

MODEL KLASIFIKASI PENYAKIT IKAN MENGGUNAKAN PEMBELAJARAN MENDALAM BERCAWANGAN

HWANG TIAN EE

PROF. MADYA. TS. DR. AZIZI ABDULLAH

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

ABSTRAK

Industri perikanan telah menjadi sumber pendapatan penting di dunia. Bagaimanapun, penyakit ikan dianggap sebagai masalah serius dalam kalangan nelayan kerana ia cenderung merebak dengan cepat melalui air. Dalam beberapa dekad, penyakit ikan telah didiagnosis secara manual oleh mata kasar penternak ikan yang berpengalaman. Walaupun memakan masa kerana beberapa kerja makmal diperlukan dalam menentukan mikroorganisma yang berkaitan yang menyebabkan penyakit, kaedah klasik ini paling kerap membawa kepada keputusan yang tidak tepat dan mengelirukan. Oleh itu, kaedah yang cepat dan murah adalah penting dan wajar. Prestasi Rangkaian Neural Konvolusi (CNN) baru-baru ini telah ditunjukkan dalam pelbagai masalah penglihatan komputer dan pembelajaran mesin. Objektif kajian ini adalah untuk membangunkan model pengesanan penyakit ikan menggunakan pembelajaran mendalam dan membuat penambahbaikan ke atas model garis dasar. Kajian ini mencadangkan untuk melaksanakan idea percabangan ke dalam model garis dasar dan mengetahui cabang yang paling optimum untuk klasifikasi penyakit ikan. Prestasi kaedah yang dicadangkan ini akan dinilai menggunakan set data penyakit ikan air tawar.

PENGENALAN

Dalam bidang akuakultur yang dinamik, kesihatan populasi ikan adalah penting untuk mengekalkan pertumbuhan industri dan memastikan keselamatan makanan global. Keupayaan untuk mengenal pasti penyakit yang menjejaskan organisma akuatik dengan pantas dan tepat adalah aspek penting dalam pengurusan akuakultur yang berkesan. Akuakultur, sebagai sektor kritikal dalam domain pengeluaran makanan yang lebih luas, menghadapi cabaran yang wujud dalam mengekalkan kesihatan dan kesejahteraan spesies akuatik. Kemunculan penyakit dalam populasi ikan bukan sahaja menimbulkan ancaman ekonomi tetapi juga kebimbangan alam sekitar, menjadikan pengenalanpastian penyakit awal dan tepat penting. Kaedah pengesanan penyakit konvensional selalunya memerlukan tenaga kerja dan memakan masa, menekankan keperluan mendesak untuk penyelesaian teknologi termaju yang boleh menyelaraskan dan meningkatkan proses pemantauan.

Kaedah moden pengesanan penyakit ikan, yang dicadangkan oleh teknik pembelajaran mendalam, mengemukakan kes yang menarik untuk menggantikan kaedah tradisional seperti pemeriksaan manual dalam industri akuakultur. Walaupun pemeriksaan manual telah menjadi amalan lama, ia sememangnya memerlukan tenaga kerja, memakan masa dan tertakluk kepada kesilapan manusia. Sebaliknya, pembelajaran mendalam memanfaatkan kuasa kecerdasan buatan untuk menganalisis sejumlah besar data dengan kelajuan dan ketepatan. Model pembelajaran mendalam, terutamanya rangkaian neural convolutional (CNN), secara autonomi boleh mempelajari corak dan ciri rumit yang menunjukkan penyakit ikan daripada set data yang besar. Penggunaan teknologi sedemikian bukan sahaja mempercepatkan proses pengesanan tetapi juga meningkatkan ketepatan, mengurangkan kemungkinan pengawasan yang berkaitan dengan pemeriksaan berasaskan manusia. Tambahan pula, sistem pembelajaran mendalam menawarkan kelebihan skalabiliti, menjadikannya sesuai untuk pemantauan masa nyata berskala besar dalam kemudahan akuakultur. Dengan mengautomasikan proses pengesanan penyakit, kaedah moden menyumbang kepada campur tangan awal, meminimumkan kesan wabak, menggalakkan kesihatan akuatik, dan akhirnya memastikan kemampanan ekonomi amalan penternakan ikan.

Pembelajaran mesin, dengan kapasitinya untuk mempelajari corak daripada set data yang luas, membentangkan penyelesaian transformatif untuk mengautomasikan pengesanan dan klasifikasi penyakit ikan. Penggunaan model pembelajaran mendalam membolehkan pengekstrakan ciri rumit daripada imej, membolehkan pemahaman bernuansa isyarat visual berkaitan penyakit. Dalam kajian ini, pengelas cawangan dilaksanakan dalam model yang mana idea itu diambil daripada Rangkaian Neural Convolutional Cawangan (B-CNN) berdasarkan kajian (Zhu & Bain 2017).

METODOLOGI KAJIAN

Metodologi CRISP-DM (Hotz 2023) berdiri sebagai rangka kerja panduan, mengatur pendekatan yang sistematik dan komprehensif. Metodologi berstruktur ini merangkumi fasa berbeza yang disesuaikan untuk mengemudi kerumitan membangunkan model pengenalan dan klasifikasi penyakit ikan yang cekap dan tepat.

Pemahaman Perniagaan:

Memulakan dengan pemahaman yang menyeluruh tentang keperluan dan cabaran industri akuakultur, metodologi dimulakan dengan mentakrifkan objektif projek dengan jelas. Bekerjasama rapat dengan pakar akuakultur, persempadanan matlamat menyelaraskan niat penyelidikan dengan permintaan industri, memastikan penjajaran strategik untuk hasil yang memberi kesan.

Pemahaman dan Penyediaan Data:

Fasa penerokaan data menetapkan sasarannya untuk mengumpulkan set data yang pelbagai yang menggambarkan kesihatan ikan merentas pelbagai spesies dan penyakit (Biswas 2024). Penilaian data awal mendedahkan sifat dan cabaran, mengemudi usaha pembersihan dan penambahan data seterusnya. Fasa penting ini membentuk set data, memastikan kualiti,

keseimbangan dan keteguhannya untuk latihan model.

Pemodelan:

Pemilihan model muncul sebagai peringkat penting, di mana seni bina CNN yang sesuai dipilih dengan teliti berdasarkan ciri set data. Dengan memanfaatkan prinsip pembelajaran pemindahan, model-model tersebut menjalani penyesuaian, memperhalusi lapisannya untuk memahami ciri khusus penyakit yang penting untuk pengelasan yang tepat dalam alam akuatik.

Penilaian:

Metodologi berputar ke fasa penilaian, di mana model dilatih dan disahkan dengan teliti. Proses berulang ini bertujuan untuk meminimumkan ralat dan overfitting, memastikan prestasi optimum. Pada masa yang sama, gelung penilaian dan penghalusan berterusan berlaku, mengalu-alukan set data yang dikemas kini dan maklum balas pengguna—kitaran yang sentiasa berubah untuk meningkatkan ketepatan dan kebolehgunaan model.

Penggunaan:

Kemuncaknya menghampiri fasa penggunaan, menghasilkan antara muka yang mesra pengguna untuk penggunaan model yang lancar oleh profesional akuakultur. Integrasi ke dalam sistem sedia ada memastikan pelaksanaan praktikal. Pada masa yang sama, pertimbangan etika menambat setiap langkah, memastikan pematuhan dengan etika data dan piawai kebajikan haiwan.

KEPUTUSAN DAN PERBINCANGAN

Model Baseline:

Bagi fasa latihan, kehilangan latihan mewakili kadar ralat model pada set data latihan. Kehilangan 9.31% menunjukkan bahawa model telah mempelajari corak dan iri data latihan dengan baik, kerana nilai kerugian yang lebih rendah menandakan prestasi yang lebih baik. Ketepatan latihan menunjukkan bahagian ramalan yang betul model yang dibuat pada set data latihan. Ketepatan 96.88% adalah sangat tinggi, menunjukkan bahawa model telah belajar dengan berkesan daripada data latihan dan menunjukkan prestasi yang baik padanya. Model ini mempamerkan prestasi cemerlang pada data latihan, dengan kehilangan yang rendah dan ketepatan yang tinggi. Ini menunjukkan bahawa model tersebut mampu mempelajari dan menyesuaikan data latihan dengan baik.

Kehilangan pengesahan mewakili kadar ralat model pada set data pengesahan, yang tidak dilihat oleh model semasa latihan. Kehilangan 15.30% adalah lebih tinggi daripada kehilangan latihan, menunjukkan bahawa model menghadapi lebih banyak kesukaran untuk membuat generalisasi kepada data yang tidak kelihatan berbanding dengan data latihan. Ketepatan pengesahan menunjukkan perkadaran ramalan yang betul pada set data pengesahan. Ketepatan 89.47% adalah lebih rendah daripada ketepatan latihan, mencadangkan penurunan sedikit dalam prestasi apabila model digunakan pada data yang

tidak kelihatan. Peningkatan kerugian dan penurunan ketepatan daripada latihan kepada pengesahan menunjukkan bahawa model itu mungkin terlampau kesesuaian dengan data latihan. Overfitting berlaku apabila model mempelajari data latihan terlalu baik, termasuk hingar dan outliernya, dan gagal untuk digeneralisasikan kepada data baharu.

Kehilangan ujian mewakili kadar ralat model pada set data ujian, satu lagi set data ghaib yang digunakan untuk menilai prestasi akhir. Kehilangan 11.27% adalah lebih rendah daripada kehilangan pengesahan tetapi lebih tinggi daripada kehilangan latihan. Ketepatan ujian ialah perkadaran ramalan yang betul pada set data ujian. Ketepatan 96.43% adalah sangat hampir dengan ketepatan latihan dan jauh lebih tinggi daripada ketepatan pengesahan. Kehilangan yang lebih rendah dan ketepatan yang tinggi pada data ujian berbanding dengan data pengesahan menunjukkan bahawa model membuat generalisasi dengan baik kepada data yang tidak kelihatan apabila overfitting dikawal. Ini menunjukkan bahawa set pengesahan mungkin mempunyai beberapa contoh yang mencabar atau hiperparameter model telah ditala dengan berkesan selepas pengesahan.

Model	Kehilangan (%)	Ketepatan (%)
Latihan	9.31	96.88
Pengesahan	15.30	89.47
Ujian	11.27	96.43

Model 3 Cawangan:

Cawangan 1 menunjukkan prestasi yang kurang memuaskan. Kehilangan latihan adalah 108.72%, manakala kehilangan pengesahan sedikit lebih tinggi pada 110.48%. Ketepatan latihan hanya 62.28% dan ketepatan pengesahan adalah 67.15%. Ini menunjukkan bahawa model ini menghadapi kesukaran dalam mempelajari corak dalam data, menghasilkan prestasi keseluruhan yang lemah.

Cawangan 2 menunjukkan peningkatan yang ketara berbanding Cawangan 1. Kehilangan latihan menurun kepada 56.26% dan kehilangan pengesahan adalah 51.70%. Ketepatan latihan dan pengesahan masing-masing adalah 82.77% dan 83.94%, menunjukkan bahawa model ini lebih baik dalam mengenali corak dan mengelakkan overfitting.

Cawangan 3 menunjukkan prestasi terbaik. Kehilangan latihan adalah 12.36% dan kehilangan pengesahan hanya 7.78%. Ketepatan latihan mencapai 96.79% dan ketepatan pengesahan adalah 97.08%. Ini menunjukkan bahawa model ini sangat berkesan dalam mempelajari corak dan mengeneralisasi dengan baik kepada data baru.

Cawangan	Model	Kehilangan (%)	Ketepatan (%)
1	Latihan	108.72	62.28
	Pengesahan	110.48	67.15

2	Latihan	56.26	82.77
	Pengesahan	51.70	83.94
3	Latihan	12.36	96.79
	Pengesahan	7.78	97.08

Model 4 Cawangan:

Cawangan 1 menunjukkan prestasi yang sangat lemah. Kehilangan latihan adalah 143.34%, manakala kehilangan pengesahan adalah 163.69%, menunjukkan bahawa model ini mempunyai ralat yang tinggi dalam kedua-dua fasa. Ketepatan latihan hanya 47.51%, dan ketepatan pengesahan adalah 39.42%. Ini menunjukkan bahawa model ini tidak mampu mengenalpasti corak dalam data dengan baik dan tidak menggeneralisasi dengan baik kepada data baru.

Cawangan 2 menunjukkan prestasi yang lebih baik berbanding Cawangan 1 tetapi masih tidak memuaskan. Kehilangan latihan adalah 107.74%, dan kehilangan pengesahan adalah 113.52%. Ketepatan latihan adalah 64.45%, dan ketepatan pengesahan adalah 62.04%. Walaupun terdapat peningkatan dalam prestasi, model ini masih menunjukkan ralat yang tinggi dan ketepatan yang rendah.

Cawangan 3 menunjukkan peningkatan yang ketara dalam prestasi. Kehilangan latihan menurun kepada 58.55%, dan kehilangan pengesahan adalah 56.71%. Ketepatan latihan mencapai 81.80%, dan ketepatan pengesahan adalah 79.56%. Ini menunjukkan bahawa model ini lebih baik dalam mengenalpasti corak dan menggeneralisasi kepada data baru berbanding dengan Cawangan 1 dan 2.

Cawangan 4 menunjukkan prestasi terbaik di antara keempat-empat cawangan. Kehilangan latihan adalah 12.42%, dan kehilangan pengesahan adalah 6.40%, menunjukkan ralat yang sangat rendah. Ketepatan latihan adalah 96.85%, dan ketepatan pengesahan adalah 97.81%. Ini menunjukkan bahawa model ini sangat berkesan dalam mempelajari corak dalam data latihan dan menggeneralisasi dengan sangat baik kepada data baru.

Cawangan	Model	Kehilangan (%)	Ketepatan (%)
1	Latihan	143.34	47.51
	Pengesahan	163.69	39.42
2	Latihan	107.74	64.45
	Pengesahan	113.52	62.04
3	Latihan	58.55	81.80
	Pengesahan	56.71	79.56
4	Latihan	12.42	96.85

Pengesahan	6.40	97.81
------------	------	-------

Model 5 Cawangan:

Cawangan 1 menunjukkan prestasi yang lemah dengan kehilangan latihan sebanyak 142.67% dan kehilangan pengesahan sebanyak 163.55%. Ketepatan latihan adalah 48.48%, sementara ketepatan pengesahan adalah 39.42%. Prestasi yang rendah ini menunjukkan bahawa model ini mengalami kesukaran dalam mempelajari corak dalam data dan tidak mengeneralisasi dengan baik kepada data baru.

Cawangan 2 menunjukkan prestasi yang lebih baik daripada Cawangan 1 tetapi masih tidak memuaskan. Kehilangan latihan adalah 108.63% dan kehilangan pengesahan adalah 108.12%. Ketepatan latihan adalah 63.54%, dan ketepatan pengesahan adalah 62.77%. Walaupun terdapat peningkatan dalam prestasi, model ini masih menunjukkan ralat yang tinggi dan ketepatan yang sederhana.

Cawangan 3 menunjukkan peningkatan yang ketara dalam prestasi. Kehilangan latihan menurun kepada 57.68%, dan kehilangan pengesahan adalah 51.74%. Ketepatan latihan mencapai 81.97%, dan ketepatan pengesahan adalah 83.94%. Ini menunjukkan bahawa model ini lebih baik dalam mengenalpasti corak dan mengeneralisasi kepada data baru berbanding dengan Cawangan 1 dan 2.

Cawangan 4 menunjukkan prestasi yang sangat baik. Kehilangan latihan adalah 11.77%, dan kehilangan pengesahan adalah 7.58%. Ketepatan latihan mencapai 97.31%, dan ketepatan pengesahan adalah 97.81%. Model ini menunjukkan kemampuan yang kuat dalam mempelajari corak dalam data latihan dan mengeneralisasi dengan baik kepada data baru.

Cawangan 5 juga menunjukkan prestasi yang sangat baik dengan kehilangan latihan sebanyak 12.41% dan kehilangan pengesahan sebanyak 8.88%. Ketepatan latihan adalah 97.20%, sementara ketepatan pengesahan adalah 96.35%. Model ini hampir setara dengan Cawangan 4 dalam prestasi, menunjukkan keupayaan yang kuat dalam mengenalpasti corak dalam data.

Cawangan	Model	Kehilangan (%)	Ketepatan (%)
1	Latihan	142.67	48.48
	Pengesahan	163.55	39.42
2	Latihan	108.63	63.54
	Pengesahan	108.12	62.77
3	Latihan	57.68	81.97
	Pengesahan	51.74	83.94
4	Latihan	11.77	97.31

	Pengesahan	7.58	97.81
5	Latihan	12.41	97.20
	Pengesahan	8.88	96.35

Model 6 Cawangan:

Cawangan 1 menunjukkan prestasi yang lemah dengan kehilangan latihan sebanyak 142.09% dan kehilangan pengesahan sebanyak 165.55%. Ketepatan latihan adalah 46.19%, sementara ketepatan pengesahan adalah 37.96%. Prestasi yang rendah ini menunjukkan bahawa model ini tidak berjaya dalam mengenalpasti corak dalam data dan mempunyai generalisasi yang lemah terhadap data baru.

Cawangan 2 menunjukkan prestasi yang lebih baik berbanding Cawangan 1 tetapi masih tidak memuaskan. Kehilangan latihan adalah 107.66% dan kehilangan pengesahan adalah 114.59%. Ketepatan latihan adalah 62.34%, dan ketepatan pengesahan adalah 59.85%. Walaupun terdapat peningkatan dalam prestasi, model ini masih menunjukkan ralat yang tinggi dan ketepatan yang sederhana.

Cawangan 3 menunjukkan peningkatan yang ketara dalam prestasi. Kehilangan latihan menurun kepada 56.86%, dan kehilangan pengesahan adalah 61.32%. Ketepatan latihan mencapai 82.83%, dan ketepatan pengesahan adalah 79.56%. Ini menunjukkan bahawa model ini lebih baik dalam mengenalpasti corak dan menggeneralisasi kepada data baru berbanding dengan Cawangan 1 dan 2.

Cawangan 4 menunjukkan prestasi yang sangat baik dengan kehilangan latihan sebanyak 14.95% dan kehilangan pengesahan sebanyak 12.38%. Ketepatan latihan mencapai 96.68%, dan ketepatan pengesahan adalah 95.62%. Model ini menunjukkan kemampuan yang kuat dalam mempelajari corak dalam data latihan dan mengeneralisasi dengan baik kepada data baru.

Cawangan 5 juga menunjukkan prestasi yang sangat baik dengan kehilangan latihan sebanyak 11.96% dan kehilangan pengesahan sebanyak 5.10%. Ketepatan latihan adalah 97.08%, sementara ketepatan pengesahan adalah 98.54%. Model ini hampir setara dengan Cawangan 4 dalam prestasi, menunjukkan keupayaan yang kuat dalam mengenalpasti corak dalam data.

Cawangan 6 menunjukkan prestasi yang cemerlang dengan kehilangan latihan sebanyak 12.02% dan kehilangan pengesahan sebanyak 5.26%. Ketepatan latihan adalah 97.37%, dan ketepatan pengesahan adalah 98.54%. Model ini menunjukkan prestasi yang terbaik dalam mengenalpasti corak dan menggeneralisasi dengan baik kepada data baru.

Cawangan	Model	Kehilangan (%)	Ketepatan (%)
1	Latihan	142.09	46.19

	Pengesahan	165.55	37.96
2	Latihan	107.66	62.34
	Pengesahan	114.59	59.85
3	Latihan	56.86	82.83
	Pengesahan	61.32	79.56
4	Latihan	14.95	96.68
	Pengesahan	12.38	95.62
5	Latihan	11.96	97.08
	Pengesahan	5.10	98.54
6	Latihan	12.02	97.37
	Pengesahan	5.26	98.54

Model 7 Cawangan:

Cawangan 1 menunjukkan prestasi yang sangat lemah dengan kehilangan latihan sebanyak 142.50% dan kehilangan pengesahan sebanyak 166.08%. Ketepatan latihan adalah 47.80%, sementara ketepatan pengesahan adalah 40.88%. Ini menunjukkan bahawa model ini tidak berjaya mengenalpasti corak dalam data dan mempunyai generalisasi yang sangat lemah terhadap data baru.

Cawangan 2 menunjukkan peningkatan prestasi berbanding Cawangan 1 tetapi masih tidak memuaskan. Kehilangan latihan adalah 108.92% dan kehilangan pengesahan adalah 116.03%. Ketepatan latihan adalah 63.14%, dan ketepatan pengesahan adalah 57.66%. Walaupun prestasi bertambah baik, model ini masih menunjukkan ralat yang tinggi dan ketepatan yang sederhana.

Cawangan 3 menunjukkan peningkatan yang ketara dalam prestasi. Kehilangan latihan menurun kepada 62.25%, dan kehilangan pengesahan adalah 67.24%. Ketepatan latihan mencapai 82.08%, dan ketepatan pengesahan adalah 75.91%. Model ini lebih baik dalam mengenalpasti corak berbanding dengan Cawangan 1 dan 2, tetapi masih memerlukan penambahbaikan.

Cawangan 4 menunjukkan prestasi yang hampir sama dengan Cawangan 3. Kehilangan latihan adalah 56.68%, dan kehilangan pengesahan adalah 60.18%. Ketepatan latihan mencapai 82.71%, dan ketepatan pengesahan adalah 76.64%. Model ini sedikit lebih baik daripada Cawangan 3 dalam mengenalpasti corak dan mengeneralisasi kepada data baru.

Cawangan 5 menunjukkan prestasi yang sangat baik dengan kehilangan latihan sebanyak 15.92% dan kehilangan pengesahan sebanyak 21.12%. Ketepatan latihan mencapai 96.16%, dan ketepatan pengesahan adalah 91.24%. Ini menunjukkan bahawa model ini mempunyai keupayaan yang kuat dalam mengenalpasti corak dan mengeneralisasi dengan

baik kepada data baru.

Cawangan 6 menunjukkan prestasi yang sangat baik dengan kehilangan latihan sebanyak 14.17% dan kehilangan pengesahan sebanyak 12.56%. Ketepatan latihan mencapai 96.79%, dan ketepatan pengesahan adalah 95.62%. Model ini menunjukkan kemampuan yang kuat dalam mempelajari corak dalam data latihan dan mengeneralisasi dengan baik kepada data baru.

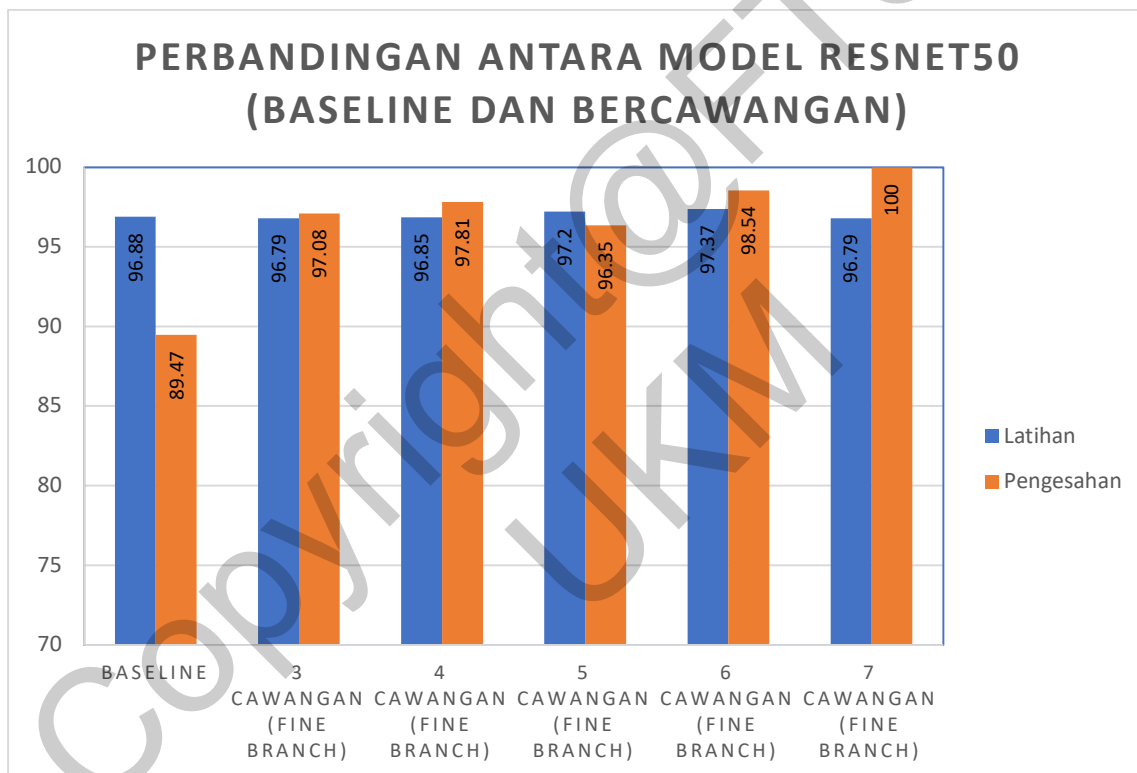
Cawangan 7 menunjukkan prestasi terbaik di antara semua model dengan kehilangan latihan sebanyak 12.73% dan kehilangan pengesahan sebanyak 6.68%. Ketepatan latihan adalah 96.79%, sementara ketepatan pengesahan mencapai 100.00%. Model ini menunjukkan keupayaan tertinggi dalam mengenalpasti corak dan mengeneralisasi kepada data baru dengan ketepatan sempurna.

Cawangan	Model	Kehilangan (%)	Ketepatan (%)
1	Latihan	142.50	47.80
	Pengesahan	166.08	40.88
2	Latihan	108.92	63.14
	Pengesahan	116.03	57.66
3	Latihan	62.25	82.08
	Pengesahan	67.24	75.91
4	Latihan	56.68	82.71
	Pengesahan	60.18	76.64
5	Latihan	15.92	96.16
	Pengesahan	21.12	91.24
6	Latihan	14.17	96.79
	Pengesahan	12.56	95.62
7	Latihan	12.73	96.79
	Pengesahan	6.68	100.00

Perbandingan Antara Model:

Model dengan 7 cawangan menunjukkan prestasi terbaik dalam fasa pengesahan dengan ketepatan sempurna sebanyak 100.00%, diikuti oleh model dengan 6 cawangan yang menunjukkan ketepatan pengesahan sebanyak 98.54%. Model dengan 4 cawangan juga menunjukkan prestasi yang baik dengan ketepatan pengesahan sebanyak 97.81%. Model-model ini menunjukkan kemampuan yang kuat dalam mengeneralisasi kepada data baru. Model Baseline menunjukkan penurunan ketara dalam ketepatan pengesahan, manakala model dengan 5 cawangan menunjukkan sedikit tanda overfitting.

Model	Ketepatan (%)	
	Latihan	Pengesahan
Baseline	96.88	89.47
3 Cawangan (fine branch)	96.79	97.08
4 Cawangan (fine branch)	96.85	97.81
5 Cawangan (fine branch)	97.20	96.35
6 Cawangan (fine branch)	97.37	98.54
7 Cawangan (fine branch)	96.79	100.00



KESIMPULAN

Secara keseluruhannya, model klasifikasi penyakit ikan dengan model bercawangan ini telah berjaya dibangunkan dengan menggunakan data yang telah dikaji dan diperolehi. Objektif kajian dan keperluan yang telah ditetapkan sebelum ini telah berjaya dicapai. Walaupun terdapat beberapa halangan, ia berjaya diatasi menggunakan pelbagai cara. Diharapkan kajian ini dijadikan titik kajian untuk kajian lain pada masa hadapan.

Kekuatan

Kajian ini menonjolkan kekuatan dalam penilaian komprehensif pelbagai seni bina model,

membandingkan ResNet50 garis dasar dengan model berbilang cawangan dari tiga hingga tujuh cawangan. Perbandingan ini meningkatkan pemahaman tentang impak konfigurasi berbeza terhadap prestasi model. Model 7-cawangan ResNet50 menunjukkan ketepatan penegsahan yang tinggi sebanyak 100%, membuktikan keberkesanannya dalam mengesan penyakit ikan. Kekuatan lain terletak pada keupayaan seni bina berbilang cawangan untuk memanfaatkan pengekstrakan ciri hierarki pada kedalaman yang berbeza, memperkaya kapasiti model untuk menangkap ciri rumit dan penting untuk diagnosis penyakit ikan. Model 7-cawangan mencapai hasil optimum tanpa menambah kerumitan yang berlebihan, menunjukkan keupayaan generalisasi yang kukuh dan prestasi baik pada data yang tidak dilihat, yang penting untuk aplikasi dunia sebenar.

Kelemahan

Kebimbangan utama dalam kajian ini ialah skop terhadap set data yang digunakan untuk latihan dan ujian. Jika set data tidak cukup pelbagai atau tidak mewakili semua variasi penyakit ikan, prestasi model mungkin tidak digeneralisasikan dengan baik kepada data lain atau senario dunia sebenar. Kajian juga tidak menyebut pengesahan pada set data luaran, yang penting untuk menilai keteguhan model dalam persekitaran berbeza. Kelemahan lain ialah potensi overfitting, terutama dengan ketepatan latihan yang tinggi pada semua model. Ini mungkin menunjukkan bahawa model telah mempelajari bunyi atau butiran tidak relevan khusus untuk set data latihan, yang boleh merosakkan prestasi pada data baru. Selain itu, model berbilang cawangan, terutama yang mempunyai lebih banyak cawangan, memerlukan sumber pengiraan yang signifikan, membatasi kegunaan praktikal model dalam persekitaran dengan sumber terhad.

PENGHARGAAN

Pertama sekali saya ingin mengucapkan ribuan terima kasih kepada penyelia saya iaitu Assoc. Prof. Ts. Dr. Azizi Abdullah di atas nasihat, bimbingan, kesabaran dan memberi sokongan kepada saya untuk melakukan kajian ini.

Seterusnya, terima kasih ingin diucapkan kepada para pensyarah FTSM atas curahan ilmu pengetahuan dan jasa mereka yang tidak terhingga dalam pemberian bimbingan kepada saya sepanjang pengajian di UKM.

Selain itu, saya ingin memberikan setinggi-tinggi penghargaan kepada ibu bapa saya dan juga keluarga saya kerana mereka yang memberikan sokongan moral yang berterusan sepanjang saya menjalankan projek ini.

Akhir sekali, tidak lupa mengucapkan terima kasih kepada rakan saya yang sentiasa memberikan bantuan dan tunjuk ajar kepada saya semasa saya menjalankan kajian ini.

RUJUKAN

Biswas, S. 2024. Freshwater Fish Disease Aquaculture in south asia.

Hotz, N. 2023. What is CRISP DM? : <https://www.datascience-pm.com/crisp-dm-2/>

Zhu, X. & Bain, M. 2017. B-CNN: Branch Convolutional Neural Network for Hierarchical Classification. <https://arxiv.org/pdf/1709.09890.pdf>

Hwang Tian Ee (A187479)

Prof. Madya Ts. Dr. Azizi Abdullah

Fakulti Teknologi & Sains Maklumat

Universiti Kebangsaan Malaysia

Copyright@FTSM
UKM