

NÂNG CAO HIỆU QUẢ PHÁT HIỆN BLOB CHO BỘ LỌC GLOG ENHANCING THE EFFECTIVENESS OF BLOB DETECTION USING THE GLOG FILTER

Lê Xuân Quang¹
Nguyễn Đình Công^{2*}
Phạm Anh Đức³

¹ Thạc sĩ ngành Khoa học máy tính Khoa Kỹ thuật Công nghệ,
Trường Đại học Hồng Đức;
² Khoa Kỹ thuật Công nghệ, Trường Đại học Hồng Đức;
³ Công ty Cổ phần Sotatek;
*Tác giả liên hệ; Email: nguyendinhcong@hdu.edu.vn

DOI: <https://doi.org/10.70117/hdujs.3030-4628.90.09.2026.1138>

Ngày nộp bài: 18/01/2026; Ngày gửi phản biện: 02/02/2026; Ngày duyệt đăng: 25/09/2026

Từ khóa:

Phát hiện blob,
Laplacian of Gaussian
tổng quát (gLoG),
trích xuất đặc trưng.

Keywords:

Blob detection,
Generalized Laplacian
of Gaussian (gLoG),
feature extraction.

TÓM TẮT

Bài báo đề xuất hai chiến lược tối ưu hóa hiệu quả tính toán cho bộ lọc Laplacian of Gaussian tổng quát (gLoG) trong phát hiện blob. Chiến lược thứ nhất dùng phân tích thành phần chính (PCA) để xác định hướng chính và rút gọn số thang đo. Chiến lược thứ hai khai thác phân bố độ lớn gradient cục bộ để chọn và áp dụng bộ lọc theo các hướng liên quan nhất.

Thực nghiệm trên các bộ dữ liệu Oxford và ORL cho thấy các phương pháp duy trì độ lặp và độ chính xác định vị tốt, đồng thời giảm thời gian xử lý: PCA giảm 44% thời gian chạy với mức suy giảm độ chính xác ghép cặp chỉ 1,7%, trong khi biến thể dựa trên gradient đạt mức tăng tốc 37%. Thiết kế gọn nhẹ và tính nhất quán hình học của các bộ lọc đề xuất cho thấy tiềm năng ứng dụng trong các bài toán trích xuất đặc trưng với tài nguyên tính toán hạn chế.

ABSTRACT

This paper proposes two strategies to optimize the computational efficiency of the Generalized Laplacian of Gaussian (gLoG) filter for blob detection. The first strategy employs Principal Component Analysis (PCA) to identify dominant orientations and reduce the number of scales to be evaluated. The second strategy exploits the distribution of local gradient magnitudes to select and apply filters along the most relevant orientations.

Experiments on the Oxford and ORL datasets show that the proposed methods maintain high repeatability and strong localization accuracy while reducing processing time: the PCA-based method achieves a 44% reduction in runtime with only a 1.7% drop in matching accuracy, while the gradient-based variant attains a 37% speed-up.

The compact design and geometric consistency of the proposed filters highlight their potential for feature extraction tasks under limited computational resources.

1. MỞ ĐẦU

1.1. Giới thiệu bài toán

Phát hiện blob là một bài toán cơ bản trong thị giác máy tính, với nhiều ứng dụng trong ảnh y sinh, nhận dạng đối tượng, viễn thám và kiểm tra công nghiệp. Blob thường được định nghĩa là các vùng ảnh có đặc trưng cường độ khác biệt so với vùng lân cận, đóng vai trò quan trọng trong trích xuất đặc trưng và phân tích đối tượng [1]-[4].

Bộ lọc Laplacian of Gaussian (LoG) là một phương pháp phổ biến trong phát hiện blob nhờ khả năng phân tích đa thang và tính bất biến theo thang đo [5][6]. Tuy nhiên, LoG tiêu chuẩn sử dụng kernel Gaussian đẳng hướng nên gặp hạn chế khi phát hiện các cấu trúc kéo dài hoặc bất đẳng hướng. Để khắc phục, bộ lọc generalized Laplacian of Gaussian (gLoG) được đề xuất bằng cách tích hợp các kernel Gaussian có hướng, cho phép phát hiện blob với hình dạng và hướng đa dạng hơn [2], và đã được ứng dụng hiệu quả trong nhiều lĩnh vực như ảnh y sinh [7], phát hiện sâu răng [8] và công nghiệp [9][10]. Mặc dù đạt hiệu quả cao, việc áp dụng gLoG trên nhiều thang đo và hướng khác nhau làm gia tăng đáng kể chi phí tính toán [11], khiến phương pháp khó đáp ứng các ứng dụng thời gian thực hoặc xử lý ảnh quy mô lớn [12]. Các nghiên cứu trước đây đã đề xuất nhiều hướng cải tiến như tăng tốc phần cứng [13], lọc bất biến theo tương phản [6] hoặc mô hình xác suất [14], tuy nhiên các phương pháp này thường yêu cầu nền tảng chuyên dụng hoặc làm giảm tính linh hoạt của thuật toán.

Trong khi đó, các chiến lược tối ưu hóa chủ yếu cho việc lựa chọn thang đo và hướng trong gLoG vẫn chưa được khai thác đầy đủ. Để giải quyết khoảng trống này, bài báo đề xuất một khuôn khổ tối ưu hóa kép nhằm giảm các phép tính dư thừa mà vẫn bảo toàn độ chính xác phát hiện. Cụ thể, phương pháp tích hợp:

Phân tích thành phần chính (PCA) [15] để ước lượng các thang đo và hướng chi phối của blob trước khi áp dụng gLoG.

Phân tích lược đồ độ lớn gradient nhằm lựa chọn có chọn lọc các hướng quan trọng nhất cho quá trình lọc.

1.2. Tổng quan hàm Gaussian và biểu diễn không gian-thang đo

Hàm Gaussian đóng vai trò nền tảng trong lý thuyết không gian-thang đo (scale-space theory), nơi nó được sử dụng cho mục đích làm trơn và biểu diễn đa thang đo. Hàm này được định nghĩa như trong phương trình (1):

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right), \quad (1)$$

trong đó σ là tham số thang đo điều khiển mức độ làm trơn [16]. Biểu diễn không gian-thang đo của một ảnh $I(x, y)$ thu được bằng cách tích chập ảnh với một kernel Gaussian như trong phương trình (2):

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (2)$$

Cách tiếp cận này đảm bảo khả năng trích xuất đặc trưng ổn định trên nhiều thang đo khác nhau [16]. Tuy nhiên, bản thân phép lọc Gaussian không thể phát hiện các cấu trúc dạng blob, do đó cần đến các toán tử vi phân bậc hai như Laplacian.

1.3. Tổng quan hàm Laplacian of Gaussian

Bộ lọc Laplacian of Gaussian (LoG) được sử dụng rộng rãi cho bài toán phát hiện blob và được định nghĩa như trong phương trình (3):

$$\nabla^2 G(x, y, \sigma) = \left(\frac{\partial^2 G}{\partial x^2} \right) + \left(\frac{\partial^2 G}{\partial y^2} \right) \quad (3)$$

Khi áp dụng LoG lên ảnh trong không gian-thang đo, ta thu được (4):

$$\nabla^2 L(x, y, \sigma) = \nabla^2 (G(x, y, \sigma) * I(x, y)) \quad (4)$$

LoG cho khả năng phát hiện blob hiệu quả [6] nhưng đòi hỏi chi phí tính toán cao, đặc biệt trong các thiết lập đa thang đo. Để khắc phục hạn chế này, nhiều phương pháp xấp xỉ đã được đề xuất.

Phương pháp Difference of Gaussians (DoG) [6] xấp xỉ LoG bằng hiệu của hai bộ lọc Gaussian ở các thang đo khác nhau, giúp tăng tốc tính toán nhưng làm giảm độ chính xác đối với các blob không đồng nhất. Fast RT-LoG [11] sử dụng bộ lọc hộp để tăng tốc phép tích chập, cho phép xử lý thời gian thực nhưng làm suy giảm độ bền vững hình học. Nhìn chung, các phương pháp này cải thiện hiệu năng tính toán nhưng gặp khó khăn khi xử lý các blob có hình dạng và hướng đa dạng.

1.4. LoG tổng quát

Bộ lọc LoG tổng quát được biết là hàm gLoG [2] - mở rộng LoG bằng cách cho phép sử dụng các kernel Gaussian dị hướng, từ đó cho phép phát hiện các blob có hình dạng và hướng khác nhau. Quá trình phát hiện blob được thực hiện bằng cách tìm các cực trị cục bộ của đáp ứng bộ lọc trong không gian, thang đo. Cụ thể, một điểm được xem là ứng viên blob nếu đáp ứng của bộ lọc tại điểm đó đạt cực đại hoặc cực tiểu so với các điểm lân cận trong không gian ảnh và trên các thang đo lân cận. Cơ chế này cho phép phát hiện cả blob sáng trên nền tối và blob tối trên nền sáng. Bộ lọc này được mô tả như trong phương trình (5):

$$gLoG(x, y, \sigma_x, \sigma_y, \theta) = \nabla^2 G(x', y', \sigma_x, \sigma_y) \quad (5)$$

trong đó (x', y') là các tọa độ sau khi quay, được xác định bởi phương trình (6):

$$x' = x \cos \theta + y \sin \theta, \quad y' = -x \sin \theta + y \cos \theta \quad (6)$$

Ở đây, θ là tham số hướng, còn σ_x, σ_y xác định độ mở rộng của Gaussian theo các trục chính và trục phụ. Phương pháp cơ sở áp dụng bộ lọc gLoG một cách toàn diện trên tất cả các thang đo và hướng, dẫn đến chi phí tính toán được biểu diễn như trong phương trình (7) trong đó N, M là kích thước ảnh, S là số thang đo, O là số hướng và k là kích thước kernel.

$$O(N \cdot M \cdot S \cdot O \cdot k^2), \quad (7)$$

Mặc dù gLoG mang lại độ chính xác cao, chi phí tính toán lớn hạn chế khả năng ứng dụng thực tế. Các nghiên cứu trước đã đề xuất lựa chọn hướng thích nghi [7] hoặc điều chỉnh động thang đo [17], tuy nhiên vẫn yêu cầu tài nguyên đáng kể hoặc có thể làm suy giảm độ chính xác hình học. Ngược lại, các phương pháp được đề xuất trong bài báo này nhằm giảm các phép tính dư thừa trong khi vẫn bảo toàn các đặc tính cấu trúc quan trọng của gLoG, thông qua việc lựa chọn có chọn lọc các hướng và thang đo mang nhiều thông tin nhất.

2. PHƯƠNG PHÁP/ VẬT LIỆU NGHIÊN CỨU

Nhằm cải thiện hiệu quả tính toán của quá trình lọc gLoG, hai chiến lược được đề xuất. Phương pháp thứ nhất lựa chọn hướng và thang đo dựa trên phân tích trị riêng của tensor cấu trúc. Phương pháp thứ hai tinh chỉnh lựa chọn hướng dựa trên phân bố gradient cục bộ.

2.1. Lựa chọn thang đo và hướng dựa trên PCA

Cách tiếp cận này tập trung vào việc tối ưu hóa gLoG bằng cách xác định hướng và thang đo chính từ tensor cấu trúc của ảnh.

2.1.1. Tính toán hướng

Với ảnh đầu vào $I(x, y)$, gradient theo hai trục được tính như trong phương trình (8):

$$I_x(x, y) = \frac{\partial I(x, y)}{\partial x}, \quad I_y(x, y) = \frac{\partial I(x, y)}{\partial y}. \quad (8)$$

Trong đó $I_x(x, y)$ và $I_y(x, y)$ lần lượt là gradient ảnh theo trục x và y . Các gradient này cung cấp thông tin thiết yếu về sự biến thiên cường độ trong ảnh. Để tăng độ ổn định trước nhiễu và phản ánh tốt hơn cấu trúc cục bộ của ảnh, các thành phần của tensor được làm trơn bằng một bộ lọc Gaussian trên vùng lân cận xung quanh điểm ảnh. Việc làm trơn này tương đương với việc tích lũy thông tin gradient trong một cửa sổ cục bộ, giúp giảm ảnh hưởng của nhiễu và cung cấp ước lượng ổn định hơn về hướng biến thiên cường độ của ảnh. Dựa trên chúng, tensor cấu trúc J được xây dựng như trong Phương trình (9):

$$J = \begin{bmatrix} \sum I_x^2 & \sum I_x I_y \\ \sum I_x I_y & \sum I_y^2 \end{bmatrix}. \quad (9)$$

Các vector riêng của J chỉ ra những hướng biến thiên cường độ chi phối. Để trích xuất hướng chi phối, ta giải bài toán tìm trị riêng của J thông qua phương trình đặc trưng trong Phương trình (10):

$$\det(J - \lambda I) = 0. \quad (10)$$

Vector riêng tương ứng với trị riêng lớn nhất biểu diễn hướng chi phối θ_{PCA} , được xác định như trong Phương trình (11):

$$\theta_{PCA} = \frac{1}{2} \tan^{-1} \left(\frac{2 \sum I_x I_y}{\sum I_x^2 - \sum I_y^2} \right) \quad (11)$$

Từ số phản ánh mức độ tương quan giữa các gradient, trong khi mẫu số biểu diễn sự chênh lệch năng lượng gradient theo hai trục. Góc này đại diện cho hướng biến thiên cường độ quan trọng nhất và được sử dụng để căn chỉnh kernel gLoG theo hướng chi phối đó.

2.1.2. Lựa chọn thang đo tối ưu

Thang đo chính được ước lượng từ các trị riêng của J trong Phương trình (9) như trong Phương trình (12):

$$\sigma_{PCA} = \alpha \times \sqrt{\frac{\lambda_1 + \lambda_2}{2}} \quad (12)$$

Trong đó λ_1, λ_2 là các trị riêng và α là hệ số chuẩn hóa xác định bằng thực nghiệm. λ_1, λ_2 của tensor cấu trúc phản ánh mức độ biến thiên cường độ ảnh theo hai hướng chính trục giao. Trong các vùng có cấu trúc blob, các giá trị này biểu thị năng lượng gradient tích lũy trong vùng lân cận và do đó liên quan trực tiếp đến kích thước đặc trưng của cấu trúc ảnh. Khi lựa chọn một tập con thang đo rút gọn S' và loại bỏ các hướng dư thừa, độ phức tạp tính toán của gLoG dựa trên PCA được giảm xuống như trong Phương trình (13):

$$O(N \cdot M \cdot S' \cdot k^2) \quad (13)$$

trong đó $S' \ll S$. Hệ số tăng tốc tương ứng so với gLoG vét cạn được biểu diễn như trong Phương trình (14):

$$Speedup_{PCA} = \frac{S \cdot O}{S'} \quad (14)$$

Kết quả này cho thấy mức giảm đáng kể về chi phí xử lý với tác động không đáng kể đến độ chính xác phát hiện.

2.2. Tinh chỉnh hướng dựa trên gradient

Cách tiếp cận này nhằm tối ưu hóa việc lựa chọn hướng trong quá trình lọc gLoG bằng cách khai thác lược đồ độ lớn gradient để xác định các hướng liên quan nhất.

2.2.1. Tính toán lược đồ độ lớn gradient

Cho một ảnh đầu vào $I(x, y)$, ta tính độ lớn gradient và hướng gradient tại mỗi điểm ảnh như trong phương trình (15):

$$|\nabla I(x, y)| = \sqrt{I_x^2(x, y) + I_y^2(x, y)}$$
$$\theta(x, y) = \tan^{-1} \left(\frac{I_y(x, y)}{I_x(x, y)} \right) \quad (15)$$

Trong đó $|\nabla I(x, y)|$ biểu thị độ lớn của độ biên và $\theta(x, y)$ là góc định hướng tại mỗi giá trị pixel tương ứng. Các giá trị này được sử dụng để xây dựng lược đồ các hướng gradient, với trọng số tương ứng là độ lớn gradient, qua đó phản ánh mức độ chi phối của từng hướng trong vùng ảnh cục bộ.

2.2.2. Lựa chọn hướng

Thay vì áp dụng bộ lọc gLoG trên toàn bộ tập hướng rời rạc khả dĩ $\{\theta_1, \theta_2, \dots, \theta_0\}$, phương pháp đề xuất chỉ lựa chọn một tập con các hướng quan trọng nhất $\{\theta_1, \theta_2, \dots, \theta_{O'}\}$, trong đó $O' \ll O$. Việc lựa chọn này được thực hiện dựa trên lược đồ hướng gradient đã xây dựng ở bước trước. Cụ thể, các giá trị hướng gradient trong một vùng ảnh cục bộ được lượng tử hóa vào một lược đồ hướng. Mỗi bin của lược đồ tích lũy trọng số tương ứng với độ lớn gradient của các điểm ảnh có hướng nằm trong khoảng hướng của bin đó. Các hướng tương ứng với các bin có giá trị tích lũy lớn nhất được xem là các hướng chi phối của cấu trúc cục bộ và được lựa chọn để áp dụng bộ lọc gLoG. Trong thực nghiệm, phương pháp lựa chọn O' hướng có giá trị của lược đồ lớn nhất (top- k hướng), giảm đáng kể số lượng hướng cần xét trong quá trình lọc.

Trong trường hợp vùng ảnh có gradient yếu hoặc phân bố hướng gần đẳng hướng (tức lược đồ không xuất hiện đỉnh nổi trội), phương pháp quay về xét toàn bộ tập hướng ban đầu nhằm tránh bỏ sót các blob có cấu trúc tròn hoặc ít định hướng. Cơ chế này giúp duy trì tính ổn định của quá trình phát hiện đặc trưng. Nhờ khai thác các hướng chi phối được trích xuất từ lược đồ gradient, độ phức tạp tính toán của quá trình lọc được giảm xuống như trong Phương trình (16).

$$O(N \cdot M \cdot S \cdot O' \cdot k^2) \quad (16)$$

trong đó $O' \ll O$; N, M là kích thước ảnh, S là số lượng thang đo, O là số hướng và k là kích thước kernel. Hệ số tăng tốc tương ứng so với gLoG vét cạn được biểu diễn trong Phương trình (17):

$$Speedup_{Gradient} = \frac{O}{O'} \quad (17)$$

Cách tiếp cận này đảm bảo rằng tài nguyên tính toán chỉ được sử dụng cho các hướng blob liên quan nhất, đồng thời vẫn duy trì hiệu năng phát hiện.

3. KẾT QUẢ NGHIÊN CỨU VÀ THẢO LUẬN


3.1. Thiết lập thực nghiệm

Các phương pháp gLoG được đề xuất được đánh giá trên bộ dữ liệu Oxford affine covariant [18] và bộ dữ liệu khuôn mặt ORL [19]. Các tiêu chí đánh giá bao gồm độ lặp (repeatability), độ chính xác ghép cặp (matching score) và thời gian tính toán trung bình trên mỗi ảnh. Chỉ số repeatability được tính theo giao thức đánh giá được đề xuất ở [18]. Hai điểm đặc trưng được xem là tương ứng nếu vùng đặc trưng của chúng, sau khi biến đổi theo phép biến đổi hình học đã biết giữa hai ảnh, có độ chồng lấn vượt quá một ngưỡng xác định. Chỉ số repeatability được tính bằng tỷ lệ giữa số cặp điểm đặc trưng tương ứng hợp lệ và số lượng điểm đặc trưng tối thiểu được phát hiện trong hai ảnh của mỗi cặp ảnh. Tất cả các thí nghiệm được thực hiện trên máy tính sử dụng bộ xử lý Intel Core i7 2.2 GHz với 16 GB RAM. Hiệu năng của hai biến thể gLoG được đề xuất được so sánh trực tiếp với gLoG tiêu chuẩn trên toàn bộ các cặp ảnh của cả hai bộ dữ liệu.

Trong các thí nghiệm, bộ lọc gLoG được áp dụng trên một tập thang đo rời rạc trong khoảng $\sigma \in [1,6]$, $S=8$ thang đo. Tập hướng ban đầu của bộ lọc gồm $O=12$ hướng được phân bố đều trong miền góc $[0,\pi)$. Đối với phương pháp dựa trên gradient, các hướng chỉ phối được lựa chọn từ lược đồ hướng gradient trong vùng lân cận cục bộ và chỉ O' hướng quan trọng nhất được sử dụng trong quá trình lọc nhằm giảm chi phí tính toán.

3.2. Kết quả thực nghiệm

Hình 1 trình bày độ lặp trung bình của các phương pháp gLoG dựa trên PCA và gradient so với gLoG tiêu chuẩn trên bộ dữ liệu Oxford, bao gồm tám tập ảnh chuẩn: boat, bark, graf, wall, ubc, bikes, trees và leuven. Kết quả cho thấy các phương pháp đề xuất đạt độ lặp gần tương đương gLoG trên các phép biến đổi khác nhau, cho thấy khả năng bảo toàn hiệu quả phát hiện điểm đặc trưng của phương pháp gốc.




Hình 1. Độ lặp trung bình của các phương pháp gLoG tiêu chuẩn và các biến thể đề xuất trên bộ dữ liệu Oxford

Bảng 1. So sánh các bộ phát hiện trên bộ dữ liệu ORL

Bộ phát hiện	Số điểm phát hiện	Độ lặp (%)	Số điểm khớp	Tỷ lệ nhận dạng (%)
SIFT	18	41.0	5	90.0
HLoG	9	59.0	3	80.0
Fast RT-LoG	76	45.4	9	94.5
gLoG	59	79.1	21	96.0
gLoG dựa trên PCA (Ours)	52	73.8	19	94.2
gLoG dựa trên Gradient (Ours)	50	72.5	18	93.5


Hình 2 (biểu đồ logarit-logarit) minh họa mối quan hệ giữa độ phân giải ảnh và thời gian tính toán của các phương pháp gLoG. Trong khi gLoG tiêu chuẩn có chi phí tính toán tăng nhanh theo độ phân giải, các biến thể dựa trên PCA và gradient giúp giảm thời gian xử lý lần lượt khoảng 44% và 37% đối với ảnh có độ phân giải cao, đồng thời vẫn duy trì hiệu năng phát hiện gần tương đương, phù hợp cho các ứng dụng thời gian thực.



Hình 2. Biểu đồ log-log thể hiện thời gian tính toán theo độ phân giải ảnh

Các kết quả thực nghiệm cho thấy gLoG tiêu chuẩn đạt độ chính xác cao nhất nhưng đi kèm chi phí tính toán lớn. Phương pháp gLoG dựa trên PCA giúp giảm đáng kể thời gian xử lý trong khi vẫn duy trì độ chính xác tốt, phù hợp cho các ứng dụng thời gian thực. Phương pháp gLoG dựa trên gradient tiếp tục cải thiện hiệu quả tính toán, đạt mức tăng tốc đáng kể trong khi vẫn giữ hiệu năng phát hiện gần với gLoG tiêu chuẩn.

Bảng 1 trình bày so sánh các bộ phát hiện điểm đặc trưng trên bộ dữ liệu ORL. gLoG tiêu chuẩn đạt độ lặp cao nhất (79,1%) và tỷ lệ nhận dạng cao nhất (96,0%). Hai biến thể gLoG được đề xuất đạt hiệu năng cạnh tranh với độ lặp lần lượt là 73,8% và 72,5%, trong khi vẫn duy trì tỷ lệ nhận dạng trên 93%, cho thấy sự đánh đổi hợp lý giữa độ chính xác và hiệu quả tính toán. Để so sánh trực quan hành vi phát hiện blob, Hình 3 minh họa các điểm đặc trưng được phát hiện bởi gLoG tiêu chuẩn và hai biến thể được đề xuất. Mỗi blob được biểu diễn dưới dạng một ellipse màu xanh lá, trong đó hình dạng và hướng phản ánh cấu trúc cục bộ và góc θ được lựa chọn. Các mũi tên màu đỏ biểu thị hướng gradient chi phối ϕ tại vị trí mỗi điểm đặc trưng.



Hình 3. Minh họa kết quả phát hiện blob với thông tin hướng. Các ellipse màu xanh lá biểu diễn hình dạng và hướng của từng blob, trong khi các mũi tên màu đỏ chỉ hướng gradient cục bộ. Từ trái sang phải: gLoG tiêu chuẩn, gLoG dựa trên PCA (đề xuất), và gLoG dựa trên gradient (đề xuất)

Như thể hiện trong hình, gLoG tiêu chuẩn tạo ra các blob với dải hướng rộng, trong khi phương pháp dựa trên PCA cho thấy sự căn chỉnh nhất quán hơn nhờ ước lượng hướng toàn cục. Phương pháp dựa trên gradient thích nghi cục bộ, tạo ra các hướng đa dạng hơn nhưng vẫn duy trì độ bền vững trong các vùng có kết cấu phức tạp.

4. KẾT LUẬN

Các phương pháp được đề xuất cung cấp một giải pháp thay thế hiệu quả cho gLoG tiêu chuẩn bằng cách ưu tiên các hướng và thang đo liên quan thông qua các phép tính nhẹ. Biến thể dựa trên PCA duy trì tính nhất quán cấu trúc toàn cục; trong khi phương pháp dựa trên gradient tăng cường khả năng thích nghi cục bộ, phù hợp với các cảnh có hình học phức tạp. Kết quả thực nghiệm trên hai bộ dữ liệu xác nhận tính ổn định và khả năng ứng dụng của các phương pháp đề xuất. Trong tương lai, hướng nghiên cứu có thể mở rộng sang tích hợp với các mô hình học máy hoặc triển khai trong các hệ thống thời gian thực.

TÀI LIỆU THAM KHẢO

- [1] A. M. Mendonca and A. Campilho, "Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction," *IEEE Transactions on Medical Imaging*, 25(9):1200-1213, 2006, DOI:10.1109/TMI.2006.879955

- [2] H. Kong, H. C. Akakin, and S. E. Sarma, "A generalized laplacian of gaussian filter for blob detection and its applications," *IEEE Transactions on Cybernetics*, 43(6):179-1733, 2013, DOI:10.1109/TSMCB.2012.2228639
- [3] R. Reisenhofer and E. J. King, "Edge, ridge, and blob detection with symmetric molecules," *SIAM Journal on Imaging Sciences*, 12(4):1585-1626, 2019, DOI:10.1137/19M1240861
- [4] J. Chen, L. Y. Duan, F. Gao, J. Cai, A. C. Kot, and T. Huang, "A low complexity interest point detector," *IEEE Signal Processing Letters*, 22(2):172-176, 2014, DOI:10.1109/LSP.2014.2354237
- [5] P. Shivakumara, T. Q. Phan, and C. L. Tan, "A laplacian approach to multi-oriented text detection in video," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(2):412-419, 2010, DOI:10.1109/TPAMI.2010.166
- [6] Z. Miao, X. Jiang, and K. H. Yap, "Contrast invariant interest point detection by zero-norm log filter," *IEEE Transactions on Image Processing*, 25(1):331-342, 2015, DOI:10.1109/TIP.2015.2470598
- [7] H. Xu, C. Lu, R. Berendt, and N. Jha, "Automatic nuclei detection based on generalized laplacian of gaussian filters," *IEEE Journal of Biomedical and Health Informatics*, 21(3):826-837, 2016, DOI:10.1109/JBHI.2016.2544245
- [8] V. Majanga and S. Viriri, "Automatic blob detection for dental caries," *Applied Sciences*, 11(19):9232, 2021, DOI:10.3390/app11199232
- [9] G. Wang, C. Lopez-Molina, and B. De Baets, "Blob reconstruction using unilateral second order gaussian kernels with application to high-iso long-exposure image denoising," in *Proc. IEEE Int. Conf. Comput. Vis. (ICCV)*, Venice, Italy, 2017, pp. 4817-4825, DOI:10.1109/ICCV.2017.516
- [10] G. Wang, C. Lopez-Molina, and B. De Baets, "Automated blob detection using iterative laplacian of gaussian filtering and unilateral second-order gaussian kernels," *Digital Signal Processing*, vol. 96, pp. 102592, 2020, DOI:10.1016/j.dsp.2019.102592
- [11] C. Nguyen Dinh, M. Delalandre, D. Conte, and T. A. Pham, "Fast rt-log operator for scene text detection," *Journal of Real-Time Image Processing*, 18(1)19-36, 2021, DOI:10.1007/s11554-020-00942-7
- [12] V. L. Petrović, "A method for real-time memory efficient implementation of blob detection in large images," *Serbian Journal of Electrical Engineering*, 14(1):67-84, 2017, DOI:10.2298/SJEE1701067P
- [13] R. Acevedo-Avila, M. Gonzalez-Mendoza, and A. Garcia-Garcia, "A linked list-based algorithm for blob detection on embedded vision-based sensors," *Sensors*, 16(6):782, 2016, DOI:10.3390/s16060782
- [14] X. Descombes, "Multiple objects detection in biological images using a marked point process framework," *Methods*, vol. 115, pp. 2-8, 2017, DOI:10.1016/j.ymeth.2016.09.009

- [15] K. Esbensen and P. Geladi, "Principal component analysis: Concept, geometrical interpretation, mathematical background, algorithms, history, practice," in *Comprehensive Chemometrics: Chemical and Biochemical Data Analysis*, vol. 2, S. D. Brown, R. Tauler, and B. Walczak, Eds. Amsterdam, Netherlands: Elsevier, 2020, pp. 3-15, DOI:10.1016/b978-0-444-64165-6.05002-3
- [16] T. Lindeberg, "Feature detection with automatic scale selection," *International Journal of Computer Vision*, vol. 30, pp. 79-116, 1998, DOI:10.1023/A:1008045108935
- [17] Y. Cho, D. Kim, S. Saeed, M. U. Kakli, S.-H. Jung, and J. Seo, "Keypoint detection using higher order laplacian of gaussian," *IEEE Access*, vol. 8, pp. 10416–10425, 2020, DOI:10.1109/ACCESS.2020.2965169
- [18] K. Mikolajczyk et al., "A comparison of affine region detectors," *International Journal of Computer Vision*, vol. 65, pp. 43-72, 2005, DOI:10.1007/s11263-005-3848-x
- [19] X. Jiang, B. Mandal, and A. Kot, "Eigenfeature regularization and extraction in face recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(3):383-394, 2008, DOI:10.1109/TPAMI.2007.70708

Tuyên bố về xung đột lợi ích: Các tác giả tuyên bố không có xung đột lợi ích.

Thông tin tài trợ: Nghiên cứu này không nhận được tài trợ từ bên ngoài.