

ORIGINAL ARTICLE

Simulation of Poisson–Gaussian Denoising Using a Deep Convolutional Network Based on Residual Learning

Ali Raheli*

Assistant Professor, Department of
Physics, Bonab Center, Islamic
Azad University, Bonab, Iran.

Correspondence

Ali Raheli

Email: ali821129@iau.ac.ir

EXTENDED ABSTRACT

Introduction: Optical image sensors are affected by signal-dependent photon counting noise and electronic readout noise. A Poisson–Gaussian model provides a practical representation of these contributions in raw imaging data (Foi et al., 2008). Their combined presence complicates denoising because noise variance varies with signal intensity. Established approaches include block-matching and three-dimensional collaborative filtering, or BM3D (Dabov et al., 2007), and variance-stabilizing transformations adapted to Poisson–Gaussian observations (Mäkitalo and Foi, 2013). Residual-learning convolutional networks offer a data-driven alternative by estimating the difference between noisy and reference images. DnCNN demonstrated this strategy for Gaussian denoising and other restoration tasks (Zhang et al., 2017). Building on this established approach, the present study evaluates an eleven-layer network under controlled Poisson–Gaussian conditions. Its contribution is a reproducible simulation-based comparison across noise compositions, rather than a new network architecture. The research question is whether residual learning consistently improves reconstruction relative to Gaussian and median filtering.

Methodology: The experiment was implemented in Python using NumPy and SciPy. Training, validation, and test datasets contained 128, 16, and 24 synthetic grayscale images, respectively. Each image comprised 64×64 pixels and included smooth backgrounds and spatial structures with different intensities. Images were generated independently across subsets, although all subsets shared the same generation procedure. Synthetic references enabled direct assessment of reconstruction errors under controlled noise conditions. The network contained eleven 3×3 convolutional layers. The first layer produced 32 feature channels followed by rectified linear activation. Nine intermediate layers combined convolution, batch normalization, and rectified linear activation. The final layer produced a single-channel residual estimate without normalization or activation. The restored image was obtained by subtracting this estimate from the observation. Training used random 24×24 patches, rotations, flips, and newly generated noise. Adam optimization (Kingma and Ba, 2015) was applied for 20 epochs with an initial learning rate of 0.001, halved every seven epochs. The objective was mean squared residual prediction error over all pixels. Gaussian and median filter settings were selected using validation performance. Each test image was evaluated with three noise realizations per condition. Primary metrics were calculated after clipping outputs to [0,1]. PSNR and SSIM (Wang et al., 2004) were averaged over realizations within each image before calculating between-image means and standard deviations.

Result: Training MSE decreased from approximately 0.0063 to 0.0018,

How to cite

Raheli, A. (2026). Simulation of Poisson–Gaussian Denoising Using a Deep Convolutional Network Based on Residual Learning, Optoelectronic, 8(4), 19-24.

while validation MSE decreased from approximately 0.0046 to 0.0011 over 20 epochs. Validation loss temporarily increased during epochs five and six, then decreased again. Later epochs exhibited smaller fluctuations without a sustained increase in validation loss. Table 1 summarizes performance at ($p=100$) and ($\sigma=0.03$). The network increased mean PSNR by 5.93 dB relative to the noisy input and by 0.72 dB relative to median filtering. Its mean PSNR exceeded Gaussian filtering by approximately 0.04 dB. Gaussian filtering achieved the highest mean SSIM. Across the nine conditions, the network achieved higher mean PSNR than median filtering in every case and higher mean PSNR than Gaussian filtering in five cases. Gaussian filtering achieved the highest mean PSNR at ($p=20$), whereas the network achieved the highest values at ($p=500$), for all three Gaussian noise levels. The network reached approximately 35.89 dB at ($p=500$) and ($\sigma=0.01$). Increasing (σ) reduced mean PSNR for every method. Visual comparisons showed reduced granular fluctuations after network reconstruction, with residual intensity differences and localized smoothing. The selected horizontal profile retained the principal rising and falling transitions but exhibited local underestimation and overshoot. The absolute-error map showed spatial variation in reconstruction error.

Discussion: The results demonstrate condition-dependent performance rather than uniform superiority of residual learning. At the intermediate noise condition, the network and Gaussian filter produced nearly equal mean PSNR, while Gaussian filtering achieved higher SSIM. This difference highlights the importance of evaluating intensity error and structural similarity together. The findings are consistent with residual learning as a useful restoration strategy (Zhang et al., 2017), but they do not constitute a direct comparison with the original DnCNN implementation. Likewise, no superiority over BM3D or variance-stabilization methods can be inferred because these methods were not experimentally evaluated. The stronger performance decline with increasing Gaussian noise at larger $\backslash(p\backslash)$ is consistent with the reduced contribution of normalized Poisson noise. However, all tested noise combinations occurred during training. The experiment therefore evaluates held-out images within the represented noise domain, rather than generalization to unseen noise conditions. Additional limitations include the shared synthetic-image generator and a single training run. Between-image standard deviations describe variation across test images, not training reproducibility. Neither overlapping error bars nor small mean differences independently establish statistical significance. Visual assessment of one image and one profile also cannot establish image-wide preservation of fine details.

Conclusions: The residual-learning network reduced Poisson–Gaussian noise and improved mean PSNR over median filtering across all investigated conditions. Its comparison with Gaussian filtering depended on noise composition and evaluation metric. These findings support controlled computational evaluation of residual learning while identifying limits to claims of general superiority. Practical application requires further validation using real sensor measurements and independently sourced images. Future work should include unseen noise conditions, repeated training, paired statistical comparisons, and advanced denoising baselines. The present results establish performance within a synthetic simulation framework, without demonstrating clinical effectiveness or general applicability to optical sensing systems.

References

Dabov, K., Foi, A., Katkovnik, V., & Egiazarian, K. (2007). Image denoising by

- sparse 3-D transform-domain collaborative filtering. *IEEE Transactions on Image Processing*, 16(8), 2080–2095. <https://doi.org/10.1109/TIP.2007.901238>
- Foi, A., Trimeche, M., Katkovnik, V., & Egiazarian, K. (2008). Practical Poissonian-Gaussian noise modeling and fitting for single-image raw-data. *IEEE Transactions on Image Processing*, 17(10), 1737–1754. <https://doi.org/10.1109/TIP.2008.2001399>
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *International Conference on Learning Representations*. <https://arxiv.org/abs/1412.6980>
- Mäkitalo, M., & Foi, A. (2013). Optimal inversion of the generalized Anscombe transformation for Poisson-Gaussian noise. *IEEE Transactions on Image Processing*, 22(1), 91–103. <https://doi.org/10.1109/TIP.2012.2202675>
- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612. <https://doi.org/10.1109/TIP.2003.819861>
- Zhang, K., Zuo, W., Chen, Y., Meng, D., & Zhang, L. (2017). Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising. *IEEE Transactions on Image Processing*, 26(7), 3142–3155. <https://doi.org/10.1109/TIP.2017.2662206>

ABSTRACT

Removing mixed Poisson–Gaussian noise is a challenging task in optical sensor image processing because the variance of its signal-dependent component varies with image intensity. In this study, a residual-learning convolutional neural network comprising 11 convolutional layers and batch normalization developed to estimate noise and reconstruct images, and trained using the Adam optimizer. Evaluation performed on 24 synthetic images held out from training unit under under 9 noise intensity combinations, with three noise realizations per image, and and the network's performance compared with Gaussian and median filtering. Both training and validation loss decreased over 20 epochs. Under the condition ($p=100$) and ($\sigma=0.03$), the mean peak signal-to-noise ratio (PSNR) and structural similarity index (SSIM) of the network achieved 31.12 dB and 0.875, respectively. The PSNR improvements over the noisy input and median filtering was 5.93 and 0.72 dB, respectively; however, however, the Gaussian filter, with a PSNR equal to 31.08 dB and an SSIM equal to 0.887, had comparable performance and was better in terms of structural similarity. Across all investigated combinations, the network achieved a higher mean PSNR than the median filter and outperformed Gaussian filtering in five combinations. Visual assessment also indicated noise reduction and partial preservation of the main image structures, although localized reconstruction errors remained.

KEYWORDS

Optical Sensors, Poisson-Gaussian Mixed Noise, Deep Learning, Residual Learning, Image Processing.

فصلنامه علمی

اپتوالکترونیک

«مقاله پژوهشی»

شبیه‌سازی حذف نویز پواسون-گاوسی با استفاده از شبکه کانولوشنی عمیق مبتنی بر یادگیری باقی‌مانده

علی راحلی *

۱ استادیار، گروه فیزیک، واحد بناب، دانشگاه آزاد اسلامی، بناب، ایران.

نویسنده مسئول:

علی راحلی

رایانامه: ali821129@iau.ac.ir

چکیده

حذف نویز ترکیبی پواسون-گاوسی، به دلیل وابستگی واریانس بخشی از نویز به شدت سیگنال، از چالش‌های پردازش تصاویر حسگرهای نوری است. در این پژوهش، یک شبکه کانولوشنی شامل ۱۱ لایه کانولوشن، مبتنی بر یادگیری باقی‌مانده و مجهز به نرمال‌سازی دسته‌ای، برای تخمین نویز و بازسازی تصویر توسعه یافت و با بهینه‌ساز آدام آموزش داده شد. ارزیابی روی ۲۴ تصویر مصنوعی مستقل از مجموعه آموزش، در ۹ ترکیب شدت نویز و با سه تحقق نویز برای هر تصویر انجام شد و عملکرد شبکه با فیلترهای گاوسی و میانه مقایسه گردید. خطای آموزش و اعتبارسنجی طی ۲۰ دوره کاهش یافت. در شرایط (p=100) و $\sigma=0.03$ ، میانگین نسبت بیشینه سیگنال به نویز (PSNR) و شاخص شباهت ساختاری (SSIM) شبکه به ترتیب به ۳۱/۱۲ دسی‌بل و ۰/۸۷۵ رسید. افزایش PSNR نسبت به ورودی نویزی و فیلتر میانه به ترتیب ۵/۹۳ و ۰/۷۲ دسی‌بل بود؛ باین‌حال، فیلتر گاوسی با PSNR برابر با ۳۱/۰۸ دسی‌بل و SSIM برابر با ۰/۸۸۷، عملکردی نزدیک و از نظر شباهت ساختاری بهتر داشت. شبکه در تمام ترکیب‌های بررسی‌شده، میانگین PSNR بالاتری نسبت به فیلتر میانه و در پنج ترکیب، مقداری بالاتر از فیلتر گاوسی به دست آورد. بررسی بصری نیز کاهش نویز و حفظ نسبی ساختارهای اصلی را همراه با خطاهای موضعی بازسازی نشان داد.

واژه‌های کلیدی

حسگرهای نوری، نویز ترکیبی پواسون-گاوسی، یادگیری عمیق، یادگیری باقی‌مانده، پردازش تصویر.

استناد به این مقاله:

علی راحلی (۱۴۰۵). شبیه‌سازی حذف نویز پواسون-گاوسی با استفاده از شبکه کانولوشنی عمیق مبتنی بر یادگیری باقی‌مانده. فصلنامه علمی اپتوالکترونیک، ۸(۴)، ۱۹-۲۴.

مقدمه

حسگرهای نوری مدرن، از جمله دستگاه‌های جفت‌کننده بار^۱ و حسگرهای پیکسل فعال مبتنی بر فناوری نیمه‌هادی اکسید فلزی مکمل^۲، به‌عنوان هسته اصلی فناوری‌های تصویربرداری نوین شناخته می‌شوند [۱]. این حسگرها بر پایه اثر فوتوالکتریک داخلی در نیمه‌هادی‌ها عمل می‌کنند. در این فرایند، فوتون‌های فرودی با انرژی بیشتر از نوار ممنوعه انرژی ماده نیمه‌هادی مانند سیلیکون، در ناحیه فعال حسگر جذب شده و منجر به تولید زوج‌های الکترون-حفره می‌شوند. تعداد حامل‌های تولیدشده به ضریب جذب اپتیکی، طول موج تابش، ضخامت لایه حساس و بازده کوانتومی آشکارساز وابسته است. از این‌رو، پاسخ نهایی حسگر نه تنها تابع شدت تابش، بلکه به ویژگی‌های اپتیکی و الکترونیکی ساختار نیمه‌هادی نیز وابسته است. بنابراین این حسگرها نقشی حیاتی در طیف گسترده‌ای از کاربردهای راهبردی، از جمله تصویربرداری تشخیصی پزشکی (نظیر توموگرافی انسجام نوری و تصویربرداری دیجیتال پرتو ایکس)، سامانه‌های بینایی ماشین در صنایع خودروسازی و ابزارهای سنجش از دور ایفا می‌کنند [۳-۴].

با وجود پیشرفت‌های چشمگیر در طراحی و ساخت تراشه‌های نوری، تخریب سیگنال ناشی از نویزهای فیزیکی همچنان یکی از چالش‌های اساسی در دستیابی به کیفیت تصویربرداری مطلوب محسوب می‌شود؛ به‌ویژه در شرایط نور کم یا هنگام استفاده از زمان‌های اکسپوزر کوتاه [۵]. زمان اکسپوزر به مدت زمانی گفته می‌شود که طی آن حسگر تصویر در معرض نور قرار می‌گیرد و در نتیجه، میزان کل نور دریافت‌شده توسط حسگر تعیین می‌شود. این پارامتر یکی از عوامل اصلی در تعیین روشنایی، کنتراست و کیفیت نهایی تصویر بوده و تنظیم مناسب آن برای جلوگیری از اشباع نوری یا تاریکی بیش‌ازحد تصویر از اهمیت ویژه‌ای برخوردار است. از منظر فیزیک الکترونیک، سیگنال ثبت‌شده توسط حسگرهای نوری همواره تحت تأثیر یک مدل نویزی ترکیبی و پیچیده قرار دارد. این مدل عمدتاً از دو مؤلفه اصلی تشکیل شده است: نویز شات نوری^۳ و نویز بازخوانی^۴ یا حرارتی [۶]. نویز شات از ماهیت کوانتومی و گسسته فوتون‌های فرودی ناشی می‌شود و فرآیند ورود فوتون‌ها به چاه پتانسیل پیکسل از توزیع آماری پواسون تبعیت می‌کند؛ از این‌رو، شدت این نویز به‌طور مستقیم به سطح سیگنال اصلی وابسته است [۷].

در مقابل، نویز بازخوانی ناشی از نوسانات حرارتی حامل‌های بار در ساختار سیلیکونی، نویز فلیکر^۵ و پدیده‌های مرتبط با مدارهای تقویت‌کننده و خوانش روی تراشه است. این نوع نویز مستقل از شدت نور بوده و معمولاً با یک توزیع آماری گاوسی مدل‌سازی می‌شود [۸]. از دیدگاه فیزیک آماری، آشکارسازی نور یک فرآیند ذاتاً تصادفی است و ورود فوتون‌ها به سطح آشکارساز از آمار کوانتومی تبعیت می‌کند. این ماهیت گسسته و تصادفی سبب ایجاد حد بنیادی نویز موسوم به حد شات می‌شود که حتی در آشکارسازهای ایده‌آل و فاقد نقص نیز قابل حذف کامل نیست. در شرایط شار نوری پایین، تعداد فوتون‌های دریافتی کاهش یافته و نسبت سیگنال به نویز به‌طور محسوسی افت می‌کند؛ بنابراین، عملکرد سامانه تصویربرداری به محدودیت‌های بنیادی فیزیک آشکارسازی فوتون نزدیک می‌شود.

هم‌زمانی حضور نویز شات و نویز بازخوانی با توزیع‌های آماری ناهمگن، یعنی توزیع پواسون وابسته به سیگنال و توزیع گاوسی مستقل از سیگنال، موجب می‌شود که مدل‌سازی آماری و حذف نویز از تصاویر به یک مسئله معکوس پیچیده تبدیل شود. این پیچیدگی به‌ویژه در تصاویر کم‌نور که تعداد فوتون‌های آشکارشده اندک است، بیشتر نمایان می‌شود و بازیابی دقیق اطلاعات اپتیکی را با چالش جدی مواجه می‌سازد. از منظر فیزیک تصویربرداری، حد نهایی آشکارسازی و تفکیک‌پذیری اطلاعات نوری توسط نسبت سیگنال به نویز و محدودیت‌های بنیادی آشکارسازی فوتون تعیین می‌شود. در کاربردهایی نظیر تصویربرداری زیست‌پزشکی، نجوم، سنجش از دور و تصویربرداری در شرایط نور بسیار ضعیف، کاهش تعداد فوتون‌های دریافتی موجب غالب شدن نویز شات و افت معنادار کیفیت اطلاعات فوتومتریکی می‌شود. در چنین شرایطی، توسعه روش‌های پیشرفته حذف نویز نه تنها به بهبود ظاهر بصری تصویر، بلکه به بازیابی دقیق‌تر اطلاعات فیزیکی، افزایش حساسیت آشکارسازی و ارتقای قابلیت استخراج پارامترهای کمی از تصاویر منجر می‌شود. در دهه‌های گذشته پژوهشگران پردازش سیگنال تلاش‌های گسترده‌ای را برای توسعه فیلترها و الگوریتم‌های کلاسیک حذف نویز انجام دادند [۹-۱۲]. روش‌های مکانی اولیه، نظیر فیلتر میانه^۶ و فیلتر وینر^۷، اگرچه از پیچیدگی محاسباتی نسبتاً پایینی برخوردارند؛ اما به دلیل فرض‌های ساده‌ساز، از جمله خطی بودن سیستم یا اعمال

5 Flicker Noise
6 Median Filter
7 Wiener Filter

1 Charge Coupled Device (CCD)
2 Complimentary Metal Oxide Semiconductor (CMOS)
3 Photon Shot Noise
4 Readout Noise

یکنواخت عملیات بر کل تصویر، معمولاً موجب محوشدگی لبه‌ها و از بین رفتن جزئیات فرکانس بالا می‌شوند [۱۳].

روش‌های پیشرفته‌تر مبتنی بر تبدیل‌های ریاضی، از جمله تبدیل موجک^۱ و فیلترینگ مشارکتی سه‌بعدی^۲ با انتقال سیگنال به حوزه‌های فرکانسی یا نمایش‌های تنک، عملکرد بهتری در حذف نویز ارائه کرده‌اند. با این حال، این روش‌ها به‌شدت به تنظیم دقیق فرامقادیر^۳ وابسته هستند و در مواجهه با نویزهای ترکیبی شدید، از انعطاف‌پذیری و پایداری عملکردی کافی برخوردار نیستند [۱۴].

با ظهور یادگیری عمیق^۴ و گسترش کاربرد آن در حوزه بینایی ماشین، شبکه‌های عصبی کانولوشنی افق جدیدی را در حل مسائل معکوس پردازش تصویر گشوده‌اند [۱۵]. معماری‌های عمیق به دلیل توانایی استخراج ویژگی‌های غیرخطی در مقیاس‌های مختلف و بهره‌گیری از فرایند آموزش داده‌محور^۵ قادرند بدون اتکا به فرضیات ساده‌ساز روش‌های سنتی، نداشت‌های پیچیده میان تصاویر نویزی و تصاویر مرجع را فراگیرند [۱۶].

یکی از موفق‌ترین معماری‌های ارائه‌شده در این حوزه، شبکه عصبی حذف نویز کانولوشنی^۶ است. این معماری با تلفیق راهبرد یادگیری باقی‌مانده^۷ و نرمال‌سازی دسته‌ای^۸ ضمن تسریع فرایند آموزش و بهبود همگرایی شبکه، کارایی بالایی در حذف نویزهای افزایشی و ترکیبی در تصاویر ثبت‌شده توسط حسگرهای نوری از خود نشان داده است [۱۷]. هدف این مطالعه، بررسی رابطه میان ترکیب نویز، کیفیت بازسازی و عملکرد نسبی شبکه در مقایسه با فیلترهای گاوسی و میانه است. برای این منظور، مجموعه‌های آموزش، اعتبارسنجی و آزمون در سطح تصویر از یکدیگر جدا شده‌اند و ارزیابی روی ۲۴ تصویر مصنوعی آزمون، در ۹ ترکیب نویز و با سه تحقق نویز برای هر تصویر انجام می‌شود. تحلیل عملکرد شامل بررسی منحنی‌های آموزش و اعتبارسنجی، مقایسه بصری تصاویر، پروفایل شدت روشنایی و شاخص‌های PSNR و SSIM است.

روش‌شناسی

رویکرد پیشنهادی این پژوهش برای بهبود کیفیت داده‌های

حاصل از حسگرهای نوری بر دو رکن اساسی استوار است: نخست، مدل‌سازی دقیق ریاضی مکانیزم‌های فیزیکی تخریب سیگنال در نیم‌هادی‌ها و دوم، طراحی یک معماری عمیق کانولوشنی پیشرفته که قادر باشد نویز را به‌صورت غیرخطی از سیگنال اصلی تفکیک کرده و در عین حال، مرزها، لبه‌ها و مؤلفه‌های فرکانس بالای تصویر را حفظ کند.

الف) مدل نویز ترکیبی حسگر^۹

داده خروجی حسگر نوری، نظیر حسگرهای CCD و CMOS، به‌طور هم‌زمان تحت تأثیر ماهیت کوانتومی نور و نوسانات حرارتی مدارهای الکترونیکی قرار دارد. برهم‌کنش این دو پدیده به‌طور متعارف با مدل نویز ترکیبی پواسون-گاوسی توصیف می‌شود [۱۶]. در این مدل، اگر $X(i,j)$ بیانگر تعداد واقعی فوتون‌های فرودی یا شدت سیگنال تمیز در موقعیت فضایی (i,j) باشد، آنگاه سیگنال ثبت‌شده توسط حسگر، یعنی $Y(i,j)$ را می‌توان به‌صورت زیر مدل‌سازی کرد [۲۰-۱۸].

$$Y(i,j) = Z(i,j) + V(i,j) \quad (۱)$$

که در آن، $Z(i,j)$ مؤلفه وابسته به سیگنال (نویز شات) است که از توزیع پواسون تبعیت می‌کند:

$$Z(i,j) \sim \text{Poisson}(\alpha X(i,j)) \quad (۲)$$

در این معادله، α ضریب تبدیل یا بهره الکترونیکی حسگر است که تعداد فوتون‌های فرودی را به تعداد الکترون‌های ذخیره‌شده در چاه پتانسیل پیکسل مرتبط می‌سازد. از آنجا که برای یک متغیر تصادفی پواسونی، میانگین و واریانس با یکدیگر برابر هستند، خواهیم داشت:

$$\mathbb{E}[Z(i,j)] = \alpha X(i,j), \quad (۳)$$

$$\text{Var}[Z(i,j)] = \alpha X(i,j) \quad (۴)$$

از سوی دیگر، $V(i,j)$ نشان‌دهنده نویز بازخوانی و حرارتی مستقل از سیگنال است که به‌صورت یک متغیر تصادفی گاوسی سفید با میانگین صفر و انحراف معیار σ_v مدل‌سازی می‌شود:

$$V(i,j) \sim \mathcal{N}(0, \sigma_v^2) \quad (۵)$$

بنابراین میانگین و واریانس نویز گاوسی به‌ترتیب برابر است

با:

$$\mathbb{E}[V(i,j)] = 0, \text{Var}[V(i,j)] = \sigma_v^2 \quad (۶)$$

1 Wavelet Transform

2 BM3D

3 Hyperparameters

4 Deep Learning

5 Data-Driven

6 Denoising Convolutional Neural Network (DnCNN)

7 Residual Learning

8 Batch Normalization

9 Mixed Noise Modeling

ساختار پیچیده تصویر تمیز، تنها بر یادگیری مؤلفه نویز متمرکز شود؛ در نتیجه مشکل محو شدن جزئیات ساختاری و تضعیف اطلاعات فرکانس بالا در لایه‌های عمیق به‌طور قابل توجهی کاهش می‌یابد.

معماری طراحی شده در محیط پایتون شامل ۱۱ لایه با پیکربندی زیر است:

(۱) لایه اول

این لایه شامل اعمال یک لایه کانولوشنی به همراه تابع فعال‌ساز یکسوساز خطی روی ورودی است. با در نظر گرفتن ابعاد وصله‌های آموزشی 24×24 (استخراج شده از تصاویر مصنوعی 64×64)، خروجی این لایه پس از اعمال تابع فعال‌ساز خطی^۳ به‌صورت زیر بیان می‌شود:

$$F_1(Y) = \max(0, W_1 * Y + b_1) \quad (12)$$

که در آن W_1 و b_1 به‌ترتیب ماتریس وزن و بردار بایاس لایه اول و * نشان‌دهنده عمل کانولوشن است.

(۲) لایه‌های میانی

این بخش از ۹ بلوک متوالی تشکیل شده است که هر بلوک شامل یک لایه کانولوشن، یک لایه نرمال‌سازی دسته‌ای^۴ و یک تابع فعال‌ساز ReLU است. عملیات نرمال‌سازی دسته‌ای برای هر کانال به‌صورت زیر تعریف می‌شود:

$$\text{BN}(x) = \gamma \left(\frac{x - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \right) + \beta \quad (13)$$

که در آن μ_B و σ_B^2 به‌ترتیب میانگین و واریانس مینی‌بچ، γ و β پارامترهای قابل آموزش و ϵ یک مقدار کوچک برای جلوگیری از تقسیم بر صفر است.

خروجی هر بلوک میانی را می‌توان به‌صورت زیر نوشت:

$$F_l = \max(0, \text{BN}(W_l * F_{l-1} + b_l)); \quad (14)$$

$l = 2, \dots, 10$

(۳) لایه خروجی

لایه انتهایی شامل یک لایه کانولوشنی منفرد است که فاقد لایه‌های BN و ReLU بوده و وظیفه بازسازی نگاشت دوبعدی نویز را بر عهده دارد. خروجی این لایه برابر است با:

$$R(Y; \Theta) = W_{11} * F_{10} + b_{11} \quad (15)$$

با فرض استقلال آماری بین نویز شات و نویز بازخوانی، میانگین سیگنال مشاهده شده برابر است با:

$$\mathbb{E}[Y(i, j)] = \alpha X(i, j) \quad (7)$$

و واریانس کل سیگنال تخریب شده در هر پیکسل به‌صورت زیر به دست می‌آید:

$$\text{Var}[Y(i, j)] = \text{Var}[Z(i, j)] + \text{Var}[V(i, j)] \quad (8)$$

در نتیجه:

$$\text{Var}[Y(i, j)] = \alpha X(i, j) + \sigma_v^2 \quad (9)$$

رابطه (۹) نشان می‌دهد که واریانس نویز در حسگرهای نوری مقدار ثابتی نیست؛ بلکه به‌طور خطی به شدت سیگنال اصلی وابسته است. به عبارت دیگر، پیکسل‌های روشن‌تر دارای واریانس نویز بیشتری نسبت به پیکسل‌های تاریک‌تر هستند. این رفتار ناهمسان^۱ یکی از مهم‌ترین چالش‌های فیلترهای کلاسیک در حذف نویز محسوب می‌شود؛ زیرا اکثر این روش‌ها بر فرض ثابت بودن واریانس نویز در کل تصویر بنا شده‌اند و در مواجهه با نویزهای پواسون-گاوسی عملکرد مطلوبی از خود نشان نمی‌دهند.

(ب) شبکه یادگیری باقی‌مانده عمیق^۲

برای معکوس‌سازی فرآیند تخریب سیگنال ناشی از نویز پواسون-گاوسی، در این پژوهش از شبکه عصبی کانولوشنی حذف نویز مبتنی بر یادگیری باقی‌مانده استفاده شده است. برخلاف شبکه‌های متداول که مستقیماً در پی بازسازی تصویر تمیز X هستند، در این رویکرد شبکه تنها مؤلفه نویز موجود در تصویر را تخمین می‌زند. به عبارت دیگر، هدف شبکه یادگیری نگاشت زیر است:

$$(Y; \Theta) \approx Y - X \quad (10)$$

که در آن $R(Y; \Theta)$ خروجی شبکه با پارامترهای قابل آموزش Θ است و تخمینی از نگاشت نویز موجود در تصویر ورودی Y را ارائه می‌دهد. پس از تخمین نویز، تصویر بازسازی شده به‌صورت زیر به دست می‌آید:

$$\hat{X} = Y - R(Y; \Theta) \quad (11)$$

این راهبرد سبب می‌شود شبکه به‌جای یادگیری مستقیم

3 ReLU
4 Batch Normalization

1 Heteroscedastic
2 Residual Learning-Based Deep Convolutional Neural Network (DnCNN)

تابع هزینه و استراتژی بهینه‌سازی

برای آموزش پارامترهای شبکه Θ ، از تابع هزینه میانگین مربعات خطا^۱ بین نویز واقعی و نویز تخمین‌زده‌شده توسط شبکه استفاده می‌شود. مؤلفه نویز ساختاری ساده‌تر دارد؛ لذا ظرفیت شبکه صرف استخراج نویز شده و جزئیات فرکانس بالای تصویر (لبه‌ها و بافت‌ها) محو نمی‌شوند. فرمول هدف (تابع هزینه) شبکه به صورت زیر است:

$$\mathcal{L}(\Theta) = \frac{1}{2NHW} \sum_{k=1}^N \|R(Y_k; \Theta) - (Y_k - X_k)\|_F^2 \quad (۱۶)$$

که در آن:

- N : تعداد نمونه‌های موجود در مینی‌بچ؛
- Y_k : تصویر نویزی حاصل از حسگر؛
- X_k : تصویر تمیز مرجع؛
- H و W : به ترتیب ارتفاع و عرض هر نمونه
- $\|\cdot\|_F$: نرم فروبنیوس ماتریس خطا.

هدف فرایند آموزش، یافتن مجموعه پارامترهای بهینه شبکه است:

$$\Theta^* = \arg \min_{\Theta} \mathcal{L}(\Theta) \quad (۱۷)$$

بهینه‌سازی تابع هزینه با استفاده از الگوریتم گردانت کاهشی تصادفی مبتنی بر گشتاور تطبیقی آدام با پارامترهای پیش‌فرض تنظیم گشتاور:

$$\eta = 10^{-3} \quad (۱۸)$$

انجام می‌شود. این الگوریتم به دلیل توانایی در تنظیم تطبیقی نرخ یادگیری و پایداری بالا در مسائل معکوس پردازش تصویر، عملکرد مناسبی در آموزش شبکه‌های حذف نویز عمیق از خود نشان داده است.


نتایج و بحث

شکل ۱ روند تغییرات تابع هزینه شبکه کانولوشنی مبتنی بر یادگیری باقی‌مانده را طی ۲۰ دوره آموزش نشان می‌دهد. این تابع، میانگین مربعات اختلاف میان مؤلفه نویز واقعی، یعنی تفاضل تصویر نویزی و تصویر مرجع و نویز تخمین‌زده‌شده توسط شبکه را اندازه‌گیری می‌کند. خطای آموزش از حدود ۰/۰۰۶۳ در دوره نخست به ۰/۰۰۱۸ در دوره پایانی کاهش یافته است که بیانگر کاهش تقریبی ۷۱ درصدی است. هم‌زمان، خطای اعتبارسنجی نیز از حدود ۰/۰۰۴۶ به ۰/۰۰۱۱

رسیده است. این روند نشان می‌دهد که به‌روزرسانی پارامترهای شبکه با استفاده از الگوریتم آدام، به بهبود برآورد نویز ترکیبی پواسون-گاوسی در داده‌های بررسی‌شده منجر شده است.


کاهش خطا در دوره‌های ابتدایی سریع‌تر است و پس از حدود دوره هشتم، منحنی اعتبارسنجی با نوسانات محدودتری ادامه می‌یابد. افزایش موقت خطای اعتبارسنجی در دوره‌های پنجم و ششم در ادامه آموزش پایدار نمی‌ماند. همچنین، کاهش خطای آموزش با افزایش مستمر خطای اعتبارسنجی همراه نیست؛ بنابراین در این بازه شواهد آشکاری از تشدید بیش‌برازش مشاهده نمی‌شود. با این‌حال، این رفتار به‌تنهایی برای تأیید همگرایی کامل شبکه یا تضمین حفظ لبه‌ها و جزئیات تصویر کافی نیست و باید همراه با ارزیابی‌های کمی و بصری تصاویر بازسازی‌شده تفسیر شود.

کمتر بودن خطای اعتبارسنجی نسبت به آموزش در بیشتر دوره‌ها، با توجه به تفاوت شرایط محاسبه این دو خطا قابل تفسیر است. در اجرای حاضر، آموزش روی وصله‌های تصادفی همراه با افزایش داده و تولید نویز جدید انجام شده است؛ در حالی که تصاویر و نمونه‌های نویزی اعتبارسنجی ثابت بوده‌اند. تفاوت عملکرد نرمال‌سازی دسته‌ای در مراحل آموزش و ارزیابی نیز می‌تواند در فاصله میان دو منحنی نقش داشته باشد. در مجموع، نتایج نشان‌دهنده بهبود یادگیری نگاشت باقی‌مانده در شرایط شبیه‌سازی‌شده است. ارزیابی کیفیت بازسازی و قابلیت تعمیم شبکه نیز باید بر نتایج مجموعه آزمون مستقل و شاخص‌های PSNR و SSIM استوار باشد.



شکل ۱. روند تغییرات میانگین مربعات خطا (MSE) شبکه حذف نویز پواسون-گاوسی طی ۲۰ دوره آموزش. منحنی‌های آبی و نارنجی به ترتیب خطای محاسبه‌شده روی وصله‌های آموزشی و تصاویر اعتبارسنجی را نشان می‌دهند. محور عمودی دارای مقیاس لگاریتمی است.

برای بررسی بصری کیفیت بازسازی، شکل ۲ تصویر مرجع مصنوعی از مجموعه آزمون، تصویر نویزی و خروجی فیلترهای گاوسی، میانه و شبکه کانولوشنی را در شرایط $p=100$ و $\sigma=0.03$ مقایسه می‌کند. تصویر مرجع شامل نواحی بیضوی با



شکل ۲. مقایسه بصری روش‌های حذف نویز برای یک تصویر مصنوعی از مجموعه آزمون در شرایط شرایط $(p=100)$ و $\sigma=0.03$. ردیف بالا، از چپ به راست: تصویر مرجع، تصویر نویزی و خروجی فیلتر گاوسی؛ ردیف پایین، از چپ به راست: خروجی فیلتر میانه، خروجی شبکه کانولوشنی مبتنی بر یادگیری باقی‌مانده و نقشه خطای مطلق شبکه نسبت به تصویر مرجع.

میانگین PSNR تصویر نویزی برابر با ۲۵/۱۹ دسی‌بل است که پس از اعمال فیلترهای گاوسی، میانه و شبکه کانولوشنی، به ترتیب به ۳۱/۰۸، ۳۰/۴۰ و ۳۱/۱۲ دسی‌بل افزایش یافته است. شبکه در مقایسه با ورودی نویزی، بهبودی معادل ۵/۹۳ دسی‌بل و در مقایسه با فیلتر میانه، افزایشی معادل ۰/۷۲ دسی‌بل ایجاد کرده است. با این حال، اختلاف میانگین PSNR شبکه و فیلتر گاوسی تنها حدود ۰/۰۴ دسی‌بل است؛ بنابراین عملکرد این دو روش از نظر این شاخص بسیار نزدیک است.

نتایج SSIM نیز بهبود شباهت ساختاری پس از حذف نویز را نشان می‌دهند. میانگین این شاخص از ۰/۶۱۹ برای تصویر نویزی، به ۰/۸۸۷ برای فیلتر گاوسی، ۰/۸۶۱ برای فیلتر میانه و ۰/۸۷۵ برای شبکه کانولوشنی افزایش یافته است. در نتیجه، شبکه از نظر میانگین SSIM عملکرد بهتری نسبت به فیلتر میانه دارد؛ اما فیلتر گاوسی بالاترین مقدار را در شرایط بررسی شده به دست آورده است. تفاوت رتبه‌بندی روش‌ها در دو شاخص نشان می‌دهد که دستیابی به PSNR بالاتر الزاماً با SSIM بالاتر همراه نیست و ارزیابی کیفیت بازسازی باید هر دو معیار را در نظر بگیرد.


میل‌های خطا پراکندگی عملکرد میان تصاویر آزمون را نشان می‌دهند و نباید به عنوان فاصله اطمینان یا تغییرپذیری ناشی از تکرار آموزش تفسیر شوند. همچنین، هم‌پوشانی آن‌ها به‌تنهایی مبنای تعیین معناداری آماری اختلاف روش‌ها نیست. در مجموع، شبکه کانولوشنی در این مجموعه آزمون نسبت به تصویر نویزی و فیلتر میانه، میانگین بالاتری در هر دو شاخص داشته است؛ با این حال مقایسه با فیلتر گاوسی نشان‌دهنده

شدت‌های متفاوت، یک ساختار روشن کوچک و تغییرات تدریجی شدت در پس‌زمینه است. افزودن نویز ترکیبی پواسون-گاوسی باعث ایجاد تغییرات دانه‌ای شدت روشنایی و کاهش وضوح ساختارها، به‌ویژه نواحی کم‌کنتراست، شده است. فیلتر گاوسی با هموارسازی تغییرات موضعی شدت، بخش قابل مشاهده‌ای از نویز را کاهش داده است؛ با این حال در برخی مرزها و اطراف ساختار روشن کوچک، هموارشدگی نیز مشاهده می‌شود. فیلتر میانه نیز نوسانات نویزی را کاهش داده؛ اما خروجی آن همچنان دارای ناهمواری‌های موضعی و تغییراتی در شکل مرزها است. این تفاوت‌ها نشان می‌دهند که کاهش نویز و حفظ جزئیات مکانی در خروجی روش‌های مختلف به یک میزان تحقق نیافته‌اند.

در خروجی شبکه کانولوشنی، تغییرات دانه‌ای نسبت به تصویر نویزی کاهش یافته و شکل کلی ساختارهای اصلی قابل تشخیص است. با این حال، مقایسه با تصویر مرجع نشان می‌دهد که بازسازی کامل نیست و اختلاف شدت و محوشدگی موضعی در برخی نواحی باقی مانده است. بنابراین این نمونه از توانایی شبکه در کاهش نویز و بازیابی ساختار کلی تصویر حمایت می‌کند؛ اما شواهد کافی برای ادعای حذف کامل نویز، حفظ بی‌نقص لبه‌ها یا برتری قطعی نسبت به فیلتر گاوسی فراهم نمی‌کند.


نقشه خطای مطلق شبکه، توزیع مکانی اختلاف میان تصویر بازسازی شده و تصویر مرجع را نشان می‌دهد. تغییرات رنگ در این نقشه بیانگر یکسان‌نبودن مقدار خطا در نقاط مختلف تصویر است. به دلیل نبود نوار مقیاس رنگ، تفسیر این پنل به توزیع نسبی خطا محدود می‌شود و مقدار عددی آن مستقیماً قابل استخراج نیست. مقایسه نهایی روش‌ها باید بر شاخص‌های PSNR و SSIM در کل مجموعه آزمون استوار باشد؛ زیرا مشاهده یک تصویر، برای نتیجه‌گیری درباره عملکرد کلی یا قابلیت تعمیم شبکه کافی نیست.

شکل ۳ نتایج ارزیابی کمی روش‌های حذف نویز را بر اساس شاخص‌های نسبت بیشینه سیگنال به نویز (PSNR) و شباهت ساختاری (SSIM)، در شرایط نویز ترکیبی پواسون-گاوسی با پارامترهای $(p=100)$ و $(\sigma=0.03)$ ، نشان می‌دهد. مقادیر گزارش شده بیانگر میانگین و انحراف معیار در ۲۴ تصویر مجموعه آزمون هستند؛ به این ترتیب که ابتدا نتایج سه تحقق نویز برای هر تصویر میانگین‌گیری شده و سپس آمار بین تصاویر محاسبه شده است.



شکل ۴. مقایسه شدت روشنایی در امتداد سطر با اندیس ۳۲ از یک تصویر مصنوعی مجموعه آزمون، در شرایط $p=100$ و $\sigma=0.03$. منحنی‌های سیاه، آبی روشن و نارنجی به ترتیب تصویر مرجع، ورودی نویزی و خروجی شبکه کانولوشنی را نشان می‌دهند. محور افقی بیانگر اندیس پیکسل و محور عمودی بیانگر شدت روشنایی نرمال شده است.


شکل ۵ تغییرات میانگین PSNR را برای ورودی نویزی، فیلترهای گوسی و میانه و شبکه کانولوشنی، در سه سطح پارامتر پواسون $p=20$ ، $p=100$ و $p=500$ و سه مقدار انحراف معیار نویز گوسی $\sigma=0.01, 0.03, 0.05$ نشان می‌دهد. نتایج بر اساس ۲۴ تصویر مجموعه آزمون و پس از میانگین‌گیری سه تحقق نویز برای هر تصویر محاسبه شده‌اند. در مدل نرمال شده استفاده شده، واریانس شرطی نویز برابر با $\sigma^2 + X/p$ است؛ بنابراین افزایش p در شدت ثابت تصویر، سهم نویز پواسون را کاهش می‌دهد؛ درحالی‌که افزایش σ موجب افزایش سهم نویز گوسی می‌شود.



شکل ۵. تغییرات میانگین PSNR روش‌های حذف نویز برحسب انحراف معیار مؤلفه گوسی، در سه سطح پارامتر پواسون $p=100$ ، $p=20$ و $p=500$. هر نقطه نشان‌دهنده میانگین نتایج ۲۴ تصویر آزمون، پس از میانگین‌گیری سه تحقق نویز برای هر تصویر است. خطوط صرفاً نقاط ارزیابی شده را به یکدیگر متصل می‌کنند.

مطابق شکل ۵، در شرایط $p=20$ میانگین PSNR تمام روش‌ها پایین‌تر از دو سطح دیگر است. فیلتر گوسی در هر سه مقدار σ ، بالاترین میانگین PSNR را دارد و شبکه کانولوشنی در رتبه بعدی قرار می‌گیرد. تغییرات نسبتاً محدود منحنی‌ها با افزایش σ ، با سهم بیشتر مؤلفه پواسون در واریانس کل نویز سازگار است. با این حال، این حساسیت کمتر به تغییرات نویز گوسی نباید به معنای کیفیت بازسازی بالاتر

PSNR تقریباً برابر و SSIM اندکی پایین‌تر است. بنابراین نتایج این شکل از بهبود کیفیت بازسازی توسط شبکه حمایت می‌کنند.



شکل ۶. مقایسه میانگین شاخص‌های PSNR (چپ) و SSIM (راست) برای ورودی نویزی، فیلتر گوسی، فیلتر میانه و شبکه کانولوشنی در شرایط $p=100$ و $\sigma=0.03$. ارتفاع ستون‌ها میانگین و میله‌های خطا انحراف معیار بین ۲۴ تصویر آزمون را پس از میانگین‌گیری سه تحقق نویز برای هر تصویر نشان می‌دهند.

شکل ۴ پروفایل شدت روشنایی در امتداد سطر با اندیس ۳۲ از یک تصویر مصنوعی مجموعه آزمون را برای تصویر مرجع، ورودی نویزی و خروجی شبکه کانولوشنی مقایسه می‌کند. منحنی تصویر نویزی دارای نوسانات موضعی نسبت به مرجع است؛ درحالی‌که خروجی شبکه در بخش عمده مسیر، تغییرات شدت مرجع را با انحراف کمتری دنبال می‌کند. نواحی با تغییرات تدریجی شدت، به‌ویژه در محدوده تقریبی پیکسل‌های ۲۵ تا ۴۰، شبکه دامنه نوسانات نویزی را کاهش داده و پروفایلی نزدیک‌تر به روند مرجع ایجاد کرده است. با این حال، در برخی نقاط، از جمله حوالی پیکسل‌های ۱۰ تا ۱۲، شدت بازسازی شده کمتر از مقدار مرجع است. این اختلاف نشان می‌دهد که کاهش نویز با بازیابی کاملاً دقیق شدت روشنایی در تمام نقاط همراه نبوده است.

بخش برجسته پروفایل در محدوده تقریبی پیکسل‌های ۴۲ تا ۵۰، امکان بررسی بازسازی تغییرات تند شدت را فراهم می‌کند. شبکه موقعیت کلی افزایش و کاهش شدت در دو سوی این ناحیه را حفظ کرده و نوسانات شدید ورودی نویزی را کاهش داده است. با این حال، در حوالی پیکسل ۴۷، مقدار بازسازی شده از مرجع بیشتر است و شکل بخش بالایی پروفایل نیز کاملاً بر منحنی مرجع منطبق نیست. بنابراین نمودار از حفظ نسبی موقعیت و دامنه ساختار اصلی حمایت می‌کند؛ اما بیانگر بازسازی بی‌نقص لبه‌ها یا حذف کامل خطای شدت نیست.

در مجموع، شبکه در هر ۹ ترکیب بررسی شده میانگین PSNR بالاتری نسبت به فیلتر میانه دارد؛ اما تنها در پنج ترکیب از فیلتر گاوسی پیشی می‌گیرد.

نتیجه‌گیری

در این پژوهش، شبکه کانولوشنی مبتنی بر یادگیری باقی‌مانده برای حذف نویز ترکیبی پواسون-گاوسی ارزیابی شد. کاهش خطای آموزش و اعتبارسنجی و بررسی تصاویر بازسازی شده نشان داد که شبکه توانسته است نویز را کاهش دهد و ساختار کلی تصاویر را حفظ کند. میانگین PSNR و SSIM شبکه به ترتیب به $31/12$ دسی‌بل و $0/875$ رسید. شبکه در هر ۹ ترکیب نویز، میانگین PSNR بالاتری نسبت به فیلتر میانه داشت؛ با این حال، برتری آن نسبت به فیلتر گاوسی به شرایط نویز و معیار ارزیابی وابسته بود. این روش پتانسیل بالایی برای کاربرد در سامانه‌های تصویربرداری پزشکی، بینایی ماشین و سنجش از دور (به‌ویژه در شرایط کم‌نور) دارد.

تفسیر شود؛ زیرا سطح کلی PSNR در این شرایط پایین‌تر است.

در سطح میانی $p = 100$ ، عملکرد شبکه و فیلتر گاوسی به یکدیگر نزدیک می‌شود. میانگین PSNR شبکه با افزایش σ از $0/1$ به $0/05$ ، از حدود $31/97$ به $29/89$ دسی‌بل کاهش می‌یابد. شبکه در $\sigma = 0.01$ اندکی بالاتر از فیلتر گاوسی قرار دارد؛ در $\sigma = 0.03$ ، اختلاف دو روش تنها حدود $0/04$ دسی‌بل است و در $\sigma = 0.05$ ، فیلتر گاوسی میانگین بالاتری نشان می‌دهد. این نتیجه با مقایسه شکل ۳ سازگار است و نشان می‌دهد رتبه‌بندی روش‌ها به شرایط نویز وابسته است.

در شرایط $p = 500$ ، شبکه کانولوشنی در هر سه سطح نویز گاوسی بالاترین میانگین PSNR را به دست آورده است. بیشترین مقدار، حدود $35/89$ دسی‌بل، در $\sigma = 0.01$ مشاهده می‌شود. با افزایش σ ، عملکرد همه روش‌ها افت می‌کند و فاصله شبکه با فیلتر گاوسی کمتر می‌شود. شیب نزولی بیشتر منحنی‌ها در این پل، با افزایش اهمیت نسبی مؤلفه گاوسی پس از کاهش سهم نویز پواسون سازگار است.

منابع

References

- [1] Fossum ER. CMOS image sensors: electronic camera-on-a-chip. *IEEE Trans Electron Devices*. 1997;44(10):1689-1698. doi:10.1109/16.628824.
- [2] El Gamal A, Eltoukhy H. CMOS image sensors. *IEEE Circuits Devices Mag*. 2005; 21(3):6-20. doi:10.1109/MCD.2005.1438751.
- [3] Optical Coherence Tomography Drexler W, Fujimoto JG. Optical Coherence Tomography: Technology and Applications. 2nd ed. Cham: Springer; 2015.
- [4] Ma J, Sheridan RP, Liaw A, Dahl GE, Svetnik V. Deep neural nets as a method for quantitative structure-activity relationships. *J Chem Inf Model*. 2015;55(2):263-274. doi:10.1021/ci500747n.
- [5] Healey GE, Kondepudy R. Radiometric CCD camera calibration and noise estimation. *IEEE Trans Pattern Anal Mach Intell*. 1994;16(3):267-276. doi:10.1109/34.273735.
- [6] Chen J, Chen J, Chao H, Yang M. Image blind denoising with generative adversarial network based noise modeling. *Proc IEEE Conf Comput Vis Pattern Recognit*. 2018:3155-3164.
- [7] Foi A, Trimeche M, Katkovnik V, Egiazarian K. Practical Poissonian-Gaussian noise modeling and fitting for single-image raw-data. *IEEE Trans Image Process*. 2008;17(10):1737-1754. doi:10.1109/TIP.2008.2001399.
- [8] Le Montagner Y, Angelini E, Olivo-Marin JC. An unbiased risk estimator for image denoising in the presence of mixed Poisson-Gaussian noise. *IEEE Trans Image Process*. 2014;23(3):1255-1268. doi:10.1109/TIP.2013.2295881.
- [9] Janesick JR. Photon Transfer. Bellingham (WA): SPIE Press; 2007.
- [10] Holst GC, Lomheim TS. CMOS/CCD Sensors and Camera Systems. 2nd ed. Bellingham (WA): SPIE Press; 2011.
- [11] Huang TS, Yang GJ, Tang GY. A fast two-dimensional median filtering algorithm. *IEEE Trans Acoust Speech Signal Process*. 1979; 27(1):13-18. doi:10.1109/TASSP.1979.1163188.
- [12] Lim JS. Two-Dimensional Signal and Image Processing. Englewood Cliffs (NJ): Prentice Hall; 1990.
- [13] Donoho DL. De-noising by soft-thresholding. *IEEE Trans Inf Theory*. 1995; 41(3):613-627. doi:10.1109/18.382009.
- [14] Dabov K, Foi A, Katkovnik V, Egiazarian K. Image denoising by sparse 3-D transform-domain collaborative filtering. *IEEE Trans Image Process*. 2007;16(8):2080-2095. doi:10.1109/TIP.2007.901238.
- [15] Buades A, Coll B, Morel JM. A non-local algorithm for image denoising. *Proc IEEE Comput Soc Conf Comput Vis Pattern Recognit*. 2005; 2:60-65. doi:10.1109/CVPR.2005.38.
- [16] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015; 521(7553): 436-444. doi: 10.1038/nature14539.
- [17] Goodfellow I, Bengio Y, Courville A. Deep

- Learning. Cambridge (MA): *MIT Press*; 2016.
- [18] Zhang K, Zuo W, Chen Y, Meng D, Zhang L. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising. *IEEE Trans Image Process.* 2017; 26(7): 3142-3155. doi:10.1109/TIP. 2017. 2662206.
- [19] Tian C, Fei L, Zheng W, Xu Y, Zuo W, Lin CW. Deep learning on image denoising: An overview. *Neural Netw.* 2020; 131: 251-275. doi:10.1016/j.neunet.2020.07.025.
- [20] Zamir SW, Arora A, Khan S, Hayat M, Khan FS, Yang MH, et al. Restormer: Efficient transformer for high-resolution image restoration. *Proc IEEE Conf Comput Vis Pattern Recognit.* 2022:5728-5739. doi:10.1109/CVPR52688.2022.00567.