

# NGHIÊN CỨU MÔ HÌNH TRÍ TUỆ NHÂN TẠO ĐỂ PHÁT HIỆN PCB LỖI TRONG SẢN XUẤT CÔNG NGHIỆP

Bùi Văn Hiệu

*Trường Đại học Thủy lợi, email: hieubv@tlu.edu.vn*

## 1. GIỚI THIỆU

Bảng mạch in (PCB) là sản phẩm quan trọng của ngành công nghiệp sản xuất thiết bị điện tử. Trong nhiều thập kỷ, PCB đã được phát triển, điều chỉnh để sử dụng trong công nghiệp sản xuất và sinh hoạt. PCB là thành phần chính trong hầu hết các thiết bị điện tử và đã được sử dụng trong các lĩnh vực như thiết bị công nghiệp, hậu cần, quốc phòng, hàng không, ô tô và y tế. PCB là những tấm mỏng rắn được chế tạo từ vật liệu nhiều lớp, sợi thủy tinh hoặc epoxy tổng hợp tạo thành một tấm cứng hỗ trợ chip và linh kiện điện tử. Các bảng này được thiết kế với các đường dẫn điện, tạo thành mạch và cấp nguồn cho các thiết bị điện tử gắn với PCB. Các ngành sản xuất và chế tạo đã cố gắng đảm bảo chất lượng 100% cho tất cả các PCB bằng cách loại bỏ đi các sản phẩm lỗi. Theo phương pháp thông thường, các khuyết tật được phát hiện ban đầu bằng máy kiểm tra tự động (AOI). Nhiều bảng được phân loại là bị lỗi bởi máy AOI có thể không bị lỗi. Máy có thể phân loại sai một PCB bị lỗi do vết xước hoặc lỗ nhỏ hoặc sự hiện diện của các hạt nano như bụi, mảnh giấy hoặc bột khí nhỏ. Kết quả này có thể dẫn đến việc máy AOI phân loại PCB không bị lỗi là bị lỗi. Để khắc phục điều này, các kỹ sư kiểm tra lại từng PCB để xác nhận lại một lần nữa. Tuy nhiên, việc dựa vào các kỹ sư kiểm định đòi hỏi nguồn nhân lực đáng kể cũng như được đào tạo bài bản. Hơn nữa, ngay cả những người vận hành lành nghề cũng có thể mắc lỗi trong quá trình kiểm tra.

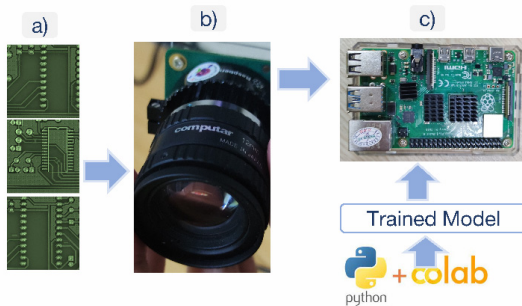
Phát hiện lỗi PCB bằng hình ảnh tự động cung cấp thông tin định lượng và nhanh chóng về khuyết tật bề mặt và do đó có thể là một phương pháp hiệu quả trong quá trình sản xuất. Một vài ví dụ về các phương pháp phát hiện khuyết tật PCB có thể được tìm thấy trong tài liệu [1]. Thông thường, phương pháp đối sánh mẫu được sử dụng để phát hiện các khuyết tật trong PCB. Một phương pháp khác để phát hiện lỗi PCB là phép trừ hình ảnh sử dụng OPENCV. Tuy nhiên, các thuật toán phát hiện này được giới hạn ở một số loại lỗi cụ thể trong PCB. Trong những năm gần đây, đã có những tiến bộ đáng kể trong việc phát hiện lỗi sản phẩm với việc sử dụng mô hình trí tuệ nhân tạo có khả năng nhận dạng và phát hiện nhiều loại lỗi từ hình ảnh được thu nhận. Mô hình xử lý ảnh dùng trí tuệ nhân tạo có nhiều ưu điểm về sự linh hoạt và chính xác trong phát hiện lỗi, tuy nhiên việc lựa chọn mô hình đảm bảo tốc độ xử lý nhanh phù hợp với dữ liệu và phần cứng cấu hình thấp cho các ứng dụng công nghiệp vẫn đang là những thách thức.

Bài báo này thể hiện nỗ lực của tác giả trong việc phát triển mô hình trí tuệ nhân tạo để phân loại sản phẩm PCB lỗi từ hình ảnh. Mô hình được phát triển trên nền mạng MobileNets [2] (một dạng mô hình nhẹ) để tiết kiệm thời gian huấn luyện và thực thi từ đó có thể nhận biết sản phẩm lỗi theo thời gian thực. Ngoài ra, mô hình cũng được điều chỉnh để phù hợp với dữ liệu sẵn có và hoạt động được trên thiết bị phần cứng có cấu hình thấp.

## 2. PHƯƠNG PHÁP NGHIÊN CỨU

### 2.1. Hệ thống phát hiện sản phẩm lỗi

Một hệ thống phát hiện lỗi sản phẩm bao gồm máy ảnh có độ phân giải cao (trong nghiên cứu này chúng tôi sử dụng Raspberry Pi High Quality Camera 12.3 megapixel Sony IMX477 sensor (Hình 1b)) kết hợp với máy tính Raspberry Pi với trọng số của mô hình trí tuệ nhân tạo đã được huấn luyện hình 1c. Kết quả thu được sau khi xử lý ảnh được chuyển thành tín hiệu đầu ra của máy tính để điều khiển các thiết bị khác của hệ thống như đèn tín hiệu, cánh tay rô bốt...



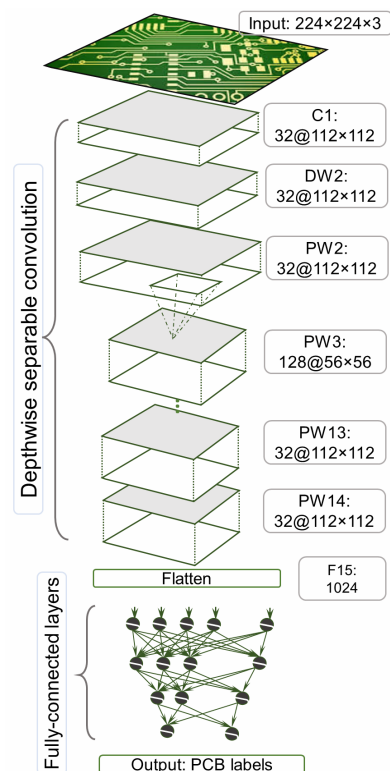
Hình 1. Quá trình phát hiện sản phẩm lỗi

### 2.2. Mạng MobileNets

Để phát triển được những ứng dụng của trí tuệ nhân tạo trên các thiết bị công nghiệp cần có các mô hình phù hợp với thời gian xử lý nhanh và chi phí tính toán thấp. MobileNets [2] là một trong những mô hình ưa chuộng thường được sử dụng do có số lượng tính toán ít và độ chính xác cao.

Cấu tạo của mạng MobileNets gồm 2 phần chính: Phân trích xuất đặc trưng và phần mạng kết nối đầy đủ (Hình 2). Phần trích xuất đặc trưng là một kiến trúc mạng nơ-ron tích chập theo chiều sâu [2]. Với mạng tích chập 2 chiều thông thường các phép tính toán sẽ được thực hiện trên toàn bộ chiều sâu của dữ liệu. Do đó, số lượng tham số của mô hình sẽ gia tăng đáng kể và phụ thuộc vào độ sâu của lớp trước đó. MobileNets sử dụng tích chập chiều sâu (Depthwise Convolution) để sẽ chia khối mảng dữ liệu đầu vào 3 chiều thành những lát cắt ma trận theo độ sâu và thực hiện phép tích chập

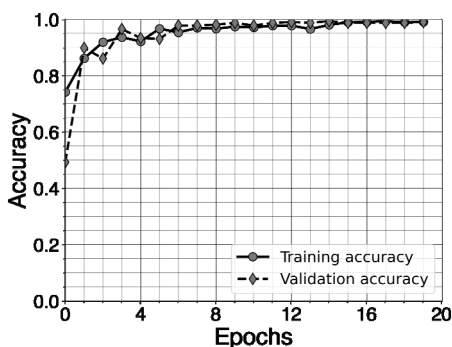
trên từng lát cắt. Tiếp đó, tích chập điểm (Pointwise Convolution) được áp dụng để thay đổi chiều sâu mà không thay đổi chiều rộng và chiều cao của mảng dữ liệu. Nhờ áp dụng phương pháp tích chập trên từng lát cắt mà khối lượng tính toán của mô hình MobileNets trong quá trình trích xuất các đặc trưng giảm đi đáng kể. Tiếp đó, các tín hiệu đặc trưng thu được sẽ được phẳng hóa thành ma trận một cột để có thể kết nối với mạng kết nối đầy đủ (FCN). Các đặc trưng này sẽ được đi qua mạng kết nối đầy đủ 3 lớp nơ-ron ẩn và đưa ra kết quả dự đoán lỗi cho PCB. Sai số dự đoán có được từ sự so sánh kết quả dự đoán và dữ liệu chuẩn sẽ được truyền lại các lớp trước và cập nhật lại trọng số của các lớp. Quá trình huấn luyện này lặp lại với các tập dữ liệu khác nhau và trọng số của mô hình được cập nhật đến khi kết quả dự đoán và dữ liệu có sự sai khác nhỏ ở mức chấp nhận được. Trọng số của mô hình đạt được bởi quá trình huấn luyện thể hiện mối quan hệ giữa các đặc trưng của ảnh và nhãn lỗi của PCB. Trọng số này sẽ được sử dụng để dự đoán cho các hình ảnh thu thập được từ camera theo thời gian thực.



Hình 2. Cấu trúc mạng MobileNets[2]

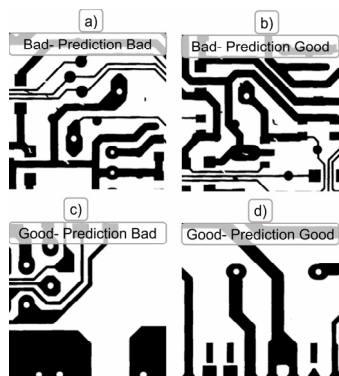
### 3. KẾT QUẢ NGHIÊN CỨU

Kết quả huấn luyện của mô hình Hình 3a thể hiện mối quan hệ của độ chính xác dự báo (Accuracy) và số lần duyệt qua tập dữ liệu (Epochs). Biểu đồ cho thấy ở giai đoạn đầu độ chính xác tăng rất nhanh, ở giai đoạn sau độ chính xác tăng chậm dần và tiệm cận về 100%. Giá trị lớn nhất độ chính xác đạt được với bộ dữ liệu kiểm tra (Training) và dữ liệu xác nhận (Validation) là 98% qua 20 lần duyệt dữ liệu. Những kết quả này thể hiện sự phù hợp của cấu trúc mạng và tập dữ liệu huấn luyện.



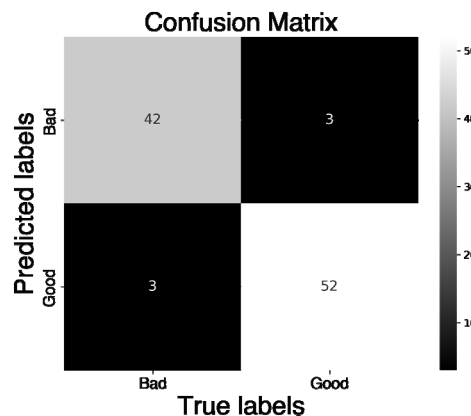
Hình 3. Kết quả huấn luyện mô hình

Hình 4 thể hiện 4/100 kết quả đại diện cho 4 loại kết quả mô hình trả về. Hình 4a (True Positive-TP) thể hiện kết quả dự đoán là có lỗi những sản phẩm có lỗi hình 4d (True Negative-TN) thể hiện kết quả dự đoán là không có lỗi cho sản phẩm không có lỗi. Hình 4b (False Negative-FN) thể hiện kết quả dự đoán là không có lỗi cho những sản phẩm có lỗi. Hình 4c (False Positive-FP) thể hiện kết quả dự đoán lỗi cho những sản phẩm không lỗi. Những sản phẩm bị dự báo sai có lỗi khác nhiều với lỗi được huấn luyện. Tăng số ảnh huấn luyện sẽ giúp khắc phục điều này.



Hình 4. Kết quả dự đoán 4/100 hình ảnh

Hình 5 thể hiện ma trận lỗi để đánh giá mô hình. Theo đó, kết quả dự báo chính xác là các ô màu xám và màu trắng (TN, TP) bao gồm 94 mẫu hình ảnh và kết quả dự báo sai là các ô màu đen (FN, FP) gồm 6 mẫu hình ảnh. Xét trên tổng thể mô hình cho kết quả dự báo tốt với tỉ lệ chính xác 94%.



Hình 5. Ma trận lỗi của mô hình dự đoán

### 4. KẾT LUẬN

Sử dụng mô hình trí tuệ nhân tạo để phát hiện lỗi PCB trong công nghiệp sản xuất là phương pháp cho hiệu quả cao, linh hoạt giúp giảm chi phí sản xuất, nâng cao chất lượng sản phẩm. Trong nghiên cứu này, một mô hình trí tuệ nhân tạo đã được phát triển dựa trên mạng MobileNets để phát hiện sản phẩm PCB lỗi từ hình ảnh. Kết quả phát hiện lỗi của mô hình đạt độ chính xác cao (94%) và có thể xử lý theo thời gian thực với chi phí tính toán thấp, phù hợp cho các ứng dụng công nghiệp. Trong bước tiếp theo, kết quả của nghiên cứu sẽ được phát triển để xác định vị trí các lỗi và áp dụng vào thiết bị phần cứng đã được tác giả xây dựng.

### 5. TÀI LIỆU THAM KHẢO:

- [1] B. Xia, J. Cao and C. Wang, "SSIM-NET: Real-Time PCB Defect Detection Based on SSIM and MobileNet-V3," 2019 2nd (WCMEIM), 2019, pp. 756-759.
- [2] Howard, Andrew G., et al. "Mobilenets: Efficient convolutional neural networks for mobile vision applications." arXiv preprint arXiv:1704.04861 (2017).