

文章编号:1006-2467(2019)07-0844-08

DOI: 10.16183/j.cnki.jsjtu.2019.07.011

# 基于卷积神经网络的用户感知评估建模

颜波, 张磊, 褚学宁

(上海交通大学 机械与动力工程学院, 上海 200240)

**摘要:** 提出了一种基于卷积神经网络的用户感知评估建模方法,充分利用产品使用数据来定量地建立用户感知评估和产品性能参数之间的映射关系,以支持产品设计改进.首先,利用滑动窗口技术将时间序列形式的使用数据转换为一系列数据单元,并在此基础上建立适用于用户感知评估模型的卷积神经网络结构;然后,通过 $K$ -折交叉验证分析确定模型的最优超参数并改善模型的过拟合问题;最后,以智能手机用户感知建模为例验证了方法的有效性.结果表明,所提出的方法能够自动从使用数据中提取出有效特征,用于用户感知评估预测,减少了建模过程中对用户和设计师的依赖,可以帮助设计师及时准确地评估产品表现,为产品设计改进提供决策支持.

**关键词:** 产品设计; 用户感知; 使用数据; 卷积神经网络; 特征提取

**中图分类号:** TB 472

**文献标志码:** A

## User Experience Evaluation Modeling Based on Convolutional Neural Network

YAN Bo, ZHANG Lei, CHU Xuening

(School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

**Abstract:** In order to transform the usage data into appropriate information that can improve the products through design modification, a method based on convolution neural network is proposed for user experience evaluation modeling, which can make full use of the usage data to establish the mapping relationship between the user information and the product engineering requirements. Firstly, the time-series usage data was converted into a series of data units by sliding window technique, and a convolution neural network architecture suitable for user experience evaluation model was established. Then, the optimal hyper parameters was selected and the over fitting problem of the model was improved by  $K$ -fold cross validation analysis. Finally, the validity of the proposed method was demonstrated by a case study of smart phone user experience evaluation modeling. The results indicated that the proposed method can automatically extract effective features from raw usage data, which can used for user experience evaluation prediction. Thus, the proposed method can decrease the dependence of the users and designers when modeling, which can help designers to assess the product performance in real time and accurately and provide support information for design decisions through usage data.

**Key words:** product design; user experience; usage data; convolutional neural network; feature extracting

收稿日期:2018-02-28

基金项目:国家自然科学基金资助项目(51875345,51475290,51075261)

作者简介:颜波(1993-),男,云南省保山市人,硕士生,主要研究方向为智能化与数字化设计.

通信作者:褚学宁,男,教授,博士生导师;E-mail: xnchu@sjtu.edu.cn.

用户感知是用户在使用产品过程中产生的特有体验,对产品设计改进有着重要的指导作用<sup>[1]</sup>. 目前设计师主要通过调查问卷<sup>[2]</sup>和在线评论挖掘<sup>[3]</sup>的方式收集用户感知信息,来建立用户感知评估模型. Bordagaray 等<sup>[4]</sup>使用 Probit 回归对公共交通的服务质量建模,探索影响公共交通过户感知质量的重要因素. Chen 等<sup>[5]</sup>利用 Logistic 回归分析了国际快递服务要素与用户感知之间的关系,为国际快递服务的设计提供了新的思路. 倪敏娜等<sup>[6]</sup>利用 BP (Back Propagation)神经网络定量地研究了感性意象与产品造型设计之间的关系,从而更全面准确地评价产品造型设计. Zhou 等<sup>[7]</sup>从在线产品评论中提取产品属性,利用支持向量机建立情感预测模型,进一步识别出用户需求.

上述方法存在以下主要问题:第一,问卷调查或在线评论分析方法获取的用户感知信息具有滞后性;第二,问卷设计可能受到设计师主观偏见的影响. 近年来,物联网技术的发展极大地促进了智能设备的普及,越来越多的产品在使用过程中的数据可以被监控和采集,通过使用数据来建立用户感知评估模型,不仅可以及时获取用户在使用产品过程中感知的变化,还可以分析出影响用户感知的产品具体性能参数,为产品设计改进提供决策支持.

为此,本文将产品使用数据引入到用户感知评

估模型中,提出了一种基于卷积神经网络(Convolutional Neural Network, CNN)<sup>[8]</sup>的用户感知评估建模方法. 该方法利用滑动窗口技术将时间序列形式的使用数据转换为一系列数据单元,并在此基础上建立适用于用户感知评估模型的 CNN 结构,模型输入为产品使用数据,输出为用户感知评估结果,通过 K-折交叉验证分析确定模型的最优超参数并改善模型的过拟合问题. 模型训练完成后,通过使用数据即可预测用户在使用产品过程中感知评估的变化. 以智能手机用户的感知评估建模为例,证明了该方法能够自动从使用数据中提取出有效特征,用于用户感知评估预测,减少了建模过程对用户和设计师的依赖,能够准确及时地评估产品表现.

1 卷积神经网络的结构和特点

卷积神经网络作为深度学习的代表模型,起源于计算机视觉和图像分类领域,能够有效地实现图片特征的自动提取和分类,而传统的机器学习算法依赖人工提取和选择特征,研究人员须具备相关领域的专业知识才能取得令人满意的结果. CNN 主要包括 3 个处理单元,卷积层、池化层和全连接层,如图 1 所示. 通过卷积层和池化层交替级联, CNN 可以根据具体任务直接提取出原始数据的深层特征表示.




图 1 典型的卷积神经网络结构图

Fig. 1 A typical architecture for convolution neural network

在卷积层中,卷积核通过遍历输入数据的不同区域来提取特征,卷积核的权重在同一层的所有区域内共享,因此一个卷积核只能提取一种特征,实际中需要使用多个卷积核来提取不同的特征. 卷积运算的输出通过激活函数形成特征图,特征图的数目和卷积核的数目相等. 对于一个给定的卷积层,假定存在  $M$  个特征图,记为  $c^m (m = 1, 2, \dots, M)$ ,每个特征图上神经元的数量为  $a (a = 1, 2, \dots, A)$ ,卷积核由权重  $w^m$  和偏置  $b^m$  确定,则每个神经元上的特征  $c_a^m$  计算公式为

$$c_a^m = f(\sum_{i \in R_a} (w_i^m x_i) + b^m) \tag{1}$$

式中:  $R_a$  表示神经元  $a$  对应的局部感受野,即卷积

核在输入数据上选定的特定区域;  $x_i$  表示输入数据的具体取值;  $f(\cdot)$  为激活函数.

在池化层中,特征图的数目不变但是分辨率降低,池化操作不仅减少了特征的维数,同时也增加了网络对输入数据存在的失真、扭曲、缩放和平移等问题的鲁棒性. 池化核遍历卷积层特征图的不同区域,根据池化函数从窗口区域中选择一个值来表示该窗口的特征,然后将多个窗口的特征组合得到降维后池化层的特征图. 池化后的特征图

$$p^m = f(\beta^m \text{pool}(c^m) + b^m), \tag{2}$$

式中:  $\beta^m$  为权重系数;  $\text{pool}(\cdot)$  为池化函数,常见的池化函数有平均池化、最大池化和随机池化等.

池化层的特征图作为全连接层或者下一个卷积层的输入. 最后, 全连接层一般通过 SoftMax 回归得到分类结果. 典型的 CNN 是一个由卷积层、池化层、全连接层和 SoftMax 回归层组成的前馈神经网络, 网络误差通过 BP 算法<sup>[9]</sup>反向传播, 根据梯度下降算法不断调节网络连接权重实现误差最小化, 从而使卷积层和池化层可以学习到输入数据的最优特征表示.

2 基于 CNN 的用户感知评估建模

2.1 建模过程

利用有监督的机器学习方法构建用户感知评估模型, 模型输入为产品使用数据, 输出为用户感知评估结果, 以此建立产品性能参数与用户感知之间的映射关系. 该模型的构建主要分为两个阶段: 一为模型训练阶段, 输入为产品使用数据, 输出为基于问卷评估的用户感知, 用于确定模型参数; 二为模型预测阶段, 此时模型参数已经确定, 只需输入产品使用数据, 即可根据模型推断出用户的感知评估结果. 在第 1 节中展示的 CNN 结构适用于静态图像识别和分类, 但使用数据是时间序列数据, 同时在进行用户感知预测时可能存在多种信号源数据, 因此本文基于滑动窗口技术提出了一种适用于用户感知评估模型的 CNN 结构.

本文利用滑动窗口技术将时间序列形式的使用数据划分为一系列数据单元进行研究. 假定存在  $s$  种信号源, 数据长度为  $l$ , 则使用数据为  $\{(x_1^1,$

$x_1^2, \dots, x_1^s; y_1), (x_2^1, x_2^2, \dots, x_2^s; y_2), \dots, (x_l^1, x_l^2, \dots, x_l^s; y_l)\}$ , 其中  $x_t^s$  表示  $t$  时刻信号源  $s$  的取值,  $y_t$  表示  $t$  时刻的用户感知评估. 窗口宽度固定为  $w_s$ , 移动步长为  $m_s$ , 通过滑动窗口技术可以将使用数据转化为  $c$  个数据单元, 每个数据单元用户感知评估的真实标签由  $w_s$  个原始数据中出现次数最多的标签决定, 相应的计算公式如下:

$$c = \left\lfloor \frac{(l - w_s)}{m_s} \right\rfloor + 1 \tag{3}$$

$$y_i = \text{mode}(\{y_{i1}, y_{i2}, \dots, y_{iws}\}), \tag{4}$$
$$i = 1, 2, \dots, c$$

式中:  $\lfloor \cdot \rfloor$  表示向下取整;  $\text{mode}(\cdot)$  函数表示求解给定数据集的众数.

将经过滑动窗口处理后的数据输入特征提取层, 特征提取通过卷积层和池化层交替级联实现, 卷积和池化操作在数据单元上进行, 最后将从多种信号源学习到的特征组合起来作为全连接层的输入, 经过 SoftMax 回归后得到用户感知评估的预测结果, 整个计算过程如图 2 所示. 对用户的不同感知评估建模时, 比如舒适性、可用性和易用性感知等, CNN 的基本结构, 包括卷积层、池化层和全连接层基本都是相同的, 并且不需要针对每个具体任务人工提取数据特征, 使用数据采集和用户感知评估预测都可以自动实现, 从而减少了建模过程中对用户和设计师的依赖, 因此所提出的方法相比于传统的用户感知建模方法更有优势.

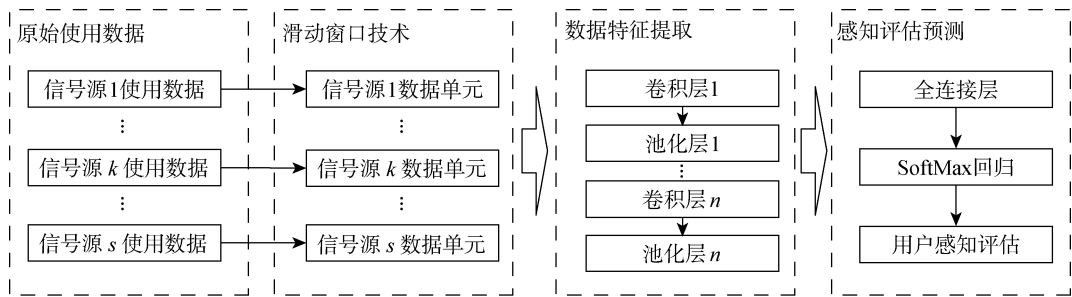


图 2 基于 CNN 的用户感知评估建模过程

Fig. 2 The procedure of user experience evaluation modeling based on CNN

2.2 用户感知评估 CNN 模型的训练过程

在机器学习领域, 超参数是指在模型开始训练之前就需要给定取值的参数, 而不是通过训练得到取值的参数, 通常情况下需要根据具体任务对超参数取值进行优化, 选择一组最优超参数取值以提高模型性能, 因此超参数取值优化问题也是机器学习领域的一个热门研究课题<sup>[10]</sup>. CNN 模型中的超参数包括卷积层和池化层的数量、卷积核和池化核的

数量及大小、全连接层中隐含层的层数和神经元个数、优化算法中学习率的大小等. 本文通过  $K$ -折交叉验证分析确定最优超参数取值并改善模型的过拟合问题, 计算流程如图 3 所示. 输入数据首先被随机分成 3 个数据集, 训练集、验证集和测试集. 然后把训练集和验证集合并为一个数据集进行  $K$ -折交叉验证分析,  $K$ -折交叉验证分析将数据分为  $K$  个子样本, 每次取 1 个样本作为验证集, 余下的  $K-1$  个样

本作为训练集,训练完成后测试模型在验证集上的性能,重复  $K$  次,取  $K$  次性能指标的平均值作为该超参数取值下模型的性能,据此测试超参数取不同值时模型的性能,最终确定最优超参数取值并得到最佳模型.  $K$ -折交叉验证分析时,模型从未使用与测试集相关的任何信息,因此最终模型在测试集的表现更能反映其真实性能,同时,最终选择的是在验证集而不是在训练集上具有最佳性能的模型,模型的过拟合问题也可以得到改善.

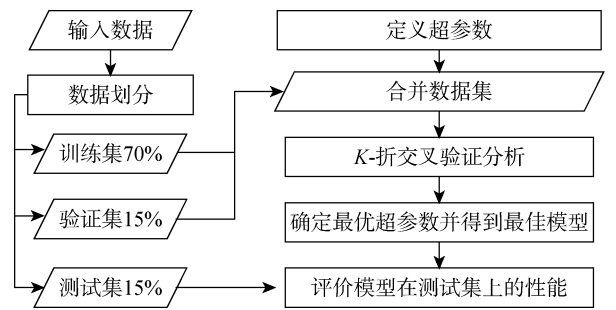


图 3 CNN 模型的训练和超参数选择过程

Fig. 3 The procedure of CNN model training and hyper parameter selecting

在利用 CNN 进行特征学习时,不同数量的特征学习层可以学习到输入数据不同层次的特征,但是随着特征学习层数的增加,计算难度和成本也在增加,同时当使用基于梯度下降和链式求导法则的算法训练多层神经网络时很可能发生梯度消失问题.为了解决这一问题,本文使用修正线性单元(Rectified Linear Unit,ReLU)作为激活函数,相比于传统的 Sigmoid 和 Tanh 函数,ReLU 函数具有梯度不饱和和计算速度快等优点,不仅改善了梯度消失问题也极大地加快了模型的收敛速度. ReLU 函数的表达式为

$$f(x_{in}) = \begin{cases} x_{in}, & x_{in} \geq 0 \\ 0, & x_{in} < 0 \end{cases} \quad (5)$$

式中: $x_{in}$ 表示激活函数的输入.

卷积层和池化层交替级联进行特征提取,将提取到的特征组合起来输入全连接层和 SoftMax 回归层,最后得到模型的输出.根据模型输出与期望输出计算总的误差,其中损失函数选择交叉熵损失函数,即

$$L_y(\hat{y}) = - \sum_i y_i \lg \hat{y}_i$$

式中: $y$ 表示实际的分布; $\hat{y}$ 表示预测的概率分布.对于分类学习任务,交叉熵损失函数可以衡量分布  $y$  与  $\hat{y}$  的相似性,即可以使得模型输出的分布尽量与训练样本的分布一致,同时选择交叉熵作为损失

函数能有效改善模型训练过程中的梯度消失问题.

模型误差通过 BP 算法反向传播,然后使用梯度下降算法训练网络从而实现误差最小化.随机梯度下降算法<sup>[11]</sup>是常用的梯度下降算法,但其存在学习率设置困难和容易陷入局部最优解等缺点,因此本文采用梯度下降优化算法来训练网络权重,常见的梯度下降优化算法有 NAG 算法(Nesterov Accelerated Gradient)<sup>[12]</sup>、Adam 算法(Adaptive Moment Estimation)<sup>[13]</sup>、AdaGrad 算法(Adaptive Subgradient Descent)<sup>[14]</sup>等,它们不仅能够训练复杂网络,并且在速度和精度上也具有优异表现.

2.3 用户感知评估 CNN 模型的性能评价

用户感知评估 CNN 模型是一个多分类模型,为了定量地评价模型的性能,利用训练好的模型在测试集上进行实验,得到实验结果的混淆矩阵,如表 1 所示.混淆矩阵显示了正确分类和错误分类的样本数,利用混淆矩阵可以进一步计算出模型的准确率、召回率和精确率等.

表 1 模型性能评价的混淆矩阵

Tab. 1 The confusion matrix for performance evaluation

真实值	预测值	
	0	1
0	$a$	$b$
1	$c$	$d$

对于给定的测试数据集,准确率  $A$  表示分类器正确分类的样本数与总样本数之比,召回率  $R$  表示正确预测到的正例数与实际正例总数之比,精确率  $P$  表示正确预测到的正例数与预测正例总数之比.  $A, P, R$  越接近于 1 表示模型的性能越好,计算公式如下:

$$A = \frac{a + d}{a + b + c + d} \quad (7)$$

$$R = \frac{d}{c + d} \quad (8)$$

$$P = \frac{d}{b + d} \quad (9)$$

3 案例研究

智能手机发展迅速,作为最具代表性的人机交互式产品,不仅更加重视用户的使用体验和感知,而且具有用户覆盖面广、更新换代速度快、使用数据易于收集等特点.根据技术接受模型(Technology Acceptance Model,TAM)<sup>[15]</sup>以及工程师和设计师的经验,用户在使用手机的过程中会产生诸如设计和品牌吸引力、对流畅性的感知、对续航的感知、对

功能的感知等多种感知,其中手机流畅性是影响用户体验的重要因素,因此本文以手机流畅性感知评估建模为例来证明所提出方法的有效性.

3.1 实验方案和数据采集

本文基于 Android 平台开发了一款数据采集软件 YouData,采集用户在使用手机过程中产生的数据. YouData 软件完全在 Eclipse 平台下开发, Eclipse 是一个开源的基于 Java 语言的可扩展集成开

发环境,除了对 Android 系统 SDK (Software Development Kit)完美支持外,还提供了强大的个人版本管理机制,是从事手机软件开发程序员的首选开发工具. YouData 监听手机使用数据并定期将其记录到日志文件中,日志文件将被保存到手机内部存储中. 为了避免干扰用户正常使用, YouData 主要在后台运行,并配置一个简单的用户界面,如图 4 所示.

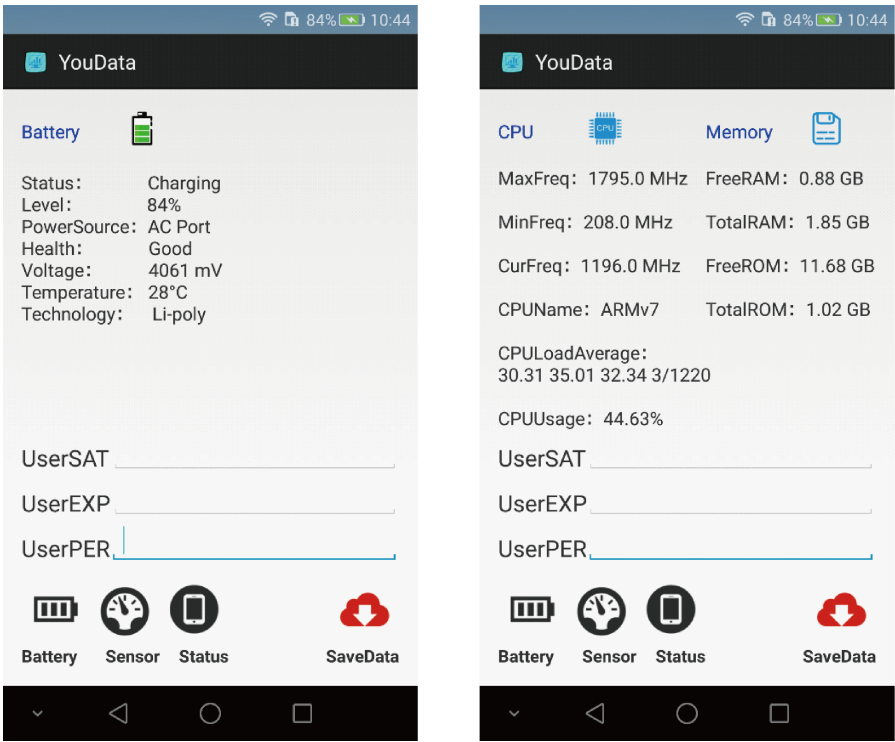


图 4 数据采集软件 YouData 界面  
Fig. 4 The interface of data acquisition application YouData

在这项研究中,每位用户使用手机来完成指定的日常任务,采集的数据主要包括 CPU (Central Processing Unit) 使用率、RAM (Random Access Memory) 占用率、ROM (Read Only Memory) 占用率、网络传输速率、电池温度和日耗电量等,采集频率为 0.5 Hz. 同时,每位用户在数据采集结束后都会被要求在手机上填写一份关于流畅性感知评估的调查问卷,调查问卷使用问卷星平台完成,问卷选项采用 Likert 5 级量表的形式,选项 1 至 5 分别代表了“非常不流畅”至“非常流畅”. 研究主要在校内进行,同时也在微信、QQ 等社交网络上发布公告以招募更多的志愿者,最后共有 182 名用户参加了这项研究,其中 168 名用户的数据可以用于分析.

3.2 基于 CNN 的用户感知评估模型

针对流畅性这一用户感知,首先从手机工程设计的角度确定了影响手机流畅性的 5 个主要功能模

块:CPU、RAM、GPU、网络功能模块和操作系统. 为了排除不同手机配置对实验结果的影响,文章选用同款手机进行实验,保证了设计参数的一致性,因此影响用户感知的主要因素为每个功能模块的性能参数,性能参数会随着用户使用手机执行的任务或者所处的环境不同而改变. 本文选取的性能参数包括 CPU 使用率、RAM 占有率、内存速度、网络传输速率和电池温度等,获取相应的使用数据和用户感知数据后,利用等宽分箱技术将使用数据离散化为 5 个区间,然后进行 Gamma 等级相关分析<sup>[16]</sup>,计算 Gamma 等级相关系数  $G$  和显著性检验统计量  $Z$ ,  $G$  越接近于 1 表示变量间的相关性越强,  $Z$  越大变量间的相关性越显著,结果如表 2 所示,最后确定 CPU 使用率、RAM 占用率和网络传输速率与用户流畅性感知显著相关,因此本文利用这 3 种使用数据来预测用户对流畅性的感知评估.

表 2 Gamma 等级相关分析结果

Tab. 2 The results of Gamma rank correlation analysis

影响因素	G	Z	显著性
CPU 使用率	0. 83	30. 55	显著
RAM 占有率	0. 78	23. 01	显著
内存速度	0. 14	1. 69	不显著
网络传输速率	0. 80	25. 46	显著
电池温度	0. 13	1. 52	不显著

注:  $Z>Z_{0.05/2}=1.96$  时,表示影响因素与用户流畅性感知评估显著相关。

首先,利用噪声滤波器和 Z-Score 方法对使用数据进行预处理.然后,以大小为 90 个数据点的固定窗口从原始数据中滑动取样,窗口每次移动 45 个数据点,每个窗口关于用户感知评估的标签由窗口内出现次数最多的类别标签决定.最后,随机选择 70% 的样本作为训练集,15% 的样本作为验证集,15% 的样本作为测试集,按照图 3 所示的过程利用 Python3.6 语言编写程序进行训练和测试.

根据第 2 节的内容建立 1 维 3 通道的 CNN 模型,使用 K-折交叉验证分析确定模型的最优超参数,其中 K 取 5.最终确定卷积层和池化层的数目都是 2 层,第 1 卷积层的卷积核大小为 10,即每个卷积核覆盖 10 个数据点,卷积核个数为 60,第 2 卷积层的卷积核大小为 6,卷积核个数为 10,卷积核的移动步幅均为 1,即每次移动 1 个数据点.本文采用最大池化操作,2 个池化层的池化核大小均为 20,池化核的移动步幅均为 2.全连接层中隐含层神经元个数为 10. SoftMax 回归层输出神经元的个数设置为 5.使用 AdaGrad 算法作为优化算法,学习率设置为 0.001,迭代次数设置为 2 000.

3.3 实验结果分析

本文将实验结果和人工神经网络 (Artificial

Neural Network, ANN) 模型的结果进行比较以进一步说明所提出方法的优越性. ANN 是基于特征的机器学习算法的代表模型, ANN 模型需要先从每个窗口中提取数据特征,根据文献[17]提取时间序列数据的常用数据特征,如表 3 所示,这些特征可能并不能完全表征用户对流畅性的感知评估,为了提高模型的性能需要在实践中不断设计出新的特征. 将这些特征输入 ANN 模型,模型中隐含层神经元数量根据试凑法[18]和 K-折交叉验证分析确定为 10 个,因此 ANN 的结构为  $18\times10\times5$ ,即输入层为 18 个神经元,隐含层为 10 个神经元,输出层为 5 个神经元,激活函数设置为 Sigmoid 函数,损失函数设置为交叉熵损失函数,使用 AdaGrad 算法训练模型,学习率设置为 0.001,迭代次数设置为 3 000.

模型训练过程中准确率的变化曲线如图 5 所示.从图中可以看出,在相同迭代次数下, CNN 模型在训练集和测试集中的准确率都高于 ANN 模型,由此说明, CNN 能自动从原始数据中提取出数据的高层次特征,而 ANN 则依赖人工设计特征,虽然随着更多的特征加入到 ANN 中,模型的准确率可能会有所提高,但这需要具有相关领域的专业知识才能完成,并且可能会花费大量的时间成本和计算成

表 3 从原始数据中提取的特征及其含义

Tab. 3 The features and meanings extracted from raw data

特征	含义
Mena	平均值
$L_2$ Norm	$L_2$ 范数
Standard Deviation	标准差
Median	中位数
Maximum	最大值
Minimum	最小值





图 5 模型训练过程中准确率的变化曲线

Fig. 5 The accuracy curves during the model training procedure



本,这也是文章所提出的基于 CNN 的方法相比于传统机器学习算法的优点.同时,CNN 模型在迭代训练了 2 000 次之后趋于收敛,而 ANN 模型则在 3 000 次之后才趋于收敛,CNN 模型的收敛速度更快并且训练时间更短.为了改善模型的过拟合问题,本文选择在迭代过程中在验证集上具有最佳性能的模型作为最终模型,测试 2 个模型在测试集上的表现.

对比 2 个模型在测试集上的性能,分类结果的混淆矩阵分别如表 4 和表 5 所示.从表中可以看出,CNN 模型的准确率达到了 83.41%,并且明显优于 ANN 模型的 75.61%.进一步分析模型对各个流畅性评分估计的精确率和召回率,除极少数指标外 CNN 模型的结果都优于 ANN 模型.但是,从表中也可以看出,CNN 和 ANN 模型在估计“不流畅”和“一般”评分时召回率和精确率都不高,将部分用户真实感受为“不流畅”的评分估计成了“一般”.此类情况的出现是由于用户感知评估存在一定的主观性,不同用户对手机“不流畅”和“一般”的评价标准可能不一致,即使手机处于相同的运行状态,用户也

有可能会给出不一样的评分.为了解决这一问题,一方面可以在获得模型结果后再次与用户沟通交流,根据用户反馈修正模型,这样有利于从一定程度上消除用户评价标准不一致的问题;另一方面,未来也可以基于模型预测结果和用户实际评分进行用户偏好相关方面的探索.

以上结果表明,利用本文所提出的方法可以自动提取出使用数据的深层特征表示,用于用户感知评估预测,减少了用户感知评估建模过程中对用户和设计师的依赖.由于越来越多的产品在使用过程中的数据可以被监控和采集,利用该模型不仅可以及时获取用户在使用产品过程中的感知变化,还可以分析出影响用户感知的主要产品性能参数,为产品设计改进提供决策支持.

3.4 讨论

本文以“手机流畅性”这一感知为例对所述感知建模方法进行了案例应用和验证,该方法同样适用于用户其他感知的建模.以“手机续航能力”这一感知为例,影响用户对手机续航感知的主要功能模块有电池、屏幕和处理器等,相应的性能参数包括电池容量、电池最大可充放电次数、电池充电速度、屏幕最高分辨率和屏幕最大亮度等,因此可采集性能参数对应的使用数据,包括电池剩余电量、电池充电次数、电池充电时间、屏幕分辨率和屏幕亮度等,对手机续航这一感知进行分析和建模.综上,对于用户的不同感知,首先可通过分析影响用户感知的主要功能模块确定相关的性能参数,采集这些性能参数对应的使用数据,然后利用相关性分析确定与用户感知显著相关的性能参数,最后利用这些性能参数对应的使用数据来构建用户感知模型,实现用户感知的建模和推断.

4 结语

针对目前用户感知建模方法存在的滞后性较大,而且问卷设计可能受到设计师主观偏见影响的问题,本文引入产品使用数据来建立用户感知评估模型,提出了一种基于卷积神经网络的用户感知评估建模方法,实现了数据特征的自动提取和用户感知的准确建模,最后通过一个智能手机用户感知建模的案例证明了所提出方法的有效性.主要创新点如下:

(1) 利用产品使用数据来建立用户感知评估模型,不仅可以及时准确预测用户在使用产品过程中感知的变化,而且可以分析出影响用户感知的主要产品性能参数,为产品设计改进提供决策支持;

表 4 CNN 模型分类结果的混淆矩阵

Tab. 4 The confusion matrix for CNN model

真实	预测					召回率/%
	非常 不流畅	不流畅	一般	流畅	非常 流畅	
非常不流畅	213	4	1	0	0	97.71
不流畅	7	30	25	0	0	48.39
一般	12	16	38	0	0	57.58
流畅	0	0	0	26	1	96.30
非常流畅	0	0	0	2	35	94.59
精确率/%	91.81	60.00	59.38	92.86	97.22	A=83.41

表 5 ANN 模型分类结果的混淆矩阵

Tab. 5 The confusion matrix for ANN model

真实	预测					召回率/%
	非常 不流畅	不流畅	一般	流畅	非常 流畅	
非常不流畅	214	3	1	0	0	98.17
不流畅	22	25	15	0	0	40.32
一般	40	4	22	0	0	33.33
流畅	2	0	4	18	3	66.67
非常流畅	2	0	0	4	31	83.78
精确率/%	76.43	78.13	52.38	81.82	91.18	A=75.61

(2) 基于滑动窗口技术和 CNN 建立用户感知评估模型,模型可以自动提取出使用数据的深层特征表示,用于用户感知评估预测,解决了传统机器学习算法依赖人工提取和选择特征的问题,模型具有非常高的效率和准确率。

本文仅探讨了用户单一感知评估建模的方法,如何考虑多种感知之间相互影响、建立多感知评估模型,是下一步的研究方向。

## 参考文献:

- [1] 罗仕鉴,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.  
LUO Shijian, PAN Yunhe. Review of theory, key technologies and its application of perceptual image in product design[J]. *Journal of Mechanical Engineering*, 2007, 43(3): 8-13.
- [2] XIONG Y, LI Y, PAN P, *et al.* A regression-based Kansei engineering system based on form feature lines for product form design[J]. *Advances in Mechanical Engineering*, 2016, 8(7): 168781401665610.
- [3] LIM S, TUCKER C S. A Bayesian sampling method for product feature extraction from large-scale textual data[J]. *Journal of Mechanical Design*, 2016, 138(6): 061403.
- [4] BORDAGARAY M, DELL'OLIO L, IBEAS A, *et al.* Modelling user perception of bus transit quality considering user and service heterogeneity[J]. *Transportmetrica A: Transport Science*, 2014, 10(8): 705-721.
- [5] CHEN M C, CHANG K C, HSU C L, *et al.* Applying a Kansei engineering-based logistics service design approach to developing international express services[J]. *International Journal of Physical Distribution & Logistics Management*, 2015, 45(6): 618-646.
- [6] 倪敏娜,孙志宏,王梓,等. 面向产品造型感性意象评价的 BP 神经网络模型的应用[J]. *东华大学学报*, 2016, 42(4): 604-607.  
NI Minna, SUN Zhihong, WANG Zi, *et al.* Applied research on BP neural network of Kansei images and elements modeling for the evaluation of product design[J]. *Journal of Donghua University*, 2016, 42(4): 604-607.
- [7] ZHOU F, JIAO R J, LINSEY J S. Latent customer needs elicitation by use case analogical reasoning from sentiment analysis of online product reviews[J]. *Journal of Mechanical Design*, 2015, 137(7): 071401.
- [8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2012, 25(2): 1097-1105.
- [9] HECHT-NIELSEN R. Theory of the backpropagation neural network[C]// *International Joint Conference on Neural Networks*. IEEE, 2002, 1: 593-605.
- [10] YOUNG S R, ROSE D C, KARNOWSKI T P, *et al.* Optimizing deep learning hyper-parameters through an evolutionary algorithm[C]// *Proceedings of the Workshop on Machine Learning in High-Performance Computing Environments*. ACM, 2015: 1-5.
- [11] BOTTOU L. Stochastic gradient descent tricks[M]. *Neural Networks: Tricks of the Trade*. Springer Berlin Heidelberg, 2012: 421-436.
- [12] BOTEV A, LEVER G, BARBER D. Nesterov's accelerated gradient and momentum as approximations to regularised update descent[C]// *International Joint Conference on Neural Networks*. IEEE, 2017: 1899-1903.
- [13] LE Q V, NGIAM J, COATES A, *et al.* On optimization methods for deep learning[C]// *Proceedings of the 28th International Conference on International Conference on Machine Learning*. Omnipress, 2011: 265-272.
- [14] HADGU A T, NIGAM A, DIAZ-AVILES E. Large-scale learning with AdaGrad on Spark[C]// *IEEE International Conference on Big Data*. IEEE, 2015: 2828-2830.
- [15] OOI K B, TAN G W H. Mobile technology acceptance model: An investigation using mobile users to explore smartphone credit card[J]. *Expert Systems with Applications*, 2016, 59: 33-46.
- [16] 卢淑华. 社会统计学[M]. 第四版. 北京大学出版社, 2009.  
LU Shuhua. Social statistics [M]. 4th edition. Peking University Press, 2009.
- [17] MUKHOPADHYAY S C. Wearable sensors for human activity monitoring: A review[J]. *IEEE Sensors Journal*, 2015, 15(3): 1321-1330.
- [18] 杜党党,贾晓亮,郝超博. 基于遗传过程神经网络算法的航空发动机健康状态图谱化预测方法[J]. *计算机集成制造系统*, 2015, 21(11): 2980-2987.  
DU Dangdang, JIA Xiaoliang, HAO Chaobo. Graphics prediction method for health states of aero engines based on GA-PNN[J]. *Computer Integrated Manufacturing Systems*, 2015, 21(11): 2980-2987.

(本文编辑:王一凡)