

PHÁT HIỆN BỆNH BỤI PHỔI SILIC NGHỀ NGHIỆP TỪ HÌNH ẢNH X-QUANG NGỰC BẰNG KIẾN TRÚC DENSENET

Nguyễn Thị Tân Tiến*,

* Trường Đại học Y-Dược, Đại học Thái Nguyên

Tóm tắt: Bệnh bụi phổi silic nghề nghiệp (BPSi) là một trong những bệnh lý nghiêm trọng ảnh hưởng đến sức khỏe người lao động, đặc biệt ở các ngành nghề tiếp xúc với bụi chứa silic tự do. Trong nghiên cứu này, chúng tôi sử dụng mô hình DenseNet201, một kiến trúc mạng nơ-ron tích chập (CNN) tiên tiến, để hỗ trợ chẩn đoán BPSi từ hình ảnh X-quang ngực. Kết quả thực nghiệm cho thấy mô hình đạt độ chính xác cao, đặc biệt trong việc phân biệt giữa nhóm bình thường và nhóm mắc bệnh bụi phổi silic. Bên cạnh đó, Grad-CAM được sử dụng để trực quan hóa các vùng đặc trưng mà mô hình tập trung, minh họa tính hiệu quả và đáng tin cậy của DenseNet201 trong việc phát hiện các bất thường đặc trưng của bệnh BPSi.

Từ khóa: Học sâu, DenseNet, CNN, Bụi phổi silic, X-quang ngực.

I. MỞ ĐẦU

Bệnh bụi phổi silic nghề nghiệp là một trong những bệnh nghề nghiệp phổ biến và nghiêm trọng nhất trên thế giới[1], gây ảnh hưởng lớn đến sức khỏe người lao động, đặc biệt trong các ngành công nghiệp tiếp xúc với bụi silic tự do như khai thác mỏ, xây dựng, sản xuất vật liệu chịu lửa và sản xuất thủy tinh [2, 3]. Bệnh phát triển do sự tích lũy hạt bụi silic trong phổi qua nhiều năm, dẫn đến viêm nhiễm và xơ hóa nhu mô phổi. Đây là một bệnh mãn tính, không thể hồi phục, và có thể gây ra các biến chứng nghiêm trọng như suy hô hấp, lao phổi, hoặc thậm chí ung thư phổi. Nếu không được phát hiện và điều trị kịp thời, bệnh có thể dẫn đến tỷ lệ tử vong cao, đặc biệt ở những người lao động tiếp xúc lâu dài với bụi silic[4]. Do đó, việc phát hiện và điều trị kịp thời rất quan trọng để người bệnh có cơ hội cải thiện chất lượng cuộc sống, ngăn ngừa các biến chứng nghiêm trọng của bệnh, kiểm soát tỷ lệ tử vong [5, 6]. Hiện nay, việc chẩn đoán bệnh chủ yếu dựa vào hình ảnh X-quang ngực và các thông tin lâm sàng, tuy nhiên, phương pháp này vẫn còn nhiều hạn chế. Sự đa dạng và phức tạp của biểu hiện bệnh trên hình ảnh X-quang đòi hỏi bác sĩ phải có kinh nghiệm và kỹ năng chuyên sâu để đưa ra chẩn đoán chính xác. Điều này dẫn đến những thách thức không nhỏ trong các tình huống cần chẩn đoán nhanh và chính xác, đặc biệt ở những khu vực thiếu hụt bác sĩ chuyên khoa[7]. Bên cạnh đó, việc phụ thuộc vào đánh giá

chủ quan của bác sĩ cũng làm gia tăng nguy cơ không nhất quán trong kết quả chẩn đoán giữa các chuyên gia khác nhau[8].

Trong những năm gần đây, các phương pháp học sâu (deep learning) đã nổi lên như một giải pháp tiềm năng để giải quyết các hạn chế trong chẩn đoán bệnh bụi phổi silic. Đặc biệt, mạng nơ-ron tích chập (Convolutional Neural Networks - CNN) đã chứng minh hiệu quả vượt trội trong việc trích xuất các đặc trưng từ dữ liệu hình ảnh y khoa, giúp cải thiện đáng kể độ chính xác và tốc độ chẩn đoán. Các mô hình CNN tiên tiến như CheXNet, ResNet, và DarkNet đã được áp dụng thành công trong chẩn đoán các bệnh phổi khác như viêm phổi và COVID-19, mở ra cơ hội mới cho việc ứng dụng các công nghệ này vào chẩn đoán bệnh bụi phổi silic.

Trong số các kiến trúc CNN, DenseNet nổi bật nhờ khả năng kết nối dày đặc giữa các lớp, giúp tái sử dụng thông tin và tối ưu hóa việc truyền gradient trong mô hình. Đặc điểm này làm cho DenseNet vượt trội trong việc xử lý dữ liệu hình ảnh phức tạp, đặc biệt là các đặc trưng nhỏ và tinh tế trên hình ảnh X-quang. Không chỉ cải thiện hiệu quả chẩn đoán, DenseNet còn giảm thiểu yêu cầu về lượng dữ liệu huấn luyện lớn – một thách thức đáng kể trong lĩnh vực y học chuyên sâu.

Nghiên cứu này áp dụng kiến trúc DenseNet, với đặc điểm nổi bật là các khối Dense Block được kết nối chặt chẽ. Kiến trúc này cho phép lưu trữ và truyền tải thông tin hiệu quả qua nhiều lớp, giúp mô hình trích xuất đặc trưng phức tạp ngay cả khi dữ liệu hạn chế. Việc ứng dụng DenseNet trong chẩn đoán bệnh bụi phổi silic không chỉ nâng cao hiệu quả của các hệ thống hỗ trợ ra quyết định y khoa mà còn cung cấp một công cụ hữu ích, hỗ trợ bác sĩ đưa ra những chẩn đoán chính xác và đáng tin cậy hơn.

II. CÁC NGHIÊN CỨU LIÊN QUAN

A. Phương pháp chẩn đoán bởi bác sĩ dựa trên hình ảnh X-quang ngực

Hình ảnh X-quang ngực (CXR) từ lâu đã là công cụ chủ yếu để phát hiện các tổn thương phổi, bao gồm các đám mờ liên quan đến bệnh bụi phổi silic. Phương pháp này không chỉ hỗ trợ chẩn đoán sớm mà còn giúp phân loại các giai đoạn bệnh [9]. Phương pháp này thường dựa vào kinh nghiệm của bác sĩ chẩn đoán hình ảnh để phát hiện các dấu hiệu bất thường trong phổi. Tuy nhiên, việc đánh giá này tốn nhiều thời gian, đòi hỏi bác sĩ chẩn đoán phải có kinh nghiệm, có thể gây ra sự không nhất quán về kết quả chẩn đoán giữa các bác sĩ, chuyên gia khác nhau [10, 11]. Bên cạnh đó, sự gia tăng các bệnh lý về phổi, nhu cầu

Tác giả liên hệ: Nguyễn Thị Tân Tiến

Email: nguyenthitantuan@tnmc.edu.vn

Đến tòa soạn: 12/2024, chỉnh sửa: 01/2025, chấp nhận đăng: 02/2025

chẩn đoán nhanh, chính xác đã thúc đẩy phát triển các hệ thống hỗ trợ chẩn đoán bằng máy tính (CAD) [12, 13]. Những hệ thống CAD sử dụng các kỹ thuật xử lý và phân tích hình ảnh tiên tiến, trích xuất các đặc điểm quan trọng từ hình ảnh, cung cấp thông tin hỗ trợ, giảm bớt thời gian chẩn đoán, giúp tăng cường độ chính xác và nhất quán trong đánh giá. [14, 15].

Bên cạnh hệ thống hỗ trợ chẩn đoán bằng máy tính (CAD), một số nghiên cứu đã phát triển các hệ thống hỗ trợ quyết định lâm sàng (CDSS) nhằm cung cấp các đề xuất chẩn đoán và điều trị toàn diện hơn. Các hệ thống CDSS này kết hợp thông tin từ ảnh X-quang ngực (CXR) với các dữ liệu y khoa khác của bệnh nhân, chẳng hạn như tiền sử bệnh, để đưa ra các gợi ý phù hợp và chính xác hơn cho từng cá nhân [16]. Bên cạnh đó, các hệ thống báo cáo tiêu chuẩn hóa cho CXR cũng được phát triển nhằm tạo ra sự đồng nhất trong quy trình chẩn đoán giữa các bác sĩ. Những sáng kiến này không chỉ giúp hạn chế sự khác biệt trong kết quả chẩn đoán mà còn cải thiện tính hiệu quả trong trao đổi thông tin giữa các chuyên gia y tế [17].

B. Các phương pháp học sâu

Phân tích hình ảnh y tế đã chứng kiến một bước phát triển quan trọng, chuyển từ các phương pháp học máy truyền thống sang các phương pháp học sâu. Thay vì dựa vào các đặc trưng được thiết kế thủ công như trước, học sâu, đặc biệt là Mạng nơ-ron tích chập (CNN), cho phép trích xuất đặc trưng tự động từ dữ liệu thô. CNN nổi bật nhờ khả năng học các đặc trưng bất biến thông qua các lớp tích chập, trở thành công cụ then chốt trong phân loại hình ảnh. Sharma et al. [18] và Stephen et al. [19] đã minh chứng điều này khi phát triển các kiến trúc CNN đơn giản để phân loại X-quang ngực (CXR). Dù dữ liệu hạn chế, các nhà nghiên cứu đã sử dụng kỹ thuật tăng cường dữ liệu để cải thiện độ chính xác của mô hình, nhưng vẫn còn hạn chế trong việc tạo ra những cải tiến đáng kể.

Một ví dụ khác về việc sử dụng các kiến trúc tích chập rất sâu được chứng minh bằng ChexNet do Rajpurkar và cộng sự [20] đề xuất. Kiến trúc của họ xác định chính xác bệnh viêm phổi và tiến xa hơn trong việc định vị các khu vực viêm phổi tối đa theo kiểu bản đồ nhiệt. Zech và cộng sự [21] đã nghiên cứu hiệu suất đào tạo ChexNet trên một tập dữ liệu nội bộ về bệnh viêm phổi và CXR y tế bình thường và thử nghiệm nó trên một tập dữ liệu bên ngoài.

Những nghiên cứu này khẳng định tầm quan trọng của CNN trong lĩnh vực phân tích hình ảnh y tế, đặc biệt trong chẩn đoán các bệnh về đường hô hấp. Sự ra đời của các mô hình học sâu như CNN đã mở ra một bước ngoặt lớn, vượt qua nhiều hạn chế của các phương pháp học máy truyền thống. Với khả năng học đặc trưng hiệu quả và khả năng ứng dụng rộng rãi, CNN tiếp tục chứng tỏ là một công cụ mạnh mẽ trong việc phân loại và chẩn đoán các bệnh lý phức tạp liên quan đến hình ảnh y tế.

C. Các nghiên cứu về DenseNet trong y khoa

DenseNet (Densely Connected Convolutional Network) [22] là một kiến trúc mạng học sâu nổi bật nhờ vào khả năng kết nối các lớp dày đặc, giúp tối ưu hóa quá trình truyền gradient và giảm thiểu hiện tượng vanishing gradient trong các mô hình sâu. DenseNet đã được ứng dụng rộng rãi trong y khoa, đặc biệt là trong phân tích ảnh y khoa để chẩn đoán các bệnh phổi, bao gồm COVID-19 và viêm phổi.

Trong các nghiên cứu gần đây về chẩn đoán COVID-19, mô hình DenseNet đã cho thấy hiệu quả vượt trội trong việc phân loại hình ảnh X-quang ngực. Ví dụ, trong nghiên cứu về COVID-19 sử dụng DenseNet-121, mô hình đạt độ chính xác và F1-score cao nhờ vào khả năng học và lưu trữ đặc trưng phức tạp của hình ảnh [23, 24]. DenseNet cũng đã được sử dụng để chẩn đoán viêm phổi, với các biến thể như DenseNet-121 và DenseNet-201 đạt hiệu suất cao, nhờ vào khả năng truyền thông tin dày đặc giữa các lớp, giúp mô hình nhận diện rõ các đặc điểm của bệnh lý trong ảnh X-quang [25]. Laboni Sarke và cộng sự [23] đã sử dụng kiến trúc DenseNet-121 kết hợp với kỹ thuật chuyển giao học tập từ CheXNet giúp mô hình COVID-DenseNet học hỏi từ kiến thức đã có, cải thiện hiệu suất và rút ngắn thời gian huấn luyện.

Những ứng dụng thành công này cho thấy tiềm năng của DenseNet trong chẩn đoán các bệnh lý phổi khác, như bệnh bụi phổi silic, vốn có biểu hiện trên ảnh X-quang tương tự với nhiều bệnh phổi khác.

III. CƠ SỞ DỮ LIỆU

A. Thu thập dữ liệu

Quá trình thu thập dữ liệu là một bước quan trọng trong việc xây dựng hệ thống hỗ trợ chẩn đoán bệnh bụi phổi silic nghề nghiệp. Bộ dữ liệu được thu thập, xây dựng và được gán nhãn chính xác bởi các bác sĩ chuyên gia trong lĩnh vực y học, có tên là BSIPTIT.

Hình ảnh X-quang ngực đóng vai trò cốt lõi trong bộ dữ liệu BSIPTIT. Đây là phương pháp hình ảnh thường được sử dụng để đánh giá các tổn thương phổi và phát hiện bệnh bụi phổi silic. Các hình ảnh X-quang trong bộ dữ liệu được phân loại thành hai nhóm chính:

Nhóm bình thường: Bao gồm các hình ảnh của phổi không có dấu hiệu bất thường hoặc tổn thương.

Nhóm mắc bệnh bụi phổi silic: Bao gồm các hình ảnh cho thấy các tổn thương điển hình như nốt mờ nhỏ, đám mờ lớn, dày thành phế quản, hoặc hình ảnh phù tổ chức kẽ.

Để đảm bảo chất lượng dữ liệu:

Các hình ảnh được thu thập từ hệ thống chụp X-quang kỹ thuật số hiện đại, với độ phân giải cao nhằm cung cấp thông tin chi tiết về tổn thương.

Quá trình chẩn đoán và gán nhãn dữ liệu được thực hiện dựa trên hướng dẫn của ILO 2011 và Thông tư 15/2016/TT-BYT, đảm bảo tính chính xác và đồng nhất.

Các trường hợp không rõ ràng hoặc hình ảnh bị nhiễu được loại bỏ để đảm bảo tính toàn vẹn của dữ liệu.

Nhờ vào chất lượng và độ chính xác của dữ liệu X-quang, hệ thống hỗ trợ chẩn đoán có thể học được các đặc trưng phức tạp và đưa ra dự đoán chính xác hơn. Điều này giúp các bác sĩ cải thiện độ chính xác và hiệu quả trong chẩn đoán bệnh bụi phổi silic nghề nghiệp.


• **Đối tượng:** Bộ dữ liệu thu thập trực tiếp từ 2089 công nhân có nguy cơ cao mắc bệnh bụi phổi silic do tiếp xúc thường xuyên với bụi silic trong các ngành công nghiệp như khai thác mỏ, xây dựng và sản xuất.

• **Địa điểm:** Các hình ảnh được thu thập từ các bệnh viện chuyên khoa ở các tỉnh như Thái Nguyên, Hải Dương, Bình Định, Phú Yên, và Đồng Nai.


• **Tiêu chuẩn chẩn đoán:** Tất cả các trường hợp bệnh bụi phổi silic đều được xác nhận theo tiêu chuẩn của ILO 2000 để đảm bảo tính nhất quán và độ tin cậy. Các hình ảnh X-quang được chụp với kích thước tiêu chuẩn là 35 x 43 cm.

• **Số lượng mẫu:** Từ 2089 người lao động này, có 535 trường hợp được chẩn đoán mắc bệnh bụi phổi silic, với hình ảnh X-quang ngực của họ được đưa vào lớp Silicosis trong bộ dữ liệu.

Hình 1 và hình 2 đưa ra hình ảnh chụp X-quang ngực tiêu biểu của người bình thường và người mắc bệnh bụi phổi silic.



Hình 1. Hình ảnh X-quang ngực của người không mắc bệnh



Hình 2. Hình ảnh X-quang ngực của người mắc bệnh bụi phổi silic nghề nghiệp

B. Tiền xử lý dữ liệu và tăng cường dữ liệu

Tiền xử lý dữ liệu: Đây là một bước quan trọng nhằm đảm bảo rằng hình ảnh X-quang và các dữ liệu liên quan được chuẩn bị kỹ lưỡng cho quá trình huấn luyện mô hình học sâu.

Định dạng dữ liệu: Dữ liệu thu thập được lưu dưới định dạng dem (DICOM), là định dạng tiêu chuẩn trong y tế để lưu trữ hình ảnh X-quang cùng các thông tin liên quan. Định dạng này cho phép hình ảnh được xem và phân tích qua các phần mềm chuyên dụng như MicroDicom hoặc RadiAnt.

Quy trình xử lý: Mặc dù định dạng DICOM thuận tiện cho lưu trữ và hiển thị hình ảnh, việc chuyển đổi và lưu hình ảnh dưới dạng jpg hoặc png có thể tốn thời gian và đòi hỏi nhiều công sức. Để tối ưu quá trình này, tác giả đã áp dụng các bước chuyển đổi tự động bằng Python, giúp thống nhất và tự động hóa việc chuyển đổi hình ảnh sang định dạng jpg. Các hình ảnh được chuẩn hóa và thay đổi kích thước về 224×224×3 để phù hợp với đầu vào của DenseNet.


Tổng quan bộ dữ liệu: Bộ dữ liệu cuối cùng bao gồm 2089 hình ảnh X-quang, trong đó có:

- 535 hình ảnh của bệnh nhân mắc bệnh silicosis.
- 1554 hình ảnh của người không mắc bệnh.

Tăng cường dữ liệu: Để cải thiện độ chính xác và khả năng tổng quát của mô hình, kỹ thuật tăng cường dữ liệu (data augmentation) được áp dụng. Các kỹ thuật như xoay góc, lật ngang, phóng to, thay đổi độ sáng để tạo ra nhiều biến thể của cùng một ảnh gốc, tăng tính đa dạng của dữ liệu, giúp mô hình học các đặc điểm phức tạp và đa dạng của dữ liệu.

IV. ÁP DỤNG MÔ HÌNH DENSENET PHÁT HIỆN BỆNH BỤI PHỔI SILIC NGHỀ NGHIỆP

A. Mô hình tổng quan



Hình 3. Mô hình tổng quan

Hình 3 minh họa mô hình tổng quan sử dụng kiến trúc DenseNet để hỗ trợ phát hiện bệnh bụi phổi silic nghề nghiệp từ hình ảnh X-quang ngực.

Input: Lô ảnh X-quang ngực trong tập dữ liệu được chia thành hai nhóm: Nhóm bình thường, nhóm mắc bệnh bụi phổi silic nghề nghiệp.

Output: Mô hình dự đoán nhãn phân loại tương ứng cho từng hình ảnh (0 - bình thường, 1 - mắc bệnh).

DenseNet là một kiến trúc mạng nơ-ron tích chập (CNN) tiên tiến, nổi bật trong lĩnh vực nhận dạng hình ảnh [22, 26]. Không giống như các mạng truyền thống chỉ kết nối các lớp liên kế, DenseNet được thiết kế với các kết nối dày đặc, trong đó mỗi lớp đầu ra không chỉ cung cấp đầu vào cho lớp tiếp theo mà còn kết nối với tất cả các lớp kế tiếp. Điều này giúp tối ưu hóa việc truyền thông tin và tái sử dụng đặc trưng, giảm số lượng tham số, giải quyết vấn đề mất mát gradient thường gặp trong các mạng sâu. DenseNet có nhiều biến thể, bao gồm DenseNet-121, DenseNet-169, DenseNet-201, DenseNet-264 với số lượng lớp khác nhau để phù hợp với các yêu cầu cụ thể của từng bài toán [27-29]. Trong bài toán phát hiện bệnh bụi phổi silic nghề nghiệp, DenseNet-201 được áp dụng nhờ khả năng xử lý các đặc trưng tinh tế từ ảnh X-quang ngực. Mỗi Dense Block trong mô hình gồm các bước: Chuẩn hóa Batch (BatchNorm); hàm kích hoạt ReLU; lớp tích chập (Convolutional Layer). Sau mỗi Dense Block, Transition Layer được thêm vào để giảm kích thước dữ liệu và kiểm soát quá khớp. Kết hợp với các bước Pooling và Softmax Classification, mô hình cho ra kết quả chẩn đoán chính xác

Mô hình DenseNet không chỉ cho phép học các đặc trưng phức tạp từ ảnh X-quang mà còn giúp cải thiện độ chính xác trong chẩn đoán. Việc áp dụng mô hình này vào phát hiện bệnh bụi phổi silic nghề nghiệp không chỉ hỗ trợ bác sĩ đưa ra chẩn đoán nhanh chóng mà còn tăng độ tin cậy trong các kết quả phân loại bệnh.

B. Kiến trúc mô hình DenseNet201

DenseNet-201 là một kiến trúc mạng nơ-ron tích chập (CNN) tiên tiến, được thiết kế để tối ưu hóa quá trình truyền thông tin và tái sử dụng đặc trưng trong các lớp mạng[30-32]. Điểm nổi bật của DenseNet nằm ở kết nối dày đặc, trong đó mỗi lớp đầu ra không chỉ kết nối đến lớp tiếp theo mà còn đến tất cả các lớp kế tiếp. Điều này giúp giảm thiểu vấn đề mất mát gradient, tăng cường khả năng học và giảm số lượng tham số cần thiết trong mạng.

Kiến trúc DenseNet-201 bao gồm bốn Dense Block, mỗi Dense Block được cấu thành từ các lớp tích chập với kích thước 1x1 và 3x3 xen kẽ. Số lượng các lớp trong từng Dense Block lần lượt là 6, 12, 48, và 32 lớp. Giữa các Dense Block, một Transition Layer được chèn vào, có chức năng giảm kích thước đặc trưng bằng một lớp tích chập 1x1 và phép gộp trung bình (Average Pooling) với kích thước 2x2 và bước nhảy (stride) là 2. Sau Dense Block cuối cùng, một lớp Pooling toàn cục (Global Average Pooling) được áp dụng, kết nối với lớp phân loại sử dụng hàm Softmax để phân loại hình ảnh.

Để cải thiện khả năng hội tụ, mô hình sử dụng hàm tối ưu Adam với tốc độ học ban đầu là 0.001. Hơn nữa, một lớp Dropout với tỷ lệ 0.25 được chèn vào trước lớp phân loại để giảm hiện tượng quá khớp.

Trong bài toán phát hiện bệnh bụi phổi silic nghề nghiệp, DenseNet-201 được áp dụng nhờ khả năng học và

tái sử dụng các đặc trưng nhỏ và tinh tế từ hình ảnh X-quang ngực. Kết quả phân loại (0 - bình thường, 1 - mắc bệnh) được đưa ra sau khi hình ảnh được phân tích qua các khối Dense Block và lớp phân loại.

Việc áp dụng DenseNet-201 không chỉ mang lại hiệu quả cao trong chẩn đoán mà còn giảm thiểu thời gian xử lý, góp phần hỗ trợ bác sĩ đưa ra kết luận chính xác và nhanh chóng hơn.

Layer Label	Input Layer Dimension	Output Dimension
Input Layer		224 × 224 × 3
Convolution	112 × 112	Filter size = 7 × 7 Stride = 2 Padding = 3
pooling	56 × 56	Maximum Pooling = 3 × 3 Stride = 2
Dense Block 1	56 × 56	$\begin{bmatrix} 1 & \times & 1 \\ 3 & \times & 3 \end{bmatrix} \times 6$
Transition Layer 1	56 × 56 28 × 28	1 × 1 convolution 2 × 2 average pooling, stride = 2
Dense Block 2	28 × 28	$\begin{bmatrix} 1 & \times & 1 \\ 3 & \times & 3 \end{bmatrix} \times 12$
Transition Layer 2	28 × 28 14 × 14	1 × 1 convolution 2 × 2 average pooling, stride = 2
Dense Block 3	14 × 14	$\begin{bmatrix} 1 & \times & 1 \\ 3 & \times & 3 \end{bmatrix} \times 48$
Transition Layer 3	14 × 14 7 × 7	1 × 1 convolution 2 × 2 average pooling, stride = 2
Dense Block 4	7 × 7	$\begin{bmatrix} 1 & \times & 1 \\ 3 & \times & 3 \end{bmatrix} \times 32$
Pooling		Average Pooling = 7 × 7 Stride = 7
		1 × 1
FC Layer		1000

Hình 4. Kiến trúc DenseNet201

V. KẾT QUẢ THỰC NGHIỆM

A. Thiết lập thực nghiệm

Phần cứng và phần mềm: Các thí nghiệm được thực hiện trên NVIDIA Tesla T4 GPU, 15GB RAM. Sử dụng các thư viện học máy PyTorch để xây dựng và huấn luyện mô hình.

Hàm mất mát: Sử dụng Cross-Entropy Loss để tính toán chênh lệch giữa nhãn thực tế và nhãn dự đoán.

Bộ tối ưu hóa: Áp dụng Adam Optimizer với tốc độ học 10^{-4} để tăng hiệu quả huấn luyện.

Số epoch: Huấn luyện trong 50 epoch với kích thước batch là 32.

Chia tập dữ liệu: Tập dữ liệu được sử dụng trong nghiên cứu này bao gồm hai lớp: Bình thường và Bụi phổi silic, với số lượng mẫu trong tập huấn luyện và kiểm tra được chia theo tỷ lệ 80% và 20% được trình bày trong Bảng I.

Bảng I. Dữ liệu trong tập huấn luyện và kiểm tra

Dữ liệu	Bụi phổi Silic	Bình thường	Tổng số
Tập huấn luyện	428	1244	1672
Tập kiểm tra	107	310	417
Tổng số	535	1554	2089

B. Kết quả

1) Đánh giá

Tiến hành đánh giá hiệu suất của các mô hình học sâu dựa trên kiến trúc DenseNet201 và MobileNet được huấn

luyện trên bộ dữ liệu X-quang ngực thu thập từ bệnh nhân mắc bệnh bụi phổi silic và người bình thường. Hai nhóm chính được phân loại gồm: Bình thường (Normal) được gán nhãn là 0 và Bụi phổi silic (Silicosis) được gán nhãn là 1. Các thước đo hiệu suất chính được tính toán dựa trên các công thức dưới đây:

Accuracy (Độ chính xác tổng quát):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Precision (Độ chính xác):

$$Độ\ chính\ xác = \frac{TP}{TP + FP}$$

Recall (Độ nhạy):

$$Độ\ nhạy = \frac{TP}{TP + FN}$$

Trong đó:

TP (True Positive): Số lượng dự đoán đúng cho lớp bệnh bụi phổi silic.

TN (True Negative): Số lượng dự đoán đúng cho lớp bình thường.

FP (False Positive): Số lượng dự đoán sai cho lớp bình thường thành bụi phổi silic.

FN (False Negative): Số lượng dự đoán sai cho lớp bụi phổi silic thành bình thường.

Những thước đo này được áp dụng nhằm đánh giá toàn diện hiệu suất phân loại của từng mô hình trên tập dữ liệu kiểm tra (test set). Kết quả đạt được giúp làm rõ mức độ hiệu quả và độ chính xác của các kiến trúc học sâu khi áp dụng vào bài toán phát hiện bệnh bụi phổi silic từ ảnh X-quang ngực.

2) Đánh giá hiệu suất

Hai kiến trúc mô hình, MobileNetV3-Small và DenseNet201, đã được huấn luyện và đánh giá trên tập dữ liệu. Các chỉ số hiệu suất, bao gồm độ chính xác trên tập huấn luyện, độ chính xác trên tập kiểm tra được trình bày trong Bảng II.

Bảng II. Kết quả thử nghiệm

Mô hình	Accuracy	
	Huấn luyện	Kiểm tra
MobileNetV3-Small	73,29	74,34
DenseNet201	78,88	76,98

MobileNetV3-Small đạt độ chính xác 73,29% trên tập huấn luyện và 74,34% trên tập kiểm tra. Sự tương đồng giữa hai giá trị này cho thấy mô hình không gặp hiện tượng quá khớp (overfitting). Tuy nhiên, hiệu suất tổng thể của MobileNetV3-Small khá thấp, đặc biệt khi so sánh với DenseNet201. MobileNetV3-Small được thiết kế tối ưu cho các thiết bị di động, với ưu tiên về tốc độ và kích thước nhỏ gọn. Mặc dù vậy, trong bài toán này, MobileNetV3-Small không đủ khả năng trích xuất đầy đủ các đặc trưng phức tạp từ hình ảnh X-quang, dẫn đến hiệu suất hạn chế, đặc biệt ở tập kiểm tra. Sự chênh lệch nhỏ giữa tập huấn luyện và tập kiểm tra (73,29% so với 74,34%) cũng chỉ ra

rằng mô hình học ổn định nhưng thiếu khả năng phân biệt rõ ràng giữa các lớp bệnh.

DenseNet201, ngược lại, đạt độ chính xác 78.88% trên tập huấn luyện và 76.98% trên tập kiểm tra, vượt trội so với MobileNetV3-Small ở cả hai chỉ số. Điều này chứng tỏ DenseNet201 có khả năng học các đặc trưng quan trọng từ dữ liệu tốt hơn. Kiến trúc DenseNet201 với các Dense Block và kết nối dày đặc giúp tái sử dụng các đặc trưng qua nhiều lớp, cho phép mô hình trích xuất thông tin phức tạp một cách hiệu quả hơn. Hơn nữa, sự chênh lệch nhỏ giữa độ chính xác trên tập huấn luyện và kiểm tra (1.90%) cho thấy DenseNet201 không bị quá khớp và có khả năng tổng quát hóa tốt hơn, phù hợp để áp dụng vào các bộ dữ liệu thực tế.

3) Phân tích ma trận nhầm lẫn

Ma trận nhầm lẫn của hai mô hình được trình bày trong Bảng III, Bảng IV, cho thấy khả năng phân loại của từng mô hình:

Bảng III. Ma trận nhầm lẫn của mô hình MobileNetV3-Small

Dự đoán/thực tế	Bụi phổi silic	Bình thường
Bụi phổi silic	0	0
Bình thường	107	310

Bảng III thể hiện ma trận nhầm lẫn (Confusion Matrix) của mô hình MobileNetV3-small khi dự đoán các hình ảnh X-quang ngực thuộc hai lớp: "Bụi phổi silic" và "Bình thường".

MobileNetV3-Small cho thấy khả năng nhận diện tốt các trường hợp không mắc bệnh (TN = 310), nhưng lại thất bại trong việc phát hiện các trường hợp bệnh (TP = 0). Điều này dẫn đến tỷ lệ phát hiện bệnh bụi phổi silic là 0%, làm giảm hiệu quả của mô hình trong ứng dụng thực tế.

Điểm mạnh của mô hình là không gây ra cảnh báo sai (FP = 0), điều này có thể giảm các chẩn đoán dư thừa, nhưng lại không đáp ứng được mục tiêu phát hiện bệnh.

Bảng IV. Ma trận nhầm lẫn của mô hình DenseNet201

Dự đoán/thực tế	Bụi phổi silic	Bình thường
Bụi phổi silic	19	8
Bình thường	88	302


Với kiến trúc tiên tiến và khả năng trích xuất đặc trưng vượt trội, DenseNet201 đã cải thiện đáng kể khả năng phát hiện bệnh với 19 trường hợp bệnh được dự đoán đúng (True Positive). Mô hình này cũng giữ mức nhầm lẫn thấp, với chỉ 8 trường hợp không bệnh bị nhầm thành bệnh (False Positive). Mặc dù vẫn còn 88 trường hợp bệnh bị bỏ sót (False Negative), nhưng so với MobileNetV3-small, DenseNet201 đã thể hiện ưu thế rõ rệt.

Kết quả so sánh hiệu năng của hai mô hình MobileNetV3-small và DenseNet201 dựa trên ma trận nhầm lẫn (Confusion Matrix) cho thấy sự khác biệt rõ rệt trong khả năng nhận diện bệnh bụi phổi silic nghề nghiệp từ hình ảnh X-quang. DenseNet201 tận dụng các kết nối dày đặc giữa các lớp trong kiến trúc của mình, cho phép tái sử dụng thông tin và tối ưu hóa hiệu quả học đặc trưng.

DenseNet201 vượt trội so với MobileNetV3-Small về mọi khía cạnh, từ khả năng nhận diện bệnh (TP) đến số lượng nhầm lẫn thấp hơn (FP). độ chính xác cao hơn: với số lượng trường hợp bệnh được dự đoán đúng cao hơn (TP = 19), DenseNet201 đã cho thấy khả năng nhận diện bệnh tiềm năng, đặc biệt trong các trường hợp phức tạp. Tỷ lệ nhầm lẫn thấp hơn: Số lượng dự đoán nhầm người không bệnh là bệnh (FP) chỉ là 8, cho thấy mô hình không gây ra quá nhiều cảnh báo sai, giúp tăng độ tin cậy trong ứng dụng thực tế. Tuy nhiên, vẫn còn hạn chế: Mặc dù DenseNet201 cải thiện đáng kể so với MobileNetV3-Small, tỷ lệ bỏ sót bệnh (FN = 88) vẫn còn cao. Điều này cho thấy cần tiếp tục cải tiến, như cân bằng dữ liệu hoặc áp dụng thêm các kỹ thuật học sâu khác để tối ưu hóa hơn nữa khả năng phát hiện bệnh.

4) Trực quan hóa vùng đặc trưng trong chẩn đoán bụi phổi silic

Grad-CAM (Gradient-weighted Class Activation Mapping) là một phương pháp hữu hiệu trong việc trực quan hóa các vùng mà mô hình học sâu tập trung khi đưa ra dự đoán [33]. Công cụ này không chỉ giúp đánh giá độ tin cậy của mô hình mà còn cung cấp thông tin chi tiết để cải thiện dữ liệu hoặc tối ưu hóa cấu trúc mô hình.



Hình 5: So sánh vùng đặc trưng được mô hình tập trung giữa MobilenetV3-Small và DenseNet201 bằng Grad-CAM

Hình ảnh Grad-CAM trong Hình 5 minh họa các vùng tập trung của từng mô hình khi phân loại.

Đối với trường hợp bình thường: MobileNetV3-Small tập trung vào nhiều vùng không liên quan trong ảnh X-quang, điều này phản ánh khả năng nhận diện đặc trưng yếu và thiếu sự tập trung vào vùng phổi trung tâm. DenseNet201 tập trung rõ ràng và chính xác vào vùng phổi trung tâm, điều này phù hợp với đặc điểm hình ảnh của trạng thái bình thường, minh họa khả năng học đặc trưng chính xác và hiệu quả hơn.

Đối với trường hợp mắc bệnh bụi phổi silic: MobileNetV3-Small không xác định chính xác vùng tổn thương, chú ý lan tỏa, mà thay vào đó phân tán sự chú ý sang nhiều vùng không liên quan, làm giảm khả năng phát hiện tổn thương. DenseNet201 xác định chính xác vùng tổn thương (được khoanh tròn trong Grad-CAM), minh chứng cho khả năng học và nhận diện đặc trưng vượt trội từ các hình ảnh X-quang.

Tóm lại, Grad-CAM đã chỉ ra rằng DenseNet201 không chỉ có khả năng học đặc trưng phức tạp hơn mà còn có khả năng tập trung chính xác vào các vùng tổn thương đặc thù của bệnh bụi phổi silic, điều mà MobileNetV3-Small không đạt được. Sự khác biệt rõ ràng trong việc xác định các vùng đặc trưng quan trọng khẳng định ưu thế của

DenseNet201, đặc biệt trong các ứng dụng y khoa cần độ chính xác cao. Kết quả này củng cố tiềm năng của DenseNet201 trong việc hỗ trợ các bác sĩ đưa ra chẩn đoán chính xác và đáng tin cậy hơn.

VI. KẾT LUẬN

Nghiên cứu này đã xây dựng và triển khai mô hình DenseNet-201 để phát hiện bệnh bụi phổi silic nghề nghiệp từ ảnh X-quang ngược. Bằng cách áp dụng các kỹ thuật tiên tiến trong học sâu, nghiên cứu đã so sánh hiệu suất của DenseNet-201 với mô hình MobileNetV3-small nhằm đánh giá khả năng phân loại và nhận diện đặc điểm bệnh lý.

Kết quả thực nghiệm cho thấy DenseNet-201 vượt trội so với MobileNetV3-small về độ chính xác và khả năng nhận diện các đặc trưng quan trọng trong ảnh X-quang. Đặc biệt, phân tích Grad-CAM minh họa rõ ràng rằng DenseNet-201 tập trung vào các vùng tổn thương đặc thù, hỗ trợ hiệu quả trong việc chẩn đoán bệnh. Điều này khẳng định tính ưu việt của DenseNet-201 trong lĩnh vực phân tích hình ảnh y tế, đồng thời góp phần nâng cao độ tin cậy và tốc độ của quá trình chẩn đoán.

Mặc dù đạt được những kết quả khả quan, nghiên cứu vẫn tồn tại một số hạn chế. Đầu tiên, sự mất cân bằng dữ liệu giữa các nhóm bệnh có thể ảnh hưởng đến hiệu suất tổng thể của mô hình. Thứ hai, độ nhạy của mô hình đối với các trường hợp bệnh hiếm vẫn chưa đạt mức tối ưu. Hướng nghiên cứu tiếp theo sẽ tập trung vào việc mở rộng bộ dữ liệu với sự cân bằng tốt hơn giữa các nhóm bệnh, ứng dụng các kỹ thuật học sâu tiên tiến để cải thiện khả năng phân loại, và đánh giá mô hình trên các bộ dữ liệu thực tế lớn hơn.

TÀI LIỆU THAM KHẢO

- [1] P. D. Blanc, A. J. A. j. o. r. Seaton, and c. c. medicine, "Pneumoconiosis Redux. Coal Workers' pneumoconiosis and silicosis are still a problem," vol. 193, ed: American Thoracic Society, 2016, pp. 603-605.
- [2] F. Brims *et al.*, "National Guidance for doctors assessing workers exposed to respirable crystalline silica dust with specific reference to the occupational respiratory diseases associated with engineered stone," Australian Government Department of Health 2022.
- [3] T. Li, X. Yang, H. Xu, and H. J. C. r. j. Liu, "Early identification, accurate diagnosis, and treatment of silicosis," vol. 2022, no. 1, p. 3769134, 2022.
- [4] E. K. Austin, C. James, J. J. I. J. o. E. R. Tessier, and P. Health, "Early detection methods for silicosis in Australia and internationally: a review of the literature," vol. 18, no. 15, p. 8123, 2021.
- [5] C. P. Bondarchuk, B. Grobman, A. Mansur, and C. Y. J. I. D. Lu, "National trends in pneumonia-related mortality in the United States, 1999-2019," pp. 1-10, 2024.
- [6] X. Liu, Q. Jiang, P. Wu, L. Han, and P. J. B. P. H. Zhou, "Global incidence, prevalence and disease burden of silicosis: 30 years' overview and forecasted trends," vol. 23, no. 1, p. 1366, 2023.
- [7] K.-I. Kim *et al.*, "Imaging of occupational lung disease," vol. 21, no. 6, pp. 1371-1391, 2001.
- [8] W. Xuan, Z. Han, and L. Zheng, "Non-invasive detection of silicosis based on array sensing and pattern recognition," in

- E3S Web of Conferences*, 2021, vol. 271, p. 03030: EDP Sciences.
- [9] C. M. Jones, S. S. Pasricha, S. B. Heinze, S. J. J. o. M. I. MacDonald, and R. Oncology, "Silicosis in artificial stone workers: Spectrum of radiological high-resolution CT chest findings," vol. 64, no. 2, pp. 241-249, 2020.
- [10] F. Song *et al.*, "A comparative study on diagnosis of silicosis by digital and high kV film-screen chest radiography," vol. 38, no. 12, pp. 919-921, 2020.
- [11] L. Kong, J. J. B. S. P. Cheng, and Control, "Classification and detection of COVID-19 X-Ray images based on DenseNet and VGG16 feature fusion," vol. 77, p. 103772, 2022.
- [12] M. L. Giger and K. Suzuki, "Computer-aided diagnosis," in *Biomedical information technology*: Elsevier, 2008, pp. 359-XXII.
- [13] C. Young, S. Barker, R. Ehrlich, B. Kistnasamy, A. J. T. I. J. o. T. Yassi, and L. Disease, "Computer-aided detection for tuberculosis and silicosis in chest radiographs of gold miners of South Africa," vol. 24, no. 4, pp. 444-451, 2020.
- [14] F. Mushtaq *et al.*, "Artificial intelligence for computer aided detection of pneumoconiosis: A succinct review since 1974," vol. 133, p. 108516, 2024.
- [15] R. Ehrlich *et al.*, "Accuracy of computer-aided detection of occupational lung disease: Silicosis and pulmonary tuberculosis in Ex-Miners from the South African gold mines," vol. 19, no. 19, p. 12402, 2022.
- [16] Y. Lee, Y. Chae, and S. J. H. i. r. Jeon, "Integration and evaluation of clinical decision support Systems for Diagnosis Idopathics Pulmonary Fibrosis (IPF)," vol. 16, no. 4, pp. 260-272, 2010.
- [17] F. Pesapane, M. Codari, and F. J. E. r. e. Sardanelli, "Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine," vol. 2, pp. 1-10, 2018.
- [18] H. Sharma, J. S. Jain, P. Bansal, and S. Gupta, "Feature extraction and classification of chest x-ray images using cnn to detect pneumonia," in *2020 10th international conference on cloud computing, data science & engineering (Confluence)*, 2020, pp. 227-231: IEEE.
- [19] O. Stephen, M. Sain, U. J. Maduh, and D.-U. J. J. o. h. e. Jeong, "An efficient deep learning approach to pneumonia classification in healthcare," vol. 2019, no. 1, p. 4180949, 2019.
- [20] P. J. A. a. Rajpurkar, "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning," vol. 5225, 2017.
- [21] J. R. Zech, M. A. Badgeley, M. Liu, A. B. Costa, J. J. Titano, and E. K. J. P. m. Oermann, "Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: a cross-sectional study," vol. 15, no. 11, p. e1002683, 2018.
- [22] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 4700-4708.
- [23] L. Sarker, M. M. Islam, T. Hannan, and Z. J. p. Ahmed, "COVID-DenseNet: A deep learning architecture to detect COVID-19 from chest radiology images," vol. 2020050151, no. 10.20944, 2020.
- [24] S. Albahli, N. Ayub, and M. J. A. S. C. Shiraz, "Coronavirus disease (COVID-19) detection using X-ray images and enhanced DenseNet," vol. 110, p. 107645, 2021.
- [25] T. Arulananth, S. W. Prakash, R. K. Ayyasamy, V. Kavitha, P. Kuppusamy, and P. J. I. A. Chinnasamy, "Classification of Paediatric Pneumonia Using Modified DenseNet-121 Deep-Learning Model," 2024.
- [26] D. Singh, V. Kumar, and M. J. A. I. Kaur, "Densely connected convolutional networks-based COVID-19 screening model," vol. 51, pp. 3044-3051, 2021.
- [27] H. A. Sanghvi *et al.*, "A deep learning approach for classification of COVID and pneumonia using DenseNet-201," vol. 33, no. 1, pp. 18-38, 2023.
- [28] P. P. Dalvi, D. R. Edla, and B. J. S. C. S. Purushothama, "Diagnosis of coronavirus disease from chest X-ray images using DenseNet-169 architecture," vol. 4, no. 3, p. 214, 2023.
- [29] O. Rochmawanti and F. Utaminigrum, "Chest X-ray image to classify lung diseases in different resolution size using DenseNet-121 architectures," in *Proceedings of the 6th International Conference on Sustainable Information Engineering and Technology*, 2021, pp. 327-331.
- [30] F. Salim, F. Saeed, S. Basurra, S. N. Qasem, and T. J. E. Al-Hadhrami, "DenseNet-201 and Xception pre-trained deep learning models for fruit recognition," vol. 12, no. 14, p. 3132, 2023.
- [31] S.-H. Wang, Y.-D. J. A. T. o. M. C. Zhang, Communications,, and Applications, "DenseNet-201-based deep neural network with composite learning factor and precomputation for multiple sclerosis classification," vol. 16, no. 2s, pp. 1-19, 2020.
- [32] G. Mohandass, G. H. Krishnan, D. Selvaraj, C. J. B. S. P. Sridhathan, and Control, "Lung Cancer Classification using Optimized Attention-based Convolutional Neural Network with DenseNet-201 Transfer Learning Model on CT image," vol. 95, p. 106330, 2024.
- [33] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-cam: Visual explanations from deep networks via gradient-based localization," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 618-626.

OCCUPATIONAL SILICOSIS DETECTION FROM CHEST X-RAY IMAGES USING DENSENET ARCHITECTURE

Abstract: Occupational silicosis (BPSi) is one of the most severe conditions affecting the health of workers, particularly in industries exposed to free silica dust. In this study, we employ the DenseNet201 model, an advanced convolutional neural network (CNN) architecture, to assist in diagnosing BPSi from chest X-ray images. Experimental results demonstrate that the model achieves high accuracy, especially in distinguishing between normal cases and those affected by silicosis. Furthermore, Grad-CAM is utilized to visualize the key regions the model focuses on, highlighting the effectiveness and reliability of DenseNet201 in identifying characteristic abnormalities of BPSi. This study underscores the

potential of deep learning applications in supporting the diagnosis of occupational diseases.

• **Keywords:** Deep Learning, DenseNet, CNN, Silicosis, Chest X-ray



Nguyễn Thị Tân Tiến, Nhận học vị Thạc sĩ năm 2010. Hiện công tác tại Trường Đại học Y-Dược, Đại học Thái Nguyên. Lĩnh vực nghiên cứu: Học máy, thị giác máy tính, xử lý ảnh.