



Cảnh báo nguy hiểm lệch làn trong vận hành an toàn cầu RTG ứng dụng mạng nơ-ron học sâu LaneNet

Warning of lane departure dangers in the safe operation of RTG crane using LaneNet deep learning neural network

Đỗ Việt Dũng^{1,*}, Nguyễn Đức Ngọc², Nguyễn Ngọc Trúc¹, Nguyễn Tiến Dũng¹, Huỳnh Tấn Đệ³

¹Nhóm nghiên cứu AIT, Trường Đại học Giao thông vận tải Thành phố Hồ Chí Minh, Hồ Chí Minh

²Công ty Cổ phần Dịch vụ Kỹ thuật Tân Cảng, Hồ Chí Minh

³Trường Đại học Tôn Đức Thắng, Hồ Chí Minh

Từ khóa:

Cảnh báo lệch làn
Cầu RTG
Học sâu LaneNet
Nguy cơ mất an toàn
Vận hành bến cảng

TÓM TẮT

Cầu trục bánh lốp (RTG) thường gặp các sự cố lệch làn làm gián đoạn kế hoạch vận chuyển hàng hóa. Nhằm nâng cao an toàn trong vận hành, bài báo này đề xuất giải pháp cảnh báo lệch làn ứng dụng mạng nơ-ron học sâu (DL). Dựa trên tập dữ liệu vận hành thực tế của cầu RTG, nhóm tác giả phát triển mạng nơ-ron LaneNet trong xây dựng mô hình cảnh báo mang lại kết quả khả thi có độ chính xác lên đến 96,3% và tốc độ xử lý đạt 65 FPS. Kết quả thử nghiệm cho thấy giải pháp này không chỉ cải thiện đáng kể mức độ an toàn mà còn tối ưu hóa hiệu suất hoạt động của cầu RTG. Qua đó, tiến hành các trường hợp thử nghiệm trong các điều kiện khắc nghiệt kết hợp mạng nơ-ron tiên tiến sẽ là hướng nghiên cứu cho hệ thống cảnh báo an toàn vận hành cầu RTG trong tương lai.

Keywords:

Lane deviation warning
RTG cranes
Deep learning
LaneNet
Risk of unsafety
Port operations

ABSTRACT

Rubber Tyred Gantry Cranes (RTG) frequently experiences lane deviation incidents that disrupt cargo transportations. This paper proposes a lane deviation warning solution utilizing deep learning (DL) neural networks to enhance operational safety. Using actual operating data from RTG cranes, the authors developed the LaneNet neural network to create a warning model that achieves an accuracy of up to 96.3% and a processing speed of 65 FPS. The experimental results demonstrate that this solution significantly improves safety levels while also optimizing the operational performance of RTG cranes. Therefore, future studies on the safety warning system for RTG crane operations will focus on conducting test cases under rigorous conditions using advanced neural networks.

* Đỗ Việt Dũng. Nhóm Nghiên cứu AIT, Trường Đại học Giao thông vận tải Thành phố Hồ Chí Minh
Email: dungdv@ut.edu.vn

<https://www.doi.org/10.55228/JTST14040111>

Ngày nhận bài: 09/04/2025; Ngày nhận bài sửa: 16/05/2025; Ngày chấp nhận đăng: 16/05/2025

Ngày xuất bản trực tuyến: 15/7/2025

pISSN: 1859-4263; eISSN: 3030-4261

1. Đặt vấn đề

Cầu trục bánh lốp (RTG) đóng vai trò quan trọng trong hoạt động xếp dỡ hàng hóa tại cảng biển. Trong quá trình vận hành cầu RTG đòi hỏi khả năng làm việc liên tục và độ chính xác cao. Bên cạnh đó, các hoạt động kinh tế biển và ngành Logistics phát triển mạnh mẽ dẫn đến nhu cầu xử lý hàng hóa ngày càng lớn, buộc các cảng biển phải duy trì hoạt động không ngừng [1]. Do đó, đảm bảo hiệu suất và độ tin cậy của cầu RTG là yếu tố then chốt để nâng cao hiệu quả khai thác cảng. Thực tế, hầu hết các cầu RTG đang được vận hành thủ công nên tiềm ẩn nhiều rủi ro trong quá trình hoạt động và khai thác thiết bị gây ra nguy cơ mất an toàn và giảm hiệu suất khai thác. Theo những báo cáo thống kê từ các cơ quan an toàn cảng như Health and Safety Executive UK [2], và Hong Kong Marine Department [3] tại Indonesia vào năm 2015 có 98 vụ tai nạn ghi nhận xảy ra tại cảng Tangijung Priok, trong đó 75 vụ liên quan đến mất an toàn tại cầu cảng và bãi container [4]. Các nguyên nhân chính dẫn đến tai nạn trong quá trình vận hành của cầu RTG có thể được xem xét bao gồm các nguyên nhân tổng hợp trong Bảng 1.

Hiện nay, nhiều nghiên cứu đã ứng dụng các công nghệ tiên tiến nhằm giảm thiểu nguy cơ tai nạn và nâng cao hiệu quả an toàn trong vận hành cầu RTG. Một số nghiên cứu tập trung vào việc xây dựng hệ thống vận hành cầu tự động thông qua công nghệ thị giác máy tính [5], qua đó giảm thiểu sự phụ thuộc vào yếu tố con người trong vận hành. Tuy nhiên, hệ thống đòi hỏi chi phí đầu tư ban đầu lớn với các yêu cầu về cơ sở hạ tầng đi kèm còn nhiều khó khăn. Ngoài ra, cũng có các nghiên cứu tập trung vào việc xử lý các yếu tố liên quan đến điều kiện thực tế khác như nhận diện tình trạng của người điều khiển cầu [6] nhằm đảm bảo an toàn khi tham gia vận hành. Mặt khác, các giải pháp về bố trí bãi container [7] để đạt hiệu quả tối ưu di chuyển cũng được xem xét làm giảm quãng đường di chuyển của cầu RTG, từ đó tăng tính an toàn cho quá trình vận hành. Tuy nhiên, hầu hết các nghiên cứu chỉ tập trung vào đề xuất giải pháp lý thuyết mà chưa thể hiện được tính thực tiễn khi áp dụng và xem xét đến điều kiện vận hành tại các cảng ở Việt Nam.

Trong những năm gần đây, việc phát triển mạnh mẽ của công nghệ trí tuệ nhân tạo [8] đem lại nhiều sự đột phá trong ứng dụng thực tế. Các phương pháp xử lý hình ảnh cổ điển dần được thay thế bằng các

thuật toán học sâu [9], [10], [11], do mang lại hiệu quả cao trong ứng dụng cảnh báo an toàn. Đặc biệt các nghiên cứu về nhận dạng làn đường, bám làn đường, phát hiện và tránh vật cản trong giao thông được ứng dụng và phát triển rộng rãi [12], [13], [14]. Đây cũng cơ sở để tác giả ứng dụng mô hình LaneNet trong cảnh báo lệch làn khi điều khiển hoạt động cầu RTG. Qua đó, giải quyết bài toán mất an toàn trong quá trình di chuyển cầu RTG tại khu vực cảng.

Các đóng góp chính của nghiên cứu này như sau: (i) Thiết lập tập dữ liệu các trường hợp vận hành của cầu RTG trong hoạt động thực tế tại cảng Tân Cảng – Cái Mép; (ii) Xây dựng mô hình cảnh báo áp dụng mạng nơ-ron LaneNet xác định tình trạng mất an toàn khi cầu RTG di chuyển lệch làn; (iii) Áp dụng mô hình cảnh báo trong vận hành thực tế nhằm đánh giá tính khả thi của giải pháp đề xuất.

Bảng 1. Các nguyên nhân gây nguy hiểm trong quá trình vận hành cầu RTG.

Nguyên nhân	Mô tả
Va chạm do di chuyển	Tầm nhìn người vận hành cầu bị che khuất, không quan sát được vật cản và làn đường bên phụ. Ngoài ra, yếu tố con người như kinh nghiệm, tinh thần, sức khỏe, vi phạm quy trình vận hành, cùng với thiếu thiết bị hỗ trợ cũng góp phần gây ra va chạm.
Container đặt lệch	Container bị đặt lệch tâm so với vị trí mong muốn, dẫn đến mất cân bằng trọng lượng gây ra đổ container.
Quá trình lùi xe	Cầu RTG di chuyển linh hoạt, thuận tiện trong sắp xếp container nhưng cũng mang lại một vấn đề về hạn chế tầm nhìn khi tài xế lùi xe nâng. Trong trường hợp tài xế kéo tời hàng chưa quá độ cao của hàng container phía sau sẽ dẫn đến xô đổ container.
Nguy cơ từ người vận hành	Yếu tố khách quan như thiếu kỹ năng, không tuân thủ quy trình, tầm nhìn bị che khuất và điều kiện thời tiết xấu. Bên cạnh đó, lỗi chủ quan của người vận hành như sử dụng điện thoại, đọc sách, ăn uống hoặc sức khỏe không đảm bảo (buồn ngủ, sử dụng chất kích thích) làm giảm sự tập trung.

Bài báo được tổ chức như sau: Phần 1 giới thiệu các căn cứ cũng như tồn tại trong phát triển mô hình cảnh báo. Tổng quan về cấu tạo, hoạt động chính của cầu RTG và các trường hợp thường xảy ra mất an toàn trong quá trình khai thác được trình bày tại Phần 2. Trong nội dung Phần 3, nhóm tác giả xây dựng giải pháp cảnh báo ứng dụng mạng nơ-ron LaneNet để xác định tình trạng mất an toàn do di chuyển lệch làn. Các kết quả thực nghiệm sẽ được tổng hợp và đánh giá thông qua các số liệu được trình bày trong Phần 4. Phần 5 sẽ đưa các kết luận và hướng phát triển cho nghiên cứu này.

2. Tổng quan cấu trúc cầu RTG và nguy cơ mất an toàn vận hành

Tổng thể cấu trúc của cầu RTG bao gồm bốn hệ thống chính, chi tiết mô tả tại Hình 1: hệ thống điều khiển, hệ thống tời nâng hàng, hệ thống xe tời và hệ thống di chuyển. Các thông số hoạt động cơ bản được thể hiện tại Bảng 2.


- **Hệ thống điều khiển:** bao gồm cần điều khiển dành cho người vận hành, bộ điều khiển chính thu thập tín hiệu đo lường từ cảm biến, công tắc, và thiết

bị an toàn nhằm điều khiển các cơ cấu chấp hành thông qua mạng truyền thông công nghiệp;

- **Hệ thống tời nâng hàng:** là một trong những bộ phận quan trọng nhất của cầu RTG, đảm nhận nhiệm vụ nâng hạ container. Hệ thống này sử dụng bộ biến tần điều khiển động cơ không đồng bộ ba pha, và nhận phản hồi tốc độ quay từ bộ cảm biến mã hóa vòng quay được gắn trên tang quấn cáp, nhằm tính toán độ cao nâng hàng hóa;

- **Hệ thống xe tời:** là bộ phận giúp cầu di chuyển tiến và lùi. Hệ thống này đảm bảo việc xếp dỡ container được thực hiện một cách chính xác và hiệu quả. Hệ thống xe tời sử dụng biến tần điều khiển vòng kín động cơ không đồng bộ ba pha, và cũng nhận phản hồi tốc độ từ cảm biến mã hóa vòng quay;

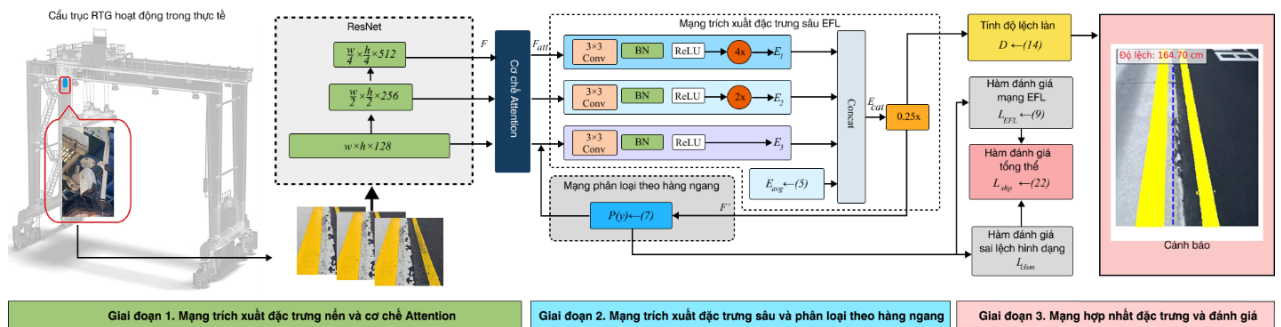
- **Hệ thống di chuyển:** là bộ phận hỗ trợ cầu RTG di chuyển trái phải trong quá trình xếp dỡ hàng. Hệ thống di chuyển được trang bị bốn biến tần điều khiển vòng kín bốn động cơ không đồng bộ ba pha độc lập phản hồi tốc độ. Bốn động cơ lai dặt 16 bánh lốp cao su, giúp cầu RTG có thể di chuyển qua trái, phải và có thể điều hướng linh hoạt nhờ vào thay đổi tốc độ độc lập giữa các động cơ.



Hình 1. Sơ đồ cấu trúc tổng quan cầu RTG.

Bảng 2. Thông số vận hành cầu RTG trong thực tế.

Thông số	Giá trị	Đơn vị
Tải nâng tối đa của cầu	41	ton
Tải trọng nâng	52,7	ton
Tải trọng xe nâng và cabinet	36	ton
Chiều cao nâng tời hàng	18	m
Chiều dài di chuyển xe nâng	18,4	m
Chiều rộng	23,47	m
Tốc độ gió cho phép	20	m/s



Hình 2. Sơ đồ mô hình cảnh báo nguy hiểm lệch làn ứng dụng mạng nơ-ron LaneNet.

Để đảm bảo an toàn, quá trình vận hành cầu RTG phải tuân thủ các yêu cầu kỹ thuật như tiêu chuẩn ISO 1161 [15] về sai lệch an toàn khi xếp container và OSHA 1910.179 [16] về yêu cầu an toàn vận hành. Trong nghiên cứu này, tiêu chuẩn ISO 1161 là cơ sở quan trọng xác định đặc tính vật lý, vị trí và giới hạn va chạm của container trong mô hình cảnh báo. Đồng thời, tiêu chuẩn OSHA 1910.179 là căn cứ để xác định ngưỡng đánh giá rủi ro khi lệch làn trong xây dựng hệ thống. Trong thực tế, bãi container ở cảng biển thường xuyên chịu tác động của gió lớn vì vậy việc đặt container lệch tâm sẽ dễ dẫn đến đổ và mất an toàn. Để đảm bảo an toàn theo tiêu chuẩn ISO 1161 khi chênh lệch cạnh trái của lỗ gù container ở trên và container ở dưới từ 00mm đến 25,4mm, nếu từ 25,5mm đến 51mm được xác định là cảnh báo nguy cơ mất an toàn, và giá trị vượt quá 52mm có thể đánh giá mất an toàn. Tuy nhiên, tại các cảng khác nhau có thể điều chỉnh ngưỡng giới hạn này để phù hợp với điều kiện vận hành và thiết bị tại từng khu vực cụ thể.

Trong thực tế vận hành cầu RTG tại cảng Tân Cảng – Cái Mép, kỹ thuật viên phải tuân thủ các quy định và kiểm tra đầy đủ các bước trước khi vận hành. Tuy nhiên trong điều kiện thực tế vẫn phát sinh các tình trạng nguy hiểm, đặc biệt vận hành trong buổi tối và thời tiết có mưa ảnh hưởng đến tầm nhìn. Qua đó, cho thấy tính cấp thiết của việc xây dựng hệ thống cảnh báo nguy hiểm lệch làn trong suốt quá trình hoạt động.

3. Xây dựng giải pháp vận hành an toàn với mạng nơ-ron LaneNet

Nghiên cứu trong phát triển mô hình cảnh báo an toàn vận hành cảng đã đạt được nhiều tiến bộ đáng kể trong những năm gần đây. Tuy nhiên, việc

đảm bảo độ chính xác và khả năng thích nghi vẫn là một thách thức lớn trong các điều kiện thực tế. Các mô hình cảnh báo áp dụng kiến trúc cơ sở như mạng nơ-ron tích chập (CNN) tuy đạt độ chính xác cao trong nhận diện làn đường nhưng vẫn gặp hạn chế khi xử lý trong các điều kiện ánh sáng yếu, làn đường mờ hoặc bị che khuất. Do đó, bài báo đề xuất mô hình mạng nơ-ron LaneNet phân tích hiệu quả các đặc trưng làn đường trong môi trường cảng. Mô hình đề xuất tăng cường kiến trúc cơ bản của mạng LaneNet thông qua tích hợp các tầng trích xuất trung gian (Attention), cho phép tập trung vào các đặc trưng quan trọng nhất và cải thiện khả năng nhận diện mà không làm tăng thêm thời gian tính toán. Cụ thể, ở phiên bản LaneNet gốc [17], được thiết kế cho nhận diện làn đường giao thông, sử dụng ENet kết hợp với H-Net để xử lý đường cong, thì mô hình được đề xuất sử dụng ResNet làm mạng nền, kết hợp với các lớp Attention và tầng trích xuất sâu EFL. Sự thay đổi cấu trúc này cho phép mô hình mới phân biệt làn đường tốt hơn trong các tình huống phức tạp đặc trưng của môi trường cảng, chẳng hạn như làn đường bị mờ, giao cắt hoặc bị che khuất. Điều này cho phép mô hình đề xuất xác định độ lệch làn đường bằng cách phân tích đường đi hiện tại so với làn đường được thiết kế theo quy định tại cảng. Tập dữ liệu làn đường sử dụng trong nghiên cứu được thu thập trực tiếp tại cảng Tân Cảng – Cái Mép trong các điều kiện ánh sáng khác nhau nhằm gia tăng độ chính xác xây dựng mô hình cảnh báo.

Mạng nơ-ron LaneNet được thiết lập thông qua ba giai đoạn chính, thể hiện tại Hình 3 bao gồm: *Giai đoạn 1* - Mạng trích xuất đặc trưng nền và cơ chế Attention (Backbone và mạng Attention) nhằm xử lý các đặc trưng cơ bản và thay đổi các kích thước nhằm tăng hiệu quả nhận diện; *Giai*

đoạn 2 - Mạng trích xuất sâu đặc trưng và phân loại theo hàng (EFL và Row-wise Classification), tại giai đoạn này các đặc trưng được phân tích theo chiều dài cụ thể của làn đường cần nhận diện; *Giai đoạn 3* - Mạng hợp nhất đặc trưng và đánh giá (Feature Fusion Network), đây là giai đoạn tính toán và đưa ra đánh giá về đặc trưng, kết quả cuối cùng về độ lệch làn của trường hợp cần cảnh báo.

- *Mạng trích xuất đặc trưng nền và cơ chế Attention*: cấu trúc của phần này được xem là tầng cốt lõi của cả mô hình LaneNet. Các hình ảnh về làn đường di chuyển và các thông số ban đầu được thiết lập ở tầng mạng này. Nhiệm vụ chính của tầng mạng này là trích xuất các đặc trưng từ dữ liệu F thông qua lớp mạng nền (Backbone), cụ thể được sử dụng trong nghiên cứu là ResNet [18]. Ngoài ra điểm mới của tầng trích xuất dữ liệu có bổ sung cơ chế CANet Attention [19], việc bổ sung cơ chế này làm tăng cường việc trích xuất dữ liệu ở những khu vực làn đường được đánh giá có mang các đặc trưng quan trọng và khuếch đại mức độ ảnh hưởng đặc trưng của vùng dữ liệu đó lên tổng thể dữ liệu được trích xuất F_{att} . Từ đó, phương trình mô tả F_{att} được viết lại như sau:

$$F_{att} = \sigma(W_2 \times \text{ReLU}(W_1 \cdot F + b_1)) + F \quad (1)$$

Trong đó, F là dữ liệu đầu vào của mạng, W_1 và W_2 lần lượt là các trọng số của lớp mạng nền ResNet và cơ chế CANet Attention, ReLU là hàm kích hoạt phi tuyến được sử dụng để giảm thiểu tính toán đặc trưng trong các lớp mạng và $\sigma(x) = 1/(1+e^{-x})$ là hàm kích hoạt để chuẩn hóa cho trọng số của cơ chế CANet Attention.

- *Mạng trích xuất sâu đặc trưng và phân loại theo hàng ngang*: Mạng trích xuất sâu đặc trưng (EFL Network) nhận đầu vào F_{att} từ giai đoạn 1. Sau đó, dữ liệu được đưa qua các lớp tích chập 3×3 và hàm kích hoạt ReLU để tạo ra ba tầng trích xuất dữ liệu E_1, E_2, E_3 với đặc trưng khác nhau của làn đường. Tiến hành thực hiện phép tính trung bình cộng ba tầng đặc trưng E_1, E_2, E_3 để tạo ra E_{avg} theo công thức (5). Kết hợp bản đồ E_{avg} với các dữ liệu đã trích xuất ban đầu bằng phép nối kênh để có được thông tin tường minh về hình dạng làn đường. Cuối cùng hợp nhất với lớp Concat E_{concat}

theo công thức (6) đưa ra thông tin về vị trí và hình dạng làn đường.

$$E_1 = \text{Upsample}(F_{att}, \text{scale}=4) \quad (2)$$

$$E_2 = \text{Upsample}(F_{att}, \text{scale}=2) \quad (3)$$

$$E_3 = \text{Upsample}(F_{att}, \text{scale}=1) = F_{att} \quad (4)$$

$$E_{avg} = \text{Mul}(E_1 + E_2 + E_3) / 3 \quad (5)$$

$$E_{cat} = \text{concat}(E_1, E_2, E_3, E_{avg}) \quad (6)$$

Đối với mạng phân loại theo hàng ngang (Row-wise Classification Network) có mục tiêu phân loại từng hàng pixel để xác định làn đường. Sau khi có dữ liệu trích xuất đặc trưng từ EFL, bước tiếp theo là phân loại từng hàng ngang của ảnh để xác định vị trí của làn đường. Tiến hành giảm chiều dữ liệu cho E_{cat} để giảm kích thước sau đó áp dụng phép biến đổi tọa độ Inverse Perspective Mapping (IPM) để dự đoán tọa độ của làn đường theo hàng ngang, qua đó thu được tập hợp các điểm (x, y) xác định làn đường. Giá trị dự đoán của mạng phân loại được xác định theo công thức sau:

$$P(y) = \text{Softmax}(W_{cls} \cdot F' + b) \quad (7)$$

Với $P(y)$ là xác suất của từng điểm ảnh thuộc vào vị trí làn đường hàng y , W_{cls} và b là trọng số và bias của quá trình phân loại và F' là biểu đồ đặc trưng sau quá trình EFL.

- *Mạng hợp nhất đặc trưng và đánh giá*: là giai đoạn cuối cùng trong cấu trúc mạng LaneNet. Ở mạng này các dữ liệu đặc trưng của làn đường sẽ được hợp nhất và đưa ra kết quả phát hiện làn đường cuối cùng. Thực hiện phép cộng để hợp nhất dữ liệu trích xuất đặc trưng từ hai mạng phân loại hàng ngang mạng EFL để tăng cường thông tin về làn đường mà không làm thay đổi kích thước. Sau đó kết hợp với bộ phân loại để tạo đầu ra cuối cùng dự đoán chính xác vị trí của làn đường. Cuối cùng, các kết quả tối ưu hóa mô hình bằng hai hàm đánh giá bao gồm hàm đánh giá làn đường chính xác (Classification loss) và hàm đánh giá sai lệch hình dạng (Shape Loss Function).

Hàm đánh giá sai lệch hình dạng L_{shp} đảm bảo rằng các điểm làn đường được dự đoán có tính liên tục, duy trì hình dạng làn đường thực tế được thể hiện tại công thức (8).

$$L_{shp} = \sum_{i=1}^c \sum_{j=1}^{h-1} \left(|Loc_{i,j} - Loc_{i,j+1} - (Loc_{i,j+1} - Loc_{i,j+1+\epsilon})| \right) \quad (8)$$

$$L_{EFL} = L_{clse} + \alpha L_{shp} \quad (13)$$

Trong đó, L_{EFL} sử dụng hàm Cross-Entropy và hệ số α để điều chỉnh mức độ ảnh hưởng của L_{shp} . Hàm đánh giá tổng thể quá trình huấn luyện mạng LaneNet L_{total} được tính toán theo biểu thức sau:

$$L_{total} = L_{clsm} + \beta L_{EFL} \quad (14)$$

Với L_{clsm} biểu thị cho hàm đánh giá phân loại trong mạng phân loại hàng ngang và β là hệ số điều chỉnh tác động của L_{EFL} .

Tổng thể quá trình tính toán được thể hiện chi tiết tại Giải thuật 1. Trong đó, đặc trưng E_1 biểu thị cho khoảng cách giữa tiêu điểm hiện tại và tâm cụm, E_2 biểu diễn cho sự đồng nhất về màu sắc hoặc đặc trưng hình học, và E_3 đảm bảo liên kết không gian, giúp các điểm ảnh trong cùng một cụm nằm liền kề và tránh nhiễu. Việc kết hợp ba đặc trưng này giúp tăng khả năng phân biệt giữa các làn đường, đặc biệt trong các trường hợp phức tạp như giao cắt hoặc làn đường bị mờ.

4. Thực nghiệm và đánh giá

4.1. Thiết lập tham số và kết quả

Quá trình huấn luyện mô hình LaneNet được thực hiện theo các thông số, biểu thị chi tiết trên Bảng 3. Bộ dữ liệu được sử dụng trong huấn luyện bao gồm 1100 hình ảnh làn đường di chuyển cầu RTG thu thập chính tại cảng Quốc tế Tân Cảng - Cái Mép, và có bổ sung thêm tại cảng Tân Cảng - Cát Lái trong các điều kiện ban ngày, ban đêm, làn đường mờ, trời mưa, che khuất và biến dạng.

Bảng 3. Tham số huấn luyện của mạng LaneNet.

Mô tả	Giá trị
Thế hệ huấn luyện	20
Tốc độ học của mạng	0,01
Tổng số lượng ảnh bộ dữ liệu	1100
Phần trăm dữ liệu huấn luyện	80%
Phần trăm dữ liệu kiểm thử	20%

Kích thước của dữ liệu là hình ảnh 640×480 pixel, được ghi nhận trong các điều kiện môi trường phức tạp chiếm hơn 65% tổng số lượng trong tập dữ liệu. Từ dữ liệu hình ảnh thô thu thập trực tiếp qua camera, nhóm tác giả tiến hành tiền

Giải thuật 1. Cảnh báo lệch làn cho cầu RTG

Input Ảnh làn đường khi cầu RTG di chuyển.
Ngưỡng cảnh báo lệch làn $K \leftarrow 15\text{cm}$.

Output Hình dạng làn đường $F' \in R^{\frac{W}{4} \times \frac{H}{4} \times C}$.
Độ lệch làn D .

```

// Giai đoạn 1
1   $F_{att} \leftarrow (1)$ 
   Tính giá trị
2   $C_{gt} = \frac{X_{left} + X_{right}}{2}$  (9)
// Giai đoạn 2
3  for  $F_{att} \in R^{(W \times H \times C)}$  do
4  |  $E_1 \leftarrow (2)$ 
5  end for
6  for  $F_{att} \in R^{(\frac{W}{2} \times \frac{H}{2} \times C)}$ 
7  |  $E_2 \leftarrow (3)$ 
8  end for
9  for  $F_{att} \in R^{(\frac{W}{4} \times \frac{H}{4} \times C)}$  do
10 |  $E_3 \leftarrow (4)$ 
11 |  $E_{avg} \leftarrow (5)$ 
12 |  $E_{cat} \leftarrow (6)$ 
   Dự đoán vị trí điểm ảnh thuộc làn đường.
13 |  $C_{pred} = \frac{\sum_x x \cdot P(x)}{\sum_x P(x)}$  (10)
14 end for
// Giai đoạn 3
15 Xác định thông tin hình dạng làn đường.
    $F' = \text{Interpolate}(E_{cat})$  (11)
16 Đánh giá tổng thể quá trình huấn luyện.
    $L_{total} \leftarrow (10)$ 
17 Tính toán độ lệch làn.
    $D = |C_{gt} - C_{pred}|$  (12)
18 if  $D > K$  then Cảnh báo lệch làn end if
19 end


```

Giá trị $\epsilon=2$ được lựa chọn dựa trên kết quả thử nghiệm nhằm đạt được sự cân bằng giữa giảm sai số trong tập hợp điểm ảnh trong cụm và tránh việc tách rời các điểm ảnh trong cùng một làn. Hàm đánh giá mạng EFL L_{EFL} được tính toán như công thức (13).

xử lý dữ liệu trước khi huấn luyện như theo các bước như sau:

- **Bước 1:** Hiệu chuẩn kích thước ảnh 640×480 pixel để đảm bảo tính đồng nhất đầu vào;
- **Bước 2:** Xử lý ảnh thông qua OpenCV để tăng giảm độ sáng và sắc nét, giúp mô hình nhận diện tốt trong các điều kiện khác nhau;
- **Bước 3:** Gán nhãn cho bộ dữ liệu dưới dạng phân đoạn (segmentation mask). Sau đó, lưu tập dữ liệu bao gồm hình ảnh và nhãn đi kèm để phục vụ huấn luyện mô hình.

Hình ảnh làn đường sau các bước tiền xử lý sẽ không mất đi các đặc trưng. Các bước tiền xử lý chỉ tập trung gia tăng độ sáng ở mức độ vừa phải (độ sáng là $\pm 3\%$, độ tương phản là $\pm 2\%$) và hiệu chỉnh độ sắc nét phù hợp (phạm vi $\pm 4\%$) nhằm không làm nổi bật các đặc trưng không cần thiết. Do đó, khi thay đổi kích thước ảnh phải đảm bảo giữ được đặc trưng quan trọng về làn đường ở trọng tâm hình ảnh.



Hình 3. Biểu đồ huấn luyện mạng nơ-ron LaneNet.

Kết quả của quá trình huấn luyện sau 20 thế hệ thu được độ chính xác cao nhất đạt 96,3% và giá trị hàm đánh giá đạt cực tiểu tại thế hệ thứ 20 là 0,1024. Các kết quả của toàn bộ quá trình huấn luyện được ghi nhận và thể hiện như Hình 3.

4.2. Thử nghiệm với cầu RTG tại cảng Tân Cảng – Cái Mép


Với các kết quả huấn luyện đã trình bày trong tiểu mục 4.1, nhóm nghiên cứu đã tiến hành nhúng mô hình cảnh báo đề xuất vào phần cứng Jetson Nano để thực nghiệm hiện trường tại cảng Tân Cảng – Cái Mép với các thông số kỹ thuật thể hiện tại Bảng 4. Quá trình thử nghiệm cảnh báo an toàn

cho vận hành cầu RTG với lớp xe cầu di chuyển trên làn kích thước lớn (làn di chuyển), và làn kích thước nhỏ phân định giữa khu vực di chuyển an toàn của cầu trục với khu vực lưu thông (làn phân cách). Theo quy định vận hành thực tế tại cảng Tân Cảng – Cái Mép tham chiếu theo tiêu chuẩn ISO 1116, nếu bánh lốp của cầu di chuyển lệch làn trong phạm vi dưới 15cm được xác định là tình trạng an toàn, trong phạm vi từ 15cm đến dưới 50cm là cảnh báo tình trạng mất an toàn có thể xảy ra, và độ lệch lớn hơn 50cm được xác định là mất an toàn cần dừng vận hành cầu RTG. Chi tiết các kịch bản thử nghiệm như sau:

- **Kịch bản 1:** Thử nghiệm trong điều kiện ban ngày đủ ánh sáng;
- **Kịch bản 2:** Thử nghiệm trong điều kiện hoạt động ban đêm, dưới ánh sáng đèn hỗ trợ vận hành;
- **Kịch bản 3:** Thử nghiệm trong điều kiện trời mưa có các tác nhân gây nhiễu ánh sáng khi nhận diện làn đường.


Bảng 4. Thông số kỹ thuật của mô hình cảnh báo áp dụng nhận dạng thực tế.

Thông số	Giá trị
Bộ xử lý trung tâm	Jetson Nano Kit
Camera	DS-2CD2T23G2-2L
Nguồn	12VDC
Ram tối thiểu	8GB
Bộ nhớ tối thiểu	64GB
Hệ điều hành	Linux
Chất lượng hình ảnh	Tối thiểu 2MP




Hình 4. Kết quả nhận diện cảnh báo ở Kịch bản 1.

Kịch bản 1 thực hiện thử nghiệm trong điều kiện đủ ánh sáng đã thu được các kết quả nhận diện làn đường tốt. Các đường xanh dương thể hiện kết quả liên tục và bám theo làn đường trong thực tế (làn màu vàng đậm). Kết quả này cũng là kết quả tốt nhất trong quá trình huấn luyện mô hình nhận diện làn đường. Thực tế, trong trường hợp này các kết quả lệch làn xác định đúng với các nhãn ban đầu được gán. Các kết quả chi tiết được thể hiện ở Hình 4.



Hình 5. Kết quả nhận diện cảnh báo ở Kịch bản 2.

Kịch bản 2 tiến hành thử nghiệm trong điều kiện hoạt động ban đêm, dưới ánh sáng của đèn hỗ trợ vận hành. Các kết quả nhận diện làn đường vẫn của giải pháp đề xuất vẫn đảm bảo khả năng nhận diện. Kết quả ở đường màu xanh dương bám sát theo các làn đường cố định đã quy định trước như kết quả ở Hình 5.



Hình 6. Kết quả nhận diện cảnh báo ở Kịch bản 3.

Trong Kịch bản 3, thử nghiệm được thực hiện trong điều kiện trời mưa có các tác nhân gây nhiễu ánh sáng khi nhận diện làn đường. Với điều kiện hoạt động dưới mưa, ánh sáng bị phản xạ ngược khi nước còn đọng lại trên bề mặt làn đường làm cho quá trình nhận diện gặp khó khăn nhất định. Các kết quả được tổng hợp ở Hình 6 cho thấy các đường dự đoán làn màu xanh ở Ảnh 3 còn chưa bám được vào làn đường ban đầu, tuy nhiên kết quả xác định lệch làn vẫn hoạt động tốt và xác định thông số lệch làn tương đối chính xác.

Để làm rõ hơn hiệu quả nhận diện của hệ thống cảnh báo trong các điều kiện thực tế, tác giả đã tiến hành thống kê tỷ lệ nhận diện sai lệch qua ba kịch bản thử nghiệm, với kết quả thể hiện trong Bảng 5. Kết quả thử nghiệm cho thấy trong điều kiện ban ngày với ánh sáng đầy đủ, hệ thống đạt độ chính xác cao, tỷ lệ sai lệch chỉ 2,3%. Khi chuyển sang ban đêm, mặc dù có đèn hỗ trợ vận hành nhưng tỷ lệ sai tăng lên 3,6% do ảnh hưởng của điều kiện ánh sáng thấp. Đáng chú ý, trong điều kiện trời mưa kèm nhiễu sáng, tỷ lệ sai lệch tăng đáng kể lên 7,3% chủ yếu do phản xạ ánh sáng gây khó khăn cho việc nhận diện làn đường.

Bảng 5. Tỷ lệ nhận diện sai lệch trong thử nghiệm.

Kịch bản	Tổng mẫu	Nhận diện sai	Tỷ lệ sai
Ban ngày, ánh sáng đầy đủ	300	7	2,3%
Ban đêm, đèn hỗ trợ vận hành	300	11	3,6%
Trong điều kiện trời mưa	300	22	7,3%

4.3. So sánh và đánh giá

Để đánh giá mô hình cảnh báo được đề xuất, chúng tôi dựa vào độ chính xác phát hiện đối tượng (Accuracy). Trong đó, độ chính xác của phát hiện đối tượng được phân loại so với tổng số mẫu, được tính toán bằng công thức (15) như sau:

$$Accuracy = (TP+TN)/\text{Tổng mẫu thử} \quad (15)$$

$$F1\text{-Score} = (2 \times TP) / (2 \times TP + \text{Mẫu sai}) \quad (16)$$

Với TP là số lần xác định chính xác các lệch làn đường, TN đại diện cho số trường hợp xác định đúng làn đường. Ngoài ra, nhóm nghiên cứu đã tiến hành so sánh kết quả thực nghiệm của mô

hình đề xuất với các mô hình được công bố trong các nghiên cứu trước đó. Quá trình so sánh tập trung vào hai chỉ số chính: độ chính xác, nhằm đánh giá tính khả thi của mô hình, và tốc độ nhận diện FPS (khung hình trên giây) phản ánh khả năng đáp ứng trong thực tế. Kết quả so sánh được trình bày chi tiết trong Bảng 6.

Bảng 6. So sánh các mô hình huấn luyện.

Mô hình	Độ chính xác		Tốc độ
	Accuracy	F1-Score	
EL-GAN	94,90%	96,26%	10 FPS
LaneATT	96,10%	96,06%	27 FPS
Cascaded-CNN	95,24%	90,82%	60 FPS
LaneNet	96,30%	97,11%	65 FPS

Kết quả trong Bảng 6 tổng hợp so sánh đáp ứng giữa thuật toán LaneNet với ba mô hình cảnh báo có cấu trúc tương đồng bao gồm EL-GAN [20], LaneATT [21] và Cascaded-CNN [22]. Cụ thể, thuật toán EL-GAN tái tạo biên làn và giảm nhiễu, tuy nhiên tốc độ xử lý rất thấp (10 FPS) và yêu cầu tài nguyên cao nên khó triển khai thực tế. Bên cạnh đó, LaneATT gia tăng độ chính xác (96,10%), nhưng tốc độ xử lý chỉ đạt 27 FPS, chưa đáp ứng tốt cho ứng dụng thời gian thực. Ngược lại, Cascaded-CNN có kiến trúc xếp tầng giúp cải thiện độ chính xác (95,24%) và đạt tốc độ xử lý cao đến 60 FPS, tuy nhiên quá trình chỉnh định tham số huấn luyện phức tạp và chiếm dụng nhiều bộ nhớ. Giải pháp đề xuất LaneNet đạt độ chính xác cao nhất (96,30%) với tốc độ xử lý cao (65 FPS) đã cho thấy tiềm năng ứng dụng tại cảng. Bên cạnh đó, khi xét đến chỉ số đánh giá F1-Score thì kết quả áp dụng mạng nơ-ron LaneNet đạt giá trị 97,11%, cao hơn so với các mô hình tham chiếu [20], [21], [22] lần lượt là 0,85%, 1,05% và 6,29%, cho thấy hiệu quả của giải pháp đề xuất.

Cầu RTG có giới hạn vận hành tốc độ tối đa 10km/h, với yêu cầu không xử lý quá nhanh nhưng lại đòi hỏi tính an toàn và độ chính xác cao. Do đó, nghiên cứu này lựa chọn phát triển thuật toán LaneNet để phù hợp, đảm bảo về độ chính xác cũng như khả năng triển khai thực tế. Hạn chế của nghiên cứu là chưa xét các tham số biên dạng container và chiều cao thao tác trong vận hành cầu RTG nhất là trong điều kiện khắc nghiệt.

5. Kết luận

Bài báo phát triển mô hình cảnh báo lệch làn trong vận hành cầu RTG dựa trên mạng nơ-ron LaneNet nhằm đảm bảo an toàn cho người và phương tiện trong quá trình vận hành. Trong nghiên cứu này, tác giả đã xây dựng bộ dữ liệu thực tế từ quá trình vận hành của cầu RTG. Qua đó, làm cơ sở dữ liệu đầu vào cho quá trình huấn luyện mô hình cảnh báo dựa trên cấu trúc mạng nơ-ron học sâu LaneNet. Quá trình thực nghiệm được thực hiện tại cảng Tân Cảng - Cái Mép đã mang lại các kết quả khả thi về đạt độ chính xác 96,3% và tốc độ xử lý 65 FPS, đã chứng minh hiệu quả của giải pháp đề xuất. Trong tương lai, nghiên cứu sẽ tiếp tục được triển khai trên cầu RTG thực tế, hoạt động trong nhiều điều kiện môi trường khắc nghiệt khác nhau. Mục tiêu là vừa cải thiện độ chính xác của mô hình cảnh báo, vừa mở rộng và đa dạng hóa cơ sở dữ liệu huấn luyện nhiều cảng với đặc điểm vận hành khác nhau. Qua đó, mô hình đề xuất không những được nâng cao hiệu suất và khả năng tổng quát mà còn góp phần đảm bảo khả năng ứng dụng hiệu quả tại các cảng khác ngoài khu vực cảng Tân Cảng - Cái Mép. Bên cạnh đó, mô hình đề xuất cũng có thể tích hợp các cảm biến xác định khoảng cách (như lidar, radar) kết hợp kết hợp mô hình học liên tục nhằm hỗ trợ nhận diện tình trạng mất an toàn trong các tình huống xảy ra sự cố bất ngờ.

Đóng góp của các tác giả trong bài báo

Đỗ Việt Dũng: Thành lập giải pháp, Kiểm chứng tính khả thi, Phân tích chính thức. **Nguyễn Đức Ngọc:** Biên soạn dữ liệu, Phân tích dữ liệu, Thành lập giải pháp, Kiểm tra và đánh giá các bản thảo. **Nguyễn Ngọc Trúc:** Phản hồi ý kiến phản biện, Quản lý dữ liệu, Viết - bản thảo gốc. **Nguyễn Tiến Dũng:** Lập trình, tính toán dữ liệu. **Huỳnh Tấn Đệ:** Đề xuất giải pháp, chỉnh sửa bản thảo bài báo.

Tuyên bố không xung đột lợi ích và cam kết bản quyền

Các tác giả tuyên bố về sự không xuất hiện những xung đột tiềm ẩn từ nghiên cứu này, và cam kết bài báo chưa từng được công bố trước đây.

Chia sẻ dữ liệu theo yêu cầu

Dữ liệu sẽ được cung cấp theo yêu cầu.

1st Đỗ Việt Dũng*. *Nhóm nghiên cứu AIT, Trường Đại học Giao thông vận tải Thành phố Hồ Chí Minh, Hồ Chí Minh*

2nd Nguyễn Đức Ngọc. *Công ty Cổ phần Dịch vụ Kỹ thuật Tân Cảng, Hồ Chí Minh*

3rd Nguyễn Ngọc Trúc. *Nhóm nghiên cứu AIT, Trường Đại học Giao thông vận tải Thành phố Hồ Chí Minh, Hồ Chí Minh*

4th Nguyễn Tiến Dũng. *Nhóm nghiên cứu AIT, Trường Đại học Giao thông vận tải Thành phố Hồ Chí Minh, Hồ Chí Minh*

5th Huỳnh Tấn Đệ. *Trường Đại học Tôn Đức Thắng, Hồ Chí Minh*

*Corresponding author: dungdv@ut.edu.vn

Tài liệu tham khảo

- [1] X. Clark, D. Dollar, and A. Micco, "Port efficiency, maritime transport costs, and bilateral trade," *J. Dev. Econ.*, vol. 75, no. 2, pp. 417–450, 2004, doi: 10.1016/j.jdeveco.2004.06.005.
- [2] Hong Kong Marine Department, Marine Industrial Accident Statistics 2015, *Report Of Marine Deptment*, 2016. Accessed: April 5, 2025
- [3] UK Health and Safety Executive, Health and safety in Port and Docks, 2016. Accessed: April 5, 2025 [Online] Available <http://www.hse.gov.uk/ports>.
- [4] M. A. Hamka, "Safety risks assessment on container terminal using hazard identification and risk assessment and fault tree analysis methods," *Procedia engineering*, vol. 194, pp. 307-314, 2017, doi: 10.1016/j.proeng.2017.08. 150.
- [5] J. Yang, N. Zhu, H. Ji and B. He, "Rubber Tyred Gantry Automatic Alignment System based on Computer Vision," in *Proceedings - 2022 8th International Symposium on System Security, Safety, and Reliability*, pp. 85–94, 2022, doi: 10.1109/ISSSR56778.2022.00021.
- [6] M. T. A. Dipu, S. S. Hossain, Y. Arafat and F. B. Rafiq, "Real-time Driver Drowsiness Detection using Deep Learning," *International Journal of Advanced Computer Science and Applications*, vol. 12, pp. 844–850, 2021, doi: 10.14569/IJACSA.2021.0120794.
- [7] S. F. Ezzahra, B. Abdelouahad, M. Khalifa and Q. Mohammed, "Optimizing Port Operations: Synchronization, Collision Avoidance, and Efficient Loading and Unloading Processes," *International Journal of Advanced Computer Science and Applications*, vol. 14, pp. 613–620, 2023, doi: 10.14569/IJACSA.2023.0140768
- [8] V. Chamola, V. Hassija, A. R. Sulthana, D. Ghosh, D. Dhingra and B. Sikdar, "A Review of Trustworthy and Explainable Artificial Intelligence (XAI)," *IEEE Access*, vol. 11, pp. 78994-79015, 2023, doi: 10.1109/ACCESS.2023.3294569.
- [9] Z. Li, F. Liu, W. Yang, S. Peng and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 12, pp. 6999-7019, 2022, doi: 10.1109/TNNLS.2021.3084827
- [10] Y. Hu, Y. Liu and Z. Liu, "A Survey on Convolutional Neural Network Accelerators: GPU, FPGA and ASIC," *2022 14th International Conference on Computer Research and Development (ICCRD)*, 2022, pp. 100-107, doi: 10.1109/ICCRD54409.2022.9730377.
- [11] S. Joshi, M. Manu and A. Mittal, "A Review of the Evolution and Applications of Convolutional Neural Network (CNN)," *2023 2nd International Conference on Edge Computing and Applications (ICECAA)*, 2023, pp. 1109-1114, doi: 10.1109/ICECAA58104.2023.10212250.
- [12] L. Tabelini, R. Berriel, T. M. Paixão, C. Badue, A. F. De Souza and T. Oliveira-Santos, "PolyLaneNet: Lane Estimation via Deep Polynomial Regression," *2020 25th International Conference on Pattern Recognition (ICPR)*, 2021, pp. 6150-6156, doi: 10.1109/ICPR48806.2021. 9412265.
- [13] P. Lu, C. Cui, S. Xu, H. Peng, and F. Wang, "SUPER: A Novel Lane Detection System," in *IEEE Transactions on Intelligent Vehicles*, vol. 6, no. 3, pp. 583-593, 2021, doi: 10.1109/TIV.2021. 3071593.
- [14] N. J. Zakaria, M. I. Shapiai, R. A. Ghani, M. N. M. Yassin, M. Z. Ibrahim, and N. Wahid, "Lane Detection in Autonomous Vehicles: A Systematic Review," in *IEEE Access*, vol. 11, pp. 3729-3765, 2023, doi: 10.1109/ACCESS.2023.3234442.
- [15] ISO Standard 1161, 2023. Accessed: April 5, 2025, [Online] Available <https://www.iso.org/standard/65553.html>.
- [16] OSHA 1910.179, Accessed: April 5, 2025, [Online] Available: <https://www.osha.gov/laws-regs/regulations/standardnumber/1910/1910.179>.

- [17] D. Neven, B. D. Brabandere, S. Georgoulis, M. Proesmans and L. V. Gool, "Towards End-to-End Lane Detection: an Instance Segmentation Approach," *2018 IEEE Intelligent Vehicles Symposium (IV)*, 2018, pp. 286-291, doi: 10.1109/IVS.2018.8500547.
- [18] D. Liang, Y. Guo, S. Zhang, T. Mu and X. Huang, "Lane detection: A survey with new results," *J. Comput. Sci. Technol.*, vol. 35, pp. 493-505, 2020, doi: 10.1007/s11390-020-0476-4.
- [19] D. Neven, B. De Brabandere, S. Georgoulis, M. Proesmans and L. Van Gool, "Towards end-to-end lane detection: an instance segmentation approach," in *Proc. IEEE Int. Veh. Symp.*, 2018, pp. 286-291, doi: 10.1109/IVS.2018.8500547.
- [20] M. Ghafoorian, C. Nugteren, N. Baka, O. Booij and M. Hofmann, "EL-GAN: Embedding loss driven generative adversarial networks for lane detection," in *Lecture Notes in Computer Science*, vol. 11129 LNCS, pp. 256-272, 2019, doi: 10.48550/arXiv.1806.05525.
- [21] L. Tabelini, R. Berriel, T. M. Paixão, C. Badue, A.F. de Souza, and T. Oliveira-Santos, "Keep your Eyes on the Lane: Real-time Attention-guided Lane Detection," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 294-302, 2021, doi: 10.48550/arXiv.2010.12035.
- [22] F. Pizzati, M. Allodi, A. Barrera, and F. García, "Lane Detection and Classification Using Cascaded CNNs," in *Lecture Notes in Computer Science*, vol. 12014 LNCS, pp. 95-103, 2020, doi: 10.48550/arXiv.1907.01294.