

# Phương pháp tiếp cận quần thể lựa chọn đặc trưng dựa trên xếp hạng đặc trưng cho phân loại hình ảnh hạt lúa giống

## A combination of feature ranking approaches for rice images classification

Lâm Trần Tuấn Dzi<sup>1\*</sup>

<sup>1</sup>Trường Chính trị Sóc Trăng, Sóc Trăng Việt Nam

\*Tác giả liên hệ, Email: tdzi2005@gmail.com

### THÔNG TIN

DOI:10.46223/HCMCOUJS.tech.vi.17.1.2234.2022

Ngày nhận: 07/04/2022

Ngày nhận lại: 14/04/2022

Duyệt đăng: 21/04/2022

*Từ khóa:*

GIST; HOG; LBP; lựa chọn đặc trưng; lúa giống; lựa chọn đặc trưng; quần thể xếp hạng đặc trưng

*Keywords:*

GIST; HOG; LBP; feature selection; rice seed image; ensemble feature selection; feature ranking

### TÓM TẮT

Trong nông nghiệp thông minh, người ta sử dụng thị giác máy tính để nhận dạng hạt lúa giống thay vì cần các chuyên gia thực hiện. Trong bài báo này, chúng tôi đã xem xét ba loại mô tả đặc trưng, như Local Binary Patterns (LBP), Histogram of Oriented Gradients (HOG) và Gradient Domain Image Stitching (GIST) để mô tả hình ảnh hạt lúa giống. Tuy nhiên, cách tiếp cận này làm nảy sinh vấn đề về hiện tượng số chiều và cần phải lựa chọn các đặc trưng liên quan để có một mô hình biểu diễn nhỏ gọn và tốt hơn. Một quần thể lựa chọn đặc trưng mới được đề xuất để đại diện cho tất cả các thông tin hữu ích được thu thập từ các phương pháp lựa chọn đặc trưng đơn lẻ khác nhau. Các kết quả thử nghiệm trên phương pháp đề xuất của chúng tôi đã cho thấy được hiệu quả về độ chính xác.

### ABSTRACT

In smart agriculture, computer vision is applied to identify rice seeds instead of being investigated by experts. In this paper, we considered three types of feature descriptors, such as Local Binary Patterns (LBP), Histogram of Oriented Gradients (HOG) and Gradient Domain Image Stitching (GIST) to characterize rice seed images. However, this method raises the problem of dimensional phenomena and it is necessary to select the relevant features to have a compact and better representation. A new combination of feature selection methods is proposed to represent all the relevant information from different single feature selection methods. The experimental results show that our approach outperforms the results from the state-of-the-art.

### 1. Giới thiệu

Lúa-gạo là nguồn lương thực quan trọng nhất của người dân ở nhiều nước bao gồm Châu Á, Châu Phi, Mỹ La tinh và Trung Đông. Các sản phẩm làm từ lúa-gạo và các sản phẩm gián tiếp được làm từ lúa gạo, là những sản phẩm thiết yếu trong các bữa ăn của hầu hết con người

trên thế giới. Ngày nay, nhiều giống lúa được tạo ra với chất lượng đa dạng và năng suất. Các loại lúa giống khác nhau có thể được trộn lẫn trong quá trình trồng trọt và buôn bán. Thực tế, chúng tôi cần phát triển một hệ thống tự động xác định hạt lúa-gạo dựa trên thị giác máy tính. Nhiều công trình khác nhau đã được đề xuất để kiểm tra tự động và kiểm tra chất lượng trong nông nghiệp (Gomes & Leta, 2012). Trong khoảng mười năm qua, một lượng lớn các mô tả hình ảnh đã được đề xuất để mô tả các đặc điểm của hình ảnh (Humeau-Heurtier, 2019). Mỗi loại đặc trưng đại diện cho dữ liệu trong một không gian riêng biệt, có ý nghĩa chính xác trong không gian đó và các thuộc tính thống kê.

Các bộ mô tả riêng khác nhau được trích xuất để tạo ra một biểu diễn hình ảnh cho nhiều chế độ quan sát, như LBP, HOG và GIST. Ta và Truong (2019) trình bày một phương pháp hợp nhất các đặc trưng được trích xuất từ ba bộ mô tả (LBP, HOG và GIST) để phân loại ảnh khuôn mặt. Sau đó, các đặc trưng được nối lại đã được áp dụng bằng phân tích tương quan chuẩn để có một biểu diễn nhỏ gọn trước khi đưa vào bộ phân loại. Nguyen và Truong (2019) đề xuất giảm các đặc trưng của Local Ternary Pattern (LTP) nhiều và không liên quan và mã hóa HOG trên các không gian màu khác nhau để phân tích khuôn mặt. Phan, Surinwarangkoon, Duong, Truong, và Meethongjan (2020) giới thiệu một nghiên cứu so sánh giữa các bộ mô tả được làm thủ công và Mạng thần kinh tích chập (CNN) để phân loại hình ảnh hạt lúa giống. Mebatsion, Paliwal, và Jayas (2013), Mirzaei, Pourahmadi, Soltani, và Sheikhzadeh (2020) hợp nhất bộ mô tả Fourier và ba đặc điểm hình học để nhận dạng hạt ngũ cốc. Duong và Truong (2019) áp dụng để trích xuất hình ảnh hạt lúa giống dựa trên các đặc trưng được mã hóa trong nhiều không gian màu bằng cách sử dụng bộ mô tả HOG. Huấn luyện đa quan sát được giới thiệu để bổ sung thông tin giữa các quan sát khác nhau. Trong khi kết hợp các bộ đặc trưng khác nhau, rõ ràng là tất cả các đặc trưng không đóng góp như nhau cho nhiệm vụ huấn luyện và một số đặc trưng có thể làm giảm hiệu suất. Do đó, các phương pháp lựa chọn đặc trưng được áp dụng như một giai đoạn tiền xử lý đối với không gian đặc trưng có số chiều cao. Nó liên quan đến việc lựa chọn các đặc trưng thích hợp và hữu ích, đồng thời tránh và bỏ qua các thông tin thừa và không liên quan (Zhang, Nie, & Wei, 2019). Một cách tiếp cận lựa chọn đặc trưng mới giữa người dạy và người học (Mirzaei & ctg., 2020) được đề xuất để tìm ra cách trình bày dữ liệu tốt nhất ở số chiều thấp.

Gần đây, quần thể lựa chọn đặc trưng đã phát triển mạnh như một cách hứa hẹn nâng cao độ mạnh mẽ và hiệu suất. Đây là quá trình thực hiện lựa chọn các đặc trưng khác nhau để tìm ra một tập hợp con các đặc trưng tối ưu. Thay vì sử dụng một cách tiếp cận lựa chọn duy nhất, một phương pháp tổng hợp kết hợp các kết quả của các cách tiếp cận khác nhau thành một tập hợp con cuối cùng của các đặc trưng. Seijo-pardo, Porto-Diaz, Bolon-Canedo, và Alonsobetanzos (2017) đề xuất kết hợp các phương pháp tiếp cận lựa chọn đặc trưng khác nhau trên dữ liệu không đồng nhất dựa trên một giá trị ngưỡng được xác định trước. Chiew, Tan, Wong, Yong, và Tiong (2019) giới thiệu một quần thể lựa chọn đặc trưng lai dựa trên hàm độ dốc phân bố lũy tích. Phương pháp này có thể xác định ước tính một cách tự động số lượng đặc trưng cắt bỏ. Drotar, Gazda, và Vokorokos (2019) đề xuất một phương pháp tiếp cận quần thể lựa chọn đặc trưng mới dựa trên các kỹ thuật bỏ phiếu khác nhau như số nhiều và đếm Borda. Đánh giá đầy đủ và chi tiết về các phương pháp quần thể lựa chọn đặc trưng được giới thiệu trong Bolon-Canedo và Alonsobetanzos (2019).

Trong bài này, chúng tôi đề xuất một quần thể lựa chọn đặc trưng mới dựa trên các bộ mô tả cho nhiều chế độ quan sát (LBP, HOG và GIST) được trích xuất từ hình ảnh hạt lúa giống. Một số phương pháp tiếp cận lựa chọn đặc trưng được nghiên cứu thêm và kết hợp để tìm ra một tập hợp con tối ưu của các đặc trưng với mục đích nâng cao hiệu suất phân loại. Trong bài báo này được tổ chức và có cấu trúc như sau. Mục 2, giới thiệu các phương pháp trích xuất đặc trưng

dựa trên ba bộ mô tả hình ảnh. Mục 3, trình bày một khung quản thể lựa chọn đặc trưng được đề xuất. Mục 4, trình bày kết quả thực nghiệm. Cuối cùng là kết luận được nêu ra trong Mục 5.

## 2. Các phương pháp trích xuất đặc trưng

Phần này đánh giá ngắn gọn ba bộ mô tả hình ảnh riêng được sử dụng trong các thử nghiệm để trích xuất đặc trưng.

### 2.1. Local Binary Pattern

$LBP_{P,R}(x_c, y_c)$  của mỗi điểm ảnh  $(x_c, y_c)$  được tính toán bằng cách so sánh giá trị xám  $g_c$  của điểm ảnh trung tâm với các giá trị xám  $\{g_i\}_{i=0}^{P-1}$  của  $P$  lân cận của nó, như sau (Ojala, Pietikainen, & Maenpaa, 2001):

$$LBP_{P,R} = \sum_{p=0}^{P-1} \omega(g_p - g_c) 2^p \quad (1)$$

Trong đó  $g_c$  là giá trị xám của trung tâm,  $g_p$  là giá trị xám của  $P, R$  là bán kính của hình tròn và  $\omega(g_p - g_c)$  được định nghĩa là:

$$\omega(g_p - g_c) = \begin{cases} 1 & \text{nếu } (g_p - g_c) > 0, \\ 0 & \text{ngược lại} \end{cases} \quad (2)$$

### 2.2. GIST

GIST lần đầu tiên được đề xuất bởi Oliva và Torralba để phân loại các đối tượng đại diện cho hình dạng của đối tượng (Oliva & Torralba, 2001). Ý tưởng chính của phương pháp này dựa trên bộ lọc Gabor:

$$h(x, y) = e^{-\frac{1}{2}(\frac{x^2}{\delta_x^2} + \frac{y^2}{\delta_y^2})} e^{-j2\pi(u_0x + v_0y)} \quad (3)$$

Với mỗi  $(\delta_x, \delta_y)$  của ảnh qua bộ lọc Gabor, chúng ta thu được tất cả các phần tử ảnh gần với màu của điểm  $(u_0x + v_0y)$ . Kết quả của vector GIST được tính toán sẽ có nhiều chiều. Để giảm kích thước, chúng tôi lấy trung bình mỗi lưới  $4 \times 4$  của các kết quả thu được. Mỗi hình ảnh cũng định cấu hình một bộ lọc Gabor với 04 thang đo và 08 hướng (định hướng), tạo ra 32 bản đồ đặc trưng  $(4 \times 8)$  có cùng kích thước.

### 2.3. Histograms of Oriented Gradient

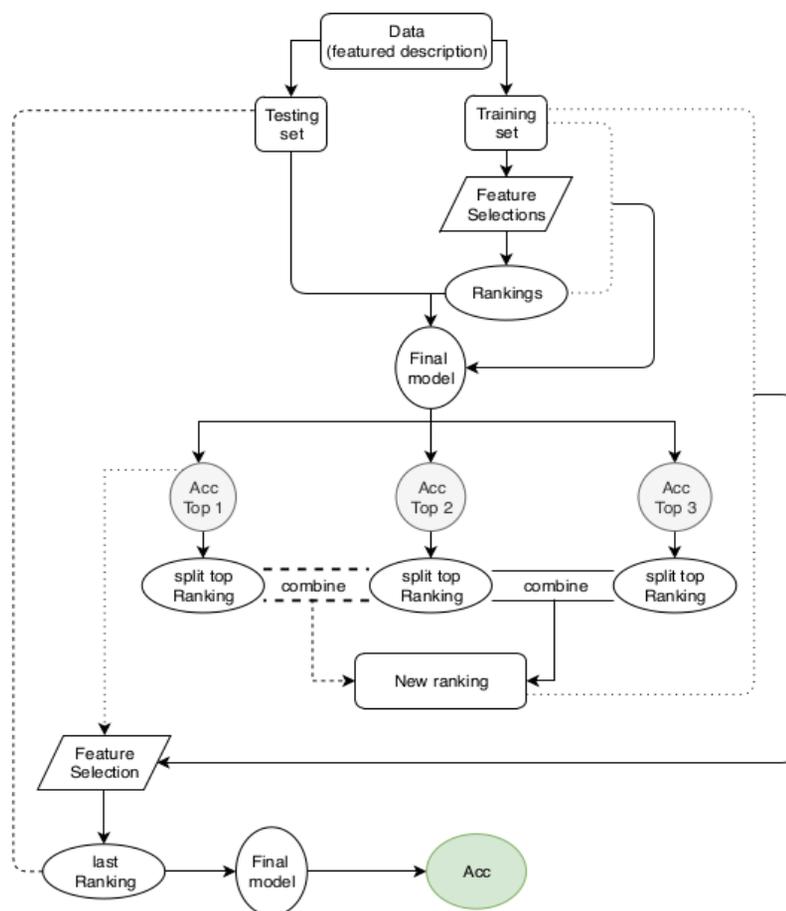
Bộ mô tả HOG được áp dụng cho các nhiệm vụ khác nhau trong thị giác máy tính (Deniz, Bueno, Salido, & De La Torre, 2011) chẳng hạn như phát hiện con người (Dalal & Triggs, 2005). Tính năng HOG được trích xuất bằng cách đếm số lần xuất hiện của định hướng gradient dựa trên góc gradient và độ lớn gradient của các mảng cục bộ của hình ảnh. Góc và độ lớn của gradient tại mỗi pixel được tính trong một bản vá  $8 \times 8$  pixel. Tiếp theo, 64 vector đặc trưng gradient được chia thành 09 góc  $0 - 180^\circ$  (mỗi góc  $20^\circ$ ). Độ lớn gradient  $T$  và góc  $K$  tại mỗi vị trí  $(k, h)$  từ ảnh  $J$  được tính như sau:

$$\Delta_k = |J(k-1, h) - J(k+1, h)| \quad (4)$$

$$\Delta_h = |J(k, h-1) - J(k, h+1)| \quad (5)$$

$$T(k, h) = \sqrt{\Delta_k^2 + \Delta_h^2} \quad (6)$$

$$K(k, h) = \tan^{-1}\left(\frac{\Delta_k}{\Delta_h}\right) \quad (7)$$



**Hình 1.** Phương pháp quần thể lựa chọn đặc trưng được đề xuất

### 3. Ensemble feature selection

Việc giảm số chiều có một số ưu điểm và tác động đến việc lưu trữ dữ liệu, khả năng tổng quát hóa và thời gian tính toán. Dựa trên sự sẵn có của thông tin được giám sát (tức là nhãn lớp), các kỹ thuật lựa chọn đặc trưng có thể được nhóm thành hai loại lớn: có giám sát và không giám sát (Benabdeslem & Hindawi, 2011). Ngoài ra, các chiến lược lựa chọn đặc trưng khác nhau được đề xuất dựa trên các quy trình đánh giá như phương pháp lọc, quy trình bao bọc và kết hợp (Guyon & Elisseeff, 2003). Các phương pháp tiếp cận kết hợp cả bộ lọc và trình bao bọc vào một cấu trúc duy nhất, để đưa ra giải pháp hiệu quả cho việc giảm số chiều (Cai, Luo, Wang, & Yang, 2018). Để nghiên cứu sự đóng góp của các phương pháp tiếp cận lựa chọn đặc trưng đối với phân loại ảnh hạt lúa, chúng tôi đề xuất áp dụng một số phương pháp lựa chọn dựa trên các ảnh được đại diện bởi các bộ mô tả đặc trưng. Trong phần sau, chúng tôi sẽ trình bày ngay các phương pháp lựa chọn đặc trưng phổ biến được áp dụng trong ngữ cảnh học có giám sát.

**LASSO** ((Least Absolute Shrinkage and Selection Operator) cho phép tính toán lựa chọn đối tượng dựa trên giả định về sự phụ thuộc tuyến tính giữa các đặc trưng đầu vào và giá trị đầu ra. Lasso giảm thiểu tổng bình phương của các phần dư khi tổng các giá trị tuyệt đối của các hệ số hồi quy nhỏ hơn một hằng số, điều này mang lại các hệ số hồi quy bằng 0 (Cai & ctg., 2018; Yamada, Jitkrittum, Sigal, Xing, & Sugiyama, 2014).

**mRMR** (Maximum Relevance and Minimum Redundancy) là tiêu chí lựa chọn đặc trưng dựa trên thông tin lẫn nhau, hoặc điểm khoảng cách /độ tương đồng để chọn các đặc trưng. Mục đích là để xử phạt mức độ liên quan của một đặc trưng bởi sự dư thừa của nó khi có các đặc trưng đã chọn khác (Zhao, Anand, & Wang, 2019).

**ReliefF** (Kononenko, 1994) được mở rộng từ Relief (Kira & Rendell, 1992) để hỗ trợ các vấn đề nhiều lớp. ReliefF dường như là một chức năng dựa trên kinh nghiệm hứa hẹn có thể vượt qua điểm không rõ ràng của các thuật toán qui nạp hiện tại. Kira và Rendell (1992) đã sử dụng ReliefF như một bộ tiền xử lý để loại bỏ các đặc trưng không liên quan từ mô tả dữ liệu trước khi cho huấn luyện. Nhìn chung ReliefF, đủ tin cậy để hướng dẫn tìm kiếm trong quá trình học tập (Kononenko, Simec, & Robniksikonja, 1997).

**CFS** (Correlation Feature Selection) chủ yếu áp dụng các phương pháp heuristic (các kỹ thuật dựa trên kinh nghiệm để giải quyết) để đánh giá ảnh hưởng của một đặc trưng tương ứng với mỗi nhóm để có được tập hợp con tối ưu của các thuộc tính.

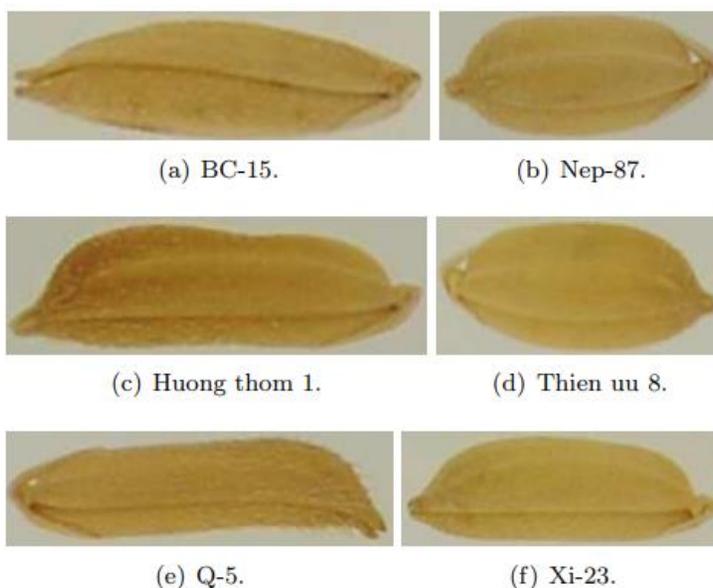
**Fisher** xác định một tập hợp con của các tính năng để khoảng cách giữa các mẫu trong các lớp khác nhau càng lớn càng tốt, trong khi khoảng cách giữa các mẫu trong cùng một lớp càng nhỏ càng tốt (Bishop, 1996). Fisher chọn các tính năng được xếp hạng hàng đầu theo điểm số của nó.

**ILFS** (Infinite Latent Feature Selection) là một kỹ thuật bao gồm ba bước như tiền xử lý, trọng số đặc trưng dựa trên biểu đồ được kết nối đầy đủ trong mỗi nút kết nối tất cả các đặc trưng. Cuối cùng, điểm số của độ dài đường dẫn được tính toán, sau đó xếp hạng tương ứng với đặc trưng (Miftahshudur, Wael, & Praludi, 2019).

Hình 1 trình bày khung lựa chọn đặc trưng được đề xuất. Mỗi phương pháp lựa chọn đặc trưng riêng lẻ có ưu và nhược điểm của nó, mục đích của đề xuất này là kết hợp các ưu điểm của các phương pháp khác nhau để tăng hiệu suất về tính chính xác. Chúng tôi đề xuất để áp dụng ba phương thức chọn đặc trưng độc lập để chọn tập hợp các đặc trưng “tốt nhất”. Sau đó, một phương thức xếp hạng mới được áp dụng cho không gian đặc trưng đã kết hợp. Điều này có thể làm tăng không gian kích thước, nhưng nó cho phép thu thập các đặc trưng có liên quan được xác định bởi các phương pháp lựa chọn khác nhau. Ý nghĩa phía sau là chọn các đặc trưng phù hợp nhất vậy nên chúng ta phải xếp thứ hạng lần cuối để loại bỏ các đặc trưng dư thừa và ồn ào.

## 4. Kết quả thực nghiệm

### 4.1. Thiết lập thực nghiệm



**Hình 2.** Bộ hình ảnh dùng để huấn luyện và thử nghiệm phương pháp đề xuất

Áp dụng các phân loại 1-NN và SVM để đánh giá hiệu suất phân loại thông qua độ chính xác. Một nửa cơ sở dữ liệu được chọn cho bộ đào tạo và nửa còn lại để thử nghiệm. Chúng tôi sử dụng phương pháp Hold-out có tỷ lệ (1/2 và 1/2) và phân chia việc đào tạo và thử nghiệm được đặt bằng cách phân chia bàn cờ. Tất cả các thực nghiệm được thực hiện và mô phỏng bởi Matlab 2019a và được thực hiện trên PC với cấu hình CPU Xeon 3.08 GHz, 64 GB RAM.

#### 4.2. Các kết quả

Bảng 1 cho thấy độ chính xác thu được bằng cách phân loại 1-NN và SVM khi không có phương pháp lựa chọn đặc trưng nào được áp dụng. Cột đầu tiên chỉ ra các đặc trưng được sử dụng để thể hiện hình ảnh. Chúng tôi sử dụng ba mô tả riêng lẻ là LBP, GIST và HOG và sự kết hợp của các đặc trưng “LBP + GIST”. Cột thứ hai cho biết số lượng các đặc trưng (hoặc số chiều) tương ứng với loại đặc trưng. Các cột thứ ba và thứ tư cho thấy độ chính xác thu được bằng cách phân loại 1-NN và SVM. Chúng tôi quan sát nhiều cách bằng cách ghép nhiều đặc trưng mang lại kết quả tốt hơn, nhưng nó làm tăng số chiều. Từ đó, cho thấy hiệu suất của phân loại SVM tốt hơn so với phân loại 1-NN với độ chính xác cao nhất là 94.7%.

**Bảng 1**

Kết quả phân loại mà không cần tiếp cận các phương pháp lựa chọn đặc trưng

Features	Dimension	1-NN	SVN
LBP	768	53.0	77.0
GIST	512	69.4	88.3
HOG	21,384	71.5	94.7
LBP + GIST	1,280	70.5	91.7

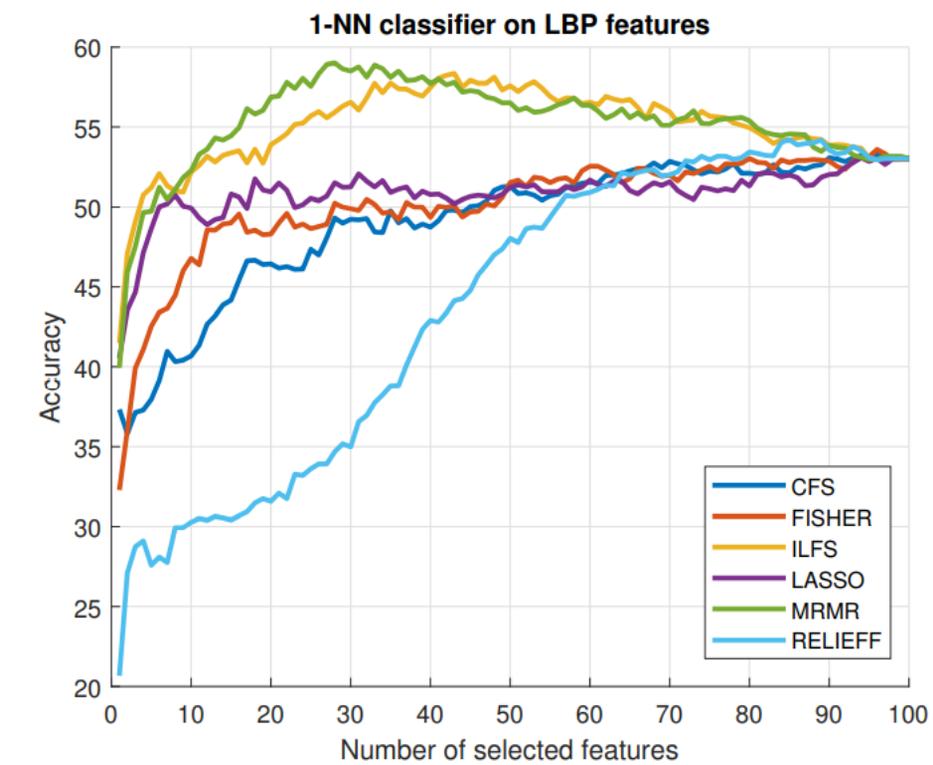
Nguồn: Kết quả xử lý từ dữ liệu điều tra

Các bảng và hình sau đây minh họa việc phân loại chi tiết bằng một hoặc nhiều cách dựa trên ba mô tả:

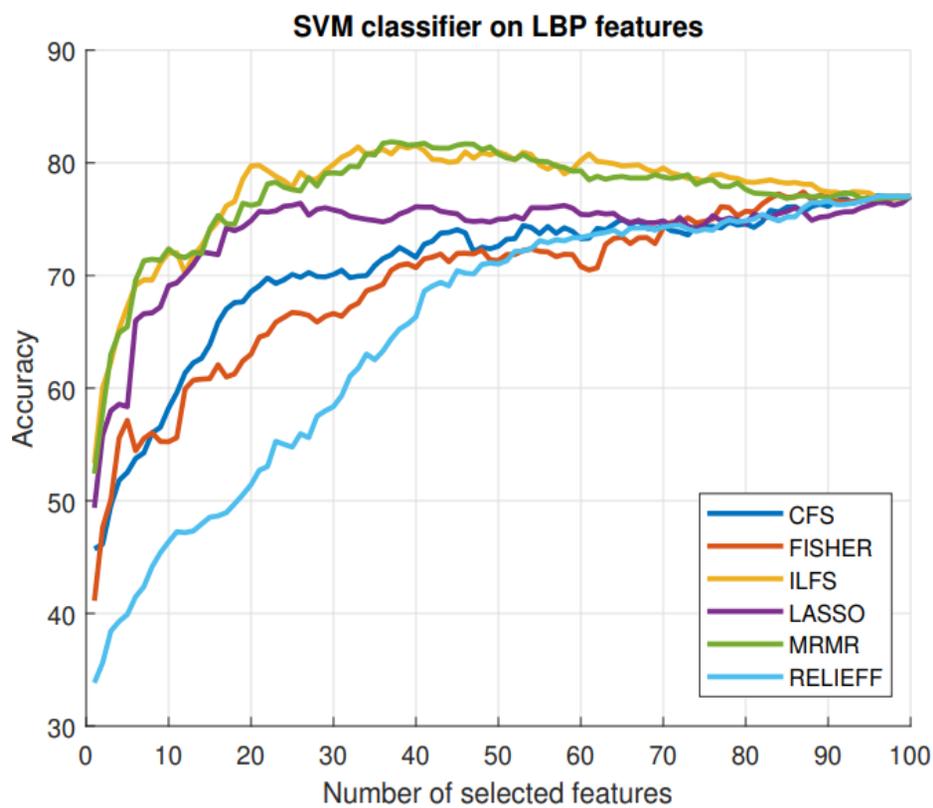
- LBP: Bảng 2, Hình 3(a) và Biểu đồ 3(b)
- GIST: Bảng 4, Hình 4(a) và Hình 4(b)
- HOG: Bảng 5, Hình 5(a) và Hình 5(b)
- LBP + GIST: Bảng 3, Hình 6(a) và Hình 6(b)

Bảng 2 và Hình 3 cho thấy hiệu suất phân loại đạt 53.0% bởi trình phân loại 1-NN trên bộ mô tả LBP. Sau khi sử dụng 06 phương pháp lựa chọn đặc trưng khác nhau, chúng tôi có được ba ứng cử viên tốt nhất với độ chính xác như sau MRMR (59.0%), ILFS (58.4%) và ReliefF (54.2%). Dựa trên phương pháp được đề xuất được minh họa trong Hình 1, tỷ lệ 85% của các đặc trưng được chọn bởi ReliefF được kết hợp với 43% đặc trưng được chọn được xác định bởi phương thức ILFS. Chúng tôi có được tập hợp con mới của các đặc trưng được tính như sau:

$$(768 \times 0.85) + (768 \times 0.43) = 983 \text{ dim.} \quad (8)$$

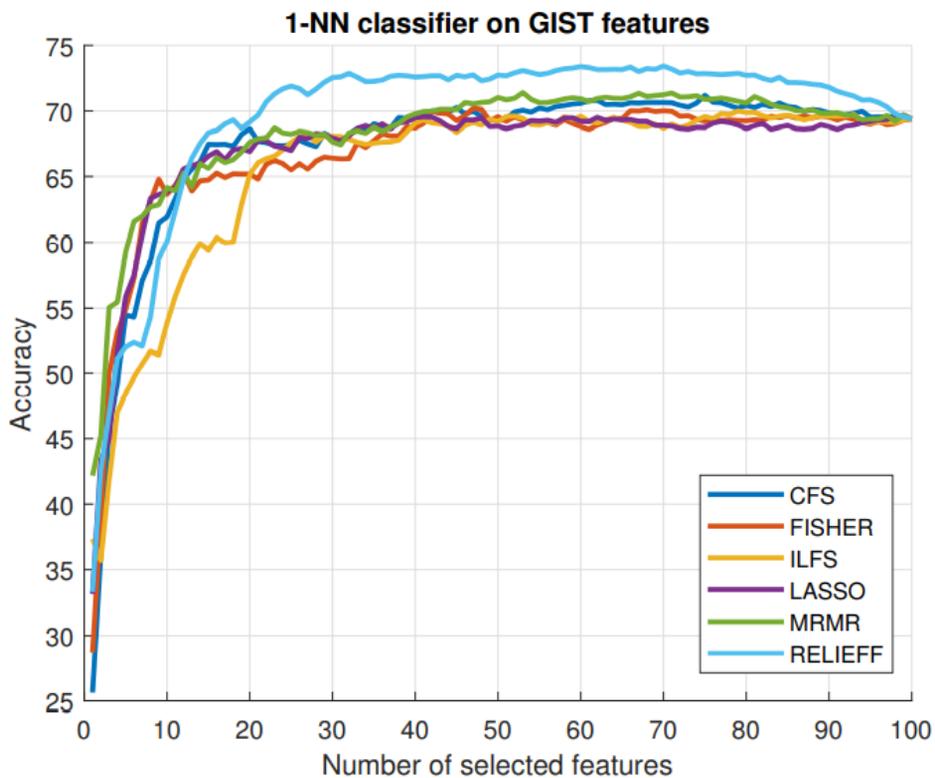


(a) 1-NN

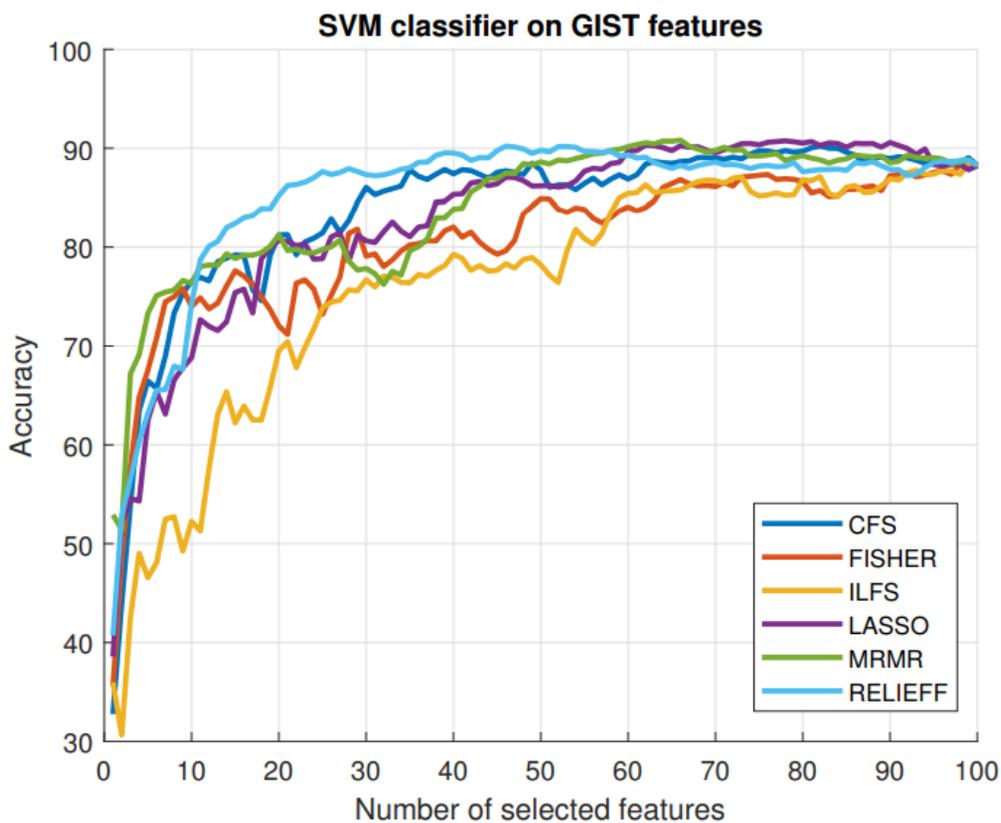


(b) SVM

**Hình 3.** Trình phân loại 1-NN (A) và SVM (B) trên các đặc trưng LBP

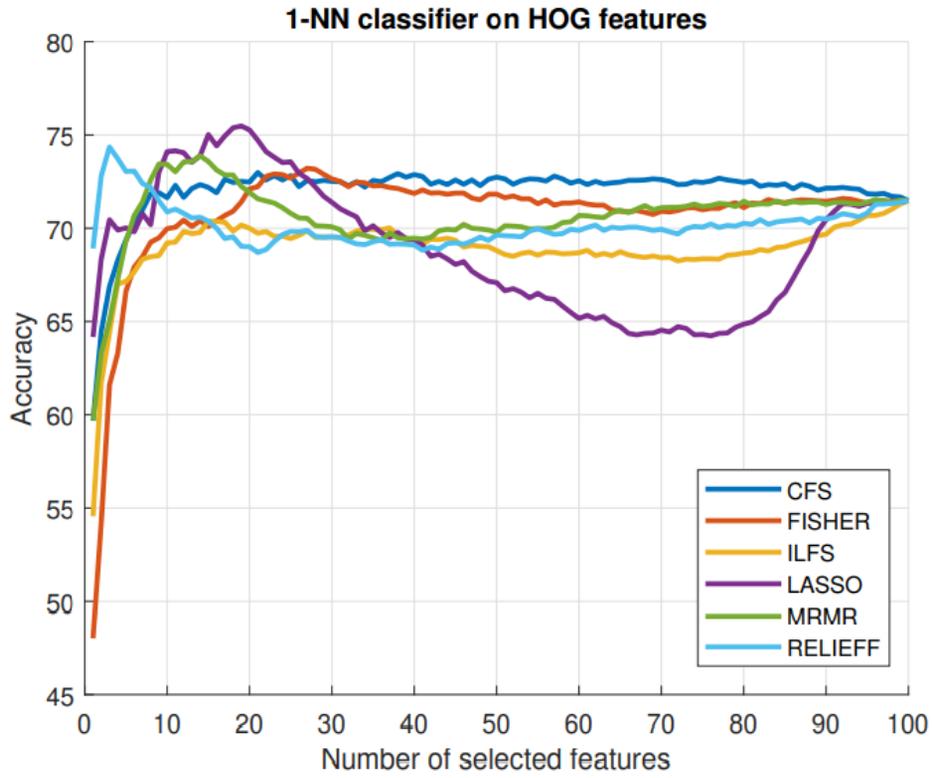


(a) 1-NN

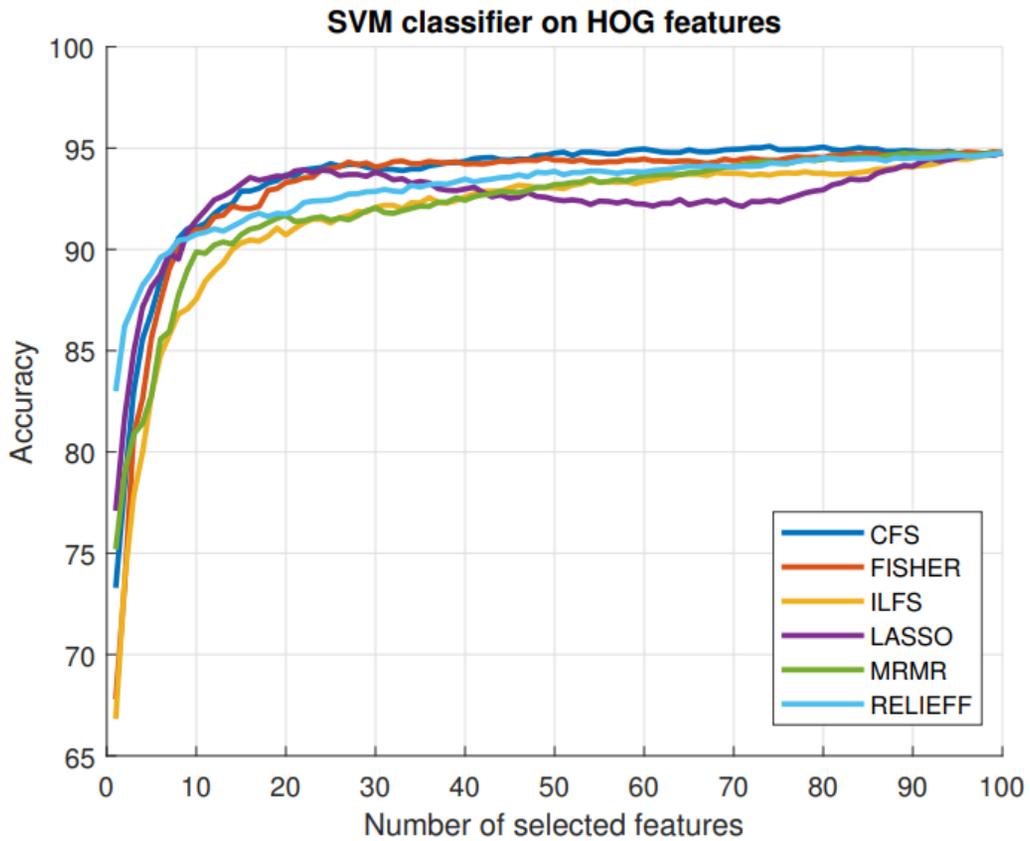


(b) SVM

**Hình 4.** Trình phân loại 1-NN (A) và SVM (B) trên các đặc trưng GIST

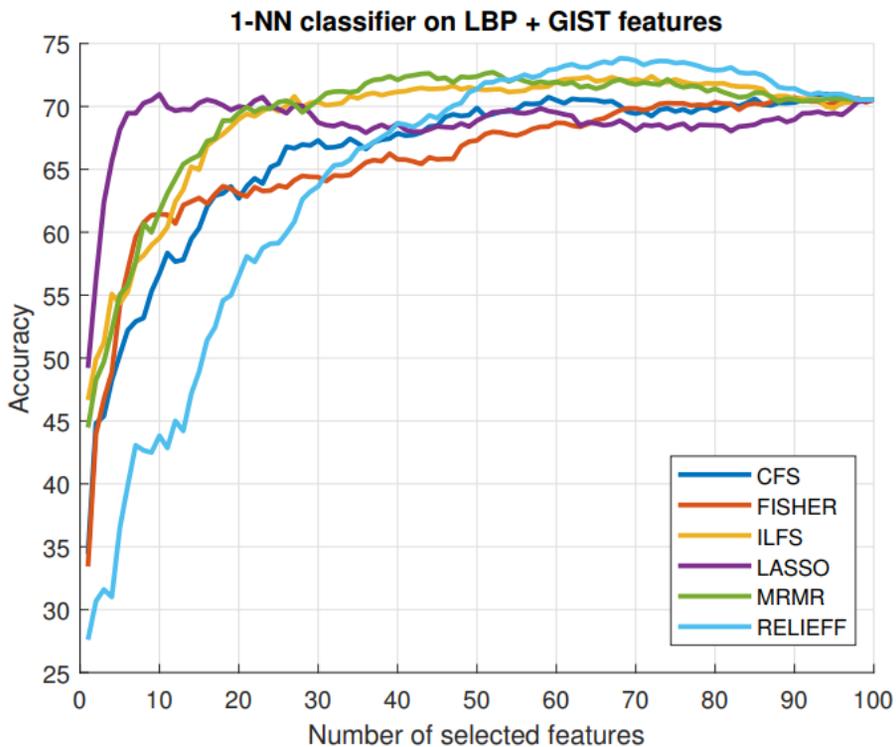


(a) 1-NN

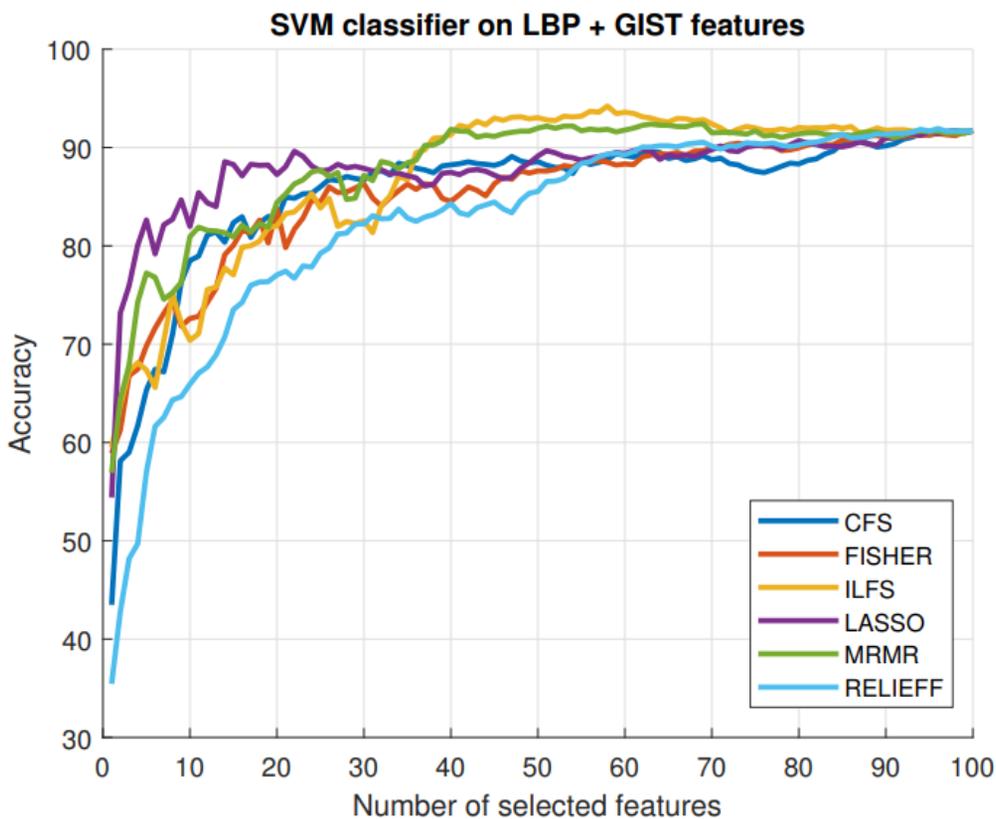


(b) SVM

**Hình 5.** Trình phân loại 1-NN (A) và SVM (B) trên các đặc trưng HOG



(a) 1-NN



(b) SVM

**Hình 6.** Trình phân loại 1-NN (A) và SVM (B) trên các đặc trưng LBP + GIST

**Bảng 2**

Đặc trưng LBP - Hiệu suất phân loại dựa trên các phương thức chọn đặc trưng khác nhau với trình phân loại 1-NN và SVM. ACC: Độ chính xác, Dim: Số chiều, id%: Tỷ lệ phần trăm của các đặc trưng được chọn,  $\geq id\%$ : Tỷ lệ phần trăm của các đặc trưng được chọn với độ chính xác từ bằng trở lên so với tất cả các đặc trưng được sử dụng

LBP	Dim	1-NN						SVM					
		ACC			Max ACC			ACC			Mã ACC		
		100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	Max	$\geq id\%$	Dim
Fisher	768	53.0	80	614	<b>53.6</b>	96	<b>737</b>	77.0	84	645	<b>77.4</b>	87	<b>668</b>
mRMR	768	53.0	11	84	<b>59.0</b>	28	<b>215</b>	77.0	22	169	<b>81.8</b>	37	<b>284</b>
ReliefF	768	53.0	74	568	<b>54.2</b>	85	<b>653</b>	77.0	97	745	<b>77.0</b>	97	<b>745</b>
Ilfs	768	53.0	12	92	<b>58.4</b>	43	<b>330</b>	77.0	19	146	<b>81.6</b>	40	<b>307</b>
Cfs	768	53.0	90	691	<b>52.3</b>	96	<b>737</b>	77.0	96	737	<b>77.1</b>	96	<b>737</b>
Lasso	768	53.0	94	722	<b>53.1</b>	94	<b>722</b>	77.0	100	768	<b>77.0</b>	100	<b>768</b>

Nguồn: Kết quả xử lý từ dữ liệu điều tra

**Bảng 3**

Đặc trưng LBP + GIST - Hiệu suất phân loại dựa trên các phương thức chọn đặc trưng khác nhau với trình phân loại 1-NN và SVM. ACC: Độ chính xác, Dim: Số chiều, id%: Tỷ lệ phần trăm của các đặc trưng được chọn,  $\geq id\%$ : Tỷ lệ phần trăm của các đặc trưng được chọn với độ chính xác từ bằng trở lên so với tất cả các đặc trưng được sử dụng

LBP + GIST	Dim	1-NN						SVM					
		ACC			Max ACC			ACC			Mã ACC		
		100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	Max	$\geq id\%$	Dim
Fisher	1,280	70.5	88	1,126	<b>70.7</b>	88	<b>1,126</b>	91.7	100	1,280	91.7	100	1,280
mRMR	1,280	70.5	31	397	<b>72.7</b>	52	<b>666</b>	91.7	40	512	<b>92.4</b>	69	<b>883</b>
ReliefF	1,280	70.5	49	627	<b>73.8</b>	68	<b>870</b>	91.7	94	1,203	<b>91.9</b>	96	<b>1,229</b>
Ilfs	1,280	70.5	27	346	<b>72.4</b>	72	<b>922</b>	91.7	41	525	<b>94.2</b>	58	<b>742</b>
Cfs	1,280	70.5	59	755	<b>70.9</b>	94	<b>1,203</b>	91.7	98	1,254	91.7	98	1,254
Lasso	1,280	70.5	10	128	<b>70.9</b>	10	<b>128</b>	91.7	98	1,254	91.7	98	1,254

Nguồn: Kết quả xử lý từ dữ liệu điều tra

**Bảng 4**

Đặc trưng GIST - Hiệu suất phân loại dựa trên các phương thức chọn đặc trưng khác nhau với trình phân loại 1-NN và SVM. ACC: Độ chính xác, Dim: Số chiều, id%: Tỷ lệ phần trăm của các đặc trưng được chọn,  $\geq id\%$ : Tỷ lệ phần trăm của các đặc trưng được chọn với độ chính xác từ bằng trở lên so với tất cả các đặc trưng được sử dụng

GIST	Dim	1-NN						SVM					
		ACC			Max ACC			ACC			Mã ACC		
		100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	Max	$\geq id\%$	Dim
Fisher	512	69.4	42	215	<b>70.2</b>	47	<b>241</b>	88.3	98	502	<b>88.3</b>	98	<b>502</b>
mRMR	512	69.4	39	200	<b>71.4</b>	53	<b>271</b>	88.3	48	246	<b>90.8</b>	66	<b>338</b>

GIST	Dim	1-NN						SVM					
		ACC			Max ACC			ACC			Mã ACC		
		100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	Max	$\geq id\%$	Dim
ReliefF	512	69.4	21	108	<b>73.4</b>	70	<b>358</b>	88.3	36	184	<b>90.2</b>	46	<b>236</b>
Ilfs	512	69.4	49	251	<b>70.0</b>	79	<b>404</b>	88.3	99	507	<b>88.4</b>	99	<b>507</b>
Cfs	512	69.4	38	195	<b>71.2</b>	75	<b>384</b>	88.3	49	251	<b>90.2</b>	82	<b>420</b>
Lasso	512	69.4	40	205	<b>69.7</b>	99	<b>507</b>	88.3	58	297	<b>90.6</b>	78	<b>399</b>

Nguồn: Kết quả xử lý từ dữ liệu điều tra

### Bảng 5

Đặc trưng HOG - Hiệu suất phân loại dựa trên các phương thức chọn đặc trưng khác nhau với trình phân loại 1-NN và SVM. ACC: Độ chính xác, Dim: Số chiều, id%: Tỷ lệ phần trăm của các đặc trưng được chọn,  $\geq id\%$ : Tỷ lệ phần trăm của các đặc trưng được chọn với độ chính xác từ bằng trở lên so với tất cả các đặc trưng được sử dụng

GIST	Dim	1-NN						SVM					
		ACC			Max ACC			ACC			Mã ACC		
		100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	100%	$\geq id\%$	Dim	Max	$\geq id\%$	Dim
Fisher	21,384	71.5	20	4,277	<b>73.2</b>	27	<b>5,774</b>	94.8	85	18,176	<b>94.8</b>	99	<b>21,170</b>
mRMR	21,384	71.5	8	1,711	<b>73.9</b>	14	<b>2,994</b>	94.8	100	21,384	<b>94.8</b>	100	<b>21,384</b>
ReliefF	21,384	71.5	2	428	<b>74.4</b>	3	<b>642</b>	94.8	100	21,384	<b>94.8</b>	100	<b>21,384</b>
Ilfs	21,384	71.5	100	21,384	<b>71.5</b>	100	<b>21,384</b>	94.8	100	21,384	<b>94.8</b>	100	<b>21,384</b>
Cfs	21,384	71.5	8	1,711	<b>72.9</b>	21	<b>4,491</b>	94.8	51	10,906	<b>95.1</b>	74	<b>15,824</b>
Lasso	21,384	71.5	9	1,925	<b>75.5</b>	19	<b>4,063</b>	94.8	100	21,384	<b>94.8</b>	100	<b>21,384</b>

Nguồn: Kết quả xử lý từ dữ liệu điều tra

### Bảng 6

Các kết quả phân loại thu được bằng phương pháp lựa chọn đặc trưng đơn và quần thể lựa chọn đặc trưng

Classifier	Dataset		Single FS		Multi FS				
	Description	Dim full	ACC Without FS (%)	ACC max of FSs (%)	Acc (%)	Dim	Pair	Dim full	Ranker
1-NN	LBP	768	53.0	59.0	60.0	432	Ilfs ReliefF	983	mRMR
	GIST	512	69.4	73.0	74.6	261	mRMR Cfs	655	mRMR
	HOG	21,384	71.5	75.5	79.3	3,416	mRMR ReliefF	3,635	mRMR
	LBP + GIST	1,280	70.5	73.8	77.1	698	mRMR Ilfs	1,587	mRMR
SVM	LBP	768	77.0	81.8	82.4	544	mRMR Ilfs	591	mRMR
	GIST	512	88.3	90.8	91.4	1,076	mRMR Ilfs Fisher	1,346	mRMR
	LBP + GIST	1,280	91.7	94.2	94.0	1,246	mRMR ReliefF	2,112	Ilfs

Nguồn: Kết quả xử lý từ dữ liệu điều tra

Vì vậy, chúng tôi kết hợp hai tập hợp con tốt nhất của các đặc trưng được bởi ReliefF và ILFS với không gian đặc trưng có số chiều là 983. Tiếp theo, vector này được áp dụng lại bằng phương pháp MRMR và phân loại 1-NN để loại bỏ các đặc trưng không liên quan. Bảng 6 trình bày sự so sánh của một không gian lựa chọn đặc trưng và quần thể lựa chọn đặc trưng. Chúng tôi quan sát rằng phương pháp quần thể lựa chọn đặc trưng vượt trội hơn phương pháp lựa chọn đặc trưng duy nhất cho tất cả các loại đặc trưng với trình phân loại 1-NN. Ví dụ: chúng tôi tăng 1% độ chính xác so với một phương thức lựa chọn đặc trưng duy nhất và tăng 7% so với phân loại khi không có phương thức lựa chọn nào được áp dụng. Kết quả thí nghiệm tương tự thu được bằng cách sử dụng phân loại SVM trên một phương pháp lựa chọn đặc trưng. Về số chiều, chúng tôi tăng không gian đặc trưng bằng cách kết hợp và chọn các đặc trưng hữu ích trong việc hình thành các phương thức lựa chọn đặc trưng riêng lẻ khác nhau. So với các mục tiêu dựa trên độ chính xác hoặc thời gian tính toán, một cách tiếp cận thích hợp cho nhu cầu tương ứng sẽ được chọn.

## 5. Kết luận

Trong bài viết này, chúng tôi đã giới thiệu một cách tiếp cận quần thể lựa chọn đặc trưng mới bằng cách kết hợp nhiều phương pháp lựa chọn đặc trưng riêng lẻ. Một tập hợp con của các đặc trưng đầu tiên được chọn bằng phương pháp lựa chọn đặc trưng và phân loại liên quan. Nhiều tập hợp con sau đó được kết hợp để tạo thành một không gian đặc trưng cuối cùng và sau đó áp dụng lại phương pháp lựa chọn tính năng để loại bỏ các tính năng nhiễu và dư thừa. Các kết quả thực nghiệm trên bộ dữ liệu VNRICE cho phân loại hình ảnh hạt giống lúa đã cho thấy hiệu quả của cách tiếp cận được đề xuất.

Tương lai của cách làm này là xác định một phương pháp lựa chọn thích hợp dựa trên mỗi thuộc tính và sử dụng các chiến lược khác nhau để kết hợp vector đặc trưng được trả về từ một phương pháp lựa chọn đặc trưng năng suất duy nhất.

## Tài liệu tham khảo

- Benabdeslem, K., & Hindawi, M. (2011). Constrained Laplacian score for semi-supervised feature selection. In *Joint European conference on machine learning and knowledge discovery in databases* (pp. 204-218). Berlin, Germany: Springer. doi:10.1007/978-3-642-23780-5\_23
- Bishop, C. M. (1996). *Neural networks for pattern recognition* (1st ed.). Oxford, UK: Oxford University Press.
- Bolon-Canedo, V., & Alonsobetanzos, A. (2019). Ensembles for feature selection: A review and future trends. *Information Fusion*, 52(1), 1-12. doi:10.1016/j.inffus.2018.11.008
- Cai, J., Luo, J., Wang, S., & Yang, S. (2018). Feature selection in machine learning: A new perspective. *Neurocomputing*, 300(1), 70-79. doi:10.1016/j.neucom.2017.11.077
- Chiew, K. L., Tan, C. L., Wong, K., Yong, K. S. C., & Tiong, W. K. (2019). A new hybrid ensemble feature selection framework for machine learning-based phishing detection system. *Information Sciences*, 484(1), 153-166. doi:10.1016/j.ins.2019.01.064
- Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. In *2005 IEEE computer society conference on Computer Vision and Pattern Recognition (CVPR '05)* (pp. 886-893). San Diego, CA: IEEE. doi:10.1109/CVPR.2005.177
- Deniz, O., Bueno, G., Salido, J., & De La Torre, F. (2011). Face recognition using histograms of oriented gradients. *Pattern Recognition Letters*, 32(12), 1598-1603. doi:10.1016/j.patrec.2011.01.004

- Drotar, P., Gazda, M., & Vokorokos, L. (2019). Ensemble feature selection using election methods and ranker clustering. *Information Sciences*, 480(1), 365-380. doi:10.1016/j.ins.2018.12.033
- Duong, T. H., & Truong, V. H. (2019). Dimensionality reduction based on feature selection for rice varieties recognition. In *4th International Conference on Information Technology (InCIT)* (pp. 199-202). Bangkok, Thailand: IEEE. doi:10.1109/INCIT.2019.8912121
- Gomes, J. F. S., & Leta, F. R. (2012). Applications of computer vision techniques in the agriculture and food industry: A review. *European Food Research and Technology*, 235(6), 989-1000. doi:10.1007/s00217-012-1844-2
- Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3(7), 1157-1182. doi:10.5555/944919.944968
- Humeau-Heurtier, A. (2019). Texture feature extraction methods: A survey. *IEEE Access*, 7(1), 8975-9000. doi:10.1109/ACCESS.2018.2890743
- Kira, K., & Rendell, L. A. (1992). A practical approach to feature selection. In *Machine learning proceedings 1992* (pp. 249-256). Aberdeen, Scotland: Elsevier. doi:10.1016/B978-1-55860-247-2.50037-1
- Kononenko, I. (1994). Estimating attributes: Analysis and extensions of ReliefF. In *European Conference on machine learning* (pp. 171-182). Berlin, Germany: Springer. doi:10.1007/3-540-57868-4\_57
- Kononenko, I., Simec, E., & Robniksikonja, M. (1997). Overcoming the Myopia of inductive learning algorithms with ReliefF. *Applied Intelligence*, 7(1), 39-55. doi:10.1023/A:1008280620621
- Mebatsion, H. K., Paliwal, J., & Jayas, D. S. (2013). Automatic classification of nontouching cereal grains in digital images using limited morphological and color features. *Computers and Electronics in Agriculture*, 90(1), 99-105. doi:10.1016/j.compag.2012.09.007
- Miftahushudur, T., Wael, C. B. A., & Praludi, T. (2019). Infinite latent feature selection technique for hyperspectral image classification. *Jurnal Elektronika dan Telekomunikasi*, 19(1), 32-37. doi:10.14203/jet.v19.32-37
- Mirzaei, A., Pourahmadi, V., Soltani, M., & Sheikhzadeh, H. (2020). Deep feature selection using a teacher-student network. *Neurocomputing*, 383(1), 396-408. doi:10.1016/j.neucom.2019.12.017
- Nguyen, T. V., & Truong, V. H. (2019). Kinship verification based on local binary pattern features coding in different color space. In *26th International Conference on Telecommunications (ICT)* (pp. 376-380). Hanoi, Vietnam: IEEE. doi:10.1109/ICT.2019.8798781
- Ojala, T., Pietikainen, M., & Maenpaa, T. (2001). A generalized local binary pattern operator for multiresolution gray scale and rotation invariant texture classification. In *International conference on advances in pattern recognition* (pp. 399-408). Rio de Janeiro, Brazil: Springer. doi:10.1007/3-540-44732-6\_41
- Oliva, A., & Torralba, A. (2001). Modeling the shape of the scene: A holistic representation of the spatial envelope. *International Journal of Computer Vision*, 42(3), 145-175. doi:10.1023/A:1011139631724
- Phan, D. H. V., Surinwarangkoon, T., Duong, T. H., Truong, V. H., & Meethongjan, K. (2020). A comparative study of rice variety classification based on deep learning and hand-crafted features. *ECTI Transactions on Computer and Information Technology (ECTI-CIT)*, 14(1), 1-10. doi:10.37936/ecticit.2020141.204170

- Seijo-Pardo, B., Porto-Diaz, I., Bolon-Canedo, V., & Alonsobetanzos, A. (2017). Ensemble feature selection: Homogeneous and heterogeneous approaches. *Knowledge-Based Systems*, 118(1), 124-139. doi:10.1016/j.knosys.2016.11.017
- Ta, H. M. N., & Truong, V. H. (2019). Feature fusion by using LBP, HOG, GIST descriptors and canonical correlation analysis for face recognition. In *2019 26th International Conference on Telecommunications (ICT)* (pp. 371-375). Hanoi, Vietnam: IEEE. doi:10.1109/ICT.2019.8798816
- Yamada, M., Jitkrittum, W., Sigal, L., Xing, E. P., & Sugiyama, M. (2014). High dimensional feature selection by feature-wise kernelized lasso. *Neural Computation*, 26(1), 185-207. doi:10.1162/NECO\_a\_00537
- Zhang, R., Nie, F., Li, X., & Wei, X. (2019). Feature selection with multi-view data: A survey. *Information Fusion*, 50(1), 158-167. doi:10.1016/j.inffus.2018.11.019
- Zhao, Z., Anand, R., & Wang, M. (2019). Maximum relevance and minimum redundancy feature selection methods for a marketing machine learning platform. In *IEEE International Conference on Data Science and Advanced Analytics (DSAA)* (pp. 442-452). Washington, D.C.: IEEE. doi:10.1109/DSAA.2019.00059

