

## ANALISI PENGARUH URUTAN PREPROCESSING TERHADAP KINERJA MOBILENETV2 DAN VGG16 UNTUK KLASIFIKASI PENYAKIT DAUN CABAI

Syafa Nabila Putri Samsuri<sup>1</sup>; Martano<sup>2</sup>; Yudhistira Arie Wijaya<sup>3</sup>; Dodi Solihudin<sup>4</sup>; Tati Suprapti<sup>5</sup>;

Program Studi Teknik Informatika<sup>1,4,5</sup>  
Program Studi Manajemen Informatika<sup>2</sup>  
Program Studi Sistem Informasi<sup>3</sup>

STMIK IKMI Cirebon  
<https://ikmi.ac.id/page/18/?lang=de>  
Email : syafanabila051@gmail.com

(\*) Corresponding Author : syafanabila051@gmail.com  
Published : 31 Desember 2025

**Abstract**— This study examines the impact of different preprocessing sequences resizing, normalization, and augmentation on the performance of two Convolutional Neural Network (CNN) architectures, MobileNetV2 and VGG16, for classifying chili leaf disease, specifically Anthracnose. A dataset of 870 images consisting of two classes (Healthy and Anthracnose) was used to evaluate three preprocessing combinations: Resizing → Normalization → Augmentation (R→N→A), Resizing → Augmentation → Normalization (R→A→N), and Normalization → Augmentation → Resizing (N→A→R). The experimental results show that MobileNetV2 achieves its highest accuracy of 99.31% with the R→A→N sequence, whereas VGG16 performs best with the R→N→A sequence, reaching an accuracy of 95.14%. These findings indicate that preprocessing order significantly influences model performance and is not universally applicable across CNN architectures. The study highlights the importance of aligning preprocessing pipelines with model characteristics to optimize classification accuracy in plant disease detection.

**Keywords:** MobileNetV2, VGG16, preprocessing, image classification, plant disease

**Abstrak**- Penelitian ini mengevaluasi pengaruh perbedaan urutan praproses resizing, normalisasi, dan augmentasi terhadap kinerja dua arsitektur Convolutional Neural Network (CNN), yaitu MobileNetV2 dan VGG16, dalam klasifikasi citra penyakit tanaman khususnya penyakit Antraknosa pada daun cabai. Dataset yang digunakan terdiri dari 870 citra dengan dua kelas, Healthy dan Anthracnose. Tiga kombinasi urutan praproses diuji, yaitu Resizing → Normalisasi → Augmentasi (R→N→A), Resizing → Augmentasi → Normalisasi (R→A→N), dan Normalisasi → Augmentasi → Resizing (N→A→R). Hasil eksperimen menunjukkan bahwa MobileNetV2 mencapai performa terbaik pada kombinasi R→A→N dengan akurasi 99,31%, sedangkan VGG16 bekerja paling optimal pada kombinasi R→N→A dengan akurasi 95,14%. Perbedaan ini mengindikasikan bahwa urutan praproses tidak bersifat universal dan harus disesuaikan dengan karakteristik arsitektur model. Temuan ini dapat menjadi rujukan penting dalam perancangan pipeline praproses untuk klasifikasi citra penyakit tanaman. algoritma Naïve Bayes kurang efektif digunakan pada dataset yang sangat tidak seimbang. Oleh karena itu, peningkatan metode atau penanganan data tambahan seperti oversampling, SMOTE, atau pemilihan algoritma alternatif diperlukan untuk menghasilkan model yang lebih adil dan akurat dalam klasifikasi multi-kelas.

**Kata Kunci:** MobileNetV2, VGG16, preprocessing, klasifikasi citra, penyakit tanaman

### INTRODUCTION

Penyakit Antraknosa pada daun cabai merupakan salah satu faktor yang menurunkan produktivitas

pertanian di Indonesia. Identifikasi manual melalui inspeksi visual sering menimbulkan subjektivitas serta tidak efisien dalam skala besar (Wang et al.,

2022). Seiring dengan perkembangan visi komputer dan deep learning, metode klasifikasi citra berbasis Convolutional Neural Network (CNN) seperti MobileNetV2 dan VGG16 menjadi alternatif yang lebih akurat dan konsisten dalam mendeteksi penyakit tanaman (Atila & Uçar, 2021; Ferentinos, 2022).

Meskipun banyak penelitian memanfaatkan CNN untuk klasifikasi penyakit tanaman, evaluasi sistematis mengenai pengaruh urutan praproses (preprocessing) masih sangat terbatas. Tahapan praproses meliputi resizing, normalisasi, dan augmentasi memiliki peran penting dalam menentukan kualitas fitur yang diekstraksi model. Namun, setiap arsitektur CNN memiliki sensitivitas berbeda terhadap skala piksel, distribusi intensitas, dan variasi tekstur, sehingga urutan praproses berpotensi menghasilkan performa yang berbeda (Rahman, 2023; Xu et al., 2021).

Penelitian ini bertujuan mengevaluasi pengaruh tiga urutan praproses utama— $R \rightarrow N \rightarrow A$ ,  $R \rightarrow A \rightarrow N$ , dan  $N \rightarrow A \rightarrow R$ —terhadap kinerja MobileNetV2 dan VGG16 dalam klasifikasi citra daun cabai dari dataset berisi 870 gambar dengan dua kelas: Healthy dan Anthracnose. Hasil penelitian menunjukkan bahwa urutan praproses optimal berbeda untuk setiap arsitektur: MobileNetV2 mencapai performa tertinggi pada  $R \rightarrow A \rightarrow N$ , sedangkan VGG16 paling optimal pada  $R \rightarrow N \rightarrow A$ . Temuan ini menegaskan bahwa perancangan pipeline praproses perlu disesuaikan dengan karakteristik internal model, sehingga tidak dapat digeneralisasi untuk seluruh arsitektur CNN.

## THEORETICAL FRAMEWORK

Penelitian terkait penerapan metode komputasional dalam domain teknik dapat ditemukan pada studi sebelumnya ("Algoritma Space Vector," 2020). Studi tersebut turut memperkuat relevansi penggunaan metode komputasional dalam penelitian ini.

### Convolutional Neural Network (CNN)

(Gomez & Pineda, 2023) Menunjukkan bahwa arsitektur CNN mampu mendeteksi penyakit tanaman dengan akurasi tinggi meskipun terdapat variasi kondisi pencahayaan dan ciri visual, sehingga memperkuat relevansi penggunaan CNN dalam penelitian ini. Convolutional Neural Network merupakan arsitektur deep learning yang dirancang untuk memproses data visual melalui operasi convolution, pooling, dan ekstraksi fitur bertingkat. CNN telah terbukti efektif dalam tugas klasifikasi penyakit tanaman karena kemampuannya mengenali pola tekstur, bentuk, dan gejala visual secara otomatis (Ferentinos, 2022). Dalam

penelitian ini, dua arsitektur populer digunakan: MobileNetV2 yang ringan dan efisien serta VGG16 yang dikenal stabil dalam ekstraksi fitur kompleks (Atila & Uçar, 2021; Wagner, 2021).

### Peran Preprocessing dalam Klasifikasi Citra

Preprocessing merupakan tahap penting sebelum citra dimasukkan ke model CNN. Teknik umum seperti resizing, normalisasi piksel, dan augmentasi berfungsi meningkatkan konsistensi data, stabilitas numerik, serta generalisasi model (Ashurov et al., 2025; Le et al., 2024). Namun, beberapa studi menunjukkan bahwa urutan penerapan preprocessing dapat memengaruhi kualitas fitur yang dipelajari model, terutama pada dataset dengan variasi tinggi dalam pencahayaan, latar belakang, dan rasio aspek (Rahman, 2023; Xu et al., 2021).


Resizing menyamakan dimensi citra agar sesuai dengan input CNN. Normalisasi menyeimbangkan rentang intensitas piksel sehingga mempercepat konvergensi pelatihan. Augmentasi menambah keragaman data dengan transformasi acak seperti rotasi dan flipping untuk mencegah overfitting. Kombinasi urutan ketiganya diperkirakan memengaruhi stabilitas representasi fitur.(Gomez & Pineda, 2023).

### Kesenjangan Penelitian

Walaupun banyak penelitian telah menerapkan teknik preprocessing, sebagian besar studi tidak menilai dampak urutan preprocessing secara sistematis terhadap masing-masing arsitektur CNN. Selain itu, belum ada penelitian yang secara langsung membandingkan MobileNetV2 dan VGG16 menggunakan kombinasi urutan praproses yang sama pada dataset penyakit daun cabai. Hal ini menunjukkan adanya gap yang ingin diisi oleh penelitian ini.

## MATERIALS AND METHODS

Penelitian ini menggunakan pendekatan kuantitatif berbasis eksperimen untuk mengevaluasi pengaruh urutan praproses (resizing, normalisasi, dan augmentasi) terhadap performa dua arsitektur CNN, yaitu MobileNetV2 dan VGG16. Setiap kombinasi praproses diterapkan pada dataset yang sama, dan hasilnya dianalisis menggunakan metrik akurasi, F1-score, serta uji signifikansi statistik. Adapun untuk Tahapan penelitian ditunjukkan pada Gambar 1 berikut.



Gambar 1 Tahapan Penelitian

### Pengumpulan Data

Penelitian ini dimulai dengan tahap pengumpulan data yang diperoleh dari kaggle yang berjudul “Anthracnose Disease in Chili – Palnadu, AP”, yang terdiri dari 870 citra daun cabai dari dua kelas: Healthy dan Anthracnose. Dataset dibagi menjadi tiga subset menggunakan struktur direktori asli: 572 citra untuk pelatihan, 154 untuk validasi, dan 144 untuk pengujian. Meskipun terdapat ketidakseimbangan pada subset tertentu, analisis tetap dilakukan dengan mempertimbangkan proporsi kelas pada setiap pembagian.

### Pengolahan Data

Dataset citra daun yang digunakan yaitu DataAnthracnose berhasil dibaca dan dimuat ke dalam lingkungan pemrograman Python. Citra-citra tersebut mencakup berbagai kondisi, baik yang sehat maupun yang menunjukkan gejala penyakit. Proses ini menghasilkan jumlah total sampel yang siap digunakan dalam tahap praproses. Berikut sampel dataset pada gambar 2.



Gambar 2 Visualisasi Dataset


### EDA

Selanjutnya tahap Eksplorasi Data Awal (EDA) dilakukan untuk memahami karakteristik dataset citra daun cabai yang digunakan dalam

proses pelatihan dan evaluasi model deteksi penyakit Antraknosa. Tahap ini bertujuan untuk memeriksa struktur data, distribusi kelas, dimensi citra, rasio aspek, serta variasi visual yang dapat memengaruhi proses *preprocessing* dan performansi model.

### Preprocessing

Setelah dilakukan proses EDA, tahap selanjutnya adalah *preprocessing* yang terdiri dari Tiga teknik utama preprocessing digunakan dalam penelitian ini. Berikut hasil *Preprocessing* yang disajikan pada gambar 3.



Gambar 1 Hasil Preprocessing

1. Resizing: seluruh citra diubah ke resolusi 128×128 piksel agar sesuai dengan input model CNN.
  2. Normalisasi: intensitas piksel dinormalisasi ke rentang 0–1 menggunakan *rescale* (1/255) untuk meningkatkan stabilitas pelatihan.
  3. Augmentasi: diterapkan transformasi acak seperti rotasi  $\pm 15^\circ$ , flipping horizontal/vertikal, zoom 0.8–1.2, dan penyesuaian brightness untuk memperluas variasi data dan mengurangi overfitting.
- Tiga urutan praproses yang diuji adalah:
1. R→N→A (Resizing → Normalisasi → Augmentasi)
  2. R→A→N (Resizing → Augmentasi → Normalisasi)
  3. N→A→R (Normalisasi → Augmentasi → Resizing).

### Arsitektur Model dan Pelatihan

Selanjutnya Model dibangun menggunakan TensorFlow 2.x dan Keras dengan parameter sebagai berikut:

1. Ukuran input: 128×128×3
2. Optimizer: Adam, learning rate 0.0001
3. Epoch: 20
4. Batch size: 32
5. *Fine-tuning*: hanya blok konvolusi terakhir dibuka, sementara lapisan awal dibekukan
6. *Hardware*: Google Colab Pro+ dengan GPU NVIDIA Tesla T4

MobileNetV2 digunakan karena keunggulan efisiensi dan arsitektur *depthwise separable convolution*, sedangkan VGG16 dipilih sebagai model konvolusi klasik dengan performa ekstraksi fitur yang stabil.

### Evaluasi Model

Tahapan terakhir dalam penelitian ini adalah evaluasi model, yang bertujuan mengukur tingkat keakuratan model dalam mengklasifikasikan citra daun cabai. Evaluasi dilakukan menggunakan *confusion matrix* untuk melihat distribusi prediksi benar dan salah pada setiap kelas, serta metrik akurasi, presisi, recall, dan F1-score. Metrik-metrik tersebut memberikan gambaran menyeluruh mengenai performa model, terutama dalam mengukur ketepatan prediksi, sensitivitas model terhadap setiap kelas, dan keseimbangan antara presisi dan recall. Uji-t dua sampel untuk menguji perbedaan signifikan antar kombinasi urutan praproses dan antar model.

## RESULTS AND DISCUSSION

Penelitian ini mengevaluasi tiga urutan praproses utama  $R \rightarrow N \rightarrow A$ ,  $R \rightarrow A \rightarrow N$ , dan  $N \rightarrow A \rightarrow R$ —pada dua arsitektur CNN, yaitu MobileNetV2 dan VGG16. Dataset terdiri dari 870 citra daun cabai yang terbagi ke dalam subset train, validate, dan test. Setiap model dilatih selama 20 epoch dengan parameter yang konsisten untuk menjaga validitas perbandingan.

### Hasil MobileNetV2

MobileNetV2 menunjukkan sensitivitas tinggi terhadap urutan praproses, dengan hasil sebagai berikut pada gambar 4.

| combination                         | accuracy        | loss            | f1_macro        | precision anthracnose | recall anthracnose | f1 anthracnose  |
|-------------------------------------|-----------------|-----------------|-----------------|-----------------------|--------------------|-----------------|
| Resizing + Normalisasi + Augmentasi | 0.9907 ± 0.0013 | 0.0390 ± 0.0004 | 0.9900 ± 0.0013 | 0.9712 ± 0.0004       | 0.9902 ± 0.0013    | 0.9805 ± 0.0010 |
| Resizing + Augmentasi + Normalisasi | 0.9931 ± 0.0008 | 0.0287 ± 0.0006 | 0.9930 ± 0.0008 | 0.9990 ± 0.0001       | 0.9990 ± 0.0001    | 0.9985 ± 0.0001 |
| Normalisasi + Augmentasi + Resizing | 0.9901 ± 0.0012 | 0.0312 ± 0.0011 | 0.9849 ± 0.0011 | 0.9837 ± 0.0011       | 0.9832 ± 0.0011    | 0.9851 ± 0.0011 |

Gambar 2 Hasil Evaluasi MobileNetV2

1.  $R \rightarrow A \rightarrow N$ : akurasi terbaik mencapai 99.31%
2.  $R \rightarrow N \rightarrow A$ : akurasi tinggi tetapi sedikit lebih rendah 99.07%
3.  $N \rightarrow A \rightarrow R$ : performa menurun signifikan 39.81%

Performansi terbaik pada  $R \rightarrow A \rightarrow N$  menunjukkan bahwa augmentasi lebih efektif ketika diterapkan sebelum normalisasi, karena menghasilkan variasi citra yang tetap ternormalisasi secara konsisten sebelum diproses layer awal model.

### Hasil Model VGG16

Berbeda dengan MobileNetV2, VGG16 lebih stabil ketika normalisasi dilakukan sebelum augmentasi. Hasil evaluasi ditunjukkan pada gambar 5.

| combination                         | accuracy        | loss            | f1_macro        | precision anthracnose | recall anthracnose | f1 anthracnose  |
|-------------------------------------|-----------------|-----------------|-----------------|-----------------------|--------------------|-----------------|
| Resizing + Normalisasi + Augmentasi | 0.9514 ± 0.0080 | 0.1705 ± 0.0041 | 0.9525 ± 0.0094 | 0.9473 ± 0.0015       | 0.9706 ± 0.0000    | 0.9545 ± 0.0078 |
| Resizing + Augmentasi + Normalisasi | 0.9444 ± 0.0170 | 0.2003 ± 0.0050 | 0.9464 ± 0.0169 | 0.9123 ± 0.0475       | 1.0000 ± 0.0000    | 0.9557 ± 0.0089 |
| Normalisasi + Augmentasi + Resizing | 0.2361 ± 0.0000 | 1.5425 ± 0.0460 | 0.0902 ± 0.0000 | 0.2361 ± 0.0000       | 1.0000 ± 0.0000    | 0.3838 ± 0.0000 |


Gambar 3 Hasil Evaluasi VGG16

1.  $R \rightarrow N \rightarrow A$ : kombinasi terbaik dengan akurasi 95.14%
2.  $R \rightarrow A \rightarrow N$ : akurasi masih tinggi 94.44% namun lebih rendah dari  $R \rightarrow N \rightarrow A$
3.  $N \rightarrow A \rightarrow R$ : performa sangat buruk 23.61%

Hasil ini menunjukkan bahwa VGG16 lebih sensitif terhadap perubahan intensitas piksel akibat augmentasi, sehingga praproses normalisasi sebelum augmentasi lebih ideal.

### Analisis Confusion Matrix MobileNetV2

Berikut hasil evaluasi model MobileNetV2 kombinasi teknik preprocessing yang disajikan pada gambar 6.



Gambar 4 Confusion Matrix - MobileNetV2


Confusion matrix menunjukkan performa yang sangat stabil:

1. Kelas Anthracnose: 34 benar, 0 salah klasifikasi
2. Kelas Healthy: 109 benar, hanya 1 salah klasifikasi

Hasil ini mendukung akurasi 99.31% dengan F1-score makro yang sangat tinggi, menunjukkan kemampuan generalisasi MobileNetV2 yang kuat.

### Analisis Confusion Matrix VGG16

Berikut hasil evaluasi model MobileNetV2 kombinasi teknik preprocessing yang disajikan pada gambar 7.



Gambar 5 Confusion Matrix - VGG16

### Analisis Statistik (Uji-t)

Uji-t dilakukan untuk mengevaluasi signifikansi perbedaan antar model dan antar kombinasi praproses. Berikut hasil uji-t disajikan pada gambar 8.

```
--- Uji T: MobileNetV2 R-A-N vs VGG16 R-N-A ---  
P-value: 0.0210 (Signifikan)  
Rata-rata Akurasi: MobileNetV2 R-A-N = 0.9931, VGG16 R-N-A = 0.9514  
  
--- Uji T: MobileNetV2 R-A-N vs MobileNetV2 R-N ---  
P-value: 0.4226 (Tidak Signifikan)  
Rata-rata Akurasi: MobileNetV2 R-A-N = 0.9931, MobileNetV2 R-N = 0.9931  
  
--- Uji T: MobileNetV2 R-N vs MobileNetV2 R ---  
P-value: 0.0019 (Signifikan)  
Rata-rata Akurasi: MobileNetV2 R-N = 0.9931, MobileNetV2 R = 0.3287
```

Gambar 8 Analisis Uji-t

1. MobileNetV2 (R→A→N) vs VGG16 (R→N→A): p-value = 0.0210 → signifikan. Artinya, performa MobileNetV2 secara konsisten lebih baik.
2. MobileNetV2 (R→A→N) vs R→N: p-value = 0.4226 → tidak signifikan. Kedua urutan ini menghasilkan performa stabil.
3. MobileNetV2 (R→N) vs R: p-value = 0.0019 → signifikan. Normalisasi memberikan dampak besar.

### CONCLUSION

Hasil penelitian menunjukkan bahwa urutan praproses tidak bersifat universal dan sangat bergantung pada arsitektur CNN. MobileNetV2, dengan struktur *depthwise separable convolution*, lebih optimal ketika augmentasi dilakukan sebelum normalisasi, sehingga variasi citra tetap terjaga namun ternormalisasi secara stabil. Sebaliknya, VGG16 memiliki lapisan awal yang sensitif terhadap intensitas piksel, sehingga normalisasi lebih efektif dilakukan sebelum augmentasi.

Kombinasi N→A→R menghasilkan performa yang buruk pada kedua model, menunjukkan bahwa resizing tidak boleh dilakukan setelah augmentasi dan normalisasi karena dapat mendistorsi fitur visual penting. Selain itu, ketidakseimbangan proporsi kelas di subset train menambah tantangan pada generalisasi model, terutama untuk VGG16 yang menghasilkan lebih banyak false positive.

Secara keseluruhan, MobileNetV2 terbukti lebih adaptif terhadap variasi hasil augmentasi dan menghasilkan performa jauh lebih tinggi dibanding VGG16. Temuan ini memberikan implikasi penting bagi perancangan pipeline preprocessing dalam sistem deteksi penyakit tanaman berbasis citra. Penelitian ini menunjukkan bahwa urutan praproses memiliki pengaruh signifikan terhadap performa model CNN dalam klasifikasi citra penyakit tanaman. MobileNetV2 mencapai performa terbaik pada kombinasi Resizing → Augmentasi → Normalisasi (R→A→N) dengan akurasi 99.31%, sementara VGG16 memperoleh hasil optimal pada kombinasi Resizing → Normalisasi → Augmentasi (R→N→A) dengan akurasi 95.14%. Perbedaan ini menegaskan bahwa urutan praproses tidak bersifat universal dan harus disesuaikan dengan karakteristik internal masing-masing arsitektur. Selain itu, kombinasi N→A→R terbukti tidak efektif untuk kedua model, menunjukkan bahwa resizing tidak boleh dilakukan pada tahap akhir. Uji-t juga mengonfirmasi bahwa perbedaan performa antara kedua model bersifat signifikan, terutama dalam membandingkan kombinasi terbaik masing-masing model.

Selain hasil utama yang diperoleh, penelitian ini juga memberikan gambaran lebih luas mengenai pentingnya menyesuaikan urutan praproses dengan karakteristik model. Faktor seperti struktur lapisan awal CNN, sensitivitas terhadap intensitas piksel, serta variasi tekstur pada citra daun sangat berpengaruh terhadap kualitas representasi fitur yang diekstraksi. Oleh karena itu, peneliti dan praktisi perlu mempertimbangkan dengan cermat aspek-aspek tersebut sebelum menentukan pipeline praproses yang digunakan. Serta membuka peluang untuk eksplorasi lanjutan, khususnya dalam pengembangan model yang lebih adaptif terhadap variasi data nyata di lapangan. Kondisi pencahayaan yang berubah-ubah, latar belakang yang beragam, serta tingkat keparahan penyakit yang berbeda-beda dapat menjadi tantangan dalam proses klasifikasi citra. Dengan memahami hubungan antara penerapan praproses dan stabilitas fitur visual, sistem deteksi penyakit tanaman berbasis pembelajaran mendalam dapat dirancang menjadi lebih robust dan akurat.

### REFERENCE

- Algoritma space vector. (2020). *Jurnal Amplifier*, 5(2), 1–6.
- Ashurov, A. Y., Al Gaashani, M. S. A. M., Samee, N. A., Alkanhel, R., Atteia, G., Abdallah, H. A., & Muthanna, M. S. A. (2025). Enhancing plant disease detection through deep learning: A depthwise CNN with squeeze and excitation

- integration and residual skip connections. *Frontiers in Plant Science*, 15, 1505857. <https://doi.org/10.3389/fpls.2024.1505857>
- Atila, U., & Uçar, A. (2021). Plant disease classification using deep transfer learning. *Expert Systems with Applications*, 168, 114363.
- Ferentinos, E. (2022). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318.
- Gomez, H., & Pineda, R. (2023). Evaluation of convolutional architectures for crop disease identification. *Journal of Imaging*, 9(1), 1–10.
- Le, A. T., Nguyen, H. M., & Tran, D. H. (2024). Optimizing plant disease classification with hybrid convolutional recurrent neural networks and image preprocessing. *Applied Sciences*, 14(19), 9118. <https://doi.org/10.3390/app14199118>
- Rahman, S. (2023). Systematic evaluation of augmentation and preprocessing pipelines in deep learning-based plant disease recognition. *Artificial Intelligence in Agriculture*, 6, 23–34.
- Wagner, K. (2021). Transfer learning for agricultural image classification: A comprehensive review. *IEEE Access*, 9, 112233–112250.
- Wang, X., Chen, L., & Zhao, Y. (2022). Deep learning-based detection of plant leaf diseases under complex field conditions. *Computers and Electronics in Agriculture*, 198, 1–12.
- Xu, Q., Liu, H., & Li, Z. (2021). Impact of preprocessing strategies on CNN performance for image-based crop disease classification. *Information Processing in Agriculture*, 8(4), 572–584.