

DOI:10.3969/j.issn.1003-5060.2024.09.015

注意力机制下的多尺度图像超分辨率重建

何启琛, 何蕾

(合肥工业大学 数学学院, 安徽 合肥 230601)

摘要:文章结合目前较流行的多尺度卷积和通道注意力机制,提出一种新颖的卷积神经网络(convolutional neural network, CNN)结构,即注意力机制下的多尺度卷积神经网络。该网络结构中加入大量的残差结构,加深了网络的深度;多尺度卷积的使用使该网络能从图片中提取更加丰富的信息;注意力机制的引入使网络处理高频信息时有更大的权重。实验结果表明,多尺度注意力机制卷积神经网络在图像超分辨率(super-resolution, SR)重建上取得了良好的表现,图像细节恢复效果令人满意。

关键词:超分辨率(SR);深度学习;卷积神经网络(CNN);注意力机制;多尺度

中图分类号:TP391.41

文献标志码:A

文章编号:1003-5060(2024)09-1255-07

Multi-scale image super-resolution reconstruction using channel attention

HE Qichen, HE Lei

(School of Mathematics, Hefei University of Technology, Hefei 230601, China)

Abstract: This paper combines the popular multi-scale convolution and channel attention mechanism, and proposes a novel convolutional neural network(CNN) structure, namely the multi-scale CNN under attention mechanism. A large number of residual structures are added to the proposed network structure, which deepens the depth of the network. The utilization of multi-scale convolution enables the network to extract richer information from pictures. The introduction of the attention mechanism enables the network to have greater weight in processing high-frequency information. Experimental results show that the multi-scale CNN under attention mechanism has achieved good performance in image super-resolution(SR) reconstruction, and the effect of image detail restoration is satisfactory.

Key words: super-resolution (SR); deep learning; convolutional neural network (CNN); attention mechanism; multi-scale

0 引言

图像超分辨率(super-resolution, SR)重建是指由一幅已知的低分辨率(low-resolution, LR)图像或同一场景下图像序列恢复出高分辨率(high-resolution, HR)图像。由一幅低分辨率图像恢复出高分辨率图像又被称为单一图像超分辨率(single image super-resolution, SISR)重建。目前图像超分辨率研究主要有基于插值、基于重建和基于学习的方法^[1]。得益于近十年来计算机

计算能力跨越式提高,基于学习的方法相较于传统方法,逐渐取得了优越的效果。

图像超分辨率在计算机视觉领域有广泛的应用,包括医疗影像^[2]、安全监控影像、目标识别任务等。然而,图像超分辨率重建是一个病态问题^[3](ill-posed problem),对于任一低分辨率图像,都存在多种重建结果,为了解决该不适定问题,即更好地得到一对低分辨率图像与高分辨率图像的映射,大量的基于卷积神经网络(convolutional neural network, CNN)的方法

收稿日期:2021-03-18;修回日期:2021-05-10

作者简介:何启琛(1995—),男,江苏扬州人,合肥工业大学硕士生;

何蕾(1980—),女,湖北钟祥人,博士,合肥工业大学副教授,硕士生导师,通信作者, E-mail: hlei80@163.com.

被提出。文献[4]首次将卷积神经网络引入图像超分辨率重建,提出超分辨率重建卷积神经网络(super-resolution convolutional neural network, SRCNN),该网络由 3 个卷积层组成,给出一种端到端的方式,相较传统方法取得了更好的效果,随后在 SRCNN 的基础上继续改进,提出一种更快的超分辨率重建卷积神经网络^[5](fast super-resolution convolutional neural network, FSRCNN)。文献[6]提出一个很深的卷积神经网络(very deep convolutional networks for super-resolution, VDSR),该网络通过引入残差链接^[7]解决了网络加深后产生的梯度问题,成功将网络深度加深至 20 层,较 SRCNN 取得了更好的重建效果。随着残差网络的广泛使用,网络的深度和宽度普遍的增加,文献[8]提出一个加强的深度残差网络(enhanced deep residual networks, EDSR),通过使用残差模块(residual group, RG),该网络的深度已经超过了 160 层。

最近的研究显示,单一的堆叠残差模块以加深网络的深度已经很难在图像超分辨率重建上取得更好的效果,至于以其他机制来加深网络的深度能否提升重建的效果还需要继续研究。文献[9]提出一种基于注意力机制的残差网络(residual channel attention networks, RCAN),该网络引入注意力机制,加强了网络对于高频信息的提取及对低频信息的过滤能力,取得了十分优秀的效果。

本文受 RCAN 启发,在 RCAN 基础上进行改进,提出注意力机制下的多尺度卷积神经网络进行图像重建。根据目前卷积神经网络的假设和理解,由网络中较浅的卷积层生成的特征图主要对低频信息进行编码,而由深层卷积层生成的特征图主要对高频信息进行编码。文献[10]引入多尺度卷积,增大了感受野,使得卷积层提取特征更加全面,提升了高频信息的丰富性和完整性。本文引入注意力机制,并通过学习的方法使得每张特征图都能学习到一个 $[0, 1]$ 之间的系数,通过系数相乘使网络不再平均地处理每张卷积出的特征图。处理的规则为蕴含高频信息的特征图的系数趋向于 1,而低频信息较多的特征图的系数趋向于 0,从而使高频信息得到更好的利用。

本文结合多尺度卷积的方法,使得网络提取的特征更加丰富,增强了对于图像尺寸的鲁棒性,提升了网络性能;引入通道注意力机制,使得高频

信息和低频信息以不同权重输入后续卷积层,有助于算法的优化。

1 相关工作

本文提出的多尺度注意力机制卷积神经网络引入多尺度卷积的方法和通道注意力机制,以模拟图像退化模型的逆过程。

1.1 图像退化模型

单幅图像超分辨率的目标是根据单幅低分辨率图像输入得到清晰的高分辨率图像。一般来说,低分辨率图像 y 是高分辨率图像 x 由以下退化过程所得,即

$$y = x \downarrow_s \otimes k \quad (1)$$

其中: $x \downarrow_s$ 为系数为 s 的下采样算子; k 为模糊核。

与一部分卷积神经网络先进行上采样操作再提取特征的步骤不同,本文模拟图像退化逆过程,先在低分辨率图像上进行特征提取,最后进行上采样操作。

1.2 多尺度卷积方法

为了解决早期一些经典网络普遍存在的缺点,即简单地堆加网络层数而对图像特征利用率不足以及对于尺寸的鲁棒性较差,文献[10]提出了多尺度卷积的方法,如图 1 所示,上一层的特征图分别在 1×1 卷积层、 3×3 卷积层、 5×5 卷积层进行卷积以及一个 3×3 最大池化层上进行池化,最后产生的特征图采用堆叠(concat)的方式输入下一层。因为 3×3 的卷积核和 5×5 的卷积核感受野不同,所以多尺度卷积结构对于特征尺寸有较好的扩展性,提取的特征更加丰富。




图 1 多尺度卷积

1.3 通道注意力机制

在以往一些经典的卷积神经网络中,下一层卷积层会不加区分地对上一层卷积层产生的所有特征图进行卷积,通道注意力机制能使下一层卷积层更有侧重地处理输入的特征图,通过学习的方法学习到一个 $[0, 1]$ 的系数,给每一张特征图乘以一个系数以达到区分特征图重要性的目的。通道注意力机制如图 2 所示。




图 2 通道注意力机制

以高度为 H 、宽度为 W 的特征图 $X = \{x_1, \dots, x_c, \dots, x_c\}$ 为下一层卷积层的输入,每张特征图经过全局池化尺变为一个像素点,以 $K = \{k_1, \dots, k_c, \dots, k_c\}$ 表示全局池化层的输出,则

$$k_c = F_{GP}(x_c) = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (2)$$

其中: $x_c(i, j)$ 为特征图 x_c 上第 i 行、第 j 列的值; F_{GP} 为全局池化操作。

$K = \{k_1, \dots, k_c, \dots, k_c\}$ 分别经过一层卷积层,进行一次 ReLU 函数^[11],再经过一层卷积层,

最后进行一次 Sigmoid 函数,以 $A = \{a_1, \dots, a_c, \dots, a_c\}$ 表示最终结果,则

$$a_c = f(\omega_2 \delta(\omega_1 k_c)) \quad (3)$$

其中: ω_1 为第 1 层卷积层卷积核的参数; δ 为 ReLU 函数; ω_2 为第 2 层卷积层卷积核的参数; f 为 Sigmoid 函数; a_c 为通道注意力机制学习到的系数,用原始的特征图 X 乘以系数 A ,得到下一层卷积层的输入 $X' = \{x'_1, \dots, x'_c, \dots, x'_c\}$,其中, $x'_c = a_c x_c$ 。

2 网络结构

注意力机制下的多尺度卷积神经网络结构如图 3 所示,该网络主要包含浅层特征提取网络、深层特征提取网络、上采样模块和重建网络 4 个部分。




图 3 注意力机制下的多尺度卷积神经网络结构

2.1 浅层特征提取网络

浅层特征提取网络由 1 个卷积层、1 个多尺度卷积层、1 个堆叠层和 1 个卷积层构成。假设 I_{LR} 和 I_{SR} 为网络的输入和输出, I_{LR} 先经过 1 个卷积层,然后分别进行 1 次 3×3 卷积和 1 次 5×5 卷积,将生成的特征图堆叠输入 1 个 1×1 卷积层减少通道数,最后输入深层特征提取网络。以 F_0 表示浅层特征提取网络的输出,则

$$F_0 = H_{SF}(I_{LR}) \quad (4)$$

其中, H_{SF} 为浅层特征网络内几次卷积操作的和函数。

2.2 深层特征提取网络

深层特征提取网络由 N 个残差模块 RG、1 个卷积层以及 1 个跳跃连接组成。以 F_{DF} 表示深层特征提取网络的输出,则

$$F_{DF} = F_0 + \omega_{LC} F_N \quad (5)$$

其中: ω_{LC} 为深层特征提取网络最后卷积层卷积核的参数; F_N 为第 N 个残差模块 RG 的输出。

残差模块 RG 的结构如图 4 所示,该模块由 M 个残差通道注意力模块(residual channel attention block, RCAB)、1 个卷积层以及 1 个跳跃

连接组成。若 F_n 表示第 n 个 RCAB 模块的 RG 输出,则

$$F_n = H_n(F_{n-1}) \quad (6)$$

其中: H_n 为第 n 个 RCAB 模块中所有操作的和函数; F_{n-1} 为第 $n-1$ 个 RCAB 模块的输出。




图 4 残差模块 RG 结构

RCAB 模块的结构如图 5 所示,以 $F_{n,m}$ 表示第 n 个 RG 中第 m 个 RCAB 的输出,则

$$F_{n,m} = H_{n,m}(F_{n,m-1}) \quad (7)$$

其中: $H_{n,m}$ 为第 n 个 RG 模块中第 m 个 RCAB 模块所有操作的和函数; $F_{n,m-1}$ 为第 n 个 RG 模块中第 $m-1$ 个 RCAB 模块的输出。




图 5 RCAB 模块结构

结合图 4 可知, F_n 表示为:

$$F_n = F_{n-1} + \omega_n F_{n,m} \quad (8)$$

其中: ω_n 为第 n 个 RG 模块中最后卷积层卷积核的参数; $F_{n,m}$ 为第 n 个 RG 模块中第 m 个 RCAB 模块的输出。

由图 5 可知, $F_{n,m}$ 可表示为:

$$F_{n,m} = F_{n,m-1} + R_{m,n}(X_{n,m})X_{n,m} \quad (9)$$

其中: $R_{m,n}$ 为注意力机制所有操作的和函数; $X_{n,m}$ 可表示为:

$$X_{n,m} = \omega_{n,m}^2 \delta(\omega_{n,m}^1 F_{n,m-1}) \quad (10)$$

其中: $\omega_{n,m}^1$ 、 $\omega_{n,m}^2$ 分别为图 5 中前 2 个卷积层卷积核参数; δ 为 ReLU 函数。

2.3 上采样模块和重建网络

深层特征提取网络输出的 F_{DF} 经过上采样模块被放大, 以 F_{UP} 表示上采样模块的输出, 则

$$F_{UP} = H_{UP}(F_{DF}) \quad (11)$$

其中, H_{UP} 为上采样操作。最后 F_{UP} 输入重建网络, 则

$$I_{SR} = H_{RC}(F_{UP}) \quad (12)$$

其中, H_{RC} 为网络中最后一个卷积层的卷积操作。

3 实验分析

3.1 实验环境与设置

在图像超分辨率重建领域中, 常用的数据集有 DIV2K、PixelShift200、BSD300、ImageNet 等。本实验采用的训练集为 DIV2K, 该数据集包含 1 000 张高清图, 其中: 800 张用于训练; 100 张用于验证; 100 张用于测试。

由于网络训练需要大量的数据, 而本文采用的数据集包含的图片较少, 因此本文采用数据增强技术^[12], 运用在线数据增强的方式, 即不增加训练集的图片数量, 而在每个 Batch 输入网络训练前先对图片随机旋转 90° 、 180° 、 270° , 翻折和平移处理, 本文采用的测试集为 Set5^[13]、Set14^[14]、BSD100^[15], 该测试集分别包含 5、14、100 张图片。实验时将原始图像进行下采样生成低分辨率图像作为输入, 然后将 RGB 图像转换为 YCbCr 通道图像, 最后对 Y 通道进行重建。

本实验的环境为 Python-PyTorch 框架, 一张 NVIDIA GeForce 2080Ti 显卡。为了具有可比性, 参照多尺度卷积注意力机制神经网络中 RG 模块设置的数目, 本文 RG 模块同样设置为 10, 由于实验设备的限制, 在训练 RCAN 时将 RCAB 的个数设置为 15, Batchsize 设置为 8, 同时在训

练多尺度卷积注意力机制神经网络时也采用相同的设置, 从而保证了对比的公平性。网络采用 Adam 优化器, 其中 $\beta_1=0.9$ 、 $\beta_2=0.999$ 、 $\epsilon=10^{-8}$, 初始学习率设为 10^{-4} , 每迭代 2×10^5 次学习率减少 $1/2$ 。

3.2 评价指标

图像超分辨率重建的评价标准主要有峰值信噪比 (peak signal to noise ratio, PSNR) 和结构相似性^[16] (structural similarity, SSIM)。

给定一张大小为 $m \times n$ 的重建图像 x 和一张同样大小的原始高清图 y , 均方误差 (mean square error, MSE) 表示为:

$$M_{SE} = \frac{1}{mm} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [y(i,j) - x(i,j)]^2 \quad (13)$$

PSNR 表示为:

$$P_{SNR} = 10 \lg \left(\frac{255 \times 255}{M_{SE}} \right) \quad (14)$$

PSNR 是一种评鉴画质的经典测量方法, 因为对于 PSNR 值高的图像, 人眼观看的画质质量不一定高, 所以评价标准还需要 SSIM 值。

结构相似性是一种衡量两幅图像相似度的测量方法, 对于两张图像 x 和 y , SSIM 的计算公式为:

$$S_{SIM} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (15)$$

其中: μ_x 为 x 的平均值; μ_y 为 y 的平均值; σ_x^2 为 x 的方差; σ_y^2 为 y 的方差; σ_{xy} 为 x 和 y 的协方差; $c_1 = (k_1L)^2$ 、 $c_2 = (k_2L)^2$ 为维持稳定的常数, 通常取 $L = 255$ 、 $k_1 = 0.03$ 、 $k_2 = 0.03$ 。

3.3 实验结果与分析

本文与目前超分辨率重建中一些流行的方法进行对比, 如 Bicubic、SRCNN^[4]、FSRCNN^[5]、VDSR^[6]、RCAN^[9]。放大倍数分别为 2、3、4, 在 Set5、Set14、BSD100 测试集上进行测试, 最终得到的 PSNR 和 SSIM 值见表 1 所列。

从表 1 可以看出, 本文提出的方法在 PSNR 和 SSIM 两项指标上均取得了很好的结果, 数据结果显示本文方法的 PSNR 和 SSIM 值最大, 表明重建的结果最好。

从 PSNR 值的比较上可以发现, 本文方法相比经典三次插值方法、SRCNN 方法和 FSRCNN 方法在不同尺度的放大倍数上均有超过 1.00 dB 的提升。本文方法相对于 VDSR 方法在 BSD100 测试集上放大 2 倍的结果提升了 1.60 dB, 并且放大 4 倍的结果提升了 1.16 dB, 说明本文方法

对于低放大倍数和高放大倍数均有较好的重建结果。同时本文方法的结果相对于 RCAN 方法也

有小幅的提升,说明多尺度卷积对于网络性能有较好的提升。

表 1 PSNR 和 SSIM 指标对比

方法	指标	Set5			Set14			BSD100		
		2 倍	3 倍	4 倍	2 倍	3 倍	4 倍	2 倍	3 倍	4 倍
三次插值	PSNR/dB	33.66	30.39	28.42	26.79	26.55	26.00	29.56	27.21	25.96
	SSIM	0.929 9	0.868 2	0.810 4	0.778 8	0.774 2	0.702 7	0.843 1	0.738 5	0.667 5
SRCNN	PSNR/dB	36.34	32.39	30.09	29.29	29.00	27.20	31.11	28.20	26.70
	SSIM	0.952 1	0.903 3	0.853 0	0.883 9	0.814 5	0.741 3	0.883 5	0.779 4	0.701 8
FSRCNN	PSNR/dB	37.05	33.18	30.48	32.66	29.37	27.61	31.53	28.53	26.98
	SSIM	0.956 0	0.914 0	0.862 8	0.909 0	0.824 0	0.755 0	0.892 0	0.791 0	0.715 0
VDSR	PSNR/dB	37.53	33.67	31.35	33.05	29.78	28.02	31.90	28.83	27.29
	SSIM	0.959 0	0.921 0	0.883 0	0.913 0	0.832 0	0.768 0	0.896 0	0.799 0	0.726 0
RCAN	PSNR/dB	37.81	34.77	31.93	33.95	30.48	28.23	33.42	29.54	28.41
	SSIM	0.952 1	0.928 6	0.881 4	0.913 3	0.843 9	0.772 6	0.904 2	0.807 0	0.760 3
本文方法	PSNR/dB	37.91	34.89	32.03	33.97	30.56	28.30	33.50	29.59	28.45
	SSIM	0.952 3	0.929 6	0.882 9	0.913 3	0.844 3	0.773 9	0.904 7	0.808 1	0.761 4

为了验证本文方法重建的效果在视觉上是最佳的,实验从 3 个测试集中随机选取 6 张图片进行重建,放大 2 倍的结果如图 6、图 7 所示,放大

3 倍的结果如图 8、图 9 所示,放大 4 倍的结果如图 10、图 11 所示。6 张图的 PSNR 和 SSIM 的结果见表 2 所列。

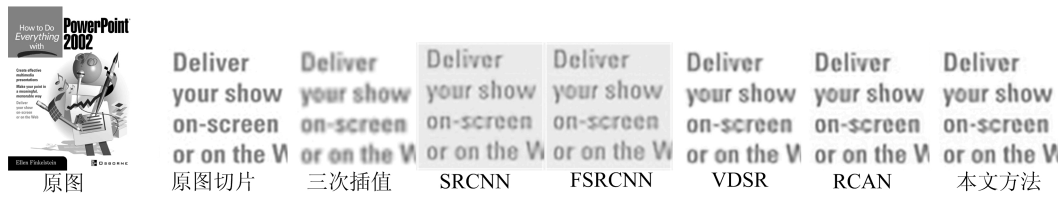


图 6 封面放大 2 倍各方法重建效果图




图 7 斑马放大 2 倍各方法重建效果图




图 8 风景放大 3 倍各方法重建效果图




图 9 猎豹放大 3 倍各方法重建效果图




图 10 飞机放大 4 倍各方法重建效果图




图 11 老鹰放大 4 倍各方法重建效果图

表 2 6 张图像的 PSNR 和 SSIM 指标

方法	图 6		图 7		图 8		图 9		图 10		图 11	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
三次插值	26.87	0.86	30.63	0.72	33.04	0.88	23.78	0.74	34.08	0.95	26.06	0.87
SRCNN	33.84	0.95	32.51	0.91	40.11	0.90	28.87	0.81	39.57	0.96	32.03	0.90
FSRCNN	31.65	0.98	33.89	0.94	35.18	0.90	26.75	0.81	38.77	0.96	30.56	0.89
VDSR	32.86	0.98	34.24	0.94	38.92	0.85	28.62	0.77	40.20	0.95	30.73	0.91
RCAN	34.03	0.98	35.26	0.95	41.11	0.92	29.82	0.84	41.07	0.98	33.30	0.95
本文方法	34.54	0.98	35.37	0.95	41.16	0.93	29.91	0.84	41.22	0.98	33.37	0.95

从图 6 可以看出,本文方法重建的图像在字母的边缘信息和其他细节上比较丰富。从图 10 可以看出,本文方法对于机尾上的字母 A 的重建效果较好,纹理较其他方法更加清晰。从图 6 和图 10 可以看出,在低放大尺寸和高放大尺寸上,本文方法对图像中文字重建效果较好。

从图 7 可以看出,本文方法重建的图像很好地恢复了马背上的纹理。从图 8 可以看出,本文方法重建的远景中的人影有更清晰的轮廓。从图 11 可以看出,本文方法重建的鹰翅膀有更好的细节。从图 9 可以看出,虽然 VDSR 方法重建的图像有更清晰的纹理,但对比原图可以发现 VDSR 重建的图像有明显失真,从表 2 中 VDSR 方法的 SSIM 值明显低于其他方法的 SSIM 值也能佐证这一点。综合图 7~图 9、图 11 可知,本文方法重建的图像在纹理和细节恢复上表现得更好。

4 结 论

本文设计了一种基于多尺度卷积和通道注意力机制的卷积神经网络结构,对单幅图像进行超分辨率重建,加强对特征图的利用。多尺度卷积通过不同尺寸的卷积核,加强了网络对图像尺寸的鲁棒性。通道注意力机制通过学习的方法,使得特征图不再像传统网络被平等的处理,计算机

算力分配更加高效。2 种机制的结合,从 2 个方向加强特征图的利用。实验结果表明本文的重建方法效果良好,在各个指标以及主观视觉上表现突出。本文研究的不足之处是网络结构未能进一步优化,因此下一步工作将是继续研究多尺度卷积和通道注意力机制的深度结合,将多尺度卷积融合进入通道注意力残差模块。

[参 考 文 献]

- [1] 刘永信,段添添. 基于深度学习的图像超分辨率重建技术的研究[J]. 科技与创新,2018(23):40-43.
- [2] PELED S, YESHURUN Y. Super resolution in MRI: application to human white matter fiber tract visualization by diffusion tensor imaging[J]. Magnetic Resonance in Medicine, 2001, 45(1):29-35.
- [3] BAKER S, KANADE T. Limits on super-resolution and how to break them[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2002, 24(9):1167-1183.
- [4] DONG C, LOY C C, HE K M, et al. Learning a deep convolutional network for image super-resolution[C]//European Conference on Computer Vision, Berlin, Springer, 2014:184-199.
- [5] DONG C, LOY C C, HE K M, et al. Accelerating the super-resolution convolutional neural network[C]//European Conference on Computer Vision, Berlin, Springer, 2016:391-407.
- [6] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks [C]//The

- IEEE Conference on Computer Vision and Pattern Recognition, Washington, D. C. ; IEEE Computer Society, 2016; 1646-1654.
- [7] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//The IEEE Conference on Computer Vision and Pattern Recognition, Washington, D. C. ; IEEE Computer Society, 2015; 770-778.
- [8] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]//The IEEE Conference on Computer Vision and Pattern Recognition, Washington, D. C. ; IEEE Computer Society, 2017; 136-144.
- [9] ZHANG Y, LI K, WANG L. Image super-resolution using very deep residual channel attention networks[C]//European Conference on Computer Vision, Berlin; Springer, 2018; 286-301.
- [10] SZEGEDY C, WEI L, JIA Y, et al. Going deeper with convolutions[C]//The IEEE Conference on Computer Vision and Pattern Recognition, Washington, D. C. ; IEEE Computer Society, 2015; 1-9.
- [11] HINTON E. Rectified linear units improve restricted boltzmann machines [C]//International Conference on Machine Learning, [S. l. : s. n.], 2010; 807-814.
- [12] LI Z, YANG J L, LIU Z, et al. Feedback network for image super-resolution[C]//The IEEE Conference on Computer Vision and Pattern Recognition, Washington, D. C. ; IEEE Computer Society, 2019; 3867-3876.
- [13] BEVILACQUA M, ROUMY A, GUILLEMOT C. Low-complexity single image super-resolution based on nonnegative neighbor embedding [C]//British Machine Vision Conference, Guildford; Springer, 2012; 1-10.
- [14] ZEYDE R, ELAD M, PROTTER M. On single image scale-up using sparse-representations [C]//The International Conference on Curves and Surfaces, Berlin; Springer, 2010; 711-730.
- [15] MARTIN D, FOWLKES C, TAL D. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]//The IEEE International Conference on Computer Vision, Washington, D. C. ; IEEE Computer Society, 2001; 416-423.
- [16] ZHANG K, ZUO W M, ZHANG L. Deep plug-and-play super-resolution for arbitrary blur kernels[C]//The IEEE Conference on Computer Vision and Pattern Recognition, Washington, D. C. ; IEEE Computer Society, 2019; 1671-1681.

(责任编辑 闫杏丽)

(上接第 1247 页)

- [5] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016; 121-146.
- [6] 杨力, 耿纪超, 汪克亮. 模糊支持向量机在煤与瓦斯突出预测中的研究[J]. 中国安全生产科学技术, 2014, 10(4): 103-108.
- [7] 李书全, 刘世杰. 基于改进的 PSO-SVM 项目安全预测模型仿真与验证[J]. 统计与决策, 2018(2): 182-185.
- [8] 远建平. 基于改进支持向量机的建设项目质量预警研究[D]. 北京: 华北电力大学, 2016.
- [9] 王学恩, 韩崇昭, 韩德强, 等. 粗糙集研究综述[J]. 控制工程, 2013, 20(1): 1-8.
- [10] 马捷, 葛岩, 蒲泓宇. 属性约简方法研究综述[J]. 数据分析与知识发现, 2020, 4(1): 40-50.
- [11] 周荣义, 钟岸, 任竞舟, 等. 基于主成分分析和神经网络的事预测方法及应用[J]. 中国安全生产科学技术, 2013, 23(7): 55-60.
- [12] 张炎亮, 秦惜梦, 崔庆安. 基于 PCA&SVM 的多品种小批量产品质量预测方法研究[J]. 科技管理研究, 2016(14): 234-237.
- [13] VAPNIK V N, LEVIN E, LE C Y. Measuring the VC-dimension of a learning machine[J]. Neural Computation, 2003, 6(5): 851-876.
- [14] VAPNIK V N. The nature of statistical learning theory [M]. New York; Springer, 1995.
- [15] 陈晋音, 熊晖, 郑海斌. 基于粒子群算法的支持向量机的参数优化[J]. 计算机科学技术, 2018, 46(6): 197-203.
- [16] KOUR V P, ARORA S. Particle swarm optimization based support vectormachine for the segmentation and classification of plants[J]. IEEE Access, 2019, 7(1): 22-16.
- [17] WINGE S, ALBRECHTSEN E, ARNESEN J. A comparative analysis of safety management and safety performance in twelve construction projects[J]. Journal of Safety Research, 2019, 71: 139-152.
- [18] 张伟, 朱双娜, 张潇, 等. 建筑施工安全事故致因系统模型与实证分析[J]. 中国安全科学学报, 2019, 29(6): 56-62.
- [19] 杜婷, 宋艳红, 李智莹, 等. 基于模糊综合评价法的建筑项目施工安全评价[J]. 土木工程与管理学报, 2019, 36(6): 61-66.
- [20] 张仕廉, 聂李琴. 基于 DEMATEL 方法的建筑施工安全管理行为影响因素分析[J]. 安全与环境工程, 2017, 24(1): 121-125.
- [21] SRIBALAJI R, CHINNASAMY M. The study on impact & improvement on construction safety management related project planning and scheduling in India[J]. International Journal of Engineering and Technical Research, 2017, 6(3): 46-49.

(责任编辑 张 镗)