光电技术及应用

DOI：10.16818/j.issn1001－5868.2021082402

# 基于GAN和CNN-ELM的监控图像智能修复及检测方法

王传平[1]，杨晓丽[1]，王晓磊[1]，乌　嵘[1]，熊永平[2*]

（1. 新疆油田公司采气一厂，新疆 克拉玛依 834000；2. 北京邮电大学 计算机学院，北京 100876）

**摘　要：** 针对目前石化危险品装车过程中海量监控视频图像人为处理效率低下、模糊图像识别率低等问题，提出一种基于生成式对抗网络（GAN）和卷积神经网络（CNN）与极限学习机（ELM）相结合的监控模糊图像智能修复及检测方法。首先，使用深度学习网络作为目标检测框架，利用GAN网络中生成器与判别器间的零和博弈对模糊图像进行复原，得到清晰完整的作业图像；其次，利用CNN自适应学习图像特征的能力，对修复后的图像进行自主特征提取；最后，将提取的图像特征输入ELM分类器中进行目标识别与分类，判断作业过程是否存在违规行为。试验结果表明：所提方法图像修复速度快，视觉效果自然，且目标识别准确率高，具有很好的泛化能力。

**关键词：** 模糊图像；图像复原；生成式对抗网络；卷积神经网络；极限学习机

**中图分类号：** TP391.41　**文章编号：** 1001－5868(2021)06－0923－08

## Intelligent Restoration and Detection Method of Monitoring Image Based on GAN and CNN-ELM

WANG Chuanping[1], YANG Xiaoli[1], WANG Xiaolei[1], WU Rong[1], XIONG Yongping[2]

(1. The First Gas Production Plant of Xinjiang Oilfield Company, Karamay 834000, CHN;
2. School of Computing, Beijing University of Posts and Telecommunications, Beijing 100876, CHN)

**Abstract:** Aiming at the problems of low artificial processing efficiency and low recognition rate of fuzzy image in the process of loading petrochemical dangerous goods, an intelligent repair and detection method of monitoring fuzzy image based on the combination of generative adversarial network (GAN), convolutional neural network (CNN) and extreme learning machine (ELM) is proposed. Firstly, using the deep learning network as the target detection framework, the fuzzy image is restored by using the zero sum game between the generator and the discriminator in the generative adversarial network to obtain a clear and complete job image. Secondly, using the ability of convolutional neural network to adaptively learn image features, the autonomous features of the repaired image are extracted. Finally, the extracted features are input into the extreme learning machine classifier for target recognition and classification to judge whether there are violations in the operation process. The experimental results show that the proposed method has fast image restoration speed, natural visual effect, high accuracy of target recognition and good generalization ability.

**Key words:** blurred image; image restoration; generative adversarial network; convolutional neural network; extreme learning machine

**收稿日期：**2021－08－24.

**基金项目：**新疆油田公司科研项目(CQYC-2021-214).

* **通信作者：**熊永平

## 0 引言

视频监控的智能化对于促进数字油田的发展有着至关重要的作用。然而，目前国内对重大危险源操作过程中的员工行为监控技术手段较少，石化领域安全事故频发，安全问题已经成为石化行业的重要问题[1-2]。视频监控的全覆盖性可以为作业过程中的违规行为识别提供基础，提升现场作业的安全性[3]。然而由于监控设备位置固定，拍摄图像中会出现目标背景复杂、多姿态及模糊等问题，导致出现误检、漏检等问题，所以提高模糊图像目标检测及识别准确率具有重要意义。

在计算机视觉任务中，模糊现象是普遍存在的，它不仅会直接影响视觉观感，而且图像信息丢失会导致识别效率低下。传统的图像修复方法主要分为基于图像纹理匹配和基于图像像素扩张两种方法，但是都只是对像素进行复制、拼接，不会生成新的像素信息。近年来，由于卷积神经网络(Convolutional Neural Networks，CNN)的快速发展，基于深度学习的模糊图像修复也取得了一定成果。文献[4]提出一种基于像素预测的无导师特征学习方法，该方法利用对抗损失约束解码器完成损失图像修复，但是修复效果不自然，连接处有明显痕迹；文献[5]利用卷积神经网络结合泊松融合方法对缺失区域进行复原，该方法修复效果较真实，但是参数模型的训练过程易出现梯度弥散现象；文献[6]提出一种前景感知修复方法，该方法结合显著性检测算法和边缘特征检测算法进行图像修复，但是网络训练测试过程用时较多，且修复后图像会出现大量背景信息丢失。文献[7]提出一种加入注意力机制的生成网络修复方法，该方法可以增强较深层次特征，修复结果较好，但存在失真现象；文献[8]提出一种堆叠卷积的修复方法，该方法可以使缺失部分产生新的纹理结构和语义联系，但是修复结果存在色差问题。

针对以上问题，本文提出一种基于生成式对抗网络(Generative Adversarial Networks，GAN)、卷积神经网络(Convolutional Neural Networks，CNN)与极限学习机(Extreme Learning Machine，ELM)相结合的监控模糊图像智能修复及检测方法。首先整理监控拍摄的低分辨率模糊图像制作样本数据集，将样本集输入 GAN 中进行训练，通过生成器生成高分辨率复原图像，其次使用 CNN 对复原图像进行特征自适应提取，最后利用 ELM 分类器对目标特征进行分类，快速判断作业现场是否存在安全隐患及操作人员是否存在违规行为，以此降低事故发生概率，保障人员及作业安全。

## 1 基于 GAN 的图像修复

### 1.1 GAN 算法简介

生成式对抗网络是一种无监督网络学习模型[9]，主要由生成器 $G$(Generator)和判别器 $D$(Discriminator)组成，两者均为非线性映射函数，整个网络模型训练均采用反向传播算法，其结构如图 1 所示。随机数据输入生成器 $G$ 后由解码器转换为图像格式的数据，判别器 $D$ 的输入由真实样本和生成样本组成，其主要工作是判别输入数据来自真实数据还是生成数据。在 GAN 训练过程中，生成器和判别器参数不断优化，最终达到纳什均衡，即 $D$ 无法判断输入数据来自真实样本还是生成样本[10]。

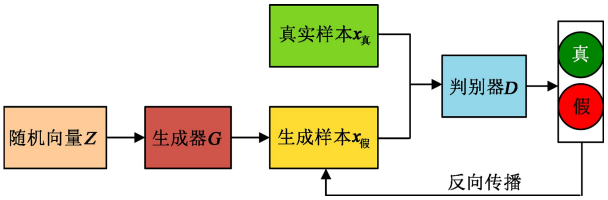



图 1 生成对抗网络示意图

GAN 目标函数描述如式(1)所示：

$$\min_G \max_D V(D,G)=E_{x\sim p_{\text{data}}(x)}[\log D(x)+E_{z\sim p_z(z)}[\log(1-D(G(z)))] \tag{1}$$

式中，$V(G,D)$为二分类交叉熵函数。网络训练过程就是不断优化各参数，使得生成分布和真实分布间的 KL 散度最小化。求解最小交叉熵的过程为：生成器 $G$ 给定，求解最优判别器 $D$，目标函数为

$$Obj^D(\theta_D,\theta_G)=-E_{x\sim p_{\text{data}}(x)}[\log D(x)-E_{z\sim p_z(z)}[\log(1-D(G(z)))]] \tag{2}$$

式中，$z$ 表示随机噪声向量，$x$ 表示真实数据分布 $P_{\text{data}}(x)$中的采样值，$E$ 表示期望值。

由式(2)可知，判别器 $D$ 的训练数据集包括生成器的数据分布 $P_g(x)$和真实数据集分布 $P_{\text{data}}(x)$。当生成器 $G$ 已知，最小化式(2)即可得到判别器 $D$ 最优解，在连续空间中，式(2)可表示为

$$Obj^D(\theta_D,\theta_G)=-\int_x p_{\text{data}}(x)\log(D(x))\mathrm{d}x-\int_z p_z(z)\log(1-D(G(z)))\mathrm{d}x=-\int_x[p_{\text{data}}(x)\cdot\log(D(x))+p_g(x)\log(1-D(x))]\mathrm{d}x \tag{3}$$

设 $P_{\text{data}}(x)$为 $m$，$P_{\text{g}}(x)$为 $n$，$y\in[0,1]$，则式(3)可简化为

$$Obj^{D}(\theta_D,\theta_G)=-m\log(y)-n\log(1-y) \tag{4}$$

式(4)在 $m/m+n$ 处取得最小值，最优判别器为

$$D_G^*(x)=\frac{p_{\text{data}}(x)}{p_{\text{data}}(x)+p_{\text{g}}(x)} \tag{5}$$

在 GAN 训练过程中，首先训练判别器 $D$ 最大化数据源于真实数据概率，同时训练生成器 $G$ 最小化 $\log(1-D(G(z)))$。通过交替迭代，固定生成器 $G$，优化判别器 $D$，使得 $D$ 的判别概率最大化；然后固定判别器 $D$，优化生成器 $G$，使得 $D$ 的判别概率最小化，当且仅当 $P_{\text{data}}=P_{\text{g}}$ 时，求得全局最优解[11-12]。

### 1.2　生成器结构

本文采用的生成器网络结构如图 2 所示，网络中加入了去模糊模块、DiscoGAN 模块、ResNeXt 残差模块。利用此网络结构生成清晰图像，为后续的目标特征提取识别打下基础。

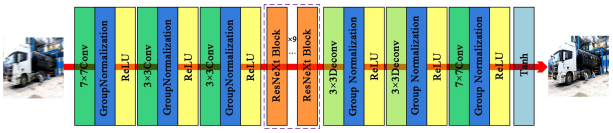



图 2　生成器网络结构

### 1.3　判别器结构

本文采用的判别器网络由七个卷积层和一个全连接层构成，选用 Sigmoid 函数输出判别概率，真假图像判别阈值设为 0.5，网络结构如图 3 所示。

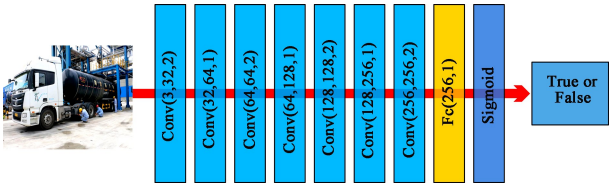



图 3　判别器网络结构

### 1.4　损失函数

GAN 中生成器和判别器都有相应的损失函数，为了得到更清晰的复原图像，本文将生成器的损失函数设计成多维度损失函数，即对抗损失函数 $L_{\text{adv}}$、感知损失函数 $L_{\text{per}}$ 和纹理损失函数 $L_{\text{tex}}$ 加权得到生成器的总损失函数 $L_{\text{G}}$：

$$L_{\text{G}}=L_{\text{adv}}+\alpha L_{\text{per}}+\beta L_{\text{tex}} \tag{6}$$

其中，$\alpha$ 和 $\beta$ 分别表示感知损失和纹理损失的权重参数。

1)对抗损失

为了 GAN 能够更加稳定地修复模糊图像，生成高质量样本，采用 WANG-GP 的对抗损失函数替换原有 GAN 的对抗损失函数，其公式为

$$L_{\text{adv}}=E_{x\sim p_G}[D(x)]-E_{x\sim p_{\text{data}}}[D(x)]+\lambda E_{x\sim\text{penalty}}[(\|\nabla_x D(x)\|-1)^2] \tag{7}$$

2)感知损失

感知损失是高维度损失，主要通过计算生成图片与真实图片特征图的欧氏距离得到两者高维度语义信息的区别，其计算公式为

$$L_{\text{per}}=\frac{1}{W_{ij}H_{ij}}\sum_{x=1}^{W_{ij}}\sum_{y=1}^{H_{ij}}(\phi^{ij}(I^{HR})_{x,y}-\phi^{ij}(G(I^{LR}))_{x,y})^2 \tag{8}$$

其中，$W_{ij}$ 和 $H_{ij}$ 分别表示特征图的宽度和高度，$\phi_{ij}$ 为第 $j$ 层卷积层(第 $i$ 层最大池化层之前)的特征图谱。

3)纹理损失

纹理损失函数 $L_{\text{tex}}$ 可以通过计算生成网络与判别网络卷积层输出特征图对应的 Gram 矩阵得到，$L_{\text{tex}}$ 计算公式为

$$L_{\text{tex}}=\|\boldsymbol{G}(\phi(I^{\text{gen}})-\boldsymbol{G}(\phi(I^{\text{HR}}))\|_2^2 \tag{9}$$

$L_{\text{tex}}$ 可以使纹理信息进行局部配准，加入纹理损失函数 $L_{\text{tex}}$ 可以有效减少生成图像伪影，产生更加逼真的纹理信息。

## 2　目标特征提取与分类

### 2.1　卷积神经网络

CNN 可以通过反向传播算法自适应学习特征[13-14]，网络一般由输入层(Input Layer)、卷积层(Conv Layer)、池化层(Pooling Layer)、全连接层(Fully Connected Layer)、输出层(Output Layer)等构成，网络结构如图 4 所示。CNN 中的卷积层和池化层交替出现，每层卷积层由若干个大小一致的卷积核构成，所以网络具有很好的容错能力和自学习能力[15]，解决了人工特征识别和标记的不可靠性问题，而且利用 CNN 进行特征提取可以处理海量数据，耗时也较短。

1)卷积层(Conv)：卷积核对输入图像进行卷积计算时会产生对应特征图谱，卷积层通常包含多个卷积核，所以每层卷积有若干个特征图谱，但同一卷积核拥有权值共享的特点，这可以有效降低模型复杂度，减少内存开支。卷积操作过程为

$$z^{(l,m)}=f(w^{(l,m)}\times p^{(l-1)}+b^{(l,m)}) \tag{10}$$

其中，$f$ 代表激励函数，$w^{(l,m)}$ 表示卷积核，$p^{(l-1)}$ 代表上一层的输入，$b^{(l,m)}$ 为偏置项。

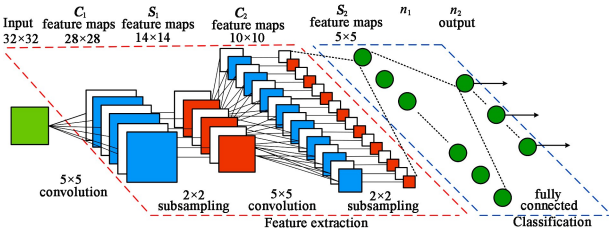



图 4 卷积神经网络结构图

2)池化层(PL)：也称为子采样层，可以将卷积层特征压缩，在保持局部不变性的同时降低特征维度，减少网络计算量的同时可以有效缓解网络过拟合现象的产生。池化类型主要分为三种，本文选取最大池化函数，其数学表示式为

$$p^{l(i,j)}=\max_{(j-1)V+1\leqslant t\leqslant jV}\{a^{l(i,j)}\} \tag{11}$$

式中，$V$ 表示池化宽度，$a^{l(i,j)}$ 表示激活值，$p^{l(i,j)}$ 表示输出值。

3)全连接层(FC)：主要作用是特征分类，它可以将在卷积层和池化层学习到的特征非线性组合，然后传递给输出层。其数学描述为

$$y=f\left(\sum_{i\in G_i}x^{(l-1,i)}w^{(l,i)}+b^{(l,j)}\right) \tag{12}$$

网络中常用的激活函数为：Sigmoid 函数、ReLu 函数及 tanh 函数[16]。其中 Sigmoid 和 tanh 为饱和非线性函数，权重值更新慢容易导致网络梯度消失，而 ReLu 函数操作简单，计算速度快，可有效降低网络时间复杂度，加快网络收敛，所以本文激励函数采用 ReLu 函数，即：

$$\mathrm{ReLU}(x)=\begin{cases}0, & x<0\\ x, & x\geqslant 0\end{cases} \tag{13}$$

为了优化训练结果，引入均方根误差(RMSE)损失函数来评价卷积神经网络模型，其定义为

$$RMSE=\sqrt{E[(x-\hat{x})^2+(y-\hat{y})^2]} \tag{14}$$

本文所使用 CNN 网络包含一个输入层、两个卷积层、两个池化层、两个归一化层、三个 ReLu 层、两个全连接层、一个 softmax 层和一个输出层，共 14 层结构。其中浅层的卷积层可以有效提取图像丰富的局部特征，深层的卷积层结合局部特征表达出更丰富的语义信息。池化层可以降低卷积层提取特征向量的维度，便于后续计算。激活函数采用 ReLu 函数。通过卷积池化的操作，将整个图像的特征提取出来，通过全连接层排成列向量，通过 softmax 函数以概率的形式输出各个类型的结果。

## 2.2 极限学习机

ELM 是一种单隐层前馈神经网络算法[17]，算法执行前网络随机生成输入权值与隐含层节点的偏置项，而输出权重矩阵可以通过计算得到对应结构下的唯一最优解，所以 ELM 分类器具有网络训练速度快、泛化性好、鲁棒性强等优点[18]。ELM 网络结构示意图如图 5 所示。

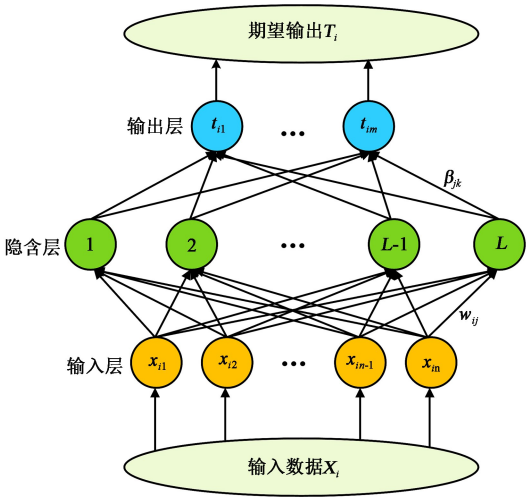



图 5 ELM 结构示意图

假设输入层有 $n$ 个神经元，隐含层有 $l$ 个神经元，输出层有 $m$ 个神经元，随机生成的偏置项为 $\boldsymbol{B}$，输入层与隐含层的连接权值矩阵为 $\boldsymbol{W}$：

$$\boldsymbol{W}=\begin{bmatrix}w_{11} & w_{12} & \cdots & w_{1n}\\ w_{21} & w_{22} & \cdots & w_{2n}\\ \vdots & \vdots & \ddots & \vdots\\ w_{l1} & w_{l2} & \cdots & w_{ln}\end{bmatrix}_{l\times n} \tag{15}$$

隐含层与输出层的连接权值矩阵为 $\boldsymbol{\beta}$：

$$\boldsymbol{\beta}=\begin{bmatrix}\beta_{11} & \beta_{12} & \cdots & \beta_{1m}\\ \beta_{21} & \beta_{22} & \cdots & \beta_{2m}\\ \vdots & \vdots & \ddots & \vdots\\ \beta_{l1} & \beta_{l2} & \cdots & \beta_{lm}\end{bmatrix}_{l\times m} \tag{16}$$

此时，具有 $k$ 个节点的 ELM 可以描述为

$$f(x_i)=\sum_{j=1}^{k}\beta_j g(w_j+x_i+b_j) \tag{17}$$

式中，$g(x)$ 为激活函数。

若确定初始 $\boldsymbol{\beta}$，则可以将以上公式优化为

$$\min_{\boldsymbol{\beta}}\|\boldsymbol{H}_0\boldsymbol{\beta}-\boldsymbol{Y}_0\| \tag{18}$$

即：

$$\boldsymbol{H}_0\boldsymbol{\beta}=\boldsymbol{Y}_0 \tag{19}$$

其中，$\boldsymbol{H}_0$ 为隐含层输出矩阵：

$$\boldsymbol{H}_0=\begin{bmatrix} g(w_1\cdot x_1+b_1) & \cdots & g(w_m\cdot x_1+b_m) \\ \vdots & \ddots & \cdots \\ g(w_1\cdot x_n+b_1) & \cdots & g(w_m\cdot x_n+b_m) \end{bmatrix} \tag{20}$$

$\boldsymbol{Y}_0$ 为网络输出矩阵：

$$\boldsymbol{Y}_0=(\boldsymbol{Y}_1^{\mathrm{T}},\boldsymbol{Y}_2^{\mathrm{T}},\cdots,\boldsymbol{Y}_n^{\mathrm{T}}) \tag{21}$$

为便于计算，将式(15)转换为

$$\boldsymbol{\beta}=\boldsymbol{H}_0^{*}\boldsymbol{Y}_0 \tag{22}$$

式中，$\boldsymbol{H}_0^{*}=(\boldsymbol{H}_0^{\mathrm{T}}\boldsymbol{H}_0)^{-1}\boldsymbol{H}_0^{\mathrm{T}}$，表示矩阵 $\boldsymbol{H}_0$ 的 Moore-Penrose 广义逆，由此可以求得全局最优输出权值矩阵。

ELM 中常用的激活函数有 Sigmoid，Sine，Hardlim 等，本文选取 Sigmoid 函数：

$$k(a_ix+c_i)=\frac{1}{1+\exp(-a_ix+c_i)} \tag{23}$$

# 3　实验与分析

## 3.1　实验准备

本文检测目标包括工服(Work Uniforms)、安全帽(Safety Hat)、消毒面具(Disinfection Mask)、手套(Glove)、明火(Flame)、烟雾(Smoke)等。GAN 网络样本数据集包含 1 500 幅监控图像，其中 1 000 幅作为训练集，300 幅作为测试集，200 幅作为验证集。实验用到的 CPU 为 Core i7-6700k，内存 16 GB，GPU 为 GTX1070ti，编程软件为 Matlab 2020a。

## 3.2　图像修复检测流程图

监控图像的修复检测流程如图 6 所示，其中图像特定位置的标注和标识在 R-CNN 框架下实现。修复检测步骤描述如下：

1)利用生成式对抗网络对拍摄的模糊或含噪图像进行复原，便于后续深度学习对图像的内容进行分类；

2)利用 Selective Search 算法划分复原后图像，得到 2 000 个待检测区域；

3)利用 CNN 网络提取候选区域的图像特征，将提取的特征作为待检测向量；

4)将提取到的特征向量输入设计好的 ELM 分类器中，对目标进行识别分类；

5)使用回归器对候选框的位置进行精细修正，以更好地框出检测目标。

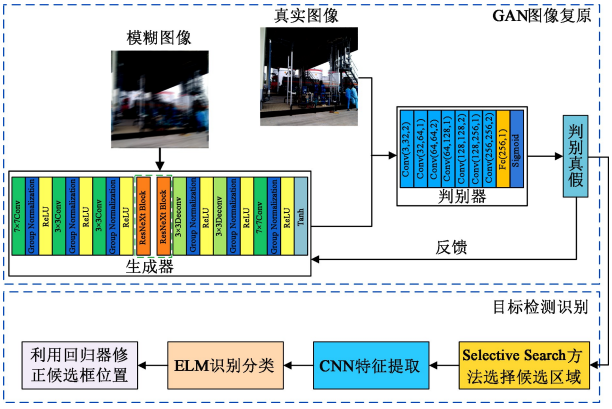



图 6　图像修复检测流程

## 3.3　GAN 实验结果分析

GAN 损失函数变化曲线如图 7 所示，从图 7 可以看出，生成器和判别器的损失函数随着网络迭代次数的增加而快速下降并逐渐在一个稳定值上波动，说明整个网络收敛速度快，训练效果较好。损失函数曲线在最后有小幅度波动，说明网络达到了纳什均衡，判别器已经无法判断是生成样本还是真实样本。

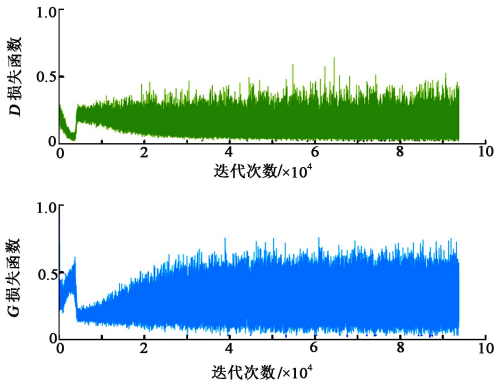



图 7　GAN 损失函数变化曲线

为了直观显示图像复原效果，将本文所提 GAN 模糊图像修复方法与逆滤波(Inverse Filtering，IF)以及维纳滤波(Wiener Filtering，WF)修复方法进行对比试验，三种方法复原结果如图8所示。从主



(a)　模糊图像



(b)　清晰图像



(c) 逆滤波



(d) 维纳滤波



(e) GAN

图 8 三种修复方法结果对比

观视觉上可以看出,模糊图像经过逆滤波恢复处理后仍有明显噪声,视觉效果不理想;经过维纳滤波去模糊处理后图像清晰度有明显提升;而经过 GAN 算法处理后人物线条流畅,图像视觉效果自然,可清晰分辨出图像中各类目标。

为了进一步验证本文利用 GAN 方法进行模糊图像修复的可行性,利用峰值信噪比(PSNR)、结构相似性(SSIM)以及弗雷歇初始距离得分(FID)对以上三种实验结果进行客观评价,结果如表 1 所示。其中,PSNR 值越大,表明修复后的图像信息越丰富,SSIM 值越接近于 1,说明修复图像失真越小,FID 用于计算清晰图像与修复图像特征向量间的距离,FID 值越低,表明二者的统计量越相似。

**表 1 三种方法修复结果评价指标对比**

| 方法名称 | PSNR | SSIM | FID |
|---|---|---|---|
| IF | 24.45 | 0.854 | 25.31 |
| WF | 28.21 | 0.825 | 16.49 |
| GAN | 35.39 | 0.957 | 13.63 |

由表 1 可知,利用 GAN 进行图像复原后图像质量有了明显提升,图像复原效果最佳,可以为后续目标检测分类提供良好条件。

实际拍摄的图像可能还有噪声,通过 GAN 算法复原的图像也可以抑制图像的噪声,图 9 给出 GAN 算法去噪、离散余弦变换(Discrete Cosine Transform,DCT)去噪和小波降噪(Wave Noise Reduction,WNR)的对比。从主观视觉即可看出,GAN 的去噪效果明显优于 DCT 去噪和小波去噪。



(a) 加噪图像



(b) DCT 去噪



(c) 小波去噪



(d) GAN 去噪

图 9 三种去噪方法结果对比

图 10 给出了三种方法在不同噪声强度下的峰值信噪比。从图中可以看出,随着噪声强度的增加,三种方法的去噪性能有所下降。当噪声强度高于 40%时,DCT 和小波降噪的效果较差,但是 GAN 算法依然保持较高的峰值信噪比,说明 GAN 算法不仅可以有效去除图像中的噪声,而且可以保留图像中的有效信息,便于后续的图像类型识别。

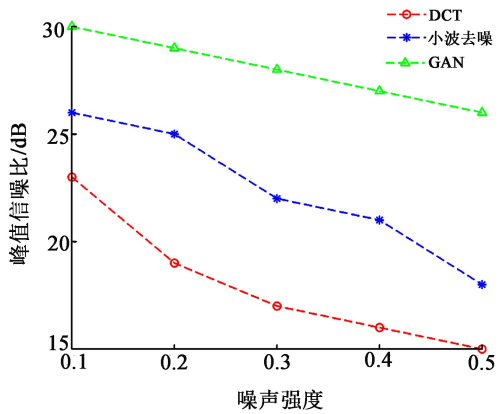



图 10 三种去噪方法的峰值信噪比

表 2 给出了不同样本数量下,去模糊和不去模糊图像识别的平均准确率对比结果。从表 2 可以看出,随着训练样本数目的增多,图像分类的平均确率有所提升,但是如果不对图像进行复原处理,图像的分类结果最高只有 78%,分类的准确率较低,而对图像进行复原操作以后,准确率可以达到 99%以上,说明在应用深度学习对图像分类之前需要保证图像具有较高的清晰度。

表 2　不同样本数量下平均准确率

| 训练样本数量 | 图像不去模糊 | 图像去模糊 |
|---|---|---|
| 160 | 69% | 92% |
| 210 | 70% | 94% |
| 260 | 75% | 96% |
| 320 | 78% | 98% |
| 410 | 78% | 99% |

### 3.4　CNN-ELM 实验结果分析

对图像进行复原以后，利用 CNN 提取图像的特征。图 11 为 CNN 网络的整体训练过程，包含训练样本的准确率和损失函数曲线，可以看到损失函数曲线从高点快速下降并趋于零，说明整个网络收敛速度快并且稳定。训练样本和验证样本的准确率最终也都稳定达到 100%，说明网络没有出现过拟合现象，网络训练效果较好。

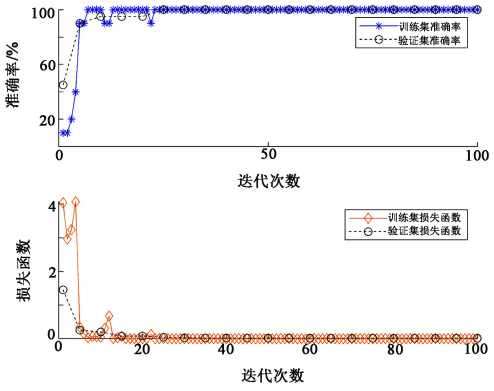



图 11　网络训练过程

将 CNN 提取的特征通过 ELM 进行分类，在 R-CNN 框架下框出要检测的目标。将正确佩戴安全帽定义为“Safety Helmet”，将错误佩戴安全帽定义为“Unsafety Helmet”。使用训练好的模型检测工作人员佩戴安全帽的规范性，所得结果如图 12 所示，可以看出本文方法可以准确地识别出工作人员是否正确佩戴安全帽。

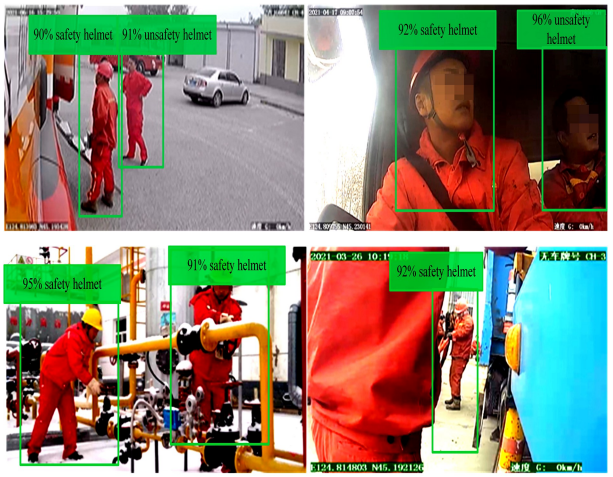



图 12　安全帽识别

将工作人员正确着装定义为“Correct Dress”，非正确着装定义为“Wrong Dress”，所得目标检测结果如图 13 所示，可以看出本文方法能够正确判断工作人员是否正确着装。




图 13　着装规范性识别

## 4　结论

针对海量监控图像分辨率低、目标检测识别不准确等问题，提出一种基于生成式对抗网络和卷积神经网络与极限学习机相结合的监控模糊图像智能修复及检测方法，得出以下结论：1）通过 GAN 算法复原图像，可以将巡检得到的模糊或含噪图像变得清晰，主观视觉效果好、客观评价指标高，通过深度学习方法提取图像特征，与不复原图像相比，复原后的图像分类准确率较高。2）利用 CNN 网络可以自主挖掘图像特征信息，避免了人工选取特征向量，智能性更高，并且 CNN 网络训练过程较好，没有出现过拟合现象。通过 ELM 对提取的特征向量进行分类，具有较高的准确度。3）在 R-CNN 框架下，可以准确地标注和定位待检测目标，文中给出了安全帽检测和着装检测的例子，由所得结果可以看出，本文方法能够正确框出需要检测的目标，为智能监控提供了一种新的机制，有助于预防安全事故的发生。

**参考文献：**

[1]　吕　品. 石油化工企业环境安全应急监控和预警管理系统的设计[J]. 石油化工自动化，2020，56(3)：56-59.

Lü Pin. Design of environmental safety emergency monitoring and early warning management system in petrochemical enterprises[J]. Automation in Petro-chemical Industry, 2020, 56(3): 56-59.

[2] 丁志文，汪如军，陈方方，等. 断溶体油气藏成因、成藏及油气富集规律——以塔里木盆地哈拉哈塘油田塔河南岸地区奥陶系为例[J]. 石油勘探与开发，2020，47(2)：286-296.
Ding Zhiwen, Wang Rujun, Chen Fangfang, et al. Origin, hydrocarbon accumulation and oil-gas enrichment of fault-karst carbonate reservoirs: A case study of ordovician carbonate reservoirs in south tash area of Halahatang oilfield, Tarim Basin [J]. Petroleum Exploration and Development, 2020, 47(2): 286-296.

[3] 张玉杰，张佳豪. LoRa通信及其在油田监控系统中的应用[J]. 西安石油大学学报(自然科学版)，2020，35(3)：116-121.
Zhang Yujie, Zhang Jiahao. LoRa communication and its application in oilfiled monitoring system[J]. J. of Xi'an Shiyou University (Natural Science Edition), 2020, 35(3): 116-121.

[4] Pathak D, Krahenbuhl P, Donahue J, et al. Context encoders: feature learning by inpainting[C]// Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition, 2016: 2536-2544.

[5] Yeh R A, Chen C, Yian Lim T, et al. Semantic image inpainting with deep generative models[C]// Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition, 2017: 5485-5493.

[6] Xiong W, Yu J, Lin Z M, et al. Foreground-aware image inpainting [C]// Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition, 2019: 5840-5848.

[7] Yu J, Lin Z, Yang J, et al. Generative image inpainting with contextual attention[C]// Proc. of IEEE Conf. on Conputer Vision and Pattern Recognition, 2018: 5505-5514.

[8] Liu G, Reda A, Shih K, et al. Image inpaintng for irregular holes using partial convolutions [J]. ACM Trans. on Graphics, 2018, 9(3): 37-51.

[9] 何 凯，刘 坤，李 宸，等. 级联式生成对抗网络图像修复模型[J]. 天津大学学报(自然科学与工程技术版)，2021，54(9)：917-924.
He Kai, Liu Kun, Li Chen, et al. Image inpainting model using cascaded generative adversarial network [J]. J. of Tianjin University (Science and Technology), 2021, 54(9): 917-924.

[10] 陈佛计，朱 枫，吴清潇，等. 生成对抗网络及其在图像生成中的应用研究综述[J]. 计算机学报，2021，44(2)：347-369.
Chen Foji, Zhu Feng, Wu Qingxiao, et al. A survey about image generation with generative adversarial nets[J]. Chinese J. of Computers, 2021, 44(2): 347-369.

[11] 罗会兰，敖 阳，袁 璞. 一种生成对抗网络用于图像修复的方法[J]. 电子学报，2020，48(10)：1891-1898.
Luo Huilan, Ao Yang, Yuan Pu. Image inpainting using generative adversarial networks[J]. Acta Electronica Sinica, 2020, 48(10): 1891-1898.

[12] 姜玉宁，李劲华，赵俊莉. 基于生成式对抗网络的图像超分辨率重建算法[J]. 计算机工程，2021，47(3)：249-255.
Jiang Yuning, Li Jinghua, Zhao Junli. Image super-resolution reconstruction algorithm based on generative adversarial networks[J]. Computer Engineering, 2021, 47(3): 249-255.

[13] 熊 皓，刘嘉勇，王俊峰. 基于神经网络和自回归模型的网络流量预测[J]. 计算机应用，2021，41(S1)：180-184.
Xiong Hao, Liu Jiayong, Wang Junfeng. Network traffic prediction based on neural network and autoregressive model [J]. J. of Computer Applications, 2021, 41(S1): 180-184.

[14] 王玉静，李少鹏，康守强，等. 结合CNN和LSTM的滚动轴承剩余使用寿命预测方法[J]. 振动，测试与诊断，2021，41(3)：439-446，617.
Wang Yujing, Li Shaopeng, Kang Shouqiang, et al. Method of predicting remaining useful life of rolling bearing combining CNN and LSTM [J]. J. of Vibration, Measurment & Diagnosis, 2021, 41(3): 439-446, 617.

[15] 樊湘鹏，周建平，许 燕，等. 基于优化Faster R-CNN的棉花苗期杂草识别与定位[J]. 农业机械学报，2021，52(5)：26-34.
Fan Xiangpeng, Zhou Jianping, Xu Yan, et al. Identification and localization of weeds based on optimized Faster R-CNN in cotton seeding stage[J]. Trans. of The Chinese Society of Agricultural Machinery, 2021, 52(5): 26-34.

[16] 侯思祖，刘雅婷，陈天威. 基于CNN-WF的高灵敏紫外成像仪中的图像配准与融合[J]. 半导体光电，2021，42(4)：596-602.
Hou Sizu, Liu Yating, Chen Tianwei. Image registration and fusion of high sensitive ultraviolet imager based on CNN-WF [J]. Semiconductor Optoelectronics, 2021, 42(4): 596-602.

[17] 谢文旺，孙云莲. 基于OS-ELM的宽带电力线通信解映射优化算法[J]. 电测与仪表，2019，56(13)：1-6，50.
Xie Wenwang, Sun Yunlian. Optimization algorithm for de-mapping module of broadband power line communication based on OS-ELM[J]. Electrical Measurement & Instrumentation, 2019, 56(13): 1-6, 50.

[18] 于志勇，张卫辉，王新库，等. 基于GA和ELM的电能质量扰动识别特征选择方法[J]. 电测与仪表，2016，53(23)：62-66.
Yu Zhiyong, Zhang Weihui, Wang Xinku, et al. A method of power quality disturbances recognition feature selection based on GA and ELM [J]. Electrical Measurement & Instrumentation, 2016, 53(23): 62-66.

## 作者简介：

**王传平**(1973－)，男，湖北省仙桃市人，高级工程师，主要研究方向为天然气加工处理；

**熊永平**(1982－)，男，江西省丰城市人，博士，副教授，主要研究方向为计算机科学与技术。