




SIDANG TUGAS AKHIR

PENERAPAN OPEN-SET RECOGNITION PADA KLASIFIKASI PENYAKIT DAUN SAWIT BERBASIS MOBILENETV4



Tito Ariffianto Miftahul Huda
11221035

Dosen Pembimbing Utama
Gusti Ahmad Fanshuri Alfarisy, Ph.D.

Dosen Pembimbing Pendamping
Rizal Kusuma Putra, M.T.

Dosen Penguji 1
Ramadhan Paninggali S.Si., M.Si., M.Sc.

Dosen Penguji 2
Rizky Amelia, S.Si., M.Han.

LATAR BELAKANG



Kelapa Sawit : Kontribusi ekonomi besar bagi Indonesia.

Penyakit daun :

- Menurunkan Produksi minyak
- bercak daun (Culvuria sp.) turunkan hasil hingga 39%(Pribadi dkk 2022)

Identifikasi dini diperlukan untuk mencegah kerugian dan meningkatkan efisiensi pengelolaan perkebunan.



Identifikasi manual

- subjektivitas pengamat
- Lambat
- real-time (Upadhyay dkk., 2025).

CNN mampu mengidentifikasi penyakit dari citra daun secara akurat melalui ekstraksi fitur otomatis (Asrianda dkk., 2021).

CNN

- **closed-set**
- berisiko salah ketika menghadapi data baru (out-of-distribution).



Open-Set Recognition :

model mengenali kelas known sekaligus menolak sampel unknown

MobileNetV4

backbone ringan yang efisien untuk perangkat dengan keterbatasan komputasi (Qin et al., 2024).

Top-K Logit Disparity Score (TKLDS)

meningkatkan kemampuan OSR known dan unknown (Alfarisy et al., 2025).

RUMUSAN MASALAH

01

Bagaimana kinerja tiap varian model MobileNetV4 pada skenario closed-set dan open-set berdasarkan metrik evaluasi klasifikasi?

02

Bagaimana pengaruh variasi parameter K pada TKLDS terhadap kemampuan model mengenali sampel unknown?

03

Bagaimana latensi inferensi model sebagai indikator efisiensi komputasi?

04

Bagaimana trade-off antara kemampuan klasifikasi dan latensi inferensi pada setiap varian MobileNetV4 dalam skenario open-set recognition berbasis TKLDS?

TUJUAN PENELITIAN

01.

Bagaimana kinerja model MobileNetV4 pada skenario closed-set dan open-set berdasarkan metrik evaluasi klasifikasi?

02.

Bagaimana pengaruh variasi parameter K pada TKLDS terhadap kemampuan model mengenali sampel unknown?

03.

Bagaimana latensi inferensi model sebagai indikator efisiensi komputasi?

04.

Mengevaluasi trade-off antara kemampuan klasifikasi dan latensi inferensi pada setiap varian MobileNetV4.

KONTRIBUSI PENELITIAN



- 01.** Menambah literatur penerapan OSR berbasis TKLDS pada penyakit tanaman, khususnya kelapa sawit.

- 02.** Memberikan bukti awal kelayakan MobileNetV4 + TKLDS untuk sistem klasifikasi penyakit yang ringan dan adaptif.

- 03.** Menjadi acuan pemilihan model untuk aplikasi mobile/edge berbasis citra.

BATASAN MASALAH

- 01.** Fokus pada klasifikasi citra penyakit daun kelapa sawit.

- 02.** Penelitian hanya menggunakan dataset Palm Disease Dataset dari Kaggle dan Dataset dari PT. Gatipura Mulya penelitian oleh Oktavanda dkk, 2025

- 03.** Arsitektur yang digunakan terbatas pada MobileNetV4 pra-latih dengan fine-tuning.

- 04.** Metode OSR yang digunakan hanya TKLDS, tanpa perbandingan dengan metode OSR lain.

- 05.** Evaluasi terbatas pada metrik klasifikasi dan latensi inferensi, tanpa membahas efisiensi energi atau deployment.

TINJAUAN PUSTAKA

Kelapa sawit & Penyakit Daun

Kelapa sawit: Komoditas strategis ekonomi indonesia

Penyakit Daun: menurunkan produktivitas

MobileNetV4, OSR, TKLDS

MobileNetV4: Backbone efisien untuk perangkat mobile. Menggunakan Universal Inverted Bottleneck (UIB) & Mobile MQA (Qin et al., 2024).

Open-Set Recognition (OSR): Mengatasi kelemahan Closed-Set. Sistem mampu menolak data Unknown (di luar data latih).

TKLDS (Top-K Logit Disparity Score): Metode scoring untuk membedakan Known vs Unknown berdasarkan disparitas logit (Alfarisy et al., 2025).

DEEP LEARNING, CNN, PCD

Deep Learning & CNN: Ekstraksi fitur otomatis dari data visual (citra daun).

Pengolahan Citra: Pra-pemrosesan (resize, noise removal) untuk standarisasi input agar model lebih optimal.


Metrik Evaluasi

Closed-Set: Akurasi, Presisi, Recall, F1-Score.

Open-Set: AUROC (Area Under ROC)

Latensi Inferensi

METODOLOGI PENELITIAN



Gambar 3.1 Diagram alir penelitian

PENGUMPULAN DATA

Palm Disease Dataset - 4 Kelas

PT. Gatipura Mulya (Bibit Sawit) - 3 Kelas.

Total: 844 Citra

Kelas: 7 kelas penyakit daun sawit

Pre-processing: Resize, normalisasi, one hot encoding (Standar ImageNet) & Augmentasi (Flip, Rotate, zooming) untuk atasi data tidak seimbang.



Skenario Open-Set (known-unknown)

Known (5 kelas)

- Healthy Seedlings
- Curvularia sp.
- Night Beetle
- Dryness
- Scale Insect

Unknown (2 kelas)

- Fungal Disease
- Magnesium Deficiency

Split Dataset

- Train 70%
- Validation 15%
- Test 15%

Arsitektur dan Strategi Pelatihan

Backbone

- MobileNetV4 Conv-Small
- MobileNetV4 Conv-Medium
- MobileNetV4 Conv-Large

1. Frozen Backbone + Custom Classifier Head

- Seluruh parameter backbone dibekukan.
- MobileNetV4 : feature extractor.
- custom classifier head yang terdiri dari:
 - Hidden layer 512 neuron
 - ReLU
 - Dropout 0,3
- Hanya classifier head yang dilatih

Tujuan:

Mempertahankan representasi fitur hasil pretraining ImageNet dan mengurangi risiko overfitting.

2. Staged Fine-Tuning + Default Classifier Head

- Tahap awal: hanya classifier bawaan yang dilatih.
- Tahap berikutnya: seluruh parameter backbone dibuka kembali (unfreeze).
- Dilakukan fine-tuning end-to-end menggunakan learning rate yang lebih kecil.


Tujuan:

Menyesuaikan representasi fitur MobileNetV4 agar lebih sesuai dengan karakteristik dataset penyakit daun kelapa sawit.

Implementasi OSR dan TKLDS

$$TKLDS_k(z) = \begin{cases} z_1 & , k = 1 \\ \frac{1}{k-1} \sum_{i=2}^k (z_1 - z_i) & , k > 1 \end{cases}$$

A. Evaluasi pada
Tahap Validasi



B. Evaluasi Open-Set
pada Tahap Pengujian



Variabel dan Evaluasi

Variabel Eksperimen

- **Variabel Bebas:**
 - Nilai k pada persamaan TKLDS (uji sensitivitas jumlah logit)
 - Augmentasi data.
- **Variabel Terikat:** Akurasi, Precision, Recall, F1-score, AUROC, dan Latensi (Waktu Inferensi)

Metrik Evaluasi

- **Closed-Set Performance:** Akurasi, Precision, Recall, F1-Score
- **Open-Set Performance:** AUROC (kemampuan membedakan Known vs Unknown), Youden Index
- **Latensi Inferensi**

HASIL DAN PEMBAHASAN


Evaluasi closed-set classification

Evaluasi open-set recognition (OSR)

Analisis latensi inferensi


Analisis trade-off performa dan efisiensi

Desain Eksperimentasi





Parameter	Nilai
Input Size	224×224
Optimizer	Adam
Loss	CrossEntropy
Batch size	32
Epoch (frozen backbone)	50
Epoch (staged fine-tuning)	10+40
GPU	Tesla T4

Oversampling Data



- **Random Oversampling**
- **Menyeimbangkan kelas known**
- **Hanya diterapkan pada data train**



Hasil Evaluasi Closed Set

Varian	Strategi	Accuracy	Precision	Recall	F1-Score
<i>Small</i>	<i>Frozen Backbone + Custom Classifier Head</i>	0.798246	0.751931	0.764455	0.746332
<i>Small</i>	Staged Fine-Tuning + Default Classifier Head	0.719298	0.63468	0.650267	0.630727
<i>Medium</i>	<i>Frozen Backbone + Custom Classifier Head</i>	0.77193	0.704619	0.696411	0.699844
<i>Medium</i>	Staged Fine-Tuning + Default Classifier Head	0.798246	0.714079	0.703784	0.707371
<i>Large</i>	<i>Frozen Backbone + Custom Classifier Head</i>	0.736842	0.675224	0.679838	0.675201
<i>Large</i>	Staged Fine-Tuning + Default Classifier Head	0.692982	0.632111	0.639744	0.634578

- MobileNetV4-Conv-Small + Frozen Backbone menghasilkan performa closed-set terbaik.
- Strategi Frozen Backbone cenderung lebih efektif dibanding Staged Fine-Tuning.
- Model yang lebih besar tidak selalu memberikan akurasi yang lebih tinggi.

Hasil Evaluasi Open-Set

Metode

- MSP
- TKLDS dengan $k=\{1,2,3,4,5\}$

Metriks



AUROC

Tujuan

Membedakan:

- Known classes
- Unknown classes

MobileNetV4 conv Small



Hasil terbaik:

Frozen Backbone + TKLDS k=2
AUROC = 0,7627

Pengaruh variasi k



k=1 → AUROC lebih rendah

k=2 → AUROC tertinggi

k>2 → AUROC kembali menurun

Conv-Small lebih stabil
menggunakan Frozen
Backbone

MobileNetV4 conv Medium



Hasil terbaik



Staged Fine-Tuning
+ TKLDS k=1
AUROC = 0,8282

Pengaruh variasi k

- k=1 memberikan AUROC tertinggi.
- k=3-5 masih relatif stabil.
- Distribusi logit lebih konsisten dibanding varian lain.

Conv-Medium memberikan performa OSR terbaik

MobileNetV4 conv Large



Freeze

Terbaik pada k=2
AUROC = 0,6553

Fine-Tuning

Terbaik pada k=1
AUROC = 0,7873

Pengaruh variasi k

- Saat backbone dibekukan, k=2 lebih optimal.
- Setelah fine-tuning, k=1 sudah cukup memberikan pemisahan known dan unknown yang baik.


PENGARUH VARIASI PARAMETER k pada TKLDS

Backbone	Strategi	k terbaik
Small	Freeze	2
Small	Fine-Tuning	2
Medium	Freeze	2
Medium	Fine-Tuning	1
Large	Freeze	2
Large	Fine-Tuning	1


Temuan

- Backbone yang dibekukan cenderung optimal pada $k=2$.
- Backbone yang di-fine tuning cenderung optimal pada $k=1$.
- Pemilihan parameter k berpengaruh terhadap kemampuan separasi known dan unknown.

ANALISIS LATENSI INFERENSI




TRADE OFF F1-Score vs Latency



- Conv-Small paling cepat
- Conv-Medium memberikan keseimbangan terbaik
- Conv-Large memiliki biaya komputasi tinggi

TRADE OFF AUROC vs Latency




Hasil terbaik

**MobileNetV4 Conv-Medium +
Fine-Tuning + TKLDS k=1**

- **AUROC = 0,8282**
- **Latensi $\approx$ 1,62 ms/image**

TRADE OFF Rata Rata F1 Score & AUROC vs Latency



- Conv-Small cocok untuk sistem ringan
- Conv-Medium memberikan keseimbangan terbaik
- Conv-Large kurang efisien.

KESIMPULAN

1. Evaluasi Closed-set dan Open-set

MobileNetV4 Conv-Small + Frozen Backbone menghasilkan performa closed-set terbaik dengan accuracy 79,82% dan F1-score 74,63%.

MobileNetV4 Conv-Medium + Staged Fine-Tuning + TKLDS k=1 menghasilkan performa open-set terbaik dengan AUROC 0,8282.

2. Pengaruh Variasi Parameter k pada TKLDS

- Variasi parameter k memengaruhi kemampuan deteksi unknown.
- Nilai k kecil (k=1 dan k=2) memberikan AUROC yang lebih tinggi.
- Nilai k yang terlalu besar menurunkan kemampuan separasi known dan unknown.

3. Efisiensi Komputasi

- Conv-Small memiliki latensi inferensi terendah (0,67–0,70 ms/image).
- Conv-Large memiliki latensi tertinggi (3,72–3,77 ms/image).
- Kompleksitas backbone lebih berpengaruh terhadap latensi dibandingkan strategi pelatihan.

4. Analisis Trade-Off

- Conv-Small unggul pada kecepatan inferensi.
- Conv-Large memiliki kompleksitas tinggi tanpa peningkatan performa yang sebanding.
- MobileNetV4 Conv-Medium + Staged Fine-Tuning + TKLDS k=1 memberikan keseimbangan terbaik antara:
 - kemampuan klasifikasi,
 - deteksi unknown,
 - dan efisiensi inferensi.



**TERIMA
KASIH**

