

# NHẬN DIỆN QUẢ XOÀI CHÍN QUA HÌNH ẢNH VỚI MÔ HÌNH EBM

## IDENTIFYING RIPE MANGOES BY IMAGE WITH EBM MODEL

Ripeness Identification of Mangoes from Images Using the Energy-Based Model (EBM)

LÊ HOÀNG HUY

Khoa công nghệ thông tin, Đại học Sư phạm Kỹ thuật Vĩnh Long

Email: [huylh@ueh.edu.vn](mailto:huylh@ueh.edu.vn)

**Nhận bài (Received): 12/06/2025; Phản biện (Reviewed): 19/08/2025; Chấp nhận (Accepted): 30/9/2025**

### TÓM TẮT

Việt Nam là quốc gia xuất khẩu xoài lớn, tuy nhiên quá trình phân loại xoài chín vẫn chủ yếu thủ công, gây tốn thời gian và dễ sai sót. Trước đây, các mô hình học sâu như CNN, ResNet đã được áp dụng nhưng vẫn hạn chế về độ ổn định và khả năng tổng quát. Bài báo này đề xuất mô hình Energy-Based Model (EBM) – một hướng tiếp cận học máy mới có khả năng mô hình hóa mối quan hệ giữa ảnh và nhãn một cách trực tiếp thông qua hàm năng lượng. Mô hình được xây dựng dựa trên đặc trưng trích xuất từ ResNet101 kết hợp với YOLO trong giai đoạn tiền xử lý, giúp tăng độ chính xác trong phân loại xoài chín qua ảnh. Kết quả thực nghiệm trên hai tập dữ liệu gồm Mango and Banana Dataset và Mango Grading Dataset với hơn 5.000 ảnh xoài cho thấy tiềm năng lớn của mô hình trong các hệ thống phân loại nông sản tự động.

**Từ khóa:** Energy-Based Model, EBM, Deep learning, Nhận diện hình ảnh, Xoài.

### ABSTRACT

mango ripeness classification

Vietnam is a major mango exporter; however, the classification of mango ripeness is still primarily done manually, which is time-consuming and prone to errors. Previous deep learning models such as CNN and ResNet have been applied, but they still face limitations in terms of stability and generalization. This paper proposes the Energy-Based Model (EBM) a novel machine learning approach capable of directly modeling the relationship between images and labels through an energy function. The model is built upon features extracted from ResNet101 and incorporates YOLO during the preprocessing stage to enhance the accuracy of mango ripeness detection. Experimental evaluations were conducted on a combined dataset derived from the Mango and Banana Dataset and the Mango Grading Dataset, totaling over 5,000 mango images. Results demonstrate the model's strong potential for deployment in automated agricultural product classification systems. that directly models

**Keywords:** Energy-Based Model, EBM, Deep learning, Image recognition, Mango

## 1. GIỚI THIỆU

Việt Nam là một trong những quốc gia có sản lượng xoài lớn trên thế giới, với hơn 1,4 triệu tấn mỗi năm. Tuy nhiên, việc phân loại xoài chín hiện nay vẫn thực hiện thủ công dựa trên cảm quan, dẫn đến sai lệch

và ảnh hưởng đến chất lượng xuất khẩu.

Sự phát triển của học sâu mở ra nhiều hướng đi mới trong nhận diện ảnh nông sản. Các mô hình như CNN, ResNet được sử dụng rộng rãi, tuy nhiên vẫn còn nhược điểm như phụ thuộc dữ liệu lớn và không

ổn định trong điều kiện ảnh thay đổi.

Bài báo này đề xuất mô hình kết hợp Energy-Based Model với ResNet101 và YOLO để phân loại xoài chín từ ảnh. EBM có khả năng mô hình hóa tốt mối liên hệ đầu vào và đầu ra thông qua hàm năng lượng, thay vì dựa vào xác suất.

Bài viết được tổ chức như sau: Mục 2 trình bày các nghiên cứu liên quan; Mục 3 là đánh giá mô hình; Mục 4 mô tả mô hình đề xuất và giải thuật; Mục 5 trình bày kết quả thực nghiệm; và Mục 6 là kết luận.


## 2. CÁC NGHIÊN CỨU LIÊN QUAN

Một số nghiên cứu trước đã áp dụng học sâu vào phân loại xoài chín như [1], [2], [3]. Trong đó, [1] sử dụng mạng CNN để nhận dạng khuyết điểm vỏ xoài nhưng độ chính xác chưa cao. [2] xây dựng mô hình phân loại dựa trên đặc trưng màu và hình dạng, áp dụng SVM và đạt độ chính xác ~92%. Nghiên cứu [3] dùng CNN để phân loại mức độ chín, nhưng thiếu khả năng tổng quát do ảnh chụp đơn điệu. Một số nghiên cứu như [14] và cũng sử dụng

ResNet101 để tăng độ sâu mạng, cải thiện khả năng học đặc trưng phức tạp. Tuy nhiên, các mô hình này vẫn còn hạn chế về khả năng tổng quát với ảnh thực tế.

Một số nghiên cứu trước đã áp dụng học sâu vào phân loại xoài chín như [1], [2], [3]. Trong đó, [1] sử dụng mạng CNN để nhận dạng khuyết điểm vỏ xoài nhưng độ chính xác chưa cao. [2] xây dựng mô hình phân loại dựa trên đặc trưng màu và hình dạng, áp dụng SVM và đạt độ chính xác ~92%. Nghiên cứu [3] dùng CNN để phân loại mức độ chín, nhưng thiếu khả năng tổng quát do ảnh chụp đơn điệu. Một số nghiên cứu như [14] và cũng sử dụng ResNet101 để tăng độ sâu mạng, cải thiện khả năng học đặc trưng phức tạp. Tuy nhiên, các mô hình này vẫn còn hạn chế về khả năng tổng quát với ảnh thực tế.

Các mô hình thị giác máy tính (CV) như CNN, ResNet đã được áp dụng thành công trong nhiều bài toán nhận diện ảnh [14], [18]. CNN giúp trích xuất đặc trưng từ ảnh theo từng tầng, trong khi ResNet cải thiện độ sâu bằng các khối residual, tránh hiện tượng mất thông tin [17].



Hình 1. Khái quát cấu trúc của mô hình ResNet

Energy-Based Model (EBM) là mô hình học máy đánh giá độ phù hợp giữa đầu vào  $x$  và đầu ra  $y$  thông qua hàm năng lượng  $E(x,y)$  [4], [5], [6], [10], [11], [15], [16], [20]. Hàm năng lượng phổ biến:


$$E(x,y)=W[y].F(x)+b[y]$$

Hàm loss:

$$L(x,y)=E(x,y)+\log\sum_y \exp(-E(x,y'))$$

EBM không yêu cầu phân phối xác suất nên phù hợp với dữ liệu không đồng

nhất và phức tạp [9], [12].



Hình 2. Cấu trúc mô hình Energy-Based Model.  $x$  là đặc trưng ảnh,  $y$  là lớp nhãn;  $W[y]$  và  $b[y]$  là trọng số và bias tương ứng với lớp  $y$ ;  $E(x,y)$  là hàm năng lượng, giá trị càng thấp càng phù hợp.

Bổ sung minh hoạ EBM với  $f(x)$  chỉ gồm 3 giá trị và tính năng lượng/chuẩn hoá/loss chi tiết như sau:

Bảng A. Tính năng lượng  $E(x,y)$  cho 2 lớp (chín/không chín) – ví dụ minh hoạ

Nhãn đúng	Loss $L(x,y)$	Giải thích
Chín ( $y=1$ )	$1.0 \cdot 0.6 + (-0.5) \cdot 0.1 + 0.8 \cdot 0.3 + 0.1$	0.89
Không chín ( $y=0$ )	$(-0.3) \cdot 0.6 + 0.9 \cdot 0.1 + (-0.7) \cdot 0.3 + 0.2$	-0.10

Bảng B. Chuẩn hoá xác suất theo  $\exp(-E)$  và tổng  $Z$

Lớp ( $y$ )	$-E(x,y)$	$\exp(-E)$	$p(y x)$
Chín (1)	-0.89	0.411	$0.411 / 1.516 \approx 0.271$
Không chín (0)	0.10	1.105	$1.105 / 1.516 \approx 0.729$
Tổng ( $Z$ )	–	1.516	1.000

Bảng C. Tính loss  $L(x,y) = E(x,y) + \log Z$

Lớp ( $y$ )	Công thức	Kết quả
Chín (1)	$0.89 + \log(1.516) \approx 1.306$	Cao – dự đoán sai
Không chín (0)	$-0.10 + \log(1.516) \approx 0.316$	Thấp – dự đoán đúng

### 3. ĐÁNH GIÁ MÔ HÌNH

Dữ liệu được chia thành tập huấn luyện (70%), tập kiểm thử (15%) và tập kiểm tra (15%). Mô hình được đánh giá bằng độ chính xác (Accuracy) và hàm mất mát (Loss). Hai mô hình được so sánh gồm: Tỷ lệ 70/15/15 được lựa chọn để cân bằng giữa huấn luyện và đánh giá trong bối cảnh dữ liệu đã được lọc giảm số lượng để tránh học vẹt, đảm bảo mô hình vẫn có khả năng tổng quát.


- ResNet101 sử dụng lớp Sigmoid (truyền thống)
- ResNet101 kết hợp Energy-Based Model (EBM)

### 4. MÔ HÌNH ĐỀ XUẤT VÀ GIẢI THUẬT

#### 4.1. Mô hình đề xuất

Trong quá trình thực nghiệm, ảnh đầu vào được đưa qua ResNet101 để trích xuất đặc trưng sâu. Các đặc trưng này tiếp tục được truyền vào mô hình EBM để tính toán hàm năng lượng và phân loại độ chín, cuối cùng dùng YOLO V8 để cắt vùng chứa quả xoài. Hệ thống đề xuất gồm 3 giai đoạn:

1. Trích xuất đặc trưng từ ảnh bằng ResNet101 pretrained [14], [18].
2. Phân loại xoài chín bằng EBM thông qua đánh giá hàm năng lượng [5], [6], [15].
3. Tiền xử lý ảnh bằng YOLO v8 để xác định vùng chứa xoài [1], [2].



Hình 3. Cấu trúc mô hình đề xuất

## 4.2. Giải thuật

Thuật toán thực hiện như sau: trước hết, ảnh đầu vào được đưa qua ResNet101 để trích xuất đặc trưng. Với mỗi lớp đầu ra  $y$ , mô hình tính giá trị hàm năng lượng  $E(x,y)$ . Lớp có năng lượng thấp nhất được chọn làm kết quả dự đoán. YOLO V8 được tích hợp để định vị chính xác vùng trái xoài trên ảnh gốc trước khi đưa vào phân loại.

- **Input:** ảnh đầu vào  $x$
- **Output:** lớp độ chín  $y$
- **Bước 1:** Trích đặc trưng  $x' = \text{ResNet101}(x)$
- **Bước 2:** Tính  $E(x',y)$  cho từng lớp  $y$
- **Bước 3:** Dự đoán nhãn =  $\arg \min_y E(x',y)$
- **Bước 4:** Phát hiện trái xoài bằng YOLO V8

## 5. KẾT QUẢ THỰC NGHIỆM

Tuy gộp từ hai tập dữ liệu khác nhau, tôi chỉ sử dụng một tập dữ liệu tổng hợp đã chuẩn hóa gồm 2.000 ảnh với nhãn nhị phân. Do đó, bài báo chỉ thực hiện hai kịch bản: một sử dụng phân loại Sigmoid truyền thống và một kết hợp EBM.

### 5.1. Tập dữ liệu

Hai tập dữ liệu được sử dụng gồm Mango and Banana Dataset (gồm cả ảnh xoài và chuối, mỗi loại khoảng 2.500 ảnh) và Mango Grading Dataset (chứa khoảng 2.500 ảnh xoài gán nhãn mức độ chín). Tổng cộng có khoảng 5.000 ảnh xoài ban

đầu. Tuy nhiên, để tránh hiện tượng học vẹt và giảm độ chênh lệch phân bố lớp giữa hai tập dữ liệu, tôi tiến hành tổng hợp và chọn lọc lại, chỉ giữ khoảng 2.000 ảnh có nhãn rõ ràng theo hai mức độ chín và chưa chín cho huấn luyện và kiểm thử. Do đó, các ma trận nhầm lẫn chỉ thể hiện kết quả trên tập dữ liệu sau khi gộp và lọc này với 2 lớp nhị phân, không phản ánh đầy đủ 8 mức độ chín gốc từ Mango Grading Dataset.

- Nguồn dữ liệu: Sử dụng hai bộ dữ liệu:

- *Mango and Banana Dataset (Ripe-Unripe)* của Viện Công nghệ Maharashtra.
- *Mango Variety and Grading Dataset* từ Đại học Nông nghiệp Muhammad Nawaz Shareef [13], [14].

### 5.2. Công cụ

- Nền tảng: Kaggle Notebook (GPU Tesla P100, RAM 13GB) với thư viện TensorFlow và Keras.
- Thư viện: TensorFlow và Keras.
- Mô hình: ResNet101 pretrained từ ImageNet.
- Tối ưu hóa: Sử dụng thuật toán Adam với learning rate mặc định.

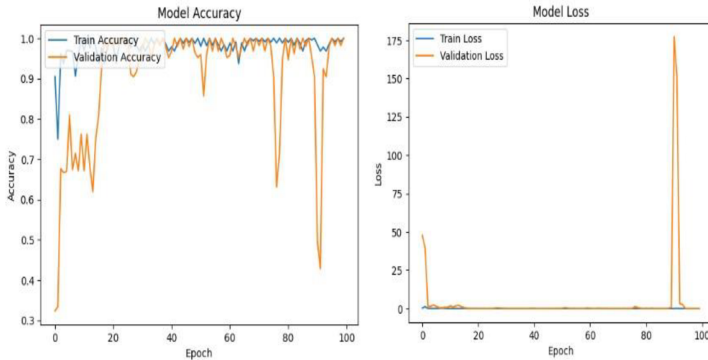
### 5.3. Kịch bản 1: ResNet101 không sử dụng EBM

Trong kịch bản đầu tiên, ResNet101 được dùng để trích xuất đặc trưng và phân

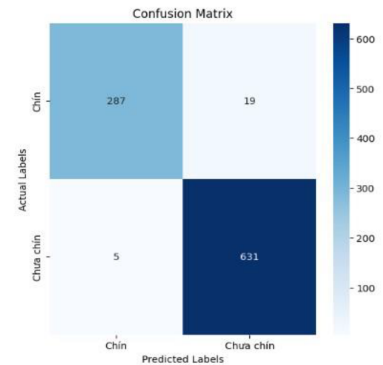
loại bằng lớp Sigmoid. Sau 50 epoch, mô hình đạt độ chính xác 95% và hàm mất mát còn 5%. Tuy nhiên, khi phân tích ma trận nhầm lẫn, mô hình còn nhầm lẫn ở các mức độ chín gần nhau.

- Cấu hình: Sử dụng ResNet101 như một bộ trích xuất đặc trưng, kết hợp với lớp phân loại Sigmoid truyền thống.


- Kết quả: Độ chính xác (Accuracy): 95.0% và Độ mất mát (Loss): 5.0 %.



Hình 4. Độ chính xác và hàm mất mát (Kịch bản 1)



Hình 5. Ma trận nhầm lẫn (Kịch bản 1)



Hình 6. Kết quả thu được (Kịch bản 1)

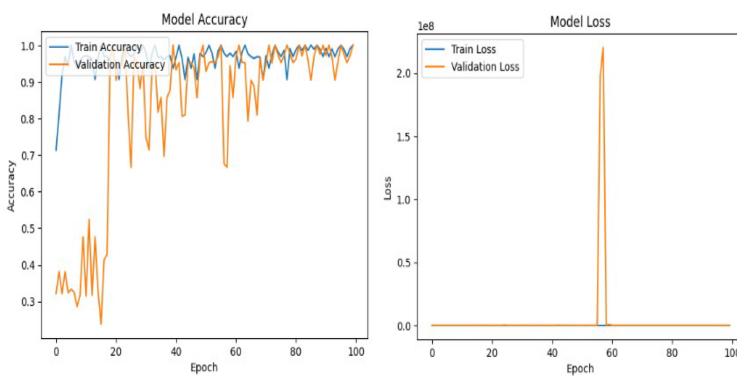
- Nhận xét: Mô hình đạt độ chính xác tương đối cao, tuy nhiên vẫn còn hạn chế trong việc phân biệt các mức độ chín gần nhau do đặc trưng trích xuất chưa đủ sâu.

### 5.4 Kịch bản 2: ResNet101 kết hợp EBM


Ở kịch bản thứ hai, EBM thay thế lớp phân loại truyền thống. Mô hình đạt độ chính xác 97.24% và loss còn 2.76%, cho thấy khả năng học tốt hơn nhờ mô hình hóa trực tiếp mối quan hệ ảnh – nhãn. Ma trận nhầm lẫn cũng cho thấy sự cải thiện rõ rệt.

- Cấu hình: Kết hợp ResNet101 để trích xuất đặc trưng và Energy-Based Model (EBM) để phân loại xoài chín.


- Kết quả: Độ chính xác (Accuracy): 97.24% và Hàm mất mát (Loss): 2.76%.



Hình 7. Độ chính xác và hàm mất mát (Kịch bản 2)



Hình 8. Ma trận nhầm lẫn (Kịch bản 2)



Hình 9. Kết quả thu được (Kịch bản 2)

- Nhận xét: Mô hình kết hợp EBM giúp

cải thiện đáng kể độ chính xác và giảm hàm mất mát, cho thấy khả năng phân biệt tốt hơn giữa các mức độ chín.

### 5.5 So sánh tổng quan

Bổ sung phân tích: EBM giảm lỗi nhầm lẫn ở các mẫu biên nhờ cơ chế cực tiểu năng lượng, nên Precision/Recall/F1/mAP đều cao hơn so với lớp Sigmoid truyền thống.

Bảng D. So sánh các chỉ số đánh giá (minh họa – cùng tập 2.000 ảnh)

Mô hình	Accuracy	Precision	Recall	F1-score	Loss (%)	mAP
ResNet101 + Sigmoid	95,0%	94,2%	93,8%	94,0%	5,0%	92,5%
ResNet101 + EBM (đề xuất)	97,24%	97,0%	96,8%	96,9%	2,76%	95,7%

Cả hai kịch bản được huấn luyện trong 50 epoch với batch size 32. Mô hình EBM mất thời gian huấn luyện dài hơn khoảng 20% do tính toán hàm năng lượng, nhưng bù lại đạt độ chính xác cao hơn.

## 6. KẾT LUẬN

Tuy nhiên, mô hình còn hạn chế trong việc xử lý dữ liệu chưa được cắt xoài rõ nét hoặc ảnh có nền phức tạp. Trong tương lai, tôi sẽ tích hợp thêm mô hình attention và mở rộng tập dữ liệu với nhiều điều kiện ánh sáng khác nhau để tăng khả năng tổng quát hóa.

Đề tài đã đề xuất ứng dụng mô hình

Energy-Based Model (EBM) trong việc phân loại độ chín của quả xoài dựa trên hình ảnh, nhằm khắc phục những hạn chế của phương pháp phân loại thủ công cũng như các mô hình học sâu truyền thống. Thông qua quá trình thu thập, xử lý dữ liệu và thiết kế mô hình, EBM cho thấy tiềm năng lớn trong việc cải thiện độ chính xác, khả năng tổng quát hóa và tính ổn định trong điều kiện thực tế. Kết quả nghiên cứu không chỉ góp phần nâng cao chất lượng sản phẩm xoài mà còn mở ra hướng ứng dụng công nghệ trí tuệ nhân tạo trong lĩnh vực nông nghiệp thông minh tại Việt Nam.

## TÀI LIỆU THAM KHẢO

- [1] T. H. Nguyen, T. T. Bui, and N. T. Tran, “Phát hiện và nhận dạng khuyết điểm trên vỏ trái xoài,” Hội nghị quốc gia lần thứ 14 về nghiên cứu cơ bản và ứng dụng Công nghệ thông tin (FAIR), pp. 449–455, 2021.
- [2] N. T. Dang, “Thiết lập mô hình phân loại trái xoài sử dụng công nghệ xử lý ảnh,” Trường Đại học Kỹ thuật Công nghiệp Thái Nguyên, 2021.
- [3] H. M. Tran, “Thiết kế hệ thống phân loại xoài tự động,” Tạp chí Khoa học và Công nghệ – Đại học Công nghiệp Hà Nội, vol. 64, no. 2, pp. 45–51, 2022.

- [4] Y. LeCun et al., “A Tutorial on Energy-Based Learning,” in Predicting Structured Data, MIT Press, 2006.
- [5] R. Kumar et al., “Deep Energy-Based Models for Computer Vision,” IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2021.
- [6] Z. Tu et al., “Energy-Based Learning for Scene Understanding,” International Journal of Computer Vision, vol. 128, pp. 2435-2462, 2020.
- [7] Nguyễn Văn B., “Ứng dụng Deep Learning trong nhận dạng và phân loại nông sản,” Tạp chí Khoa học Công nghệ Việt Nam, số 5, tr. 45-52, 2023.
- [8] D. Grattarola and C. Alippi, “Graph Neural Networks in TensorFlow and Keras with Spektral,” IEEE
- [9] F. Scarselli, Y. LeCun, “Energy Based Models in Deep Learning,” Annual Review of Control, Robotics, and Autonomous Systems, 2022.
- [10] Du, Y., & Mordatch, I., “Implicit Generation and Modeling with Energy-Based Models,” NeurIPS, 2019.
- [11] Grathwohl et al., “Your Classifier is Secretly an Energy Based Model and You Should Treat it Like One,” ICLR, 2020.
- [12] Naseer et al., “Fruit Recognition Using Deep Learning: A Review,” Computers and Electronics in Agriculture, 2023.
- [13] Liu et al., “Mango Ripeness Classification Using RGB Images and Convolutional Neural Networks,” IEEE Access, 2022.
- [14] Zheng et al., “On the Learning Dynamics of Deep Energy-Based Models,” ICML, 2021.
- [15] Nijkamp et al., “Learning Energy-Based Models by Diffusion Recovery Likelihood,” ICLR, 2021.
- [16] Gonzalez, R. C., & Woods, R. E., “Digital Image Processing,” 4th Edition, Pearson, 2018.
- [17] Mureşan, H., & Oltean, M., “Fruit Recognition from Images Using Deep Learning,” Acta
- [18] Nguyễn Văn A., “Nghiên cứu phương pháp nhận dạng trái cây tự động dựa trên học sâu,” Tạp chí Khoa học Công nghệ Việt Nam, 2023.
- [19] D. Kingma et al., “A Survey of Energy-Based Models,” Technical Report, OpenAI, 2021.