

# SCI-FFDNet-TV 阅读报告

赖泽强

2021 年 5 月 17 日

论文: Effective Snapshot Compressive-spectral Imaging via Deep Denoising and Total Variation Priors

## 1 基本思路

本质上就是对不同噪声强度的 FFDnet Prior 和 TV Prior 做了个加权, 论文乱七八糟讲了一大堆, 就是权重要怎么计算。

$$\begin{aligned} \min_{w^{ffd}, w^t} & \left\| \sum_{\sigma \in A} w_{\sigma}^{ffd} \text{FFD}_{\sigma}(\mathbf{x}) - \sum_{t \in B} w_t^{tv} \text{TV}_t(\mathbf{x}) \right\|_2^2 \\ \text{subject to} & \sum_{\sigma \in A} w_{\sigma}^{ffd} = 1, \sum_{t \in B} w_t^{tv} = 1 \\ & w_{\sigma}^{ffd} \geq 0, w_t^{tv} \geq 0, \sigma \in A, t \in B \end{aligned} \quad (1)$$

## 2 实验与分析

单纯用 FFDNet 效果会很差, 图像质量和 PSNR 都非常差; 单纯用 TV 的话, 图像质量看起来算正常, 但 PSNR 不高。表1展示了 Compress Sensing 的实验结果 (选了 ICVL 的 5 张图做的测试, 所有方法都迭代 100 次), 可以看成这篇论文确实有效融合了 TV 和 FFDNet 两个先验, 并且获得了比较大的提升, 但是, 使用我们自己 PnP-GRUNet 的方法效果更好。

	TV	FFDNet	SCI-FFDNet-TV	Ours
PSNR	29.98	26.39	34.31	39.31
SSIM	0.887	0.801	0.936	0.988

表 1: Compress Sensing 实验结果

考虑到 FFDNet 可能和我们的 GRUNet 差的比较多, 我们用 GRUNet 替代 FFDNet, 再测一下 SCI-Unet-TV 的效果。表2展示了将 SCI-FFDNet-TV 中的 FFDNet 替换为我们的 GRUNet 的结果。不难看出, 替换之后, 随着迭代的增多, SCI 这篇论文方法的上限明显提高了, 但是相比于我们的方法还是比较差, 并且时间复杂度大幅提高。

但是, 简单的将 FFDNet 替换成 GRUNet 效果不好的原因也有可能是参数没有配好。为此, 我们还需要进一步实验排除这个可能性。与此同时, SCI-FFDNet-TV 这篇用的 GAP 算法似乎和 GRUNet 并不是很配, 可能 ADMM 算法效果会更好。

SCI-FFDNet-TV	100 iter	200 iter	300 iter
PSNR	32.13	32.30	32.27
Time	3:06	6:37	10:08
SCI-GRUNet-TV	100 iter	200 iter	300 iter
PSNR	32.91	35.33	35.74
Time	20:36	40:08	59:33
Ours-GRUNet	100 iter	200 iter	300 iter
PSNR	39.43	39.59	39.49
Time	1:27	2:54	4:21

表 2: 不同 Denoiser 的测试结果。

### 3 扩展

为了验证这个方法的通用性, 我用 ADMM 算法 (原文在 Compress Sensing 上用的叫 GAP 算法), 使用相同的思路在 Deblur 问题上进行了测试。表3展示了 deblur 上的实验结果, 可以看出 Deblur 问题上, 融合 FFDNet 和 TV 也是有效果的, 但是和我们的方法比较还是差。

	TV	FFDNet	SCI-FFDNet-TV	Ours
PSNR	41.96	42.91	43.86	53.00
SSIM	0.969	0.969	0.975	0.999

表 3: Deblur 实验结果

### 4 对比

我们之前也做过融合 TV 的实验, 那么这篇论文的方法和我们之前的方法的不同在哪呢? 我们之前的融合深度和 TV Prior 的公式推导如下:

$$\begin{aligned}
& \text{minimize} && \frac{1}{2} \|Ax - y\|_2^2 + \phi g(v) + \lambda \sum_i^3 \|z_i\|_1 \\
& \text{subject to} && D_i x - z_i = 0 \\
& \text{subject to} && x - v = 0
\end{aligned} \tag{2}$$

$$\begin{aligned}
x^{(k+1)} &= \arg \min_x \frac{1}{2} \|Ax^{(k)} - y\|_2^2 + \sum_i^3 \frac{\rho}{2} \left\| D_i x^{(k)} - z_i^{(k)} + \mu_i^{(k)} \right\|_2^2 + \frac{\beta}{2} \|x^{(k)} - v^{(k)} + \mu^{(k)}\|_2^2 \\
z_i^{(k+1)} &= \arg \min_z \left( \lambda \|z_i^{(k)}\|_1 + \frac{\rho}{2} \left\| D_i x^{(k+1)} - z_i^{(k)} + \mu_i^{(k)} \right\|_2^2 \right) = TV\_denoising \left( x^{(k)} + \mu^{(k)} \right) \\
v^{(k+1)} &= \arg \min_v \left( \phi g(v^{(k)}) + \frac{\beta}{2} \left\| x^{(k)} - v^{(k)} + \mu^{(k)} \right\|_2^2 \right) = Deep\_denoising \left( x^{(k)} + \mu^{(k)} \right) \\
\nu_i^{(k+1)} &= \nu_i^{(k)} + D_i x^{(k+1)} - z_i^{(k+1)} \\
u^{(k+1)} &= u^{(k)} + x^{(k+1)} - v^{(k+1)}
\end{aligned} \tag{3}$$

单独的深度 Prior 推导如下:

$$\begin{aligned} & \text{minimize} && \frac{1}{2} \|Ax - y\|_2^2 + \phi g(v) \\ & \text{subject to} && x - v = 0 \end{aligned} \quad (4)$$

$$\begin{aligned} x^{(k+1)} &= \arg \min_x \frac{1}{2} \|Ax^{(k)} - y\|_2^2 + \frac{\beta}{2} \|x^{(k)} - v^{(k)} + \mu^{(k)}\|_2^2 \\ v^{(k+1)} &= \text{Deep\_denoising} \left( x^{(k)} + \mu^{(k)} \right) \\ u^{(k+1)} &= u^{(k)} + x^{(k+1)} - v^{(k+1)} \end{aligned} \quad (5)$$

单独的 TV Prior 推导如下:

$$\begin{aligned} & \text{minimize} && \frac{1}{2} \|Ax - y\|_2^2 + \lambda \sum_i^3 \|z_i\|_1 \\ & \text{subject to} && D_i x - z_i = 0 \end{aligned} \quad (6)$$

$$\begin{aligned} x^{(k+1)} &= \arg \min_x \frac{1}{2} \|Ax^{(k)} - y\|_2^2 + \sum_i^3 \frac{\rho}{2} \left\| D_i x^{(k)} - z_i^{(k)} + \mu_i^{(k)} \right\|_2^2 \\ z_i^{(k+1)} &= \text{TV\_denoising} \left( x^{(k)} + \mu^{(k)} \right) \\ \nu_i^{(k+1)} &= \nu_i^{(k)} + D_i x^{(k+1)} - z_i^{(k+1)} \end{aligned} \quad (7)$$

**SCI-FFDNet-TV** 这篇文章的思路本质上是将不同 Prior 的去噪结果进行一个加权, 然后将加权平均作为去噪结果。那么这篇论文本质上公式应该是下面这样的:

$$\begin{aligned} & \text{minimize} && \frac{1}{2} \|Ax - y\|_2^2 + \phi g(v) \\ & \text{subject to} && x - v = 0 \end{aligned} \quad (8)$$

$$\begin{aligned} x^{(k+1)} &= \arg \min_x \frac{1}{2} \|Ax^{(k)} - y\|_2^2 + \frac{\beta}{2} \|x^{(k)} - v^{(k)} + \mu^{(k)}\|_2^2 \\ v_{\text{deep}}^{(k+1)} &= \text{Deep\_denoising} \left( x^{(k)} + \mu^{(k)} \right) \\ v_{\text{tv}}^{(k+1)} &= \text{TV\_denoising} \left( x^{(k)} + \mu^{(k)} \right) \\ v^{(k+1)} &= w_1 v_{\text{deep}}^{(k+1)} + w_2 v_{\text{tv}}^{(k+1)} \\ u^{(k+1)} &= u^{(k)} + x^{(k+1)} - v^{(k+1)} \end{aligned} \quad (9)$$

综合比较我们的公式推导和 SCI-FFDNet-TV 的推导可以看出, 我们的方法本质上还是将 TV 作为一个显式手工先验加入到优化目标里, 而 SCI-FFDNet-TV 的话, 则是将 TV 作为和深度 Prior 一样的隐式先验, 通过在去噪那一步同时使用两个去噪者来引入两个先验。

## 5 总结

简单总结, SCI-FFDNet-TV 通过在 PnP 框架中去噪那一步, 使用一个加权和的方式引入 TV 先验的方式可能会比直接在 PnP 优化目标中显式引入 TV 先验的方式更加有效。实验证明, SCI-FFDNet-TV 确实能够在 TV 的帮助下在多个任务 (已经测了 Compress Sensing 和 Deblur) 获得一些性能提升。

当与我们的 PnP-GRUNet 的方法比较时, 这个方法还是显著弱于我们的方法。这可能源于两个方法的深度去噪者之间的差距, 但是进一步实验, 替换 SCI-FFDNet-TV 中的 FFDNet 为 GRUNet 后, SCI-GRUNet-TV 仍差于我们的方法。考虑到可能参数, 使用的 PnP 算法不太一样, 可能还需要进一步的实验验证 SCI-FFDNet-TV 的思路是否能够进一步提升我们 PnP-GRUNet 方法的性能。