文章编号:1674-2974(2025)06-0036-08 DOI:10.16339/j.cnki.hdxbzkb.2025174

利用卷积自编码器的体压分布数据重构及分析

郭巍[1],阮金伟[1],马晓兰[2†],周蒙蒙[1],彭强[1]
(1. 武汉理工大学 汽车工程学院,湖北 武汉 430070;
2. 上汽通用五菱汽车股份有限公司,广西 柳州 545000)

摘 要:针对体压分布实验采集数据的噪声干扰问题,本研究提出了基于卷积自编码器的数据重构方法以提高数据的质量和可用性.首先,将体压分布数据归一化,并添加高斯噪声作为训练集,设计并利用卷积自编码器模型对数据进行特征提取和去噪;再将实验采集的体压分布数据作为测试集,评估重构结果的准确性和稳定性.实验结果表明:该模型在98个测试样本上得到的相对误差的均值和标准差分别为0.010和0.018,有较高的准确性和稳定性.最后,利用该模型处理实验采集的体压分布数据,得到体压分布指标随座椅位置的变化关系.

关键词:汽车座椅系统;自编码器;体压分布;乘坐舒适性
中图分类号:U461.4 **文献标志码**:A

Reconstruction and Analysis of Body Pressure Distribution Data with Convolutional Autoencoder

GUO Wei[1],RUAN Jinwei[1],MA Xiaolan[2†],ZHOU Mengmeng[1],PENG Qiang[1]
(1. School of Automotive Engineering, Wuhan University of Technology, Wuhan 430070, China;
2. SAIC-GM-Wuling Automobile Co., Ltd., Liuzhou 545000, China)

Abstract: To address the noise issue in experimentally acquired body pressure distribution data, this study proposes a convolutional autoencoder-based data reconstruction method to enhance data quality and usability. First, the body pressure distribution data is normalized. And Gaussian noise is added to construct the training set. A convolutional autoencoder model is designed and used for feature extraction and denoising. Subsequently, experimentally collected body pressure distribution data is utilized as the test set to evaluate the accuracy and stability of the reconstruction results. Experimental results demonstrate that the model achieves a mean relative error of 0.010 with a standard deviation of 0.018 across 98 test samples, indicating high accuracy and stability. Finally, the trained model is applied to process experimentally collected body pressure data, revealing the variation patterns of pressure distribution metrics with seat positions.

Key words: automotive seating systems; autoencoders; body pressure distribution; sitting comfort

* **收稿日期**:2024-02-15
基金项目:广西重点研发计划项目(AB23026112); Key Research and Development Program of Guangxi(AB23026112)
作者简介:郭巍(1982—),男,湖北黄冈人,武汉理工大学副教授,博士
† 通信联系人,E-mail: yuki2378@sina.com

随着汽车的普及化，越来越多的人倾向于使用汽车作为通勤和旅行的工具.因此，人们对汽车的需求已不仅仅停留在将其视为交通工具，驾驶的舒适性也变得日益重要[1].对于汽车座椅来说，其舒适度直接关联到乘客的身体健康和驾驶体验.舒适度可以进一步细分为静态舒适度和动态舒适度，静态舒适度主要与体压分布相关.体压分布反映了座椅对人体各部分施加的压力大小及其分布情况，它揭示了座椅的设计参数与人体特征之间的相互作用，从而体现了座椅的舒适度.Mastrigt等[2]发现在汽车座椅静态舒适性评估中，体压分布对舒适性的主观评价影响最为显著，它最能体现座椅的舒适度.高开展等[3]发现体压分布中平均压力变化率和法向力变化率的均方根值与主观不舒适性评分具有较强的相关性，可以表征汽车座椅的振动舒适性.Huang等[4]研究了不同腰椎支撑和驾驶速度条件下的压力分布、腰椎支撑的存在和厚度对驾驶员舒适性的影响，发现体压分布指标与驾驶员的主观评价存在一定的相关性，能够反映乘坐舒适性.彭强等[5]发现汽车座椅调节会影响体压分布，利用方差分析-同时主成分分析方法对正交实验的数据进行分析，得到了座椅调节对体压分布的影响规律.

体压分布数据的采集后处理同样至关重要.若数据中混杂有噪声、异常峰值或缺失值，将对后续体压分布数据的提取产生不利影响.因此，对体压分布数据进行预处理是重要且必要的.

神经网络具有强大的数据表达和映射能力.其中，自编码器神经网络结构的输入和输出是维度完全相同的数据，能够达到图像重构的目的.目前，自编码器在众多领域已经取得了显著的效果和贡献.医学中樊夏玥等[6]提出基于深度卷积自编码器和空间配准进行神经元形态相似性度量，该方法能高效、精确对比神经元形态数据，通用性强.工程学中，Wei等[7]利用三维倾斜圆盘流场数据集建立三维卷积自编码器模型，发现该模型能够很好地重建流场.王逸宸等[8]使用卷积自编码器处理含噪重力数据，并对其进行了验证，结果表明，卷积自编码器能够有效地重构含噪重力数据.Fainstein等[9]使用自动编码器处理复杂的时空数据，通过一个低维混沌的对流问题和一个具有周期动力学的鸟类发声器官证明了自编码器可以保留数据的相空间表示.

本文以含有噪声的体压分布数据为输入，以去除噪声的重构体压分布图像为输出，建立卷积自编码器模型，通过实验采集体压分布数据，以实验数据为测试集进行测试，提取体压分布指标进行分析.

1　模型原理

1.1　卷积自编码器

随着深度学习技术的不断发展，越来越多的学者将深度学习与工程学科相结合，为解决工程问题提供了新思路.自编码器是由Bourlard等[10]于1988年进行了详细的阐述之后，被广泛应用于处理高维数据、数据降维的问题上.

自编码器是一种特殊结构的神经网络模型，有着无监督学习的特点，其输入和输出的张量形状完全相同.目前基于传统的自编码器也有很多不同的形态，例如Vincent等[11]提出的降噪自编码器、Masci等[12]提出了卷积自编码器.卷积自编码器是一种可以对图像进行压缩和重构的深度学习模型，可以从图像中学习到有用的特征，并且可以用于图像降噪、分割、生成等任务.

卷积自编码器的结构大致如图1所示，包含输入、编码网络、解码网络和输出四个部分.输入图像经过编码网络后生成表示隐含特征的图像，将该图像再输入解码网络进行重构，得到输出图像.编码和解码网络通过卷积层和反卷积层所连接.卷积操作是指使用多个二维的卷积核对输入图像进行卷积，生成对应数量的尺寸较小的特征图.相对而言，反卷积则是使用相同数量的二维卷积核对特征图像进行反卷积，合成一个尺寸较大的图像作为输出.不过反卷积与卷积有所不同,在进行反卷积之前需要对图像进行0值填充，将其扩大，因此反卷积之后还需对输出图像进行裁剪，将其缩小.

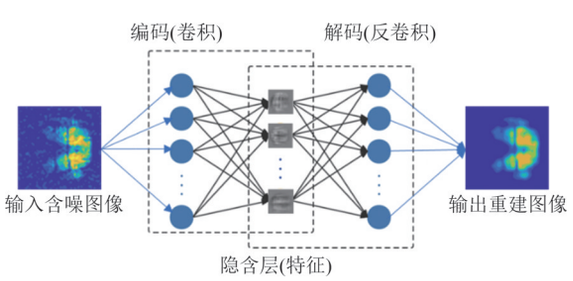


图1　卷积自编码器结构

Fig.1　Convolutional autoencoder architecture

1.2　体压分布数据重构

为了重构体压分布数据，本文采用卷积自编码器模型对其进行重构处理，其中体压分布数据通过汽车座椅舒适性研究中的实验采集，共有500个体压分布样本数据.体压分布数据是从由多个传感器

组成的系统采集的，每个传感器的输出值反映了该位置人体与座椅接触面的压力大小. 采集到的体压分布数据阈值为0.06 N/cm^2，即从0.06 N/cm^{2}开始显示，分辨率为0.01 N/cm^2，总数量为48 × 48，即每行每列均为48个传感器.

在模型搭建时，可以将体压分布数据作为卷积自编码器的输入，进行特征提取和去噪. 卷积自编码器模型的输入一般是RGB图或者8位灰度图. 而采集到的体压分布数据是具有实际物理含义的物理量，图像数据仅包含无量纲的数值信息，未赋予实际物理单位，因此在进行训练之前，需要将体压分布数据进行归一化处理，消除量纲，以便于带入卷积自编码器的输入和输出. 归一化处理之后，将体压分布数据看作二维灰度图像，其中每个传感器相当于图像的一个像素，每个像素值对应于一个传感器的压力值.

为了达成上述目的，需要将体压分布数据的物理单位转换为像素值的整数单位. 设训练样本数据中的压力最小值、最大值分别为 $p_{\min}$、$p_{\max}$，然后通过如下公式进行归一化处理：

$$p' = \frac{p - p_{\min}}{p_{\max} - p_{\min}} \tag{1}$$

式中：p'、p分别为输入卷积自编码器的体压像素值、实际体压值. 在卷积自编码器的输出端，当我们利用模型得到重构后的体压分布数据后，也需要使用相同的公式进行逆运算，将归一化后的数据还原为原本的压力数据. 通过这样的预处理，卷积自编码器能够适应不同的数据范围，并保证数据的一致性.

将上述归一化后得到的体压分布数据作为输入样本进行训练. 使用回归层作为输出，在训练过程中，利用模型实际输出与输入之差的平方和，即均方误差(mean square error，MSE)，作为损失函数L：

$$L(Y, f(x)) = \frac{1}{n}\sum_{i=1}^{n}(Y_i - f(x_i))^2 \tag{2}$$

式中：Y_i是不含噪声图像中第i个像素值；$f(x_i)$是预测图像的第i个像素值；n是像素总数. MSE的值越小，表示预测图像和真实图像越接近. 为了最小化损失函数，综合对比RMSProp优化器与Adam优化器对网络的训练效果. 结果发现，在相同的网络模型与训练参数下，RMSProp优化器的训练时间为87 s，MSE为3.142 8，Adam的训练时间为90 s，MSE为3.205 1. 因此，选用训练时间更短，验证误差更小的RMSProp优化算法进行迭代优化至损失函数收敛，得到优化完成的卷积自编码器模型，后续将其用于重构体压分布数据.

2 卷积自编码器模型

2.1 卷积自编码器模型的建立与训练

为了实现最佳的重构效果，本文对卷积自编码器模型的卷积核尺寸、数量以及神经网络的学习参数进行了调整和测试，并最终选定了以下设计参数的卷积自编码器模型结构. 表1展示了网络训练参数，表2列出了网络模型参数. 特别地，卷积层3被用于调整通道数，而激活层Sigmoid则用于图像的归一化处理.

表1 网络训练参数

Tab. 1 Network training parameters

优化器	最大迭代次数	学习率	$L2$正则化参数
RMSProp	200	0.001	0.000 1

表2 网络模型参数

Tab. 2 Network model parameters

编码层	描述	解码层	描述
卷积层1	24个3 × 3	转置卷积层1	48个2 × 2
激活层	ReLU	激活层	ReLU
最大池化层1	2 × 2	转置卷积层2	24个2 × 2
卷积层2	48个3 × 3	激活层	ReLU
激活层	ReLU	卷积层3	1个1 × 1
最大池化层2	2 × 2	激活层	Sigmoid

如图2所示，体压分布数据由48 × 48个均匀分布的压力传感器采集得到，每个传感器的大小为边长1.27 cm的正方形. 这些传感器测得的数据都是压力的数值，因此网络的输入和输出都是1 × 48 × 48的张量，下一部分是编码网络.

编码网络由两层卷积层构成，每个卷积层均使用了大小为3 × 3的卷积核，步长为1. 编码网络第

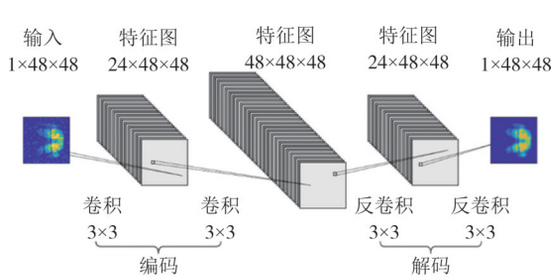


图2 用于重构体压分布数据的卷积自编码器

Fig. 2 Convolutional autoencoder for reconstructing body pressure distribution data

一层设置24个卷积核，输入数据经过编码网络的卷积后，每个卷积核通过卷积操作能够形成特征图像，也就是提取出来的体压分布图像的局部特征，得到24个48 × 48的特征图.将特征图输入编码网络的第二层，进行相同的操作，该卷积层设置了48个卷积核，得到48 × 48 × 48的特征图集合，表示体压分布中更高层次的特征.压缩完成后，可以将这些特征带入由两个反卷积层组成的反卷积解码网络，经过解码网络中的两次反卷积操作，可以将原本输入的48 × 48 × 48的特征图还原为1 × 48 × 48的张量，得到输出的重构体压分布图.

本研究选用10名试验人员，包括5名50百分位人员、5名95百分位人员.在同一座椅的不同驾驶位置进行体压分布数据采集，实验台架如图3所示，通过调节座椅高度、前后距离和靠背角度来改变体压分布数据，从而确保实验采集得到250个不同的座椅靠背和坐垫的体压分布图像，将一共500张体压分布图像作为训练集.将含噪体压分布图像输入网络进行训练，直至损失函数收敛.

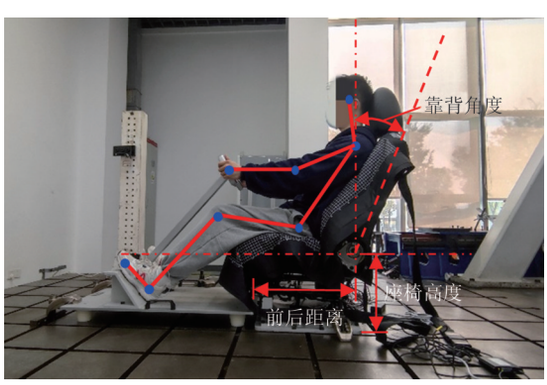


图 3　实验台架示意图

Fig. 3　Schematic diagram of the experimental bench

体压分布数据在采集时会由于压力垫的部分折叠或者试验人员的衣物而产生不均匀噪声，其值通常位于0.06~0.10 N/cm^2，如图4(a)所示.而采集到的体压分布数据约为0.2 N/cm^2，如果不去除噪声压力可能会导致部分体压分布指标失真.为了提高模型的鲁棒性，在原始图像中随机添加幅度大小为每幅图形平均压力的5%~15%的高斯噪声，图4(b)为10%的高斯噪声，添加的高斯噪声幅值范围为0~0.4 N/cm^2，该范围既覆盖了实际采集噪声的典型值0.06~0.10 N/cm^2，也能模拟潜在极端噪声(如0.4 N/cm^2).选择该范围是为了避免噪声过大而影响模型学习特征，或噪声过小而不足以提升模型的鲁棒性，如果仅使用原始图像进行训练，模型在遇到不同噪声水平时可能无法有效去除噪声.因此，通过这种策略，模型得以对含有噪声的图像进行精确预测.

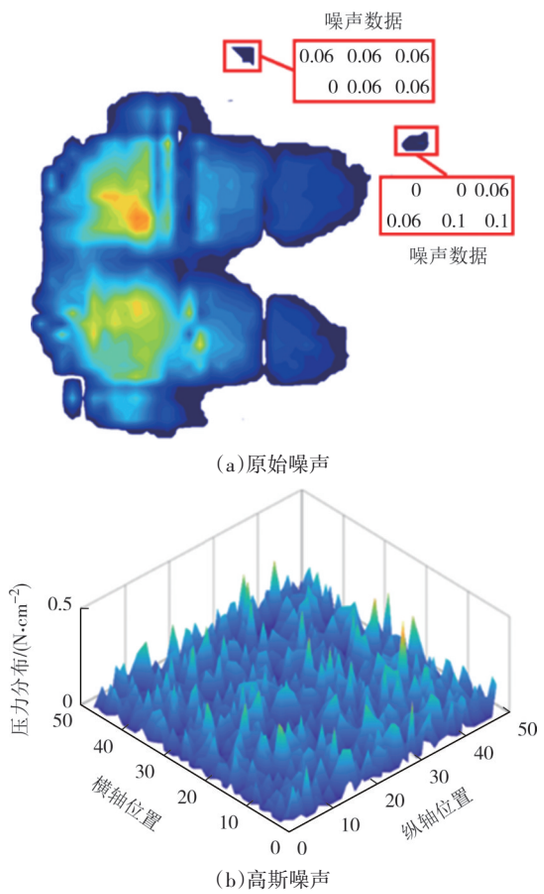


图 4　原始噪声与高斯噪声

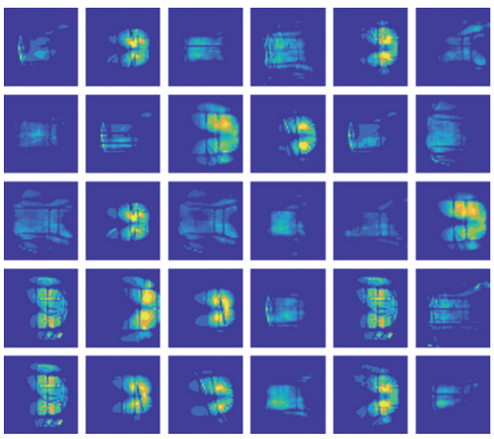
Fig.4　Original noise and Gaussian noise

2.2　模型测试

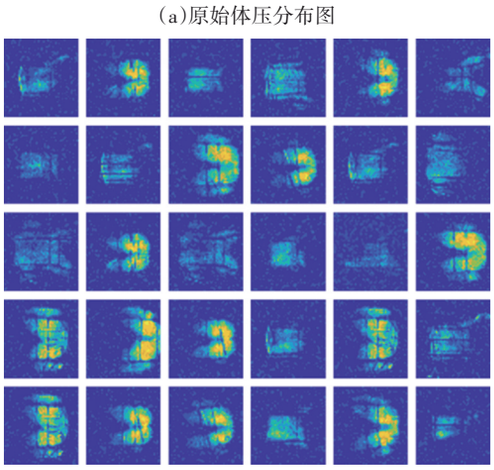
为了验证该模型的重构效果，本文通过实验采集了不同身高、体重的7位人员的7组体压分布数据.为了确保数据质量，在采集过程中会人为控制体压分布数据，以避免产生噪声数据，因此为了验证模型效果，在测试集的体压分布数据中随机加入平均压力的10%的高斯噪声，得到98个测试样本，图5为部分样本数据.

引入噪声是为了检验模型的泛化能力和鲁棒性.所选用的10%高斯噪声能够覆盖大多数常见的噪声类型，确保模型在实际应用中能够有效地重构体压分布数据，即便数据中存在一些不可预见的噪声.将测试样本输入卷积自编码器模型中进行重构，并统计测试重构输出结果的相对误差，计算公式如下：

$$\varepsilon = \frac{1}{N}\sum_{i=1}^{N}\frac{\widehat{p_i} - p_i}{p_i} \tag{3}$$



(a)原始体压分布图



(b)含噪体压分布图

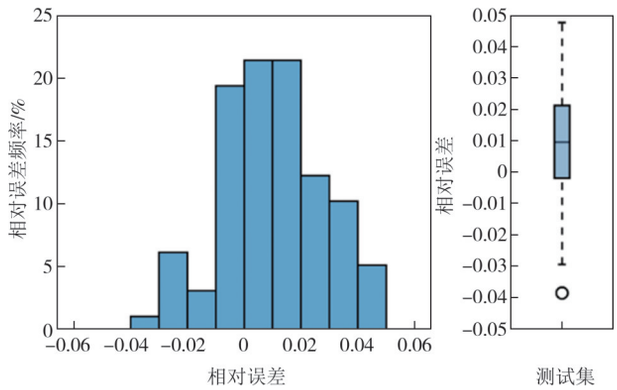
图5 部分训练集样本示意图

Fig.5 Partial training set sample diagram

式中：$\hat{p}_i$、p_i分别为重构体压分布压力值和体压分布原始压力值；N为总像素个数，在本文中为48 × 48 = 2 304.

测试集重构结果的相对误差如图6所示，图中显示了模型在98个测试样本上得到的相对误差的频率直方图，以及相对误差的箱型图.可以看出，相对误差呈现出近似正态分布的形状，大部分误差集中分布在-0.01~0.02之间，相对误差的均值和标准差分别为0.010和0.018，可见卷积自编码器模型在重构体压分布数据方面具有较高的准确性和稳定性.

为了分析卷积自编码器模型的重构性能，选用测试集中一个体压分布图像进行分析，如图7所示，图7(a)、(b)、(c)分别为含噪体压、原始体压和重构体压分布图.可以看出，对于重构的体压分布来说，自编码器模型能够很好地去除图像中添加的高斯噪声和图像原来存在的噪声，并且较为完整地恢复了



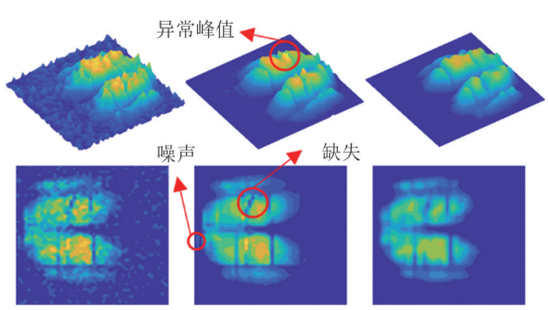
(a)相对误差频率直方图 (b)相对误差箱型图

图6 测试集相对误差

Fig.6 Test set relative error

体压分布的外形特征，梯度特征和压力大小特征、以及轮廓、压力过渡信息，同时，在确保体压分布保持原有的压力分布情况和接触面大小的基础上，有效地减少了噪声，并使压力过渡更加平滑，过滤掉对体压分布分析无用的细节信息.

此外，针对特定的压力异常状况，该模型具备将压力分布调整至更正常状态的能力.例如，在处理局部异常峰值时，模型会将其值向周围区域分散；而在面对不规则断层时，会利用邻近数据轻微填补断层处的空隙.这样的处理方式能够更好地反映出体压分布对人体的直观感受的影响.研究人员在对体压分布数据进行观察和计算的时候，由于其平滑的特点，体压分布数据也更利于分析.



(a)含噪体压分布 (b)原始体压分布 (c)重构体压分布

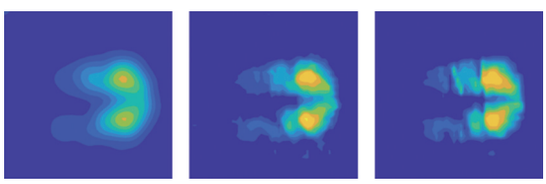
图7 原始、含噪和重构体压分布

Fig.7 Original, noisy and reconstructed body pressure distributions

为了更直观地展示和对比卷积自编码器的重构效果，选取图像处理领域常用的高斯滤波和中值滤波技术，对含有噪声的体压分布图像进行处理.处理后的结果如图8所示.

由图8可知，经过高斯滤波处理的图像仅保留

了梯度信息,其效果并不理想;而经过中值滤波处理的图像,虽然重构效果尚可,能够展现出基本的边缘轮廓,但同时也丢失了一些峰值和间隙细节,并且噪声的清除并不彻底.相比之下,卷积自编码器在去除噪声的同时,能够有效地保留重要的压力信息.



(a)高斯滤波　(b)中值滤波　(c)卷积自编码器

图 8　三种图像滤波对比

Fig.8　Comparison of three kinds of image filtering

卷积自编码器模型在处理体压分布数据上效果较好,主要是因为它结合了卷积神经网络在图像处理中的强大能力和自编码器在数据降维和特征学习方面的优势.它能够有效地提取图像中的局部特征和高层次抽象特征,并且在降维过程中有效压缩重要信息.

2.3　体压分布指标数据测试

为了深入分析体压分布数据,不仅需要观察体压分布图像,还应当提取相关的体压分布指标,以便进行客观评价.体压分布指标能够反映体压分布图像中的一些特征,可以用来分析舒适性的好坏.本文选用总压力、平均压力、接触面积作为体压指标.

1)　总压力

总压力指的是该部位所有压力传感器测得的压力之和,单位是N/cm^2,计算方法为:

$$P_{TP}=\sum_{i=1}^{N}P_i \tag{4}$$

2)　平均压力

平均压力指在该部位中,压力传感器测得的总压力除以总测量点个数,单位是N/cm^2,计算方法为:

$$P_{AP}=P_{TP}/N \tag{5}$$

3)　接触面积

接触面积指在该部位中,身体与压力垫接触的面积大小,可以通过传感器的面积大小与有数据的传感器数量的乘积获得,单位是cm^2,计算方法为:

$$A=S_0\times N \tag{6}$$

式中:S_0表示传感器的面积大小;N表示有数据的传感器数量.

为了更好地适应不同个体,选择将每张图像作为一个整体来进行特征提取,并未对图像进行分区处理.选用测试集49个样本中的坐垫和靠背体压分布,分别计算重构体压分布和含噪体压分布图与原始体压分布图的相对误差大小,并统计为图9所示数据.

由图9可以明显看到,含有噪声的数据相对误差较大.对于接触面积来说,噪声的加入导致接触面积误差过大;对于总压力和平均压力来说,含有噪声的数据误差大部分大于20%.但是对于重构体压分布的接触面积、平均压力来说,误差大多为5%~10%,总压力的误差大多为10%~20%.因此利用卷积自编码器对体压分布数据进行重构去噪后的数据能够更好地提取出体压分布的指标数据,并且在去除噪声的情况下,保留不同个体的特征,提取出有效的体压分布指标数据.

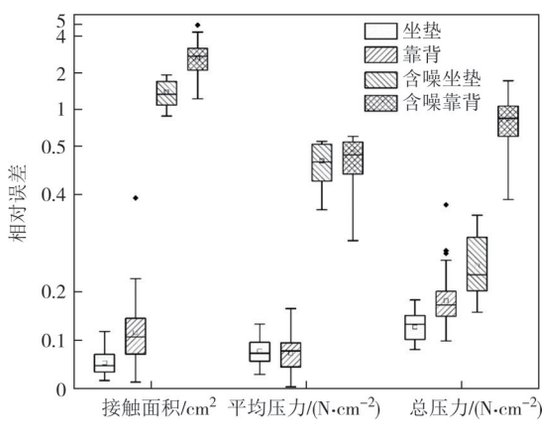


图 9　体压分布指标相对误差图

Fig.9　Relative error plots for body pressure distribution indicators

3　体压参数与座椅位置的关系

为了探究体压分布数据与汽车座椅位置的关系,邀请一名95百分位的实验人员来参与实验.采用控制变量的方法进行两组实验,第一组实验先将座椅高度固定在中间位置并保持不动,调节滑轨位置在80 cm位置处,只将靠背角度从80°调节到100°,每5°进行一次实验采集.第二组实验先将靠背角度固定在90°,将座椅前后距离从80 cm调节到110 cm,每10 cm进行一次实验采集,得到体压分布数据.最后将得到的体压分布图像带入卷积自编码器中进行去噪处理,并提取出体压分布指标,如图10所示.

由于压力指标的量纲不同,因此将体压指标归

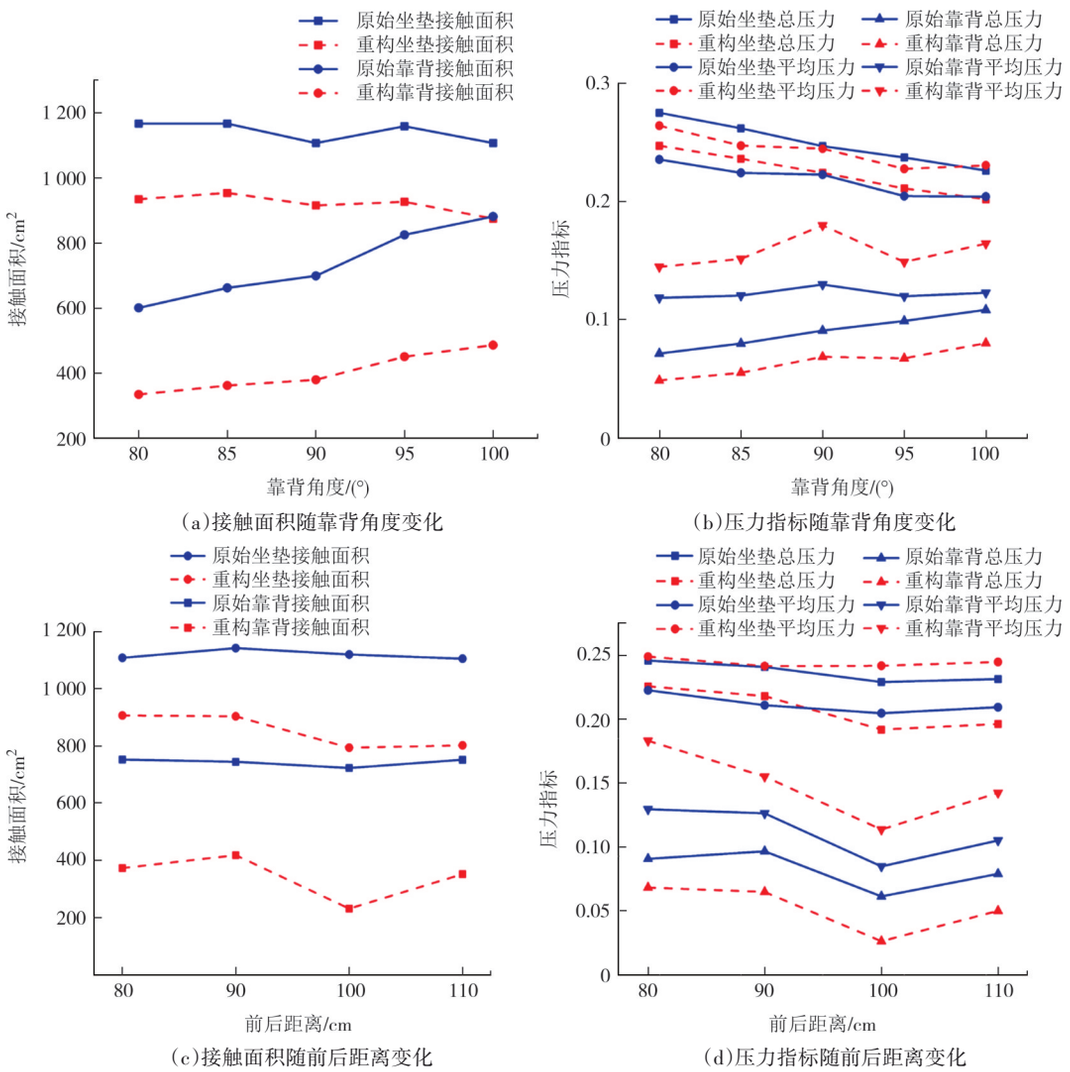


图 10 体压分布指标与座椅位置关系

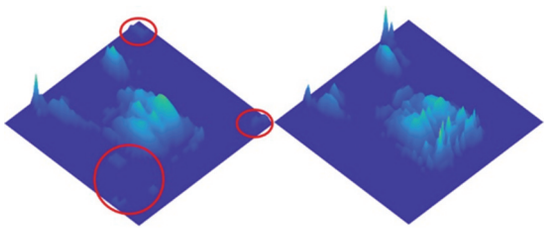
Fig.10 Body pressure distribution indicators in relation to seat position

一化展示.观察图 10 可以发现,经过重构的体压分布显示,接触面积和总压力的指标通常会略有下降,但整体趋势保持不变.此外,重构过程有效地剔除了原始数据中的噪声,从而提供了更为精确的数据.

整体观察重构后的数据,发现随着靠背角度的增大,坐垫的接触面积、总压力和平均压力总体呈逐步减小的趋势,伴随一些由于坐姿变化的波动.全行程变化率分别为:-6.38%、-18.30%、-12.72%;靠背的接触面积、总压力和平均压力都有所上升,变化率分别为 45.19%、65.05%、13.62%. 而随着前后距离的增大,坐垫的接触面积、总压力和平均压力总体呈下降趋势,伴随一些由于坐姿变化的波动,变化率分别为:-11.56%、-13.06%、-1.69%;靠背总压力和平均压力呈先下降后上升的趋势,总体为下降趋势,变化率分别为:-26.67%、-22.27%;靠背接触面积总体呈现先上升后下降再上升趋势,变化率为-5.63%.

体压分布的重构也对体压分布指标的提取有一定的改变.细致对比能够发现,相对于原始的体压分布数据,图 10(c)中的靠背接触面积由于噪声的存在原本呈现为基本不变的趋势,但是通过卷积自编码器模型重构后就还原成先增后减再增的趋势.图 11 为前后距离分别为 80 cm 和 90 cm 两个位置的体压分布对比图.

对比前后距离为 80 cm 处与 90 cm 处的靠背体压分布图可以看出,图 11(a)中红圈处表明,80 cm 处采集到较多的噪声数据,从而导致其接触面积较大.而自编码器模型通过重构之后,其指标数据变为去除噪声后的正常指标数值,具有参考意义.除此之外其他参数的一些趋势也因为通过自编码器的模型重构后有了更真实的效果.



(a)前后距离 80 cm 靠背图像　(b)前后距离 90 cm 靠背图像

图 11　两种位置体压分布重构后对比图

Fig.11　Comparison of reconstructed body pressure distribution at two positions

4　结 论

本文利用卷积自编码器对体压分布数据进行了重构，旨在提升汽车座椅舒适性的评价效果.首先通过体压分布数据的特点来确定数据处理方法，并设计了卷积自编码器的网络结构，通过训练和测试验证了其重构性能.实验结果表明，卷积自编码器模型能够有效地去除体压分布数据中的噪声，恢复其原始特征，同时保持数据的一致性.此外，本文还利用重构后的体压分布数据提取了体压分布的指标，包括平均压力、总压力和接触面积，并分析了其与原始指标的误差情况，并利用该方法探究了体压分布指标与座椅位置的关系变化.本文的研究为汽车座椅舒适性的评价提供了一种新的思路和工具，也为卷积自编码器在其他领域的应用拓展了范围.

参考文献

[1] 唐继尧，韦鸿建. 汽车座椅静态舒适性评价方法与应用[J]. 时代汽车，2022(8):160-161.
TANG J Y，WEI H J. Evaluation method and application of static comfort of car seat[J]. Auto Time，2022(8):160-161.(in Chinese)

[2] MASTRIGT S H V，GROENESTEIJN L，VINK P，et al. Predicting passenger seat comfort and discomfort on the basis of human，context and seat characteristics:a literature review[J]. Ergonomics，2017，60(7):889-911.

[3] 高开展，罗巧，张志飞，等. 基于体压分布的汽车座椅振动舒适性评价[J]. 汽车工程，2022，44(12):1936-1943，1963.
GAO K Z，LUO Q，ZHANG Z F，et al. Vibration comfort evaluation of vehicle seat based on body pressure distribution[J]. Automotive Engineering，2022，44(12):1936-1943，1963.(in Chinese)

[4] HUANG Q Y，JIN X P，GAO M Y，et al. Influence of lumbar support on tractor seat comfort based on body pressure distribution[J]. PloS ONE，2023，18(4):1-17.

[5] 彭强，袁欢，郭巍，等.汽车座椅体压分布变化规律和调节策略[J].机械设计与研究，2023，39(3):185-192.
PENG Q，YUAN H，GUO W，et al，Study on the law of automobile seat body pressure distribution and strategy of Automobile Seat Adjustment[J]. Machine Design & Research，2023，39(3):185-192.(in Chinese)

[6] 樊夏玥，甄昊天，商增谊，等.基于卷积自编码器与点云配准的神经元形态相似性度量方法[J].中国生物医学工程学报，2023，42(1):62-73.
FAN X Y，ZHEN H T，SHANG Z Y，et al. Similarity measurement of neuronal morphology based on convolutional auto-encoder and spatial registration[J]. Chinese Journal of Biomedical Engineering，2023，42(1):62-73.(in Chinese)

[7] WEI L，GUO X X，TIAN X L，et al. Three-dimensional autoencoder for the flow field reconstruction of an inclined circular disk[J]. Ocean Engineering，2024，299:117284.

[8] 王逸宸，柳林涛，许厚泽. 利用卷积自编码器重建含噪重力数据[J].武汉大学学报(信息科学版)，2022，47(4):543-550.
WANG Y C，LIU L T，XU H Z. Noisy gravity data reconstruction using the convolutional autoencoder [J]. Geomatics and Information Science of Wuhan University，2022，47(4):543-550.(in Chinese)

[9] FAINSTEIN F，CATONI J，ELEMANS C P H，et al. The reconstruction of flows from spatiotemporal data by autoencoders[J]. Chaos，Solitons & Fractals，2023，176:114115.

[10] BOURLARD H，KAMP Y. Auto-association by multilayer perceptrons and singular value decomposition [J]. Biological Cybernetics，1988，59(4/5):291-294.

[11] VINCENT P，LAROCHELLE H，BENGIO Y，et al. Extracting and composing robust features with denoising autoencoders[C]// Proceedings of the 25th International Conference on Machine Learning. July 5-9，2008，Helsinki，Finland. ACM，2008:1096-1103.

[12] MASCI J，MEIER U，CIREŞAN D，et al. Stacked convolutional auto-encoders for hierarchical feature extraction[C]// Artificial Neural Networks and Machine Learning-ICANN 2011. Berlin，Heidelberg:Springer Berlin Heidelberg，2011:52-59.