

DOI: 10.19650/j.cnki.cjsi.J2209528

基于多阶通道响应对称双线性卷积神经网络的 分布式压力识别*

褚洁¹, 蔡觉平¹, 李龙², 王帅利¹

(1. 西安电子科技大学微电子学院 西安 710071; 2. 国网陕西省电力有限公司电力科学研究院 西安 710199)

摘要:目前基于传感阵列的分布式压力识别方法,通常先将压力信息表征为图像,然后再进行特征的提取与分类,但存在两个问题:传感阵列密度有限,压力图像分辨率低;柔性传感阵列存在弹性耦合,压力图像边缘模糊。本文提出了一种多阶通道响应对称双线性卷积神经网络(HoSB-CNN)。首先,构建通道注意力响应CNN,通过给不同特征依照显著性赋权值以提升一阶特征的描述能力。其次提出对称双线性特征,引入二阶特性提高CNN对边缘和纹理的敏感度,并利用其结构对称性降低网络复杂度。最后,提出多阶特征混合策略提升网络的非线性拟合能力。此外,通过自制数据采集平台和8×8传感阵列,建立压力字母数据集用于HoSB-CNN的验证。结果表明,该算法获得了98.11%的准确率。

关键词: 分布式压力识别;卷积神经网络;对称双线性特征;多阶特征混合

中图分类号: TH82 TP24 **文献标识码:** A **国家标准学科分类代码:** 510

Hybrid-order channel response symmetric bilinear convolutional neural network for distributed pressure recognition

Chu Jie¹, Cai Jueping¹, Li Long², Wang Shuaili¹

(1. College of Microelectronics, Xidian University, Xi'an 710071, China;
2. State Grid Shaanxi Electric Power Research Institute, Xi'an 710199, China)

Abstract: The distributed pressure recognition method based on sensing arrays is usually to characterize pressure information as an image. Then, features for classification are extracted. However, there are still two problems. The first is the limited density of sensing arrays which leads to low resolution of the formed pressure images. The second is the existence of elastic coupling in flexible sensing arrays, which results in blurred edges of the pressure images. In this article, a hybrid-order channel response symmetric bilinear convolutional neural network (HoSB-CNN) is proposed. Firstly, the channel attention response CNN is constructed for enhancing the representation of first-order features. Secondly, symmetric bilinear features are proposed to improve the sensitivity to edges. In addition, due to the structural symmetry of the symmetric bilinear features, only the triangular matrix is retained in the storage and transfer of the features, which could reduce the network complexity. Finally, a multi-order feature hybrid strategy is used to enhance the nonlinear fitting ability of the network. And a press-letter dataset is constructed by self-built data collection platform and 8×8 sensor array to evaluate the HoSB-CNN. Results show that the accuracy of the proposed method is 98.11%.

Keywords: distributed pressure recognition; convolutional neural network; symmetric bilinear feature; hybrid-order feature

0 引言

物体的压力信息是机械与外界进行互动时重要的信息媒介,对其识别与分析在人机交互、智能机械、智慧工业等领域具有广泛的应用前景^[1-2]。分布式压力识别本质是对压力

信息进行重新表征与特征提取,以获取接触对象和外部环境的多种性质,是后续抓取、操纵、移动等动作的基础。

传感阵列通过感应外部刺激,映射压力的大小与空间分布,能够反映接触对象和环境的多种性质^[3]。通常,将传感阵列中的每个敏感元件视为单点像素,则分布式压力信息可以被表征为压力图像^[4]。因此对分布式压力

的识别可以迁移使用视觉图像的特征提取与分类方法。目前,语义驱动的深度学习能端到端的进行特征提取与分类,其中卷积神经网络(convolutional neural network, CNN)因其强大的特征提取能力被广泛研究并应用于各类压力识别任务^[5]。李铁军等^[6]自制了基于压力阵列传感器的触觉手柄,并使用CNN网络分类3种抓握状态。Pastor等^[7]受视频识别启发,通过主动触觉感知构建一个三维触觉张量并自建3DCNN对其进行识别。Cao等^[8]将用于RGB图像识别的正交平铺卷积迁移至压力识别任务,对水果的正确分类达到90%以上。

然而,目前的研究缺少针对压力传感器与光学传感器的差距、压力图像与RGB图像的差异进行算法设计,因此分布式压力识别仍面临如下挑战:1)压力图像的分辨率取决于传感阵列的密度和面积,目前的材料制备以及工艺水平不能满足其进行高密度、大面积部署。因此与RGB图像相比,压力图像是低分辨率的小尺寸图像。目前主流CNN是针对大尺寸高分辨率的RGB图像设计的深网络,即通过加深、加宽网络来提升特征描述能力。而小尺寸低分辨率的压力图像仅适用浅层网络。2)由于分布式压力感知通常应用于实时监测与反馈的任务中,识别网络不能太过复杂,轻量化的网络有助于其进一步扩大应用范围,因此需要平衡网络性能与复杂度之间的关系。3)由于压力传感器主要由柔性材料制备,传感元件之间的弹性耦合无法避免,受力点周围产生伪输出,导致压力图像的边缘模糊。因此,需要在识别网络的层数和宽度受限的情况下,对小尺寸、边缘模糊的压力图像进行有效的特征提取。

针对以上问题,本文提出了一种混合阶通道响应对称双线性卷积神经网络(hybrid-order symmetric bilinear convolutional neural network, HoSB-CNN)。首先构建浅层二维CNN进行特征提取,并插入通道响应增强CNN的一阶特征描述能力;其次通过矩阵外积引入二阶信息来改进CNN的对边缘和纹理的敏感度,并利用其结构对称性,轻量化识别网络;最后通过多阶特征混合来提升特征利用效率,增加其互补优势。此外,本文通过自建压力采集平台和8×8压力阵列,构建了具有复杂边缘的26个字母形状的压力数据集(A-Z)用于模型验证。

1 传感阵列的分布力表征与压力图像的非理想效应

传感阵列的敏感元件分布对应压力图像的像素分布,传感阵列中各元件的电阻值对应压力图像各像素点的灰度值,因此传感阵列的整体输出即视为压力灰度图像,如图1(a)所示。以先前研究的中空碳球填充PDMS压阻传感器为例^[9],传感阵列在外部刺激下产生形变,外力变化转换为电阻的变化。传感阵列在压力下被压缩,由于弹性耦合,受力点周围的非受力点也会发生形变。且力敏薄膜的四周是紧支的,因此受力点周围区域也可能被拉伸,并且其变形程度会随距离而变化。图1(b)展示了500 Pa压力下弹性膜的压力与应力分布。传感阵列由压力和应力共同作用产生形变,从而改变输出电阻。

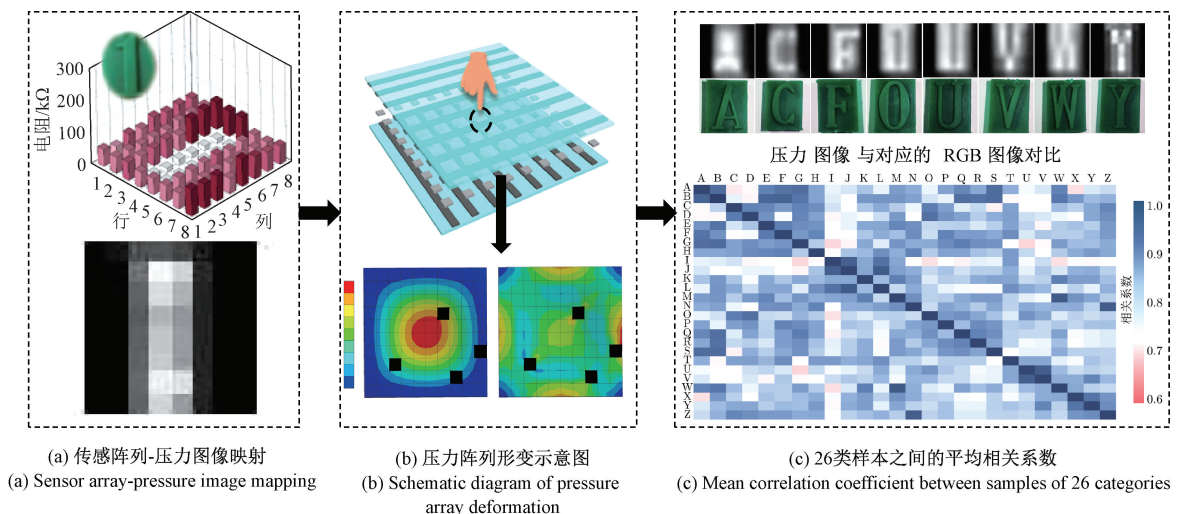


图1 压力图像的非理想效应

Fig. 1 Non-ideal effects of pressure images

另外,压力图像的尺寸取决于压力传感器的密度和面积。目前的材料制备与工艺水平难以支持传感器进行

高密度大面积的部署。因此与RGB图像相比,压力图像是小尺寸、低分辨率、边缘模糊的图像。字母具有复杂的

边缘,其压力图像可以充分说明压力图像存在的问题。一组通过自制 8×8 压力传感器采集的分布式压力图像和相应的 RGB 视觉图像的对比如图 1(c) 所示。可以看出,压力图像呈现低分辨率和边缘模糊状态,一些不同的类别表现出相似的边缘,例如“O”和“U”。为了定量说明低分辨率和边缘模糊对压力图像的影响,本文采用平均相关系数量化 26 个字母形状相似情况。平均相关系数可以表示为:

$$r = \frac{\sum_{i=1}^8 \sum_{j=1}^8 (I_A(i,j) - \bar{I}_A)(I_B(i,j) - \bar{I}_B)}{\sqrt{\left(\sum_{i=1}^8 \sum_{j=1}^8 (I_A(i,j) - \bar{I}_A)^2\right)\left(\sum_{i=1}^8 \sum_{j=1}^8 (I_B(i,j) - \bar{I}_B)^2\right)}} \quad (1)$$

其中, $I(x, y)$ 表示图像在点 (x, y) 处的灰度值。 r 数值越大表示不同类别之间的关联性越强,意味着更容易发生混淆。结果如图 1(c) 所示,不同类别之间表现出较强的相关性,大部分数值分布在 $[0.7, 0.85]$ 。其中部分类别达到 0.9 以上,例如“G”和“Q”,“M”和“W”,“O”和“U”等。原始压力信息映射的不准确降低了样本的可分性,低分辨率和模糊的边缘导致类别之间的差异减小,不同类别容易产生误分类。目前的 CNN 是基于视觉图像的深度网络,而压力图像的低分辨率限制了可配置的 CNN 深度,因此不适合处理压力识别任务。

2 多阶通道响应对称双线性卷积神经网络

针对压力图像分辨率低、尺寸小、边缘模糊的问题,本文提出了 HoSB-CNN 识别框架。首先构建了浅层通道注意力响应 CNN,用于提升一阶 CNN 的特征描述能力;其次提出对称的双线性特征,通过引入二阶特性提高 CNN 的特征提取能力,并利用其对称性进行网络轻量化;最后,通过多阶多层特征的融合,充分利用特征的互补性,在保持网络深度不变的情况下,提升 CNN 的非线性拟合能力。

2.1 HoSB-CNN 框架

HoSB-CNN 框架由 3 部分组成:通道响应一阶 CNN 特征提取器;二阶对称双线性生成模块和特征融合模块,如图 2 所示。一阶特征提取器基于二维 CNN 结构,由卷积层和池化层交替构成。使用 5 个卷积层和 3 个池化层,为了防止过拟合,加入批量归一化(batch normalization, BN)。双线性特征由 CNN 的一阶特征进行单通道整体内积生成,具有显著的结构对称性,包含重要的统计意义与网络轻量化潜力。对低分辨率的输入,低层特征的尺寸较大,包含更丰富的边缘信息。因此本文使用低层特征生成双线性特征,更有利于二阶特征的表示。高层一阶特征包含语义信息,低层二阶特征挖掘了局部特征的边缘信息。因此多阶多层级特征的融合在不增加网络深度的情况下,增加了网络的非线性与特征利用效率。

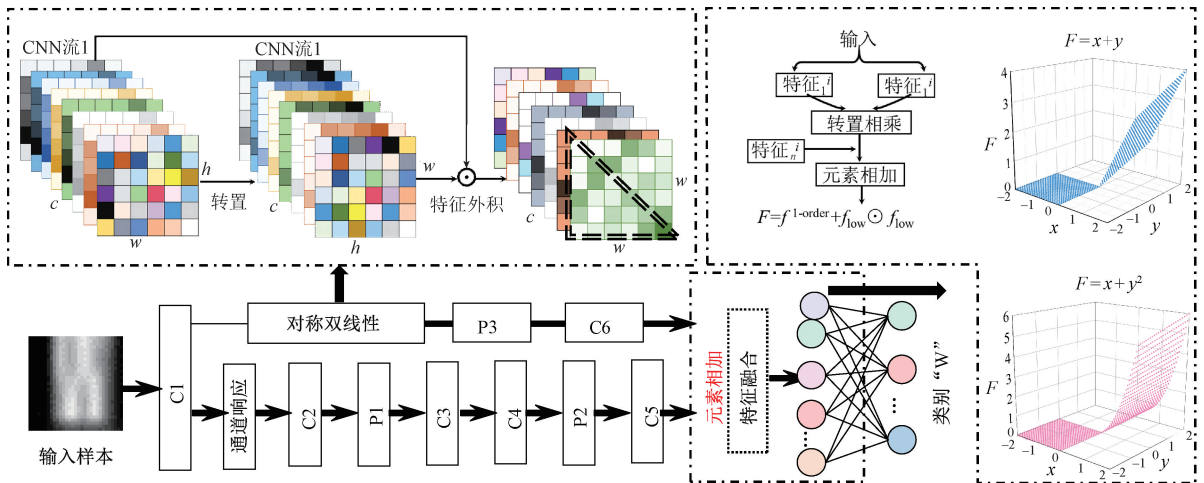


图 2 多阶通道响应对称双线性卷积神经网络框架

Fig. 2 Schematic diagram of the hybrid-order channel response symmetric bilinear convolutional neural network

2.2 通道响应的一阶特征提取器

1) 基于二维 CNN 的一阶特征

本文采用二维 CNN 提取一阶特征。卷积的本质是用不同权值的滤波器以滑动的方式扫描图像,进行特征

提取,其数学形式可以表示为:

$$f^i = \varphi(w^i \otimes f^{i-1} + b^i) \quad (2)$$

其中, f^i 第 i 层的特征, w^i 是本层卷积核的权值, b^i 是本层偏置, φ 表示激活函数,这里选择经典的 ReLU^[10]。

2) 基于压缩-激励的通道注意力响应模块

传统 CNN 在提取局部特征后直接在全连接层进行组合并作出判断, 其中每个通道的权重一样, 忽略了不同的通道对结果的贡献度差异。不同于视觉图像, 压力图像存在尺寸小、类别之间差别不明显的特点。为了突出特征的重要性差异, 在 CNN 中引入基于通道响应注意力机制^[11]。依据不同通道对分类结果的重要性, 给不同通道分配不同的权值, 增强重要的通道, 抑制无用通道对结果的干扰, 如图 3 所示。




图 3 基于压缩-激励的通道注意力响应模块

Fig. 3 Compression-excitation based channel attention response

通道响应通过在卷积层后插入压缩-激励模块进行权值计算与分配。压缩操作是通过特征进行挤压, 获得一个全局描述向量 Z , 以描述特征在不同通道上的响应分布。对于一组特征 $f \in R^{h \times w \times c}$, 进行下列数学计算:

$$Z = \frac{GP(f^c)}{h \times w} \quad (3)$$

$$GP(f^c) = \sum_{i=1}^h \sum_{j=1}^w f^c(i, j) \quad (4)$$

选择全局平均池化进行数据压缩, 使用通道内特征图的平均激活值代表本通道的响应, 获得的全局描述为向量 $Z \{1 \times 1 \times c\}$ 。激励操作是将压缩得到的全局向量 Z

送入全连接层, 进一步学习通道之间的关系, 辨别不同通道的特征对于分类的重要性, 最终获得通道注意力权重 S :

$$S = \varphi(fc(Z)) \quad (5)$$

其中, φ 表示激活函数, fc 表示全连接层。最后将权重 S 依照通道序号分配给对应的原始特征图, 得到重新“缩放”的特征图 $f^i \in R^{h \times w \times c}$:

$$\tilde{f}^i = S^i \cdot f^i \quad (6)$$

显然, 压缩-激励模块能够增强对分类结果更重要的特征图, 提升一阶特征的代表能力。此外, 基于通道响应的特征图不仅提取到了样本信息, 同时能够反映特征在通道之间的依赖关系。

2.3 二阶对称双线性特征

1) 二阶对称双线性特征的生成

一阶特征对低分辨率的压力图像表征不够充分, 而二阶信息对纹理和边缘更敏感, 在视觉任务中能显著提高细粒度物体的识别准确率^[12]。受此启发, 通过对 CNN 提取到的一阶特征进行外积计算引入对称的双线性特征。传统的双线性特征是通过不同通道中同一位置的元素组成向量, 再转置相乘获得, 重点用于捕捉 CNN 通道之间的关系, 如图 4(a) 所示^[13]。但对于压力识别任务, 需要提升特征本身的描述能力, 而不是聚焦通道之间的关系。因此本文所提出的双线性特征是由同一通道内整个特征的外积生成, 由底层包含更多边缘信息的大尺寸特征产生, 如图 4(b)。将 CNN 提取的一阶低层特征记为 f_{low} , 则对称的双线性特征 f_B 可以表示为:

$$f^B = f_{low} \odot f_{low} \quad (7)$$

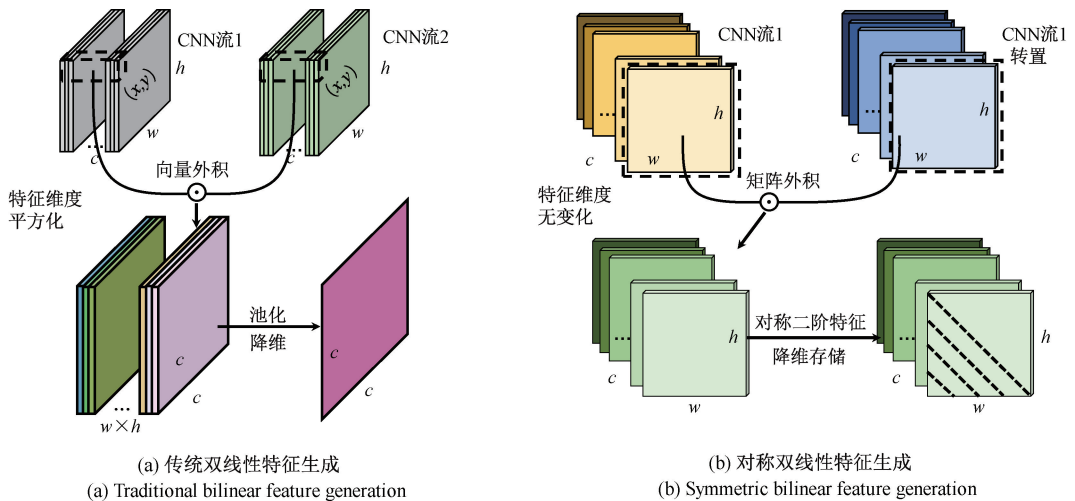


图 4 对称双线性特征的生成与对别

Fig. 4 Comparison and generation of symmetric bilinear feature

由于 ReLU 已经归零部分神经元,在使用 BN 层对数据进行标准化会造成结果不稳定,这里使用 sigmoid 激活函数:

$$S(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

将 f^B 写成向量形式 $f_{low} = (y_1, y_2, \dots, y_n)$, 则式(7)可以表示为:

$$f^B = (y_1, y_2, \dots, y_n)^T (y_1, y_2, \dots, y_n) = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} (y_1, y_2, \dots, y_n) \quad (9)$$

$$y_n = \begin{pmatrix} \langle y_1, y_1 \rangle & \langle y_1, y_2 \rangle & \cdots & \langle y_1, y_n \rangle \\ \langle y_2, y_1 \rangle & \langle y_2, y_2 \rangle & \cdots & \langle y_2, y_n \rangle \\ \vdots & \vdots & \ddots & \vdots \\ \langle y_n, y_1 \rangle & \langle y_n, y_2 \rangle & \cdots & \langle y_n, y_n \rangle \end{pmatrix} \quad (9)$$

可以看出对称双线性特征 f^B 是通过外积聚合得到的矩阵,矩阵内的每个元素是特征图在本通道内激活值的内积。

传统的双线性特征生成过程中,特征的维度扩展为原始通道数的平方,产生了维度爆炸。因此需要进一步的特征降维,一般选择和池化或者多项式近似等方法。显然,本文提出的对称双线性特征 f^B 与一阶特征 f_{low} 具有相同的维度,所以不需要增加额外的降维操作。

为了进一步提高对称双线性特征的表示,对 f_B 进行元素级别的平方根归一化:

$$G = \text{sign}(f^B) \sqrt{|f^B|} \quad (10)$$

其中, sign 是符号函数:

$$\text{sign}(x) = \begin{cases} 1, & x > 0 \\ 0, & x = 0 \\ -1, & x < 0 \end{cases} \quad (11)$$

然后再进行 L_2 正则化:

$$L(f_{low}^v f_{low}) = \frac{\text{sign}(f^B) \times \sqrt{|f^B|}}{\| \text{sign}(f^B) \times \sqrt{|f^B|} \|_2} \quad (12)$$

处理后的特征被缩放至 $[0, 1]$ 。

2) 二阶对称双线性特征分析

网络性能的提升通常伴随着网络复杂度的增加。但如果网络过于复杂,会导致模型的训练和预测消耗大量的时间与内存空间。分布式压力识别任务通常应用于实时监测,网络不能过于复杂。

对称双线性特征 f^B 中每一个元素都是 f_{low} 元素的内积,且压力图像的像素矩阵元素非负。显然,得到的双线性特征是对称的半正定矩阵。由于这种良好的结构对称性,在后续特征的计算与特征图的存储中,可以仅保存三角矩阵,能从根本上降低网络的复杂度。双线性特征 f^B 的尺寸为 $n \times n$,需要的内存个数为 n^2 ,在神经元个数为 m

的全连接层中需要训练的参数数量为:

$$Para = C_{in} \cdot C_{out} + C_{out} = n^2 \cdot m + m \quad (13)$$

在保留三角矩阵后,需要的内存个数仅为 $(1+n)n/2$,而同样在神经元个数为 m 的全连接层中需要训练的参数数量为:

$$Para = \frac{(1+n)n}{2} \cdot m + m = \frac{n^2}{2}m + \frac{n}{2}m + m \quad (14)$$

则由式(13)、(14)可知, HoSB-CNN 在训练和测试中,内存占用将减少 $(n-1)n/2$,网络的训练参数将减少 $mn(n-1)/2$,从根本上降低了网络的空间复杂度和时间复杂度。

协方差矩阵具有重要的统计学意义,包含图像的亮度、梯度及空间位置特征。对边缘信息丰富的灰度图像具有良好的特征描述能力,在不同的分类应用中已得到验证^[14]。对于一个 $n \times n$ 的矩阵 X ,将其改写成向量形式,即 $X = (x_1, x_2, \dots, x_n)$,则对应的协方差矩阵可以表示为:

$$\Sigma(X) = \begin{pmatrix} \text{cov}(x_1, x_1) & \text{cov}(x_1, x_2) & \cdots & \text{cov}(x_1, x_n) \\ \text{cov}(x_2, x_1) & \text{cov}(x_2, x_2) & \cdots & \text{cov}(x_2, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(x_n, x_1) & \text{cov}(x_n, x_2) & \cdots & \text{cov}(x_n, x_n) \end{pmatrix} \quad (15)$$

$$\text{cov}(x, y) = E[(x - \bar{x})(y - \bar{y})] \quad (16)$$

其中, cov 表示协方差计算, $E(\cdot)$ 为求均值计算。显然协方差矩阵与二阶对称双线性特征 f^B 均为对称半正定矩阵。对 f^B 进行去中心化计算,其转换函数如下:

$$f^{B*} = \frac{f^B - \bar{f}^B}{\text{cov}(f^B, f^B)} \quad (17)$$

其中, f^{B*} 是去中心化的对称双线性特征。去中心化的本质的平移,平移后所有的数据中心都变成了 $(0, 0)$,而数据的内部结构和映射关系则不发生变化。显然,当 $X = f^B$ 时,对称的双线性特征与协方差矩阵有以下简单的数学关系:

$$\frac{f^{B*}}{n} = \Sigma(X) = \Sigma(f^B) \quad (18)$$

即对称的双线性特征经过中心化与放缩后,是等价的。因此对称的双线性特征与协方差矩阵具有相同的统计意义。

2.4 多阶多层特征混合

不同阶特征具有不同的特征描述侧重点^[15]。在不增加网络深度和引入额外参数的情况下,提出了多阶多层特征混合,以提高网络的非线性拟合能力和特征的利用效率,如图2中框图所示。特征混合可以表示为:

$$F = f^{1-order} \oplus f^{2-order} \quad (19)$$

在本文中元素相加的方式计算混合特征 F :

$$F = f^{1-order} + g(f_{low} \odot f_{low}) \quad (20)$$

其中, $g(\cdot)$ 表示归一化, 避免过拟合。这里一阶特征 $f^{1-order} \{h_1 \times h_1 \times d_1\}$ 选择高层语义特征, 二阶特征则由低层一阶特征 $f_{low} \{h_2 \times h_2 \times d_2\}$ 产生。但不同层次的特征尺寸和通道数目不同, 因此需要进行特征维度调整。通过 $\{1 \times 1 \times d_1\}$ 的卷积核 (C6) 与 n 倍池化 ($n = h_2/h_1$) (P3) 将对称双线性特征与一阶特征对齐。来自不同层的特征其激活值差别很大, 为了避免特征被覆盖, 在融合前对特征进行 L_2 归一化。如果仅使用一阶网络进行压力识别, 最终用于分类的特征 F 和 CNN 提取到的特征是分段的线性关系, 非线性只出现在二维平面 R^2 的几个一维子空间中。当加入了二阶特征时, 混合特征 F 的非线性几乎存在于 $R^2 = [0, \infty)^2$, 原理示意如图 2 所示。

3 实验与结果分析

3.1 数据集及实验设置

本文通过自建压力字母图像数据集进行实验验证。字母形状轮廓复杂, 能充分体现压力图像的非理想效应, 适合用于验证 HoSB-CNN 的性能。本实验采用的压力数据采集平台如图 5 所示, 包括一个 8×8 传感阵列、可旋转压力计、驱动模块和微控制单元。在实验中, 将带有字母形状凸起的印章贴敷在压力计上, 并向下按压传感阵列。压力范围设置在 $25 \sim 100$ kPa, 压力计旋转角度随机。读出电路以 20 Hz 的频率扫描传感阵列的压力信息后量化至 $[0, 255]$ 区间, 并存储为灰度图像。

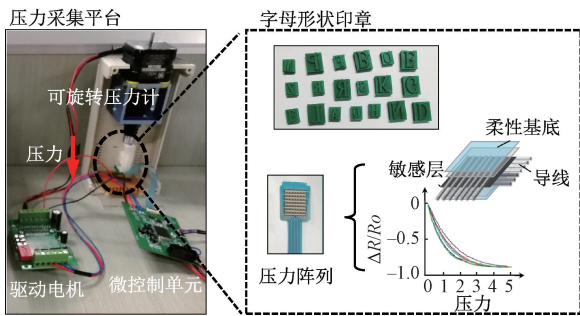


图 5 自建压力数据采集平台

Fig. 5 Self-built pressure data collection platform

根据印章字母的形状, 将样本标记为 A-Z 共计 26 类, 每个字母类别采集 100 个样本。使用数据增强将每类样本扩充至 500 张, 并采用最邻近、双线性内插、三次内插的方法将压力图像统一插值到 32×32 。图 6 是数据集的 26 类样本图片。数据集为 26 个字母类别 (A~Z), 每类样本 500 张, 共计 13 000 张。实验使用 5 倍交叉验证自动划分训练集和验证集。实验基于 MatConvNet 框架与 Intel Core i5-6500 CPU @ 3.2 GHz 硬件平台。优化算法使用 Adam, 初始学习率设置为 0.01 ^[16]。使用 Xavier 算法初始

化 HoSB-CNN 的权重, 超参数分别设置为 $0.9, 0.999, \epsilon = 10^{-8}$ ^[17]。HoSB-CNN 网络的详细参数如表 1 所示。




图 6 压力字母数据集

Fig. 6 Pressure letter dataset

表 1 网络详细参数

Table 1 Detailed parameters of the network

层类别	HoSB-CNN	Baseline1	Baseline2	Baseline3	
输入	$32 \times 32 \times 1$	$32 \times 32 \times 1$	$32 \times 32 \times 1$	$32 \times 32 \times 1$	$32 \times 32 \times 1$
卷积层 C1	$3 \times 3 \times 16$	$5 \times 5 \times 6$	$3 \times 3 \times 16$	$3 \times 3 \times 16$	$5 \times 5 \times 16$
通道注意力	√	-	√	√	√
卷积层 C2	$3 \times 3 \times 16$	-	$3 \times 3 \times 16$	$3 \times 3 \times 16$	-
BN	√	-	√	√	√
双线性特征	$30 \times 30 \times 16$	-	-	-	-
池化层 P1	$2 \times 2, 2$	$2 \times 2, 2$	$2 \times 2, 2$	$2 \times 2, 2$	$2 \times 2, 2$
卷积层 C3	$3 \times 3 \times 32$	$5 \times 5 \times 16$	$3 \times 3 \times 32$	$3 \times 3 \times 32$	$5 \times 5 \times 32$
卷积层 C4	$3 \times 3 \times 32$	-	$3 \times 3 \times 32$	$3 \times 3 \times 32$	$5 \times 5 \times 32$
池化层 P2	$2 \times 2, 2$	$2 \times 2, 2$	$2 \times 2, 2$	$2 \times 2, 2$	$2 \times 2, 2$
卷积层 C5	$3 \times 3 \times 64$	$5 \times 5 \times 16$	$3 \times 3 \times 64$	$3 \times 3 \times 64$	$3 \times 3 \times 64$
双线性特征	-	-	-	$64 \times 64 \times 3 \times 3$	
和池化 SP	-	-	-	$64 \times 64 \times 1$	
全连接层 FC1	100	84	100	100	
全连接层 FC2	26	26	26	26	

3.2 实验结果

1) HoSB-CNN 网络训练与识别性能

为了验证 HoSB-CNN 算法与数据集的匹配性以及设计的合理性, 在训练过程中记录损失和部分卷积层的梯度分布, 如图 7 与 8 所示。结果表明网络的损失在 20 epoch 内迅速下降, 然后趋于平稳, 没有出现欠拟合与过拟合现象。卷积层的梯度在反向传播过程中逐渐增大, 没有在训练过程中出现梯度消失或者梯度爆炸的问题。以上结果说明本文网络模型是合理且与数据集是匹配的。HoSB-CNN 的验证识别准确率达到 98.11% 。将 HoSB-CNN 中通道响应模块移除, 识别准确率为 96.91% , 下降了 1.2% 。

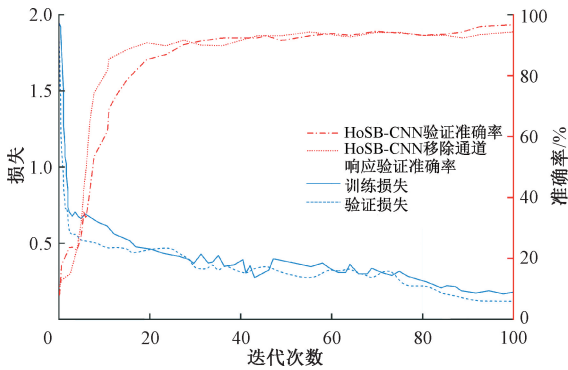


图7 HoSB-CNN 损失与识别准确率

Fig. 7 HoSB-CNN loss and recognition accuracy




图8 HoSB-CNN 梯度分布

Fig. 8 HoSB-CNN gradient distribution

2) HoSB-CNN 与其他算法的性能对比

为了公平验证 HoSB-CNN 的有效性,将本文算法与经典的一阶 CNN、二阶 CNN 及传统的局部特征算法进行了比较。为避免随机情况对实验结果的影响,以下实验均使用重复 5 次的平均识别准确率。网络的具体参数如表 1 所示。

Baseline1 (B1): 经典的一阶 CNN 算法 Lenet-5^[18], 在小尺寸二值图像中取得了良好效果。

Baseline2 (B2): 一阶特征算法,网络的参数设置与 HoSB-CNN 完全一致。该基线移除了双线性特征生成与特征混合模块,用于说明对称双线性特征与多阶多层特征混合的作用。

Baseline3 (B3): 二阶特征算法,经典的双线性算法 Bilinear-CNN^[13]。由于压力图像尺寸小,不能使用原模型中的骨干网络(VGG),因此构建与 HoSB-CNN 网络参数一致的 Bilinear-CNN。

Baseline4 (B4): 使用 SIFT 描述符作为局部特征、训练支持向量机 SVM 作为分类器^[19]。

对比结果如图 9 所示,使用一阶特征的 B1 和 B2 分别获得了 90.40% 和 93.26% 的识别准确率,相较于 HoSB-CNN 分别降低了 7.70% 和 4.85%,充分说明了二阶特征和特征混合的有效性。B3 的准确率达到

96.47%,比 HoSB-CNN 低 1.64%,表明对称双线性特征比传统的双线性特征更适合压力图像的特征提取。B4 获得了 78.55% 的准确率。5 次实验对应的标准差在图 9 中用折线标出, HoSB-CNN 的标准差为 0.53%,略高于一阶 CNN 算法,与二阶 CNN 算法持平。

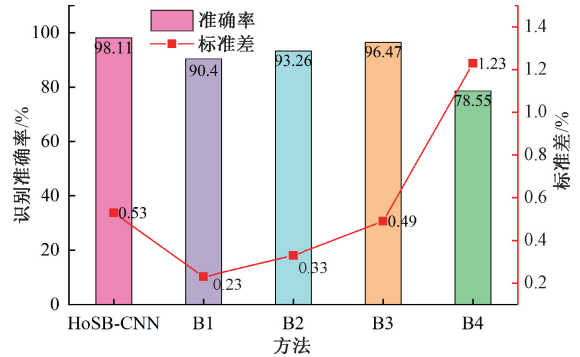


图9 HoSB-CNN 与其他方法的识别性能对比

Fig. 9 Performance comparison of HoSB-CNN with other baselines

为了验证 HoSB-CNN 的复杂度,分别使用几种基准 CNN 算法进行对比,结果如表 2 所示。HoSB-CNN 和主流的二阶 Bilinear-CNN 相比(B3),计算量减少 35.99%,可训练参数量降低一个数量级,推理时间减少 0.014 ms/张,内存占用量减少 78.81%。这是因为对称双线性特征的产生本身不额外引入需要学习的参数,仅进行矩阵内积计算,特征整体内积计算不涉及特征通道维度的平方。

表2 HoSB-CNN 网络复杂度

Table 2 Network complexity of HoSB-CNN

方法	FLOPs	推理时间 /ms	可训练参数量/kB	内存占用量/MB
HoSB-CNN	3.81×10^6	0.475	43.31	17.2
Baseline1	4.23×10^5	0.450	241.04	4.43
Baseline2	3.78×10^6	0.474	42.25	11.41
Baseline3	5.95×10^6	0.489	2 119.68	81.17

3) 对称双线性特征与多阶多层特征融合的性能分析

为了说明对称双线性特征和多阶多层特征混合对网络性能提升的贡献,比较了 HoSB-CNN 与一阶算法不同层特征的准确性,结果如表 3 所示。通过比较 HoSB-CNN 中 C1 层和 C1^B 的准确率,可以看出,对称双线性特征显著提高了特征的可分性。C1^B 的准确率相比 C1 提高了 17.1%。不同阶的特征首先进行融合,然后送入 FC1,通过比较每个网络 FC1 的准确性,可以进一步明确特征混合的有效性。与不添加融合模块的 B2 相比,FC1 的准确率增加了 4.6%。

通过比较 HoSB-CNN 中不同层、不同阶特征的融合效果,可以说明多阶多层融合特征的性能。包含不同层组合的 F-C1 识别准确率如表 4 所示。可以看出,包含二阶特征的混合组比一阶特征混合组的识别率更高。另外,组合中包含局部特征的卷积层越靠近输入端,混合特征的可分性越强。因为对于低分辨率的压力图像,低层特征尺寸更大,包含丰富的边缘信息,更有利于产生对边缘和纹理敏感的二阶特征。C1^B 和 C5 特征的组合取得了最高的准确率 94.7%,比一阶混合组 C1 和 C5 的识别率高 3.9%。以上结果说明了利用多阶多层特征的互补性可以提高网络的非线性拟合能力。

表 3 HoSB-CNN 各层识别准确率

Table 3 Recognition accuracy of HoSB-CNN for each layer

网络	C1	C1 ^B	C2	C3	C4	C5	FC1
HoSB-CNN	41.0	57.1	53.1	65.5	77.6	84.4	94.7
B2(一阶 CNN)	41.1	-	53.2	64.8	76.9	85.1	90.1

表 4 HoSB-CNN 不同层组合识别准确率

Table 4 Recognition accuracy of HoSB-CNN with different layer combinations

多层多阶组合	准确率/%	多层一阶组合	准确率/%
C1 ^B +C5	94.7	C1+C5	90.8
C2 ^B +C5	93.6	C2+C5	91.6
C3 ^B +C5	93.5	C3+C5	92.1
C4 ^B +C5	93.3	C4+C5	92.3

4 结 论

本文针对分布式压力识别存在低分辨率和边缘模糊的非理想效应,提出了 HoSB-CNN 算法并构建具有复杂形状的压力字母数据集用于算法验证,获得了 98.11% 的识别准确率。本文的主要贡献在于:1) 构建了通道注意力响应 CNN,依照对分类结果的重要性为特征分配不同权值,提升一阶 CNN 特征的描述能力。2) 提出了二阶对称双线性特征,提高网络对纹理和边缘的敏感度,且不涉及特征维度爆炸,不需要特征的降维操作。3) 二阶对称双线性特征具有结构对称性,可以在特征传递与储存中仅保留三角矩阵,简化网络复杂度。4) 建立多阶多层混合特征,充分利用 CNN 不同层不同阶的互补优势,促进特征利用效率,提升网络的非线性拟合能力。

本文提出的 HoSB-CNN 在不增加网络深度的情况下

提高了网络的特征提取能力和利用效率,取得了更高的识别准确性。此外,由于非理想的原始数据、环境干扰和其他因素,小尺寸和低分辨率的输入在实际识别任务中很常见。因此,本文提出的算法是一个新的通用框架,可以扩展到不同的实际应用中。

参考文献

- [1] WU X A, HUH T M, SABIN A, et al. Tactile sensing and terrain-based gait control for small legged robots[J]. IEEE Transactions on Robotics, 2020,36(1): 15-27.
- [2] 陆熊,陈晓丽,孙浩浩,等. 面向自然人机交互的力触觉再现方法综述[J]. 仪器仪表学报,2017,38(10): 2391-2399.
LU X, CHEN X L, SUN H H, et al. Haptic rendering methods for natural human computer interaction: A review [J]. Chinese Journal of Scientific Instrument, 2017,38(10):2391-2399.
- [3] 吴一川,孟欢欢,黄启洋,等. 面向触觉力反馈的可穿戴柔性执行器研究现状[J]. 仪器仪表学报,2021,42(9):244-252.
WU Y CH, MENG H H, HUANG Q Y, et al. Research status of wearable and flexible actuators for haptic force feedback [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 244-252.
- [4] SHAN L, BIMBO J, DAHIYA R, et al. Robotic tactile perception of object properties: A review [J]. Mechatronics, 2017, 48:54-67.
- [5] VOULODIMOS A, DOULAMIS N, DOULAMIS A, et al. Deep learning for computer vision: A brief review [J]. Computational Intelligence and Neuroscience, 2018: 1-13.
- [6] 李铁军,刘应心,刘今越,等. 基于阵列式触觉传感器的操作意图实时感知[J]. 仪器仪表学报,2020,41(1):100-112.
LI T J, LIU Y X, LIU J Y, et al. Real-time perception of operational intention based on arrayed tactile sensors[J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 100-112.
- [7] PASTOR F, GANDARIAS J M, GARCÍA-CEREZO A J, et al. Using 3D convolutional neural networks for tactile object recognition with robotic palpation [J]. Sensors, 2019, 19(24): 5356.
- [8] CAO L, SUN F, LIU X, et al. End-to-end ConvNet for tactile recognition using residual orthogonal tiling and pyramid convolution ensemble [J]. Cognitive Computation, 2018, 10(7): 1-19.

- [9] CHU J, CAI J. Flexible pressure sensors with a highly pressure-and strain-sensitive layer based on nitroxyl radical-grafted hollow carbon spheres [J]. *Nanoscale*, 2020, 12: 9375-9384.
- [10] GLOROT X, BOR DE S A, BENGIO Y. Deep sparse rectifier neural networks [C]. *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics*, Fort Lauderdale, USA, 2011:315-323.
- [11] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. *Proceedings of 2018 IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7132-7141.
- [12] CARREIRA J, RUI C, BATISTA J, et al. Semantic segmentation with second-order pooling [C]. *Proceedings of the 12th European Conference on Computer Vision*, Florence, Italy, 2012: 430-443.
- [13] LIN T Y, ROYCHOWDHURY A, MAJI S. Bilinear convolutional neural networks for fine-grained visual recognition [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2018, 40(6): 1309-1322.
- [14] WON J H, LIM J, KIM S J, et al. Condition-number-regularized covariance estimation [J]. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 2013, 75(3):427-450.
- [15] YU W, YANG K, YAO H, et al. Exploiting the complementary strengths of multi-layer CNN features for image retrieval [J]. *Neurocomputing*, 2016, 237: 235-241.
- [16] KINGMA D, BA J. Adam: A method for stochastic optimization [J]. *ArXiv Preprint*, 2014, ArXiv: 1412.6980.
- [17] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [J]. *Journal of Machine Learning Research*, 2010, 9: 249-256.
- [18] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [19] LUO S, MOU W, ALTHOEFER K, et al. Novel tactile-sift descriptor for object shape recognition [J]. *IEEE Sensors Journal*, 2015, 15(9): 5001-5009.


作者简介



褚洁, 2014 年于西安电子科技大学获得学士学位, 现为西安电子科技大学博士研究生, 主要方向为智能传感与机器学习。

E-mail: jiechu@stu.xidian.edu.cn

Chu Jie received her B.Sc. degree from Xidian University in 2014. She is currently a Ph.D. candidate at Xidian University. Her main research interests include machine learning and intelligent sensor.



蔡觉平(通信作者), 1998 年与 2001 年于西安电子科技大学分别获得学士与硕士学位, 2004 年于上海交通大学获得博士学位, 现为西安电子科技大学教授、博士生导师, 主要方向为信号处理, 人工智能芯片技术等。

E-mail: jpcai@mail.xidian.edu.cn


Cai Jueping (Corresponding author) received his B.Sc. and M.Sc. degrees both from Xidian University in 1998 and 2001, and received his Ph.D. degree from Shanghai Jiao Tong University in 2004. He is currently a professor at Xidian University. His research interests include signal processing, artificial intelligence chip technology, etc.



李龙, 2010 年、2013 年与 2020 年于西安交通大学分别获得学士学位、硕士学位与博士学位。现为国网陕西省电力有限公司电力科学研究院工程师, 主要研究方向为信号处理, 人工智能算法等。

E-mail: lilong217@163.com

Li Long received his B.Sc. degree, M.Sc. degree and Ph.D. degree all from Xi'an Jiaotong University in 2010, 2013 and 2020, respectively. He is currently an engineer at State Grid Shaanxi Electric Power Research Institute. His main research interests include signal processing and artificial intelligence algorithm.



王帅利, 2020 于西安电子科技大学获得学士学位。现为西安电子科技大学硕士研究生, 主要研究方向为机器学习。

E-mail: slwang1016@163.com

Wang Shuaili received his B.Sc. degree from Xidian University in 2020. He is currently pursuing his master degree at Xidian University. His main research interest is machine learning.