

MENGKLASIFIKASI IMEJ ANAK BENIH TUMBUHAN

MENGGUNAKAN PEMBELAJARAN DALAMAN

NURUL NAJWA BINTI MAHIZIR
TS. DR. ABDUL HADI ABD RAHMAN

Fakulti Teknologi & Sains Maklumat, Universiti Kebangsaan Malaysia

ABSTRAK

Dalam kajian ini telah mencadangkan aplikasi teknik pembelajaran mendalam untuk mengklasifikasi 12 spesies berbeza di mana tiga adalah spesies anak benih tumbuhan dan sembilan lagi adalah spesies rumput dengan menggunakan set data awam sebanyak 4750 imej tumbuhan daripada kerjasama kumpulan Universiti Aarhus dengan Universiti Selatan Denmark. Tiga seni bina Rangkaian Neural Konvolusi (CNN) baharu direka iaitu Seni Bina 1, Seni Bina 2 dan Seni Bina 3, untuk mengelaskan 12 spesies anak pokok tumbuhan pada peringkat awal pertumbuhan. Teknik yang dibentangkan dinilai menggunakan set data ‘Plant Seedlings’. Sistem ini diperhalusi untuk seni bina mempunyai masa latihan lebih cepat dan penggunaan memori yang rendah. Seni bina telah dinilai menggunakan hiperparameter rangkaian yang berbeza, seperti bilangan lapisan konvolusi, bilangan lapisan padat (dense layer) dan bilangan parameter untuk dilatih. Purata ketepatan, ketepatan, ingatan semula dan skor F1 pula digunakan sebagai metrik penilaian untuk menilai prestasi sistem. Keputusan kajian yang dijalankan telah membuktikan Seni Bina 3 telah mencapai prestasi yang baik berbanding Seni Bina 1 dan Seni Bina 2 dengan mencapai ketepatan keseluruhan sebanyak 95.09% dan skor purata F1 sebanyak 0.94 dengan nilai parameter yang terendah iaitu 542412.

1 PENGENALAN

Anak benih tumbuhan merupakan sporofit tumbuhan muda yang berkembang daripada biji benih kepada embrio. Perkembangan anak benih bermula dengan percambahan benih. Anak benih muda biasanya terdiri daripada tiga bahagian utama iaitu radikel (akar embrio), hipokotil (pucuk embrio) dan juga kotiledon (daun benih). Kedua-dua kelas tumbuhan berbunga (angiosperma) dibezakan dengan bilangan daun benih, monokotil yang mempunyai satu kotiledon berbentuk bilah, manakala dikotiledon mempunyai dua kotiledon bulat. Sebagai contoh, anak pokok pain mempunyai sehingga lapan kotiledon. Anak benih beberapa tumbuhan berbunga tidak mempunyai kotiledon sama sekali. Ini dikatakan sebagai acotyledon. Plumule adalah bahagian embrio benih yang berkembang menjadi pucuk yang mengandungi daun pertama tumbuhan. Dalam kebanyakan biji, contohnya bunga matahari, plumula adalah struktur kon kecil tanpa sebarang struktur daun. Pertumbuhan plumula tidak berlaku sehingga kotiledon telah tumbuh di atas tanah. Ini adalah percambahan epigeal. Walau bagaimanapun, dalam benih seperti kacang lebar, struktur daun kelihatan pada plumule dalam benih. Benih ini berkembang oleh plumula yang

tumbuh melalui tanah dengan kotiledon yang tinggal di bawah permukaan. Ini dikenali sebagai percambahan hipogeal. Tumbuhan yang tumbuh secara terus membantu sebagai sumber khasiat dan oksigen untuk semua jenis kehidupan di bumi. Pertanian menjadi keutamaan di mana automasi proses pertanian yang betul akan membantu dalam mengoptimumkan penuaan tanaman dan melindungi produktiviti dan kemampuan yang berterusan. Pengubahsuaian wilayah pertanian dengan menggunakan kaedah pertanian pintar boleh mempengaruhi pertumbuhan ekonomi di banyak negara. Terdapat hubungan yang kuat antara peningkatan produktiviti dan kemewahan ekonomi.

Pertumbuhan pesat populasi global telah memberi tekanan besar pada sektor pertanian untuk meningkatkan kualiti dan kuantiti pengeluaran makanan. Pada tahun 2050 berkemungkinan populasi global akan mencapai sembilan bilion dan hal ini boleh menyebabkan sektor pertanian terpaksa mengeluarkan hasil pertanian berlipat ganda daripada yang sedia ada sekarang bagi memenuhi permintaan yang semakin meningkat (Singh et al. 2016). Walaubagaimanapun, para petani akan menghadapi cabaran yang besar di mana ancaman penyakit tanaman, perosak dan juga serangan rumpai yang semakin meningkat (Dadashzadeh et al. 2020). Segala racun perosak, kutu dan penyakit tanaman boleh mengurangkan hasil dan kualiti penghasilan tanaman, serat dan juga nilai nutrisi yang ada pada tanaman. Kerugian yang disebabkan oleh musibah yang berlaku telah menyumbang sebanyak 3% dan 1.3% pada kadar purata harian dalam pengeluaran sayur-sayuran dan buah-buahan (Negin Vaghefi 2020).

Seperti perosak-perosak yang lain, rumpai merupakan tanaman yang tidak diingini yang akan bersaing dengan tanaman yang lain secara produktif untuk mendapatkan ruang, cahaya, nutrisi tanah dan air. Rumpai juga akan membiak secara rimpang, pelari atau biji. Secara umumnya, rumpai merupakan tanaman perosak yang boleh menghalang pengurusan tanaman sekaligus boleh menyebakan pertumbuhan tanaman terbantut dan hasilnya juga akan berkurangan. Disebabkan kurangnya teknologi atau sokongan teknikal yang sesuai untuk menyelesaikan masalah ini, para petani terpaksa mengeluarkan perbelanjaan yang amat tinggi hanya untuk pengurusan rumpai yang telah mengakibatkan penurunan dalam hasil tanaman. Oleh sebab itu, kawalan rumpai merupakan aspek yang amat penting dalam pengurusan tanaman

kerana kegagalan untuk mengawal rumpai dengan baik boleh menyebabkan penurunan hasil tanaman dan kualiti produk (Myers et al. 2017).

Dalam masa yang sama, amalan pertanian organik (OA) juga telah menimbulkan persoalan mengenai kesihatan, persekitaran dan juga isu-isu kelestarian di mana ia menentang dalam penggunaan bahan kimia dan bahan yang diubahsuai secara genetik (GM) di ladang Nandwani & Nwosisi, (2016). OA telah menolak penggunaan racun rumpai dan baja sintetik malah ia mendorong untuk melakukan penggiliran tanaman, mengawal pertumbuhan rumpai secara mekanik dan mengawal rumpai atau hama biologi bagi menjaga kesihatan tanah, menyediakan nutrisi yang cukup pada tanaman, meminimumkan serangga dan juga rumpai. Sebahagian besar pengurus dalam sektor pertanian terutamanya petani organik akan meletakkan pengurusan rumpai sebagai salah satu kos pengeluaran utama mereka. Maka, pengurusan rumpai secara efektif berubah menjadi salah satu perkara yang penting dalam produk organik seperti SRI kerana berlakunya peningkatan pasaran beberapa tahun kebelakangan ini (Fumitaka et al., 2015). Selain itu, sesetengah petani mengawal rumpai dengan menggunakan bahan kimia atau lebih dikenali sebagai racun. Walaubagaimanapun, penggunaan bahan kimia yang tidak diurusukan dengan baik dan teliti boleh mengakibatkan kesan buruk terhadap persekitaran. Bagi menangani masalah ini, penggunaan alat kos rendah untuk mengenalpasti dan memetakan rumpai pada peringkat pertumbuhan awal boleh menyumbang kepada pengurusan rumpai yang lebih berkesan dan efektif. Pengawalan rumpai pada peringkat awal juga amat berkesan di mana kehilangan hasil tanaman sebanyak 34% dapat dikurangkan dan juga dapat mengurangai penyakit dan perosak yang ada pada tanaman (Aharon et al. 2020). Seperti yang dijumpai dalam beberapa kajian, rumpai mempunyai daya saing yang tinggi untuk mendapatkan air dan nutrisi dan ini telah menyebabkan kekurangan kualiti dan kuantiti penghasilan tanaman (Alam et al. 2020). Oleh hal yang demikian, pengawalan rumpai pada peringkat awal amat diperlukan.

Malah, penggunaan teknologi juga amat diperlukan lebih-lebih lagi dalam sektor pertanian bagi meningkatkan penghasilan tanaman yang berkualiti. Erti kata lain, ia juga mampu membantu setiap petani dalam penggunaan teknik pertanian yang efektif dan membantu dalam membuat keputusan mengenai tanaman. Walaubagaimanapun, terdapat beberapa faktor yang tidak boleh dikawal oleh manusia

terutamanya perubahan iklim, angin, kelembapan tanah, serangan serangga perosak dan pertumbuhan rumpai liar. Oleh hal yang demikian, setiap petani digalakkan untuk menggunakan teknologi yang wujud pada era ini dalam pertanian bagi mengatasi masalah-masalah yang timbul. Dengan penggunaan teknologi sekarang, para petani dapat mengenalpasti kawasan tanaman yang bermasalah dengan cepat. Sebagai contoh, mengesan sekiranya ada tumbuhan lain yang tumbuh seperti pertumbuhan rumpai. Pada era yang serba canggih dengan penggunaan teknologi bukan sahaja dapat meningkatkan penghasilan tanaman malah dapat menjimatkan masa.

2 PENYATAAN MASALAH

Memandangkan kos buruh telah meningkat dan orang ramai menjadi lebih prihatin terhadap kesihatan dan isu alam sekitar, automasi kawalan rumpai telah menjadi keutamaan (B. Liu & Bruch, 2020). Oleh demikian, sistem kawalan rumpai secara automatik boleh memberi manfaat dari segi ekonomi dan alam sekitar. Malah, sistem sedemikian juga boleh mengurangkan kos buruh dengan menggunakan mesin untuk membuang rumpai dan teknik semburan terpilih boleh meminimumkan penggunaan racun herba (Lameski et al., 2018). Bagi membangunkan sistem pengurusan rumpai secara automatik, langkah pertama yang penting adalah dengan mengesan dan mengenali rumpai dengan betul (B.Liu & Bruch, 2020). Pengesanan rumpai dalam tanaman agak mencabar kerana kebiasaannya rumpai dan tanaman mempunyai warna, tekstur dan bentuk yang serupa. Antara cabaran yang kerap dijumpai adalah halangan antara tumbuhan dan rumpai, persamaan dalam warna dan tekstur (Bakhshipour & Jafari, 2018), bayangan tumbuhan dan rumpai(PyTorch, 2020), kesan daripada pencahayaan (Cicco et al., 2017) dan spesies tumbuhan rumpai yang mempunyai pelbagai sifat yang sama(Olsen et al., 2019). Kesan daripada imej yang kabur juga boleh menyukarkan dalam mengklasifikasi tumbuhan(Ahmad et al., 2018; Giselsson et al., 2017). Selain itu, lokasi geografi, cuaca, keadaan tanah dan spesies rumpai yang berbeza juga merupakan antara faktor yang menjadi cabaran kepada pengesanan dan pengelasan tumbuhan.(Lameski et al., 2017).

Sistem pengesanan rumpai kebiasaannya mempunyai empat langkah utama iaitu pemerolehan imej, pra pemprosesan imej, pengekstrakan ciri, pengesanan dan pengelasan rumpai (Shanmugam et al., 2020). Pada era ini, teknologi baru yang wujud

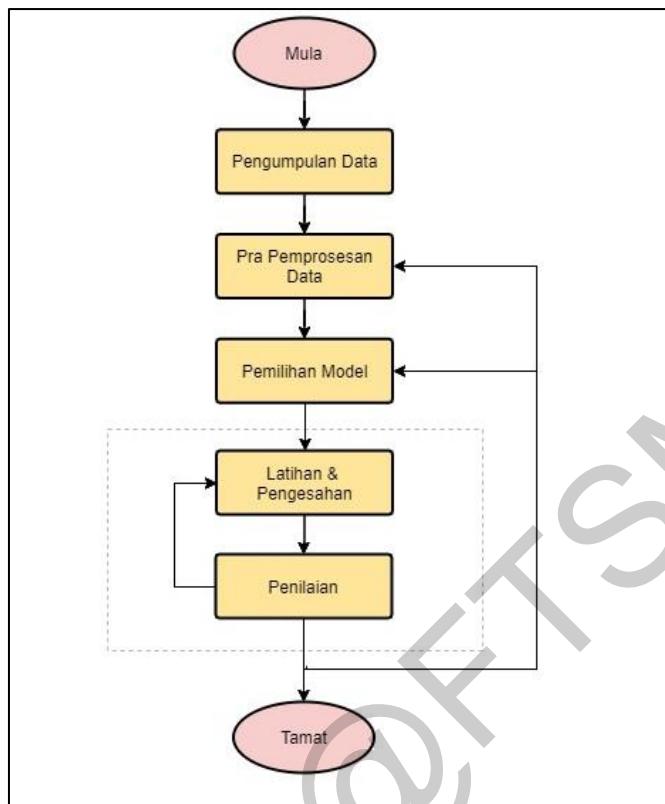
telah digunakan bagi mencapai langkah-langkah tersebut. Bahagian utama dalam langkah ini ialah pengesanan dan pengelasan rumpai. Pembelajaran mendalam (DL) ialah cabang penting bagi pembelajaran mesin. Bagi klasifikasi imej, pengesanan objek dan pengecaman, algoritma pembelajaran mendalam mempunyai banyak kelebihan berbanding pendekatan pembelajaran mesin tradisional. Mengestrak dan memilih ciri yang mendiskriminasi dengan kaedah pembelajaran mesin tradisional adalah sukar kerana tanaman dan rumpai berkemungkinan mempunyai ciri yang sama. Walau bagaimanapun, masalah ini boleh diatasi dengan menggunakan pendekatan pembelajaran mendalam berdasarkan keupayaan pembelajaran ciri yang kukuh.

3 OBJEKTIF KAJIAN

Projek ini bertujuan untuk mengenalpasti ciri-ciri yang membezakan antara tumbuhan rumpai dengan anak benih tumbuhan dan untuk membangunkan kaedah yang sesuai untuk digunakan bagi mengklasifikasi tumbuhan rumpai dengan anak benih tumbuhan.

4 METOD KAJIAN

Bahagian akan menerangkan kaedah yang digunakan daripada proses pra pemprosesan kepada pengelasan imej tumbuhan menggunakan pembelajaran mendalam. Penerangan tentang langkah pra pemprosesan yang penting dan klasifikasi model akan dibincangkan dalam bahagian ini. Kaedah dalam kajian ini terdapat empat fasa dalam mengklasifikasi tumbuhan rumpai dengan anak benih tumbuhan yang bermula dengan fasa pengumpulan data, fasa pra pemprosesan, proses pembangunan model pengelasan dan diakhiri dengan menguji hasil kajian menggunakan kaedah pembelajaran mendalam seperti dalam Rajah 1.



Rajah 1 Carta Aliran Kajian

4.1 Fasa Pengumpulan Data

Pemerolehan data adalah langkah pertama dalam pembangunan sistem untuk mendapatkan sampel atau imej. Proses pengumpulan data bergantung pada jenis projek yang ingin dilakukan. Sebagai contoh, menggunakan beberapa set data yang boleh didapati di internet. Kaggle dan UCI Machine Learning adalah antara medium yang paling banyak dikunjungi untuk mempraktikkan algoritma pembelajaran mendalam. Walau bagaimanapun, sesetengah data yang dikumpul berkemungkinan tidak dapat digunakan secara langsung untuk melakukan proses analisis kerana mungkin terdapat banyak data yang hilang, nilai yang terlalu besar, teks data yang tidak tersusun dan juga data yang bising. Oleh itu, bagi menyelesaikan masalah ini, penyediaan data dilakukan.

Dalam kajian ini, set data yang disediakan secara terbuka oleh Universiti Aarhus (Giselsson, Jørgensen, Jensen, Dyrmann, & Midtiby, 2017) telah digunakan. Set data yang digunakan dikumpul oleh kumpulan Universiti Aarhus dengan kerjasama Universiti Denmark Selatan. Set data tersedia untuk dimuat turun dalam versi yang berbeza iaitu, imej mentah, imej dipotong dan imej bersegmen. Set data ini mengandungi 4750 imej kira-kira 960 tumbuhan unik yang dimiliki oleh 12 spesies tumbuhan.

4.2 Fasa Pra Pemprosesan

Fasa pra pemprosesan data merupakan salah satu langkah yang terpenting dalam pembelajaran mendalam. Hal ini kerana ia dapat membantu dalam membina model dengan lebih tepat. Pra pemprosesan adalah satu proses di mana ia akan membersihkan data mentah iaitu data yang dikumpulkan secara nyata dan ditukarkan menjadi satu set data yang bersih. Erti kata lain, setiap kali data yang dikumpulkan daripada sumber yang berlainan dan dikumpul dalam bentuk format mentah, maka data tersebut tidak boleh dilakukan untuk analisis. Oleh hal yang demikian, proses pra pemprosesan data patut dilakukan bagi mengubah data tersebut ke set data yang bersih supaya data dapat digunakan untuk melatih model.

Beberapa langkah pra pemprosesan dalam kajian ini telah dilakukan di mana pada awalnya, saiz imej diubah mengikut kesusaian. Selepas imej di saiz semula, ia akan menjalani proses seterusnya. Set data ini tidak seimbang dan bising. Maka proses pra pemprosesan telah dijalankan pada anak benih tumbuhan itu sendiri tanpa ada sebarang barang yang membuatkan imej itu bising seperti kod bar, tanah latar belakang dan kerikil. Jadi, pada bahagian ini telah dilakukan pengalihan keluar latar belakang dan menangani data ketidakseimbangan. Imej-imej pada set data ditukar kepada imej yang kabur, imej HSV, imej yang telah di topengkan (*masking*) dan akhir sekali imej tanpa latar belakang.

4.3 Fasa Pemodelan

Dalam kajian ini, model Rangkaian Neural Konvolusi (CNN) telah digunakan untuk mengklasifikasi tumbuhan rumpai dengan anak benih tumbuhan. CNN adalah serupa dengan rangkaian saraf biasa di mana ia terdiri daripada neuron dan mempunyai berat dan bias yang boleh dipelajari. Perbezaan utama ialah CNN mengambil kesempatan daripada imej dan menerima imej sebagai imej dengan lebar, ketinggian dan kedalaman manakala jaring saraf biasa meratakan input. Jadi, adalah tidak baik dalam mengenal pasti beberapa ciri imej sedangkan CNN dengan mudah boleh mengenal pasti beberapa ciri imej. Blok bangunan utama seni bina CNN dijelaskan dalam bahagian seterusnya. Pengelas yang dibina ialah CNN yang merupakan algoritma terkini untuk masalah pengelasan imej. Ia memerlukan sejumlah besar data. Oleh yang demikian, set data yang digunakan mempunyai data yang mencukupi untuk melatih model yang akan digunakan. Algoritma ini mengambil imej sebagai input, melalui urutan lapisan dan mengembalikan kebarangkalian untuk setiap kelas. Terdapat banyak hiperparameter yang boleh ditala untuk melaraskan prestasi algoritma. Sebahagian daripadanya ialah:

- Bilangan *epoch*
- Saiz kelompok

- Kadar Pembelajaran
- Penyelesai (Algoritma digunakan untuk pembelajaran)
- Bilangan lapisan dalam seni bina
- Fungsi pengaktifan

Di sini dapat dilihat di mana, bilangan *epoch* merupakan hiperparameter keturunan kecerunan yang mengawal bilangan hantaran lengkap melalui set data latihan. Manakala, saiz kelompok ialah hiperparameter keturunan kecerunan yang mengawal bilangan sampel latihan untuk diuruskan sebelum parameter dalaman model dikemas kini. Dalam kajian ini, model CNN telah digunakan untuk mengklasifikasi tumbuhan rumpai dengan anak benih tumbuhan. Pengelas imej asas menggunakan CNN pada mulanya akan dibina dan kemudian kajian akan diteruskan dengan membina 3 jenis seni bina CNN yang berlainan. Selepas kajian dilakukan, pemilihan seni bina terbaik akan dipilih dan menggunakan untuk membina algoritma yang mengklasifikasikan spesies tumbuhan yang diberi imej sebagai input.

4.4 Fasa Latihan dan Pengesahan

Langkah yang seterusnya adalah melatih dan menguji model pada data. Dalam set data ini mempunyai lebih 65536 fitur untuk setiap imej dan hanya 3336 imej dalam set data latihan. Bagi Seni Bina 1 terdapat 14830412 parameter, Seni Bina 2 sebanyak 1345868 parameter dan Seni Bina 3 sebanyak 542412 parameter dilatih dan mengekstrak 1280 fitur dengan setiap saiz kernel adalah 3x3. Pengelas rangkaian saraf konvolusi mengandungi lapisan pengumpulan, lapisan bersambung sepenuhnya dan lapisan output. Dalam lapisan pengumpulan, pengumpulan purata global digunakan pada semua peta ciri untuk mendapatkan purata nilai tunggal bagi setiap peta ciri. Lapisan ini membantu dalam mengelakkan overfitting. Lapisan yang disambungkan sepenuhnya mengandungi 512 nod dengan pengaktifan ReLU. Ia membantu untuk mempelajari ciri yang lebih khusus daripada data input untuk meningkatkan prestasi model. Akhir sekali, lapisan keluaran mengandungi 12 nod keluaran dengan pengaktifan softmax. Ia menghasilkan label dengan kebarangkalian tertinggi sebagai output.

Setiap seni bina dilatih untuk 200 epoch dengan kadar pembelajaran 0.001. Imej dikumpulkan dengan saiz kelompok 32. Fungsi kehilangan entropi silang kategori digunakan untuk mengira kerugian dan pengoptimum Adam digunakan untuk mengoptimumkan kerugian dengan mengemas kini pemberat semasa perambatan belakang sambil melatih model .

4.4 Fasa Penilaian

Fasa penilaian adalah sebahagian daripada proses pengembangan model. Ia adalah untuk

membantu mencari model yang terbaik dan sebaik mana model yang dipilih akan berfungsi pada masa hadapan. Kebiasaannya ketepatan klasifikasi sering digunakan untuk mengukur prestasi model tetapi ia tidak cukup untuk menilai model kita dengan betul. Oleh itu terdapat beberapa jenis matrik penilaian yang digunakan untuk menilai tahap prestasi seni bina dalam mengklasifikasi rumput dan anak benih tumbuhan. Antaranya ialah matriks kekeliruan, ketepatan klasifikasi, kejituhan, dapatan semula dan skor F1.

5 HASIL KAJIAN

Setelah latihan dijalankan, di antara semua seni bina, dapat dilihat bahawa Seni Bina 3 mempunyai prestasi terbaik dan mencapai 0.95097 untuk ketepatan ujian. Seni Bina 1 pula mempunyai ketepatan yang kurang baik daripada Seni Bina 2 dan Seni Bina 3 iaitu sebanyak 0.8679 manakala Seni Bina 2 mempunyai ketepatan sebanyak 0.9082. Walaubagaimanpun, Seni Bina CNN yang tersuai masih memberikan prestasi terbaik antara penanda aras. Ini mungkin menunjukkan bahawa tugas pengelasan anak benih tumbuhan pada asasnya agak berbeza daripada tugas pengelasan imej umum dalam memerlukan lebih terperinci dan halus dalam pembentukan daripada imej input.

Pemberat yang disimpan semasa set latihan digunakan pada set ujian dan kemudian meramalkan keuntungan kelas dan kelas dengan kebarangkalian yang lebih tinggi telah diambil sebagai label yang diramalkan dan digunakan untuk mengira skor ketepatan. Seni bina yang diguna telah berjaya meramalkan kebanyakan kelas set ujian dengan skor ketepatan lebih daripada 85% yang jauh lebih baik daripada penanda aras yang hanya memberikan ketepatan sebanyak 57.80%. Oleh itu, boleh menganggap bahawa 3 seni bina yang telah disuai telah mengklasifikasikan anak pokok tumbuhan dengan baik.

Jadual 1 Perbandingan Ketepatan Latihan & Ketepatan Ujian

Seni Bina	Ketepatan Latihan (%)	Ketepatan Ujian (%)
Seni Bina 1	86.79	84.43
Seni Bina 2	90.82	88.21
Seni Bina 3	95.09	93.12

Matriks kekeliruan bagi Seni Bina 1 pada Rajah 2 menunjukkan bahawa 16

daripada imej kepunyaan kelas Black grass dikelaskan sebagai Loose Silky Bent dan 31 daripada imej milik Loose Silky-Bent telah diklasifikasikan sebagai Black-grass.

Confusion matrix												
Actual label	Black-grass	Charlock	Cleavers	Common Chickweed	Common wheat	Fat Hen	Loose Silky-bent	Maize	Scentless Mayweed	Shepherds Purse	Small-flowered Cranesbill	Sugar beet
	16	0	0	0	6	0	16	0	0	0	0	1
	0	54	0	0	0	3	0	1	0	0	0	0
	0	4	36	0	0	1	0	0	0	1	1	0
	0	0	0	87	0	0	0	2	3	0	0	0
	3	0	0	0	27	1	0	0	0	0	0	2
	0	0	0	0	0	70	1	1	0	0	0	0
	31	0	0	0	5	0	62	0	0	0	0	0
	0	0	0	0	0	0	0	33	0	0	0	0
	1	0	0	3	1	1	0	0	70	0	0	2
	0	2	0	1	0	0	0	1	4	26	0	0
	0	0	1	0	1	0	0	2	1	0	70	0
	0	1	0	0	0	0	0	6	0	0	0	51

Rajah 2 Matriks Kekeliruan bagi Seni Bina 1

Rajah 3 pula menunjukkan matriks kekeliruan bagi Seni Bina 2 di mana 4 daripada imej kepunyaan kelas Black grass dikelaskan sebagai Loose Silky Bent dan 42 daripada imej milik Loose Silky-Bent telah diklasifikasikan sebagai Black-grass.

Confusion matrix												
Actual label	Black-grass	Charlock	Cleavers	Common Chickweed	Common wheat	Fat Hen	Loose Silky-bent	Maize	Scentless Mayweed	Shepherds Purse	Small-flowered Cranesbill	Sugar beet
	32	0	0	0	3	0	4	0	0	0	0	0
	0	57	0	0	0	1	0	0	0	0	0	0
	0	2	37	0	0	0	0	2	1	0	0	1
	0	0	0	90	0	0	0	0	1	1	0	0
	4	0	0	0	28	1	0	0	0	0	0	0
	1	0	0	0	1	69	0	0	1	0	0	0
	42	0	0	0	3	0	53	0	0	0	0	0
	0	0	0	0	0	0	0	33	0	0	0	0
	0	1	2	0	0	0	0	0	72	3	0	0
	0	0	0	0	0	0	0	0	1	33	0	0
	0	0	1	0	1	1	0	0	0	0	72	0
	0	0	0	0	2	1	0	2	0	0	0	53

Rajah 3 Matriks Kekeliruan bagi Seni Bina 2

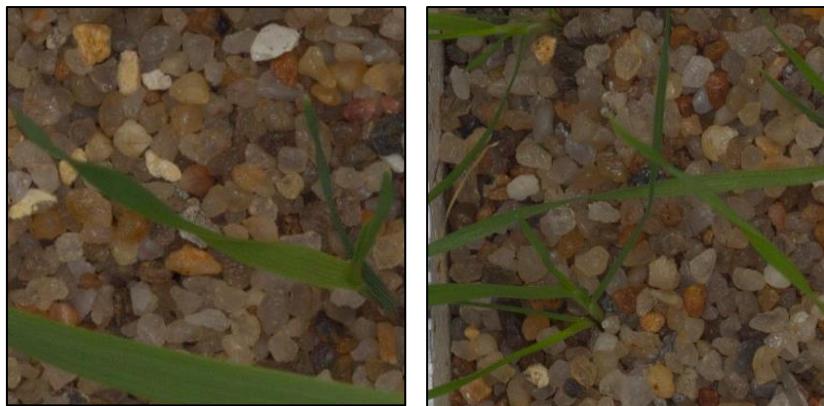
Kemudian, Rajah 4 menunjukkan matriks kekeliruan bagi Seni Bina 3 di mana 6 daripada imej kepunyaan kelas Black grass dikelaskan sebagai Loose Silky Bent dan 14 daripada imej milik Loose Silky-Bent telah diklasifikasikan sebagai Black-grass.

Confusion matrix											
Actual label	Black-grass	Charlock	Cleavers	Common Chickweed	Common wheat	Fat Hen	Loose Silky-bent	Maze	Scentless Mayweed	Shepherds Purse	Small-flowered Cranesbill
	29	0	0	0	4	0	6	0	0	0	0
	0	56	1	0	0	1	0	0	0	0	0
	0	2	38	0	1	0	0	0	1	1	0
	0	0	0	91	0	0	0	0	1	0	0
	2	0	0	0	29	0	2	0	0	0	0
	1	0	0	0	1	70	0	0	0	0	0
	14	0	0	0	2	0	82	0	0	0	0
	0	0	0	0	0	0	0	33	0	0	0
	0	0	0	3	0	0	0	0	73	2	0
	0	1	0	0	0	0	0	0	0	32	1
	0	0	0	1	1	0	0	0	0	0	73
	0	0	0	0	0	0	0	0	0	0	58

Rajah 4 Matriks Kekeliruan bagi Seni Bina 3

Di sini dapat dirumuskan bahawa ketiga-tiga seni bina salah mengklasifikasi kedua-dua jenis kelas tumbuhan ini. Walaubagaimanapun, Seni Bina 3 menunjukkan hasil klasifikasi yang terbaik berbanding Seni Bina 1 dan Seni Bina 2.

Salah satu sebab misklasifikasi yang tinggi berlaku adalah kerana kedua-dua kelas ini sangat serupa antara satu sama lain dalam rupa bentuk mereka. Rajah 5 menunjukkan satu contoh setiap imej daripada setiap kelas ini. Dalam rajah tersebut boleh dilihat bahawa imej dalam kedua-dua kelas ini sangat serupa antara satu sama lain. Ini menjadikan pemilihan ciri untuk mengklasifikasikan kelas ini dengan betul ke dalam kelas masing-masing adalah sukar.



Black-grass **Loose Silky-Bent**
Rajah 5 Perbezaan antara Black-grass & Loose Silky-Bent

6 KESIMPULAN

Kesimpulannya, fitur warna dan bentuk digunakan untuk mengelaskan rumpai dan anak pokok. Imej asal terdapat banyak bunyi disebabkan oleh imej diambil dalam persekitaran sebenar. Pengaburan imeh telah dilakukan bagi membuang bunyi dan kemudian imej ditukar daripada imej RGB ke HSV. Setelah itu, imej diciptakan topeng bagi mengeluarkan latar belakang imej supaya memudahkan untuk imej rumpai dan anak benih tumbuhan diklasifikasi semasa latihan dan ujian dilakukan. Kontur kemudian diekstrak. Ciri diekstrak menggunakan ciri garis kontur. Menggunakan ciri ini, kadar pengecaman adalah mencapai sehingga 90% apabila diklasifikasikan melalui pembelajaran mendalam. Oleh kerana bentuk garisan daun adalah serupa antara satu sama lain, cirinya sahaja menjadikannya sukar untuk mengklasifikasikan tumbuhan.

Seni bina CNN dibangunkan untuk mendiskriminasi antara imej tumbuhan spesies tanaman dan spesies rumpai pada beberapa peringkat pertumbuhan awal. CNN yang dicadangkan telah mencapai peningkatan dalam prestasi kerana gabungan kehadiran lapisan normalisasi, lapisan pengumpulan purata global dan pilihan kedalaman penapis. Hasilnya mendedahkan bahawa CNN yang dihuraikan mempunyai prestasi yang memberangsangkan ke arah membina sistem kawalan rumpai yang merupakan langkah kepada pertanian jitu. Dalam kajian ini, model rangkaian saraf konvolusi telah dibangunkan untuk klasifikasi spesies anak benih tumbuhan. Set data yang digunakan hanya diberi set data latihan, jadi saya telah membahagikan data kepada set data latihan dan ujian menggunakan sklearn train_test_split. Kemudian menukar imej masing-masing kepada tatasusunan numpy. Seterusnya, data juga diubah dan mengaplikasikan normalisasi. Model CNN menunjukkan prestasi yang lebih baik dalam klasifikasi, oleh itu keputusan yang diperoleh adalah seperti

yang diharapkan. Walaupun mencapai hasil yang diingini dengan hanya penalaan parameter, penambahan lapisan conv, lapisan padat (dense layer) dan menggunakan penormalan kelompok meningkatkan hasil keputusan.

Tiga jenis seni bina CNN yang dicadangkan telah digunakan untuk klasifikasi imej pada set data untuk mengklasifikasikan imej anak benih tumbuhan dan rumput ke dalam kelas masing-masing dan telah mencapai keputusan yang lebih baik daripada penandaarasan. Di antara ketiga-ketiga seni bina ini, Seni Bina 3 memberikan hasil terbaik dengan ketepatan ujian sebanyak 95.09% manakala Seni Bina 1 mencapai ketepatan sebanyak 86.79% dan Seni Bina 2 mencapai ketepatan sebanyak 90.82%.

7 RUJUKAN

- Abouzahir, S.; Sadik, M.; Sabir, E. Enhanced Approach for Weeds Species Detection Using Machine Vision. In Proceedings of the 2018 International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS), Kenitra, Morocco, 5–6 December 2018; pp. 1–6.
- Singh, A.; Ganapathysubramanian, B.; Singh, A.K.; Sarkar, S. Machine Learning for High-Throughput Stress Phenotyping in Plants. *Trends Plant Sci.* 2016, 21, 110–124.
- Dadashzadeh, M.; Abbaspour-Gilandeh, Y.; Mesri-Gundoshmian, T.; Sabzi, S.; Hernández-Hernández, J.L.; HernándezHernández, M.; Arribas, J.I. Weed Classification for Site-Specific Weed Management Using an Automated Stereo Computer-Vision Machine-Learning System in Rice Fields. *Plants* 2020, 9, 559.
- Negin Vaghefi. (2020). The Heavy Impact of Covid-19 on the Agriculture Sector and the Food Supply Chain. Socioeconomics and Statistics Programme, Penang Institute.
- Myers, S.S.; Smith, M.R.; Guth, S.; Golden, C.D.; Vaitla, B.; Mueller, N.D.; Dangour, A.D.; Huybers, P. Climate change and global food systems: potential impacts on food security and undernutrition. *Annu. Rev. Public Health* 2017, 38, 259–277.
- Nandwani, D and Nwosisi. (2016). Organic Farming for Sustainable Agriculture. Switzerland: Springer International Publishing.
- Fumitaka, Shiootsu.; Nobuo Sakagami.; Naomi Asagi.; Dewa Ngurah Suprapta.; Nurwulan Agustiani.; Youji Nitta.; and Masakazu Komatsuzaki (2015). Initiation and Dissemination of Organic Rice Cultivation in Bali, Indonesia *Sustainability* 7, 5171–5181. doi: 10.3390
- Aharon, S.; Peleg, Z.; Argaman, E.; Ben-David, R.; Lati, R.N. Image Based High-Throughput Phenotyping of Cereals Early Vigor and Weed-Competitiveness Traits. *Remote Sens.* 2020, 12, 3877.
- Alam, M.; Alam, M.S.; Roman, M.; Tufail, M.; Khan, M.U.; Khan, M.T. Real-Time Machine-Learning Based Crop/Weed Detection and Classification for Variable-Rate Spraying in Precision Agriculture. In Proceedings of the 2020 7th International

Conference on Electrical and Electronics Engineering (ICEEE), Antalya, Turke, 14–16 April 2020; pp. 273–280.

- Liu, B., & Bruch, R. (2020). Weed detection for selective spraying: A review. *Current Robotics Reports*, 1 (1), 19–26. Lameski, P., Zdravevski, E., Trajkovik, V., & Kulakov, A. (2017). Weed detection dataset with rgb images taken under variable light conditions. International Conference on ICT Innovations, 112–119.
- Bakhshipour, A., Jafari, A., Nassiri, S. M., & Zare, D. (2017). Weed segmentation using texture features extracted from wavelet subimages. *Biosystems Engineering*, 157, 1–12.
- Di Cicco, M., Potena, C., Grisetti, G., & Pretto, A. (2017). Automatic model based dataset generation for fast and accurate crop and weeds detection. 2017 IEEE/RSJ International Conference on Intelligent.
- Olsen, A., Konovalov, D.A., Philippa, B. et al 2019 DeepWeeds: A Multiclass Weed Species Image Dataset for Deep Learning Sci Rep 9, 2058.
- Ahmad, J., Muhammad, K., Ahmad, I., Ahmad, W., Smith, M. L., Smith, L. N., Jain, D. K., Wang, H., & Mehmood, I. (2018). Visual features based boosted classification of weeds for real-time selective herbicide sprayer systems. *Computers in Industry*, 98, 23–33.
- T. M. Giselsson, R. N. Jørgensen, P. K. Jensen, M. Dyrmann and H. S. Midtiby 2017 A Public Image Database for Benchmark of Plant Seedling Classification Algorithms arXiv:1711.05458.
- Lameski, P., Zdravevski, E., Trajkovik, V., & Kulakov, A. (2017). Weed detection dataset with rgb images taken under variable light conditions. International Conference on ICT Innovations, 112–119.
- Shanmugam, S., Assun,c~ao, E., Mesquita, R., Veiros, A., & Gaspar, P. D. (2020). Automated weed detection systems: A review. *KnE Engineering*, 271–284.
- T. M. Giselsson, R. N. Jørgensen, P. K. Jensen, M. Dyrmann and H. S. Midtiby 2017 A Public Image Database for Benchmark of Plant Seedling Classification Algorithms arXiv:1711.05458.

Nurul Najwa Binti Mahizir (P110334)
 Ts. Dr. Abdul Hadi Abd Rahman
 Fakulti Teknologi & Sains Maklumat,
 Universiti Kebangsaan Malaysia