

IMAGE QUALITY IMPROVEMENT BY COMBINING TRADITIONAL LUCY – RICHARDSON – ROSEN ALGORITHM AND UNET-FORMED DEEP LEARNING TECHNIQUE

Tran Trong Thang¹, Le Trong Hieu¹, Nguyen Quang Thi², Dinh Van Sang², Le Van Nhu^{2*}

¹Electric Power University, ²Le Quy Don University

ARTICLE INFO		ABSTRACT
Received:	23/11/2024	The contrast, similarity to the original image, and visual quality have been significantly improved with traditional restoration techniques. Among these, the conventional Lucy - Richardson - Rosen - Algorithm is one of the recently created algorithms for boosting resolution and image resemblance to the original. However, tests have found that this method still inserts noise into the recovered image, with artifacts following the image details. This research suggests using additional deep learning approaches to reduce noise and improve the quality of the recovered image. Unet is the deep learning model that was employed. The simulation process results on a set of medical images showed that with a blurred medical image from an optical system, after two processing steps using the traditional Lucy - Richardson - Rosen - Algorithm and combining it with the Unet deep learning network, the reconstructed image was better. The Structural Similarity Index and Learned Perceptual Image Patch Similarity Index demonstrated that the reconstructed image had lower artifact noise component, better resolution, and a higher degree of resemblance with the original image.
Revised:	30/12/2024	
Published:	30/12/2024	

KEYWORDS

Image restoration
Lucy – Richardson – Rosen
Image quality
Deep learning
Unet model

NÂNG CAO CHẤT LƯỢNG ẢNH BẰNG KẾT HỢP THUẬT TOÁN TRUYỀN THỐNG LUCY – RICHARDSON – ROSEN VÀ KỸ THUẬT HỌC SÂU DẠNG UNET

Trần Trọng Thăng¹, Lê Trọng Hiếu¹, Nguyễn Quang Thi², Đinh Văn Sang², Lê Văn Nhu^{2*}

¹Trường Đại học Điện lực, ²Trường Đại học Kỹ thuật Lê Quý Đôn

THÔNG TIN BÀI BÁO	TÓM TẮT
Ngày nhận bài: 23/11/2024	Các thuật toán khôi phục truyền thống đã cải thiện đáng kể chất lượng ảnh về độ phân giải, tính tương tự với ảnh gốc và độ tương phản. Trong đó, thuật toán truyền thống Lucy – Richardson – Rosen là một trong những phương pháp mới được phát triển gần đây cho cải thiện độ phân giải ảnh và tính tương đồng với ảnh gốc. Tuy nhiên, các nghiên cứu cũng chỉ ra rằng phương pháp này vẫn đưa đến tạp chất gây nhiễu trên ảnh khôi phục, xuất hiện các artifacts bám theo các chi tiết ảnh. Để loại bỏ được nhiễu này và nâng cao chất lượng ảnh khôi phục, bài báo này đã đề xuất sử dụng thêm kỹ thuật học sâu. Mô hình học sâu được sử dụng dạng Unet. Quá trình mô phỏng trên bộ ảnh y tế đã chỉ ra rằng với một ảnh y tế mờ từ hệ thống quang học, sau hai bước xử lý bằng thuật toán Lucy – Richardson – Rosen và kết hợp với mạng học sâu Unet đã cho ảnh khôi phục tốt hơn. Ảnh khôi phục đã giảm được thành phần nhiễu artifact, cải thiện độ phân giải và tăng tính đồng dạng với ảnh gốc được minh chứng bằng chỉ số tương đồng cấu trúc và chỉ số nhận thức thị giác của người.
Ngày hoàn thiện: 30/12/2024	
Ngày đăng: 30/12/2024	

TỪ KHÓA

Khôi phục ảnh
Thuật toán Lucy – Richardson - Rosen
Chất lượng ảnh
Kỹ thuật học sâu
Mô hình Unet

DOI: <https://doi.org/10.34238/tnu-jst.11593>

* Corresponding author. Email: vannhu.le@lqdtu.edu.vn

1. Giới thiệu

Một hệ thống quang học hoạt động tương đương với một bộ lọc thông thấp với hàm truyền là một hàm Gaussian (hàm này thường được gọi là hàm nhòe điểm). Do vậy, ảnh được tạo từ một hệ thống quang học sẽ bị mờ đi so với ảnh gốc. Mô phỏng quá trình tạo ảnh của một hệ thống quang học với đầu thu có thể được biểu diễn bằng công thức sau đây:

$$g = o \otimes h \quad (1)$$

Ở đây, o là vật, h là hàm nhòe điểm (PSF), toán tử \otimes là tích chập.

Từ phương trình trên có thể thấy rằng, kích thước hàm nhòe điểm càng nhỏ thì ảnh g thu được càng tiến tới o . Tuy nhiên, giảm kích thước hàm nhòe điểm luôn luôn là thách thức đối với phần cứng của hệ quang học. Vì vậy, thách thức của các nhà khoa học là với ảnh mờ thu được của hệ quang học có hàm nhòe điểm kích thước lớn phải khôi phục về ảnh như hệ thống quang học có hàm nhòe kích thước nhỏ hơn, qua đó chất lượng ảnh sẽ tốt hơn. Nhiều thuật toán khôi phục đã được nghiên cứu trước đây như Fresnel Incoherent Correlation Holography (FINCH), Interferenceless Coded Aperture Correlation Holography (I-COACH), Lucy – Richardson, None - Linear Reconstruction (NLR) và gần đây là Lucy – Richardson - Rosen Algorithm (LRR) [1] – [4]. Sau FINCH và COACH, I-COACH được phát triển nhờ NLR tuy nhiên ảnh khôi phục bị nhiễu [3]. LRR được phát triển dựa trên sự kết hợp của NLR với một phương pháp nổi tiếng là Lucy – Richardson (LRA), phương pháp đã tạo ra ảnh khôi phục có tỉ lệ tín trên tạp (SNR) tốt hơn NLR và LRA [4]. LRR đã được chỉ ra có khả năng hội tụ nhanh hơn và ước lượng tốt hơn hẳn so với LRA. Tuy nhiên, ảnh khôi phục của LRR vẫn cho nhiều chi tiết giả (artifact).

Bên cạnh đó, kỹ thuật học sâu gần đây đã và đang trở thành một công cụ rất mạnh được ứng dụng trong rất nhiều lĩnh vực và xử lý ảnh cũng không phải ngoại lệ [5] – [10]. Các mô hình học sâu đã được sử dụng có nhiều loại như Convolutional Neural Network (CNN), Generative Adversarial Networks (GAN), Unet [6], [7]. Mặc dù có nhiều kiến trúc mạng khả dụng, chúng tôi đã chọn Unet vì nó được sử dụng rộng rãi trong hình ảnh. Unet xử nhiều hình ảnh cuối cùng, có thể sửa lỗi không khớp mô hình và làm cho hình ảnh trông hấp dẫn hơn về mặt thị giác [8]. Vai trò của mạng học sâu Unet này là huấn luyện cho từng cặp ảnh có độ phân giải thấp (LR) với ảnh chất lượng cao (HR). Tuy nhiên, khác với phương pháp khác huấn luyện trực tiếp các ảnh mờ với ảnh nhận độ sắc nét cao, chúng tôi sẽ khôi phục ảnh mờ trước bằng thuật toán LRR như là bước đệm để tạo ảnh LR, giúp quá trình so sánh từng cặp ảnh trong mạng học sâu gần hơn với ảnh HR, qua đó nâng cao hiệu quả khôi phục ảnh. Kết thúc quá trình huấn luyện, một bộ tham số sẽ thu được phục vụ cho quá trình khôi phục cho bất kỳ ảnh mờ nào có định dạng giống với quá trình đã được huấn luyện. Kết quả là ảnh nhận được đã sửa được các chi tiết giả (artifacts) trên ảnh của phương pháp LRR và độ phân giải được cải thiện.

2. Phương pháp

2.1. Khôi phục ảnh theo phương pháp truyền thống (LRR)

Bài báo [4] đã chỉ ra trong phương pháp khôi phục ảnh bằng LRR, ảnh tái tạo thứ $n+1$ được xác định bằng công thức :

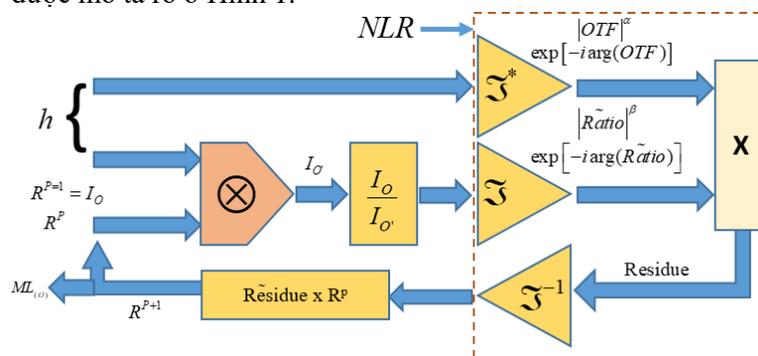
$$I_R^{n+1} = I_R^n \left\{ \left(\frac{I_o}{I_R^n \otimes h} \right) \otimes_{\beta}^{\alpha} h \right\} \quad (2)$$

Trong đó, \otimes_{β}^{α} tham chiếu tới thuật toán NLR và nó được định nghĩa cho hàm A và B:

$$\left| F^{-1} \left\{ |A|^{\alpha} \exp \left[j \arg(|A|) \right] |B|^{\beta} \exp \left[-j \arg(|B|) \right] \right\} \right| \quad (3)$$

Trong đó, A và B là biến đổi Fourier của A và B. α và β có thể thay đổi được từ - 1 đến 1. Quá trình khôi phục ảnh của thuật toán sẽ bắt đầu với ảnh đầu tiên là I_0 khi $n = 1$ là ảnh dự đoán,

nó được tích chập với h (hàm nhòe điểm), sau đó đem kết quả so sánh với I_0 bằng cách tính tỉ lệ giữa ảnh vừa tạo ra với ảnh I_0 . Tỉ lệ này được tương quan với h để thu được phần dư và nhân với ảnh trước đó. Quá trình lặp này diễn ra cho tới khi tỉ lệ này đạt đến độ hội tụ ở một giá trị không đổi, quá trình này được mô tả rõ ở Hình 1.

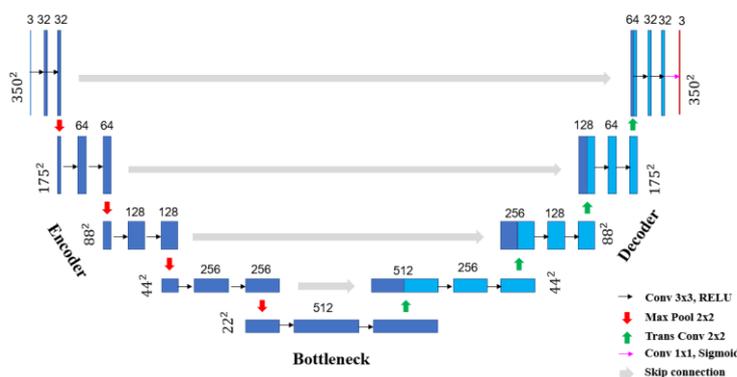


Hình 1. Sơ đồ nguyên lý khôi phục ảnh bằng LRRA

Như đã nói ở trên, bộ ảnh đầu ra đã được chỉ ra có chất lượng tốt hơn ảnh mờ nhiều, tuy nhiên khôi phục bằng LRRA còn tồn tại nhiều chi tiết giả vì thế sau khôi phục LRRA, ảnh này được coi là ảnh LR. Ở bước tiếp theo, các ảnh này tiếp tục được chúng tôi huấn luyện bằng một mạng học sâu theo mô hình mạng Unet bằng cách cho học ảnh xạ với ảnh HR.

2.2. Mạng học sâu cho bài toán khôi phục ảnh mờ

Mạng học sâu được sử dụng để huấn luyện từng cặp ảnh LR thành HR, theo mô hình mạng Unet dưới đây [6], [7].



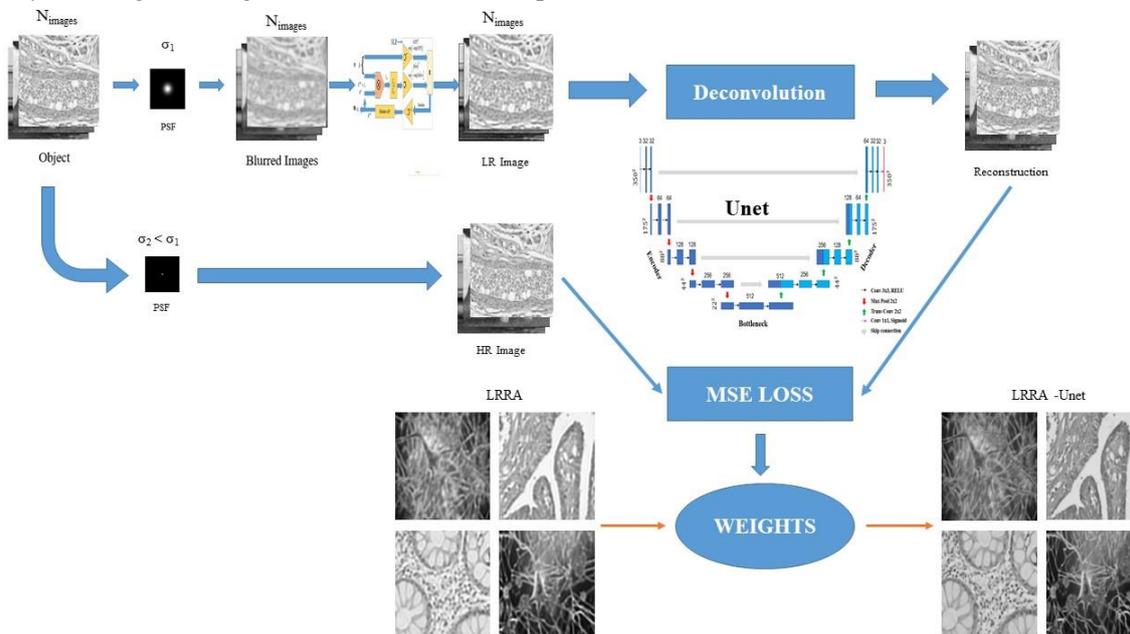
Hình 2. Mô hình mạng Unet sử dụng [7]

Mô hình Unet của chúng tôi bao gồm một bộ mã hóa và một bộ giải mã, với 09 tầng và 32 đến 512 bộ lọc như Hình 2. Trong mỗi tầng của giai đoạn mã hóa, ảnh đầu vào trải qua hai lớp tích chập 3×3 , bước tiếp theo là một hàm kích hoạt (ReLU). Sau đó, lớp gộp 2×2 được sử dụng để giảm kích thước không gian của ảnh (ví dụ, từ 350×350 xuống 175×175 , từ 175×175 xuống 88×88 , v.v...). Tương tự như vậy, trong mỗi tầng của giai đoạn giải mã, một tích chập chuyển vị 2×2 để tăng kích thước không gian của ảnh (ví dụ, từ 22×22 lên 44×44). Tiếp theo là hai lớp tích chập 3×3 theo sau là hàm kích hoạt ReLU. Tại mỗi mức giải mã, có một bước kết nối rút ngắn (skip connection) lấy các đặc trưng tương ứng trong bộ mã hóa (Encoder). Kết nối rút ngắn giúp giữ lại thông tin chi tiết từ bộ mã hóa và kết hợp với thông tin đặc trưng từ bộ giải mã (Decoder).

Sau khi huấn luyện, bộ tham số lưu lại các trọng số (WEIGHTS) và độ lệch (biases) của các lớp trong mạng nơ-ron. Các tham số này đóng vai trò như "bộ nhớ" của mạng, giúp mạng lưu lại các đặc trưng và thông tin học được từ dữ liệu để sử dụng cho các dự đoán hoặc nhận diện sau này.

2.3. Mô hình kết hợp khôi phục ảnh truyền thống với mạng học sâu

Từ các phân tích ở trên, bài báo này đề xuất mô hình kết hợp giữa phương pháp khôi phục ảnh truyền thống và mạng học sâu, ảnh sẽ tái tạo qua hai bước được mô tả như Hình 3.



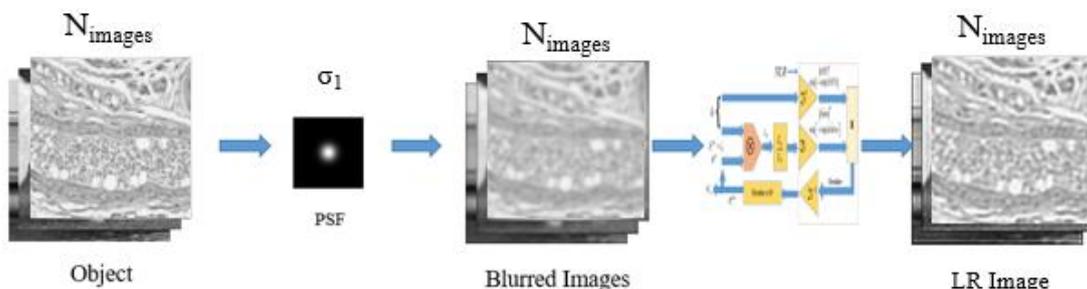
Hình 3. Mô hình kết hợp phương pháp khôi phục ảnh truyền thống và mạng học sâu Unet

Trong mô hình kết hợp giữa LRRA với Unet, một ảnh mờ sẽ được khôi phục lần thứ nhất bằng thuật toán LRRA và ảnh này coi như ảnh LR. Trong mô hình mạng Unet, ứng với mỗi ảnh LR này chúng tôi tạo ra một ảnh HR tương ứng bằng cách tích chập ảnh gốc với hàm PSF có kích thước δ nhỏ hơn. Với số lượng cặp ảnh HR – LR được tạo ra, mạng Unet sẽ huấn luyện ảnh LR về ảnh HR và hàm MSE được dùng để so sánh ảnh khôi phục với ảnh HR. Bộ thông số WEIGHTS được ghi lại và phục vụ khôi phục ảnh cho các ảnh đầu vào sau này.

Hiệu quả của mô hình được chúng tôi đánh giá ở phần kết quả mô phỏng với độ phân giải ảnh, chỉ số tương đồng của ảnh (SSIM) và chỉ số nhận thức thị giác của người (LPIPS).

3. Kết quả và thảo luận

3.1. Bộ dữ liệu

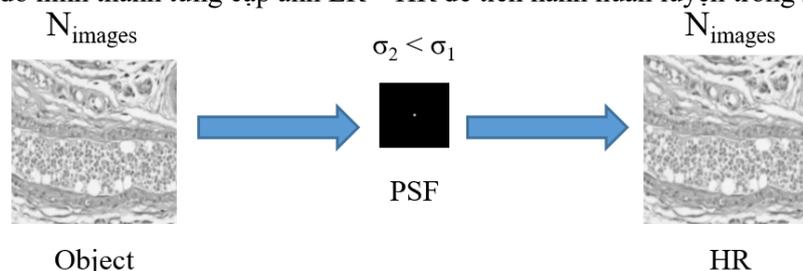


Hình 4. Thực hiện khôi phục ảnh mờ (bằng thuật toán LRRA)

Tạo ảnh mờ kích thước $m \times m$ như phương trình (1) bằng cách cuộn PSF là một ma trận hàm Gaussian cùng kích thước $m \times m$ hệ số σ_1 với ảnh gốc o . Thực hiện thuật toán LRRA như Hình 4 với số lần lặp là 20, hệ số ứng $\alpha = 1$ và $\beta = 0,8$ ứng với mỗi ảnh mờ là đầu vào, ta sẽ thu được một ảnh sau khôi phục.

Như đã nói ở trên, các ảnh khôi phục bằng LRRA này có chất lượng tốt hơn ảnh mờ tuy nhiên vẫn tồn tại nhiều các chi tiết giả được gọi là artifact. Để loại bỏ bớt nhiễu này đặc biệt ở viền xung quanh thì ảnh kích thước $m \times m$ được cắt xén viền để thành ảnh $n \times n$ ($m > n$). Thực hiện bước xử lý này với hơn 10000 ảnh nhằm tạo ra bộ dữ liệu đầu vào cho mạng học sâu tiếp theo, các ảnh này được coi là các ảnh LR.

Tương tự vậy, 10000 ảnh nhân tương ứng từng cặp với các ảnh LR ở trên, bằng cách tích chập ảnh gốc O với ma trận PSF có σ_2 (với $\sigma_2 < \sigma_1$) như Hình 5. Các ảnh nhân này được coi như các ảnh HR để từ đó hình thành từng cặp ảnh LR – HR để tiến hành huấn luyện trong mạng học sâu.



Hình 5. Tạo ảnh nhân

Bộ ảnh gốc được sưu tập từ nhiều nguồn, chủ yếu tại Flickr và Kaggle. Mô hình được huấn luyện trên phần mềm Colab của Google, thời gian thực hiện là 01 tháng. Quá trình huấn luyện được thực hiện với GPU T4, RAM 16GB trên Colab của Google. Sau khi huấn luyện, bộ trọng số (weights) được lưu lại như là bộ nhớ và mỗi ảnh đầu vào sẽ được khôi phục theo bộ trọng số này. Kết quả sẽ được chỉ ra và phân tích chi tiết trong mục 3.3.

3.2. Tham số mạng Unet

Learn rate: Lựa chọn hệ số learning rate cho model huấn luyện cực kỳ quan trọng, do đó để tối ưu được tốt tham số này, chúng tôi tiến hành giảm dần learning rate sau một khoảng thời gian huấn luyện nhất định, từ đó đạt được độ sâu hội tụ tốt nhất [9]. Tuy nhiên chỉ cần giảm xuống khoảng 10^{-6} là bảo đảm.

Hàm mất mát (Loss Function): Hàm mất mát của mạng sử dụng trung bình bình phương sai số (MSE) [10] được xác định bằng biểu thức sau:

$$MSE = \frac{1}{2} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4)$$

Trong đó: y_i là giá trị điểm ảnh nhân label, \hat{y}_i là giá trị điểm ảnh dự đoán được

N là số pixels.

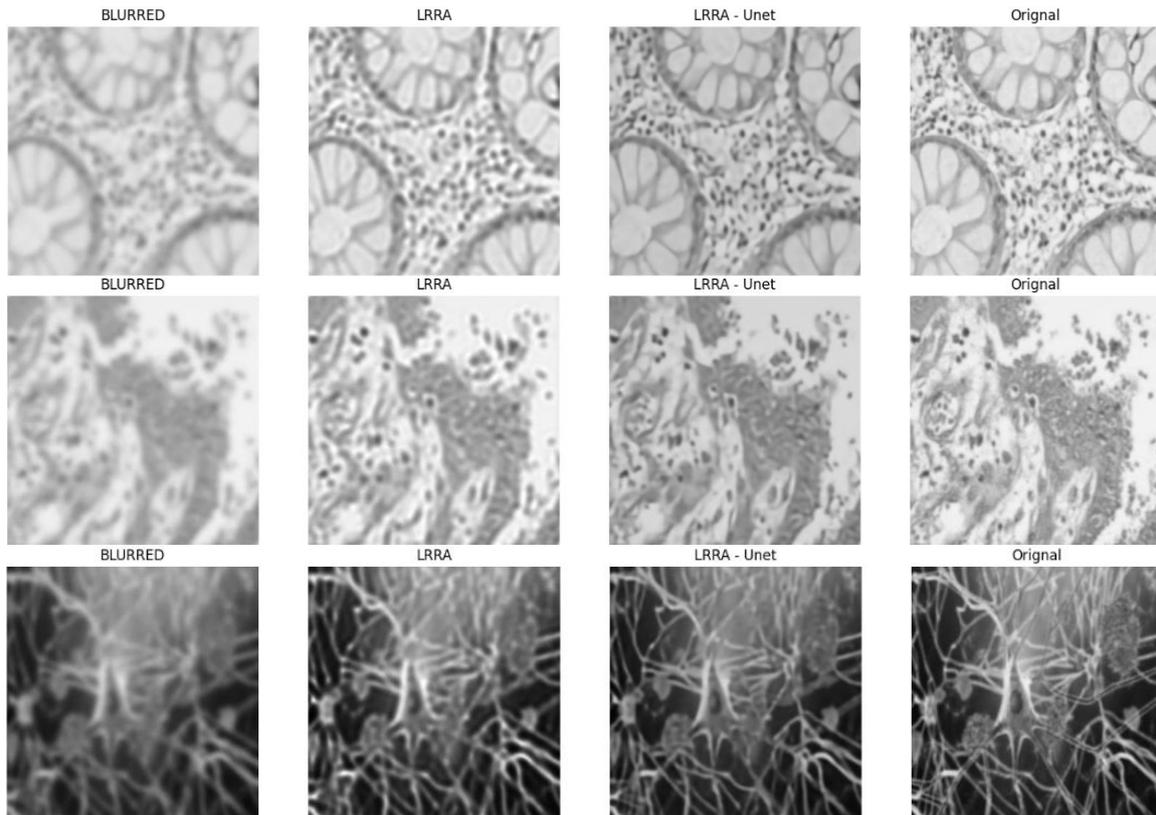
Bên cạnh đó, chỉ số SSIM rất hữu ích để đánh giá độ tương đồng giữa ảnh khôi phục với ảnh kì vọng, được mô tả bằng công thức:

$$SSIM(x, y) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (5)$$

Ở đây, l là độ sáng (được sử dụng để so sánh độ sáng giữa hai hình ảnh), c là độ tương phản (được sử dụng để phân biệt các phạm vi giữa vùng sáng nhất và tối nhất của hai hình ảnh) và s là cấu trúc (được sử dụng để so sánh mẫu độ sáng cục bộ giữa hai hình ảnh để tìm điểm giống và khác nhau của các hình ảnh) và α , β và γ là các hằng số dương thường được đặt mặc định bằng 1 khi tính toán trong phần mềm mô phỏng.

3.3. Kết quả mô phỏng

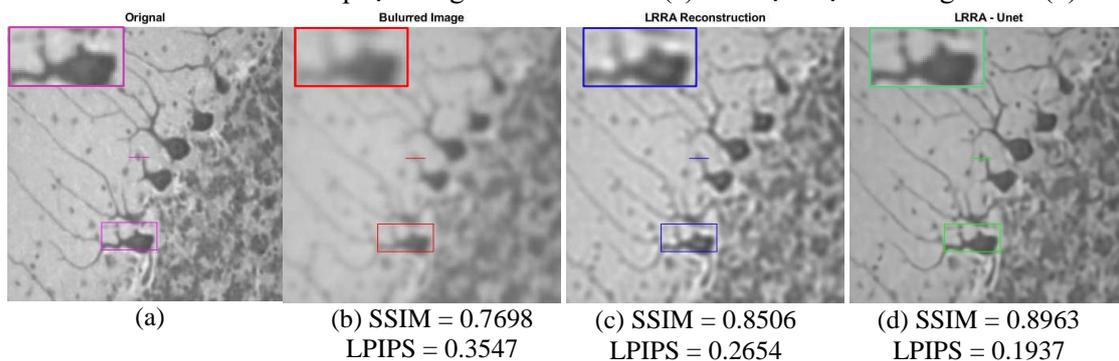
Trong phần này chúng tôi đánh giá hiệu quả của phương pháp đề xuất trên một số tập ảnh các bệnh phẩm, ảnh tế bào da, tế bào ung thư, tế bào máu và nơ ron thần kinh nằm ngoài bộ dữ liệu huấn luyện, được tham khảo tại Kaggle. Một số ảnh đại diện được sử dụng cho đánh giá hiệu quả của phương pháp đề xuất được biểu diễn trên Hình 6.



Hình 6. Kết quả khôi phục một số ảnh chụp từ mô hình đề xuất

Từ trái qua phải lần lượt là ảnh đã được làm mờ (Blurred), tiếp theo là ảnh khôi phục bằng thuật toán LRRRA, tiếp đến là ảnh khôi phục bằng mô hình kết hợp LRRRA-Unet, cuối cùng bên phải là ảnh gốc (Original). Từ kết quả ở Hình 6 không khó để nhận ra ảnh khôi phục bằng mô hình đề xuất LRRRA – Unet có chất lượng tốt hơn về mặt thị giác.

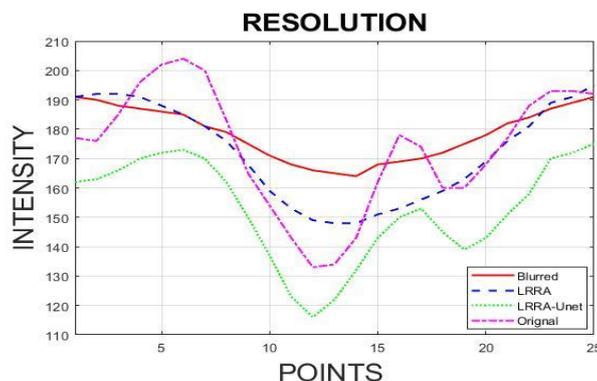
Chỉ số SSIM của các ảnh lần lượt trong Hình 7(b), Hình 7(c), Hình 7(d) tương ứng với các ảnh mờ, ảnh khôi phục bằng LRRRA, và ảnh khôi phục bằng LRRRA- Unet tăng dần, trong khi đó chỉ số LPIPS có xu hướng giảm dần. Các chỉ số đó cho thấy mô hình đề xuất cho ảnh khôi phục tương đồng hơn với ảnh gốc Hình 7(a) và tốt hơn về mặt thị giác. Các nhiễu gọi là artifact bám theo viền các chi tiết ảnh khôi phục bằng LRRRA ở Hình 7(c) đã được loại bỏ trong Hình 7(d).



Hình 7. Ảnh phân tích chi tiết: Ảnh gốc (a), ảnh làm mờ (b), ảnh khôi phục bằng LRRRA (c), ảnh khôi phục bằng phương pháp kết hợp LRRRA – Unet (d)

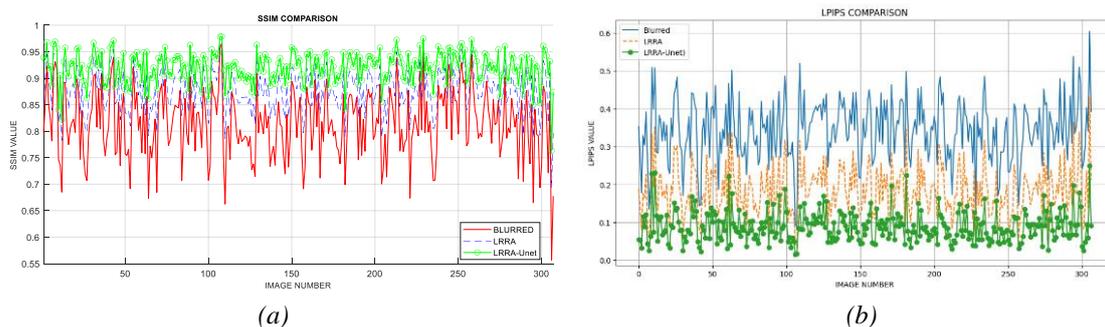
Phân tích biểu đồ cường độ sáng trong Hình 8 ta thấy đường nét liền vùng đánh dấu trong ảnh mờ Hình 7(b) có 2 đỉnh tuy nhiên không rõ rệt, đường nét đứt của vùng đánh dấu trong ảnh

Hình 7(b) có cường độ 2 đỉnh cao và rõ rệt hơn đường màu đỏ, thể hiện độ phân giải của ảnh khôi phục bằng LLRA đã được cải thiện hơn so với ảnh mờ. Đường chấm chấm của vùng đánh dấu ở Hình 7(c) xuất hiện 3 đỉnh rõ ràng và bám sát đường chấm gạch của ảnh gốc Hình 7(a). Điều này chứng minh độ phân giải ảnh của phương pháp đề xuất tốt hơn so với LRRA và tính tương đồng của ảnh sau khôi phục bằng phương pháp đề xuất cũng tốt hơn phương pháp truyền thống LRRA.



Hình 8. Biểu đồ cường độ sáng của các điểm trong vùng đánh dấu

Để đánh giá chỉ số SSIM và LPIPS của phương pháp đề xuất, chúng tôi thực hiện khôi phục với hơn 300 ảnh ngẫu nhiên và thu được biểu đồ như Hình 9.



Hình 9. (a) SSIM và (b) LPIPS của hơn 300 ảnh mờ, ảnh khôi phục LRRA và ảnh khôi phục bằng LRA – Unet

Chỉ số SSIM của các ảnh ở Hình 9(a) cho thấy đường '-' của phương pháp đề xuất LLRA - Unet có sự thay đổi theo từng ảnh nhưng luôn luôn cao hơn đường '--' của phương pháp khôi phục LRRA. Ngược lại, Hình 9(b) cho thấy chỉ số LPIPS của các ảnh theo phương pháp đề xuất luôn thấp hơn ảnh của phương pháp LRRA. Điều này cho thấy tính ổn định của phương pháp đề xuất và được thể hiện rõ thông qua các chỉ số SSIM, LPIPS trung bình của các loại ảnh so với ảnh gốc ở Bảng 1.

Bảng 1. SSIM và LPIPS trung bình của ảnh mờ, ảnh khôi phục bằng LRRA và ảnh khôi phục bằng phương pháp LRRA – Unet (mô phỏng với hơn 300 ảnh đầu vào)

	Ảnh mờ	LRRA	LRRA-Unet
SSIM _{TB}	0,8146	0,8772	0,9191
LPIPS _{TB}	0,3431	0,1853	0,0887

4. Kết luận

Trong bài báo này, chúng tôi đã đề xuất mô hình kết hợp giữa khôi phục ảnh theo phương pháp truyền thống và mô hình mạng học sâu. Kết quả mô phỏng cho thấy mô hình kết hợp này mang lại kết quả ảnh tốt hơn bằng cách loại bỏ các nhiễu artifact của phương pháp LRRA và tăng chỉ số tương đồng của ảnh khôi phục với ảnh gốc đồng thời giảm chỉ số nhận thức về thị giác của

người, được thể hiện qua tham số SSIM và LPIPS. Bên cạnh đó, phương pháp này cũng tăng cường độ phân giải ảnh so với phương pháp truyền thống LRRA. Cuối cùng, phương pháp khôi phục ảnh đề xuất đã chứng tỏ tính ổn định cao.

Lời cảm ơn

Bài báo này là kết quả của Đề tài nghiên cứu khoa học cấp Trường Đại học Điện lực năm 2024, mã số ĐTKHCN 08/2024.

TÀI LIỆU THAM KHẢO/ REFERENCES

- [1] W. H. Richardson, "Bayesian-Based Iterative Method of Image Restoration," *Journal of the Optical Society of America*, vol. 62, pp. 55-59, 1972.
- [2] L. B. Lucy, "An iterative technique for the rectification of observed distributions," *The Astronomical Journal*, vol. 79, pp. 745-754, 1974.
- [3] M. R. Rai, A. Vijayakumar, and J. Rosen, "Non-linear adaptive three-dimensional imaging with interferenceless coded aperture correlation holography (I-COACH)," *Optics Express*, vol. 26, pp. 18143-18154, 2018.
- [4] S. Gopinath, A. S. Rajeswary, and V. Anand, "Sculpting axial characteristics of incoherent imagers by hybridization methods," *Optics and Lasers in Engineering*, vol. 172, 2024, Art. no. 107837.
- [5] K. Zhang, W. Zuo, and L. Zhang, "Learning a single convolutional super-resolution network for multiple degradations," *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018, pp. 3262-3271.
- [6] A. Jayavel, S. Gopinath, P. P. Angamuthu, F. G. Arockiaraj, A. Bleahu, A. P. I. Xavier, D. Smith, M. Han, I. Slobozhan, *et al.* "Improved Classification of Blurred Images with Deep-Learning Networks Using Lucy-Richardson-Rosen Algorithm," *Photonics*, vol. 10, 2023, Art. no. 396.
- [7] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional networks for biomedical image segmentation," *International Conference on Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*, vol. 9351, pp. 234-241, 2015.
- [8] Y. Zhang, "Deep learning-enhanced microscopy with extended depth-of-field," *Light: Science & Applications*, vol. 12, 2023, Art. no. 284.
- [9] J. Jepakoch, D. M. Mugo, K. K. Benson, and E. C. Too, "The Effect of Adaptive Learning Rate on the Accuracy of Neural Networks," *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 8, pp. 736-751, 2021.
- [10] U. Sara, M. Akter, and M. Uddin, "Image Quality Assessment through FSIM, SSIM, MSE and PSNR—A Comparative Study," *Journal of Computer and Communications*, vol. 7, pp. 8-18, 2019.