

基于卷积神经网络的激光距离选通式成像目标识别

王书宇*, 陶声祥, 杨钊, 艾磊

陆军炮兵防空兵学院, 安徽 合肥 230031

摘要 为解决距离选通式激光成像中由于图像模糊而导致目标识别率偏低的难题, 提出一种保留特征的卷积神经网络(KFCNN)模型, 用于激光选通图像中的目标识别。与传统的卷积神经网络不同, KFCNN 使用一个特征保留层来提高模糊目标的识别率, 提高目标识别的稳健性。为实现特征保留, KFCNN 通过增加特征保留约束项及正则化来优化特征保留目标函数并进行训练, 通过减小特征保留目标函数值来保证训练样本在模糊之前和之后的特征映射相一致。实验结果表明, KFCNN 改善了因模糊造成识别率降低的问题, 进而提升了距离选通式激光成像中对指定目标的识别率。

关键词 图像处理; 距离选通; 卷积神经网络; 模糊图像; 目标识别; 特征保留

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP56.021001

Laser Range-Gated Imaging Target Recognition Based on Convolutional Neural Network

Wang Shuyu*, Tao Shengxiang, Yang Fan, Ai Lei

Army Artillery Air Defense Academy of PLA, Hefei, Anhui 230031, China

Abstract In order to solve the difficult problem of low target recognition rate caused by image blur in the laser range-gated imaging process, we propose the keep-feature convolutional neural network (KFCNN) model for the target recognition of laser range-gated images. Different from the convolutional neural network (CNN), the KFCNN model is used to improve the recognition rate of blurred targets and the robustness of target recognition with a new keep-feature layer. To achieve keep-feature in the KFCNN model, we optimize the keep-feature objective functions and the training by imposing keep-feature constraints and regularization. In addition, the feature maps of training samples are kept consistent before and after image blur when the value of the keep-feature objective function is reduced. The experimental results show that KFCNN improves the problem of recognition rate reduction caused by image blur and further improves the recognition rate of specified targets in laser range-gated imaging.

Key words image processing; rang-gate; convolutional neural network; blur image; target recognition; keep-feature

OCIS codes 100.2960; 100.4996; 110.1758

1 引言

激光选通成像技术具有探测距离远、可夜间成像等优点, 同时对雨、雪、雾有一定穿透能力, 近年来受到国内外的广泛关注。在光电跟踪系统中要想对运动目标进行实时跟踪, 仅获取目标成像是不够的, 最关键的是如何提高目标识别的准确率。由于激光选通图像本身相对模糊, 传统做法是利用 BP(back propagation)神经网络进行目标识

别, 文献[1]中使用多层感知器神经网络对陆上军事目标进行自动识别, 文献[2]中通过提取 7 个不变 Hu 矩构成特征量, 再用 136 个权值组成的 BP 神经网络算法对黑夜条件下 450 m 运动目标进行识别, 其识别率达到了 68.87%。文献[3]中采用双隐含层 BP 神经网络算法对目标进行识别, 对 550 m 处的目标识别率达到 72.11%。文献[4]中使用粗糙集与神经网络相结合的方法, 将粗糙集算法简约后的样本特征作为神经网络的前置输

收稿日期: 2018-06-22; 修回日期: 2018-06-25; 录用日期: 2018-07-26

* E-mail: 1512264822@qq.com

人,识别正确率大约为 80%。

卷积神经网络(CNN)是在 BP 神经网络基础上发展起来的一种多层前馈深度学习模型,可以直接输入图像,通过多隐层结构自动学习特征,避免了手工提取特征识别流程复杂以及应用场景单一的问题。诸多实验已经证实卷积神经网络比传统 BP 神经网络在目标识别上有更好的效果^[5-6]。

2014 年牛津大学 VGG 在 ILSVRC 提出了 VGG 模型^[7]。VGG 具有比传统 CNN 更深层的结构,因此处理的训练数据更多,能提取到更全局更抽象的特征,网络拟合能力更强。因此本文以 VGG 网络结构为基础,提出新的特征保留卷积神经网络(KFCNN)模型。通过对目标函数增加特征保留约束项,通过最小化特征保留目标函数,使得图像模糊前后共享相似的特征,完成特征保留层的学习。同时,为了增加网络泛化能力,训练新增的特征保留层,固定其余的模型参数,然后以较小的学习速率对整个 KFCNN 模型进行专门微调,以进一步提高性能。最后,使用测试集对 KFCNN 进行全面评估,并与文献[3]中提出的使用双隐含层 BP 神经网络进行识别的算法和文献[4]中提出的使用粗糙集与神经网络相结合的算法进行比较。实验结果表明,KFCNN 模型提高了激光选通图像中各类目标的识别准确率,从而证明了所提方法的可行性、有效性以及稳健性。

2 激光选通成像工作原理与图像分析

2.1 距离选通成像原理

激光距离选通成像系统的工作过程如图 1 所示,激光器发射激光脉冲对目标进行照射(T_0 时刻),其激光脉冲在传输过程中,部分激光被大气颗

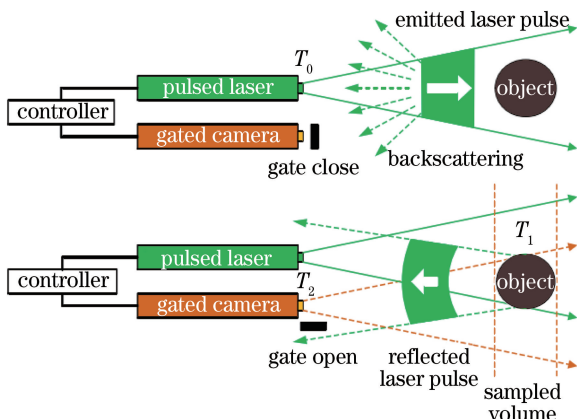


图 1 激光距离选通成像系统工作原理图

Fig. 1 Working principle of laser rang-gated imaging

粒散射或被中间物体反射回来时(T_1 时刻),接收器的选通门处于关闭状态,从而拒绝了大气的后向反射及背景杂波。只有当目标区域反射回的激光信号到达接收器时,选通门才打开(T_2 时刻),对目标区域进行成像,之后再次关闭选通门。

2.2 图像分析

空气中充满各种烟雾和粉尘,激光在碰到颗粒时会产生后向散射,虽然通过选通门能够滤除非目标区域内的后向散射光,但目标区域内被烟雾和粉尘反射的激光会进入成像系统,进而在像平面上产生附加噪声,同时颗粒还会使光波发生衍射形成“相位光栅”。入射光波相位发生变化并在空间发生干涉,表现在图像上,即形成无规则分布的颗粒形状的散斑图像。同时,像增强器中存在由荧光屏的低通性和电源纹波引起的光电噪声,使图像对比度降低,出现噪声。以上因素使采用激光距离选通获得的图像比较模糊,同时缺少彩色特征。

3 基于 KFCNN 方法

3.1 VGG 网络模型

VGG 是一种典型的具有较高识别率的深度学习模型,该模型能够通过多隐层结构自动学习到图像中的典型特征^[8]。VGG16 具有深层次的结构和尺寸较小的卷积核(3×3),比传统 CNN 拥有更多优点。VGG16 模型是由 16 个加权层组成,包括 13 层卷积层、5 层池化层和 3 层全连接层。VGG 网络深度比传统卷积神经网络更深,而且所有卷积层使用的卷积核大小均为 3×3 。多个小尺寸卷积核的卷积层比一个大尺寸卷积层的参数要少,而且能够在不影响视野域的情况下增加其映射函数的非线性,另外较小的卷积核也使 VGG 网络更具有判别性^[9]。

3.2 KFCNN 模型

由于 VGG 具有良好的判别性,因此在 VGG 网络结构的基础上提出了一种保留特征卷积神经网络激光选通目标识别方法,该方法用于识别 6 类激光选通目标,其系统结构图如图 2 所示。该系统以 KFCNN 作为核心,KFCNN 前 13 层加载已由 VGG16 网络在 CIFAR10 训练集上事先训练好的参数,通过对剩余网络层设定一个相对较大的学习率进行训练,再以较小的学习率微调 KFCNN。使用 CIFAR10 大量图像训练的参数,作为 KFCNN 模型的起点,便于训练网络。与 VGG16 不同的是,增加的特征保留层,通过特征保留约束项,使模糊

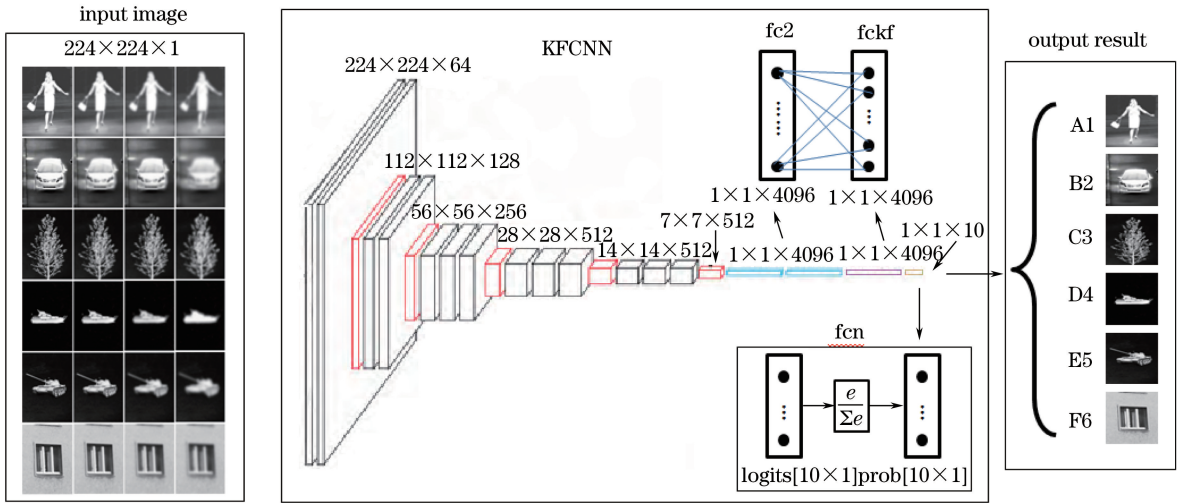


图 2 保留特征卷积神经网络激光选通目标识别系统结构图

Fig. 2 Structural diagram of laser rang-gated target recognition by KFCNN

图像与清晰图像的特征差距趋于无穷小,网络实现特征保留。当模糊的激光选通图像通过该识别系统时,得到的 KFCNN 特征表达与其清晰图像的特征表达相似,再通过 softmax 判别^[10],模糊图像可以与清晰图像一样得到较高的识别率,从而得出目标识别的结果。

KFCNN 由 13 个卷积层、3 个全连接层和 1 个特征保留层串联组成。首先,KFCNN 前 14 层网络结构和 VGG 网络的前 15 层结构一致,由 13 个卷积池化层和 2 个全连接层组成,其次是 fckf 特征保留层,最后使用 softmax 判别的 fcn 层作为 KFCNN 输出。网络最终输出的类别是 6 类目标,fcn 由 10 个神经元组成。fckf 层的输出作为 fcn 层的输入,通过自学习特征保留层,完成 KFCNN 模型的设计。

为了便于训练和避免过度拟合,将通过 CIFAR10 训练的 VGG 前 13 层的网络权重直接加载到 KFCNN 的前 13 层,然后以较小的学习速率对特征保留层和全连接层进行微调。目标函数是网络拟合数据真实分布的一个重要指标^[11],KFCNN 优化了目标函数多项式回归方程,使其更符合模糊图像数据分布。清晰图像作为学习样本,通过增加特征保留约束项,使最小经验误差加上先验知识特征保留的约束,使模糊图像和清晰图像共享相似特征。优化目标函数时,使其向特征保留方向降低梯度,使最终解接近数据的真实分布,同时避免过度拟合^[12]。另外,由于激光选通图像是灰度图,为适应 VGG 网络图像输入格式要求,采用 3 个 1×1 的卷

积核对输入图像进行通道变换。

给定训练样本 $X = \{x_i\}$ 和对应的标签 $Y = \{y_i | x_i \in X\}$,其中 y_i 表示为样本的真值标签向量,仅有一个元素为 1,其余均为 0。通过输入目标对 (X, Y) 训练一个 KFCNN 模型。对于训练样本 X ,fc2 层的输出特征是 $O_2(x_i)$ 。同时, $O_2(x_i)$ 作为特征保留层 fckf 的输入,经过 fckf 层的输出结果是 $O_b(x_i)$,最后, $O_b(x_i)$ 经过 fcn 层输出而得到 $O_n(x_i)$ 。如图 3 所示,softmax 函数将 logits 变换为概率向量,用来表示输入样本属于每个输出类的概率。 (W_{bi}, B_{bi}) 和 (W_{ni}, B_{ni}) 为 fckf 层和 fcn 层的网络参数, W 为该层网络的权重, B 为网络偏置。

$$O_b(x_i) = \text{relu} [W_{bi}O_2(x_i) + B_{bi}], \quad (1)$$

$$O_n(x_i) = \text{softmax} [W_{ni}O_b(x_i) + B_{ni}], \quad (2)$$

式中: $\text{relu}(x) = \max(0, x)$, $\text{softmax } x = \exp x / \|\exp x\|_1$, B_b 为由 B_{bi} 组成的矩阵, B_n 为由 B_{ni} 组成的矩阵。在给定训练样本和对应标签的情况下,除了要求 KFCNN 应尽量减少训练数据集上的错误识别误差外,还需特别要求 KFCNN 模型具有任意一组训练样本的特征保留能力。将模糊图像 x_i 与清晰图像样本 y_i 的特征距离作为特征保留约束,则特征保留卷积神经网络算法表示为目标函数最优化解问题。因此,提出了一个新的学习目标函数:

$$J(W, B) = \min \times \left[S(X, Y) + \lambda_1 D(x_i, y_i) + \frac{\lambda_2}{2} \|W\|_2^2 \right], \quad (3)$$

式中: $S(X, Y)$ 为 softmax 损失函数; $\lambda_1 D(x_i, y_i)$ 为特征保留约束项, $\lambda_2 \|W\|_2^2 / 2$ 为权值衰减项,其中

λ_1 和 λ_2 是控制(3)式中3项相对关系重要性的两个权衡参数, $\|\cdot\|_2$ 表示求取2范数。

令损失最小化, softmax 损失函数表示为

$$S(X, Y) = -\frac{1}{N} \sum \langle \mathbf{y}_i, \lg \mathbf{O}_n(\mathbf{x}_i) \rangle, \quad (4)$$

式中: N 代表输入样本的个数。(4)式采用交叉熵方式计算 softmax 分类损失。

特征保留约束项 $\lambda_1 B(\mathbf{x}_i, \mathbf{y}_i)$ 使原数据样本 \mathbf{x}_i 和模糊处理后的样本 \mathbf{y}_i 共享相似的特征, 通过定义的特征保留约束项公式, 使图像模糊前后的 KFCNN 特征距离实现最小化, 使模糊图像与清晰样本特征误差尽可能小。如果该项的结果是一个很小的值, 则特征表示为模糊近似不变, 将特征保留约束项公式展开得到

$$D(\mathbf{x}_i, \mathbf{y}_i) = \sqrt{\sum |\mathbf{O}_b(\mathbf{x}_i) - \mathbf{O}_b(\mathbf{y}_i)|}. \quad (5)$$

(3)式第3项为权值衰减项, 用它降低网络权重的大小, 以防止网络出现过拟合的现象, 进一步提高网络的泛化能力。由(3)式定义的目标函数不仅能实现识别损失最小化, 还定义了一个特征保留约束项来实现特征的保留性。在实验过程中, 使用随机梯度下降(SGD)方法来解决优化问题。 J_{x_i} 为单个样本 \mathbf{x}_i 的目标函数值, W_k 为网络权重, η 为学习率。

$$W_k^* = W_k - \eta \frac{dJ_{x_i}}{dW_k}, \quad (6)$$

$$\frac{dJ}{dW} = -\frac{1}{N} \sum_{i=1}^N (\mathbf{a}_i - \mathbf{y}_i) \mathbf{x}_i^T + \sum_{i=1}^N \frac{\mathbf{O}_b(\mathbf{x}_i) - \mathbf{O}_b(\mathbf{y}_i)}{\sqrt{\|\mathbf{O}_b(\mathbf{x}_i) - \mathbf{O}_b(\mathbf{y}_i)\|_2}} (\mathbf{x}_i - \mathbf{y}_i) + \lambda_2 W, \quad (7)$$

式中: $\mathbf{a}_i = \exp(\mathbf{y}_i) / \sum_k \exp(\mathbf{y}_k)$, $k = b, n$ 。

由于交叉熵能判定神经网络实际输出与期望输出的距离^[13], 通过使交叉熵损失最小化, 调整 KFCNN 权重, 最终得出深度特征, 用于选通目标的识别。fcn 层最终识别结果由概率值最大的输出向量元素确定, 具体数值通过 softmax 函数计算, 其样本对应概率最大的类别。

3.3 基于 KFCNN 识别过程

基于 KFCNN 实现过程, 主要有以下3个步骤:

1) 建立样本库

识别的目标共有6类: 人、汽车、树、船、坦克、窗口。通过实际实验取得每类目标图像100张, 共计600张。实验参数为: 半导体激光器波长为860 nm, 重复频率为750 Hz, 脉冲宽度为80 ns, 增强电荷耦合器件

(ICCD)快门时间设为100 ns, 选通门步进为10 ns, 镜头焦距为410 mm, 口径为290 mm, 透过率为0.9。

由于通过实际实验难以获取大量训练样本, 所以本研究通过仿真获取更多样本。具体方法是使用 Unity3D 搭建仿真环境, 放置目标模型, 环境设置为黑夜, 用柱状光源模拟激光, 根据选通距离设定目标和环境物体表面的反光程度, 获取清晰的模拟激光选通成像效果。基于清晰图像集 \mathbf{x}_i , 需要作一些模糊处理。定义8个不同的模糊尺度, 模糊尺度分别为1, 2, 3, 4, 5, 6, 7, 8, 对原始数据集通过模糊变换, 完成选通图像模糊数据集($\mathbf{y}_1 - \mathbf{y}_8$)的制作。使用模糊处理之前 \mathbf{x}_i 和模糊处理之后 \mathbf{y}_i ($\mathbf{y}_1 - \mathbf{y}_8$) 作为总训练样本, 用于训练本文提出的 KFCNN 模型。

训练集共有30000张, 交叉验证集6000张, 测试集6000张。实验中所有图片大小均为 224×224 , 每张图片均作归一化处理。图3是本文数据集中6种识别目标的部分图集, 每一类8张样本图像分别表示模糊尺度从1依次增大到8。

2) KFCNN 训练

KFCNN 训练流程图如图4所示, 首先将 VGG16 上针对 CIFAR-10 预训练参数迁移至 KFCNN 对应网络, 全连接层的学习率为0.001, 其余层学习率为0.0001, 训练的 batchsize 为32, λ_1 为0.01, λ_2 为0.005, 迭代次数为20000。

训练样本 X 输入参数迁移后的 KFCNN, 图片中每个像素乘以滤波器的值再进行求和运算, 第一层卷积层有64个滤波器, 步长设为1, 得到的卷积层输出特征图为张量 $[32, 64, 224, 224]$ 。此张量通过激活函数 ReLU 增加映射函数的非线性^[14]。

经过两次卷积之后进行池化, 本研究采用最大池化, 选用 2×2 的滤波器, 步长为2, 经过池化后, 数据特征在保留有用信息之后数据量减少一半^[15]。

最后, 经过后面的13个卷积池化层, 得到图像的分布式特征, 全连接层将该特征线性变换到样本标签标记空间。经过特征保留层, 增加特征保留约束项, 最小化模糊图像的特征与清晰图像的特征距离, 使模糊图像接近清晰样本的特征向量, 从而实现特征保留层。计算网络输出值 \mathbf{O}_n 与样本标签 \mathbf{e} 的误差 E :

$$E = \frac{1}{2} \sum |\mathbf{e} - \mathbf{O}_n|^2, \quad (8)$$

式中: $\mathbf{e} = [f_1, f_2, f_3, f_4, f_5, f_6]$, 当该样本属于 i 类别时, 则 f_i 为1, 其余均为0。

根据误差计算权值和偏置调整量, ΔW_{ij} 为输入层到隐含层权重调整量, ΔV_{jk} 为隐含层到输出层权




图3 激光选通目标部分图集

Fig. 3 Partial atlas of laser rang-gated targets

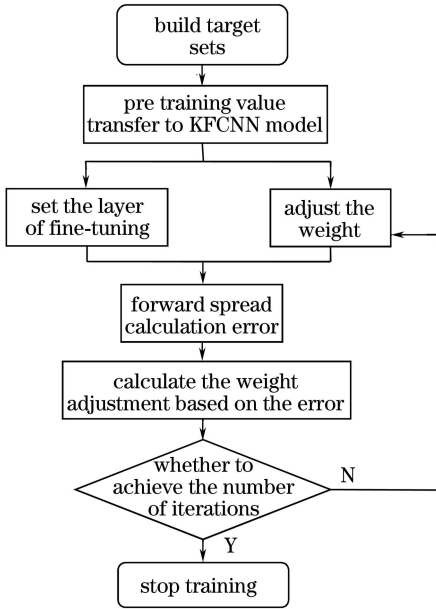


图4 KFCNN 训练流程图

Fig. 4 Flow chart of KFCNN training

值调整量,分别表示为

$$\Delta W_{ij} = -\eta \frac{\partial E}{\partial W_{ij}}, \quad (9)$$

$$\Delta V_{jk} = -\eta \frac{\partial E}{\partial V_{jk}}, \quad (10)$$

式中: W_{ij} 为输入层到隐藏层权值; V_{jk} 为隐藏层到输出层权值调整量。

根据权值调整量,调整网络权值:

$$W_{ij}(t+1) = W_{ij}(t) + \Delta W_{ij} =$$

$$W_{ij}(t) + \eta(e - O_n)O_n(1 - O_n)Y_{out}, \quad (11)$$

$$V_{jk}(t+1) = V_{jk}(t) + \Delta V_{jk} = V_{jk}(t) +$$

$$\eta\{(e - O_n)O_n(1 - O_n)\}W_j Y_{out}(1 - Y_{out})X_{in}, \quad (12)$$

式中: X_{in} 为隐含层的输出向量, Y_{out} 为隐含层的输出向量。

将调整量经过反向传播反馈到 KFCNN 权值,完成一次网络训练,直到达到迭代次数网络结束训练^[16]。

本实验使用 SGD 进行误差的反向传播,随机梯度下降要求仔细调整学习率和初始参数值^[17]。使用 Batch Normalization 对神经元作归一化处理,协调网络整体参数,提高 KFCNN 的收敛速度,提升该网络泛化能力^[18]。

4 实验结果与验证

为验证特征保留层的作用,分别提取 VGG16 和 KFCNN 的特征向量进行对比。从 4096 维度的特征向量中随机抽取 64 维绘制成为直方图。以人体目标为例,选取清晰样本和模糊尺度为 2、5、8 的样本图集,分别提取两种神经网络的特征向量,并将随机抽取的 64 维特征绘制为直方图。

图 5(a)展示了人体样本图,包括清晰的人体样本以及模糊尺度为 2、5、8 的模糊人体样本;图 5(b)是由 VGG16 网络提取对应样本的特征向量直方图;图 5(c)是通过具有特征保留层的 KFCNN 提取




图5 特征直方图。(a)人体样本;(b) VGG16 对应的直方图;(c) KFCNN 对应的直方图

Fig. 5 Feature histograms. (a) Body samples; (b) histograms corresponding to VGG16; (c) histograms corresponding to KFCNN

到的特征向量直方图。由图 5(b)所示,VGG 网络面对不同模糊尺度的样本提取出来的直方图特征,各不相同,容易降低网络识别的精确度。而从图 5(c)中可以看到,KFCNN 面对不同模糊尺度的样本提取出来的直方图特征,基本上与清晰图像相同,这使得模糊图像具有更高的判别性。因此 KFCNN 具备特征保留性,能极大改善距离选通图像模糊情况下的识别率较低问题。

为进一步验证 KFCNN 模型的性能,将 KFCNN 模型与对激光距离选通图像识别效果较好的两个算法进行比较。一个是文献[3]中的双隐含层 BP 神经网络算法,另外一个为文献[4]中使用的粗糙集与神经网络相结合的方法。这两个算法对目标都能达到较高的识别率。同时在对比实验中,针对 KFCNN 模型,分别测试了采用微调 and 单独训练两种方式,即微调 KFCNN 模型和无微调 KFCNN 模型。

本文采用模糊尺度为 6 的测试集 830 张,对 KFCNN、文献[3]中的算法、文献[4]中的算法、VGG 模型进行测试,计算出平均识别率。针对人体的识别率计算表达式为

$$A_c = \frac{\sum_{i=1}^Q n}{M}, \quad (13)$$

表 1 各类算法在不同模糊尺度人体图像上的平均识别率

Table 1 Average recognition rates of different algorithms for human images with different blur scales

| Blur scale | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 |
|---------------------------|-------|-------|-------|-------|-------|-------|-------|-------|
| Algorithm in Ref. [3] | 72.05 | 75.72 | 74.01 | 73.51 | 78.50 | 79.15 | 74.33 | 74.58 |
| Algorithm in Ref. [4] | 83.55 | 89.43 | 82.60 | 85.67 | 87.25 | 82.33 | 86.70 | 89.25 |
| VGG16 | 90.26 | 94.22 | 92.37 | 89.16 | 86.47 | 81.71 | 77.83 | 74.32 |
| KFCNN without fine-tuning | 92.34 | 93.41 | 95.02 | 91.78 | 94.34 | 94.02 | 91.98 | 92.56 |
| KFCNN with fine-tuning | 98.91 | 98.53 | 97.65 | 96.75 | 95.12 | 95.47 | 91.57 | 96.94 |

为验证 KFCNN 模型的实时性,通过 10 张人体图像测试算法的识别时间,并与文献[3]中算法和 VGG16 网络进行对比,结果如表 2 所示。实验配置如下:CPU 为 Intel i5-8400 (2.50 GHz),显卡为 GTX1060,内存为 16 G。

表 2 各算法的实时识别时间

Table 2 Real-time computing time of different algorithms

| Model | Algorithm in Ref. [3] | VGG16 | KFCNN with fine-tuning |
|---------------------|-----------------------|-------|------------------------|
| Recognition time /s | 11.057 | 9.635 | 10.217 |

5 结 论

为了解决由于选通图像模糊而导致目标识别率

式中: n 为每种类别里识别正确的样本数量; Q 为样本类别; M 为样本总数。

实验中,同时测试 VGG16、文献[3]中算法、文献[4]中算法、无微调 KFCNN 和微调后的 KFCNN 在不同模糊尺度的人体图像上的平均识别率,进行对比。所选数据包括模糊尺度为 1,2,3,4,5,6,7,8 的图像各 730 张。按照 KFCNN 模型进行训练后,使用不同模糊尺度的人体图像样本测试集测试网络,得到如图 6 和表 1 所示各个算法的识别率。对照上述各种算法平均识别率可以验证该系统的有效性,以及 KFCNN 具有的特征保留性、泛化能力及稳健性。

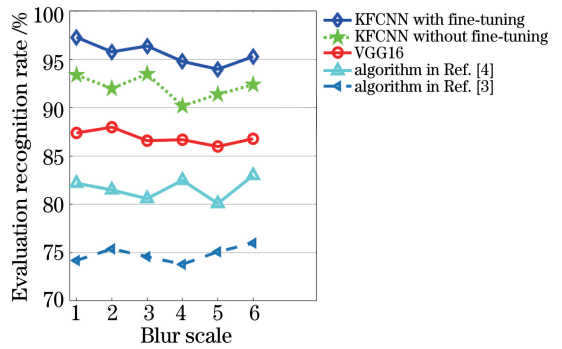


图 6 各类算法下的网络平均识别率

Fig. 6 Average recognition rates of different algorithms

偏低的问题,提出了一种新的有效的 KFCNN 模型。优化目标函数,使模糊前后训练样本的特征向量一致。KFCNN 预先加载了 VGG16 前 13 层在 CIFAR10 训练的权重,通过清晰图像和具有不同尺度的模糊图像样本库对 KFCNN 进行训练。同时在 VGG、文献[3]中的算法、文献[4]中的算法和 KFCNN 微调网络以及 KFCNN 无微调网络进行模糊图像类型识别测试,与 VGG 方法以及文献[3]中的算法、文献[4]中的算法相比,KFCNN 模型显著地提高了在模糊的激光选通图像中目标识别率,该方法可以准确识别目标类型。

参 考 文 献

[1] Göztepe K. Automatic target recognition on land

- using three dimensional (3D) laser radar and artificial neural networks [J]. The South African Journal of Industrial Engineering, 2013, 24(1): 107-120.
- [2] Zhao J C, Wang D N, Chen C Q, *et al.* Infrared laser active imaging and recognition technology [J]. Chinese Optics, 2013, 6(5): 795-802.
赵建川, 王弟男, 陈长青, 等. 红外激光主动成像和识别 [J]. 中国光学, 2013, 6(5): 795-802.
- [3] Wang C J, Sun T, Shi N N, *et al.* Laser active imaging and recognition system based on double hidden layer BP algorithm [J]. Optics and Precision Engineering, 2014, 22(6): 1639-1647.
王灿进, 孙涛, 石宁宁, 等. 基于双隐含层 BP 算法的激光主动成像识别系统 [J]. 光学精密工程, 2014, 22(6): 1639-1647.
- [4] Li Y C, Fan Y C. 3-D target recognition algorithm of laser image based on rough set and neural network [J]. Laser and Infrared, 2014, 44(6): 676-681.
李迎春, 范有臣. 一种创新性激光图像三维目标识别算法 [J]. 激光与红外, 2014, 44(6): 676-681.
- [5] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [6] Liu D W, Han L, Han X Y. High spatial resolution remote sensing image classification based on deep learning [J]. Acta Optica Sinica, 2016, 36(4): 0428001.
刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究 [J]. 光学学报, 2016, 36(4): 0428001.
- [7] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J/OL]. 2014 [2018-05-25]. <https://arxiv.org/abs/1409.1556>.
- [8] Liu F, Shen T S, Ma X X. Convolutional neural network based multi-band ship target recognition with feature fusion [J]. Acta Optica Sinica, 2017, 37(10): 1015002.
刘峰, 沈同圣, 马新星. 特征融合的卷积神经网络多波段舰船目标识别 [J]. 光学学报, 2017, 37(10): 1015002.
- [9] Schroff F, Kalenichenko D, Philbin J. Facenet: a unified embedding for face recognition and clustering [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 815-823.
- [10] Ye G L, Sun S Y, Gao K J, *et al.* Night time pedestrian detection based on faster region convolution neural network [J]. Laser & Optoelectronics Progress, 2017, 54(8): 081003.
叶国林, 孙韶媛, 高凯珺, 等. 基于加速区域卷积神经网络的夜间行人检测研究 [J]. 激光与光电子学进展, 2017, 54(8): 081003.
- [11] Taigman Y, Yang M, Ranzato M A, *et al.* Deepface: Closing the gap to human-level performance in face verification [C] // Deepface: Closing the gap to human-level performance in face verification, June 23-28, 2014 Columbus, OH, USA. New York: IEEE, 2014: 1701-1708.
- [12] Wang J R, Yuan C. Facial expression recognition with multi-scale convolution neural network [C] // Chen E, Gong Y, Tie Y. Advances in Multimedia Information Processing: PCM 2016. Cham: Springer, 2016: 376-385.
- [13] Richardson W H. Bayesian-based iterative method of image restoration [J]. Journal of the Optical Society of America A, 1972, 62(1): 55-59.
- [14] Ojansivu V, Heikkilä J. Blur insensitive texture classification using local phase quantization [C] // Elmoataz A, Lezoray O, Nouboud F, *et al.* Image and Signal Processing: ICISP 2008. Berlin, Heidelberg: Springer, 2008: 236-243.
- [15] Chen Y, Fan R S, Wang J X, *et al.* High resolution image classification method combining with minimum noise fraction rotation and convolution neural network [J]. Laser & Optoelectronics Progress, 2017, 54(10): 102801.
陈洋, 范荣双, 王竞雪, 等. 结合最小噪声分离变换和卷积神经网络的高分辨率影像分类方法 [J]. 激光与光电子学进展, 2017, 54(10): 102801.
- [16] Yu D, Deng L. Deep learning and its applications to signal and information processing [exploratory dsp] [J]. IEEE Signal Processing Magazine, 2011, 28(1): 145-154.
- [17] Ji S W, Xu W, Yang M, *et al.* 3D convolutional neural networks for human action recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(1): 221-231.
- [18] Hu F, Xia G S, Hu J W, *et al.* Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery [J]. Remote Sensing, 2015, 7(11): 14680-14707.