













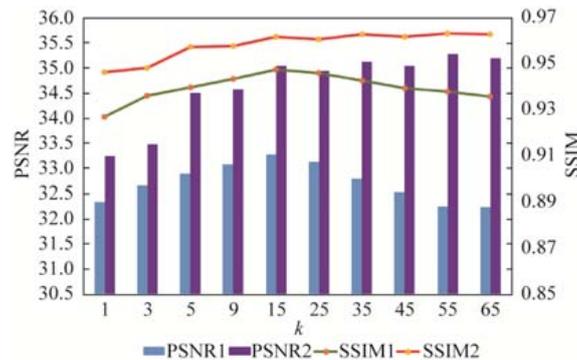
练,100 张人脸图像进行测试,HR 图像分辨率为  $64 \times 64$ ,LR 图像分辨率为  $32 \times 32$ .分别计算了 100 张测试图像的平均 PSNR 和平均 SSIM.从表 1 中可以看出,通过近邻初始化网络权重神经网络的训练时间减少为原来的  $\frac{1}{3}$ ,同时网络得到更好的收敛,在 100 个测试图像中 PSNR 有了 4.8dB 的提高,而 SSIM 也提高了 0.6.

**Table 1** Comparison between initial network weight randomly and initial it by neighbor

表 1 随机初始化与近邻初始化结果对比

|                | Initial randomly | Initial by neighbor |
|----------------|------------------|---------------------|
| Train time (h) | 2.101 3          | 0.635 4             |
| PSNR           | 30.266 0         | 35.006 9            |
| SSIM           | 0.904 7          | 0.961 6             |

在第 2.2 节中,本文就为什么选用图结构来描述人脸图像进行了详细的讨论,分析了传统的基于网格的特征描述方法与基于图结构特征描述方法的主要区别,为了证明提出方法的有效性,同样在 DUT Multi-View 数据集中进行了实验.实验中为了模拟基于网格的特征描述方法,使用公式(3)计算每条边的权重,即只考虑坐标的相似性而忽略纹理的相似性.选取 400 张多角度人脸图像进行训练,100 张多角度人脸图像进行测试,其中 HR 图像分辨率为  $64 \times 64$ ,LR 图像分辨率为  $32 \times 32$ .神经网络隐藏层神经元个数为 50.分别计算两种方法取不同  $k$  值时,在测试集上的平均 PSNR 以及平均 SSIM,得到如图 4 所示结果.图中,PSNR1 和 SSIM1 表示用公式(3)计算权重得到的结果,PSNR2 和 SSIM2 为由公式(4)计算权重得到的实验结果,横坐标为  $k$  的值,左边的纵坐标表示 PSNR 值,右边纵坐标表示 SSIM 值.从图中可以看出,基于图结构的局部特征描述方法相对于只考虑坐标相似的基于网格的方法取得了更好的结果.这说明,在人脸超分辨率问题中,在对每个像素的局部信息进行描述时,同时考虑坐标相似性与纹理相似性会更有效地描述当前像素的特征.从图中还可以看出,在基于网格的特征描述方法中,随着  $k$  值的增大,无效信息和有效信息同时增加,并且很快无效信息占据主导地位,当  $k=15$  时,算法取得最大精度,之后随着  $k$  值的增加,精度便开始下降.而在本文的方法中,由于尽可能避免加入无效信息,所以在  $k$  值较小时,便取得了较网格方法更好的精度(这里对于  $k=1$  时,两种方法结果不同的原因,本文认为主要是由于每个节点的描述信息过少,神经网络收敛不稳定导致).同时,随着  $k$  值的增大,当基于网格的方法的精度已经不能继续提高时,本文方法的精度却随着  $k$  值的增大而进一步提高.值得注意的是,本文在相同的训练集以及测试集上对最新的人脸超分辨率算法 SRLSPS<sup>[26]</sup>进行了实验,得到的平均 PSNR 和平均 SSIM 值分别为 33.413 5dB 和 0.952 7,而当  $k=15$  时,基于网格的特征描述方法的平均 PSNR 和平均 SSIM 值分别为 33.275 9dB 和 0.947 5,这说明,对基于网格的特征描述方法的模拟几乎可以达到最新人脸超分辨率算法的精度,也进一步证明了本文方法的有效性.



**Fig.4** Comparison between grid based method and our graph based method

图 4 基于网格方法与本文的基于图结构方法比较

对于隐藏层神经元的数量,依旧选用上述训练集和测试集,本文针对取不同隐藏层神经元数量时对算法的影响进行了评估,得到如图 5 所示结果.图中横坐标表示隐藏层神经元数量,可以看出当隐藏层神经元数量在 10~100 之间时,实验结果基本保持不变.而当隐藏层神经元数量进一步增加到 150~500 后,在有限数量的训练样

本的情况下,网络出现过拟合,准确率下降.为了在保证精度的前提下,尽可能地简化每个子网络的结构,本文在拥有少量训练样本的情况下取隐藏层神经元数量为 50,当训练样本数量增加时,隐藏层神经元数量也会适当增加.

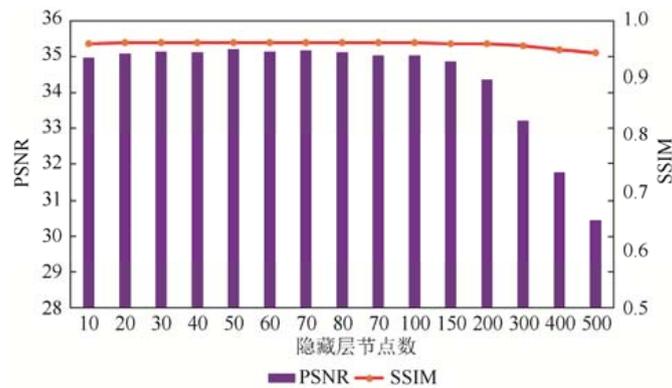


Fig.5 The influence of the number of neur for regression precision

图 5 不同隐藏层神经元数对回归精度的影响

### 3.3 对比实验

首先本文在 FEI<sup>[39]</sup>数据集上将基于图结构的人脸超分辨率回归方法与最新的人脸超分辨率方法行了对比.实验中设定 HR 图像分辨率为  $180 \times 130$ ,对 HR 图像进行 2、4、8 倍降采样得到的 LR 图像分辨率分别为  $90 \times 65$ 、 $45 \times 33$ 、 $23 \times 18$ .对比的人脸超分辨率算法包括:LCR<sup>[40]</sup>、LINE<sup>[41]</sup>、SRLSPS<sup>[38]</sup>.其中,LCR<sup>[40]</sup>在邻域嵌入过程中,通过自适应地选择最相关的像素块,避免了传统邻域嵌入算法中使用固定数量近邻导致的欠拟或过拟合.而 LINE<sup>[41]</sup>采取由粗到细的方法,迭代地更新每个 LR 像素块所对应的相关像素块,从而解决图像降采样过程中 LR 图像与 HR 图像在流形空间局部一致性假设不成立的问题.对于每一种方法都使用随机选取出的 300 张人脸图像进行训练,剩余的 100 张人脸图像进行测试.本文的方法中,神经网络隐层神经元数为 50.

**Table 2** Comparison of performance of our method against state-of-the-art method on FEI dataset

表 2 本文方法与最新人脸超分辨率方法在 FEI 数据集上的对比

| SRF | Our      |         | LCR      |         | LINE     |         | SRLSPS   |         |
|-----|----------|---------|----------|---------|----------|---------|----------|---------|
|     | PSNR     | SSIM    | PSNR     | SSIM    | PSNR     | SSIM    | PSNR     | SSIM    |
| 2   | 40.361 7 | 0.976 1 | 36.677 7 | 0.951 5 | 36.629 7 | 0.940 0 | 37.484 2 | 0.967 3 |
| 3   | 34.310 8 | 0.916 3 | 33.499 7 | 0.908 6 | 33.607 3 | 0.909 3 | 30.125 8 | 0.847 9 |
| 4   | 28.889 6 | 0.793 3 | 25.611 5 | 0.725 9 | 25.820 4 | 0.745 5 | 24.750 5 | 0.639 4 |

实验结果见表 2.可以看出,在 2 倍、4 倍以及 8 倍降采样的 LR 测试图像上,相比其他 3 种方法,本文方法都取得了最好的实验结果,特别是在 2 倍和 8 倍降采样测试图像上,PSNR 值相比其他 3 种方法提高了 3dB~4dB.这充分说明,相比利用规则矩形网格描述图像局部的方法,本文通过将 LR 人脸图像转化为传统图结构,并在对每个像素的描述过程中,同时考虑到了几何和纹理的影响,很好地表达了每个像素的局部信息;再加以分治的思想,针对人脸局部结构相似的特点,为每一个像素所形成的局部区域训练一个简单的神经网络,充分学习到了每个 LR 图像像素与 HR 图像像素之间的映射关系,最终使得本文的方法在 2 倍、4 倍、8 倍降采样的测试 LR 图像上都取得了最好结果.值得说明的是,上述与本文对比的 3 种方法都只是在灰度通道对人脸图像进行超分辨率操作,而本文的方法利用神经网络同时回归 RGB 三通道的像素值,但是为了方便比较,本文将得到的三通道结果图像转为灰度图像,并在灰度图像上与 3 种方法进行了对比.图 6 为本文方法和其他 3 种方法在 FEI 数据集上的部分结果,可以看出,对于 8 倍降采样的 LR 人脸图像,本文方法获得了更多的细节表现,更好地重建出人脸图像中关键的五官信息.

随后,在 DUT Multi-View 多视角人脸数据集上,本文与人脸超分辨率算法 SRLSPS<sup>[38]</sup>,以及 SRCNN<sup>[42]</sup>、SelfExSR<sup>[43]</sup>、VDSR<sup>[44]</sup>这 3 种最新的针对自然图像的超分辨率算法进行了对比.其中, SRCNN<sup>[42]</sup>与 VDSR<sup>[44]</sup>采

用深度卷积神经网络来实现超分辨率重建,而SelfExSR<sup>[43]</sup>直接根据输入LR图像中存在的自相似性进行超分辨率重建.实验过程中,设定HR图像分辨率为128×128,对HR图像进行3、4、8倍降采样得到的LR图像分辨率分别为43×43、32×32和16×16.对于SRLSPS<sup>[38]</sup>、SRCNN<sup>[42]</sup>、VDSR<sup>[44]</sup>和本文方法,选取DUT Multi-View多视角人脸数据集中2000张图像进行训练.在本文的方法中,设定每个子神经网络隐藏层神经元数为100.而SelfExSR<sup>[43]</sup>通过输入图像的自相似性进行超分辨率重建,不需要训练集.实验中测试样本集为DUT Multi-View多视角人脸数据集中的500张不同视角的人脸图像,且训练样本集与测试样本集不存在交叉.

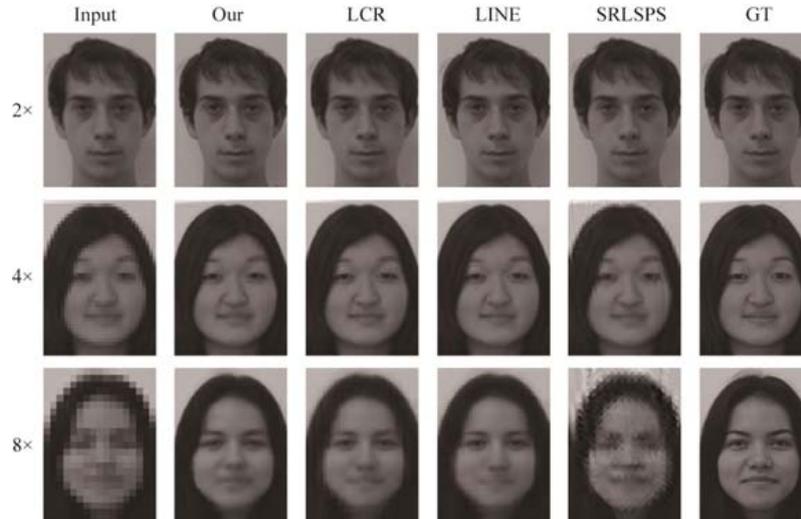


Fig.6 Some of results on FEI dataset

图6 FEI数据集上的部分实验结果

实验结果见表3.对于3倍降采样的LR人脸图像,本文方法得到的结果与基于图像自相似性的SelfExSR<sup>[38]</sup>相当,超过了基于卷积神经网络的SRCNN<sup>[42]</sup>以及基于邻域嵌入的SRLSPS<sup>[38]</sup>,可以看出,在3倍降采样人脸图像上,基于图结构的神经网络回归方法超越了浅层卷积神经网络.在4倍降采样人脸图像上,本文方法达到了与利用20层卷积层的VDSR相当的结果.进一步地,在8倍降采样人脸图像上,基于图结构的神经网络回归方法超过所有其他方法,在PSNR和SSIM上均取得了最好结果.说明本文方法在处理高倍降采样的人脸图像上,相比卷积神经网络等其他方法更具优势.这也充分证明第2.2节中所得出的结论,即对于人脸超分辨率问题,在提取每个像素局部特征时,将图像转化为传统图结构,同时考虑节点间几何与纹理的相似性,相比直接不加区分地利用规则网矩形格中所有信息的方法具有更好的描述能力.图7中给出了实验中5种方法得到的部分实验结果.从图7中可以看出,对于4倍降采样的LR人脸图像,本文方法在PSNR和SSIM上虽然没有VDSR出色,但在双眼、鼻子、嘴巴附近,特别是脸颊边缘,获得了更多的细节表现.进一步地,对于8倍降采样的LR人脸图像,SelfExSR<sup>[43]</sup>和VDSR<sup>[44]</sup>的结果已经很难辨认出五官信息,出现了严重的涂抹情况,SRLSPS<sup>[38]</sup>结果中的边缘也严重抖动.而此时,通过为每一个像素训练一个简单神经网络,并将整张人脸图像的超分辨率问题分解成对每个像素的超分辨率回归问题,使得本文方法在高降采样倍数的情况下,在纹理边缘位置获得了出众的细节表现,很大程度上避免了涂抹情况的产生.

**Table 3** Comparison of performance of our method against state-of-the-art method on DUT Multi-View

表3 本文方法与最新人脸超分辨率方法在DUT Multi-View数据集上的对比

| SRF | Our      |         | SRLSPS   |         | SRCNN    |         | SelfExSR |         | VDSR     |         |
|-----|----------|---------|----------|---------|----------|---------|----------|---------|----------|---------|
|     | PSNR     | SSIM    |
| 3   | 36.215 8 | 0.953 5 | 34.234 4 | 0.938 1 | 35.076 7 | 0.945 3 | 36.259 9 | 0.958 0 | 36.875 4 | 0.960 4 |
| 4   | 33.921 5 | 0.924 4 | 31.314 6 | 0.891 8 | 32.567 7 | 0.908 5 | 33.434 7 | 0.925 3 | 34.307 5 | 0.933 7 |
| 8   | 28.956 9 | 0.819 9 | 26.966 2 | 0.753 8 | 26.734 2 | 0.747 9 | 26.866 8 | 0.756 7 | 28.319 2 | 0.809 0 |

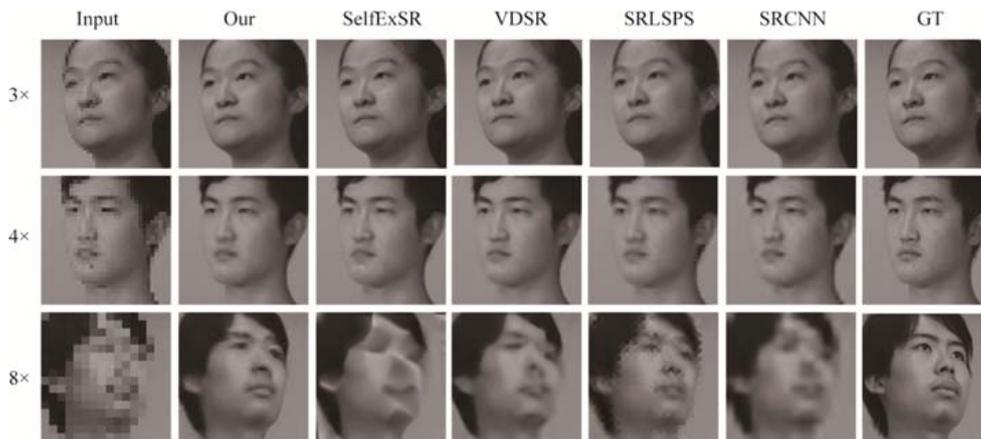


Fig.7 Some of results on DUT Multi-View dataset

图7 DUT Multi-View 数据集上的部分实验结果

#### 4 结论与总结

本文针对人脸图像具有局部一致性的特点,提出了一种基于图结构的人脸超分辨率神经网络回归方法.通过将 LR 人脸图像转换为图结构,在局部特征描述时,同时考虑节点的纹理与几何的相关性,相比传统的基于网格的方法更好地表达了每个像素周围的局部特征.同时,通过为每一个像素训练一个简单的子神经网络,将整张人脸图像上的超分辨率问题分解成对每个像素的超分辨率回归问题,使得本文方法在高降采样倍数的情况下,在纹理边缘位置获得了出色的细节表现,很大程度上避免了涂抹情况的产生.在子网络训练过程中,充分利用相邻像素较为相似的特点,本文提出一种神经网络参数传递方法,通过用已经收敛的相邻像素的网络参数来初始化下一个网络的参数,极大地提高了神经网络的收敛速度以及预测精度.在与 3 种最新人脸超分辨率算法的比较中,本文方法取得了最好的结果;在与最新的基于深度卷积神经网络等最新的自然图像超分辨率算法的比较中,本文方法在高降采样倍数的 LR 人脸图像上表现出极大的优势.本文提出的图神经网络(GNN)并不局限于解决二维人脸图像的超分辨率问题,它还可以应用于诸如 3D 网格等各种具有不规则拓扑结构的数据,解决不同的问题.

#### References:

- [1] Shin HC, Roth HR, Gao M, Lu L, Xu, Z, Nogueis I, Summers RM. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE Trans. on Medical Imaging*, 2016,35(5):1285–1298. [doi: 10.1109/TMI.2016.2528162]
- [2] Rastegari M, Ordonez V, Redmon J, Farhadi A. XNOR-Net: ImageNet classification using binary convolutional neural networks. In: Bastian L, Jiri M, Nicu S, Max W, eds. *Proc. of the European Conf. on Computer Vision*. Cham: Springer Int'l Publishing, 2016. 525–542. [https://link.springer.com/chapter/10.1007/978-3-319-46493-0\\_32](https://link.springer.com/chapter/10.1007/978-3-319-46493-0_32)
- [3] Gatys LA, Ecker AS, Bethge M. Image style transfer using convolutional neural networks. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2016. 2414–2423. [doi: 10.1109/CVPR.2016.265]
- [4] Wang CF, Su L, Zhang WG, Huang QM. No reference video quality assessment based on 3D convolutional neural network. *Ruan Jian Xue Bao/Journal of Software*, 2016,27(Suppl.(2)):103–112 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/16025.htm>
- [5] Liu N, Li CH. Single image super-resolution reconstruction via deep convolutional neural network. *China Sciencepaper*, 2015, 10(2):201–206 (in Chinese with English abstract).
- [6] Hu W, Cheung G, Kazui M. Graph-Based dequantization of block-compressed piecewise smooth images. *IEEE Signal Processing Letters*, 2016,23(2):242–246. [doi: 10.1109/LSP.2015.2510379]

- [7] Pang J, Cheung G. Graph Laplacian regularization for image denoising: Analysis in the continuous domain. *IEEE Trans. on Image Processing*, 2017,26(4):1770–1785. [doi: 10.1109/TIP.2017.2651400]
- [8] Niepert M, Ahmed M, Kutzkov K. Learning convolutional neural networks for graphs. In: Balcan MF, Weinberger KQ, eds. *Proc. of the 33rd Annual Int'l Conf. on Machine Learning*. New York: ACM, 2016. <http://proceedings.mlr.press/v48/niepert16.html>
- [9] Puy G, Kitić S, Pérez P. Unifying local and non-local signal processing with graph CNNs. *arXiv:1702.07759*, 2017.
- [10] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering. In: Lee DD, Sugiyama M, Luxburg UV, Guyon I, Garnett R, eds. *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2016. 3837–3845.
- [11] Xie S, Girshick R, Dollár P, Tu Z, He K. Aggregated residual transformations for deep neural networks. *arXiv: 1611.05431*, 2016.
- [12] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2016. 770–778. [doi: 10.1109/CVPR.2016.90]
- [13] Gao X, Zhang K, Tao D, Li X. Image super-resolution with sparse neighbor embedding. *IEEE Trans. on Image Processing*, 2012,21(7):3194–3205. [doi: 10.1109/TIP.2012.2190080]
- [14] Dai S, Han M, Xu W, Wu Y, Gong Y. Soft edge smoothness prior for alpha channel super resolution. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2007. 1–8. [doi: 10.1109/CVPR.2007.383028]
- [15] Sun J, Xu Z, Shum HY. Image super-resolution using gradient profile prior. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2008. 1–8. [doi: 10.1109/CVPR.2008.4587659]
- [16] Ji H, Fermüller C. Robust wavelet-based super-resolution reconstruction: Theory and algorithm. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2009,31(4):649–660. [doi: 10.1109/TPAMI.2008.103]
- [17] Belekos SP, Galatsanos NP, Katsaggelos AK. Maximum a posteriori video super-resolution using a new multichannel image prior. *IEEE Trans. on Image Processing*, 2010,19(6):1451–1464. [doi: 10.1109/TIP.2010.2042115]
- [18] Zhu Y, Li K, Jiang J. Video super-resolution based on automatic key-frame selection and feature-guided variational optical flow. *Signal Processing, Image Communication*, 2014,29(8):875–886. [doi: 10.1016/j.image.2014.06.005]
- [19] Li K, Zhu Y, Yang J, Jiang J. Video super-resolution using an adaptive superpixel-guided auto-regressive model. *Pattern Recognition*, 2016,51,59–71. [doi: 10.1016/j.patcog.2015.08.008]
- [20] Su H, Zhou J, Zhang ZH. Survey of super-resolution image reconstruction methods. *Acta Automatica Sinica*, 2013,39(8):1202–1213 (in Chinese with English abstract).
- [21] Yang J, Wright J, Huang TS, Ma Y. Image super-resolution via sparse representation. *IEEE Trans. on Image Processing*, 2010,19(11):2861–2873. [doi: 10.1109/TIP.2010.2050625]
- [22] Zhang Y, Liu J, Yang W, Guo Z. Image super-resolution based on structure-modulated sparse representation. *IEEE Trans. on Image Processing*, 2015,24(9):2797–2810. [doi: 10.1109/TIP.2015.2431435]
- [23] Ledig C, Theis L, Huszár F, Caballero J, Cunningham A, Acosta A, Shi W. Photo-Realistic single image super-resolution using a generative adversarial network. *arXiv:1609.04802*, 2016. [doi: 10.1109/CVPR.2017.19]
- [24] Wang Z, Liu D, Yang J, Han W, Huang T. Deep networks for image super-resolution with sparse prior. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2015. 370–378. [doi: 10.1109/ICCV.2015.50]
- [25] Chakrabarti A, Rajagopalan AN, Chellappa R. Super-Resolution of face images using kernel pca-based prior. *IEEE Trans. on Multimedia*, 2007,9(4):888–892. [doi: 10.1109/TMM.2007.893346]
- [26] Wang X, Tang X. Hallucinating face by eigentransformation. *IEEE Trans. on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 2005,35(3):425–434. [doi: 10.1109/TSMCC.2005.848171]
- [27] An L, Bhanu B. Face image super-resolution using 2D CCA. *Signal Processing*, 2014,103:184–194. [doi: 10.1016/j.sigpro.2013.10.004]
- [28] Wu W, Liu Z, He X. Learning-Based super resolution using kernel partial least squares. *Image and Vision Computing*, 2011,29(6):394–406. [doi: 10.1016/j.imavis.2011.02.001]
- [29] Park JS, Lee SW. An example-based face hallucination method for single-frame, low-resolution facial images. *IEEE Trans. on Image Processing*, 2008,17(10):1806–1816. [doi: 10.1109/TIP.2008.2001394]
- [30] Capel D, Zisserman A. Super-Resolution from multiple views using learnt image models. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*, Vol.2. 2001. II. [doi: 10.1109/CVPR.2001.991022]
- [31] Yang J, Wright J, Huang TS, Ma Y. Image super-resolution via sparse representation. *IEEE Trans. on Image Processing*, 2010, 19(11):2861–2873. [doi: 10.1109/TIP.2010.2050625]

- [32] Li M, Cheng J, Le X, Luo HM. Super-Resolution based on sparse dictionary coding. Ruan Jian Xue Bao/Journal of Software, 2012,23(5):1315–1324 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/3989.htm> [doi: 10.3724/SP.J.1001.2012.03989]
- [33] Chang H, Yeung DY, Xiong Y. Super-Resolution through neighbor embedding. In: Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition, Vol.1. 2004. I. [doi: 10.1109/CVPR.2004.1315043]
- [34] Huang H, Wu N. Fast facial image super-resolution via local linear transformations for resource-limited applications. IEEE Trans. on Circuits and Systems for Video Technology, 2011,21(10):1363–1377. [doi: 10.1109/TCSVT.2011.2163461]
- [35] Huang H, He H, Fan X, Zhang J. Super-Resolution of human face image using canonical correlation analysis. Pattern Recognition, 2010,43(7):2532–2543. [doi: 10.1016/j.patcog.2010.02.007]
- [36] Gao X, Zhang K, Tao D, Li X. Joint learning for single-image super-resolution via a coupled constraint. IEEE Trans. on Image Processing, 2012,21(2):469–480. [doi: 10.1109/TIP.2011.2161482]
- [37] He H, Siu WC. Single image super-resolution using Gaussian process regression. In: Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition. 2011. 449–456. [doi: 10.1109/CVPR.2011.5995713]
- [38] Jiang J, Chen C, Ma J, Wang Z, Wang Z, Hu R. SRLSP: A face image super-resolution algorithm using smooth regression with local structure prior. IEEE Trans. on Multimedia, 2017,19(1):27–40. [doi: 10.1109/TMM.2016.2601020]
- [39] Thomaz CE, Giraldi GA. A new ranking method for principal components analysis and its application to face image analysis. Image and Vision Computing, 2010,28(6):902–913. [doi: 10.1016/j.imavis.2009.11.005]
- [40] Jiang J, Hu R, Wang Z, Han Z. Noise robust face hallucination via locality-constrained representation. IEEE Trans. on Multimedia, 2014,16(5):1268–81. [doi: 10.1109/TMM.2014.2311320]
- [41] Jiang J, Hu R, Wang Z, Han Z. Face super-resolution via multilayer locality-constrained iterative neighbor embedding and intermediate dictionary learning. IEEE Trans. on Image Processing, 2014,23(10):4220–4231. [doi: 10.1109/TIP.2014.2347201]
- [42] Dong C, Loy CC, He K, Tang X. Image super-resolution using deep convolutional networks. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2016,38(2):295–307. [doi: 10.1109/TPAMI.2015.2439281]
- [43] Huang JB, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars. In: Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition. 2015. 5197–5206. [doi: 10.1109/CVPR.2015.7299156]
- [44] Kim J, Kwon LJ, Mu LK. Accurate image super-resolution using very deep convolutional networks. In: Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition. 2016. 1646–1654. [doi: 10.1109/CVPR.2016.182]

#### 附中文参考文献:

- [4] 王春峰,苏荔,张维刚,黄庆明.基于3D卷积神经网络的无参考视频质量评价.软件学报,2016,27(增刊(2)):103–112. <http://www.jos.org.cn/1000-9825/16025.htm>
- [5] 刘娜,李翠华.基于多层卷积神经网络学习的单帧图像超分辨率重建方法.中国科技论文,2015,10(2):201–206.
- [20] 苏衡,周杰,张志浩.超分辨率图像重建方法综述.自动化学报,2013,39(8):1202–1213.
- [32] 李民,陈建,乐翔,罗环敏.稀疏字典编码的超分辨率重建.软件学报,2012,23(5):1315–1324. <http://www.jos.org.cn/1000-9825/3989.htm> [doi: 10.3724/SP.J.1001.2012.03989]



呼延康(1992—),男,内蒙古太仆寺旗人,硕士生,主要研究领域为图像处理,3D人脸重建.



余乐天(1995—),男,学士,主要研究领域为图像处理,图像合成.



樊鑫(1977—),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为计算机视觉与图像处理,医学影像分析.



罗钟铉(1966—),男,博士,教授,博士生导师,CCF 专业会员,主要研究领域为计算几何,图像处理,机器视觉.