

4984-99Z_Article Text-16367-1-2- 20220611.docx

PENGEMBANGAN ALGORITMA *DENOISING* DENGAN KONSEP *DEEP BACK-PROJECTION*

DEVELOPMENT OF *DENOISING* ALGORITHM BASED ON *DEEP BACK-PROJECTION*

Abstrak

Penelitian ini mengangkat salah satu permasalahan umum pada citra digital, terutama pada *smartphone*, yaitu *noise* yang disebabkan oleh kecilnya *aperture* dan ukuran *sensor* pada kamera digital. Untuk menyelesaikan permasalahan tersebut, peneliti mengembangkan metode *denoising* untuk mentransformasi citra kotor menjadi citra bersih. Terinspirasi dari konsep *deep back-projection*, penelitian ini melakukan modifikasi terhadap implementasi asli *deep back-projection*, menggunakan *down-projection* layer sebagai tahapan untuk menghilangkan *noise* dengan intuisi menggunakan bahwa proses *down-sampling* mampu menghilangkan *noise* pada input citra. Lalu citra kembali diperbesar sesuai ukuran aslinya. Pada eksperimen yang dilakukan, penelitian ini membuktikan bahwa teknik yang diajukan mampu memperoleh hasil terbaik dibandingkan metode lainnya pada dataset SIDD. Hasil eksperimen memperlihatkan peningkatan kualitas sebesar 6 dB dibandingkan model lainnya.

Kata kunci: *denoising*, *back-projection*, citra kotor, citra bersih

Abstract


This research discuss about one of the general problem in digital image, especially the one produced by *smartphone*, which is produced by small *aperture* and *sensor* on the *smartphone*. To solve this problem, the researcher develops *denoising* method that can transform noisy image to clean image. Inspired by *deep back-projection* network, this research modifies the original implementation of *deep back-projection*. We use the *down-projection* layer as a stage that can intuitively remove the *noise* by *down-sampling* procedure [14] then brings back the image to original size using *up-sampling* layer. In the experimental result, we show that the proposal is superior compared to other methods on SIDD dataset. The proposal has better quality, shown by the increased of 6 dB compare to other models.

Keywords: *denoising*, *back-projection*, noisy image, clean image

1. PENDAHULUAN

Dengan banyaknya jumlah *smartphone* terjual tiap tahun, kemampuan atau teknologi kamera pada *smartphone* semakin diharapkan menyamai kemampuan kamera *Digital Single Lens Reflex* (DSLR). Keunggulan dan kemudahan penggunaan merupakan salah satu penyebab *smartphone* semakin berkembang dan semakin banyak peminat. Namun, salah satu permasalahan yang dihadapi citra digital pada *smartphone* diantaranya adalah *denoising*. *Denoising* diakibatkan kecilnya ukuran sensor dan lensa pada *smartphone* dibandingkan DSLR.

Noise pada citra digital bukan hanya menyebabkan citra digital menjadi kurang baik secara estetik. Namun, berdasarkan riset yang dilakukan pada penelitian sebelumnya, citra kotor seperti pada Gambar 1, menyulitkan algoritma *computer vision*, seperti *object detection*, *segmentation*, untuk berfungsi dengan baik, atau bisa juga mengurangi performa dari model tersebut. Intuisi ini dibuktikan pada penelitian sebelumnya [1]. Haris et al [1]., menunjukkan citra resolusi rendah dapat mengurangi akurasi deteksi objek.



Gambar 1. Contoh perbandingan citra bersih dan citra kotor

Pada penelitian awal terkait denoising, banyak riset menggunakan noise buatan atau sintesis, seperti gaussian noise. Hal ini membuat metode denoising menjadi tidak aplikatif pada permasalahan nyata. Namun, kemajuan teknologi dan AI, memacu para periset untuk dapat menghasilkan model AI yang lebih aplikatif. Dataset SIDD [2] menyajikan banyak tipe citra kotor dari 5 tipe kamera pada smartphone dan menyediakan ground truth image yang diambil dari kamera DSLR. Dataset ini terdiri dari ~30,000 citra digital baik tipe sRGB maupun Raw. Pada penelitian ini kami fokus menggunakan dataset SIDD sebagai data untuk melatih dan mengevaluasi model yang dibuat.

Penelitian terkait denoising sudah banyak dilakukan oleh beberapa peneliti, seperti [3, 4, 5, 6, 7, 8]. Namun, pada awal penelitiannya, banyak periset bergantung pada noise sintesis dalam membuat dan mengevaluasi model denoising, seperti menggunakan white gaussian noise (AWGN) [8, 9]. Tren kenaikan performa deep learning juga searah dengan perbaikan cara mengevaluasi model denoising. Penelitian denoising semakin terdorong menggunakan data asli [2, 10]. Pada era deep learning, topik denoising juga menjadi salah satu topik yang banyak diteliti hingga sekarang [8]. Selain itu, permasalahan denoising umum juga dibahas pada pemrosesan sinyal [11].

Adapun kontribusi paper ini terbagi menjadi 2 yaitu sebagai berikut:

- **Deep back-projection network untuk denoising.** Penulis menunjukkan perubahan urutan pada up- dan down-projection modul dapat memodifikasi fungsi dari deep back-projection network untuk penyelesaian masalah denoising. Down-projection module dapat digunakan sebagai module denoising dengan cara memperkecil ukuran dari fitur citra, lalu up-projection digunakan sebagai module upsampling agar fitur tersebut kembali ke resolusi semula.


- **Eksperimen yang menyeluruh pada data non artifisial.** Pada hasil eksperimen, penulis menunjukkan performa model yang diajukan menggunakan data publik dengan komprehensif, serta membandingkan performanya dengan 7 metode lain. Model usulan sukses melampaui kualitas dari model lain dengan selisih sampai 6 dB.

2. DENOISING DEEP BACK-PROJECTION

Denoising merupakan salah satu inverse problem yang populer di domain citra digital. Selain *denoising*, ada banyak *inverse problem* lain yg populer seperti *super-resolution*, *image enhancement*, dan lain-lain. Pada problem *super-resolution*, DBPN [12, 13] diperkenalkan oleh Haris et al. DBPN berhasil menjadi model terbaik pada kompetisi *Super-resolution* di NTIRE2018 [14].

DBPN mengusulkan modul *iterative up-projection* dan *down-projection* yang digunakan untuk memperkuat relasi dua arah antara fitur resolusi rendah dan fitur resolusi tinggi. Selain itu, DBPN juga memperkenalkan modul *back-projection* [15] pada *deep learning* yang digunakan untuk meminimalisir *error feedback* untuk merekonstruksi citra yang lebih baik.

Terinspirasi dari model DBPN, penulis memanfaatkan modul *iterative down-projection* dan *up-projection* untuk menyelesaikan problem *denoising*. Transformasi yang dilakukan tergambar pada Gambar 2. Model usulan tetap mempertahankan komponen yang digunakan pada desain asli deep back-projection network.



Gambar 2. Proposal perubahan deep back-projection untuk Denoising dengan merubah urutan projection module pada deep back-projection network

Secara umum, komponen yang digunakan untuk model denoising sama dengan desain asli deep back-projection network. Pada model usulan, hanya output fitur dari up-projection network yang digabungkan untuk merekonstruksi *clean image*. Namun, perbedaan terletak pada tahapan

awal module back-projection. Pada super-resolution, tahapan pertama merupakan up-projection yang digunakan untuk memperbesar resolusi dari fitur citra tersebut. Sedangkan pada denoising, tahapan pertama merupakan down-projection yang digunakan untuk memperkecil resolusi dari fitur yg diharapkan noise akan diperkecil melalui operator down-sampling.

3. PEMBAHASAN

Pada metode yang kami ajukan, *projection unit* menggunakan 2 tipe *filter* dengan ukuran 8×8 *striding* 4 dan *padding* 2 untuk dataset sRGB serta *filter* dengan ukuran 12×12 *striding* 8 dan *padding* 2 untuk dataset Raw. Inisialisasi masing-masing layer menggunakan standard deviasi dengan perhitungan pada [16]. Seluruh convolutional and deconvolutional layer dipasangkan dengan parametric rectified linear units (PreLUs).

Dataset SIDD digunakan untuk melatih model yang diusulkan. Pelatihan model menggunakan augmentasi untuk meningkatkan generalisasi pada model sehingga menghasilkan performa yang lebih baik. Pelatihan menggunakan *batch size* = 8 dan *patch size* 256×256 . *Learning rate* yang digunakan pada saat inisialisasi adalah $1e-4$ untuk semua layer, lalu berkurang dengan skala $1/10$ di tiap 10^4 iterasi dengan total 2×10^4 iterasi. Untuk optimisasi, *network* menggunakan Adam dengan momentum = 0.9. Seluruh eksperimen menggunakan PyTorch 1.0 pada NVIDIA TITAN X GPUs, dan Python 3.5.

Model yang digunakan mengkombinasikan *dense connection*, *recurrent network*, dan *residual learning* seperti yang direkomendasikan pada [13]. Model juga menggunakan $n_0 = 256$ dan $n_R = 64$, $t = 7$, dengan iterasi = 3. Pada layer rekonstruksi, model menggunakan layer conv(3,3). Untuk meningkatkan performa model, kami juga mengimplementasikan *pseudo-ensemble*. *Pseudo-ensemble* menggunakan *horizontal flipping*, *vertical flipping*, dan *transpose*. Penggunaan *pseudo-ensemble* terbukti mampu meningkatkan performa model hingga ~ 0.2 dB.


Untuk mengkonfirmasi kemampuan *network* yang dihasilkan, kita bandingkan performa model dengan beberapa paper terkait. Perbandingan menggunakan tujuh model denoising lainnya yaitu: BM3D [3], KSVD-DCT [4], KSVD-G [5], LPG-PCA [6], WNNM [7], EPLL [8], DnCNN [9]. Perbandingan ini juga menggunakan dataset SIDD yang memiliki 2 tipe yaitu sRGB dan Raw.

Tabel 1. Hasil performa model usulan dibandingkan dengan model lainnya pada dataset SIDD. Angka merah menunjukan nilai tertinggi dan angka biru menunjukan nilai kedua tertinggi. Nilai tertinggi pada PSNR dan SSIM menunjukkan performa lebih baik.

	Dataset	Ours	BM3D [3]	KSVD-DCT [4]	KSVD-G [5]	LPG-PCA [6]	WNNM [7]	EPLL [8]	DnCNN [9]
PSNR	Raw	51.68	45.52	42.70	42.50	42.79	44.85	40.73	43.30
	sRGB	39.48	25.65	27.51	27.19	24.49	25.78	27.11	23.66
SSIM	Raw	0.996	0.980	0.970	0.969	0.974	0.975	0.935	0.965
	sRGB	0.971	0.685	0.780	0.771	0.681	0.809	0.870	0.583

Tabel 1 menunjukkan hasil komparasi pada seluruh model *denoising* yang dievaluasi menggunakan SIDD dataset. Pada SIDD dataset, terdapat 2 jenis dataset yaitu sRGB dan Raw. Pada kedua dataset tersebut, model usulan memiliki performa terbaik dibandingkan seluruh model lain. Pada dataset Raw, model usulan lebih tinggi sebanyak ~6 dB, sedangkan untuk metrik SSIM, model usulan lebih tinggi 0.016. Pada dataset sRGB, model usulan lebih tinggi sebanyak ~12 dB, sedangkan untuk metrik SSIM, model usulan lebih tinggi 0.101.

Performa terbaik kedua pada dataset Raw yaitu BM3D [3]. Model BM3D mampu mengalahkan DnCNN [9] yang merupakan model deep learning. Hal ini membuktikan bahwa pelatihan menggunakan data sintesis berpotensi mengurangi performa model jika dievaluasi menggunakan data asli.



Gambar 3. Evaluasi kualitatif pada model usulan. Noise image merupakan input dari model, sedangkan output dari model usulan menghasilkan image yang berhasil dibersihkan dari noise.

Gambar 3 menunjukkan output dari model usulan. Model usulan berhasil menghilangkan noise yang ada pada citra input. Pada citra yang berisi *text*, terlihat bahwa *text* menjadi lebih terbaca dengan penghilangan noise pada gambar. Hal yang sama pada gambar lain, objek yang ada pada gambar semakin jelas dan tajam, sehingga meningkatkan estetika gambar tersebut.

4. KESIMPULAN

Penelitian ini menunjukkan penggunaan deep back-projection untuk denoising. Dengan perubahan yang minimal yaitu merubah urutan dari up- dan down-projection unit, penelitian ini menunjukkan performa yang sangat baik. Down-projection unit digunakan untuk menghilangkan noise pada citra digital pada domain fitur, sedangkan up-projection unit digunakan untuk mengembalikan resolusi fitur pada resolusi semula. Model usulan mampu memiliki nilai PSNR dan SSIM paling tinggi dibandingkan model lainnya, dengan selisih dibandingkan model terbaik kedua mencapai 6 dB pada dataset Raw dan 11 dB pada dataset sRGB. Hal ini membuktikan bahwa model usulan berhasil mengatasi permasalahan denoising pada dataset SIDD.

DAFTAR PUSTAKA

- [1] Haris, M., Shakhnarovich, G., & Ukita, N. (2021, December). Task-driven super resolution: Object detection in low-resolution images. In *International Conference on Neural Information Processing* (pp. 387-395). Springer, Cham.
- [2] Abdelhamed, A., Lin, S., & Brown, M. S. (2018). A high-quality denoising dataset for smartphone cameras. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1692-1700).
- [3] K. Dabov, A. Foi, V. Katkovnik, and K. Egiazarian. Image denoising by sparse 3D transform-domain collaborative filtering. *IEEE TIP*, 16(8):2080–2095, 2007.
- [4] M. Elad and M. Aharon. Image denoising via sparse and redundant representations over learned dictionaries. *IEEE TIP*, 15(12):3736–3745, 2006.
- [5] L. Zhang, W. Dong, D. Zhang, and G. Shi. Two-stage image denoising by principal component analysis with local pixel grouping. *Pattern Recognition*, 43(4):1531–1549, 2010.
- [6] S. Gu, L. Zhang, W. Zuo, and X. Feng. Weighted nuclear norm minimization with application to image denoising. In *CVPR*, 2014.
- [7] D. Zoran and Y. Weiss. From learning models of natural image patches to whole image denoising. In *ICCV*, 2011.
- [8] K. Zhang et al. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising. *IEEE TIP*, 2017.
- [9] A. Buades, B. Coll, and J. Morel. A non-local algorithm for image denoising. In *CVPR*, 2005.
- [10] T. Plotz and S. Roth. Benchmarking denoising algorithms with real photographs. In *CVPR*, 2017.
- [11] Setiowati, S., Sitompul, MEH. 2020. Denoising of Electrocardiogram (ECG) Signal Using Fast Fourier Transform Method in Drowsiness Detection System. *JETT*. Vol. 7 No. 1. 789-796.
- [12] Haris, M., Shakhnarovich, G., & Ukita, N. (2018). Deep back-projection networks for super-resolution. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1664-1673).
- [13] Haris, M., Shakhnarovich, G., & Ukita, N. (2020). Deep back-projection networks for single image super-resolution. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(12), 4323-4337.

- [14] R. Timofte, S. Gu, J. Wu, L. Van Gool, L. Zhang, M.-H. Yang, M. Haris, G. Shakhnarovich, N. Ukita et al., "Ntire 2018 challenge on single image super-resolution: Methods and results," in Computer Vision and Pattern Recognition Workshops (CVPRW), 2018 IEEE Conference on, 2018.
- [15] M. Irani and S. Peleg, "Improving resolution by image registration," CVGIP: Graphical Models and image processing, vol. 53, no. 3, pp. 231–239, 1991.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," arXiv preprint arXiv:1512.03385, 2015.

19%

SIMILARITY INDEX

PRIMARY SOURCES

- 1 openaccess.thecvf.com 88 words — 4%
Internet
- 2 Muhammad Haris, Gregory Shakhnarovich, Norimichi Ukita. "Deep Back-Projection Networks for Single Image Super-resolution", IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020 46 words — 2%
Crossref
- 3 "Computer Vision – ECCV 2020 Workshops", Springer Science and Business Media LLC, 2020 37 words — 2%
Crossref
- 4 Submitted to Telkom University 36 words — 2%
Your Indexed Documents
- 5 content.sciendo.com 31 words — 1%
Internet
- 6 ebin.pub 31 words — 1%
Internet
- 7 Junhan Zhao, Zhijie Zhou, Yu Liu. "Improving GAN for Image Super-Resolution by Using Attention Mechanism and Dense Module", 2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP), 2022 30 words — 1%
Crossref

8	arxiv.org Internet	26 words — 1%
9	mafiadoc.com Internet	20 words — 1%
10	codingnote.cc Internet	19 words — 1%
11	Deqing Sun. "Secrets of optical flow estimation and their principles", 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 06/2010 Crossref	18 words — 1%
12	journals.telkomuniversity.ac.id Internet	14 words — 1%
13	link.springer.com Internet	11 words — 1%
14	"Neural Information Processing", Springer Science and Business Media LLC, 2019 Crossref	8 words — < 1%

EXCLUDE QUOTES OFF
EXCLUDE BIBLIOGRAPHY OFF

EXCLUDE SOURCES OFF
EXCLUDE MATCHES OFF