

## TỰ ĐỘNG PHÁT HIỆN ĂN MÒN TRÊN BỀ MẶT ĐƯỜNG ỐNG DẪN KHÍ SỬ DỤNG TRÍ TUỆ NHÂN TẠO

Lê Huy Thuởng<sup>1</sup>, Nguyễn Văn Ngo<sup>1</sup>, Nguyễn Tuấn Linh<sup>2</sup>

<sup>1</sup>Công ty TNHH Cortek

<sup>2</sup>Học viện Công nghệ Bưu chính Viễn thông

Email: [thuonglehuy@cortek.vn](mailto:thuonglehuy@cortek.vn)

<https://doi.org/10.47800/PVJ.2022.02-03>

### Tóm tắt

Bài báo trình bày phương pháp phát hiện ăn mòn đường ống dẫn khí bằng cách sử dụng trí tuệ nhân tạo để phân tích các hình ảnh trực quan, gồm 3 bước: tiền xử lý ảnh đầu vào; phân đoạn và trích chọn các đặc trưng biểu đồ tần suất màu và đặc trưng kết cấu; đề xuất sử dụng mô hình Markov ẩn được huấn luyện từ các vector đặc trưng có khả năng tự động phân tích các hình ảnh chụp từ camera và nhận dạng các vùng bị ăn mòn của đường ống dẫn khí. Thử nghiệm ban đầu trên tập dữ liệu hơn 5.000 ảnh chụp các đường ống dẫn khí cho thấy phương pháp đề xuất cho kết quả chính xác trên 90%.

**Từ khóa:** Ăn mòn, đường ống dẫn khí, mô hình Markov ẩn, trí tuệ nhân tạo.

### Giới thiệu

Ăn mòn là dạng hư hỏng vật liệu, thường xuyên xảy ra đối với các bộ phận và cấu kiện thiết bị kim loại, trong đó có đường ống dẫn khí. Theo nghiên cứu của Koch và cộng sự [1] chi phí ăn mòn hàng năm trên toàn cầu ước tính 2,5 nghìn tỷ USD. Những con số này chỉ thể hiện các chi phí trực tiếp như đóng cửa hoặc tai nạn buộc phải đóng cửa; không bao gồm chi phí khắc phục các hậu quả về môi trường. Cũng theo nghiên cứu [1], chiến lược phát hiện ăn mòn kịp thời, thích hợp có thể làm giảm chi phí này từ 18 - 35%. Việc phát hiện sớm sự xuống cấp của kết cấu kim loại trong đó có đường ống dẫn khí trước khi bị hỏng hóc không chỉ mang lại lợi ích kinh tế mà còn giúp ngăn chặn các sự cố ảnh hưởng đến con người và môi trường. Môi trường gây ăn mòn cho đường ống dẫn khí gồm môi trường bên trong và bên ngoài. Quá trình ăn mòn bên trong đường ống phụ thuộc vào bản chất vật liệu cấu tạo của ống, điều kiện vận hành và các tạp chất ăn mòn. Đối với ống nổi, môi trường ăn mòn bên ngoài ống có thể là không khí, độ ẩm. Tại các khu vực khác nhau, tính xâm thực của đất và nước sẽ khác nhau do nồng độ muối, độ ẩm, độ dẫn điện khác nhau, dẫn đến các dạng ăn mòn

phổ biến đối với đường ống dẫn khí bao gồm: ăn mòn đều, ăn mòn cục bộ, nứt do tác động môi trường và bị phá hủy do dòng chảy. Trong phạm vi nghiên cứu này, nhóm tác giả chỉ tập trung vào phát hiện ăn mòn do tác nhân môi trường bên ngoài đường ống dẫn khí đối với các đoạn đường ống đi nổi trên mặt đất.

Trước đây, kỹ thuật viên thường kiểm tra các đường ống dẫn khí bằng cách quan sát bằng mắt thường và tiếp theo là đo đạc. Cách tiếp cận này phát hiện ăn mòn bề mặt và mô tả sơ bộ về tình trạng của đường ống và sự hư hỏng. Phương pháp này tốn nhiều thời gian và phần lớn phụ thuộc vào kinh nghiệm và trình độ của kỹ thuật viên. Hơn thế nữa, có nhiều vị trí khó tiếp cận hoặc hoàn toàn không thể tiếp cận được vì lý do an toàn, ví dụ: khí độc hoặc cản trở việc xây dựng.

Bài báo tập trung nghiên cứu phát hiện ăn mòn trên đường ống dẫn khí bằng việc xử lý hình ảnh với mô hình trí tuệ nhân tạo. Kỹ thuật này sẽ hỗ trợ sàng lọc các khu vực đường ống thông qua hình ảnh được chụp bởi máy bay không người lái đến các vị trí không thể tiếp cận mà không gây nguy hiểm cho kỹ thuật viên.

Sự xuất hiện của ăn mòn đi kèm với 2 đặc điểm trực quan chính: (i) tạo ra 1 kết cấu bề mặt thô ráp và (ii) màu sắc của các sản phẩm phụ nằm trong một phổ màu được xác định rõ ràng. Do đó, việc sử dụng phân tích kết cấu,



Ngày nhận bài: 15/3/2021. Ngày phân biên đánh giá và sửa chữa: 15/3 - 13/9/2021.

Ngày bài báo được duyệt đăng: 22/1/2022.

phân tích màu sắc hoặc kết hợp cả 2 thường được sử dụng để phát triển các thuật toán phát hiện ăn mòn. Hai tính năng này có thể được áp dụng độc lập hoặc được thực hiện trong 1 kỹ thuật nhận dạng mẫu.

Kết cấu là đặc điểm đầu tiên được sử dụng để phát hiện ăn mòn [3, 4]. Một trong những yêu cầu của phân tích kết cấu là việc chuyển đổi hình ảnh màu sang những hình ảnh có thang độ xám. Chen và cộng sự [5] phát triển kỹ thuật nhận dạng hình ảnh để đánh giá lớp phủ cầu; trích xuất các đặc điểm thống kê của ma trận đồng xuất hiện mức xám (GLCM) của các hình ảnh kỹ thuật số, là kỹ thuật được sử dụng để đo lường các giá trị đặc trưng kết cấu và áp dụng kỹ thuật phân nhóm được gọi là phân loại mẫu đa phân giải (MPC). Pidaparti và cộng sự đã phân tích dựa trên các phép biến đổi Wavelet và Fractal để phân loại các vết rỗ/nứt trong ảnh ống dẫn khí thang độ xám của các mẫu hợp kim đồng nhôm nickel [6].

Trong quá trình chuyển đổi hình ảnh màu sang thang độ xám, màu sắc là thông tin quan trọng. Marat Enikeev [3] tập trung vào thông tin màu sắc để phân biệt các khuyết tật rỉ sét so với kim loại nền. Nghiên cứu này khảo sát hình ảnh có các khuyết tật rỉ sét nhỏ và nền tương phản. Phổ của màu rỉ sét được xác định theo thống kê trong không gian màu đỏ - lục - lam (RGB). Chen và cộng sự đã nghiên cứu 14 không gian màu để tìm ra không gian màu tốt nhất để phát hiện sự ăn mòn trong các hình ảnh kỹ thuật số được chiếu sáng không đồng đều, [9] chọn  $a * b *$  làm cấu hình màu tốt nhất, đã cho thấy tính hiệu quả của phương pháp, cách tiếp cận hình elip thích ứng. Khan và cộng sự [6] đã sử dụng thông tin màu sắc để ước tính độ ăn mòn của đường ống dưới biển; phát triển thuật toán phục hồi và nâng cao hình ảnh nhằm giảm thiểu hiệu ứng làm mờ, tăng cường màu sắc và độ tương phản của hình ảnh dưới nước.


Một số nhà nghiên cứu đã sử dụng cả đặc điểm kết cấu và màu sắc để phát hiện ăn mòn. Luca Petricca và cộng sự [8] đã sử dụng phương pháp học chuyên sâu (deep learning) dựa trên ngôn ngữ lập trình Python (ngôn ngữ thông dụng cho phát triển các mô hình học máy) để

phát hiện ăn mòn đường ống kim loại tự động, trong đó đã huấn luyện mô hình học máy với hơn 3.500 hình ảnh. Tom J. Gibbons và cộng sự [9] đã áp dụng không gian màu  $L * a * b *$  và các tính năng kết cấu Gabor để đào tạo mô hình hỗn hợp Gaussian để phát hiện ăn mòn. Francisco Bonnin-Pascual và Ortiz [10] sử dụng 2 bộ phân loại yếu để tự động phát hiện ăn mòn trong bể chứa, tàu và trên đường ống dẫn khí. Bộ phân loại đầu tiên, độ nhám, được đo bằng đặc tính năng lượng của GLCM. Màu sắc được sử dụng làm bộ phân loại thứ 2 và được kiểm tra trong không gian màu Hue - Saturation - Intensity (HSI) và Hue - Saturation - Value (HSV). Để cung cấp hệ thống phổ màu tham chiếu, Medeiros và cộng sự sử dụng phân tích phân biệt trong khi Bonnin-Pascual và Ortiz áp dụng các chiến lược lọc khác nhau trên biểu đồ Hue - Saturation (HS) được huấn luyện.

Các phương pháp kể trên có đặc điểm chung là kết hợp các kỹ thuật xử lý ảnh (image processing) với các mô hình trí tuệ nhân tạo để phát hiện các vùng ăn mòn và đã cho kết quả tương đối khả quan. Tuy nhiên, phương pháp trên thường yêu cầu khối lượng tính toán lớn, tiêu tốn nhiều tài nguyên tính toán như bộ nhớ và bộ xử lý, chưa đánh giá được thời gian thực hiện tính toán phát hiện ăn mòn. Chính vì vậy, trong nghiên cứu này nhóm tác giả đề xuất 1 mô hình Markov ẩn (hidden Markov model - HMM) hiệu quả để phát hiện các khu vực bị ăn mòn trên bề mặt của đường ống dẫn khí. Mô hình HMM của nhóm tác giả được huấn luyện trên máy tính cá nhân và có thể được triển khai trên các thiết bị có tài nguyên tính toán hạn chế như điện thoại, laptop, để các kỹ thuật viên có thể theo dõi các khu vực bị ăn mòn trên đường ống dẫn khí trong thời gian thực.

**2. Phát hiện ăn mòn trên đường ống dẫn khí**

Quy trình phát hiện ăn mòn đường ống dẫn khí được trình bày trong Hình 1. Việc phát hiện ăn mòn được tiến hành qua 3 bước với đầu vào là 1 ảnh RGB chứa 1 đoạn đường ống dẫn khí và đầu ra là vùng ảnh chứa các vị trí bị ăn mòn của đoạn đường ống.



Hình 1. Quá trình phát hiện ăn mòn đường ống dẫn khí dựa trên trí tuệ nhân tạo.

## 2.1. Tiền xử lý (pre-processing)

Do ảnh đầu vào có thể được chụp từ các thiết bị khác nhau (mobile phone, UAV, máy ảnh thường) trong các điều kiện môi trường khác nhau (tay chụp rung, sương mù, mưa, tối trời...) nên ảnh có thể chứa nhiễu. Vì vậy, trước khi phát hiện vùng ăn mòn thì ảnh thu nhận được tiền xử lý để loại bỏ nhiễu. Các kỹ thuật giảm thiểu nhiễu được áp dụng trong nghiên cứu này là các phép toán hình thái học (mathematical morphology) gồm phép toán co giãn (dilation), phép loại bỏ vùng ảnh nhiễu (erosion), phép mở (opening) và phép đóng (closing), từ đó thu được ảnh sau khi đã được giảm thiểu nhiễu.

## 2.2. Phân đoạn và trích xuất các đặc trưng (segmentation and feature extraction)

Bước tiếp theo sau khi tiền xử lý ảnh là tiến hành phân đoạn (segmentation) để trích ra vùng ảnh chứa đoạn ống dẫn khí (gas pipe segment) cần phát hiện ăn mòn. Tại bước này, sẽ loại bỏ ảnh của các đối tượng xung quanh khu vực đường ống mà không phải đoạn ống dẫn khí (ví dụ đất, đá, cây cỏ, lá cây...); tiếp theo những vùng ảnh thuộc về ống dẫn khí sẽ được trích chọn đặc trưng. Nhóm tác giả lựa chọn 2 loại đặc trưng là biểu đồ tần suất màu (colour histogram) và đặc trưng kết cấu (texture) và kết hợp để xây dựng vector đặc trưng (feature vector) dùng cho quá trình huấn luyện và nhận dạng vùng bị ăn mòn. Lý do lựa chọn 2 đặc trưng này là việc tính toán đơn giản, màu đặc trưng của vùng bị ăn mòn thường có màu nâu đậm hoặc ngả vàng đồng thời đặc trưng kết cấu phản ánh tốt độ thô ráp trên bề mặt của vùng bị ăn mòn.

## 2.3. Mô hình Markov ẩn phát hiện vùng ăn mòn (HMM for corrosion detection)

Mô hình Markov ẩn [11] là mô hình học máy trí tuệ nhân tạo dựa trên xác suất thống kê trong đó hệ thống được mô hình hóa bằng một quá trình Markov với các tham số không biết trước. Mỗi mô hình HMM gồm bộ ba  $(\pi, A, B)$ , trong đó  $\pi$  là ma trận khởi tạo,  $A$  là ma trận chuyển trạng thái và  $B$  là ma trận quan sát. Trong bài toán này, nhiệm vụ của mô hình là xác định các tham số ẩn (vùng ăn mòn) từ các tham số quan sát được là vector đặc trưng trích xuất từ ảnh đầu vào sau khi đã được tiền xử lý và phân đoạn. Các tham số của mô hình được ước lượng (huấn luyện) sau đó sử dụng để thực hiện các phân tích áp dụng cho ảnh kế tiếp. Trong mô hình Markov, trạng thái được quan sát trực tiếp và được mã hóa thành vector đặc trưng từ ảnh, vì vậy các xác suất chuyển tiếp trạng thái là các tham số duy nhất. Mô hình Markov ẩn thêm

vào các đầu ra: mỗi trạng thái có xác suất phân bố trên các biểu hiện đầu ra có thể. Vì vậy, từ dãy của các biểu hiện được sinh ra bởi HMM sẽ không trực tiếp thấy được dãy các trạng thái. Để nhận dạng được vùng ăn mòn từ ảnh quan sát (chứa đoạn ống dẫn khí), trước hết HMM cần được huấn luyện để ước lượng các tham số của mô hình. Pha huấn luyện mô hình HMM được tiến hành như sau:

Cho  $X$  là vector ngẫu nhiên từ 1 tập hợp được tham số hóa, cần tìm  $\theta$  sao cho  $P(X|\theta)$  là cực đại. Yêu cầu này gọi là ước tính tối đa khả năng (maximum likelihood, ML) cho  $\theta$ . Để ước tính  $\theta$ , hàm hợp lý log (log likelihood function) được định nghĩa là:

$$L(\theta) = \ln P(X|\theta) \quad (1)$$

Trong đó:

$X$ : Vector đặc trưng được trích chọn từ ảnh quan sát;

$\theta$ : Tham số của mô hình (gồm 3 ma trận  $\pi, A, B$ ).

Hàm likelihood được coi là hàm của tham số  $\theta$  cho dữ liệu  $X$ . Vì  $\ln(x)$  là 1 hàm gia tăng nghiêm ngặt, giá trị của  $\theta$  tối đa hóa cho  $P(X|\theta)$  cũng tối đa cho  $L(\theta)$ .

Thuật toán EM [10] là 1 thủ tục lặp để tối đa hóa  $L(\theta)$ . Giả sử sau lần lặp thứ  $n$  ước tính hiện tại cho  $\theta$  được đưa ra bởi  $\theta_n$ . Vì mục tiêu là tối đa hóa  $L(\theta)$ , muốn tính toán một ước tính cập nhật  $\theta$  thì:

$$L(\theta) > L(\theta_n) \quad (2)$$

Tương tự, muốn tối đa hóa sự khác biệt:

$$L(\theta) - L(\theta_n) = \ln P(X|\theta) - \ln P(X|\theta_n) \quad (3)$$

Trong các vấn đề về tồn tại dữ liệu, thuật toán EM cung cấp 1 khuôn khổ tự nhiên cho sự bao hàm của chúng. Nói cách khác, các biến ẩn có thể được giới thiệu hoàn toàn như thủ thuật để ước tính khả năng tối đa  $\theta$  để kiểm soát. Trong trường hợp này, giả định việc biết rõ các biến ẩn sẽ làm cho việc tối đa hóa hàm có khả năng dễ dàng hơn. Có nghĩa là, biểu diễn các vector ngẫu nhiên ẩn bởi  $Z$  và được thể hiện bởi  $z$ . Tổng xác suất  $P(X|\theta)$  có thể được viết theo các biến ẩn  $z$  như sau:

$$P(X|\theta) = \sum_z P(X|z, \theta) P(z|\theta) \quad (4)$$

Công thức (3) có thể viết lại như sau:

$$L(\theta) - L(\theta_n) = \ln \sum P(X|z, \theta) P(z|\theta) - \ln P(X|\theta_n) \quad (5)$$

Lưu ý rằng, biểu thức này liên quan đến logarit của 1 tổng. Sử dụng bất đẳng thức Jensen (Jensen's inequality) đã chứng minh rằng:

$$\ln \sum_{i=1}^n \lambda_i x_i \geq \sum_{i=1}^n \lambda_i \ln(x_i)$$

cho hằng số  $\lambda_i \geq 0$  với  $\sum_{i=1}^n \lambda_i = 1$ . Kết quả này được áp dụng cho công thức (5) liên quan đến logarit của tổng được cung cấp các hằng số  $\lambda_i$  có thể được xác định. Xem xét để các hằng số có dạng  $P(z|X, \theta_n)$ . Vì  $P(z|X, \theta_n)$  là 1 thước đo xác suất, ta có  $P(z|X, \theta_n) \geq 0$  và  $\sum_z P(z|X, \theta_n) = 1$  theo yêu cầu.

Từ công thức (5) hằng số  $P(z|X, \theta_n)$  được đưa ra:

$$\begin{aligned} L(\theta) - L(\theta_n) &= \ln \sum_z P(X|z, \theta) P(z|\theta) - \ln P(X|\theta_n) \\ &= \ln \sum_z P(X|z, \theta) P(z|\theta) \cdot \frac{P(z|X, \theta_n)}{P(z|X, \theta_n)} - \ln P(X|\theta_n) \\ &= \ln \sum_z P(X|z, \theta) \left( \frac{P(X|z, \theta) P(z|\theta)}{P(z|X, \theta_n)} \right) - \ln P(X|\theta_n) \\ &\geq \sum_z P(z|X, \theta_n) \ln \left( \frac{P(X|z, \theta) P(z|\theta)}{P(z|X, \theta_n)} \right) - \ln P(X|\theta_n) \\ &= \sum_z P(z|X, \theta_n) \ln \left( \frac{P(X|z, \theta) P(z|\theta)}{P(z|X, \theta_n) P(X|\theta_n)} \right) \\ &\stackrel{\Delta}{=} \Delta(\theta|\theta_n) \end{aligned} \tag{6}$$

Từ công thức (6) có thể viết lại tương đương:


$$L(\theta) \geq L(\theta_n) + \Delta(\theta|\theta_n) \tag{7}$$

và để thuận tiện cho xác định  $l(\theta|\theta_n) \stackrel{\Delta}{=} L(\theta_n) + \Delta(\theta|\theta_n)$  để mối quan hệ trong công thức (7) có thể được thể hiện rõ ràng:

$$L(\theta) \geq l(\theta|\theta_n)$$

Ta có 1 hàm  $l(\theta|\theta_n)$  được giới hạn trên bởi hàm  $L(\theta)$ . Ngoài ra, có thể quan sát:

$$\begin{aligned} l(\theta_n|\theta_n) &= L(\theta_n) + \Delta(\theta_n|\theta_n) \\ &= L(\theta_n) + \sum_z P(z|X, \theta_n) \ln \frac{P(X|z, \theta_n) P(z|\theta_n)}{P(z|X, \theta_n) P(X|\theta_n)} \\ &= L(\theta_n) + \sum_z P(z|X, \theta_n) \ln \frac{P(X, z|\theta_n)}{P(X, z|\theta_n)} \\ &= L(\theta_n) + \sum_z P(z|X, \theta_n) \ln 1 \\ &= L(\theta_n) \end{aligned} \tag{8}$$



Hình 2. Biểu diễn đồ họa 1 lần lặp của thuật toán EM.

vì vậy đối với  $\theta = \theta_n$  các hàm  $l(\theta|\theta_n)$  và  $L(\theta)$  bằng nhau.

Hàm  $L(\theta|\theta_n)$  bị giới hạn trên bởi hàm  $L(\theta)$ . Các hàm có kết quả  $= \theta_n$ . Thuật toán EM chọn  $\theta_{n+1}$  làm giá trị của  $\theta$  mà  $l(\theta|\theta_n)$  là cực đại. Vì  $L(\theta) \geq l(\theta|\theta_n)$ , tăng  $l(\theta|\theta_n)$  sẽ đảm bảo giá trị của hàm  $L(\theta)$  khả năng được tăng lên ở mỗi bước.

Mục tiêu của nhóm tác giả là chọn 1 giá trị  $\theta$  sao cho  $L(\theta)$  cực đại. Nghiên cứu chỉ ra rằng hàm  $l(\theta|\theta_n)$  bị giới hạn trên bởi hàm  $L(\theta)$ , và giá trị của các hàm  $l(\theta|\theta_n)$  và  $L(\theta)$  bằng với ước tính hiện tại cho  $\theta = \theta_n$ . Vì vậy, bất kỳ  $\theta$  làm tăng  $l(\theta|\theta_n)$  sẽ làm tăng  $L(\theta)$ . Để  $L(\theta)$  đạt được giá trị gia tăng lớn nhất có thể, thuật toán EM được gọi để lựa chọn  $\theta$  sao cho  $l(\theta|\theta_n)$  đạt cực đại. Nhóm tác giả biểu thị giá trị được cập nhật là  $\theta_{n+1}$ . Quá trình này được minh họa trong Hình 2.

Pha nhận dạng sẽ được tiến hành như sau:

$$\begin{aligned} \theta_{n+1} &= \arg \max_{\theta} \{l(\theta|\theta_n)\} \\ \theta_{n+1} &= \arg \max_{\theta} \left\{ L(\theta_n) + \sum_x P(z|X, \theta_n) \right. \\ &\quad \left. \ln \frac{P(X|z, \theta) P(z|\theta)}{P(X|\theta_n) P(z|X, \theta_n)} \right\} \end{aligned} \tag{9}$$

Sau đó giảm các hằng số w.r.t.  $\theta$

$$\begin{aligned} &= \arg \max_{\theta} \{ \sum_x P(z|X, \theta_n) \ln P(X|z, \theta) P(z|\theta) \} \\ &= \arg \max_{\theta} \left\{ \sum_x P(z|X, \theta_n) \ln \frac{P(X, z, \theta) P(z, \theta)}{P(z, \theta) P(\theta)} \right\} \\ &= \arg \max_{\theta} \{ \sum_x P(z|X, \theta_n) \ln P(X, z|\theta) \} \\ &= \arg \max_{\theta} \{ E_{z|X, \theta_n} \{ \ln P(X, z|\theta) \} \} \end{aligned} \tag{10}$$

Trong công thức (9) các bước kỳ vọng và tối đa là đầy đủ, rõ ràng và hữu hạn. Do đó, thuật toán EM gồm việc lặp lại:

- E-step: Xác định kỳ vọng có điều kiện  $E_{z|X, \theta_n} \{ \ln P(X, z|\theta) \}$

- M-step: Tối đa hóa biểu diễn liên quan đến  $\theta$

Tiếp đến thay thế hàm tối đa hóa  $L(\theta)$  với hàm tối đa hóa gần với xác suất điều kiện  $l(\theta|\theta_n)$ . Thực tế là  $l(\theta|\theta_n)$  tính đến dữ liệu không được quan sát hoặc bị thiếu dữ liệu  $Z$ . Trong trường hợp nhóm tác giả ước tính các biến này, các thuật toán EM cung cấp 1 nền tảng cho việc này. Ngoài ra, cách xử lý này khá thuận lợi để đưa ra các biến ẩn để tối đa hóa

$l(\theta|\theta N)$ , điều này được đơn giản hóa nhờ kiến thức về các biến ẩn (so với tối đa hóa trực tiếp của  $L(\theta)$ ).

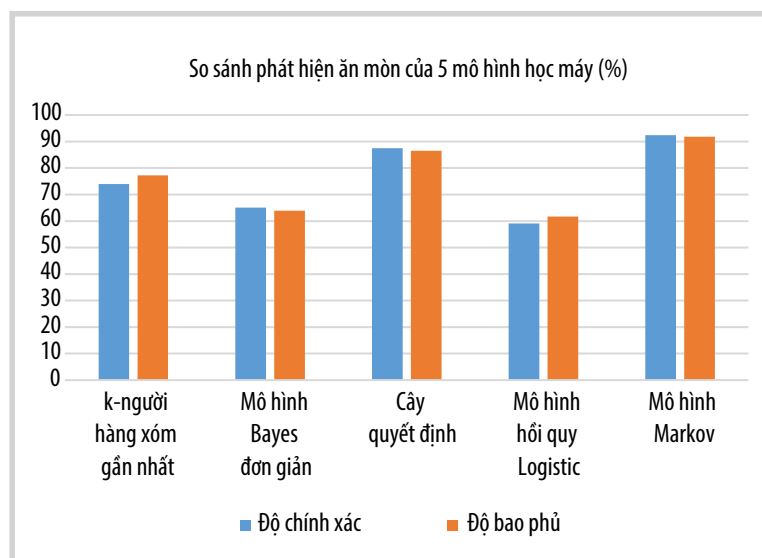
Các tính chất hội tụ của thuật toán EM được đề xuất bởi G. McLachlan và T. Krishnan [14]. Nhóm tác giả xem xét sự hội tụ chung của thuật toán. Vì  $\theta_{n+1}$  là ước tính cho  $\theta$  tối đa hóa sự khác biệt  $\Delta(\theta|\theta_n)$ . Bắt đầu với ước tính hiện tại cho  $\theta$ , đó là  $\theta_n$ , nhóm tác giả đã có  $\Delta\theta/\theta_n = 0$ . Vì  $\theta_{n+1}$  được chọn để tối đa hóa  $\Delta(\theta|\theta_n)$ , mặt khác  $\Delta(\theta_{n+1})/\theta_n \geq \Delta(\theta_n|\theta_n) = 0$ , do đó đối với mỗi lần lặp, khả năng  $L(\theta)$  là không thay đổi.

Khi thuật toán đạt đến 1 điểm cố định cho một số  $\theta_n$  giá trị  $\theta_n$  tối đa hóa  $l(\theta)$ . Vì  $L$  và  $l$  bằng nhau tại  $\theta_n$  nếu  $L$  và  $l$  có khả năng khác nhau tại  $\theta_n$  thì  $\theta_n$  phải là một điểm dừng của  $L$ . Điểm dừng là không cần thiết, tuy nhiên là cực đại cục bộ. Kết quả cho thấy rằng có thể cho các thuật toán hội tụ đến cực tiểu địa phương hoặc điểm yên trong trường hợp bất thường.

Trong thuật toán EM mô tả ở trên,  $\theta_{n+1}$  được chọn làm giá trị  $\theta$  với  $\Delta(\theta|\theta_n)$  cực đại hóa. Trong khi điều này đảm bảo sự gia tăng lớn nhất trong  $L(\theta)$ , tuy nhiên nó có thể làm nhẹ bởi yêu cầu tối đa hóa một trong những  $\Delta(\theta|\theta_n)$  sao cho:

$$\Delta(\theta_{n+1})/\theta_n \geq \Delta(\theta_n|\theta_n) \tag{11}$$

Như vậy những điểm ảnh thỏa mãn các công thức (9) và (11) sẽ được đưa vào vùng bị ăn mòn trong ảnh kết quả.



Hình 3. So sánh hiệu quả phát hiện ăn mòn của 5 mô hình học máy.

Bảng 1. Kết quả phát hiện vùng ăn mòn

Mô hình học máy	Độ chính xác (%)	Độ bao phủ (%)
k-người hàng xóm gần nhất	73,91	77,25
Mô hình Bayes đơn giản	65,12	63,92
Cây quyết định	87,45	86,55
Mô hình hồi quy logistic	59,12	61,73
<b>Mô hình Markov ẩn</b>	<b>92,36</b>	<b>91,85</b>

### 3. Thử nghiệm và đánh giá

Để đánh giá hiệu quả của phương pháp đề xuất, nhóm nghiên cứu đã lựa chọn ra khoảng 5.000 ảnh có độ phân giải full HD (1.280 x 720 pixels) chụp những khu vực đường ống dẫn khí bị ăn mòn với các mức độ khác nhau từ tập dữ liệu gồm 140.000 ảnh được thu thập bởi Blossom Treasa Bastian và cộng sự [13]. Tập dữ liệu thử nghiệm được tiền xử lý theo thuật toán của nhóm tác giả sau đó được chia thành 10 phần. 9 phần dùng để huấn luyện và 1 phần dùng để nhận dạng những khu vực bị ăn mòn. Sau đó nhóm tác giả lặp lại quá trình này cho đến khi tất cả 10 phần được nhận dạng. Kết quả cuối cùng được tính trung bình trên cả 10 lần thử nghiệm. Phương pháp này gọi là kiểm tra chéo (10-fold cross validation) được dùng như một phương pháp chuẩn để đánh giá các mô hình trí tuệ nhân tạo.

Ngoài ra, nhóm tác giả cũng so sánh với một số phương pháp học máy khác, bao gồm mô hình k-nearest neighbors, mô hình Bayes đơn giản (naïve Bayes), mô hình cây quyết định (decision tree) và mô hình hồi quy logistic (logistic regression) theo cách thử nghiệm kiểm tra chéo 10 lần và kết quả về độ chính xác được trình bày trong Bảng 1.

Theo Bảng 1 và Hình 3, độ chính xác và độ bao phủ được tính so với thực tế bằng các thông số TP (true positive), FP (false positive), TN (true negative) và FN (false negative). Theo đó, mô hình HMM cho kết quả tốt nhất với trên 90% độ chính xác (precision) và độ bao phủ (recall). Tiếp theo là mô hình cây quyết định cho kết quả khả quan với trên 86% độ chính xác và độ bao phủ. Ở chiều ngược lại, mô hình hồi quy logistic cho kết quả thấp nhất. Điều này có thể giải thích là do mô hình hồi quy thường không phù hợp với bài toán phân loại với đầu vào là các vector đặc trưng nhiều



chiều (multi-dimensional feature vectors) như bài toán phát hiện vùng ăn mòn. Trong khi đó, HMM là một mô hình học máy có tính khái quát dữ liệu cao (generative models). Khi có đủ dữ liệu huấn luyện thì HMM thường cho kết quả tương đối khả quan đối với các bài toán nhận dạng từ ảnh như bài toán phát hiện ăn mòn đường ống dẫn khí. Ngoài ra, mô hình cây quyết định cũng cho kết quả tương đối tốt do việc phân loại khá hiệu quả dựa trên vector đặc trưng đã được trích xuất. Các mô hình khác như k-nearest neighbors và Bayes đơn giản cho kết quả trung bình: Bayes đơn giản dựa trên giả định là các đặc trưng độc lập hoàn toàn, điều này có thể thiếu chính xác vì độ nhò nhám của vùng ăn mòn có thể liên quan đến màu của vùng bị ăn mòn; k-nearest neighbors chưa tận dụng được các mối liên quan giữa các vector đặc trưng trong tập dữ liệu. Trực quan hóa kết quả so sánh được trình bày trong Hình 3.

#### 4. Kết luận

Bài báo đã trình bày kết quả bước đầu ứng dụng trí tuệ nhân tạo là mô hình học máy Markov ẩn để nhận dạng vùng bị ăn mòn trên đường ống dẫn khí. Phương pháp đề xuất của nhóm tác giả gồm 3 bước: tiền xử lý ảnh đầu vào; phân đoạn và trích chọn các đặc trưng biểu đồ tần suất màu và đặc trưng kết cấu; cuối cùng là dùng mô hình học máy được huấn luyện từ các vector đặc trưng để nhận dạng vùng ăn mòn trên đường ống dẫn khí. Kết quả thử nghiệm ban đầu cho thấy phương pháp đề xuất có nhiều tiềm năng cải tiến để ứng dụng rộng rãi trên thực tiễn.

Theo kế hoạch, nhóm tác giả sẽ cải tiến mô hình đã đề xuất bằng các mô hình trí tuệ nhân tạo tiên tiến như học sâu và xây dựng các robot tự động thu nhận ảnh của đường ống dẫn khí trong các môi trường khác nhau (bao gồm cả dưới nước) để thúc đẩy mạnh mẽ hơn nữa các mô hình trí tuệ nhân tạo, nâng cao quá trình tự động hóa trong việc dò tìm, đánh giá và theo dõi mức độ ăn mòn cũng như phát hiện nhanh những rủi ro tiềm ẩn đối với hệ thống đường ống dẫn dầu khí.

#### Lời cảm ơn

Bài báo là kết quả nghiên cứu của nhiệm vụ khoa học và công nghệ cấp Quốc gia: "Nghiên cứu, xây dựng giải pháp trực tuyến đánh giá và quản lý rủi ro phục vụ công tác kiểm định thiết bị công nghiệp", Mã số KC.01.15/16-20.

#### Tài liệu tham khảo

[1] Gerhardus Koch, Jeff Varney, Neil Thopson, Oliver Moghissi, Melissa Goud, and Joe Payer, "International

measures of prevention, application, and economics of corrosion technologies study", *NACE International*, 2016.

[2] Duzgun Agdas, Jennifer A. Rice, Justin R. Martinez, and Ivan R. Lasa, "Comparison of visual inspection and structural-health monitoring as bridge condition assessment methods", *Journal of Performance of Constructed Facilities*, Vol. 30, No. 3, pp. 1 - 10, 2016. DOI: 10.1061/(ASCE)CF.1943-5509.0000802.

[3] Marat Enikeev, Irek Gubaydullin, and Marina Maleeva, "Analysis of corrosion process development on metals by means of computer vision", *Engineering Journal*, Vol. 21, No. 4, pp. 183 - 192, 2017. DOI: 10.4186/ej.2017.21.4.183.

[4] Flávio Felix Feliciano, Fabiana Rodrigues Leta, and Fernando Benedicto Mainier, "Texture digital analysis for corrosion monitoring", *Corrosion Science*, Vol. 93, pp. 138 - 147, 2015. DOI: 10.1016/j.corsci.2015.01.017.

[5] Po-Han Chen, Ya-Ching Yang, and Luh-Maan Chang, "Automated bridge coating defect recognition using adaptive ellipse approach", *Automation in Construction*, Vol. 18, No. 5, pp. 632 - 643, 2009. DOI: 10.1016/j.autcon.2008.12.007.

[6] Amjad Khan, Syed Saad Azhar Ali, Atif Anwer, Syed Hasan Adil, and Fabrice Mériaudeau, "Subsea pipeline corrosion estimation by restoring and enhancing degraded underwater images", *IEEE Access*, Vol. 6, pp. 40585 - 40601, 2018. DOI: 10.1109/ACCESS.2018.2855725.

[7] M. Khayatizad, L. De Pue, and W. De Waele, "Detection of corrosion on steel structures using automated image processing", *Developments in the Built Environment*, Vol. 3, 2020. DOI: 10.1016/j.dibe.2020.100022.

[8] Luca Petricca, Tomas Moss, Gonzalo Figueroa, and Stian Broen. "Corrosion detection using AI: A comparison of standard computer vision techniques and deep learning model", *The 6<sup>th</sup> International Conference on Computer Science, Engineering and Information Technology, Vienna, Austria, 21 - 22 May 2016*. DOI: 10.5121/csit.2016.60608.

[9] Tom Gibbons, Gareth Pierce, Keith Worden, and Ifigeneia Antoniadou, "A Gaussian mixture model for automated corrosion detection in remanufacturing", *16<sup>th</sup> International Conference on Manufacturing Research ICMR, 11 - 13 September 2018*. DOI: 10.3233/978-1-61499-902-7-63.

[10] Francisco Bonnin-Pascuala and Alberto Ortiz, "Corrosion detection for automated visual inspection",

*Developments in Corrosion Protection*. InTech, 2014, pp. 619 - 632. DOI: 10.5772/57209.

[11] Kristie Seymore, Andrew McCallum, and Ronald Rosenfeld, "Learning hidden Markov model structure for information extraction", *AAAI Technical Report WS-99-11*, pp. 37 - 42, 1999.

[12] Yasuo Matsuyama, "Hidden Markov model estimation based on alpha-EM algorithm: Discrete and continuous alpha-HMMs", *International Joint Conference*

*on Neural Networks, USA, 31 July - 5 August 2011*. DOI: 10.1109/IJCNN.2011.6033304.

[13] Blossom Treasa Bastian, N. Jaspreeth, S. KumarRanjithb, and C.V. Jiji, "Visual inspection and characterization of external corrosion in pipelines using deep neural network", *NTD & E International*, No. 107, pp. 102 - 134, 2019. DOI: 10.1016/j.ndteint.2019.102134.

[14] G. McLachlan and T. Krishnan, *The EM algorithm and extensions, 2<sup>nd</sup> edition*. John Wiley & Sons, 2008.

## AUTOMATED GAS PIPELINE CORROSION DETECTION WITH ARTIFICIAL INTELLIGENCE

**Le Huy Thuong<sup>1</sup>, Nguyen Van Ngo<sup>1</sup>, Nguyen Tuan Linh<sup>2</sup>**

<sup>1</sup>Cortek Co. Ltd.

<sup>2</sup>Posts and Telecommunications Institute of Technology

Email: thuonglehuy@cortek.vn

### Summary

The article presents a method to detect gas pipeline corrosion using artificial intelligence to analyse visual images with 3 steps: preprocessing of input images; segmentation and extraction of histogram features and texture features; and proposing to use the hidden Markov model trained from feature vectors capable of automatically analysing the camera images and identifying eroded areas of the gas pipeline. An initial experiment on a dataset of over 5000 published oil pipeline images shows the proposed method achieves results with over 90% accuracy.

**Key words:** Corrosion, gas pipeline, hidden Markov model, artificial intelligence.