集	总计	维度 2	训练集	验证集	测试集	总计
年轻	1 436	410	205	2 051	耐看	1 586	453	227	2 266
普通	2 064	590	295	2 949	普通	1 909	550	275	2 734




(a) 损失变化




(b) 测试集准确率

图 6 “年轻-普通”维度

Fig. 6 The "young-normal" dimension



(a) 损失变化



(b) 测试集准确率

图 7 “耐看-普通”维度

Fig. 7 The "durable-normal" dimension

由图6、图7可见,不同深度的网络模型在2个类别中的训练损失均表现出稳步下降,且在测试集上的准确率逐渐上升,证明各模型均得到了有效训练。其中,ResNet-34、ResNet-50和ResNet-101在测试集中的准确率并无显著性差异,且ResNet-34在2个情感维度的测试集准确率相对略高,识别准确率分别达到了95.0%和90.8%,其情感识别分类均达到了较高的准确率,并且具有很好的泛化能力。而更深的网络模型则意味着需要更多计算资源,参数量显著增加,模型训练周期更长。因此,选取ResNet-34作为最终的汽车前脸情感分类模型。

另外,各个深度的ResNet模型在“年轻-普通”和“耐看-普通”的测试集准确率普遍相差超过4%,从侧面反映了受试者对于“年轻”比“耐看”具备更明显的认知感受和更准确的隐性分类依据,这与情感标注时受试者的反馈是一致的,因此“年轻-普通”数据集的分类依据更为明显,模型识别准确率也更高。而这也是将深度学习模型应用到情感分类中必然面对的一个挑战,人类在情感标注时同样会受到主观性和对比性等因素影响,难免会产生暂时的情感差异性,这可能导致数据集的分类依据在客观性上表现不足,网络模型难以拟合先验信息,甚至产生过拟合。因此,在数据集标注中,情感词汇要具备明显的情感认知感受,尽量避免选取抽象、晦涩难懂词汇,使被试在主观性情感标注时有更确定的潜在客观性分类依据,才能使模型获得更有效学习,获得更强的鲁棒性和泛化能力。

5 结束语

本文以深度学习技术实现了情感化的产品设计初步应用。以汽车前脸为例,构建了情感分类图像识别模型,将客观属性的图像分类模型应用至情感识别中。本文研究中利用ResNet-34、ResNet-50和ResNet-101网络结构分别对汽车前脸情感分类数据集进行了模型训练,经过模型验证,3种不同深度的情感分类模型在测试集中的准确率并无显著性差异。其中,ResNet-34在测试集中的准确率最高,在“年轻-普通”和“耐看-普通”等2个情感维度上的准确率分别达到了95.0%和90.8%,可有效应用于汽车前脸情感化设计开发中的消费者情感认知预测,从而大幅提高汽车前脸情感化设计效率。此外,研究发现,在不同深度的模型中,“年轻-普通”维度上的准确率普遍高于“耐看-普通”的情感维度,从而也验证了“年轻-普通”在人类对汽车前脸情感认

知中具有更为明显的认知感受,该维度下的数据标注更为客观有效,“耐看-普通”的分类依据则相对模糊。

参考文献

- [1] 夏进军,周方舟,樊真成,等. 基于深度学习的汽车造型设计工具研究[J]. 包装工程,2021,42(18):42-49,6.
- [2] 王晨. 基于深度学习的汽车造型分析与评价[D]. 大连:大连理工大学,2020.
- [3] 戴佳. 基于消费者情感需求的产品个性化设计研究[D]. 上海:上海交通大学,2007.
- [4] ALPHONSE C. Man-machine engineering[M]. Belmont:Wadsworth Publishing Company, 1965.
- [5] NAGAMACHI M. Kansei engineering: A new ergonomic consumer-oriented technology for product development[J]. International Journal of Industrial Ergonomics, 1995, 15(1): 3-11.
- [6] 罗仕堂,潘云鹤. 产品设计中的感性意象理论、技术与应用研究进展[J]. 机械工程学报,2007,43(3):8-13.
- [7] 李少波,张慧,秦志远. 基于推论式感性工学的汽车前脸造型设计研究[J]. 包装工程,2017,38(18):82-86.
- [8] 焦合金. 基于脑电信号的汽车前脸造型特征设计决策[J]. 机械设计,2023,40(2):134-139.
- [9] 林丽,郭主恩,阳明庆. 面向产品感性意象的造型优化设计研究现状及趋势[J]. 包装工程,2020,41(2):65-79.
- [10] 殷瑞刚,魏帅,李晗,等. 深度学习中的无监督学习方法综述[J]. 计算机系统应用,2016,25(8):1-7.
- [11] SHARMA N, JAIN V, MISHRA A. An analysis of convolutional neural networks for image classification[J]. Procedia Computer Science, 2018, 132: 377-384.
- [12] MAYYA V, PAI R M, PAI M M M. Automatic facial expression recognition using DCNN[J]. Procedia Computer Science, 2016, 93: 453-461.
- [13] 周俊宇,赵艳明. 卷积神经网络在图像分类和目标检测应用综述[J]. 计算机工程与应用,2017,53(13):34-41.
- [14] AL-SAFFAR A A M, TAO H, TALAB M A. Review of deep convolution neural network in image classification[C]//2017 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET). Jakarta, Indonesia: IEEE, 2017: 26-31.
- [15] 李彦冬,郝宗波,雷航. 卷积神经网络研究综述[J]. 计算机应用,2016,36(9):2508-2515,2565.
- [16] 郑远攀,李广阳,李晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用,2019,55(12):20-36.
- [17] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报,2017,40(6):1229-1251.
- [18] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas:IEEE,2016: 770-778.
- [19] 杨默涵,汤建明,钱晓松. 决策支持系统交互界面设计中的视觉显著性评估研究[J]. 包装工程,2021,42(20):77-84.
- [20] 郝雅娴,孙艳蕊. 基于手写体数字识别的损失函数对比研究[J]. 电子技术与软件工程,2022(6):203-206.
- [21] 陈青,杨晶东,王晗,等. 一种有效神经网络训练优化方法[J]. 智能计算机与应用,2022,12(9):56-64.