

AN EFFECTIVE SELF-KNOWLEDGE DISTILLATION METHOD FOR WASTE CLASSIFICATION

Ma Thi Hong Thu

Tan Trao University

ARTICLE INFO		ABSTRACT
Received:	02/4/2024	Garbage classification is a critical task in overcoming environmental pollution. People classify waste based on what they understand about the waste object rather than on its recyclable status, which leads to inaccurate classification in manual sorting. In addition, the direct processing of toxic waste can be physically dangerous for humans. Several machine learning and deep learning techniques have been proposed using standardized garbage classification datasets. However, these methods still have some disadvantages such as (i) the computational cost and memory of the proposed networks are large; (ii) they are difficult to run in real time; (iii) The training process is complicated because it is pre-trained on large data sets to avoid the phenomenon of "overfitting". In this paper, we propose a new approach based on self-knowledge distillation to overcome the above drawbacks. Experimental results have shown that our model achieves the best performance on the Trash Net dataset without having to pre-train the model. This proves the effectiveness of the self-knowledge distillation method brings to the problem of waste classification.
Revised:	23/5/2024	
Published:	24/5/2024	
KEYWORDS		
Self-Knowledge distillation		
Knowledge distillation		
Waste classification		
Computer vision		
Convolutional Neural Network		

MỘT PHƯƠNG PHÁP TỰ CHUNG CÁT KIẾN THỨC HIỆU QUẢ ĐỂ PHÂN LOẠI CHẤT THẢI

Ma Thị Hồng Thu

Trường Đại học Tân Trào

THÔNG TIN BÀI BÁO		TÓM TẮT
Ngày nhận bài:	02/4/2024	Phân loại rác là một nhiệm vụ trọng tâm trong việc khắc phục ô nhiễm môi trường. Con người phân loại rác dựa trên những gì họ hiểu về đối tượng rác hơn là dựa trên trạng thái có thể tái chế của rác, điều này dẫn đến việc phân loại không chính xác trong cách phân loại thủ công. Ngoài ra, việc tiếp xúc trực tiếp với chất thải độc hại có thể gây nguy hiểm về mặt thể chất cho con người. Một số kỹ thuật học máy và học sâu đã được đề xuất bằng cách sử dụng bộ dữ liệu phân loại rác được chuẩn hóa. Tuy nhiên, các phương pháp này còn tồn tại một số nhược điểm như (i) chi phí tính toán và bộ nhớ của các mạng được đề xuất lớn (ii) khó thể chạy trong thời gian thực; (iii) Quá trình huấn luyện phức tạp do được huấn luyện trước trên các bộ dữ liệu lớn để tránh hiện tượng "overfitting". Trong bài báo này chúng tôi đề xuất một cách tiếp cận mới dựa trên tự chung cát kiến thức để khắc phục các nhược điểm trên. Kết quả thử nghiệm cho thấy mô hình được đề xuất đạt hiệu suất tốt nhất trên bộ dữ liệu Trash Net mà không cần phải huấn luyện trước mô hình. Điều này chứng minh sự hiệu quả của tự chung cát kiến thức cho bài toán phân loại chất thải.
Ngày hoàn thiện:	23/5/2024	
Ngày đăng:	24/5/2024	
TỪ KHÓA		
Tự chung cát kiến thức		
Chung cát kiến thức		
Phân loại rác thải		
Thị giác máy tính		
Mạng nơron tích chập		

DOI: <https://doi.org/10.34238/tnu-jst.10013>

Email: thutq7@gmail.com

<http://jst.tnu.edu.vn>

85

Email: jst@tnu.edu.vn

1. Giới thiệu

Theo dữ liệu của Ngân hàng Thế giới, lượng chất thải rắn toàn cầu phát sinh năm 2016 là khoảng 2,01 tỷ tấn mỗi năm. Thế giới dự kiến sẽ sản xuất lần lượt 3,01 và 3,40 tỷ tấn vào năm 2030 và 2050 [1], [2]. Rác được quản lý kém và thải bừa bãi sẽ gây hại cho môi trường, đe dọa sức khỏe của người dân địa phương, gây ô nhiễm nước và không khí, ô nhiễm/thoái hóa đất và nhiều hậu quả khác [3]. Lượng rác chôn lấp không hợp vệ sinh đang hàng ngày gây ô nhiễm cho môi trường đất, môi trường nước và không khí. Vấn đề này trở nên đặc biệt nghiêm trọng ở các thành phố lớn. Ngoài ra, trong số 30% được xử lý bằng phương pháp không chôn lấp thì cũng có đến 2/3 là được đốt tiêu hủy bằng các lò đốt rác thủ công, gây khói bụi ô nhiễm không khí [4].

Từ những khó khăn do việc đổ rác thải không đúng cách ở những địa điểm không được chỉ định [5], nhiều người đã sử dụng nhiều kỹ thuật khác nhau để phát hiện và phân loại rác. Tuy nhiên, hầu hết các phương pháp phân loại rác đều dựa vào chuyên môn của con người, điều này đôi khi có thể khó khăn và tốn thời gian. Một số tính năng cụ thể được xem xét trong phân loại rác là trạng thái vật lý, yếu tố kỹ thuật, khả năng tái sử dụng, khả năng phân hủy sinh học, nguồn sản xuất và tác động môi trường.

Chính vì những lý do trên mà những năm gần đây đã có rất nhiều các công trình nghiên cứu được đề xuất nhằm khắc phục tình trạng ô nhiễm môi trường do rác thải gây ra, đặc biệt là các công trình phân loại rác thải dựa trên trí tuệ nhân tạo đặc biệt là học sâu. Hầu hết các mô hình học sâu được đề xuất dựa trên mạng Convolutional Neural Networks (CNNs) - một mô hình phổ biến trong thị giác máy tính và học máy. Cụ thể, Haruna và Mohd [6] đã đề xuất phương pháp học chuyển giao (transfer learning) bằng mô hình VGG16 để phân loại rác thải sinh hoạt. Việc tái huấn luyện mô hình VGG16 (được huấn luyện trước trên bộ dữ liệu ImageNet) trên bộ dữ liệu TrashNet đạt hiệu suất trên 96% với sáu loại rác thải gồm chất thải, thủy tinh, giấy, bìa cứng, nhựa và kim loại. EwasteNet [7] được đề xuất bởi Nifal Islam cùng các cộng sự đã cung cấp một phương pháp hiệu quả dựa trên sự kết hợp giữa mô hình Convolutional Neural Network và Transformer nhằm phân loại rác thải điện tử. Trong [7], các tác giả đã đề xuất phân loại rác thải bằng một mô hình hai luồng, luồng 1 gọi là Edge stream, nhiệm vụ chính của chúng là tìm các cạnh bằng cách tính toán độ dốc tại vị trí của mỗi pixel. Sau đó các đặc trưng cạnh được đưa vào các tầng 2D Convolution và tầng DeiT (Data-efficient image Transformer). Luồng thứ hai gọi là Pyramid Stream nhằm mục đích trích xuất ra các đặc trưng từ ảnh đầu vào dựa trên các khối ASPP (Atrous Spatial Pyramid Pooling) và cơ chế chú ý CBAM (Convolution Block Attention Module). Sự kết hợp giữa hai luồng thông qua toán tử Concatenate cho một bản đồ đặc trưng toàn diện của dữ liệu đầu vào và cuối cùng là tầng Fully Connected để đưa ra dự đoán phân loại rác thải điện tử. Kết quả thử nghiệm trên bộ dữ liệu E-Waste Vision cho thấy mô hình EwasteNet đạt 0,9670 recall và F1 đạt 0,96. Khác với các phương pháp được trình bày ở trên, Karan Belsare cùng các cộng sự [8] đề xuất một phương pháp phân loại hình ảnh chất thải rắn trong đô thị thông minh dựa trên sự tích hợp IoT (Internet of Things) và mạng cảm biến không dây (Wireless Sensor Network) sử dụng biến đổi wavelet và học máy. Cụ thể, các tác giả trình bày một phương pháp độc đáo để quản lý chất thải bằng cách sử dụng IoT để giám sát chất thải, mạng cảm biến không dây để truyền dữ liệu và biến đổi wavelet, xử lý hình ảnh và học máy để phân loại hình ảnh. Các tác giả cũng đề xuất một kỹ thuật tiền xử lý để xử lý ảnh và mô hình CNN để phân loại ảnh chất thải, kết quả của mô hình được đề xuất được so sánh với bộ phân loại KNN (K-Nearest Neighbors) và nhận thấy rằng độ chính xác của phương pháp được đề xuất tốt hơn so với phân loại KNN. Việc phân loại chất thải y tế là mục tiêu của hệ thống EnSegNet-CFE-DNNTC, được mô tả trong [9]. Điều này được thực hiện bằng cách giải quyết các vấn đề đánh giá sai trong bộ phân loại của học sâu. Mô hình EnSegNet bắt đầu bằng cách phân đoạn các hình ảnh rác y tế được đưa vào đó. Các hình ảnh rác được phân đoạn được sử dụng để tạo ra một số đặc điểm kết cấu khác nhau, chẳng hạn như GLCM, MLBP, LDP và LTP, cũng như các đặc điểm sâu được trích xuất, đạt độ chính xác 87,5%. Nafiz cùng các cộng sự [10] đã trình bày một phương pháp tiếp cận dựa trên học

chuyển giao, trong đó họ đã tinh chỉnh mạng InceptionResnetV2 được đào tạo trước trên tập ImageNet và đạt được độ chính xác 98%. Họ đã tích hợp mô hình này vào một máy phân loại rác tự động có thể đặt rác thải vào các thùng tương ứng.

Mặc dù đạt được hiệu suất hiện đại trên nhiều bộ dữ liệu khác nhau, nhưng các phương pháp được trình bày ở trên vẫn còn tồn tại nhiều nhược điểm như (i) các mô hình chủ yếu tập trung vào việc đề xuất các kiến trúc mạng mới dẫn đến chi phí tính toán và bộ nhớ của các mạng được đề xuất này trở lên vô cùng phức tạp và lớn, điều này gây trở ngại rất lớn khi áp dụng chúng vào các hệ thống nhúng hoặc các thiết bị di động (các thiết bị có bộ vi xử lý và bộ nhớ thấp); (ii) bên cạnh việc khó triển khai trên các thiết bị có cấu hình thấp, các kiến trúc mạng phức tạp còn có số lượng phép tính lớn dẫn đến không thể chạy trong thời gian thực; (iii) do kiến trúc mạng lớn nên các mô hình này thường phải được huấn luyện trước trên các bộ dữ liệu lớn chẳng hạn như ImageNet (để tránh hiện tượng “overfitting”), sau đó được chuyển giao sang các bộ dữ liệu phân loại rác. Điều này làm phức tạp thêm quá trình huấn luyện của các mô hình.

Từ những nhược điểm trên, chúng tôi đề xuất một cách tiếp cận hiệu quả dựa trên tự chưng cất kiến thức - một biến thể của chưng cất kiến thức để giải quyết bài toán phân loại rác thải. Chưng cất kiến thức [11] được đề xuất để chuyển kiến thức từ mô hình lớn sang mô hình nhỏ hơn mà không mất giá trị. Vì các mô hình nhỏ hơn ít tốn kém hơn khi thực hiện nên chúng có thể được triển khai trên phần cứng kém mạnh mẽ hơn chẳng hạn như thiết bị di động. Tự chưng cất kiến thức là một cải tiến từ chưng cất kiến thức nhằm loại bỏ mạng lớn (mạng giáo viên) trong quá trình chưng cất kiến thức. Điều này giúp cho việc huấn luyện trở lên đơn giản hơn, hơn nữa tự chưng cất kiến thức còn loại bỏ khoảng cách năng lực giữa mạng giáo viên và mạng sinh viên [12]. Tự chưng cất kiến thức đã được chứng minh là hiệu quả ở rất nhiều bài toán khác nhau trong lĩnh vực thị giác máy tính và học máy chẳng hạn như phân loại ảnh [13], nhận dạng hành động [14], xử lý tiếng nói [15],... Trong bài báo này, chúng tôi đề xuất một mô hình tự chưng cất kiến thức hiệu quả dựa trên tăng cường dữ liệu. Cụ thể, đầu tiên là tạo ra các biến thể khác nhau của mỗi hình ảnh đầu vào, sau đó sử dụng mạng CNN để dự đoán các lớp cho chúng. Kết quả của mỗi biến thể sẽ được sử dụng như kiến thức của mạng giáo viên để chưng cất kiến thức cho chính biến thể còn lại. Quá trình này được lặp đi lặp lại trong suốt giai đoạn huấn luyện. Thử nghiệm mô hình trên các bộ dữ liệu về phân loại rác thải cho thấy cách tiếp cận tự chưng cất kiến thức đạt hiệu suất hiện đại và tốt hơn so với các mô hình được đề xuất gần đây.

Ngoài trừ phần tài liệu tham khảo, phần còn lại của bài báo được trình bày như sau: Phần 2 mô tả chi tiết về phương pháp được đề xuất, bao gồm mô tả bài toán, mô hình tự chưng cất kiến thức, kiến trúc mạng và các phép tăng cường dữ liệu. Tiếp theo, ở phần 3, chúng tôi tiến hành thử nghiệm và so sánh phương pháp tự chưng cất kiến thức được đề xuất với một số phương pháp gần đây nhằm chứng minh tính hiệu quả của phương pháp. Cuối cùng là kết luận rút ra được trong quá trình nghiên cứu và thử nghiệm phương pháp.

2. Phương pháp được đề xuất

Trong phần này, chúng tôi mô tả ngắn gọn về bài toán phân loại rác thải với các thiết lập đầu vào và đầu ra của bài toán, tiếp theo là trình bày chi tiết phương pháp được đề xuất - tự chưng cất kiến thức bao gồm ba bước chính. Bước 1: tạo nhiều khung nhìn từ một hình ảnh đầu vào, bước 2 trích xuất vector đặc trưng và dự đoán của mạng CNN với các khung hình, bước 3 tính toán hàm mất mát và tự chưng cất kiến thức.

2.1. Tổng quan bài toán

Gọi $\mathcal{D} = \{(x_i, y_i)\}$ với $i = 1, 2, 3, \dots, N$ là tập dữ liệu huấn luyện của bài toán phân loại rác thải, trong đó x_i là ảnh đầu vào với $x_i \in \mathbb{R}^{H \times W \times C}$ với H, W, C lần lượt là chiều cao, chiều rộng và số kênh màu của ảnh x_i ($i \in \{1, 2, 3, \dots, N\}$). N là số lượng ảnh huấn luyện. y_i tương ứng là nhãn của ảnh x_i với $y_i \in \{1, 2, 3, \dots, K\}$ và K là số lượng lớp. Bài toán phân loại rác thải tập trung vào việc dự đoán ảnh đầu vào x_i thuộc lớp nào trong K lớp. Để làm được điều này, chúng ta xây dựng mô

hình học sâu F nhận đầu vào x_i và dự đoán ra $\hat{y}_i$ sao cho $\hat{y}_i \cong y_i$, tức là $F(x_i) = \hat{y}_i \cong y_i$. Để đánh giá độ sai lệch giữa nhãn thực y_i và nhãn dự đoán của mô hình $\hat{y}_i$, hàm cross-entropy được sử dụng như công thức (1):


$$\mathcal{L}_{CE}(y_i, \hat{y}_i) = - \sum_{i=1}^n y_i \times \log \hat{y}_i \quad (1)$$

Trong đó, n là số lượng ảnh trong mỗi batch của $\mathcal{D}$ ($n \ll N$).

2.2. Tự chưng cất kiến thức

Cách tiếp cận tự chưng cất kiến thức được mô tả như trong Hình 1. Trong đó, thay vì sử dụng mạng giáo viên để truyền đạt kiến thức cho mạng sinh viên như trong chưng cất kiến thức truyền thống [11], chúng tôi kế thừa ý tưởng tự chưng cất kiến thức [12]-[14] bằng cách sử dụng chính mạng sinh viên để chưng cất cho nó. Cách tiếp cận này có thể tóm tắt gồm ba bước chính như sau:

- (1) – Tạo nhiều khung nhìn khác nhau từ một ảnh đầu vào;
- (2) – Các khung hình được đưa vào mạng CNN để thu nhận vector đặc trưng và kết quả dự đoán;
- (3) – Kết quả dự đoán của mạng CNN sẽ được so sánh với nhãn thực trong khi các vector đặc trưng của mỗi khung nhìn được so sánh với nhau để có thể phân tích và chưng cất kiến thức cho nhau.



Hình 1. Tổng quan cách tiếp cận được đề xuất dựa trên tự chưng cất kiến thức cho bài toán phân loại rác thải

2.2.1. Tạo nhiều khung nhìn

Để có thể tạo nhiều khung nhìn khác nhau từ một ảnh đầu vào, chúng tôi sử dụng các toán tử tăng cường dữ liệu chẳng hạn như xoay ảnh, cắt ảnh, đổi màu ảnh, chuyển từ ảnh màu sang ảnh đen trắng, thêm nhiễu vào ảnh,... Tăng cường dữ liệu là một trong những phương pháp đơn giản nhất làm tăng lượng dữ liệu huấn luyện mà không cần phải gán nhãn (do các hình ảnh được tăng cường vẫn thuộc nhãn ban đầu, chúng chỉ khác nhau về hình dạng, màu sắc). Tăng cường dữ liệu đã được chứng minh hiệu quả trong việc nâng cao khả năng tổng quát hóa của các mô hình học sâu mà không cần phải thu thập thêm dữ liệu [16]. Có rất nhiều phương pháp được đề xuất cho tăng cường dữ liệu ảnh, trong khuôn khổ bài báo này, RandAugment [16] được sử dụng nhằm tạo ra hai khung nhìn khác nhau từ ảnh rác thải đầu vào.

Gọi $\mathcal{T}$ là tập các phép tăng cường dữ liệu, tại mỗi bước lặp, chúng tôi ngẫu nhiên chọn ra hai tập con các phép tăng cường dữ liệu từ $\mathcal{T}$ gọi là t và t' . Áp dụng các phép tăng cường dữ liệu t cho ảnh đầu vào ta thu được khung nhìn thứ nhất và áp dụng các phép tăng cường dữ liệu t' cho ảnh đầu vào, ta thu được khung nhìn thứ hai. Do tập các phép tăng cường dữ liệu $\mathcal{T}$ là lớn và với

mỗi phép tăng cường dữ liệu đều có các ngưỡng tham số khác nhau nên luôn đảm bảo tại mỗi bước lặp chúng ta đều thu được khung nhìn 1 và khung nhìn 2 là khác nhau.

$$\begin{aligned}v_1 &= t(x) \\v_2 &= t'(x)\end{aligned}\quad (2)$$

2.2.2. Trích xuất vector đặc trưng và dự đoán

Đối với mỗi khung nhìn sẽ được đưa vào mạng CNN và thu được hai đầu ra là vector đặc trưng z và dự đoán p như trong công thức (3).

$$\begin{aligned}z_1, p_1 &= F(v_1) \\z_2, p_2 &= F(v_2)\end{aligned}\quad (3)$$

Trong đó, z_1, p_1 tương ứng là vector đặc trưng và dự đoán của khung nhìn v_1 , và z_2, p_2 tương ứng là vector đặc trưng và dự đoán của khung nhìn v_2 . Đối với mỗi dự đoán p , áp dụng hàm softmax để trích xuất ra xác suất của mỗi lớp theo công thức (4).

$$\begin{aligned}\hat{y}_1 &= \text{softmax}(p_1) \\ \hat{y}_2 &= \text{softmax}(p_2)\end{aligned}\quad (4)$$

2.2.3. Tính hàm mất mát và tự chung cất kiến thức

Như được trình bày ở Hình 1, có hai hàm mất mát được sử dụng trong cách tiếp cận này là (i) hàm mất mát giữa nhãn thực và dự đoán của mô hình mạng; (ii) hàm mất mát giữa các vector nhúng của các khung nhìn khác nhau.

Hàm mất mát cross-entropy được sử dụng để tính độ sai khác giữa nhãn thực và các nhãn dự đoán của mô hình như được mô tả trong công thức (5).

$$\mathcal{L}_1 = \mathcal{L}_{CE}(y, \hat{y}_1) + \mathcal{L}_{CE}(y, \hat{y}_2) \quad (5)$$

Trong đó, $\mathcal{L}_{CE}$ là hàm mất mát cross-entropy được trình bày ở công thức (1), ở công thức (5) chúng tôi tính hàm mất mát giữa nhãn thực y với kết quả nhãn $\hat{y}_1$ được tạo ra từ mạng CNN với đầu vào là khung nhìn v_1 và hàm mất mát giữa nhãn thực y với kết quả nhãn $\hat{y}_2$ được tạo ra từ mạng CNN với đầu vào là khung nhìn v_2 . Bên cạnh hàm mất mát cross-entropy, hàm mất mát MSE (Mean Square Error) được sử dụng để tính toán sự khác biệt giữa 2 vector đặc trưng của hai khung hình như trong công thức (6).

$$\mathcal{L}_2 = \mathcal{L}_{MSE}(\text{stop_grad}(z_1), z_2) + \mathcal{L}_{MSE}(\text{stop_grad}(z_2), z_1) \quad (6)$$

Trong (6), ta có $\text{stop_grad}()$ thể hiện bước dừng lan truyền ngược, hay nói cách khác $\text{stop_grad}(z_1)$ tức là gọi z_1 là vector đặc trưng của mạng giáo viên và yêu cầu mạng sinh viên (tức z_2) phải học hỏi được kiến thức như vậy và tương tự ngược lại với $\text{stop_grad}(z_2)$. Kết hợp giữa (5) và (6) ta được hàm mất mát tổng quát cho cách tiếp cận tự chung cất như sau:

$$\mathcal{L}_{net} = \alpha \times \mathcal{L}_1 + (1 - \alpha) \times \mathcal{L}_2 \quad (7)$$

Trong đó, α là tham số thể hiện sự cân bằng giữa $\mathcal{L}_1$ và $\mathcal{L}_2$. Trong thử nghiệm, chúng tôi thiết lập $\alpha = 0,9$.

3. Thử nghiệm

Trong phần này, trước tiên chúng tôi mô tả ngắn gọn về bộ dữ liệu được sử dụng để so sánh – Trash Net và chi tiết triển khai mô hình tự chung cất kiến thức. Sau đó, chúng tôi cung cấp các kết quả chạy thử nghiệm mô hình và so sánh chúng với các phương pháp khác được đề xuất gần đây nhằm chứng minh tính hiệu quả của cách tiếp cận tự chung cất kiến thức.

3.1. Bộ dữ liệu và chi tiết triển khai

- Bộ dữ liệu: Trash Net là tập dữ liệu chuẩn được sử dụng nhiều nhất để phân loại rác [17]. Bộ dữ liệu Trash Net bao gồm sáu lớp: chất thải, thủy tinh, giấy, bìa cứng, nhựa và kim loại. Bộ dữ liệu bao gồm 2.527 bức ảnh được gán nhãn theo danh mục (501 kính, 594 giấy, 403 bìa cứng,

482 nhựa, 410 kim loại và 137 rác thải khác). Tập dữ liệu bao gồm các ảnh được chụp trên nền trắng bằng nhiều cái đặt phơi sáng và ánh sáng khác nhau (chủ yếu là một đối tượng cho mỗi ảnh). Bộ dữ liệu Trash Net đặt ra thách thức về việc phân loại sai nghiêm trọng và/hoặc không khái quát hóa bất kỳ mô hình học máy hoặc học sâu nào, chủ yếu khi áp dụng cho tình huống thực tế.

- Chi tiết triển khai: Mạng CNN được đào tạo từ đầu bằng trình tối ưu hóa Stochastic Gradient Descent. Các ảnh đào tạo được thay đổi kích thước về $224 \times 224 \times 3$. Kích thước lô được đặt thành 32 ảnh. Tốc độ học được khởi tạo là 0,001 và giảm 10 lần nếu mô hình không cải thiện độ chính xác trong 10 kỷ nguyên liên tiếp. Tất cả các mô hình đều được đào tạo với 100 kỷ nguyên và các độ đo được tính toán trên bộ kiểm tra. Trong công việc này, chúng tôi sử dụng bộ chiến lược tăng cường dữ liệu trong [16]. Mỗi toán tử tăng cường có xác suất được chọn là 0,5. Để đánh giá hiệu suất mạng, chúng tôi so sánh kết quả của mô hình với các phương pháp đào tạo độc lập (Baseline) và các phương pháp được đề xuất gần đây trong [6], [18].

3.2. Kết quả mô hình đề xuất

Bảng 1 mô tả chi tiết độ chính xác của cách tiếp cận được đề xuất và so sánh với hai phương pháp được công bố gần đây là [6] và [18]. Để đảm bảo sự công bằng trong quá trình so sánh, chúng tôi tái sử dụng toàn bộ kiến trúc mạng (VGG-16), cách chia tập dữ liệu huấn luyện và kiểm thử. Các kết quả được đánh giá chi tiết trên từng lớp của tập kiểm thử trong dữ liệu Trash Net.

Như được thể hiện trong Bảng 1, mô hình tự chưng cất vượt trội hơn hai phương pháp trong [6] và [18] trên tất cả các lớp. Cụ thể, với lớp “Bìa”, mô hình đạt 96% độ chính xác trong khi phương pháp trong [6] đạt 88% (hơn 8%) và phương pháp trong [18] đạt 91% (hơn 5%). Đối với lớp “Thủy tinh”, mô hình vượt hơn 17% độ chính xác so với phương pháp trong [6] và 3% độ chính xác so với phương pháp trong [18]. Lớp “Kim loại” cũng có sự chênh lệch rất lớn (15%) về độ chính xác giữa phương pháp tự chưng cất và phương pháp trong [6]. “Giấy” là một lớp dễ phát hiện và phân loại nhất trong số các loại chất thải có trong tập dữ liệu Trash Net khi mà cả ba phương pháp đều đạt độ chính xác hơn 90%, tuy nhiên cách tiếp cận này vẫn cho hiệu suất tốt nhất với 96% hơn 6% so với [6] và 2% so với [18]. Tương tự các lớp trước, phương pháp được đề xuất cũng đạt hiệu suất tốt nhất trên lớp “Nhựa” với 91% trội hơn 13% so với [6] và 4% so với [18]. Lớp “Rác thải khác” bao gồm các loại chất thải không thuộc 5 loại trên, do đó, các mô hình cho độ chính xác kém nhất trên lớp này so với các lớp khác. Thật vậy, vì đây là lớp gồm nhiều loại rác thải khác nhau, dẫn đến khó khăn trong quá trình tổng quát hóa của mạng CNN ở giai đoạn huấn luyện vì mỗi hình ảnh trong lớp này đều không có mối liên hệ gì với nhau. Do đó, phương pháp trong [6] chỉ đạt 70% độ chính xác và phương pháp trong [18] đạt 87%, mô hình tự chưng cất kiến thức vẫn tỏ ra hiệu quả hơn so với hai phương pháp trên khi đạt hiệu suất 91% trên lớp “Rác thải khác”.

Bảng 1. Kết quả mô hình của chúng tôi trên bộ dữ liệu Trash Net và so sánh với các phương pháp khác được đề xuất gần đây

Phương pháp	Kiến trúc mạng	Lớp					
		Bìa	Thủy tinh	Kim loại	Giấy	Nhựa	Rác thải khác
Trong [6]	VGG-16	0,88	0,6	0,80	0,90	0,78	0,70
Trong [18]	VGG-16	0,91	0,90	0,92	0,94	0,87	0,85
Của chúng tôi	VGG-16	0,96	0,93	0,95	0,96	0,91	0,91

4. Kết luận

Trong bài báo này, chúng tôi trình bày một cách tiếp cận hiệu quả dựa trên tự chưng cất kiến thức để giải quyết bài toán phân loại rác. Khác với các phương pháp chưng cất kiến thức thông

thường, kỹ thuật tự chưng cất kiến thức giúp loại bỏ mạng giáo viên trong quá trình huấn luyện, từ đó giảm đáng kể thời gian huấn luyện mà vẫn giữ được những điểm đặc trưng của chưng cất kiến thức. Cách tiếp cận này sử dụng tập các phép tăng cường dữ liệu nhằm tạo ra nhiều khung nhìn khác nhau từ mỗi ảnh đầu vào. Sau đó, mỗi khung hình sẽ cho kết quả dự đoán và các vector đặc trưng của khung hình. Giống như các bài toán phân lớp khác, kết quả dự đoán được so sánh với nhãn thực thông qua hàm mất mát cross-entropy, trong khi các vector đặc trưng được sử dụng để chưng cất kiến thức cho mạng CNN. Thử nghiệm phương pháp trên bộ dữ liệu Trash Net với kiến trúc mạng và các cài đặt tương tự các phương pháp được công bố gần đây. Kết quả thử nghiệm cho thấy cách tiếp cận sử dụng tự chưng cất kiến thức đạt hiệu suất vượt trội hơn so với các phương pháp được công bố gần đây ở tất cả các lớp khác nhau trong bộ dữ liệu Trash Net. Trong tương lai, việc nghiên cứu, mở rộng và phát triển phương pháp tự chưng cất kiến thức trên một số bài toán khác là một trong những công việc quan trọng cần được thực hiện. Bên cạnh đó, vấn đề nghiên cứu lý thuyết toán học cho tự chưng cất kiến thức cũng cần được xem xét kỹ lưỡng trong các công việc tiếp theo của chúng tôi.

TÀI LIỆU THAM KHẢO/ REFERENCES

- [1] K. N. Sami, Z. M. A. Amin, and R. Hassan, "Waste management using machine learning and deep learning algorithms," *International Journal on Perceptive and Cognitive Computing*, vol. 6, no. 29, pp. 7-106, 2020.
- [2] S. Shahab, M. Anjum, and M. S. Umar, "Deep learning applications in solid waste management: A deep literature review," *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 3, pp. 1-15, 2022.
- [3] M. Triassi, R. Alfano, M. Illario, A. Nardone, O. Caporale, and P. Montuori, "Environmental pollution from illegal waste disposal and health effects: A review on the "Triangle of Death"," *International Journal of Environmental research and public health*, vol. 12, no. 2, pp. 1216-1236, 2015.
- [4] Q. H. Nguyen, "Domestic waste in Vietnam: Current situation and solutions," National Assembly of the Socialist Republic of Vietnam, 2023. [Online]. Available: <https://quochoi.vn/tintuc/Pages/tin-hoat-dong-cua-quoc-hoi.aspx?ItemID=82916>. [Accessed Feb. 20, 2024].
- [5] A. A. Namen, F. D. C. Brasil, J. J. G. Abrunhosa, G. G. S. Abrunhosa, R. M. Tarré, and F. J. G. Marques, "RFID technology for hazardous waste management and tracking," *Waste management & research*, vol. 32, no. 9, pp. 59-66, 2014.
- [6] H. Abdu and M. H. M. Noor, "Domestic trash classification with transfer learning using VGG16," *In 12th International Conference on Control System, Computing and Engineering (ICCSCE)*, IEEE, 2022, pp. 137-141.
- [7] N. Islam, M. M. H. Jony, E. Hasan, S. Sutradhar, A. Rahman, and M. M. Islam, "Ewastenet: A two-stream data efficient image transformer approach for e-waste classification," *In 2023 IEEE 8th International Conference on Software Engineering and Computer Systems (ICSECS)*, IEEE, 2023, pp. 435-440.
- [8] K. Belsare, M. Singh, A. Gandam, P. K. Malik, R. Agarwal, and A. Gehlot, "An integrated approach of IoT and WSN using wavelet transform and machine learning for the solid waste image classification in smart cities," *Transactions on Emerging Telecommunications Technologies*, vol. 35, no. 4, 2023, Art. no. e4857.
- [9] T. Mythili and A. Anbarasi, "A concatenation of deep and texture features for medicinal trash image classification using EnSegNet-DNN-based transfer learning," *Materials Today: Proceedings*, vol. 62, pp. 4691-4698, 2022.
- [10] M. S. Nafiz, S. S. Das, M. K. Morol, A. A. Juabir, and D. Nandi, "Convowaste: An automatic waste segregation machine using deep learning," *In 3rd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)*, IEEE, 2023, pp. 181-186.
- [11] G. Hinton, O. Vinyals, and J. Dean, "Distilling the knowledge in a neural network," *In International Conference on Neural Information Processing Systems*, 2015, pp. 1-9.
- [12] D.-Q. Vu, N. Le, and J.-C. Wang, "Teaching yourself: A self-knowledge distillation approach to action recognition," *IEEE Access*, vol. 9, pp. 105711-105723, 2021.

-
- [13] S. Yun, J. Park, K. Lee, and J. Shin, "Regularizing class-wise predictions via self-knowledge distillation," *In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020, pp. 13876-13885.
- [14] D.-Q. Vu and J.-C. Wang, "A novel self-knowledge distillation approach with siamese representation learning for action recognition," *In 2021 International Conference on Visual Communications and Image Processing (VCIP)*, IEEE, 2021, pp. 1-5.
- [15] H. M. Tan, D.-Q. Vu, C.-T. Lee, Y.-H. Li, and J.-C. Wang, "Selective mutual learning: an efficient approach for single channel speech separation," *In International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 2022, pp. 3678-3682.
- [16] E. D. Cubuk, B. Zoph, J. Shlens, and Q. V. Le, "Randaugment: Practical automated data augmentation with a reduced search space," *In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*, 2020, pp. 702-703.
- [17] G. Thung and M. Yang, "Dataset of images of trash; Torch-based CNN for garbage image classification," Github. [Online]. Available: <https://github.com/garythung/trashnet>. [Accessed Jan. 30, 2024].
- [18] K. Liu and X. Liu, "Recycling Material Classification using Convolutional Neural Networks," *In 2022 21st IEEE International Conference on Machine Learning and Applications (ICMLA)*, IEEE, 2022, pp. 83-88.