

SISTEM PENGELASAN SAYUR-SAYURAN BERDASARKAN PEMBELAJARAN MENDALAM

NUR FARHAN BINTI ABD JAMAL

TS. DR. NOOR FARIDATULAINUN BINTI ZAINAL

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

ABSTRAK

Sayur-sayuran merupakan makanan yang sering dibeli dan dimakan oleh manusia. Namun begitu, terdapat beberapa situasi yang menyukarkan manusia untuk mengetahui nama dan jenis sesuatu sayuran kerana rupa dan warna luaran yang hampir sama. Selain itu, sesetengah kedai tidak melabelkan jenis sayur-sayuran terutama kedai-kedai runcit yang kecil dan ini menyukarkan pembeli memilih sayur yang dikehendaki. Projek ini bertujuan mengkaji dan memilih algoritma pembelajaran mendalam terbaik bagi melakukan pengelasan sayur-sayuran. Dalam projek ini, sistem berasaskan web pengelasan sayur-sayuran berdasarkan pembelajaran mendalam telah dibangunkan bagi kegunaan masyarakat umum. Dua algoritma CNN yang telah dikaji dan dibandingkan ialah AlexNet dan VGG16. Selain itu, penggunaan hiperparameter yang berbeza-beza seperti pengoptimum dan bilangan epoch telah diimplementasi kepada model. Model yang memberikan prestasi terbaik dalam melakukan pengelasan telah dipilih dan diguna dalam pembangunan sistem Vegetates. Daripada analisis model yang telah dijalankan, model VGG16 yang menggunakan pengoptimum Adamax dan 50 epoch menunjukkan prestasi yang terbaik dengan peratusan ketepatan sehingga 97% serta mampu memberikan model yang stabil dan tergeneralisasikan. Bagi menambah ketepatan ramalan model pada imej sayur-sayuran sebenar, bilangan imej pada dataset telah ditambah. Dengan menggunakan teknik pembelajaran mendalam, sayur-sayuran dapat dikelaskan dengan baik.

Kata kunci: Sayur-sayuran, pembelajaran mendalam, AlexNet, VGG16, hiperparameter

PENGENALAN

Pada abad ke-21, dunia sedang bergerak pantas ke arah kecerdasan buatan (AI) iaitu pembelajaran mesin dan pembelajaran mendalam. Pelbagai Model AI teguh telah dibuat yang berprestasi jauh lebih baik daripada otak manusia, seperti penjanaan deepfake, pengelasan imej dan pengelasan teks (Garg 2022). Beliau juga menyatakan bahawa rangkaian neural konvolusi (CNN) merupakan subset kepada rangkaian neural buatan (ANN) yang digunakan dalam pembelajaran mendalam dan kerap digunakan dalam pengenalpastian serta pengelasan objek dan imej.

Kajian awal telah dijalankan dengan menggunakan kaedah soal selidik. Soal selidik yang telah dijalankan ini bertujuan untuk lebih memahami pengetahuan masyarakat dalam membezakan jenis sayur-sayuran serta mengetahui isu yang dihadapi dalam pembelian dan pemilihan sayur-sayuran. Kajian ini terdiri daripada 20 orang responden yang terdiri daripada kaum Melayu, Cina dan India, lelaki dan wanita yang berusia 18 tahun ke atas. Seramai 68% responden pernah mengalami kesukaran dalam mengenal pasti jenis sayur-sayuran dan 64% responden telah mengalami situasi tersilap membeli sayur. Berdasarkan soal selidik ini juga, 90% responden bersetuju bahawa sayur-sayuran berdaun hijau agak sukar untuk dibezakan. Tambahan pula, 84% responden mendapati sesetengah kedai tidak melabelkan jenis sayur-sayuran terutama kedai-kedai runcit yang kecil.

Bagi menyelesaikan masalah yang dinyatakan, projek ini bertujuan membangunkan sebuah sistem berasaskan web yang membolehkan pengelasan sayur-sayuran mengikut jenisnya. Sistem ini akan dinamakan sebagai ‘Vegetates’ dan akan melakukan pengelasan imej berdasarkan pembelajaran mendalam. Kategori sayur yang akan diutamakan adalah berdasarkan daripada kajian terdahulu. Terdapat lapan kelas yang akan digunakan bagi pengelasan imej. Kelas-kelas pengelasan termasuklah kubis, kubis bunga, brokoli, tomato, terung, lada benggala, lobak merah dan timun. Sistem ini akan menerima input berasaskan imej daripada pengguna dan kemudia meramal serta mengelaskan sayuran tersebut. Output keputusan pengelasan akan dipaparkan kepada pengguna.

Objektif kajian ini adalah mengenal pasti model algoritma pembelajaran mendalam terbaik bagi sistem pengelasan jenis sayur-sayuran daripada perbandingan prestasi model, membangunkan aplikasi berasaskan web yang mampu meramal dan mengelas sayur-sayuran berasaskan imej yang dimuat naik oleh pengguna ke dalam sistem dan terakhir, menguji dan menilai kebolehan sistem.

METODOLOGI KAJIAN

Sistem pengelasan sayur-sayuran Vegetates berlandaskan dan bergantung kepada teknik kecerdasan buatan iaitu pembelajaran mendalam. Secara khususnya, algoritma yang digunakan dalam melatih model adalah CNN. Dua senibina model CNN yang berbeza iaitu VGG16 dan AlexNet akan digunakan dan dilaksanakan bagi melakukan pengelasan sayur-sayuran. Penalaan hiperparameter dilakukan bagi menguji model untuk memberikan pengesanan dan pengelasan terbaik. Hasil keputusan ramalan melalui kedua-dua algoritma berbeza tersebut dibandingkan dan satu model yang memberi ketepatan paling tinggi dipilih dan digunakan dalam pembangunan sistem Vegetates. Bagi sumber dataset imej, ia diambil daripada laman web Kaggle. Dataset menjalani prapemprosesan data bagi memastikan data tersedia sebelum menjalani latihan model.

Pengumpulan data

Data yang dikumpulkan adalah berdasarkan kelas-kelas sayuran yang akan digunakan bagi projek iaitu brokoli, kubis, lada benggala, lobak merah, kubis bunga, timun, terung dan tomato. Kelas-kelas ini adalah rujukan daripada kajian Li et al. (2020) bertajuk Vegetable

Recognition and Classification Based on Improved VGG Deep Learning Network Model, dan menggantikan kelas cendawan dan labu kepada kelas terung bagi projek ini. Sumber dataset imej bagi projek telah dimuat turun daripada laman web Kaggle yang disediakan oleh Ahmed & Mamun (2021). Setiap kelas terdiri daripada 1000 imej. Walau bagaimanapun, dataset imej bagi terung tidak terdapat di dalam Kaggle. Oleh itu, dataset imej terung telah dikumpul sendiri melalui laman web Google Images dan berjaya mengumpulkan 1000 imej bagi kelas terung. Ini membuatkan jumlah dataset imej yang digunakan bagi projek ini adalah sebanyak 8000 imej bagi lapan kelas yang berbeza-beza.

Prapemprosesan data

Prapemprosesan data bertujuan memastikan data yang digunakan adalah bersih dan berada dalam format yang sesuai untuk permodelan. Langkah-langkah prapemprosesan data yang telah dilaksanakan adalah penapisan imej, pengubahan saiz imej, dan pembahagian dataset.

Penapisan imej bertujuan membuang imej yang tidak mengikut format yang ditetapkan. Format fail imej yang ditetapkan adalah jpg, jpeg, png dan bmp. Di akhir pelaksanaan kod langkah ini, imej dataset yang tinggal hanyalah dalam format tersebut dan boleh digunakan bagi pembelajaran model.

Pengubahan saiz imej adalah mengikut senibina algoritma model. Saiz input imej akan diubah mengikut senibina model pembelajaran mendalam. VGG16 menerima saiz input imej berukuran 224x224, manakala model pembelajaran mendalam AlexNet menerima saiz input imej berukuran 227x227.

Penukaran tatasusunan kepada tatasusunan NumPy bermaksud menukar imej data kepada format tatasusunan berangka dan bertujuan melakukan operasi kepada keseluruhan imej secara serentak. Oleh itu, tugas pemprosesan imej menjadi lebih cekap. Selain itu, lapisan model pembelajaran mendalam menggunakan perpustakaan TensorFlow Keras dan ia menerima input data dalam bentuk tatasusuan Numpy.

Pembahagian dataset adalah proses di mana dataset dibahagikan kepada tiga subset yang akan digunakan untuk fungsi yang berbeza-beza. Tiga subset tersebut ialah set latihan, set pengesahan dan set ujian. Nisbah pembahagian set ialah 7:2:1.

Latihan model

Projek ini telah mengkaji lapan model yang berbeza-beza hiperparameter seperti algoritma senibina, pengoptimum dan nilai epoch. Algoritma senibina yang terlibat ialah VGG16 dan AlexNet. Pengoptimum yang terlibat ialah Adamax dan RMSProp. Nilai epoch yang terlibat ialah 50 dan 70. Hiperparameter untuk setiap model ditunjukkan dalam Jadual 1.

Jadual 1 Hiperparameter setiap model

Model	Algoritma	Pengoptimum	Epoch
1	VGG16	Adamax	50
2	VGG16	RMSProp	50
3	VGG16	Adamax	70
4	VGG16	RMSProp	70
5	AlexNet	Adamax	50
6	AlexNet	RMSProp	50
7	AlexNet	Adamax	70
8	AlexNet	RMSProp	70

Selain itu, terdapat parameter-parameter yang telah ditetapkan untuk setiap model. Fungsi kehilangan yang digunakan bagi setiap model ialah sparse categorical crossentropy. Metrik penilaian yang ditetapkan semasa latihan adalah ketepatan. Saiz kumpulan yang digunakan bagi setiap model ialah 32. Bagi rangka kerja, perpustakaan TensorFlow Keras telah digunakan.

Pengujian Model

Pelan pengujian dan penilaian yang dijalankan untuk projek ialah pengujian model dan pengujian pengelasan. Pengujian model ialah hasil metrik penilaian yang diterima oleh setiap model selepas latihan. Model pembelajaran mendalam yang memberikan prestasi terbaik dalam melakukan pengelasan akan digunakan bagi pengujian pengelasan. Pengujian model adalah menggunakan data set ujian ke atas model yang telah dilatih. Pengujian pengelasan akan dijalankan di aplikasi Gradio dengan menggunakan imej sayur-sayuran sebenar dan melihat hasil ramalan. Keputusan ramalan direkodkan.

KEPUTUSAN DAN PERBINCANGAN

Prestasi setiap model akan dinilai menggunakan beberapa metrik penilaian iaitu ketepatan, kejituhan, penilai panggilan dan skor F1 model terhadap set ujian. Selain itu, masa yang diambil oleh setiap model untuk menjalani latihan, graf ketepatan dan graf kerugian turut dicatat. Hasil keputusan setiap model adalah seperti yang ditunjukkan dalam Jadual 2 bagi model-model VGG16 dan Jadual 3 bagi model-model AlexNet.

Jadual 2 Hasil keputusan model-model VGG16

Pengoptimum	Epoch	Tempoh latihan	Ketepatan	Kejituhan	Penilai panggilan	Skor-F1
Adamax	50	1j 41m 14s	0.97	0.9709	0.97	0.9702
Rmsprop	50	1j 35m 14s	0.885	0.8875	0.885	0.8847
Adamax	70	2j 11m 43s	0.9525	0.954	0.9525	0.9528
Rmsprop	70	2j 29m 52s	0.8794	0.8907	0.8794	0.8803

Jadual 3 Hasil keputusan model-model AlexNet

Pengoptimum	Epoch	Tempoh latihan	Ketepatan	Kejituhan	Penilai panggilan	Skor-F1
Adamax	50	58m 23s	0.9774	0.9777	0.9774	0.9773
Rmsprop	50	59m 51s	0.9786	0.9788	0.9786	0.9786
Adamax	70	1j 43m 22s	0.9912	0.9913	0.9912	0.9912
Rmsprop	70	1j 49m 17s	0.9825	0.9827	0.9825	0.9825

Ketepatan

Berdasarkan Jadual 2, model VGG16 yang menggunakan pengoptimum Adamax dan epoch 50 memberikan nilai ketepatan paling tinggi iaitu 0.97 bersamaan 97%. Perbandingan tersebut juga menunjukkan bahawa penggunaan pengoptimum Adamax pada kedua-dua model VGG16 memberikan ketepatan yang lebih tinggi berbanding model-model VGG16 yang menggunakan pengoptimum RMSProp.

Jadual 3 menunjukkan bahawa model AlexNet yang menggunakan pengoptimum Adamax dengan 70 epoch memberikan ketepatan yang paling tinggi iaitu 99.12%. Penggunaan 50 epoch pada kedua-dua model yang menggunakan pengoptimum Adamax dan RMSprop memberikan nilai ketepatan yang hampir sama di mana masing-masing memberikan 97.74% dan 97.86%. Ketepatan tersebut bertambah apabila 70 epoch digunakan.

Kejituhan

Berdasarkan Jadual 2, model VGG16 yang menggunakan pengoptimum Adamax dan epoch 50 memberikan nilai ketepatan paling tinggi iaitu 0.9709. Ia bermaksud secara purata, model dapat melakukan 97.09% ramalan positif dengan betul. Perbandingan tersebut juga menunjukkan bahawa penggunaan pengoptimum Adamax kepada kedua-dua model VGG16 memberikan nilai kejituhan yang lebih tinggi berbanding model-model VGG16 yang menggunakan pengoptimum RMSProp.

Jadual 3 menunjukkan bahawa model AlexNet yang menggunakan pengoptimum Adamax dengan 70 epoch memberikan kejituhan yang paling tinggi iaitu 0.9913. Penggunaan 50 epoch pada kedua-dua model yang menggunakan pengoptimum Adamax dan RMSprop memberikan nilai kejituhan yang hampir sama di mana masing-masing memberikan 0.9777 dan 0.9788. Kejituhan tersebut bertambah apabila 70 epoch digunakan.

Penilai Panggilan

Berdasarkan Jadual 2, model VGG16 yang menggunakan pengoptimum Adamax dan epoch 50 memberikan nilai penilai panggilan yang paling tinggi iaitu 0.97. Ia bermaksud secara purata, model dapat memberikan ramalan positif sebenar dengan betul daripada keseluruhan sampel positif sebenar data model sebanyak 97%. Perbandingan tersebut juga menunjukkan bahawa penggunaan pengoptimum Adamax pada kedua-dua model VGG16 memberikan nilai penilai panggilan yang lebih tinggi berbanding model-model VGG16 yang menggunakan pengoptimum RMSProp.

Jadual 3 menunjukkan bahawa model AlexNet yang menggunakan pengoptimum Adamax dengan 70 epoch memberikan penilai panggilan yang paling tinggi iaitu 0.9912. Penggunaan 50 epoch pada kedua-dua model yang menggunakan pengoptimum Adamax dan RMSprop memberikan penilai panggilan yang hampir sama di mana masing-masing memberikan 0.9774 dan 0.9786. Penilai panggilan tersebut bertambah apabila 70 epoch digunakan.

Skor F1

Berdasarkan Jadual 2, model VGG16 yang menggunakan pengoptimum Adamax dan epoch 50 memberikan skor F1 yang paling tinggi iaitu 0.9702. Ia bermaksud kedua-dua nilai kejituhan dan penilai panggilannya adalah tinggi serta mampu melakukan ramalan dengan efektif. Perbandingan tersebut juga menunjukkan bahawa penggunaan pengoptimum Adamax pada kedua-dua model VGG16 memberikan skor F1 yang lebih tinggi berbanding model-model VGG16 yang menggunakan pengoptimum RMSProp.

Jadual 3 menunjukkan bahawa model AlexNet yang menggunakan pengoptimum Adamax dengan 70 epoch memberikan skor F1 yang paling tinggi iaitu 0.9912. Penggunaan 50 epoch pada kedua-dua model yang menggunakan pengoptimum Adamax dan RMSprop memberikan skor F1 yang hampir sama di mana masing-masing memberikan 0.9773 dan 0.9786. Skor F1 tersebut bertambah apabila 70 epoch digunakan.

Tempoh Latihan

Tempoh latihan ialah masa yang diambil bagi melatih model menggunakan set latihan dan set pengesahan. Latihan model ini dilakukan menggunakan T4 GPU yang tersedia oleh platform Google Colab. Berdasarkan Jadual 2 dan 3, ia menunjukkan bahawa semakin tinggi nilai epoch, semakin bertambah masa yang diambil untuk melatih model. Hal ini kerana semakin tinggi nilai epoch, semakin tinggi bilangan yang perlu dilalui oleh set latihan kepada algoritma yang menyebabkan ia memakan masa yang lebih lama.

Penggunaan algoritma AlexNet menunjukkan bahawa masa latihan adalah lebih singkat berbanding algoritma VGG16. Masa latihan model AlexNet menggunakan pengoptimum Adamax dan epoch 50 adalah yang paling singkat iaitu 58 minit 23 saat. Manakala masa latihan yang paling lama adalah model VGG16 yang menggunakan pengoptimum RMSProp dan epoch 70, iaitu selama 2 jam 29 minit 52 saat.

Graf Ketepatan

Jadual 4 menunjukkan graf ketepatan bagi dua model, iaitu model VGG16 dan AlexNet yang telah memberikan ketepatan paling tinggi. Model VGG16 yang menggunakan pengoptimum Adamax dan 50 epoch memberikan kelancaran penumpuan dan generalisasi graf yang terbaik. Bagi model AlexNet yang menggunakan pengoptimum Adamax dan 70 epoch, lengkuk bagi ketepatan bagi set latihan adalah baik tetapi lengkuk bagi ketepatan set pengesahan menunjukkan prestasi yang tidak baik dan dalam keadaan turun naik. Menurut DK (2019), perkara tersebut terjadi akibat model bersifat sensitif pada data yang bising

Jadual 4 Graf ketepatan model

Algoritma	Pengoptimum	Epoch	Graf Ketepatan Model
VGG16	Adamax	50	
AlexNet	Adamax	70	

Graf Kerugian

Jadual 5 menunjukkan graf kerugian bagi dua model, iaitu model VGG16 dan AlexNet yang telah memberikan ketepatan paling tinggi. Model VGG16 yang menggunakan pengoptimum Adamax dan 50 epoch menunjukkan prestasi yang baik di mana ia memberikan kelancaran, penumpuan dan generalisasi graf yang terbaik. Walau bagaimanapun, model AlexNet yang menggunakan pengoptimum Adamax dan 70 epoch tidak memperlihatkan hasil yang baik kerana berlaku penurunan dan kenaikan. Ibrahim (2024) juga menyatakan bahawa penurunan dan kenaikan pada graf berlaku akibat model yang mengalami overfit disebabkan data yang bising yang mengganggu proses pembelajaran model.

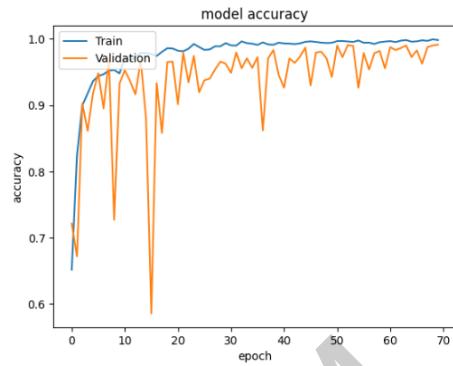
Jadual 5 Graf kerugian model

Algoritma	Pengoptimum	Epoch	Graf Kerugian Model
VGG16	Adamax	50	

AlexNet

Adamax

70



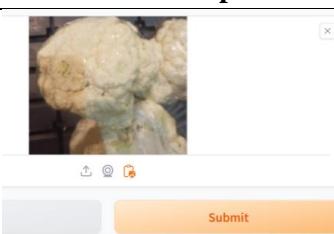
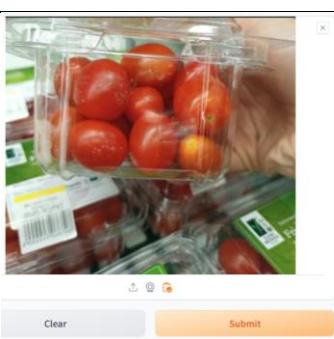
Pemilihan Model

Berdasarkan hasil keputusan dan analisis yang telah dijalankan daripada metrik-metrik penilaian, model yang paling efektif telah menunjukkan prestasi yang paling baik dari segi ketepatan, penilaian panggilan, skor F1 dan kestabilan graf antara kelapan-lapan model pembelajaran mendalam dalam melakukan pengelasan sayur-sayuran. Model tersebut adalah model VGG16 menggunakan pengoptimum Adamax dan 50 epoch. Ketepatan yang diberikan oleh model tersebut adalah 97% manakala masa yang diambil oleh melatih model tersebut adalah selama 1 jam 41 minit 14 saat.

Pengujian Pengelasan

Pengujian pengelasan dijalankan di aplikasi Gradio. Pengujian ini menggunakan sayur-sayuran sebenar yang terdapat di pasaraya Malaysia. Jadual 6 menunjukkan pengujian pengelasan yang telah dijalankan di aplikasi Gradio pada laman web. Output yang akan dipaparkan ialah keputusan ramalan yang dibuat oleh model serta peratusan ramalannya mengikut kelas.

Jadual 6 Pengujian pengelasan sayur-sayuran

Sayur	Keputusan Pengelasan							
Kubis bunga	 <table border="1"> <thead> <tr> <th>output</th> </tr> </thead> <tbody> <tr><td>Kubis Bunga</td><td>87%</td></tr> <tr><td>Kubis</td><td>12%</td></tr> <tr><td>Tomato</td><td>0%</td></tr> </tbody> </table>	output	Kubis Bunga	87%	Kubis	12%	Tomato	0%
output								
Kubis Bunga	87%							
Kubis	12%							
Tomato	0%							
Tomato	 <table border="1"> <thead> <tr> <th>output</th> </tr> </thead> <tbody> <tr><td>Tomato</td><td>98%</td></tr> <tr><td>Lobak Merah</td><td>2%</td></tr> <tr><td>Lada Bengal</td><td>0%</td></tr> </tbody> </table>	output	Tomato	98%	Lobak Merah	2%	Lada Bengal	0%
output								
Tomato	98%							
Lobak Merah	2%							
Lada Bengal	0%							

Lada
bengala



Submit

Lada Bengala

Lada Bengala	98%
Tomato	2%
Terung	0%

Lobak
merah



Submit

Lobak Merah

Lobak Merah	100%
Tomato	0%
Kubis Bunga	0%

Terung



Submit

Terung

Terung	100%
Kubis	0%
Timun	0%

Kubis



Submit

Kubis

Kubis	100%
Tomato	0%
Kubis Bunga	0%

Brokoli



Submit

Brokoli

Brokoli	100%
Kubis	0%
Lada Bengala	0%

Timun



Submit

Timun

Timun	100%
Tomato	0%
Kubis Bunga	0%

Cadangan Penambahbaikan

Selepas menjalankan kajian yang menyeluruh, cadangan penambahan yang boleh dilakukan adalah penambahan kelas sayur-sayuran yang agak serupa. Sebagai contoh, jenis sayur dengan varian yang sama sendiri seperti kubis cina, kubis bulat dan kubis ungu. Cadangan ini telah diberikan daripada pengguna melalui soal selidik kepenggunaan yang telah dijalankan. Selain itu, penambahbaikan model boleh dilakukan bagi memperoleh model yang mampu melakukan pengelasan sayur-sayuran dengan lebih tepat. Terdapat lebih lagi hiperparameter model yang boleh diubah-ubah seperti kadar pembelajaran dan algoritma CNN yang lain seperti ResNet dan YOLO.

KESIMPULAN

Secara keseluruhannya, sistem pengelasan sayur-sayuran ini telah berjaya dibangunkan dengan menggunakan model-model pembelajaran mendalam yang telah dikaji dan dianalisis. Objektif kajian dan keperluan yang telah ditetapkan sebelum ini telah berjaya dicapai. Walaupun terdapat beberapa halangan, ia berjaya diatasi menggunakan pelbagai cara. Diharapkan sistem pengelasan sayur-sayuran ini dijadikan titik kajian untuk kajian lain pada masa hadapan. Berdasarkan keputusan ujian, model pembelajaran mendalam yang paling baik dan efektif adalah model VGG16 yang menggunakan pengoptimum Adamax dan 50 epoch. Ia mampu memberikan ketepatan sehingga 97% dan menghasilkan model yang stabil serta tergeneralisasi sepanjang latihan model.

Kekuatan Sistem

Berdasarkan daripada analisis keputusan yang telah dijalankan, model pembelajaran mendalam ini mampu melakukan pengelasan sayur-sayuran dengan baik. Sistem ini boleh diakses dan digunakan daripada komputer dan telefon pintar. Bagi memuat naik imej untuk melakukan pengelasan, pengguna boleh menggunakan kaedah muat naik imej daripada galeri, membuka kamera, dan juga salin tampil. Kaedah-kaedah ini boleh memudahkan pengguna melakukan pengelasan sayur-sayuran di mana-mana sahaja dan pada bila-bila masa.

Kelemahan Sistem

Terdapat beberapa sayur-sayuran yang tidak dapat dikelaskan dengan betul seperti tomato, lobak merah dan lada bengala. Hal ini kerana bentuk dan warna yang dimiliki mereka adalah hampir sama. Selain itu, beberapa sayuran lain dikelaskan secara salah kepada kubis. Perkara ini mungkin terjadi kerana dataset kelas kubis yang agak variasi. Sebagai contoh, apabila imej-imej kubis yang baru ditambah kepada dataset, ia mengelirukan model dengan sayur-sayuran yang lain.

PENGHARGAAN

Segala pujian bagi Allah atas kurniaan ilhamNya di sepanjang berlangsungnya perancangan dan pembangunan bagi projek ini.

Terima kasih yang tidak terhingga kepada penyelia projek tahun akhir saya, Ts. Dr. Noor Faridatul Ainun Binti Zainal atas dorongan dan panduan bermakna yang telah diberikan selama kajian ini dilakukan. Juga kepada para pensyarah dan pihak Fakulti Teknologi dan Sains Maklumat yang telah banyak memberikan tunjuk ajar melalui sesi taklimat projek tahun akhir mingguan serta bahan-bahan rujukan berkaitan.

Terima kasih yang tidak terkata kepada ibu bapa, keluarga, dan rakan-rakan seperjuangan atas doa, sokongan dan tunjuk ajar yang telah diberikan kepada saya.

RUJUKAN

- Ahmed, M. I & Mamun, S. M. 2021. Vegetable Image Dataset. *Kaggle*. <https://www.kaggle.com/datasets/misrakahmed/vegetable-image-dataset> [24 Jun 2024].
- DK. 2019. Why is the Validating Accuracy Fluctuating. *Stack Exchange*. <https://stats.stackexchange.com/questions/255105/why-is-the-validation-accuracy-fluctuating>. [3 Julai 2024].
- Garg, A. 2022. How to Make an Image Classification Model Using Deep Learning? *Analytics Vidya*. <https://www.analyticsvidhya.com/blog/2022/11/how-to-make-a-image-classification-model-using-deep-learning/> [24 Oktober 2024].
- Ibrahim, M. 2024. A Deep Dive Into Learning Curves in Machine Learning. *Weight & Biases*. <https://wandb.ai/mostafaibrahim17/ml-articles/reports/A-Deep-Dive-Into-Learning-Curves-in-Machine-Learning--Vmlldzo0NjA1ODY0#what-are-accuracy-and-loss-curves?> [3 Julai 2024].
- Li, Z. et al. 2020. Vegetable Recognition and Classification Based on Improved VGG Deep Learning Network Model. *International Journal of Computational Intelligence Systems* 13(1) hlmn 559–559. <https://doi.org/10.2991/ijcis.d.200425.001> [31 Oktober 2024].

Nur Farhan Binti Abd Jamal (A188086)

Ts. Dr. Noor Faridatul Ainun Binti Zainal

Fakulti Teknologi & Sains Maklumat

Universiti Kebangsaan Malaysia