

DERMIFY: SISTEM PENCADANG PRODUK PENJAGAAN KULIT YANG SESUAI DENGAN JENIS KULIT BERASASKAN PEMBELAJARAN MENDALAM

Aina Nasuha Binti Ismail Zakri & Ts. Dr. Nor Samsiah Sani

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

ABSTRAK

Dermify bertujuan untuk membangunkan sistem cadangan produk penjagaan kulit yang disesuaikan dengan jenis kulit menggunakan teknologi pembelajaran mendalam. Masalah utama yang ingin diselesaikan ialah kesukaran pengguna, khususnya mereka yang mempunyai alahan kulit, untuk memilih produk yang sesuai tanpa risiko reaksi alergi. Sistem ini mencadangkan penyelesaian dengan mengintegrasikan model pembelajaran mendalam, mekanisme perhatian (*Attention Mechanism*) untuk analisis kulit wajah pengguna bagi mengelaskan profil kulit pengguna dengan produk yang tepat. Metodologi pembangunan mengikuti pendekatan CRISP-DM, bermula dengan pengumpulan data, pembersihan data, pembangunan model, dan evaluasi sistem. Jangkaan hasil projek adalah sistem yang dapat memberikan cadangan produk yang selamat dan tepat berdasarkan profil kulit pengguna, meningkatkan pengalaman pengguna dan mengurangkan risiko reaksi alahan.

Kata kunci: Sistem Pencadang, Pembelajaran Mendalam, Convolutional Neural Network, Aplikasi Mudah Alih

PENGENALAN

Pembelajaran mendalam adalah cabang canggih dalam pembelajaran mesin yang menggunakan rangkaian saraf tiruan berlapis untuk memecahkan dan menganalisis corak data yang rumit. Model pembelajaran mendalam sangat berguna dalam pelbagai aplikasi, seperti sistem cadangan, kerana mereka dapat secara automatik mengekstrak ciri-ciri dari data mentah dengan meniru cara otak manusia menganalisis maklumat. Dalam konteks penjagaan kulit, sistem ini menggunakan pembelajaran mendalam untuk meneliti tingkah laku dan keutamaan pengguna serta memberikan cadangan produk yang disesuaikan berdasarkan keperluan setiap pengguna. Dengan memanfaatkan set data besar mengenai interaksi pengguna-item, sistem ini secara dramatik meningkatkan relevansi dan ketepatan cadangan, yang seterusnya meningkatkan kepuasan dan penglibatan pengguna dengan rutin penjagaan kulit.

Penjagaan kulit merujuk kepada amalan mengekalkan dan meningkatkan kesihatan kulit melalui pelbagai produk, rawatan, dan rutin. Ia melibatkan pembersihan, pelembapan, dan perlindungan kulit, serta menangani masalah kulit tertentu seperti jerawat, kekeringan, penuaan, dan sensitiviti. Oleh itu, dengan menawarkan cadangan yang disesuaikan berdasarkan jenis kulit, keadaan, gaya hidup dan pilihan, pembelajaran mendalam meningkatkan penjagaan kulit. Ia menggunakan algoritma ramalan untuk meramalkan perubahan kulit, analisis imej untuk mengenal pasti masalah kulit, dan pemprosesan bahasa semula jadi untuk menilai bahan untuk alergen. Teknologi ini menjadikan rutin penjagaan kulit lebih proaktif dan disesuaikan dengan membantu pengguna dalam memilih produk yang sesuai, memberi amaran kepada mereka tentang kemungkinan alergen, dan mengubah suai cadangan dari semasa ke semasa untuk meningkatkan ketepatan dan keberkesanan.

Dalam industri penjagaan kulit, pemilihan produk yang sesuai dengan jenis kulit dan kepekaan individu adalah satu cabaran besar, terutamanya bagi mereka yang mempunyai alahan kulit. Produk kosmetik telah diketahui untuk menyebabkan tindak balas kulit kepada pengguna, akan tetapi disebabkan oleh tindak balas yang lambat, pengguna tidak mengesyaki bahawa tindak balas tersebut adalah disebabkan oleh bahan daripada produk yang digunakan (Bruusgaard et al., 2020). Terdapat 2 akibat disebabkan oleh kesalahan memilih produk penjagaan kulit, *Allergic Contact Dermatitis* (ACD) dan *Irritant Contact Dermatitis* (ICD). ACD adalah penyakit radang kulit yang disebabkan oleh tindak balas hipersensitiviti jenis 4


dan terhasil daripada sentuhan bahan kimia atau antigen yang menyinggung dengan kulit, dan tindak balas pengantaraan sel T (Murphy et al., 2023) manakala ICD adalah tindak balas tidak spesifik kulit terhadap kerosakan kimia langsung yang membebaskan mediator keradangan terutamanya daripada sel epidermis (Litchman, 2023). Walaupun terdapat banyak produk penjagaan kulit di pasaran, ketiadaan sistem cadangan yang berfokus pada keperluan alahan kulit menjadikan proses pemilihan produk yang selamat dan berkesan sukar dicapai.

Sistem cadangan berasaskan model pembelajaran mendalam yang dapat mengenal pasti jenis alahan kulit adalah penting untuk membantu pengguna membuat pilihan produk yang lebih selamat dan sesuai. Namun, cabaran utama adalah memastikan bahawa sistem ini mampu mengenal pasti tanda-tanda alahan kulit dengan tepat melalui model pembelajaran mendalam dan menggunakan mekanisme perhatian bagi membantu sistem pengecaman jenis kulit. Kajian yang telah dijalankan mendapati *Mekanisme perhatian* ini pada asalnya diperkenalkan dalam tugas *Natural Language Processing* (NLP) seperti terjemahan mesin dan diilhamkan oleh konsep visi biologi yang memfokuskan pada kawasan yang relevan. Mekanisme perhatian bukan sahaja meningkatkan prestasi, tetapi juga menawarkan cara untuk mentafsir rangkaian neural yang sukar difahami. Mekanisme ini akan membolehkan sistem memberi perhatian lebih kepada kawasan kulit yang lebih penting dan meningkatkan kebolehpercayaan klasifikasi (Galassi et al., 2020).

Projek ini akan membangunkan sistem cadangan berasaskan pembelajaran mendalam yang dapat mengenal pasti keperluan kulit setiap pengguna, seterusnya mencadangkan produk yang sesuai dan selamat. Projek ini juga akan memilih pembelajaran mendalam yang sesuai untuk mengenal pasti bahan-bahan yang berkemungkinan menyebabkan tindak balas alergi kepada pengguna. Pembelajaran mendalam telah dibuktikan boleh meningkatkan ketepatan dan kecekapan proses pengenalanpastian tindak balas alahan, yang mungkin memudahkan pengawasan dan panduan keselamatan pesakit masa nyata masa depan untuk kesilapan perubatan dan penambahbaikan sistem (Yang, 2020). Sistem ini boleh mengumpulkan data sejarah alahan pengguna dan menggunakan Mekanisme perhatian untuk memberi fokus kepada bahan produk yang berpotensi menyebabkan reaksi alahan, dengan bantuan analisis bahasa semula jadi (NLP) untuk mengenal pasti bahan alergenik dengan tepat. Pemilihan kaedah yang optimum juga akan membantu meningkatkan ketepatan cadangan produk yang sesuai berdasarkan profil kulit pengguna, memastikan pengguna dapat membuat pilihan produk penjagaan kulit yang lebih selamat dan berkesan.

METODOLOGI KAJIAN

Projek ini menggunakan kaedah metodologi 'Cross Industry Standard Process for Data Mining' atau lebih dikenali sebagai CRISP-DM. Metodologi ini digunakan secara luas dalam *data mining* dan analisis data untuk membantu dalam perancangan dan pelaksanaan projek analisis data. CRISP-DM juga dipilih bagi membantu dalam menawarkan pendekatan sistematik untuk memahami dan menyelesaikan masalah perniagaan menggunakan *data mining*, serta memastikan projek dijalankan secara teratur dan terkawal.



Rajah 1 Carta Alir CRISP-DM

Dalam langkah pertama fasa pembangunan sistem Dermify, fasa pemahaman dan pengumpulan data memainkan peranan penting dalam memahami keperluan sistem serta situasi sebenar penggunaan produk penjagaan kulit mengikut jenis kulit pengguna. Data yang dikumpulkan terdiri daripada imej wajah pengguna yang telah dilabelkan mengikut kategori kulit seperti normal, kering, dan berminyak, serta senarai produk penjagaan kulit berserta ramuan masing-masing. Sumber data diperoleh daripada platform atas talian seperti *Kaggle* yang dipercayai dan mempunyai kepelbagaian dari segi jenis kulit, pencahayaan, latar belakang, serta variasi wajah pengguna. Langkah ini amat penting bagi memastikan model dapat dilatih dengan data yang mewakili pelbagai keadaan sebenar pengguna, sekali gus meningkatkan ketepatan dan keberkesanan cadangan produk.

Dalam fasa pra-pemprosesan imej bagi sistem DERMIFY, beberapa langkah penting telah dilaksanakan untuk memastikan imej wajah pengguna berada dalam keadaan terbaik sebelum dimasukkan ke dalam model pembelajaran mendalam. Proses ini bermula dengan penetapan laluan data yang merujuk kepada direktori imej wajah yang telah disegmentasi mengikut kategori jenis kulit. Seterusnya, pelbagai pustaka sokongan seperti *'OpenCV'*, *'PIL'*, dan *'torchvision'* digunakan bagi membolehkan pemprosesan imej dan pembinaan dataset tersuai dilaksanakan dengan berkesan. Salah satu langkah utama dalam pra-pemprosesan ini adalah penggunaan teknik *Contrast Limited Adaptive Histogram Equalization* (CLAHE) yang berfungsi untuk meningkatkan kontras pada bahagian pencahayaan imej dalam ruang warna LAB. Teknik ini membantu menyerlahkan tekstur dan tona kulit tanpa mengubah maklumat warna asal, seterusnya membantu model mengenal pasti ciri-ciri penting pada kulit pengguna. Fungsi *'apply_clahe()'* digunakan untuk memproses setiap imej secara automatik sebelum ia dimasukkan ke dalam model.

Fasa pembangunan model pengecaman imej dalam sistem DERMIFY melibatkan beberapa langkah utama, bermula daripada pemilihan model, proses latihan, penilaian prestasi, sehingga integrasi ke dalam aplikasi sistem. Dalam projek ini, tiga model utama telah dipilih iaitu DenseNet121, EfficientNet-V2, dan MobileNet-V2. Pemilihan model-model ini dibuat berdasarkan kajian literatur dan kemampuan masing-masing dalam melaksanakan klasifikasi imej wajah secara cepat dan tepat, khususnya dalam konteks pengenalanpastian jenis kulit. DenseNet121 menampilkan seni bina dengan sambungan padat antara lapisan, yang membantu dalam pengaliran ciri dan pengurangan kehilangan maklumat semasa proses pembelajaran. EfficientNet-V2 pula merupakan versi terkini dengan pengoptimuman dalam prestasi dan kelajuan latihan, manakala MobileNet-V2 pula terkenal yang ia sangat praktikal dan efektif untuk pengecaman jenis kulit, terutamanya dalam sistem yang mengutamakan kecekapan dan kebolehlaksanaan masa nyata. Setiap model mempunyai struktur konvolusi dan parameter tersendiri yang memberi kelebihan tersendiri, membolehkan analisis menyeluruh dijalankan bagi menentukan model yang paling sesuai untuk digunakan dalam sistem DERMIFY.

Fasa pengujian dalam pembangunan sistem DERMIFY bertujuan untuk menilai prestasi model pembelajaran mendalam yang telah dilatih dalam mengenal pasti jenis kulit berdasarkan imej wajah pengguna. Tiga model utama iaitu DenseNet121, EfficientNet-V2, dan MobileNet-V2 telah diuji untuk membandingkan ketepatan, kestabilan, dan keberkesanan dalam tugas klasifikasi kulit. Pengujian dijalankan menggunakan kaedah *K-Fold Cross*

Validation dengan lima bahagian lipatan, bagi memastikan penilaian dilakukan secara menyeluruh terhadap keseluruhan dataset. Setiap model diuji menggunakan metrik prestasi seperti ketepatan, ketelitian, ingat semula, skor F1, dan matriks kekeliruan, bagi menilai sejauh mana model mampu mengenal pasti dengan betul kategori kulit normal, kering, dan berminyak. Proses pengujian turut melibatkan analisis visual menggunakan *Gradient-weighted Class Activation Mapping* (Grad-CAM), yang membantu memvisualisasikan kawasan wajah yang paling mempengaruhi keputusan model. Ini penting bagi memastikan model tidak membuat keputusan secara rawak dan bergantung kepada ciri kulit yang relevan.

Setelah model mencapai prestasi yang memuaskan, ia akan bergerak ke fasa seterusnya iaitu Fasa Pemilihan dan Penerbitan. Model yang dilatih akan diterapkan ke dalam sistem aplikasi. Integrasi dengan aplikasi membolehkan pengguna menggunakan sistem pencadang produk penjagaan kulit. Fasa ini juga memerlukan pemantauan yang berterusan untuk penambahbaikan pada masa hadapan. Hal ini kerana, model yang diterapkan juga perlu menjalani pemantauan berterusan untuk menilai prestasinya dalam senario dunia sebenar. Penilaian berkala, maklum balas dari pengguna akhir dan kemaskini berdasarkan data baru menyumbang kepada penambahbaikan berterusan, memastikan model kekal berkesan dan adaptif kepada perubahan persekitaran.

KEPUTUSAN DAN PERBINCANGAN


Aktiviti pengujian bagi kajian ini dilakukan dengan menggunakan dua teknik pengujian yang berbeza iaitu pengesahan model pembelajaran mendalam yang telah dilatih dan pengujian kotak hitam terhadap aplikasi yang telah diintegrasikan bersama model pembelajaran mendalam bagi tujuan pemantauan dan pengurusan data. Pengesahan model merupakan proses untuk menilai ketepatan dan prestasi model yang telah dibangunkan. Dalam proses ini, Laporan Klasifikasi (classification report) akan digunakan sebagai penanda aras dalam teknik pengesahan model. Manakala, Pengujian Kotak Hitam adalah pendekatan ujian sistem yang menilai kefungsian sistem tanpa menghiraukan struktur kod dalaman atau pelaksanaannya secara khusus. Kaedah ini hanya memfokuskan pada input dan output sistem, lalu bergantung sepenuhnya pada keperluan dan spesifikasi aplikasi. Berdasarkan keputusan yang diperolehi, dapat dilihat bagaimana model ini berfungsi dalam situasi dunia nyata dan sejauh mana ia mampu mencadangkan produk penjagaan kulit berdasarkan jenis kulit dengan betul. Keputusan ini penting untuk memahami kekuatan dan kelemahan model, serta langkah-langkah

penambahbaikan yang boleh diambil untuk meningkatkan prestasi model. Jadual 1 di bawah menunjukkan keputusan pengujian bagi tiga model pembelajaran mendalam yang telah dipilih dengan dua kadar pembelajaran yang berbeza.

Jadual 1 Keputusan pengujian antara model-model pembelajaran mendalam

Metrik & kadar Pembelajaran	EfficientNet-V2			DenseNet201			MobileNet-V2		
	Dry	Normal	Oily	Dry	Normal	Oily	Dry	Normal	Oily
Ketelitian	0.91	0.98	0.94	0.83	0.91	0.78	0.94	0.95	0.96
Ingat Semula	0.96	0.95	0.96	0.91	0.76	0.93	0.96	0.95	0.92
Skor F1	0.93	0.96	0.95	0.87	0.83	0.85	0.95	0.95	0.94
Ketepatan (Test Data)	0.95			0.85			0.94		

Berdasarkan hasil evaluasi, tiga model iaitu EfficientNet-V2, DenseNet201, dan MobileNet-V2 telah dibandingkan secara terperinci menggunakan metrik utama seperti ketelitian, ingat semula, skor F1, dan ketepatan keseluruhan untuk setiap kategori jenis kulit (kering, normal, dan berminyak). EfficientNet-V2 menunjukkan prestasi tertinggi secara keseluruhan, dengan nilai ketelitian antara 0.91 hingga 0.98, ingat semula antara 0.95 hingga 0.96, dan skor F1 setinggi 0.93 hingga 0.96 bagi ketiga-tiga jenis kulit. Ini menunjukkan bahawa model ini bukan sahaja konsisten dalam mengenal pasti semua kelas kulit, tetapi juga seimbang antara keupayaan mengenal pasti dan mengelakkan kesilapan.



Rajah 5.1 Matriks Kekeliruan bagi model EfficientNet-V2

Matriks kekeliruan di atas mewakili prestasi model EfficientNetV2 dalam mengklasifikasikan jenis kulit berdasarkan data ujian. Matriks ini menunjukkan perbandingan antara label sebenar dan label yang diramalkan oleh model bagi tiga kelas utama iaitu dry (kulit kering), normal (kulit normal), dan oily (kulit berminyak). Nilai pada diagonal matriks menunjukkan bilangan sampel yang diklasifikasikan dengan betul oleh model. Dalam kes ini, model telah berjaya mengenal pasti 129 kes dry, 207 kes normal, dan 112 kes oily dengan tepat.

Secara keseluruhan, prestasi model EfficientNetV2 adalah sangat baik dan seimbang. Metrik prestasi yang diperoleh daripada matriks kekeliruan ini seperti ketepatan (accuracy) sebanyak 0.95, ketelitian (precision) antara 0.91 hingga 0.98, ingat semula (recall) antara 0.95 hingga 0.96, dan skor F1 yang konsisten antara 0.93 hingga 0.96 menunjukkan bahawa model

ini sangat berkesan dalam pengecaman jenis kulit. Keupayaannya dalam mengekalkan prestasi tinggi bagi ketiga-tiga kelas menjadikannya pilihan yang sesuai untuk digunakan dalam sistem cadangan penjagaan kulit automatik yang boleh diharap dan tepat.

Bagi keputusan pengujian sistem pula, pengujian ini menumpukan pada input dan output sistem serta memastikan setiap komponen sistem memenuhi keperluan yang telah ditetapkan. Berikut adalah jadual keputusan pengujian kotak hitam untuk setiap kes pengujian yang dilakukan, di mana semua ujian telah lulus.

Jadual 2 Senarai status kes pengujian bagi fungsi utama sistem Dermify

ID Kes Pengujian	ID Fungsi	Fungsi yang diuji	Status (Lulus/Gagal)
D-001	DF-01	Memastikan pengguna boleh mendaftar akaun dengan betul dan maklumat disimpan dalam pangkalan data	Lulus
D-002	DF-02	Memastikan pengguna boleh log masuk menggunakan e-mel/katalaluan atau akaun Google	Lulus
D-003	DF-03	Memastikan sistem dapat mengenal pasti jenis kulit (kering, normal, berminyak) secara tepat	Lulus
D-004	DF-04	Memastikan pengguna boleh mengemaskini profil dan menyimpan perubahan dengan jayanya	Lulus
D-005	DF-05	Memastikan sistem dapat mencadangkan 5 produk terbaik berdasarkan jenis kulit dan bahan yang dielakkan	Lulus
D-006	DF-06	Memastikan sejarah analisis kulit dan cadangan produk disimpan secara automatik	Lulus
D-007	DF-07	Memastikan pengguna boleh log keluar dengan betul tanpa sebarang ralat	Lulus

Setiap pengujian untuk setiap fungsi sistem yang diuji telah berjaya melepasi ujian yang dilakukan dan menunjukkan bahawa sistem berfungsi seperti yang diharapkan.

CADANGAN PENAMBAHBAIKAN

Berdasarkan pelaksanaan dan penilaian projek Dermify, terdapat beberapa cadangan penambahbaikan yang boleh dilaksanakan pada masa hadapan bagi meningkatkan lagi keberkesanan, ketepatan, dan kebolehgunaan sistem. Cadangan ini bertujuan untuk

memperkuat fungsi sistem agar lebih responsif terhadap keperluan pengguna sebenar dan bersedia untuk digunakan secara meluas dalam industri penjagaan kulit.

Pertama, adalah dicadangkan agar saiz dan kualiti set data diperluas dengan melibatkan lebih banyak variasi jenis kulit, umur, latar belakang etnik, dan keadaan kulit yang berbeza. Ini akan membantu meningkatkan keupayaan generalisasi model pembelajaran mendalam serta mengurangkan risiko berat sebelah data (data bias). Kerjasama dengan pakar dermatologi atau institusi kesihatan boleh dipertimbangkan untuk mendapatkan data yang lebih sahih dan relevan.

Kedua, sistem boleh dipertingkatkan dengan mengintegrasikan pengesanan bahan alergenik secara automatik menggunakan teknik pemprosesan bahasa semula jadi (NLP) yang lebih canggih. Fungsi ini membolehkan analisis terperinci terhadap senarai ramuan produk, sekali gus memberi amaran kepada pengguna terhadap bahan-bahan yang berpotensi menyebabkan tindak balas alahan berdasarkan sejarah alahan atau profil kulit mereka.

Selain itu, pembangunan masa hadapan juga boleh memberi tumpuan kepada fungsi penjejak perubahan kulit dari masa ke masa. Ciri ini membolehkan pengguna memuat naik imej wajah secara berkala untuk melihat perkembangan atau kesan penggunaan produk yang disyorkan, serta membantu sistem menyesuaikan cadangan produk berdasarkan perubahan tersebut. Ini sekaligus meningkatkan aspek pemperibadian sistem dan membina hubungan jangka panjang antara pengguna dan aplikasi.

Dari sudut teknikal, cadangan masa hadapan juga melibatkan penggunaan model yang lebih ringan dan pantas seperti MobileNetV3 atau pengoptimuman model sedia ada menggunakan teknik kuantisasi dan pruning. Langkah ini dapat memastikan aplikasi Dermify berjalan lancar di pelbagai peranti mudah alih tanpa menjejaskan ketepatan pengesanan.

Akhir sekali, aplikasi Dermify boleh diperluas dari aspek fungsi interaktif dan sokongan pengguna. Contohnya, penambahan modul chatbot berasaskan AI untuk menjawab soalan berkaitan penjagaan kulit, forum komuniti untuk berkongsi pengalaman pengguna, serta integrasi dengan e-dagang untuk pembelian terus produk yang dicadangkan.

KESIMPULAN

Secara keseluruhannya, projek pembangunan Dermify telah berjaya direalisasikan dengan mencapai objektif utama iaitu membangunkan satu sistem cadangan produk penjagaan kulit yang diperibadikan berdasarkan jenis kulit pengguna menggunakan teknologi pembelajaran mendalam. Projek ini telah menggabungkan kekuatan model-model seperti EfficientNet-V2, DenseNet201, dan MobileNet-V2, serta elemen mekanisme perhatian (*attention mechanism*) untuk meningkatkan keupayaan pengesanan dan klasifikasi jenis kulit. Hasilnya, sistem dapat mencadangkan produk penjagaan kulit yang bukan sahaja sesuai, tetapi juga mengambil kira risiko alahan berdasarkan profil pengguna. Dalam aspek pembangunan, projek ini telah melalui proses yang menyeluruh bermula dari pengumpulan dan pemprosesan data, pembangunan serta penilaian model, hinggalah kepada penghasilan aplikasi mesra pengguna. Ujian keberkesanan dan soal selidik pengguna yang dijalankan menunjukkan bahawa sistem Dermify bukan sahaja berfungsi dengan baik dari sudut teknikal, tetapi juga diterima baik dari sudut pengalaman pengguna dengan tahap kepuasan yang tinggi.

Walaupun terdapat beberapa kekangan seperti keterbatasan data, kepelbagaian jenis kulit, dan keperluan pengoptimuman model, projek ini tetap membuktikan potensi besar untuk dikembangkan pada masa akan datang. Cadangan-cadangan seperti penambahan fungsi penjejak kulit, integrasi pengesanan bahan alergenik, serta peluasan data dan sokongan interaktif akan menjadikan Dermify lebih komprehensif dan mantap sebagai satu solusi penjagaan kulit pintar. Secara tuntas, Dermify bukan sekadar aplikasi teknikal, tetapi merupakan satu inisiatif ke arah memperkasakan pengguna untuk membuat keputusan yang lebih bijak, selamat dan disesuaikan dalam rutin penjagaan kulit mereka. Projek ini juga membuktikan bagaimana kecerdasan buatan dan pembelajaran mendalam dapat dimanfaatkan secara praktikal dalam kehidupan seharian, khususnya dalam bidang penjagaan kesihatan dan kesejahteraan individu.

PENGHARGAAN

Pertama sekali, saya ingin mengucapkan rasa syukur yang tidak terhingga kepada Illahi atas limpahan rahmat-Nya, petunjuk, dan kekuatan yang diberikan sepanjang perjalanan ini, sehingga saya berjaya menyiapkan projek tahun akhir ini dengan baik.

Seterusnya, saya ingin merakamkan setinggi-tinggi penghargaan kepada Dr. Nor Samsiah Sani, selaku penyelia projek tahun akhir saya, atas bimbingan, sokongan, dan kepakaran beliau yang sangat bernilai. Dorongan dan maklum balas yang diberikannya telah banyak membantu dalam membentuk arah dan kejayaan projek ini. Terima kasih juga yang tidak terhingga kepada beliau kerana sentiasa sabar dan tabah dalam membimbing dan mengajar saya sepanjang penyediaan projek ini.

Saya juga ingin menzahirkan rasa terima kasih yang tidak terhingga kepada ibu bapa dan ahli keluarga tercinta atas kasih sayang, doa, dan sokongan yang tidak pernah putus. Keprihatinan mereka menjadi sumber kekuatan terbesar saya sepanjang perjalanan ini. Penghargaan ini juga saya tujukan kepada rakan-rakan atas persahabatan, bantuan, dan motivasi mereka yang telah menjadikan perjalanan yang mencabar ini lebih bermakna dan menyenangkan.

Projek ini tidak akan dapat disempurnakan tanpa sumbangan dan sokongan daripada semua pihak. Terima kasih.

RUJUKAN

- 4.8 *reka bentuk Antaramuka Pengguna [f3.4]*. MySQA Portal. (2023a). <https://sqa.jdn.gov.my/index.php/ms/4-8-reka-bentuk-antaramuka-pengguna-f3-4>
- Amer, Abdalla, & Nguyen (2021). Enhancing recommendation systems performance using highly-effective similarity measures. *Knowledge-Based Systems*, 217, 106842.
- Blackley, Salem, & Zhou, (2023). Deep learning for detection of drug hypersensitivity reactions. *Journal of Allergy and Clinical Immunology*, 152(2), 350-352.
- Bo Jin, Leandro Cruz, & Nuno Goncalves. (2020). Deep Facial Diagnosis: Deep Transfer Learning From Face Recognition to Facial Diagnosis. *IEEE Access*, 8, 123649–123661. <https://doi-org.eresourcesptsl.ukm.remotexs.co/10.1109/ACCESS.2020.3005687>
- Brauwers, & Frasincar, (2021). A general survey on mekanisme perhatians in deep learning. *IEEE Transactions on Knowledge and Data Engineering*, 35(4), 3279-3298.
- Brooklyn, & Potter, CONVOLUTIONAL NEURAL NETWORKS (CNNs) FOR IMAGE RECOGNITION.
- Bruusgaard, Johansen, Zachariae, Kirkeby, & Garvey, (2020). Natural ingredients in cosmetic products—A suggestion for a screening series for skin allergy. *Contact Dermatitis* (01051873), 83(4), 251–270. <https://doi-org.eresourcesptsl.ukm.remotexs.co/10.1111/cod.13550>
- Buku Panduan KRISA*. MySQA Portal. (2023). <https://sqa.jdn.gov.my/index.php/ms/3-9-penentuan-keperluan-bukan-fungsian-f2-5>
- Fairley, 2019. Sci-Hub | Systems Engineering of Software - Enabled Systems, 201–240 | 10.1002/9781119535041.ch8. Sci-Hub.se. [https://sci-hub.se/https://ieeexplore.ieee.org/document/8826523 \[2019\]](https://sci-hub.se/https://ieeexplore.ieee.org/document/8826523 [2019])
- Falk, (2019). Practical recommender systems. Simon and Schuster.
- Galassi, Lippi, & Torroni, (2020). Attention in natural language processing. *IEEE transactions on neural networks and learning systems*, 32(10), 4291-4308.
- Ibm. (2024, December 2). *What are convolutional neural networks?*. IBM. <https://www.ibm.com/think/topics/convolutional-neural-networks>
- Jack, (2024). Improving Movie Recommendations Using Hybrid AI Systems: Leveraging Text-to-Number Conversion and Cosine Similarity (No. 12700). EasyChair.
- Jayaram, Reddy, Praneetha, Pujitha, Chandra, & Prakash, (2024). SMART COSMETICS RECOMMENDATION SYSTEM BASED ON SKIN CONDITION USING ARTIFICIAL INTELLIGENCE. *skin*, 53(5).
- Kavyashree, KV, Rasal, Jadhav, Saidireddy, & Kharade, (2022, December). Artificial Intelligence based Smart Cosmetics Suggestion System based on Skin Condition. In

2022 International Conference on Automation, Computing and Renewable Systems (ICACRS) (pp. 797-801). IEEE.

Kelleher, (2019). Deep learning. MIT press.

Ketkar, Moolayil, Ketkar, & Moolayil, (2021). Convolutional neural networks. *Deep learning with Python: learn best practices of deep learning models with PyTorch*, 197-242.

Lee, Yoon, Kim, Lee, Lee, & Yoo, (2024). Deep learning - based skin care product recommendation: A focus on cosmetic ingredient analysis and facial skin conditions. *Journal of Cosmetic Dermatology*, 23(6), 2066-2077. <https://doi-org.eresourcesptsl.ukm.remotexs.co/10.1111/jocd.16218>

Litchman, (2023, September 4). Contact dermatitis. StatPearls [Internet]. <https://www.ncbi.nlm.nih.gov/books/NBK459230/#:~:text=Irritant%20contact%20dermatitis%20is%20a,reaction%20to%20exogenous%20contact%20antigens>.

Murphy, (2023, July 13). Allergic contact dermatitis. StatPearls [Internet]. <https://www.ncbi.nlm.nih.gov/books/NBK532866/#:~:text=Allergic%20contact%20dermatitis%20is%20an,subsequent%20T%2Dcell%20mediated%20response>.

Nirupama, & Virupakshappa. (2024). Mobilenet-v2: An enhanced skin disease classification by attention and multi-scale features. *Journal of Imaging Informatics in Medicine*, 1-21.

Niu, Zhong, & Yu, (2021). A review on the mekanisme perhatian of deep learning. *Neurocomputing*, 452, 48-62.

Patil, S. N., Patil, H. D., Adhiya, K. P., & Patil, P. G. (2024). Densenet-201 for Skin Melanoma Classification: A Comprehensive Performance Evaluation and Analysis. *International Research Journal of Multidisciplinary Scope*, 5(4), 711-721.

Pinaya, Vieira, Garcia-Dias, & Mechelli, (2020). Convolutional neural networks. In *Machine learning* (pp. 173-191). Academic Press.

Quattrini, A., Boër, C., Leidi, T., & Paydar, R. (2022). A Deep Learning-Based Facial Acne Classification System. *Clinical, Cosmetic and Investigational Dermatology*, 15, 851–857. <https://doi.org/10.2147/CCID.S360450>

Saiwaeo, S., Arwatchananukul, S., Mungmai, L., Preedalikit, W., & Aunsri, N. (2023). Human skin type classification using image processing and deep learning approaches. *Heliyon*, 9(11).

Sangaiah, (Ed.). (2019). Deep learning and parallel computing environment for bioengineering systems. Academic Press.

Schröer, Kruse, & Gómez, (2021). A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, 181, 526-534.

Shiri, Perumal, Mustapha, & Mohamed, (2023). A comprehensive overview and comparative analysis on deep learning models: CNN, RNN, LSTM, GRU. arXiv preprint arXiv:2305.17473.

- Sze, Chen, Yang, & Emer, (2020). Efficient processing of deep neural networks. San Rafael: Morgan & Claypool Publishers.
- Thomas, & Jeba, (2024). A novel framework for an intelligent deep learning based product recommendation system using sentiment analysis (SA). *Automatika: Journal for Control, Measurement, Electronics, Computing & Communications*, 65(2), 410–424. <https://doi-org.eresourcesptsl.ukm.remotexs.co/10.1080/00051144.2023.2295148>
- Yang, (2020, December). An overview of the mekanisme perhatians in computer vision. In *Journal of physics: Conference series* (Vol. 1693, No. 1, p. 012173). IOP Publishing.
- Yang, Wang, Phadke, Wickner, Mancini, Blumenthal, & Zhou, (2020). Development and validation of a deep learning model for detection of allergic reactions using safety event reports across hospitals. *JAMA Network Open*, 3(11), e2022836-e2022836.
- Yang, Wang, Phadke, Wickner, Mancini, Blumenthal, & Zhou, (2020). Development and validation of a deep learning model for detection of allergic reactions using safety event reports across hospitals. *JAMA Network Open*, 3(11), e2022836-e2022836.
- Zhang, Lu, & Zhang, (2021). Recommender Systems in E-learning. *Journal of Smart Environments and Green Computing*, 1(2), 76-89.
- Zhao, Huang, Lv, Duan, Qin, Li, & Tian, (2020, November). Do RNN and LSTM have long memory?. In *International Conference on Machine Learning* (pp. 11365-11375). PMLR.