

PENGESANAN PENYAKIT POKOK KELAPA SAWIT MENGUNAKAN TEKNIK PEMBELAJARAN MENDALAM

CHONG YU JIE
TS. DR. NOR SAMSI AH SANI

Fakulti Teknologi & Sains Maklumat, Universiti Kebangsaan Malaysia

ABSTRAK

Malaysia adalah pengeluar kedua terbesar dan pengeksport minyak sawit terbesar di dunia selepas Indonesia. Malaysia dan Indonesia menyumbang sekitar 85 peratus pengeluaran minyak sawit ke seluruh dunia. Kelapa sawit adalah salah satu tanaman pertanian penting di Malaysia kerana ia lebih berkesan daripada tanaman penghasil minyak lain dalam bidang pengeluaran komoditi. Dengan itu, adalah penting untuk mengetahui kuantiti pokok kelapa sawit di kawasan perkebunan kerana dapat membantu kita meramalkan hasil kelapa sawit, memantau pertumbuhan pokok kelapa sawit dan memaksimumkan produktiviti mereka. Namun, minyak sawit terancam oleh penyakit-penyakit pada bila-bila masa dan akan mempengaruhi hasil pengeluaran minyak sawit. Model pembelajaran mendalam telah dicadangkan untuk membantu petani mengenal pasti penyakit daun kelapa sawit dengan pemprosesan imej dan klasifikasi rangkaian saraf tanpa pengetahuan pakar mengenai pelbagai penyakit pada pokok kelapa sawit. Oleh itu, petani tidak perlu mencari pakar untuk mengenal pasti penyakit pokok kelapa sawit dan secara langsung dapat menjimatkan lebih banyak masa. Dalam projek ini, metodologi CRISP-DM digunakan untuk membangunkan aplikasi ini dalam 6 fasa berbeza. Fasa pertama iaitu fasa pemahaman perniagaan dimana objektif kajian ditentukan. Seterusnya, fasa kedua merupakan fasa pemahaman data dimana data daripada Malaysian Palm Oil Board (MPOB) telah dikumpulkan. Fasa kemudian iaitu fasa penyediaan data akan menyesuaikan set data untuk pengesanan kelapa sawit dengan menggunakan teknik penambahan data. Dalam fasa keempat iaitu fasa pemodelan dimana pendekatan pembelajaran pemindahan telah diaplikasikan dengan menggunakan model pembelajaran mendalam yang telah dilatih untuk melaksanakan pemilihan ciri pada contoh set imej. Kemudian, lapisan klasifikasi asal model pembelajaran mendalam tersebut digantikan dengan lapisan klasifikasi baharu yang sesuai untuk kajian ini. Terdapat tiga model pembelajaran mendalam yang telah dilatih digunakan dalam projek ini iaitu model InceptionResnetV2, Xception dan VGG19. Model InceptionResNetV2 mampu memperoleh ketepatan keseluruhan secara 99 % manakala kedua-dua model VGG-19 dan model Xception dapat memperoleh ketepatan keseluruhan secara 100 % dalam mengklasifikasikan sebanyak 6 penyakit pokok kelapa sawit semasa fasa penilaian prestasi model. Analisis prestasi perbandingan antara ketiga-tiga model tersebut menunjukkan bahawa VGG-19 merupakan model terbaik dalam pengesanan penyakit pokok kelapa sawit dalam kajian ini. Pada fasa yang terakhir iaitu fasa pembangunan, aplikasi web pengesanan penyakit pokok kelapa sawit berintegrasi dengan model VGG-19 telah dibina.

1 PENGENALAN

Minyak sawit adalah salah satu kegunaan tanah yang paling menguntungkan dan dengan itu pokok kelapa sawit dianggap sebagai tanaman penting di Malaysia. Ini kerana minyak sawit memberi sumbangan besar kepada ekonomi negara dan penyumbang utama kepada Keluaran Dalam Negara Kasar (KDNK) selain petroleum dan getah.

Produktiviti kelapa sawit boleh ditingkatkan dengan menjaga kesihatan pokok kelapa sawit. Hal ini kerana pokok kelapa sawit terdedah kepada pelbagai penyakit. Kulat, bakteria, dan virus adalah mikroorganisma penyakit yang paling biasa (Ysuhaimi 2017). Jangkitan penyakit boleh mengganggu pengeluaran minyak sawit, itulah sebabnya kesihatan pokok kelapa sawit adalah penting untuk mencapai output maksimum. Penyakit boleh menjangkiti pokok kelapa sawit di

mana-mana peringkat pembangunan. Walau bagaimanapun, tidak ada teknik yang baik untuk meminimumkan pengaruh jangkitan terhadap hasil dalam jangkitan penyakit maju. Kaedah pemeriksaan visual adalah teknik yang paling asas untuk mengesan penyakit pokok kelapa sawit. Selain itu, dengan menggunakan tenaga buruh untuk mengklasifikasikan penyakit ini juga boleh menyebabkan kesilapan manusia.

Dengan menggunakan teknik pembelajaran mendalam, klasifikasi penyakit kelapa sawit boleh dikesan dan diketahui dengan tepat dan cepat (Masazhar et al. 2017, November) supaya langkah-langkah pencegahan yang betul dapat diambil dengan segera. Rangkaian Konvolusi Saraf (CNN) adalah model pembelajaran mendalam, dan ia telah mencapai prestasi yang sangat baik dalam bidang klasifikasi imej. Dalam penyelidikan baru-baru ini mengenai pengesanan penyakit tumbuhan, sesetengah penyelidik telah menunjukkan prestasi yang sangat baik dengan menggunakan model pembelajaran mendalam. Sebagai bukti, Ma et al. (2018) telah mencapai ketepatan sebanyak 93.4 peratus dengan menggunakan CNN yang mendalam untuk mengenal pasti empat penyakit timun (downy mildew, anthracnose, mildew serbuk, dan tompok daun sasaran) berdasarkan gejala mereka. Kawasaki et al. (2015) membangunkan kaedah berasaskan CNN untuk mengesan penyakit daun timun yang mempunyai kadar ketepatan 94.9 peratus.

Walaupun keputusan yang cemerlang telah dilaporkan dalam kesusasteraan, kepelbagaian set data yang digunakan dalam kajian ini adalah terhad. Latihan CNN memerlukan penggunaan set data yang besar (yang terdiri daripada beribu-ribu imej). Pembelajaran pemindahan (*Transfer Learning*) pada masa ini adalah kaedah yang paling berkesan untuk meningkatkan keteguhan pengelasan CNN untuk pengesanan penyakit daun tumbuhan. Pembelajaran pemindahan adalah teknik untuk menggunakan semula rangkaian konvolusi saraf pra-terlatih untuk menyelesaikan isu baru. Akibatnya, tempoh latihan model boleh dikurangkan berbanding model yang dibina dari awal, dan prestasi model yang dicadangkan boleh diperbaiki. Dengan mengeluarkan lapisan terakhir yang disambungkan sepenuhnya atau memperhalusi beberapa peringkat terakhir yang akan beroperasi lebih khusus untuk set data yang berkenaan, pembelajaran pemindahan boleh digunakan untuk menghasilkan model yang boleh digunakan sebagai pengekstrak ciri tetap. Oleh itu, gabungan pembelajaran mendalam dan pembelajaran pemindahan menyediakan cara baru untuk menyelesaikan masalah set data terhad penyakit pokok kelapa sawit.

Dengan yang demikian, matlamat projek ini adalah membangunkan satu aplikasi web berintegrasi dengan model pembelajaran mendalam yang boleh mengesan penyakit pokok kelapa sawit dengan tepat dan cepat berdasarkan imej yang dimuat naik oleh pengguna.

2 PEMASALAHAN KAJIAN

Industri kelapa sawit merupakan antara penyumbang kepada pertumbuhan ekonomi Malaysia. Pengeluaran minyak sawit dapat dimaksimumkan dengan menjaga kesihatan pokok kelapa sawit. Penyakit pada pokok kelapa sawit boleh menyebabkan kerugian besar dalam pengeluaran dan ekonomi negara. Semua peringkat pokok kelapa sawit boleh dijangkiti penyakit. Penyakit ini jika tidak dikawal, akan menyebabkan jangkitan dan secara tidak langsung boleh mengganggu pengeluaran minyak sawit. Oleh itu, untuk memperoleh pengeluaran yang maksimum, adalah penting untuk menjaga kesihatan pokok kelapa sawit. Walau bagaimanapun, pada masa kini, kaedah pengesanan penyakit pokok kelapa sawit dalam mengurangkan jangkitan pada hasil, masih tidak memuaskan dan dilakukan secara tradisional (Masazhar & Kamal 2017).

Jangkitan penyakit pada tanaman kelapa sawit biasanya mempunyai simptom tertentu. Kaedah asas yang digunakan untuk mengesan pokok kelapa sawit yang dijangkiti penyakit adalah melalui pemerhatian yang dipantau oleh peladang dan ia memakan masa yang lama (Liu & Wang 2021, Asrianda et al. 2021). Selain itu, dengan menggunakan tenaga buruh untuk mengklasifikasikan penyakit, ia boleh menyebabkan kesalahan dalam pengelasan penyakit. Ini boleh berlaku kerana sesetengah penyakit, tidak dapat dikesan oleh mata manusia dan simptomnya tidak kelihatan. Salah satu teknik kecerdasan buatan iaitu memproses imej adalah cara yang sesuai dalam membantu pengesanan penyakit pada daun yang sukar dilihat dengan lebih awal. Pengesanan penyakit pokok kelapa sawit yang tepat adalah penting supaya tindakan pencegahan yang betul dapat dilakukan dan diambil dengan segera (Mohanty et al. 2016). Dengan menggunakan pemprosesan gambar dan corak penyakit pada tumbuhan, pengelasan penyakit kelapa sawit dapat dikesan dan diketahui dengan tepat dan cepat (Masazhar & Kamal 2017).

Di era Industri 4.0 ini, pekebun kecil kelapa sawit diseru untuk menggunakan teknologi untuk meningkatkan hasil. Walau bagaimanapun, peladang di negara ini terus menggunakan teknologi komunikasi pada tahap yang rendah, ketinggalan di belakang peladang di negara-negara perindustrian seperti Amerika Syarikat, Jepun, dan Korea Selatan. (Mahamood et al. 2016). Dalam masa yang sama, sehingga kini, masih belum ada produk khusus yang boleh digunakan sebagai teknologi untuk tujuan kawalan dan pencegahan penyakit diperingkat pengeluaran hasil kelapa sawit di ladang. Elemen penting dalam mengurangkan kadar

jangkitan penyakit pokok kelapa sawit adalah dengan memahami simptom, jenis penyakit dan kesan serangan penyakit. Apabila sesuatu penyakit itu dapat dikesan dengan lebih awal dan tepat, kaedah pencegahan dan kawalan penyakit dapat diambil dengan segera. Penggunaan teknologi dalam pengurusan penyakit pokok kelapa sawit merupakan aspek penting yang perlu diambil berat untuk menambah kuantiti dan kualiti hasil yang akan dikeluarkan. Selain itu, kecekapan dan produktiviti pertanian dapat dipertingkatkan melalui penggunaan teknologi digital, seperti pertanian pintar dan data raya. Kekurangan penyelidikan mengenai topik ini dalam konteks pembangunan pertanian telah mendorong para penyelidik untuk menggali lebih mendalam ke dalam fenomena ini.

3 OBJEKTIF KAJIAN

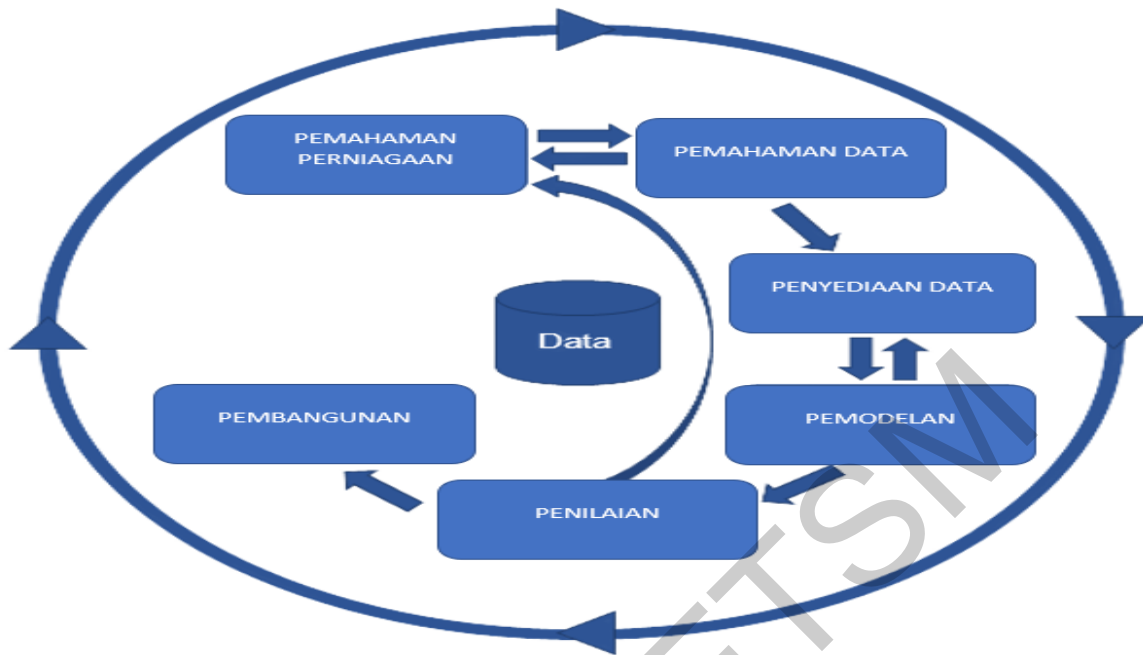
Objektif kajian projek ini adalah untuk membangunkan satu aplikasi web berintegrasi model pembelajaran mendalam yang dapat mengesan penyakit pokok kelapa sawit berdasarkan gambar yang diberikan.

Kajian ini merangkumi objektif berikut:

- a. Untuk mencadangkan tiga model pengesanan penyakit pokok kelapa sawit berdasarkan teknik pembelajaran mendalam.
- b. Untuk menguji dan memilih model yang paling sesuai, tepat dan baik untuk mengesan penyakit pokok kelapa sawit.
- c. Untuk membangunkan satu aplikasi web berintegrasi dengan model pembelajaran mendalam yang terpilih untuk melakukan proses pengesanan.

4 METHOD KAJIAN

Metodologi kajian ini merujuk kepada *CRISP-DM* metodologi yang terbahagi kepada enam fasa iaitu fasa pemahaman perniagaan, fasa pemahaman data, fasa penyediaan data, fasa pemodelan, fasa penilaian, dan fasa pembangunan. Secara keseluruhannya, perincian metodologi kajian adalah seperti dalam Rajah 1.



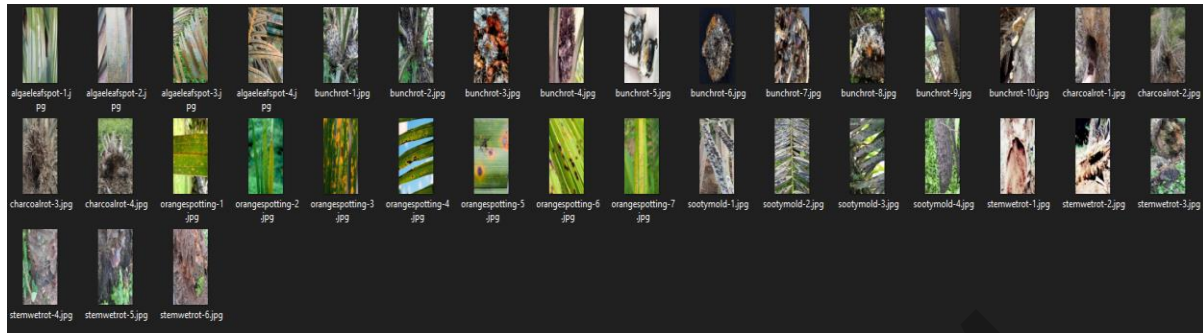
Rajah 1 Metodologi Kajian (CRISP-DM)

FASA PEMAHAMAN PERNIAGAAN

Fasa ini melibatkan pemahaman objektif perniagaan dengan jelas dan mengetahui keperluan perniagaan. Seterusnya, menilai keadaan semasa dengan mencari sumber, andaian, kekangan, dan faktor penting lain yang harus dipertimbangkan. Dari objektif perniagaan dan situasi semasa, menghasilkan tujuan perlombongan data untuk mencapai objektif perniagaan dalam keadaan semasa. Hasil daripada fasa ini, pembangun akan mendapat pemahaman yang jelas mengenai data yang berkaitan dengan model perniagaan semasa fasa pemahaman perniagaan.

FASA PEMAHAMAN DATA

Menambah asas pemahaman perniagaan tersebut, fasa pemahaman data mendorong tumpuan untuk mengenal pasti, mengumpul, dan menganalisis set data yang dapat membantu pembangun mencapai matlamat projek. Set data yang digunakan dalam projek ini adalah dikumpulkan dari *MPOB* (Lembaga Kelapa Sawit Malaysia). Set data yang digunakan adalah semua imej mengenai pelbagai penyakit pokok kelapa sawit seperti '*Algae Leaf Spot*', '*Bunch Rot*', '*Charcoal Rot*', '*Orange Spotting*', '*Sooty Mold*', '*Stem Wet Rot*'. Selain itu, imej-imej ini adalah dalam format warna dan saiz semua imej yang tidak sama. Rajah di bawah menunjukkan imej berkenaan enam penyakit pokok kelapa sawit tersebut.




Rajah 2 Imej berkenaan penyakit-penyakit pokok kelapa sawit

FASA PENYEDIAAN DATA

Dalam fasa ini, beberapa langkah pra-pemprosesan data dijalankan sebelum memasuki fasa pemodelan. Jumlah saiz set data yang sedia ada ditingkatkan dengan menggunakan teknik penambahan data untuk menambah salinan yang diubah suai sedikit bagi data sedia ada atau data sintetik yang baru dibuat daripada data sedia ada. Terdapat beberapa teknik penambahan yang digunakan pada set data iaitu memutar, mengezum dan menyelak. Hal ini kerana saiz set data yang terhad tidak mencukupi untuk melatih model pembelajaran mendalam. Selain itu, saiz data perlu diubah agar sesuai dengan model tertentu kerana setiap algoritma model pembelajaran mendalam mempunyai keperluan asas input yang berbeza, terutamanya saiz imej. Hasil daripada fasa ini, set data yang diubah suai disediakan dengan baik untuk fasa seterusnya.

FASA PEMODELAN

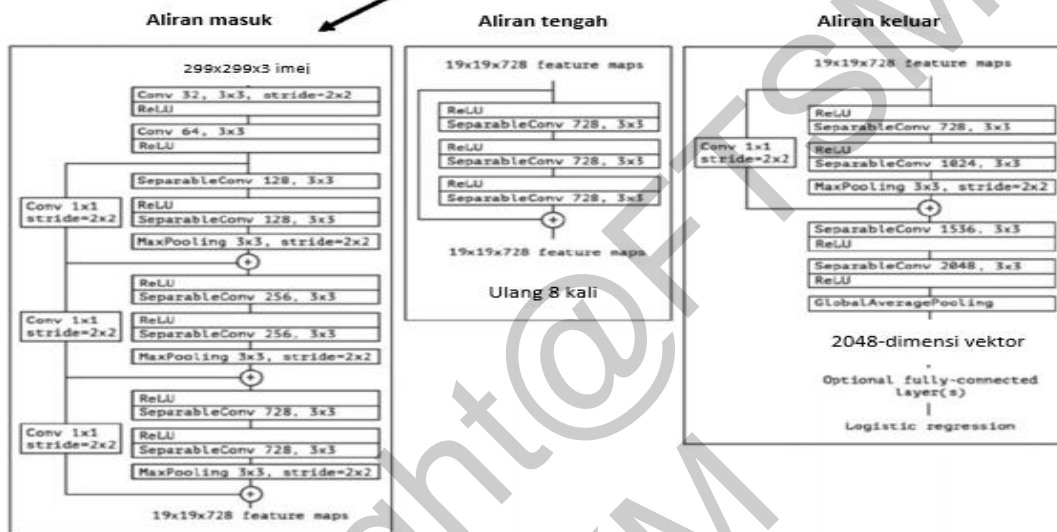
Fasa pemodelan adalah bahagian paling penting dalam projek. Dalam projek ini, model pembelajaran mendalam yang telah dilatih akan digunakan sebagai titik permulaan dan bertindak sebagai mekanisme pengekstrakan ciri. Lapisan keluaran akan dikeluarkan daripada model terlatih dan kemudian gunakan keseluruhan rangkaian sebagai pengekstrak ciri tetap untuk set data yang sedia ada. Lapisan keluaran baharu kemudiannya akan disesuaikan dan dilatih berdasarkan set data yang sedia ada. Terdapat tiga model akan digunakan dalam projek ini seperti model *InceptionResNetV2*, model *VGG19* dan model *Xception*. Rajah di bawah menunjukkan seni bina ketiga-tiga model dan penjelasannya.



Rajah 3 Seni bina VGG19 model

Rajah 3 menunjukkan seni bina VGG19 model. Input model ini adalah imej penyakit pokok kelapa sawit. Setiap imej mewakili satu jenis penyakit pokok kelapa sawit. Sebagai contohnya, input model ini ialah imej pokok kelapa sawit yang mengandungi penyakit 'orange spotting'. Seni bina model VGG19 mempunyai saiz tetap (224 * 224) imej RGB diberikan sebagai input kepada rangkaian ini, membayangkan bahawa matriks itu berbentuk (224,224,3). Model VGG19 menggunakan kernel dengan saiz (3 * 3) dan saiz langkah 1 piksel untuk merangkumi keseluruhan konsep imej. Resolusi spatial imej telah dikekalkan dengan menggunakan *padding spatial*, dan operasi *maximum pooling* dilakukan pada tettingkap (2 * 2) piksel dengan langkah 2. *Rectified Linear unit* (ReLU) kemudiannya digunakan untuk memperkenalkan konsep bukan linear ke dalam model untuk meningkatkan klasifikasi dan masa pengiraan, kerana model sebelumnya telah bergantung pada fungsi *tanh* atau *sigmoid*. Lapisan sebelumnya kemudiannya dilaksanakan, diikuti oleh tiga lapisan bersambung sepenuhnya. Saiz dua lapisan pertama yang bersambung sepenuhnya ialah 4096 manakala lapisan terakhir yang juga dikenali sebagai lapisan pengelasan ataupun lapisan keluaran kerana tujuan lapisan ini adalah untuk mengklasifikasikan imej ke dalam kelas masing-masing dengan menggunakan fungsi *softmax*. Saiz lapisan keluaran bergantung pada bilangan kelas yang akan dikelaskan. Fungsi *softmax* akan mengeluarkan satu nilai untuk setiap nod dalam lapisan keluaran. Nilai output akan mewakili (atau boleh ditafsirkan sebagai) kebarangkalian dan jumlah nilai kepada 1.0. Nod yang mempunyai kebarangkalian tertinggi antara lain ialah kelas input tersebut. Sebagai contoh, output model akan berkelakuan seperti [0.231, 0.456, 0.313] dan kelas dengan kebarangkalian 0.456 akan dipilih sebagai penyakit input imej tersebut.

Imej penyakit pokok
kelapa sawit

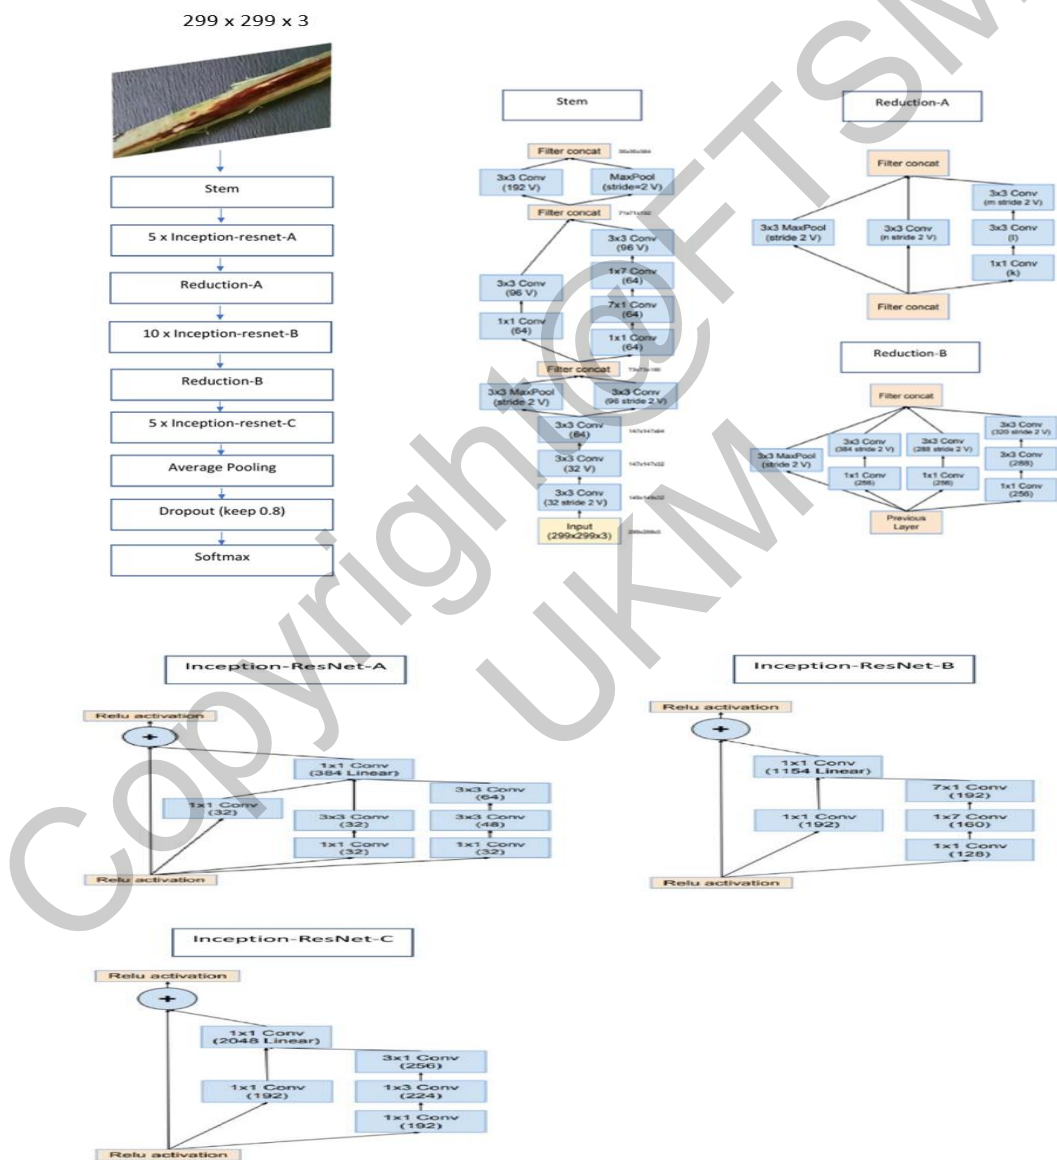


Rajah 4 Seni bina Xception model

Rajah 4 menunjukkan seni bina *Xception* model. Input model ini adalah imej penyakit pokok kelapa sawit. Setiap imej mewakili satu jenis penyakit pokok kelapa sawit. Sebagai contohnya, input model ini ialah imej pokok kelapa sawit yang mengandungi penyakit 'orange spotting'. Seni bina model *Xception* mempunyai saiz tetap (299 * 299) imej RGB diberikan sebagai input kepada rangkaian ini, membayangkan bahawa matriks itu berbentuk (299,299,3). Dengan merujuk kepada gambaran keseluruhan seni bina ini, data mula-mula melalui aliran masuk, kemudian melalui aliran tengah yang diulang lapan kali, dan akhirnya melalui aliran keluar. Seni bina *Xception* model mempunyai 36 lapisan konvolusi yang membentuk asas pengekstrakan ciri rangkaian. 36 lapisan konvolusi distrukturkan kepada 14 modul, kesemuanya mempunyai sambungan *Rectified Linear unit* (ReLU) di sekelilingnya, kecuali modul pertama dan terakhir. Pada penghujung aliran keluar, ciri-ciri yang diekstrak daripada input adalah dalam vektor dimensi 2048. Vektor ini kemudiannya disambungkan ke lapisan yang bersambung sepenuhnya iaitu lapisan keluaran dan saiz lapisan ini bergantung pada

bilangan kelas yang akan dikelaskan. Fungsi *softmax* akan mengeluarkan satu nilai untuk setiap nod dalam lapisan keluaran. Nilai output akan mewakili (atau boleh ditafsirkan sebagai) kebarangkalian dan jumlah nilai kepada 1.0. Nod yang mempunyai kebarangkalian tertinggi antara lain ialah kelas input tersebut. Sebagai contoh, output model akan berkelakuan seperti [0.231, 0.456, 0.313] dan kelas dengan kebarangkalian 0.456 akan dipilih sebagai penyakit input imej tersebut.

Imej penyakit pokok kelapa sawit



Rajah 5 Seni bina InceptionResnetV2 model

Rajah 5 menunjukkan seni bina *InceptionResNetV2* model. Input model ini adalah imej penyakit pokok kelapa sawit. Setiap imej mewakili satu jenis penyakit pokok kelapa sawit.

Sebagai contohnya, input model ini ialah imej pokok kelapa sawit yang mengandungi penyakit 'orange spotting'. Seni bina model *InceptionResNetV2* mempunyai saiz tetap ($299 * 299$) imej RGB diberikan sebagai input kepada rangkaian ini, membayangkan bahawa matriks itu berbentuk $(299,299,3)$. *InceptionResNetV2* menggabungkan seni bina *Inception*, dengan *residual connection*. Seni bina ini terdiri daripada beberapa komponen dan seni bina komponen ini juga ditunjukkan di rajah atas. Dalam blok *Inception-Resnet*, penapis konvolusi berbilang saiz digabungkan dengan *residual connection*. Setiap blok *Inception-Resnet* diikuti oleh lapisan pengembangan penapis (1×1 konvolusi tanpa pengaktifan) yang digunakan untuk meningkatkan dimensi bank penapis sebelum penambahan supaya sepadan dengan kedalaman input. Penggunaan *residual connection* bukan sahaja mengelakkan masalah degradasi yang disebabkan oleh struktur dalam tetapi juga mengurangkan masa latihan. Selepas input melalui komponen seni bina *InceptionResNetV2*, maka ciri yang diekstrak akhirnya berada dalam format vektor. Fungsi *softmax* akan mengambil vektor ini dan bertukar kepada nilai sebenar. Nilai output akan mewakili (atau boleh ditafsirkan sebagai) kebarangkalian dan jumlah nilai kepada 1.0. Nod yang mempunyai kebarangkalian tertinggi antara lain ialah kelas input tersebut. Sebagai contoh, output model akan berkelakuan seperti $[0.231, 0.456, 0.313]$ dan kelas dengan kebarangkalian 0.456 akan dipilih sebagai penyakit input imej tersebut.

FASA PENILAIAN

Fasa penilaian bertujuan untuk menguji keputusan prestasi setiap model supaya boleh memastikan model boleh mendapat ketepatan yang tinggi semasa mengesan penyakit pokok. Terdapat beberapa alat penilaian yang digunakan semasa penilaian prestasi model seperti matriks kekeliruan (*Confusion matrix*) dan laporan klasifikasi (*Classification report*). Alat penilaian tersebut amat penting dalam fasa ini. Hal ini kerana alat ini boleh menunjukkan bahawa prestasi model lebih terperinci dengan merujuk kepada metrik penilaian seperti F1-skore, kehilangan logaritma dan ketepatan yang dijana oleh alat tersebut. Selepas menilai prestasi setiap model, model terbaik akan dipilih dan disepadukan dengan aplikasi web pada fasa seterusnya.

FASA PEMBANGUNAN

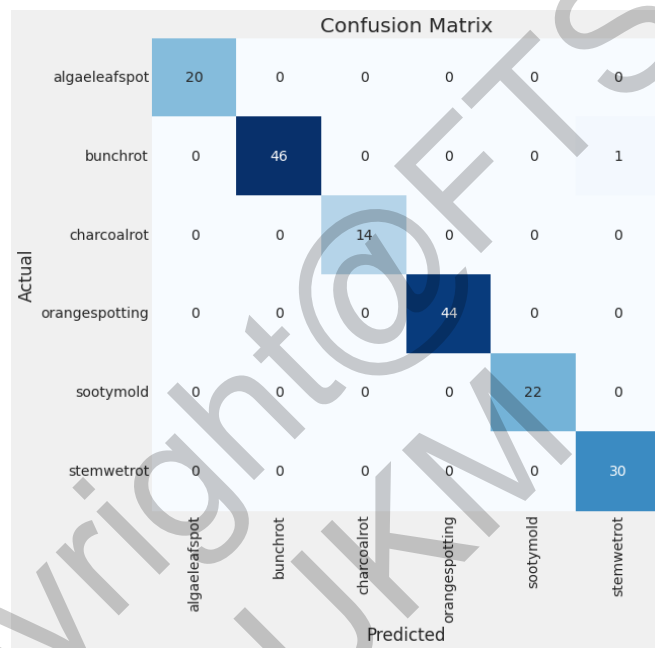
Fasa pembangunan adalah langkah terakhir dalam metodologi ini. Model yang dipilih pada fasa sebelumnya akan berintegrasi dengan aplikasi web dalam projek ini. Aplikasi web ini memberi pengguna ruang untuk memuat naik imej dan menerima keputusan pengesanan

daripada sistem. Aplikasi web telah dibuat menggunakan HTML dan digayakan dengan CSS untuk projek ini. Aplikasi web kemudiannya akan digunakan ke pelayan.

5 HASIL KAJIAN

5.1 HASIL PEMBANGUNAN MODEL

Model InceptionResNet-V2



Rajah 6 Matrik kekeliruan model InceptionResNet-V2


Rajah 6 menunjukkan matrik kekeliruan model InceptionResNet-V2. Matriks kekeliruan ialah jadual yang digunakan untuk menentukan prestasi algoritma pengelasan. Ia digunakan untuk membandingkan kekerapan kelas yang diramalkan dengan kelas yang dijangkakan. Model tersebut telah melakukan satu kesilapan di mana mengklasifikasikan penyakit *bunch rot* kepada penyakit *stem wet rot* dengan merujuk kepada rajah di atas.

	precision	recall	f1-score	support
algaeleafspot	1.00	1.00	1.00	20
bunchrot	1.00	0.98	0.99	47
charcoalrot	1.00	1.00	1.00	14
orangespotting	1.00	1.00	1.00	44
sootymold	1.00	1.00	1.00	22
stemwetrot	0.97	1.00	0.98	30
accuracy			0.99	177
macro avg	0.99	1.00	1.00	177
weighted avg	0.99	0.99	0.99	177

Rajah 7 Laporan klasifikasi model InceptionResNet-V2

Rajah 7 menunjukkan laporan klasifikasi model InceptionResNet-V2. Laporan klasifikasi dapat menunjukkan lebih terperinci tentang hasil pengelasan yang dibuat oleh model. Metrik skor F1 dan ketetapan hanya akan digunakan dalam mentafsir laporan ini selain daripada metrik *precision* dan *recall*. Hal ini kerana skor F1 adalah min harmonic *precision* dan *recall* dan metrik ini dapat menentukan prestasi klasifikasi model keseluruhan dengan keteguhan yang lebih tinggi terhadap masalah ketidakseimbangan kelas (saiz set data ujian untuk setiap penyakit tidak sama). Model ini mampu mencapai ketepatan 99% untuk mengklasifikasikan penyakit dengan betul kepada kelas yang sepadan. Walau bagaimanapun, nilai skor f1 untuk kedua-dua penyakit *bunch rot* dan penyakit *stem wet rot* telah dijatuh kerana model telah melakukan kesilapan ketika dalam peringkat ujian.

Model VGG-19



Rajah 8 Matrik kekeliruan model VGG-19


Rajah 8 menunjukkan matrik kekeliruan model VGG-19. Matriks kekeliruan ialah jadual yang digunakan untuk menentukan prestasi algoritma pengelasan. Ia digunakan untuk membandingkan kekerapan kelas yang diramalkan dengan kelas yang dijangkakan. Model tersebut dapat mengklasifikasikan semua data dengan betul dengan merujuk kepada rajah di atas.

	precision	recall	f1-score	support
algaeleafspot	1.00	1.00	1.00	20
bunchrot	1.00	1.00	1.00	47
charcoalrot	1.00	1.00	1.00	14
orangespotting	1.00	1.00	1.00	44
sootymold	1.00	1.00	1.00	22
stemwetrot	1.00	1.00	1.00	30
accuracy			1.00	177
macro avg	1.00	1.00	1.00	177
weighted avg	1.00	1.00	1.00	177

Rajah 9 Laporan klasifikasi model VGG-19

Rajah 9 menunjukkan laporan klasifikasi model VGG-19. Laporan klasifikasi dapat menunjukkan lebih terperinci tentang hasil pengelasan yang dibuat oleh model. Metrik skor F1 dan ketetapan hanya akan digunakan dalam mentafsir laporan ini selain daripada metrik *precision* dan *recall*. Hal ini kerana skor F1 adalah min harmonic *precision* dan *recall* dan metrik ini dapat menentukan prestasi klasifikasi model keseluruhan dengan keteguhan yang lebih tinggi terhadap masalah ketidakseimbangan kelas (saiz set data ujian untuk setiap penyakit tidak sama). Oleh kerana model tersebut dapat mengklasifikasikan semua data dengan betul kepada kelas yang sepadan, ketepatan dan skor f1 model mampu mencapai 100%.

Model Xception



Rajah 10 Matrik kekeliruan model Xception

Rajah 10 menunjukkan matrik kekeliruan model Xception. Matriks kekeliruan ialah jadual yang digunakan untuk menentukan prestasi algoritma pengelasan. Ia digunakan untuk membandingkan kekerapan kelas yang diramalkan dengan kelas yang dijangkakan. Model tersebut dapat mengklasifikasikan semua data dengan betul dengan merujuk kepada rajah di atas.

	precision	recall	f1-score	support
algaeleafspot	1.00	1.00	1.00	20
bunchrot	1.00	1.00	1.00	47
charcoalrot	1.00	1.00	1.00	14
orangespotting	1.00	1.00	1.00	44
sootymold	1.00	1.00	1.00	22
stemwetrot	1.00	1.00	1.00	30
accuracy			1.00	177
macro avg	1.00	1.00	1.00	177
weighted avg	1.00	1.00	1.00	177

Rajah 11 Laporan klasifikasi model Xception

Rajah 11 menunjukkan laporan klasifikasi model Xception. Laporan klasifikasi dapat menunjukkan lebih terperinci tentang hasil pengelasan yang dibuat oleh model. Metrik skor F1 dan ketetapan hanya akan digunakan dalam mentafsir laporan ini selain daripada metrik *precision* dan *recall*. Hal ini kerana skor F1 adalah min harmonic *precision* dan *recall* dan metrik ini dapat menentukan prestasi klasifikasi model keseluruhan dengan keteguhan yang lebih tinggi terhadap masalah ketidakseimbangan kelas (saiz set data ujian untuk setiap

penyakit tidak sama). Oleh kerana model tersebut dapat mengklasifikasikan semua data dengan betul kepada kelas yang sepadan, ketepatan dan skor f1 model mampu mencapai 100%.

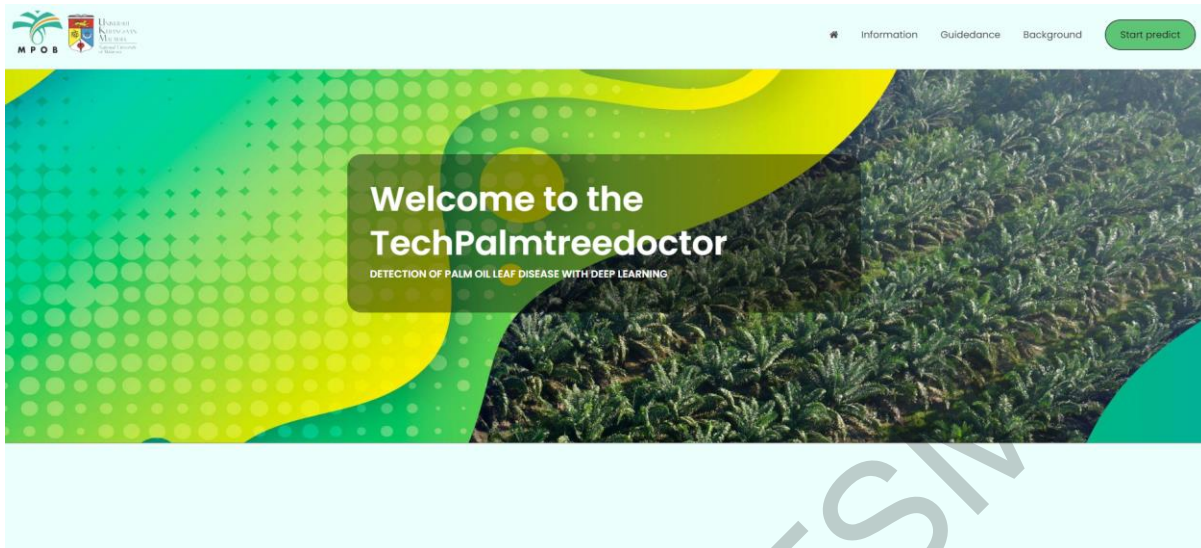
Analisis prestasi perbandingan antara ketiga-tiga model

Model	Kehilangan logaritma (<i>Logarithm loss</i>)	Ketepatan keseluruhan (<i>Overall accuracy</i>)	Jumlah parameter
InceptionResNet-V2	0.4134	99.44%	54,737,894
VGG-19	0.3668	100.00%	20,159,302
Xception	0.2838	100.00%	21,395,758

Jadual 1 Analisis prestasi perbandingan antara ketiga-tiga model

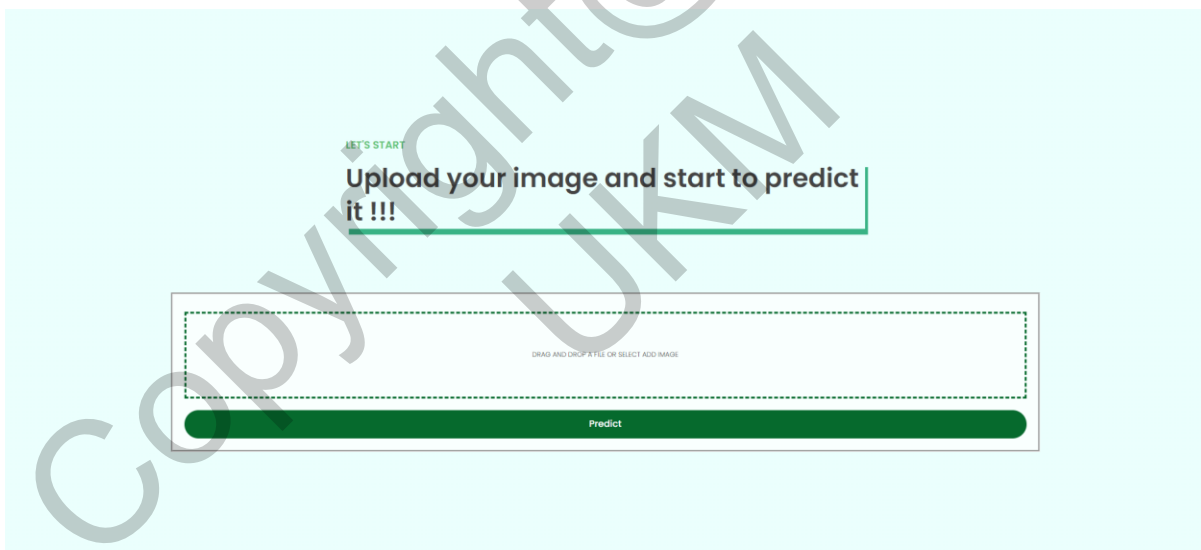
Jadual 1 menunjukkan analisis prestasi perbandingan antara ketiga-tiga model iaitu model InceptionResNet-V2, model VGG-19 dan model Xception. Ketiga-tiga model ini mencapai keputusan yang sangat baik semasa ujian manakala model Xception adalah yang terbaik antara ketiga-tiga model dengan merujuk kepada kedua-dua metrik kehilangan logaritma dan ketepatan keseluruhan. Walaupun model Xception mempunyai nilai kehilangan logaritma yang lebih rendah berbanding model VGG-19 tetapi model kedua mempunyai jumlah parameter yang lebih rendah. Tambahan pula, nilai kehilangan logaritma antara kedua-dua model ini sebenarnya adalah kecil. Parameter kecil cenderung mempunyai saiz yang kecil dalam fail dan ia mudah bagi saya untuk menggunakan aplikasi ringan dan mengehoskannya pada pelayan. Sebagai kesimpulan, saya memilih model VGG-19 sebagai model pengesanan dan kemudiannya model ini akan berintegrasi dengan aplikasi web saya.

5.2 HASIL PEMBANGUNAN APLIKASI WEB



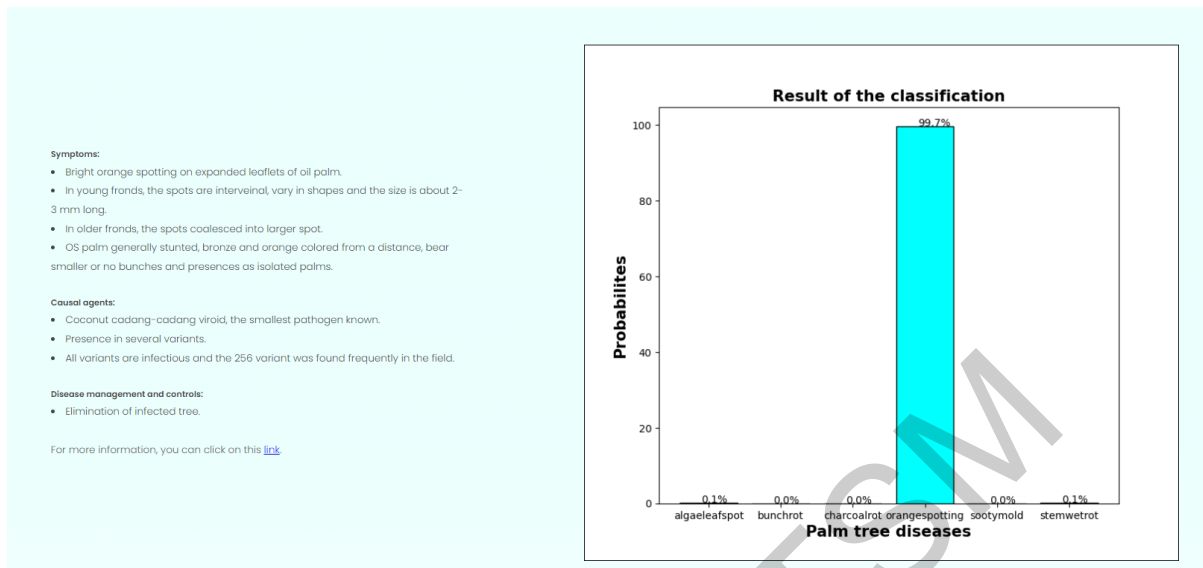
Rajah 12 Antara muka laman utama aplikasi

Rajah 12 menunjukkan antara muka laman utama aplikasi. Pengguna boleh menavigasi ke bahagian aplikasi yang berbeza melalui butang yang disenaraikan dalam bar navigasi.



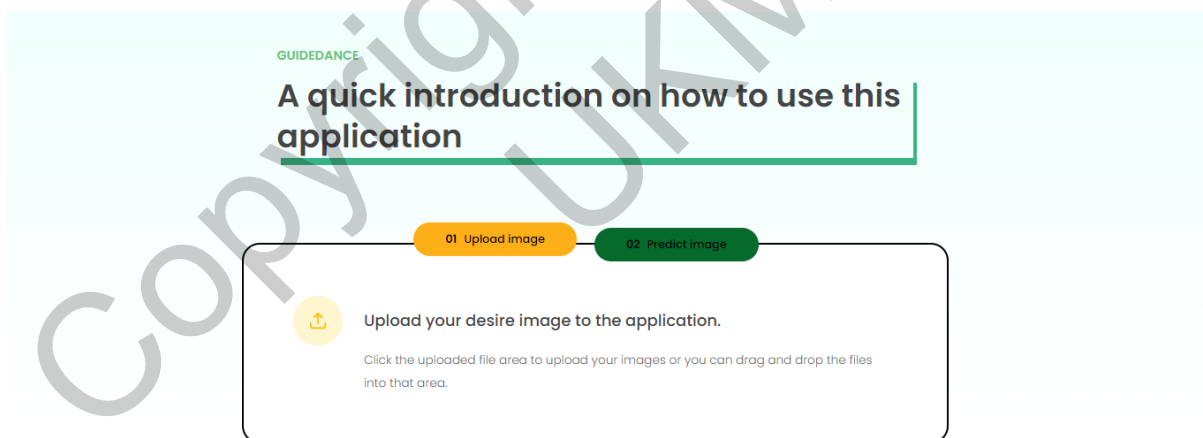
Rajah 13 Ruang untuk memuat naik imej dan memulakan proses pengesanan

Rajah 13 menunjukkan ruang untuk memuat naik imej dan memulakan proses pengesanan. Pengguna boleh memuat naik imej mereka ke aplikasi sama ada dengan seret dan lepas atau pilih imej daripada peranti mereka. Kemudian, pengguna boleh mengklik butang dan memulakan proses pengesanan.



Rajah 14 Contoh keluaran pengesanan selepas proses pengesanan telah tamat

Rajah 14 menunjukkan contoh keluaran pengesanan selepas proses pengesanan telah tamat. Hasil keluaran akan dipaparkan pada antara muka sebaik sahaja proses selesai. Keluaran pengesanan ini akan menunjukkan maklumat mengenai penyakit kelapa sawit seperti nama penyakit, kaedah rawatan penyakit serta kaedah untuk mengelakkan penyakit.



Rajah 15 Panduan untuk menggunakan aplikasi

Rajah 15 menunjukkan panduan menggunakan aplikasi. Pengguna boleh mengikut arahan yang diberikan untuk menggunakan aplikasi tersebut.

BACKGROUND

The background of this project

// The goal of this project.

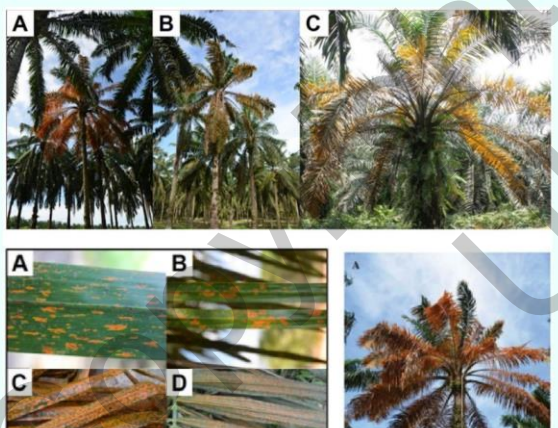
Using the deep learning technique, this project aims to classify images of palm oil tree diseases into their respective disease classes. Visual inspection, which is known to be labor-intensive and time-consuming, is the most fundamental method for detecting infected palm oil trees. Disease infections on palm oil trees typically exhibit certain symptoms. In addition, relying on labor to classify these diseases can result in human error. With the aid of deep learning, the time required to determine the disease of palm oil trees can be decreased, and the classification accuracy can be enhanced. Simultaneously, it is also possible to avoid the inevitable errors made by humans.

Rajah 16 Latar belakang kajian

Rajah 16 menunjukkan latar belakang kajian. Pengguna boleh mengetahui gambaran keseluruhan penyelidikan dalam bahagian ini.

INFORMATION

What is the symptom of the palm tree disease? How to solve it?



Orange Spotting disease

Symptoms:

- Bright orange spotting on expanded leaflets of oil palm.
- In young fronds, the spots are interveinal, vary in shapes and the size is about 2-3 mm long.
- In older fronds, the spots coalesced into larger spot.
- OS palm generally stunted, bronze and orange colored from a distance, bear smaller or no bunches and presences as isolated palms.

Caused agents:

- Coconut cadang-cadang viroid, the smallest pathogen known.
- Presence in several variants.
- All variants are infectious and the 255 variant was found frequently in the field.

Disease management and controls:

- Elimination of infected tree.

Rajah 17 Informasi tentang penyakit-penyakit pokok kelapa sawit

Rajah 17 menunjukkan informasi tentang penyakit-penyakit pokok kelapa sawit. Pengguna boleh melihat maklumat tentang penyakit lain dalam bahagian ini. Maklumat ini disertakan ama penyakit, kaedah rawatan penyakit serta kaedah untuk mengelakkan penyakit.

6 KESIMPULAN

Terdapat beberapa kekangan dalam kajian ini. Walaupun masalah set data kecil diselesaikan dengan menggunakan teknik penambahan data, masalah kualiti data yang rendah masih kekal.

Hal ini kerana kekurangan set data penyakit pokok kelapa sawit yang agak lengkap dan berkualiti tinggi, klasifikasi beberapa penyakit atau spesies yang jarang ditemui masih tidak sesuai. Oleh itu, model pengesanan ini masih tidak dapat mengenal pasti semua penyakit pokok kelapa sawit terutamanya penyakit jarang berlaku. Selain itu, model sukar mengklasifikasikan penyakit kepada kelas masing-masing dengan betul jika maklumat imej adalah kabur. Sebagai contoh, imej mengandungi banyak halangan dan oleh itu model sukar untuk mengesan objek sebenar dengan betul.

Antara cadangan yang boleh dibuat peningkatan pada masa hadapan adalah kuantiti dan kualiti semua penyakit pokok kelapa sawit perlu dijamin. Hal ini kerana kekurangan pangkalan data penyakit pokok kelapa sawit yang agak lengkap dan berkualiti tinggi, klasifikasi beberapa penyakit atau spesies yang jarang ditemui masih tidak sesuai.

7 RUJUKAN

- Ysuhaimi. 2017. Penyakit Bawaan Tanah. <https://myagri.com.my/2017/12/penyakit-bawaan-tanah/> [24 Oktober 2021]
- Masazhar, A. N. I., & Kamal, M. M. 2017, November. Digital image processing technique for palm oil leaf disease detection using multiclass SVM classifier. In *2017 IEEE 4th International Conference on Smart Instrumentation, Measurement and Application (ICSIMA)*.
- J. Ma, K. Du, F. Zheng, L. Zhang, Z. Gong, and Z. Sun. 2018. A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network. *Computers and Electronics in Agriculture*, 154, 18-24.
- Y. Kawasaki, H. Uga, S. Kagiwada, and H. Iyatomi. 2015. Basic study of automated diagnosis of viral plant diseases using convolutional neural network. *Lecture Notes in Computer Science*, 638-645.
- Liu, J., & Wang, X. 2021. Plant diseases and pest detection based on deep learning: a review. *Plant Methods*, 17(1), 1-18.
- Asrianda, A., Aidilof, H. A. K., & Pangestu, Y. 2021. Machine Learning for Detection of Palm Oil Leaf Disease Visually using Convolutional Neural Network Algorithm. *Journal of Informatics and Telecommunication Engineering*, 4(2), 286-293.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. 2016. Using deep learning for image-based plant disease detection. *Frontiers in plant science*, 7, 1419.

Mahamood, A. F., Mohammed, R., & Ahmad, M. K. 2016. Peranan agen pengembangan dalam mempengaruhi petani menggunakan teknologi komunikasi di Lembaga Kemajuan Pertanian Muda (MADA). *Journal of Global Business and Social Entrepreneurship (GBSE)*, 2(5), 78-82.

Copyright@FTSM
UKM