

PENAPIS KONVOLUSI GABOR UNTUK SISTEM PENGELASAN BUAH-BUAHAN

Nur Izzati binti Mohd Talib
Azizi Abdullah

Fakulti Teknologi dan Sains Maklumat, Universiti Kebangsaan Malaysia

ABSTRAK

Terdapat peningkatan dalam menggunakan pembelajaran mendalam untuk penglihatan komputer dan membantu tugas seperti klasifikasi imej, pengesanan objek, pengesanan muka dan banyak lagi. Convolutional Neural Network (CNN) merupakan salah satu daripada banyak seni bina pembelajaran dalam digunakan bagi membantu klasifikasi imej. CNN dapat mengesan ciri penting tanpa sebarang pengawasan manusia. Walaupun begitu, CNN kekurangan kemampuan memodelkan transformasi geometri disebabkan reka bentuk penapis. Penapis dalam CNN adalah penting dalam mengesan ciri-ciri imej. Penapis Gabor telah diperkenalkan untuk mengurangkan dimensi dan komputasi CNN dan meningkatkan keupayaan untuk mempelajari ciri-ciri mendalam dengan perubahan orientasi dan skala. Oleh itu, penapis standard di CNN akan diganti dengan penapis Gabor kerana ia mempunyai sifat yang dapat dipandu yang akan berguna dalam meningkatkan ketepatan. Penapis asas CNN akan digantikan dengan penapis Gabor dalam kajian ini untuk meningkatkan ketepatannya. Penapis Gabor telah digunakan secara meluas untuk mengekstrak ciri-ciri tekstur dari imej untuk pengambilan imej dan telah terbukti berguna dalam tugas pengesanan muka. CNN yang digunakan bersama penapis Gabor akan diuji pada imej buah-buahan. Objektif dalam kajian ini adalah untuk menganalisis dan memahami kesan penapis Gabor dalam CNN kepada klasifikasi imej, khususnya klasifikasi buah-buahan. Kelas-kelas buah khususnya yang akan digunakan untuk menganalisis adalah pisang, anggur, mangga, oren and nenas. Antara cara untuk memahami kesannya adalah dengan penggambaran penapis. Hasilnya, prestasi model dapat ditingkatkan daripada 33.50% ke 34.50% dengan penalaan parameter Gabor theta dan psi.

1 PENGENALAN

Pembelajaran mendalam (Deep Learning) membolehkan model pengiraan yang terdiri daripada beberapa lapisan pemprosesan untuk mempelajari perwakilan data dengan pelbagai peringkat abstraksi. Pendekatan pembelajaran mendalam membolehkan penguasaan beberapa tugas klasifikasi. Pembelajaran mendalam dapat menemui struktur rumit dalam set data yang besar dengan menggunakan algoritma perambatan berbalik untuk menunjukkan bagaimana mesin harus mengubah parameter dalamannya yang digunakan untuk mengira perwakilan di setiap lapisan dari perwakilan pada lapisan sebelumnya. Hasilnya telah membawa kejayaan dalam memproses imej, video, pertuturan, audio, dan juga pada data berurutan seperti teks dan ucapan (Lecun et al. 2015).

Pembelajaran mendalam telah digunakan di beberapa industri, termasuk industri buah-buahan. Pengelasan buah-buahan menggunakan pembelajaran mesin bukan konsep baru. Aplikasi bertujuan untuk mengenal pasti buah-buahan daripada imej atau video semakin meningkat. Terdapat banyak sebab mengapa pengelasan buah adalah penting. Ini terbukti dengan penyelidikan terdahulu yang telah menggunakan aplikasi ini untuk penuaian automatic. Selain itu, klasifikasi buah-buahan digunakan bagi perbandingan kualiti dengan mengenalpasti secara automatic, mengira dan mengukur buah-buahan (Song et al. 2014). Terdapat lagi masalah untuk mereka sistem pengenalpastian buah-buahan yang cepat dan boleh dipercayai kerana variasi yang tinggi dalam penampilan buah-buahan, termasuk warna, bentuk, saiz, tekstur dan sifat reflektif. Di samping itu, masalah ini disebabkan oleh pencahayaan dan keadaan bayangan yang sentiasa berubah-ubah (Sa et al. 2016).

Convolutional neural network (CNN) merupakan antara contoh baik idea yang menggunakan biology untuk menyelesaikan masalah kejuruteraan. CNN dikenali sebagai sejenis rangkaian neural mendalam yang terbukti berfungsi untuk mengklasifikasikan imej dan digunakan untuk memproses data yang mempunyai topologi, contohnya data imej yang boleh dianggap sebagai grid piksel 2D. Rangkaian ini menggunakan operasi matematik dipanggil konvolusi, dan merupakan sejenis operasi linear. Rangkaian neural konvolusi terdiri daripada lapisan, convolution layer, pooling layer dan fully connected layer (Goodfellow et al. 2016).

Baru-baru ini, rangkaian neural konvolusi mendalam telah menarik perhatian dalam penglihatan computer. Model ini mempunyai keupayaan tinggi untuk belajar ciri-ciri daripada imej piksel mentah, meningkatkan prestasi tugas klasifikasi imej (Luan et al. 2018). Antara kelebihan lain rangkaian neural konvolusi ialah kesenangan untuk dipakai di perkakasan kerana cip analog/digital khusus telah direka untuk mengenal huruf-huruf dan memproses imej. Oleh sebab itu, bagi projek ini, CNN akan digunakan untuk memproses imej dan membantu dalam pengelasan buah-buahan.

2 PERNYATAAN MASALAH

CNN menghadapi masalah dalam melatih rangkaian besar yang menuntut masa dan keperluan tenaga pengkomputeran yang tinggi. Selain itu, reka bentuk penapis dalam CNN merupakan antara salah satu sebab CNN biasanya gagal menangani transformasi objek yang besar dan tidak diketahui jika data latihan tidak mencukupi. Masalah ini diatasi menggunakan rangkaian neural konvolusi mendalam yang menggunakan orientasi penapis Gabor dikenali sebagai penapis Gabor konvolusi. Penapis Gabor konvolusi telah menunjukkan hasil yang terbaik (Luan et al. 2018). Walaupun begitu, ketepatan penapis gabor dalam menganalisis imej oleh ditingkatkan lagi dengan mengubah nilai parameter. Beberapa kajian sebelum ini telah menggunakan beberapa parameter dalam penapis Gabor tetapi kebanyakannya tidak memberi penjelasan bagi pemilihan parameter tersebut (Chen et al. 2004).

3 OBJEKTIF KAJIAN

1. Mengkaji peranan dan sifat penapis Gabor menggunakan parameter tuning.
2. Membandingkan sifat penapis Gabor dengan sifat penapis rawak yang sedia ada.
3. Menggunakan penapis Gabor konvolusi untuk mengklasifikasikan imej buah-buahan.

3 METOD KAJIAN

Metodologi yang digunakan untuk membangunkan Sistem Pengelasan Buah-Buahan ialah Metodologi Air Terjun seperti Rajah 1.3. Metodologi ini dipilih kerana mudah difahami, mudah untuk digunakan membangunkan projek ini mengikut turutan dan juga mudah untuk dipantau kemajuannya. Metodologi ini terdiri daripada lima fasa iaitu fasa perancangan, fasa analisis, fasa reka bentuk, fasa implementasi dan fasa pengujian. Rajah 1.3 Metodologi Air Terjun

4.1 Fasa Perancangan

Dalam pembangunan system pengelasan buah-buahan, fasa ini merupakan fasa terpenting kerana melibatkan kefahaman dan pengenalpastian tujuan dan langkah-langkah untuk membina sistem ini dan juga membincangkan skop dan objektif projek. Oleh sebab itu, kajian awal diperlukan untuk perancangan dalam membangunkan sistem supaya lebih jelas tentang kajian. Pengumpulan dan pencarian maklumat dan rujukan tentang topic penting untuk lebih memahami projek ini. Sumber maklumat yang bagus merupakan perpustakaan atau di Internet melalui *google scholar* untuk mencari kajian-kajian yang boleh dipercayai.

4.2 Fasa Analisis

Bagi mengenalpastikan kelemahan-kelemahan yang dihadapi oleh sistem semasa, analisis terhadap sistem adalah sangat penting. Maklumat tentang maklumat sistem sedia ada akan menjadi rujukan. Tujuan mengkaji sistem ini adalah untuk membanggunkan sebuah sistem yang dapat memenuhi keperluan dan kehendak pengguna. Selain itu, pengumpulan maklumat tentang buah-buahan juga dilakukan dalam fasa ini. Isi kandungan dan skop berkenaan juga dikenalpastikan dalam fasa ini.

Dalam kajian ini, penapis Gabor akan digunakan. Berdasarkan kajian-kajian lepas, kebanyakan telah guna penapis Gabor untuk mengekstrak fitur imej dan meningkatkan prestasi pengelasan imej (Avinash et al. 2016; Song et al. 2015). Manakala, reka bentuk *CNN* yang merupakan pengesan objek dibuktikan dengan beberapa kajian memberi prestasi yang tinggi untuk membangunkan sistem pengelasan (Bargoti et al. 2017; Sa et al. 2016).

4.3 Fasa Reka Bentuk

Sistem pengelasan buah-buahan akan direkabentukkan dalam fasa ini. Bagaimana sistem ini akan beroperasi, dari segi perkakasan, perisian, dan infrastruktur rangkaian akan dikenalpastikan.

4.4 Fasa Implementasi

Dalam fasa ini, membina dan menguji sistem pengelasan buah-buahan sama ada berfungsi seperti mana yang direkabentukkan. Dengan ini, kelemahan-kelemahan di sistem akan dikenalpastikan dan boleh memastikan sistem ini bebas daripada kesalahan.

4.5 Fasa Pengujian

Fasa pengujian bertujuan untuk menguji model sistem yang dibina secara keseluruhan. Dalam fasa ini, sistem yang dibina akan diuji untuk memeriksa sama ada ia memenuhi keperluan.

5 HASIL KAJIAN

Bab ini akan membincangkan pembangunan dan pengujian sistem bagi sistem pengelasan buah-buahan. Dalam projek ini, *CNN* diaplikasi bersama penapis Gabor dan keputusan ketepatan model akan direkordkan. Sisihan piawai dan min pemberat (*weights*) dalam penapis juga akan diukur. *Parameter tuning* digunakan untuk memahami parameter mana yang memberi impak yang tinggi.

5.2 KEPUTUSAN ALEXNET DAN GABOR-ALEXNET

Jadual 5.1 Penetapan Parameter Gabor

Parameter	Nilai
Lambda, λ	[8,100]
Sigma, σ	[2,21]
Gamma, γ	[0,300]
Psi, ψ	[0,360]
Theta, θ	[0,360]

Jadual 5.1 menunjukkan nilai parameter Gabor yang digunakan. Nilai-nilai ini didapati daripada kajian Ozbulak. Ozbulak telah membina bank penapis Gabornya menggunakan kaedah carian grid. Julat parameter penapis Gabor bergantung pada berapa banyak penapis yang digunakan di lapisan pertama (Özbulak et al. 2018).

A) 1000 imej

Jadual 5.2 Keputusan bagi *CNN* dan *Gabor-CNN* bagi 1000 imej

Keputusan	CNN	Gabor-CNN
Ketepatan (%)	31.50	27.00
Sisihan Piawai	0.0123	0.602
Min	-0.022	0.006

Jadual 5.2 menunjukkan perbezaan keputusan *CNN* tanpa penapis Gabor dan *CNN* dengan penapis Gabor menggunakan dataset buah-buahan bagi 1000 imej. Ketepatan bagi *CNN* lebih tinggi berbanding *Gabor-CNN* tetapi mendapat sisihan piawai pemberat yang rendah berbanding *Gabor-CNN*.

B) 2000 imej

Jadual 5.3 Keputusan bagi *CNN* dan *Gabor-CNN* bagi 2000 imej

Keputusan	CNN	Gabor-CNN
Ketepatan (%)	33.50	26.25
Sisihan Piawai	0.013	0.602
Min	0.031	0.006

Jadual 5.3 menunjukkan perbezaan keputusan *CNN* tanpa penapis Gabor dan *CNN* dengan penapis Gabor menggunakan dataset buah-buahan bagi 2000 imej. Ketepatan bagi *CNN* lebih tinggi berbanding Gabor-*CNN* tetapi mendapat sisihan piawai pemberat yang rendah berbanding Gabor-*CNN*.

C) 3000 imej

Jadual 5.4 Keputusan bagi *CNN* dan Gabor-*CNN* bagi 3000 imej

Keputusan	CNN	Gabor-CNN
Ketepatan (%)	27.17	21.50
Sisihan Piawai	0.013	0.602
Min	0.002	0.006

Jadual 5.4 menunjukkan perbezaan keputusan *CNN* tanpa penapis Gabor dan *CNN* dengan penapis Gabor menggunakan dataset buah-buahan bagi 3000 imej. Ketepatan bagi *CNN* lebih tinggi berbanding Gabor-*CNN* tetapi mendapat sisihan piawai pemberat yang rendah berbanding Gabor-*CNN*.

5.3 PARAMETER TUNING

Jadual 5.5 Penetapan parameter Gabor statik

Parameter	Nilai
Lambda, λ	1
Sigma, σ	10
Gamma, γ	3
Psi, ψ	0
Theta, θ	0

Jadual 5.5 menunjukkan penetapan parameter Gabor statik yang digunakan bagi *parameter tuning*. Nilai ini merupakan nilai terbaik bagi parameter tersebut (Pham 2019; Wong 2018). Bagi *parameter tuning*, satu parameter akan berubah manakala parameter lain akan menggunakan nilai di Jadual 5.1.

5.3.1 1000 imej

A) Semua Nilai

Jadual 5.6 Keputusan Gabor-CNN bagi semua nilai parameter statik bagi 1000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	22.50	23.00	26.50	24.00
Sisihan Piawai	0.042	0.042	0.042	0.042
Min	0.952	0.952	0.952	0.952

Jadual 5.6 menunjukkan keputusan ketepatan, sisihan piawai dan min Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor. Purata bagi ketepatan model, sisihan piawai dan min pemberat selepas tiga test run diambil.

B) Sigma

Jadual 5.7 Keputusan Gabor-CNN bagi semua nilai parameter kecuali sigma statik bagi 2000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	23.00	23.50	21.00	22.50
Sisihan Piawai	0.160	0.160	0.160	0.160
Min	0.910	0.910	0.910	0.910

Jadual 5.7 menunjukkan keputusan ketepatan, sisihan piawai dan min Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali sigma. Purata bagi ketepatan model, sisihan piawai dan min pemberat selepas tiga test run diambil.

C) Lambda

Jadual 5.8 Keputusan Gabor-CNN bagi semua nilai parameter kecuali lambda statik bagi 1000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	21.50	28.00	19.00	22.83
Sisihan Piawai	0.348	0.348	0.348	0.348
Min	0.780	0.780	0.780	0.780

Jadual 5.8 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali lambda. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

D) Theta

Jadual 5.9 Keputusan Gabor-CNN bagi semua nilai parameter kecuali theta menggunakan 1000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	25.50	31.50	30.00	29.00
Sisihan Piawai	0.683	0.683	0.683	0.683
Min	0.058	0.058	0.058	0.058

Jadual 5.9 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali theta. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

E) Gamma

Jadual 5.10 Keputusan Gabor-CNN bagi semua nilai parameter kecuali gamma menggunakan 1000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	26.00	24.00	18.00	22.67
Sisihan Piawai	0.155	0.155	0.155	0.155
Min	0.838	0.838	0.838	0.838

Jadual 5.10 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali gamma. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

E) Psi

Jadual 5.11 Keputusan Gabor-CNN bagi semua nilai parameter kecuali gamma menggunakan 1000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	27.00	25.50	26.50	26.33
Sisihan Piawai	0.675	0.675	0.675	0.675
Min	-0.003	-0.003	-0.003	-0.003

Jadual 5.11 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali psi. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

5.3.2 2000 imej

A) Semua Nilai

Jadual 5.12 Keputusan Gabor-CNN bagi semua nilai parameter statik bagi 2000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	19.50	21.25	24.00	21.58
Sisihan Piawai	0.042	0.042	0.042	0.042
Min	0.952	0.952	0.952	0.952

Jadual 5.12 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

B) Sigma

Jadual 5.13 Keputusan Gabor-CNN bagi semua nilai parameter kecuali sigma statik bagi 2000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	25.0	23.25	19.75	22.67
Sisihan Piawai	0.160	0.160	0.160	0.160
Min	0.910	0.910	0.910	0.910

Jadual 5.13 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali sigma. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

C) Lambda

Jadual 5.14 Keputusan Gabor-CNN bagi semua nilai parameter kecuali lambda statik bagi 2000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	23.50	22.50	25.50	23.83
Sisihan Piawai	0.348	0.348	0.348	0.348
Min	0.780	0.780	0.780	0.780

Jadual 5.14 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali lambda. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

D) Theta

Jadual 5.15 Keputusan Gabor-CNN bagi semua nilai parameter kecuali theta menggunakan 2000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	35.25	32.00	32.25	33.17
Sisihan Piawai	0.683	0.683	0.683	0.683
Min	0.058	0.058	0.058	0.058

Jadual 5.15 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali theta. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

E) Gamma

Jadual 5.16 Keputusan Gabor-CNN bagi semua nilai parameter kecuali gamma menggunakan 2000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	20.00	21.25	25.50	22.25
Sisihan Piawai	0.155	0.155	0.155	0.155
Min	0.838	0.838	0.838	0.838

Jadual 5.16 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali gamma. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

E) Psi

Jadual 5.17 Keputusan Gabor-CNN bagi semua nilai parameter kecuali gamma menggunakan 2000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	27.75	23.50	24.75	25.33
Sisihan Piawai	0.675	0.675	0.675	0.675
Min	-0.003	-0.003	-0.003	-0.003

Jadual 5.17 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali psi. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

5.3.3 3000 imej

A) Semua Nilai

Jadual 5.18 Keputusan Gabor-CNN bagi semua nilai parameter statik bagi 3000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	25.67	23.83	24.67	24.72
Sisihan Piawai	0.042	0.042	0.042	0.042
Min	0.952	0.952	0.952	0.952

Jadual 5.18 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

B) Sigma

Jadual 5.19 Keputusan Gabor-CNN bagi semua nilai parameter kecuali sigma statik bagi 3000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	22.33	21.16	24.00	22.50
Sisihan Piawai	0.160	0.160	0.160	0.160
Min	0.910	0.910	0.910	0.910

Jadual 5.19 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali sigma. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

C) Lambda

Jadual 5.20 Keputusan Gabor-CNN bagi semua nilai parameter kecuali lambda statik bagi 3000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	22.83	22.67	22.67	22.72
Sisihan Piawai	0.348	0.348	0.348	0.348
Min	0.780	0.780	0.780	0.780

Jadual 5.20 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali lambda. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

D) Theta

Jadual 5.21 Keputusan Gabor-CNN bagi semua nilai parameter kecuali theta menggunakan 3000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	31.33	30.83	38.33	33.50
Sisihan Piawai	0.683	0.683	0.683	0.683
Min	0.058	0.058	0.058	0.058

Jadual 5.21 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali theta. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

E) Gamma

Jadual 5.22 Keputusan Gabor-CNN bagi semua nilai parameter kecuali gamma menggunakan 3000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	22.83	23.50	22.83	23.05
Sisihan Piawai	0.155	0.155	0.155	0.155
Min	0.838	0.838	0.838	0.838

Jadual 5.22 menunjukkan keputusan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali gamma. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

E) Psi

Jadual 5.23 Keputusan Gabor-CNN bagi semua nilai parameter kecuali gamma menggunakan 3000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	25.33	29.00	27.50	27.28
Sisihan Piawai	0.675	0.675	0.675	0.675
Min	-0.003	-0.003	-0.003	-0.003

Jadual 5.23 menunjukkan ketepatan model, sisihan piawai dan min pemberat Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali psi. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil.

5.3.4 Keputusan *Parameter Tuning*

Daripada *parameter tuning*, dua parameter Gabor yang memberi ketepatan paling tinggi ialah theta diikuti dengan psi. Maklumat ini selaras dengan kajian lepas yang telah merekodkan bahawa theta dan psi memberi impak yang tinggi (Pham 2019). Oleh sebab itu, dalam pembinaan penapis Gabor, theta dan psi akan diberi tumpuan.

A) 1000 imej

Jadual 5.24 Perbandingan keputusan *parameter tuning* bagi 1000 imej

Parameter	Purata	Purata	Min	Pangkat
	Ketepatan	Sisihan Piawai		Ketepatan
Sigma	22.50	0.160	0.910	5
Lambda	22.83	0.348	0.780	3
Theta	29.00	0.683	0.058	1
Gamma	22.67	0.155	0.838	4
Psi	26.33	0.675	-0.003	2

B) 2000 imej

Jadual 5.25 Perbandingan keputusan *parameter tuning* bagi 2000 imej

Parameter	Purata	Purata	Min	Pangkat
	Ketepatan	Sisihan Piawai		Ketepatan
Sigma	22.67	0.160	0.910	5
Lambda	23.83	0.348	0.780	3
Theta	33.17	0.683	0.058	1
Gamma	22.15	0.155	0.838	4
Psi	25.33	0.675	-0.003	2

C) 3000 imej

Jadual 5.26 Perbandingan keputusan *parameter tuning* bagi 3000 imej

Parameter	Purata	Purata	Min	Pangkat
	Ketepatan	Sisihan Piawai		Ketepatan
Sigma	22.50	0.160	0.910	5
Lambda	22.72	0.348	0.780	4
Theta	33.50	0.683	0.058	1
Gamma	23.05	0.155	0.838	3
Psi	27.28	0.675	-0.003	2

5.4 KEPUTUSAN BARU GABOR-CNN

Hasil daripada *parameter tuning*, nilai-nilai tersebut akan digunakan untuk membina model Gabor-CNN yang baru dengan 1000 imej, 2000 imej dan 3000 imej. Jadual 5.27, Jadual 5.28 dan Jadual 5.29 menunjukkan keputusan bagi model tersebut.

A) 1000 imej

Jadual 5.27 Keputusan baru Gabor-CNN bagi 1000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	27.00	32.50	37.50	32.33
Sisihan Piawai	0.675	0.675	0.675	0.675
Min	-0.003	-0.003	-0.003	-0.003

Jadual 5.27 menunjukkan keputusan ketepatan, sisihan piawai dan min Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali theta dan psi bagi 1000 imej. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil. Ketepatan Gabor-CNN telah meningkat iaitu daripada 27.00% kepada 32.33%, dan melebihi ketepatan CNN iaitu 31.50%.

B) 2000 imej

Jadual 5.28 Keputusan baru Gabor-CNN bagi 2000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	33.25	28.75	41.50	34.50
Sisihan Piawai	0.675	0.675	0.675	0.675
Min	-0.003	-0.003	-0.003	-0.003

Jadual 5.28 menunjukkan keputusan ketepatan, sisihan piawai dan min Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali theta dan psi bagi 2000 imej. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil. Ketepatan Gabor-CNN telah meningkat iaitu daripada 26.25% kepada 34.50%, dan melebihi ketepatan CNN iaitu 33.50%.

C) 3000 imej

Jadual 5.29 Keputusan baru Gabor-CNN bagi 3000 imej

Keputusan	Test Run 1	Test Run 2	Test Run 3	Purata
Ketepatan (%)	29.50	36.83	30.67	32.33
Sisihan Piawai	0.675	0.675	0.675	0.675
Min	-0.003	-0.003	-0.003	-0.003

Jadual 5.29 menunjukkan keputusan ketepatan, sisihan piawai dan min Gabor-CNN yang menggunakan nilai statik bagi semua parameter Gabor kecuali theta dan psi bagi 3000 imej. Purata bagi ketepatan, sisihan piawai dan min selepas tiga test run diambil. Ketepatan Gabor-CNN telah meningkat iaitu daripada 21.50% kepada 32.33%, dan melebihi ketepatan CNN iaitu 27.17%.

Bagi lebih memahami kesan setiap parameter Gabor dan bagaimana ia membantu meningkatkan ketepatan model Alexnet , tiga model Alexnet dan tiga Gabor-Alexnet dibina untuk dilatih dan diuji pada 1000, 2000 dan 3000 gambar. Sebelum *parameter tuning*, Alexnet mengatasi ketepatan Gabor-Alexnet. Selepas *parameter tuning*, dan menemui parameter Gabor yang memberi impak iaitu theta dan psi, tiga model lain dibina menggunakan nilai-nilai tersebut. Model yang dilatih pada 2000 gambar mendapat yang tertinggi iaitu 34.50% dan mendapat prestasi lebih tinggi daripada Alexnet yang mendapat ketepatan sebanyak 33.50%, terdapat sedikit peningkatan dalam prestasi model.

6 KESIMPULAN

Sistem ini bertujuan untuk membantu dalam mengklasifikasi imej buah-buahan. Penambahbaikan yang dicadangkan bagi sistem ini ialah penambahan fungsi seperti pengesanan kualiti buah-buahan atau mengira dan mengukur buah-buahan dalam imej. Selain itu, penapis dalam lapisan konvolusi boleh dikaji dengan lebih mendalam dan digantikan dengan penapis lain kerana penapis merupakan antara mempengaruhi ketepatan klasifikasi imej.

7 RUJUKAN

- Avinash, S., Manjunath, K. & Kumar, S. S. 2016. An Improved Image Processing Analysis for the Detection of Lung Cancer Using Gabor Filters and Watershed Segmentation Technique. *2016 International Conference on Inventive Computation Technologies (ICICT)*, hlm. 1-6.
- Bargoti, S. & Underwood, J. 2017. Deep Fruit Detection in Orchards. *2017 IEEE International Conference on Robotics and Automation (ICRA)*, hlm. 3626-3633.
- Chen, L., Lu, G. & Zhang, D. 2004. Effects of Different Gabor Filters Parameters on Image Retrieval by Texture. 10th International Multimedia Modelling Conference, 2004. Proceedings., hlm. 273-278.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. & Fei-Fei, L. 2009. Imagenet: A Large-Scale Hierarchical Image Database. *2009 IEEE conference on computer vision and pattern recognition*, hlm. 248-255.
- Goodfellow, I., Bengio, Y. & Courville, A. 2016. *Deep Learning*. MIT press.
- Lecun, Y., Bengio, Y. & Hinton, G. 2015. Deep Learning. *nature* 521(7553): 436.
- Luan, S., Chen, C., Zhang, B., Han, J. & Liu, J. 2018. Gabor Convolutional Networks. *IEEE Transactions on Image Processing* 27(9): 4357-4366.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T. & Mccool, C. 2016. Deepfruits: A Fruit Detection System Using Deep Neural Networks. *Sensors* 16(8): 1222.
- Song, X., Liu, F., Yang, C., Luo, X. & Zhang, Y. 2015. Steganalysis of Adaptive Jpeg Steganography Using 2d Gabor Filters. *Proceedings of the 3rd ACM workshop on information hiding and multimedia security*, hlm. 15-23.

Özbulak, G. & Ekenel, H. K. 2018. Initialization of Convolutional Neural Networks by Gabor Filters. *2018 26th Signal Processing and Communications Applications Conference (SIU)*, hlm. 1-4.

Pham, L. 2019. Gabor Filter Initialization and Parameterization Strategies in Convolutional Neural Networks.

Copyright@FTSM