

ANALISIS DAN KLASIFIKASI IMEJ MAKANAN BERASASKAN KANDUNGAN NUTRISI MENGGUNAKAN TEKNIK CNN

NUR ALYSSA SOFEA BINTI EDRIAN

PROF. MADYA DR. SABRINA TIUN

*Fakulti Teknologi & Sains Maklumat, Universiti Kebangsaan Malaysia, 43600 UKM Bangi,
Selangor Darul Ehsan, Malaysia*

ABSTRAK

Pengenalpastian jenis makanan secara automatik daripada imej boleh membantu pengguna mendapatkan maklumat pemakanan dengan lebih pantas dan mudah, terutamanya dalam konteks pemantauan diet dan kesedaran kesihatan. Masalah utama yang ingin diselesaikan ialah kekurangan sistem pintar yang mampu mengenal pasti jenis makanan Malaysia secara visual dan memaparkan kandungan nutrisi secara automatik dan interaktif. Kebanyakan sistem sedia ada hanya tertumpu kepada makanan barat dan tidak menyokong maklumat makanan tempatan, sekali gus mengehadkan penggunaannya kepada masyarakat Malaysia. Sebagai penyelesaian, projek ini membangunkan dua model klasifikasi imej iaitu model CNN manual dan model pralatih MobileNetV2. Kedua-dua model dilatih menggunakan set data Malaysia Food 11 yang mengandungi 11 kelas makanan tempatan. Maklumat nutrisi diperoleh daripada fail CSV yang dipadankan secara automatik berdasarkan hasil klasifikasi. Antara muka pengguna dibangunkan menggunakan Gradio untuk membolehkan pengguna memuat naik gambar dan melihat hasil klasifikasi serta kandungan nutrisi dengan serta-merta. Strategi pembangunan bagi projek ini merangkumi langkah-langkah seperti pemilihan set data, prapemprosesan imej, pembangunan dan latihan model CNN, pemanfaatan dengan data nutrisi, dan integrasi dengan Gradio. Pengujian dilakukan menggunakan metrik seperti ketepatan (accuracy), precision, recall dan F1-score bagi menilai prestasi model. Hasil pengujian menunjukkan model CNN pralatih MobileNetV2 mencapai ketepatan yang lebih tinggi berbanding model CNN manual. Antara muka Gradio yang dibangunkan juga dapat memaparkan jenis makanan, maklumat nutrisi dan graf nutrien dengan berkesan. Secara keseluruhannya, projek ini menunjukkan potensi dalam menyokong pemantauan pemakanan menggunakan teknologi klasifikasi imej pintar.

Kata kunci: Convolutional Neural Network (CNN)”, “MobileNetV2”.

PENGENALAN

Dalam era digital yang serba pantas, pemilihan makanan yang sihat dan seimbang memainkan peranan penting dalam mengekalkan tahap kesihatan individu dan mengurangkan risiko penyakit kronik seperti obesiti, diabetes, dan penyakit jantung. Menurut laporan Tinjauan Kesihatan dan Morbiditi Kebangsaan (NHMS) 2023, lebih 54.4% rakyat Malaysia mengalami masalah berat badan berlebihan dan obesiti, menunjukkan peningkatan berbanding tahun-tahun sebelumnya. Statistik ini mencerminkan keperluan mendesak untuk meningkatkan kesedaran dan pemahaman masyarakat mengenai pemakanan sihat.

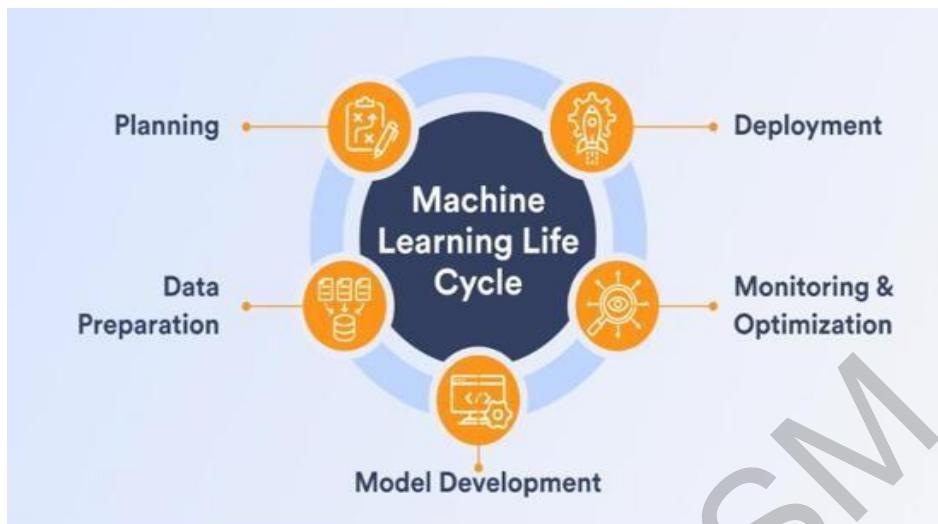
Walau bagaimanapun, cabaran utama yang dihadapi oleh kebanyakan individu ialah kekurangan maklumat yang mudah difahami dan boleh diakses mengenai kandungan nutrisi makanan harian, terutama makanan tempatan. Oleh itu, kemajuan dalam teknologi kecerdasan buatan (AI) dan pembelajaran mendalam (deep learning), terutamanya melalui model Convolutional Neural Network (CNN), membuka peluang baharu dalam pembangunan sistem pengenalpastian makanan secara automatik berdasarkan imej serta memberikan maklumat nutrisi secara terus kepada pengguna.

Projek ini bertujuan membangunkan sistem klasifikasi imej makanan Malaysia dengan memanfaatkan dua pendekatan pembelajaran mendalam: (1) model CNN manual yang direka khas, dan (2) model pralatih (pre-trained) MobileNetV2. Imej makanan yang dikelaskan akan dipadankan dengan data nutrisi (kalori, protein, karbohidrat, dan lemak) dan dipaparkan secara visual melalui antara muka pengguna berasaskan Gradio.

Set data Malaysia Food 11 digunakan dalam projek ini dan diproses melalui beberapa peringkat penting seperti pembersihan data, augmentasi imej, pembahagian set data, pembangunan model, dan penilaian prestasi. Dengan penggunaan bahasa pengaturcaraan Python dan pustaka seperti TensorFlow, Keras, Pandas, dan Matplotlib dalam persekitaran Google Colab, sistem yang dibangunkan diharap dapat menyumbang kepada peningkatan kesedaran pemakanan sihat serta menyokong usaha pencegahan penyakit berkaitan gaya hidup di peringkat individu dan masyarakat.

METODOLOGI KAJIAN

Projek ini menggunakan model pembangunan Kitaran Hayat Pembelajaran Mesin, di mana pembangunan model akan dilakukan dalam beberapa fasa secara berperingkat. Model ini dipilih kerana ia menyediakan aliran kerja yang jelas dan sistematik dalam pembangunan model pembelajaran mesin. Pendekatan ini memastikan setiap peringkat dalam projek dikendalikan dengan baik, dari awal hingga akhir, untuk menjamin keberkesan dan ketepatan model.



Rajah 1 Model Kitaran Hayat Pembelajaran Mesin. (Sumber: Tigran, 2022).

Rajah yang menunjukkan model Kitaran Hayat Pembelajaran Mesin ini diambil dari blog oleh Tigran (2022) di Plat.AI. Kitaran ini merangkumi beberapa fasa utama seperti perancangan, penyediaan data, pembangunan model, pemantauan & pengoptimuman, dan penyebaran yang semuanya memerlukan pendekatan berulang dan adaptif. Model ini dipilih kerana ia membolehkan penambahbaikan berterusan berdasarkan maklum balas dan penemuan baru, yang amat penting dalam projek pembelajaran mesin di mana data dan keperluan sering berubah. Selain itu, kitaran hayat ini menekankan kepentingan pengurusan data yang baik, pengoptimuman model, dan pemantauan berterusan selepas penyebaran, memastikan model yang dibangunkan kekal relevan dan berprestasi tinggi dalam persekitaran sebenar. Fasa-fasa ini bekerja secara berulang dan adaptif, memastikan model yang dibangunkan bukan sahaja berprestasi tinggi tetapi juga relevan dan berkesan dalam persekitaran sebenar. Kitaran hayat ini memberikan asas yang kukuh untuk mengurus projek pembelajaran mesin dari perancangan hingga penyebaran.

Fasa Perancangan (Planning)

Fasa pertama dalam kitaran hayat pembelajaran mesin melibatkan perancangan yang menyeluruh untuk menentukan objektif projek dan pemilihan set data. Dalam projek ini, objektif utama adalah membangunkan model CNN untuk mengklasifikasikan makanan berdasarkan imej dan memberikan maklumat nutrisi. Pemilihan set data yang sesuai adalah langkah penting, dan dalam kes ini, set data seperti Malaysia Food-11 akan digunakan. Selain itu, perancangan model merangkumi keputusan tentang struktur rangkaian CNN, bilangan lapisan, fungsi aktivasi, dan pengoptimuman yang akan digunakan. Di samping itu, fasa ini juga melibatkan pemilihan metrik penilaian seperti ketepatan, kepekaan, kekhususan, F1-score, serta visualisasi confusion matrix untuk menilai prestasi model.

Fasa Penyediaan Data (Data Preparation)

Fasa penyediaan data adalah langkah kritikal dalam pembelajaran mesin. Proses ini bermula dengan pengumpulan dan pembersihan data. Set data utama yang digunakan dalam projek ini ialah *Malaysia Food 11* daripada *Kaggle*, yang mengandungi 11 kategori makanan tempatan. Setiap kategori mengandungi ratusan imej, menjadikan jumlah keseluruhan imej melebihi 8,000. Proses pembersihan data melibatkan penapisan imej yang mengandungi ralat, hilang, kabur, atau tidak berkaitan dengan kategori sebenar. Dalam projek ini, setiap imej makanan diteliti dan disahkan labelnya untuk memastikan data yang digunakan adalah bersih, berkualiti tinggi, dan bersesuaian untuk proses latihan model. Selepas itu, augmentasi imej digunakan

untuk meningkatkan kebolehan model dalam generalisasi. Teknik seperti putaran, pemotongan rawak, dan penskalaan imej digunakan untuk meningkatkan kepelbagaiannya data latihan. Seterusnya, set data akan dibahagikan kepada set latihan, validasi, dan ujian untuk memastikan model dilatih dengan baik dan tidak mengalami overfitting. Pembahagian data yang betul memastikan model dapat diuji secara objektif menggunakan data yang tidak dilihat semasa latihan.

Fasa Pembangunan Model (Model Development)

Dalam fasa pembangunan model, reka bentuk dan latihan model CNN dimulakan. Struktur model CNN dirancang dengan teliti, dan latihan dimulakan dengan menggunakan set data yang telah diproses. Parameter seperti kadar pembelajaran, bilangan epoch, dan saiz batch perlu ditetapkan dengan teliti untuk mencapai prestasi yang optimum. Pemantauan prestasi semasa latihan adalah penting untuk memastikan model tidak overfitting atau underfitting. Jika model tidak mencapai prestasi yang baik, penalaan hyperparameter dijalankan dengan mengubah suai parameter seperti saiz lapisan konvolusi dan jenis pengoptimuman untuk meningkatkan hasil. Fasa ini bertujuan untuk mencapai model yang dapat mengklasifikasikan makanan dengan tepat berdasarkan imej yang dimasukkan.

Fasa Pemantauan & Pengoptimuman (Monitoring & Optimization)

Setelah model selesai dilatih, fasa pemantauan dan pengoptimuman dilakukan untuk menilai prestasi model dengan menggunakan set ujian. Metrik seperti ketepatan, kepekaan, kekhususan, dan F1-score akan digunakan untuk menilai prestasi model dalam mengklasifikasikan makanan dengan betul. Visualisasi confusion matrix juga akan digunakan untuk memberikan gambaran yang lebih jelas tentang prestasi model. Jika model tidak memberikan keputusan yang memuaskan, teknik pengoptimuman seperti regularisasi dan *fine-tuning* akan digunakan untuk memperbaiki hasil. Pengoptimuman ini bertujuan untuk meningkatkan prestasi model dan memastikan model dapat mengklasifikasikan makanan dengan lebih tepat dan berkesan.

Fasa Penyebaran (Deployment)

Fasa terakhir dalam kitaran hayat pembelajaran mesin adalah penyebaran, di mana model yang telah siap akan disediakan untuk penggunaan sebenar. Walaupun projek ini tidak melibatkan pembangunan antara muka pengguna yang kompleks, model ini akan disediakan dengan antara muka ringkas menggunakan *Gradio* untuk menerima imej makanan dan memberikan klasifikasi makanan serta maklumat nutrisi secara langsung. Pengguna boleh memuat naik imej makanan melalui antara muka Gradio, dan model akan menghasilkan klasifikasi serta maklumat seperti protein, lemak, karbohidrat dan kalori berdasarkan imej yang diberikan. Pemantauan selepas penyebaran adalah penting untuk memastikan model berfungsi dengan baik dalam persekitaran sebenar. Penambahbaikan berterusan akan dilakukan berdasarkan penemuan baru dalam analisis model, bagi memastikan model tetap relevan dan berprestasi tinggi dalam jangka masa yang panjang.

KEPUTUSAN DAN PERBINCANGAN

Pembangunan model dalam projek ini melibatkan dua pendekatan utama iaitu model CNN manual yang dibina dari awal, serta model pralatih MobileNetV2 yang diubah suai melalui teknik pemindahan pembelajaran (transfer learning). Kedua-dua model dibina dan dilatih secara berasingan bagi tujuan perbandingan prestasi dalam mengklasifikasikan imej makanan tempatan. Setiap model dirangka dengan struktur tersendiri yang melibatkan pemilihan lapisan, fungsi pengaktifan, dan parameter latihan yang sesuai untuk memastikan ketepatan

dan kebolehpercayaan sistem klasifikasi yang dibangunkan.

i. Pembangunan Model CNN Manual

Model pertama yang dibangunkan dalam projek ini ialah model CNN manual yang dibina sepenuhnya dari awal tanpa menggunakan model pralatih. Model ini terdiri daripada beberapa lapisan asas CNN termasuk dua lapisan Conv2D yang masing-masing mengekstrak ciri visual penting daripada imej menggunakan penapis berukuran 3×3 dan fungsi pengaktifan ReLU. Setiap lapisan konvolusi diikuti dengan lapisan MaxPooling2D bagi mengurangkan dimensi ciri dan mengelakkan overfitting. Selepas proses pengekstrakan ciri, lapisan Flatten digunakan untuk menukar data dua dimensi kepada satu dimensi sebelum dihantar ke Dense layer untuk pembelajaran. Lapisan Dense(128, activation='relu') berperanan sebagai lapisan tersembunyi utama yang belajar pola kompleks, dan lapisan terakhir Dense(num_classes, activation='softmax') bertanggungjawab menghasilkan output ramalan kelas makanan berdasarkan bilangan kelas yang telah ditentukan sebelumnya. Model ini dikompilasi menggunakan fungsi kehilangan categorical_crossentropy, optimizer Adam, dan metrik ketepatan accuracy. Model CNN manual ini digunakan sebagai penanda aras untuk dibandingkan dengan model pralatih dari segi ketepatan dan kecekapan.

```
# CNN

custom_cnn = Sequential([
    Conv2D(32, (3, 3), activation='relu', input_shape=input_shape),
    MaxPooling2D(2, 2),

    Conv2D(64, (3, 3), activation='relu'),
    MaxPooling2D(2, 2),

    Conv2D(128, (3, 3), activation='relu'),
    MaxPooling2D(2, 2),

    Flatten(),
    Dense(128, activation='relu'),
    Dropout(0.5),
    Dense(num_classes, activation='softmax')
])

custom_cnn.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
custom_cnn.summary()
```

Rajah 2 Pembinaan model CNN manual

ii. Pembangunan Model CNN MobileNetV2 (Pretrained)

Model kedua pula dibangunkan menggunakan pendekatan pemindahan pembelajaran (transfer learning) dengan memanfaatkan model MobileNetV2 yang telah dilatih sebelumnya (pretrained) di atas dataset besar ImageNet. Model ini dimuat dengan parameter weights='imagenet' dan include_top=False, yang bermaksud hanya struktur pengekstrak ciri asal dimuat tanpa lapisan akhir klasifikasi. Ini membolehkan struktur akhir model disesuaikan untuk tugas klasifikasi makanan tempatan. Lapisan base_model dikunci (trainable=False) untuk mengekalkan ciri-ciri pengetahuan terdahulu, diikuti dengan lapisan GlobalAveragePooling2D() yang bertindak meratakan peta ciri (feature map) sebelum dimasukkan ke dalam lapisan Dense dengan 128 neuron. Lapisan terakhir juga merupakan Dense(num_classes, activation='softmax') yang menghasilkan keputusan akhir klasifikasi. Model ini turut dikompilasi menggunakan Adam optimizer dan categorical_crossentropy untuk kesesuaian klasifikasi berbilang kelas. Pendekatan MobileNetV2 ini dipilih kerana kelebihannya dalam memberi prestasi tinggi walaupun dengan parameter yang lebih ringan

dan masa latihan yang lebih pantas, selain mampu mengekalkan ketepatan yang tinggi hasil daripada pembelajaran sebelumnya daripada set data berskala besar.

```
# 3. MobileNetV2 Model (Transfer Learning)
base_model = MobileNetV2(weights='imagenet', include_top=False, input_tensor=Input(shape=input_shape))

# Freeze base model
for layer in base_model.layers:
    layer.trainable = False

mobilenet_model = Sequential([
    base_model,
    GlobalAveragePooling2D(),
    Dropout(0.3),
    Dense(128, activation='relu'),
    Dropout(0.3),
    Dense(num_classes, activation='softmax')
])

mobilenet_model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
mobilenet_model.summary()
```

Rajah 3 Pembinaan model CNN MobileNetV2 (Pretrained)

Penilaian Model

Penilaian model dilakukan bagi mengukur keberkesanannya sistem klasifikasi imej makanan yang dibangunkan. Beberapa metrik digunakan termasuk ketepatan (accuracy), kerugian (loss), dan confusion matrix untuk mengenal pasti prestasi model terhadap data ujian sebenar. Selain itu, visualisasi seperti graf perbandingan ketepatan dan kehilangan bagi set latihan dan validasi turut digunakan bagi memantau kestabilan dan kebolehumuman (generalization) model sepanjang proses latihan.

Dua model telah dinilai menggunakan set data pengujian bagi menilai keberkesanannya sistem klasifikasi imej makanan yang dibangunkan. Model CNN manual mencatatkan ketepatan (accuracy) sebanyak 47.67% dan nilai loss sebanyak 1.5980, menunjukkan prestasi asas yang sederhana dalam mengenal pasti kategori makanan. Sebaliknya, model MobileNetV2 menunjukkan prestasi yang jauh lebih baik, dengan ketepatan mencapai 84.88% dan nilai kehilangan hanya 0.3985. Prestasi ini selaras dengan jangkaan kerana MobileNetV2 telah dilatih terlebih dahulu pada set data berskala besar, sekali gus membolehkannya mengecam ciri visual dengan lebih berkesan. Selain metrik ini, confusion matrix turut digunakan untuk menganalisis kelas makanan yang sering dikelirukan antara satu sama lain, manakala graf visualisasi accuracy dan loss sepanjang epoch digunakan untuk memantau kestabilan model dan tanda-tanda overfitting atau underfitting.

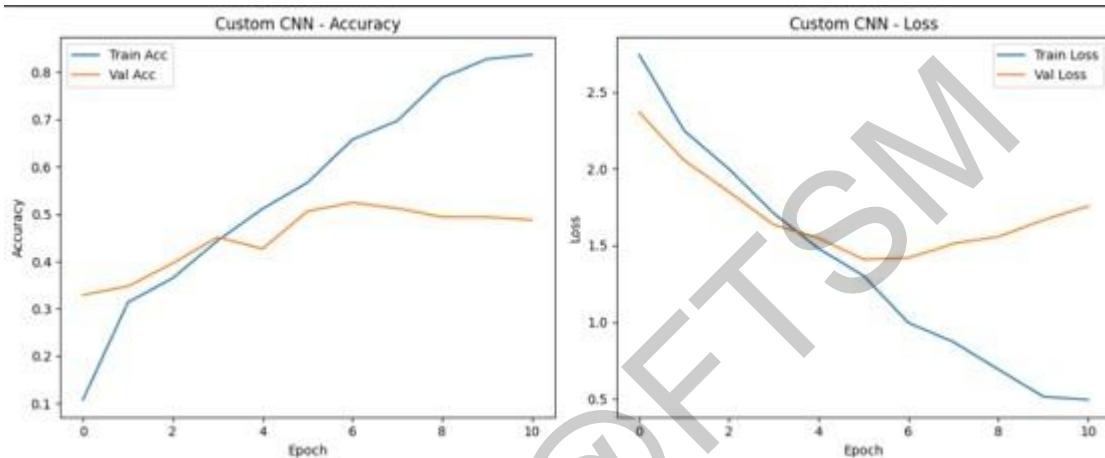
Jadual 1 Penilaian model

Model	Ujian Ketepatan	Ujian Kehilangan
CNN manual	0.4826	1.5512
MobileNetV2	0.8547	0.4703

i. Model CNN Manual

Graf ketepatan pada data latihan (Train Acc) meningkat secara konsisten dari sekitar 0.1 hingga melebihi 0.85, menunjukkan bahawa model berjaya belajar daripada data latihan. Namun, ketepatan pada data penilaian (Val Acc) hanya meningkat sedikit dari sekitar 0.35 kepada lebih kurang 0.55 sebelum mendatar dan sedikit menurun selepas epoch ke-6. Ini menunjukkan bahawa model mula mengalami overfitting, iaitu terlalu menyesuaikan diri

dengan data latihan sehingga prestasi pada data baharu (validation) tidak lagi bertambah baik. Graf kerugian model CNN manual ini memaparkan nilai loss bagi data latihan dan penilaian. Nilai Train Loss menunjukkan penurunan berterusan daripada sekitar 2.7 kepada 0.5, menandakan model semakin baik dalam meminimumkan ralat semasa latihan. Walau bagaimanapun, Val Loss menurun sehingga epoch ke-5 (~1.4), tetapi kemudian meningkat semula sehingga ~1.8. Corak ini mengukuhkan bukti overfitting, di mana prestasi model pada data penilaian semakin merosot walaupun prestasi pada data latihan terus bertambah baik.

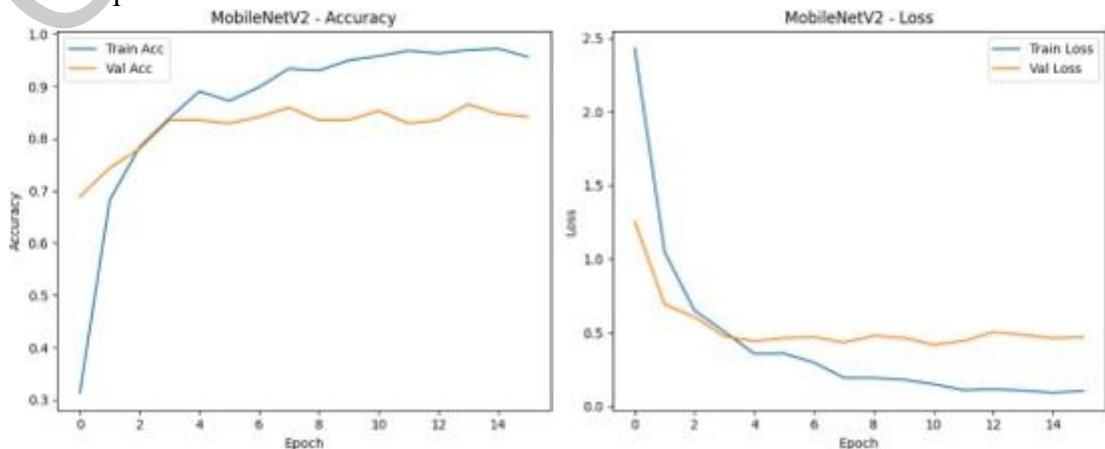


Rajah 4 Graf ketepatan dan kerugian bagi model CNN manual

ii. Model CNN MobileNetV2 (Pretrained)

Graf prestasi ketepatan model MobileNetV2 sepanjang 15 epoch. Berbeza dengan model CNN manual, Train Acc untuk MobileNetV2 meningkat dengan lebih pantas dan stabil dari ~0.3 hingga menghampiri 0.98. Ketepatan penilaian (Val Acc) juga tinggi dan stabil sekitar 0.8 hingga 0.86 selepas beberapa epoch awal. Tiada tanda overfitting yang ketara, kerana jurang antara Train Acc dan Val Acc kekal kecil. Ini menunjukkan model MobileNetV2 lebih bagus dan berbanding model CNN manual.

Graf bagi nilai loss untuk model MobileNetV2 pada data latihan dan penilaian. Train Loss menurun dengan sangat cepat dari sekitar 2.5 kepada bawah 0.2, manakala Val Loss turut menunjukkan penurunan yang stabil dan kekal rendah (sekitar 0.4 hingga 0.5) sepanjang epoch. Tiada peningkatan Val Loss yang ketara, menandakan bahawa model ini tidak mengalami overfitting. Ini menunjukkan prestasi MobileNetV2 sangat baik dalam kedua-dua latihan dan penilaian.



Rajah 5 Graf ketepatan dan kerugian bagi Model CNN MobileNetV2 (Pretrained)

Laporan klasifikasi bagi model CNN MobileNetV2 (*Pretrained*) berdasarkan Rajah 6 dibawah, Model MobileNetV2 telah dinilai menggunakan laporan klasifikasi yang merangkumi metrik seperti *precision*, *recall*, dan *f1-score* bagi setiap kelas makanan. Hasil penilaian menunjukkan bahawa model mencapai ketepatan keseluruhan (*accuracy*) sebanyak 85% ke atas 172 imej dalam set pengujian, satu prestasi yang boleh dianggap tinggi bagi tugas klasifikasi pelbagai kelas imej makanan.

Kebanyakan kelas seperti ‘apple’, ‘banana’, ‘carrot’, ‘cucumber’, ‘orange’, dan ‘unknown’ telah dikelaskan dengan sangat tepat, masing-masing mencapai skor 1.00 untuk *precision*, *recall* dan *F1-score*, menunjukkan tiada kesilapan klasifikasi berlaku untuk kategori tersebut. Ini menunjukkan bahawa ciri visual bagi kelas ini sangat mudah dikenalpasti oleh model.

Kategori ‘fish_and_chips’, ‘nasi_lemak’, ‘satay’, dan ‘roti_canai’ juga menunjukkan prestasi yang memuaskan, dengan *F1-score* melebihi 0.80, membuktikan bahawa model mampu mengenalpasti makanan tempatan dengan baik walaupun terdapat variasi dalam imej. Namun, terdapat beberapa kelas yang mencatatkan prestasi sederhana seperti ‘fried_noodles’ dan ‘hamburger’ dengan *F1-score* masing-masing 0.74, menunjukkan masih ada beberapa imej yang dikelaskan secara salah.

Kelas ‘kaya_toast’ dan ‘popiah’ mencatatkan *F1-score* yang lebih rendah iaitu 0.69 dan 0.64. Ini menunjukkan bahawa model menghadapi kesukaran untuk mengenal pasti makanan dalam kategori ini dengan tepat, kemungkinan disebabkan ciri visual yang menyerupai kelas lain dan kekurangan imej latihan yang pelbagai.

Purata metrik keseluruhan menunjukkan bahawa *macro average F1-score* ialah 0.87 dan *weighted average F1-score* ialah 0.85, yang menunjukkan prestasi yang seimbang antara kelas majoriti dan minoriti. Secara keseluruhan, model MobileNetV2 terbukti mampu memberikan prestasi klasifikasi yang bagus dan boleh dipercayai dalam mengenal pasti pelbagai jenis makanan termasuk makanan tempatan Malaysia.

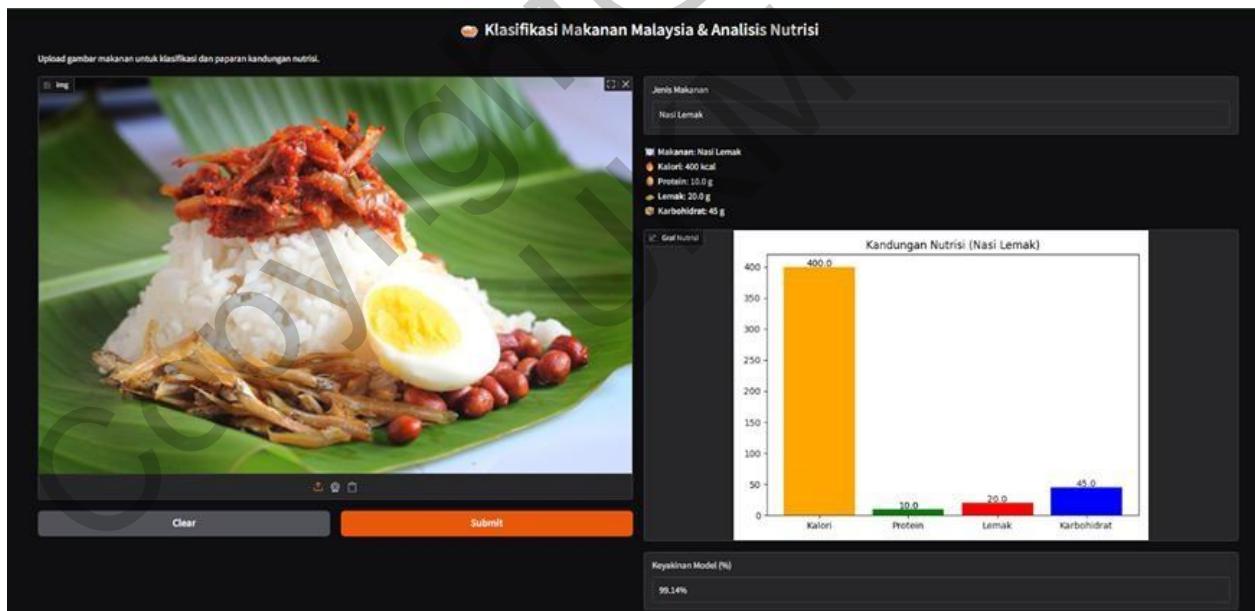
	precision	recall	f1-score	support
apple	1.00	1.00	1.00	8
banana	1.00	1.00	1.00	7
carrot	1.00	1.00	1.00	8
cucumber	1.00	1.00	1.00	8
fish_and_chips	0.92	0.92	0.92	13
fried_noodles	0.77	0.71	0.74	14
fried_rice	1.00	0.80	0.89	10
hamburger	0.78	0.70	0.74	10
kaya_toast	0.69	0.69	0.69	13
laksa	0.74	0.93	0.82	15
nasi_lemak	0.74	1.00	0.85	14
orange	1.00	1.00	1.00	6
popiah	0.64	0.64	0.64	11
roti_canai	0.89	0.73	0.80	11
satay	1.00	0.73	0.84	11
unknown	1.00	1.00	1.00	13
accuracy			0.85	172
macro avg	0.89	0.87	0.87	172
weighted avg	0.86	0.85	0.85	172

Rajah 6 Laporan klasifikasi bagi model CNN MobileNetV2 (*Pretrained*)

Antara Muka

Bagi melengkapkan model klasifikasi imej makanan yang dibangunkan, antara muka interaktif telah dibina menggunakan pustaka *Gradio*, sebuah kerangka kerja sumber terbuka yang membolehkan integrasi model pembelajaran mesin dengan antaramuka pengguna web secara mudah dan intuitif. Fungsi ini membolehkan pengguna memuat naik imej makanan, dan model akan membuat klasifikasi secara serta-merta menggunakan model terlatih MobileNetV2. Hasil klasifikasi termasuk nama makanan serta paparan kandungan nutrisi yang dipadankan daripada fail CSV nutrisi berdasarkan label ramalan.

Bagi meningkatkan kefahaman pengguna terhadap nilai nutrisi, bar graf turut dibina secara automatik bagi memvisualkan jumlah kalori, protein, lemak, dan karbohidrat dalam makanan yang dikenal pasti. Ciri ini menjadikan model ini bukan sahaja berfungsi sebagai pengklasifikasi makanan, tetapi juga sebagai alat kesedaran pemakanan. Tambahan pula, peratus keyakinan model juga turut ditambah bagi memastikan ketepatan model dalam mengklasifikasikan imej makanan. Selain itu, struktur aplikasi *Gradio* ini membolehkan integrasi masa sebenar (*real-time*), mudah diakses melalui pelayar web, serta boleh digunakan dalam persekitaran awan seperti *Google Colab*. Fungsi ini melengkapkan objektif projek dengan menyediakan satu bentuk demonstrasi klasifikasi imej makanan yang praktikal, interaktif dan bermanfaat dari segi aplikasi dunia sebenar.



Rajah 7 Gambaran fungsi *gradio* bagi imej makanan

Salah satu ciri penting dalam mengklasifikasi imej makanan ini ialah keupayaannya mengenal pasti input yang tidak tergolong dalam mana-mana kelas makanan terlatih, lalu memaparkan hasil ramalan sebagai “Unknown”. Fungsi ini direka bentuk bagi meningkatkan kebolehpercayaan model dalam aplikasi sebenar, terutamanya apabila pengguna secara tidak sengaja atau sengaja memuat naik imej yang bukan berkaitan dengan makanan, seperti haiwan, objek, atau persekitaran. Ciri ini menjadikan model lebih tepat, praktikal, dan sesuai untuk digunakan dalam situasi dunia sebenar yang tidak dapat dijangka sepenuhnya oleh data latihan.

Kaedah dan Teknik Pengujian

Objektif utama pengujian bagi projek ini adalah untuk menilai tahap ketepatan dan kebolehpercayaan model klasifikasi imej makanan yang dibangunkan menggunakan model CNN dan MobileNetV2. Sistem ini turut mengandungi fungsi tambahan iaitu pemanasan maklumat nutrisi daripada fail CSV dan paparan maklumat tersebut melalui antaramuka interaktif *Gradio*. Oleh itu, pengujian perlu memastikan bahawa model bukan sahaja dapat mengklasifikasikan jenis makanan dengan betul daripada imej, tetapi juga memadankan maklumat nutrisi yang tepat serta memaparkannya dengan betul sebagai output yang tepat. Pengujian dilaksanakan pada tiga peringkat utama. Pertama, pengujian komponen iaitu pada peringkat model CNN dan MobileNetV2, bagi menilai keupayaan setiap model dalam mengenal pasti kelas imej makanan secara individu. Kedua, pengujian integrasi dilakukan bagi memastikan fungsi pemanasan data nutrisi dari fail CSV dapat dijalankan dengan betul dan tanpa ralat. Ketiga, pengujian sistem penuh dilaksanakan melalui antaramuka *Gradio* yang dibina, untuk menilai sama ada keseluruhan aliran model (*pipeline*) berfungsi dengan lancar atau tidak, bermula daripada muat naik imej sehingga paparan keputusan akhir (jenis makanan, nutrisi, dan graf).

Asas pengujian ini berlandaskan kepada dokumen keperluan sistem yang telah ditentukan semasa fasa spesifikasi terdahulu. Ini termasuk keperluan fungsi seperti klasifikasi makanan, pemanasan kandungan nutrisi berdasarkan data CSV, serta paparan hasil dalam bentuk teks dan visual. Turut dipertimbangkan ialah keperluan bukan fungsi seperti tahap ketepatan model (melebihi 80%), kelajuan masa tindak balas (*respons time*) yang memuaskan, serta ketahanan model terhadap input yang tidak dijangka seperti gambar bukan makanan. Teknik dan pendekatan pengujian yang digunakan dalam projek ini terdiri daripada beberapa kaedah utama yang dipilih berdasarkan atas pengujian dan kesesuaian projek.

i. Pengujian Kotak Hitam (*Black Box Testing*)

Pengujian ini dipilih kerana ia sesuai untuk menilai model dari perspektif pengguna akhir. Dalam kaedah ini, pengujian dilakukan dengan memberi input pada model (contohnya imej makanan) dan menilai output yang dihasilkan (nama makanan, nutrisi dan bar graf) tanpa mengambil kira struktur dalaman kod atau algoritma model. Teknik ini membolehkan pengujian pelbagai senario seperti:

- Imej makanan yang dikenali → model harus memberi klasifikasi yang betul dan padanan nutrisi yang tepat.
- Imej bukan makanan atau imej tidak relevan → model perlu mengenal pasti sebagai “*unknown*” sebagai maklum balas kesalahan.

ii Ujian Sistem (*System Testing*)

Ujian sistem dilaksanakan melalui antara muka pengguna interaktif menggunakan *Gradio*. Ia bertujuan untuk mensimulasikan pengalaman sebenar pengguna akhir apabila menggunakan model klasifikasi imej makanan.

Pengujian ini merangkumi beberapa langkah penting: pertama, pengguna akan memuat naik imej makanan melalui antara muka *Gradio*. Seterusnya, sistem akan memproses imej tersebut

untuk membuat klasifikasi menggunakan model CNN yang telah dilatih (sama ada CNN manual atau MobileNetV2). Selepas itu, sistem akan memadankan hasil klasifikasi dengan rekod data nutrisi yang disimpan dalam fail CSV. Akhirnya, keputusan akan dipaparkan kepada pengguna dalam bentuk teks (nama makanan dan maklumat nutrisi) serta visual (graf bar kandungan nutrisi).

Ujian ini penting bagi memastikan bahawa keseluruhan proses bermula daripada input (imej) hingga output (maklumat nutrisi dan visualisasi) berjalan lancar, tanpa ralat teknikal, dan memberikan maklumat yang tepat kepada pengguna. Ia juga mengesahkan bahawa sistem dapat menangani input yang sah mahupun input tidak sah (seperti gambar bukan makanan), dengan memberikan respons yang sesuai seperti klasifikasi "*unknown*" atau mesej kesalahan.

iii. Pengesahan Data / Penilaian Model

Penilaian model adalah aspek yang kritikal kerana ia melibatkan ketepatan dan keberkesanan algoritma pembelajaran mesin yang dibangunkan. Dalam projek ini, dua model utama iaitu CNN manual dan MobileNetV2 (pra-latih) telah dibina dan diuji menggunakan set data ujian yang terpisah daripada data latihan dan validasi.

Prestasi setiap model dinilai berdasarkan beberapa metrik penilaian standard yang biasa digunakan dalam klasifikasi berbilang kelas (*multi-class classification*), iaitu:

- *Accuracy*: Peratusan jumlah ramalan betul daripada keseluruhan sampel ujian.
- *Precision*: Keupayaan model dalam memberikan ramalan positif yang benar bagi setiap kelas.
- *Recall*: Keupayaan model dalam mengenal pasti semua contoh sebenar bagi sesuatu kelas.
- *F1-score*: Purata harmoni antara precision dan recall, berguna apabila terdapat ketidakseimbangan antara kelas.
- *Confusion Matrix*: Matriks yang menunjukkan jumlah ramalan betul dan salah untuk setiap kelas.

Penilaian ini membolehkan pemilihan model terbaik dibuat secara objektif dan berdasarkan data. Model MobileNetV2 telah dipilih, kerana menunjukkan ketepatan tinggi, generalisasi yang baik terhadap data baharu, dan masa inferens yang lebih pantas berbanding model CNN manual.

Reka bentuk kes ujian merangkumi perancangan prosedur pengujian dan data input yang digunakan untuk menilai sama ada sistem berfungsi seperti yang diharapkan. Dalam projek ini, kes ujian direka bentuk untuk menguji ketepatan klasifikasi imej makanan, pemanfaatan dengan data nutrisi, dan paparan output secara interaktif melalui antaramuka *Gradio*.

Jadual 2 jadual ringkasan kes ujian

ID Ujian	Tujuan	Input	Jangkaan Output	Keputusan
TC01	Klasifikasi makanan sah	Gambar nasi lemak	Output: "Nasi Lemak", nutrisi betul, graf muncul	Lulus
TC02	Imej bukan makanan	Gambar kereta	Output: " <i>Unknown</i> " atau mesej ralat	Lulus
TC03	Klasifikasi makanan rawak	Gambar makanan dari luar set data	Output tepat	Lulus
TC04	Muat naik tiada fail	Tiada input	Papar mesej ralat	Lulus
TC05	Tindak balas sistem	Gambar <i>satay</i>	Masa inferens < 2 saat	Lulus

Prosedur ini membantu memastikan sistem berfungsi dengan tepat dalam pelbagai senario dan membolehkan pemberian dibuat jika terdapat ralat semasa ujian.

Secara keseluruhannya, perbandingan antara model CNN manual dan model pralatih MobileNetV2 menunjukkan perbezaan prestasi yang ketara dari segi ketepatan klasifikasi dan keupayaan generalisasi terhadap data baharu. Model CNN manual yang dibina dari awal mencatatkan ketepatan sekitar 47.67% dan nilai kehilangan sebanyak 1.5980 apabila diuji pada set pengujian. Ini menunjukkan bahawa model tersebut mempunyai prestasi asas dalam pengecaman imej makanan, namun masih tidak cukup stabil untuk digunakan dalam aplikasi sebenar, terutamanya disebabkan oleh bilangan parameter terhad dan kesukaran untuk mengekstrak ciri visual yang kompleks daripada imej makanan.

Sebaliknya, model MobileNetV2 yang dibangunkan menggunakan kaedah pemindahan pembelajaran menunjukkan prestasi yang jauh lebih baik, dengan ketepatan mencecah 85.47% dan kehilangan hanya 0.4703. Model ini juga berjaya mencapai skor precision, recall dan F1-score yang tinggi dalam hampir semua kelas makanan, termasuk makanan tempatan seperti nasi lemak, laksa dan satay. Ini membuktikan keupayaan model pralatih untuk mengenal pasti ciri-ciri visual penting walaupun dengan jumlah data latihan yang terhad. Selain itu, model MobileNetV2 juga lebih stabil semasa proses latihan dan kurang terdedah kepada masalah overfitting atau *underfitting*, seperti yang ditunjukkan dalam graf ketepatan dan kehilangan.

Jadual 3 Perbandingan Prestasi Model CNN Manual dan MobileNetV2

Ciri / Metrik	CNN Manual	MobileNetV2 (<i>Pretrained</i>)
Jenis Model	CNN dibina dari awal	Model pralatih dengan <i>transfer learning</i>
Ketepatan (Accuracy)	48.26%	85.47%
Nilai Kehilangan (Loss)	1.5512	0.4703
F1-Score Purata	Lebih rendah dan tidak stabil	Tinggi dan konsisten
Kestabilan Latihan	Cenderung kepada <i>underfitting</i>	Stabil & seimbang

Cadangan Penambahbaikan

Selepas menjalankan kajian yang menyeluruh, terdapat beberapa aspek yang boleh ditambah baik untuk meningkatkan keupayaan dan kebolehgunaan sistem. Pertama, memperbanyakkan kelas makanan dengan menambah lebih banyak kategori makanan tempatan bagi memastikan sistem lebih menyeluruh dan relevan dengan kepelbagaian makanan di Malaysia. Selain itu, sistem boleh ditambah dengan fungsi pengesanan pelbagai jenis makanan dalam satu imej (multi-label classification), memandangkan pengguna mungkin memuat naik gambar yang mengandungi lebih daripada satu jenis makanan. Akhir sekali, dari aspek antaramuka, sistem boleh dibangunkan ke dalam aplikasi web atau aplikasi mudah alih yang lebih mesra pengguna dan responsif.

KESIMPULAN

Secara keseluruhannya, projek ini telah berjaya membangunkan sebuah sistem klasifikasi imej makanan tempatan Malaysia yang mampu mengenal pasti jenis makanan secara automatik dan memaparkan maklumat nutrisi secara interaktif kepada pengguna. Dengan menggunakan pendekatan pembelajaran mendalam melalui model Convolutional Neural Network (CNN) manual dan model CNN pralatih MobileNetV2, sistem ini menunjukkan prestasi klasifikasi yang baik, terutamanya apabila menggunakan model MobileNetV2 yang mencapai ketepatan yang lebih tinggi. Penggunaan set data Malaysia Food 11 membolehkan sistem mengenal pasti pelbagai makanan tempatan seperti nasi lemak, roti canai, dan laksa dengan berkesan. Tambahan pula, integrasi antara hasil klasifikasi dan maklumat nutrisi daripada fail CSV membolehkan pengguna mendapatkan maklumat penting seperti kalori, protein, lemak, dan karbohidrat dengan mudah. Antara muka pengguna yang dibangunkan menggunakan *Gradio* pula menyediakan pengalaman interaktif dan mesra pengguna dalam menampilkan hasil klasifikasi serta visualisasi graf nutrien. Projek ini bukan sahaja menunjukkan potensi penggunaan teknologi klasifikasi imej dalam bidang pemakanan dan kesihatan, tetapi juga membuka ruang kepada penyelidikan dan pembangunan lanjut dalam membina sistem sokongan diet berdasarkan kecerdasan buatan yang lebih menyeluruh dan bersesuaian dengan konteks tempatan.

Kekuatan Projek

Dari segi kekuatan, projek ini menunjukkan kebolehlaksanaan sistem klasifikasi makanan yang boleh mengenal pasti jenis makanan tempatan dengan ketepatan yang memuaskan. Model pralatih MobileNetV2 menunjukkan prestasi yang lebih baik berbanding model CNN manual, dengan ketepatan melebihi 85% dalam klasifikasi imej makanan, sekali gus membuktikan keberkesanannya. Pendekatan CNN pralatih dalam konteks pengenalpastian imej makanan tempatan. Selain itu, integrasi antara klasifikasi imej dan pemadanan data nutrisi dalam satu sistem bersepadan iaitu dalam bentuk paparan teks dan visual bar graf, membolehkan pengguna menerima maklumat dengan lebih cepat dan mesra pengguna. Penggunaan antaramuka interaktif berdasarkan *Gradio* juga merupakan satu kekuatan kerana ia membolehkan pengguna memuat naik gambar secara mudah dan mendapatkan maklumat makanan dengan pantas. Tambahan pula, sistem ini direka dengan ciri yang dapat mengesan input tidak sah seperti gambar bukan makanan dan memberi maklum balas 'unknown', sekali

gus meningkatkan ketahanan sistem terhadap input luar jangka.

Kelemahan Projek

Namun begitu, terdapat beberapa kelemahan dalam projek ini yang perlu diberi perhatian. Model CNN manual yang dibina menunjukkan ketepatan yang rendah (sekitar 47%) dan kurang stabil berbanding model MobileNetV2, menjadikan ia tidak sesuai digunakan dalam aplikasi sebenar. Selain itu, sistem ini hanya dilatih menggunakan set data *Malaysia Food 11* yang mempunyai bilangan imej terhad bagi setiap kelas. Ini menyukarkan model untuk mengeneralisasi kepada imej makanan lain di luar set latihan. Kekangan lain termasuklah ketiadaan ujian kebolehgunaan bersama pengguna sebenar serta kebergantungan kepada CSV luaran yang jika rosak atau tidak boleh dicapai, akan menjelaskan paparan nutrisi dalam sistem.

PENGHARGAAN

Terlebih dahulu, saya ingin mengucapkan syukur ke hadrat Allah S.W.T atas limpah kurnia-Nya yang membolehkan saya menyiapkan tesis ini walaupun berdepan pelbagai cabaran. Setinggi-tinggi penghargaan saya tujukan kepada penyelia saya, Prof. Madya Dr. Sabrina binti Tiun, atas bimbingan, kesabaran, dan nasihat yang sangat membantu sepanjang proses ini. Tidak dilupakan juga kepada para pensyarah di Fakulti Teknologi & Sains Maklumat, UKM, atas ilmu dan tunjuk ajar yang amat bermakna.

Jutaan terima kasih kepada ibu bapa saya, Edrian bin Mohd dan Azizah binti Mohamad, serta ahli keluarga atas kasih sayang, doa, dan dorongan yang tidak putus-putus. Pengorbanan kalian amat saya hargai. Akhir kata, ucapan terima kasih juga kepada semua rakan-rakan seperjuangan saya di UKM dan juga kenalan yang terlibat secara langsung dan tidak langsung dalam memberikan sumbangan cadangan dan bantuan dalam menyiapkan tesis ini. Semoga penyelidikan dan tesis ini dapat dijadikan wadah ilmu yang berguna untuk tatapan generasi akan datang.

RUJUKAN

- C. Kar Keng. (2020). *Malaysia Food 11 Dataset*. Retrieved from <https://www.kaggle.com/datasets/hassanamin/malaysia-food-image-dataset>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- Islam, Md & Siddique, B.M. Nafiz & Rahman, Sagidur & Jabid, Taskeed. (2018). Food Image Classification with Convolutional Neural Network. 257-262. 10.1109/ICIIBMS.2018.8550005.

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *In Advances in Neural Information Processing Systems (NeurIPS)*.
- L. Jiang, B. Qiu, X. Liu, C. Huang and K. Lin, "DeepFood: Food Image Analysis and Dietary Assessment via Deep Model," in IEEE Access, vol. 8, pp. 47477-47489, 2020, doi: 10.1109/ACCESS.2020.2973625.
- R. Krutik, C. Thacker and R. Adhvaryu(2024), "Advancements in Food Recognition: A Comprehensive Review of Deep Learning-Based Automated Food Item Identification," 2nd International Conference on Electrical Engineering and Automatic Control (ICEEAC), Setif, Algeria, 2024, pp. 1-6, doi: 10.1109/ICEEAC61226.2024.10576416.
- Rohan Volety "ML Guide to Train Food Recognition and Classification Model" (2024) <https://www.labellerr.com/blog/food-recognition-and-classification-using-deep-learning/#:~:text=Deep%20learning%20in%20Food%20image%20classification,-Deep%20learning%20has&text=By%20training%20on%20large%20datasets,of%20deep%20learning%2Dbased%20classifiers>.
- Saxena, S. (2024,). Incremental Process Model – Software Engineering. GeeksforGeeks.
- Shonkoff E, Cara KC, Pei XA, Chung M, Kamath S, Panetta K, Hennessy E. AI-based digital image dietary assessment methods compared to humans and ground truth: a systematic review. Ann Med. 2023;55(2):2273497. doi: 10.1080/07853890.2023.2273497. Epub 2023 Dec 7. PMID: 38060823; PMCID: PMC10836267.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. Journal of Big Data, 6(1), 60.
- S. S. Alahmari and T. Salem, "Food State Recognition Using Deep Learning," in IEEE Access, vol. 10, pp. 130048-130057, 2022, doi: 10.1109/ACCESS.2022.3228701.keywords: {Deep learning;Dairy products;Neural networks;Image recognition;Feature extraction;Transfer learning;Training;Food recognition;food state recognition;deep learning;features fusion;DenseNet},
- Zhang, Yudong & Deng, Lijia & Zhu, Hengde & Wang, Wei & Ren, Zeyu & Zhou, Qinghua & Lu, Siyuan & Sun, Shiting & Zhu, Ziquan & Gorriz, Juan & Wang, Shuihua. (2023). Deep Learning in Food Category Recognition. 98. 101859. 10.1016/j.inffus.2023.101859.

Nur Alyssa Sofea binti Edrian (A195034)

Prof. Madya Dr. Sabrina Tiun

Fakulti Teknologi & Sains Maklumat

Universiti Kebangsaan Malaysia