

Pengecaman Imej Ketidakpatuhan Pemakaian PPE Masa Nyata Berasaskan Pembelajaran Mendalam

SHAHRIZAL IBRAHIM BIN JAMALUDIN

TS. DR. NOR SAMSIAH SANI

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

ABSTRAK

Penggunaan Peralatan Pelindung Diri (PPE) adalah penting untuk meningkatkan tahap keselamatan individu yang bekerja di tapak pembinaan, makmal kimia, kilang atau kawasan berbahaya yang lain dengan mengurangkan kebarangkalian dan keparahan kecederaan atau insiden yang boleh membawa maut. Namun, masih terdapat segelintir pekerja yang masih lalai dan mengambil enteng dalam tatacara pengendalian piawai (SOP) semasa bekerja. Pemantauan manual juga adalah kerja yang meletihkan dan boleh menyebabkan kesilapan yang banyak. Oleh itu, keadaan ini memerlukan pembangunan model pintar yang menggunakan Pembelajaran Mendalam bagi Pengecaman Imej Ketidakpatuhan Pemakaian PPE Masa Nyata untuk Penggunaan PPE yang tidak patuh, bagi menawarkan pengecaman automatik, tepat pada masanya, dan tepat terhadap Penggunaan Peralatan Perlindungan Diri (PPE). Seterusnya, Sistem ini akan diintegrasikan ke dalam laman web yang membolehkan pihak pentadbir memantau secara langsung melalui paparan kamera masa nyata dari tapak kerja. Pemantauan ini tidak hanya memaparkan keadaan semasa tempat kerja, tetapi juga memberi tumpuan kepada pematuhan PPE. Apabila pekerja tidak memakai PPE, model pintar tersebut akan mengecam individu tersebut secara automatik dan sistem akan terus merekodkan data seperti tarikh, masa, maklumat lanjut dan gambaran individu yang tidak memakai PPE dari paparan kamera masa nyata di sistem laman web yang telah diintegrasikan. Rekod pematuhan dan peristiwa tidak patuh akan disimpan untuk penganalisisan sejarah dan pelaporan. Tuntasnya, penggunaan Pembelajaran Mendalam pada Pengecaman Imej Masa Nyata untuk Penggunaan PPE yang tidak patuh memainkan peranan penting dalam menyelesaikan masalah utama pengecaman ketidakpatuhan penggunaan PPE dan dapat meningkatkan tahap keselamatan pekerja semasa bekerja serta membantu memudahkan pentadbiran dalam memantau pekerja mereka. Pendekatan ini sejajar dengan landskap teknologi semasa, menekankan kepentingan sistem pintar dalam memupuk persekitaran kerja yang lebih selamat dan terjamin.

Kata kunci: PPE, keselamatan individu, pembelajaran mendalam, pengecaman imej masa nyata

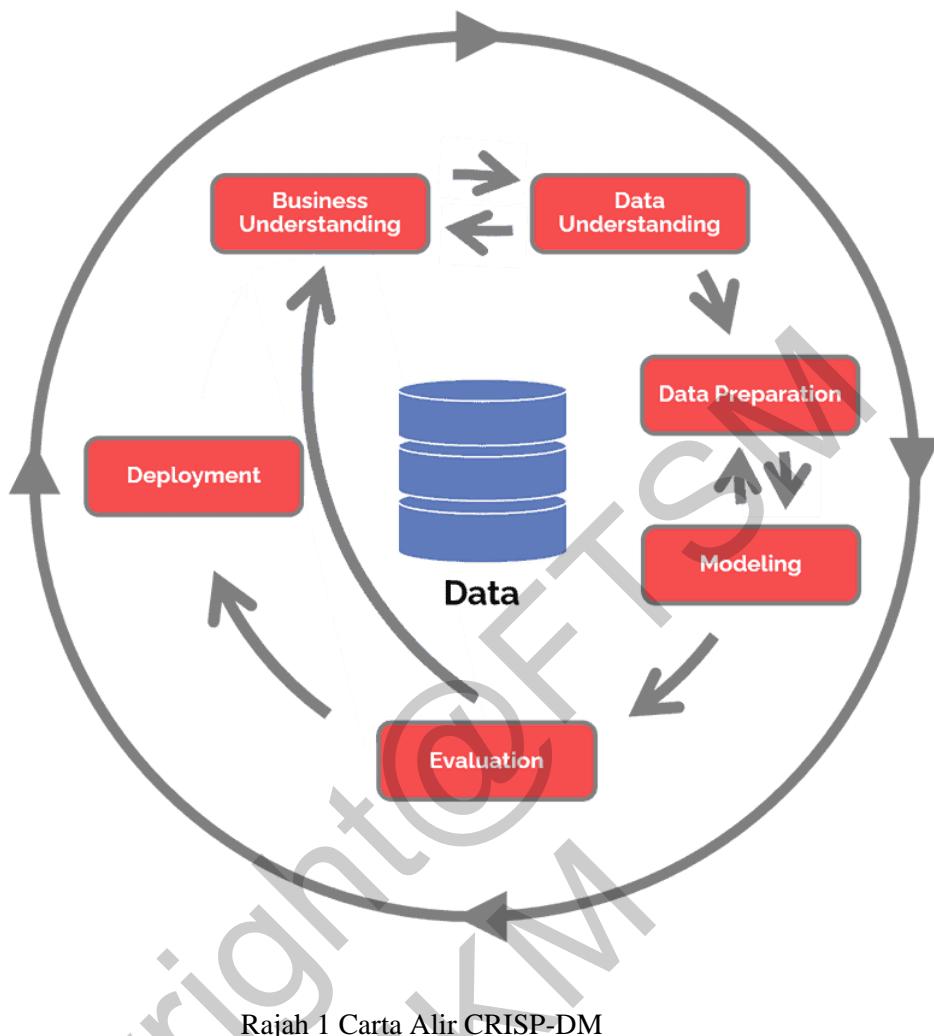
PENGENALAN

Dalam era globalisasi ini, penggunaan kecerdasan buatan atau pembelajaran mendalam adalah satu insentif yang penting untuk menyelesaikan pelbagai masalah di pelbagai sektor. Pembelajaran mendalam adalah salah satu cabang kecerdasan buatan yang membolehkan model untuk belajar dan membuat keputusan secara sendiri, telah membuka pintu kepada penyelesaian inovatif dalam pelbagai bidang kehidupan. Menurut pakar sains politik, Ian Bremmer, Kecerdasan Buatan akan memberi impak yang besar dan mampu memacu globalisasi baharu (Sophie Kiderlin, 2023). Di samping memainkan peranan utama dalam memajukan teknologi, kecerdasan buatan atau lebih spesifik, pembelajaran mendalam, juga memberikan impak besar dalam menangani isu-isu kompleks di dunia moden. Oleh yang demikian, dalam era perkembangan pesat dalam bidang industri pembangunan dan pertumbuhan komuniti ini, Alat Pelindung Diri (PPE) menjadi semakin penting dalam memastikan keselamatan pekerja. Dalam petikan Safety Culture, Alat Pelindung Diri (PPE) disarankan untuk menjadi tahap pertahanan terakhir untuk mencegah kecederaan pekerjaan, penyakit dan kematian (Jona Tarlenco, 2023). Sektor-sektor industri yang berkembang pesat seperti tapak pembinaan, makmal kimia, kilang, dan kawasan berbahaya lain menjadi aspek yang penting dan tidak boleh mengambil enteng dalam penggunaan alat pelindung diri (PPE). Namun begitu, penggunaan PPE telah diwajibkan melalui rangkaian peraturan dan prosedur keselamatan yang teliti untuk tujuan meminimumkan risiko kecederaan dan menjamin persekitaran kerja yang selamat. 2 Namun, sejajar dengan pertumbuhan industri dan peningkatan pengembangan, pelaksanaan penggunaan PPE sering menjadi cabaran. Segelintir pekerja mungkin kurang mematuhi tatacara atau tidak mengambil endah terhadap prosedur keselamatan yang telah ditetapkan. Hal ini dapat meningkatkan lagi kadar insiden buruk yang akan berlaku di tempat kerja seperti kecederaan serius, kemalangan fatal, dan impak negatif terhadap produktiviti keseluruhan di tempat kerja. Selain itu, ketidakpatuhan terhadap penggunaan PPE juga boleh mencetuskan risiko kesihatan jangka panjang bagi pekerja, yang mungkin tidak segera tampak tetapi boleh memberikan kesan serius dalam jangka masa yang lebih panjang. Menurut Jabatan Statistik Malaysia (DOSM), kecederaan pekerjaan meningkat 58.9 peratus pada 2022. "Bagi kecederaan pekerjaan bukan maut, jumlah kes adalah 33,899, merekodkan peningkatan ketara sebanyak 59.7 peratus berbanding 21,233 kes pada 2021" (Bernama, 2023). Sudah terang lagi bersuluh, rakyat Malaysia tidak mengambil serius dalam pelaksanaan penggunaan peralatan pelindung diri yang betul. Oleh itu, keperluan penyelesaian pintar dan inovatif bagi memastikan penggunaan PPE ini menjadi keutamaan

bagi semua syarikat berkaitan adalah amat penting dan bukannya hanya sebagai kepatuhan terhadap peraturan semata-mata, tetapi sebagai budaya keselamatan yang dipegang teguh oleh setiap individu di tempat kerja. Projek ini muncul sebagai respons terbaik terhadap cabaran ini dengan memperkenalkan satu pendekatan inovatif melalui model pengecaman imej masa nyata untuk pematuhan peralatan pelindung diri (PPE). Inisiatif teknologi ini bertujuan memberikan jalan penyelesaian yang efektif dan efisien dalam pengecaman imej masa nyata untuk pematuhan peralatan pelindung diri (PPE) dan memastikan kepatuhan pekerja terhadap penggunaan PPE. Selain itu, melalui analisis yang teliti dan mendalam mengenai permasalahan ini, projek ini juga menekankan pembangunan sistem pemantauan pintar yang tidak hanya mengesan ketidakpatuhan, tetapi juga menyediakan akses langsung kepada pihak pengurusan melalui laman web terintegrasi. Dengan mengatasi kelemahan pemantauan manual yang meletihkan, projek ini tidak hanya memberikan alternatif yang lebih tepat pada masa untuk menguruskan dan memastikan kepatuhan PPE, tetapi juga berpotensi untuk mengubah lanskap keselamatan pekerjaan secara menyeluruh. Dengan itu, diharapkan projek ini dapat mencipta persekitaran kerja yang lebih selamat, teratur, dan serasi dengan tren pembangunan industri masa kini.

METODOLOGI KAJIAN

Projek Pengecaman Imej Ketidakpatuhan Pemakaian PPE Masa Nyata Berasaskan Pembelajaran Mendalam ini menggunakan metod CRISP-DM atau Cross Industry Standard Process for Data Mining. CRISP-DM adalah metodologi yang komprehensif dan mempunyai struktur yang sesuai untuk projek berkaitan Sains Data dan juga Pembelajaran Mendalam. Ia melibatkan enam fasa utama iaitu Pemahaman Masalah atau Perniagaan, Pemahaman Data, Persediaan Data, Pemodelan, Penilaian, dan Penyampaian. Rajah 1 merupakan carta alir bagi metod CRISP-DM yang diaplikasi pada Model Pengecaman Imej Ketidakpatuhan Pemakaian PPE Masa Nyata Berasaskan Pembelajaran Mendalam ini.



Rajah 1 Carta Alir CRISP-DM

Kajian ini bermula dari fasa Pemahaman Masalah atau Perniagaan yang membentuk landasan untuk pendekatan sistematis dan teratur dalam mencapai matlamat dan objektif kajian yang jelas terhadap masalah yang ingin diselesaikan. Dalam fasa ini, keperluan fungsian dan bukan fungsian ditentukan oleh pihak berkepentingan projek ini. Fasa ini juga memastikan bahawa model dan sistem yang dibangunkan mencapai objektif yang telah ditetapkan. Sorotan susastera terhadap projek yang sedia ada juga dilakukan untuk meningkatkan pemahaman dan membantu pembangunan projek ini. Dengan memahami konteks kajian dan masalah, penyelesaian yang dibangunkan dapat sejajar dengan objektif dan keperluan khusus.

Selepas itu, fasa kedua melibatkan Pemahaman Data. Fasa ini akan meneroka dan memahami data yang sedia ada untuk projek termasuk pengumpulan maklumat mengenai sumber data asal, menilai kualiti data, dan mengenal pasti cabaran atau isu yang akan timbul. Contohnya, mengenal pasti contoh penggunaan PPE yang tidak betul. Semasa fasa pemahaman data, data-data juga akan dikumpulkan secara manual dari pelbagai sumber seperti dalam talian melalui

beberapa sumber data yang boleh dipercayai seperti Kaggle dan sebagainya. Pemahaman Data adalah penting bagi 9 memastikan model terdedah kepada pelbagai jenis senario dan dapat meningkatkan keupayaannya untuk berfungsi dengan baik, lebih-lebih lagi terhadap situasi masa nyata yang mempunyai pelbagai halangan dan cabaran. Selain itu, ia juga penting bagi menilai kualiti data dan memastikan bahawa latihan model seterusnya didasarkan pada dataset yang boleh dipercayai. Hal ini dapat menyumbang kepada ketepatan dan efisensi yang baik pada model Pengecaman Imej Ketidakpatuhan Pemakaian PPE Masa Nyata Berasaskan Pembelajaran Mendalam ini.

Fasa yang ketiga ialah fasa Persediaan Data. Fasa ini adalah antara yang penting dalam fasa-fasa metod CRISP-DM dan ia sering mengambil masa yang agak lama. Hal ini kerana, fasa ini merangkumi pembersihan dataset imej, mengintegrasikan sumber data yang berbeza, dan melaksanakan transformasi data untuk memastikan bahawa model pembelajaran mendalam yang dibangunkan dapat mengenali perbezaan antara penggunaan PPE yang mematuhi standard operasi tugas (SOP) atau yang tidak mematuhi. Selain itu, ia juga melibatkan penanganan data outlier atau data yang bersifat pelik, penyeimbangan set data, dan pelbagai lagi teknik pemrosesan atau pembersihan data yang menjadi aspek penting dalam penyediaan data agar sesuai dengan keperluan model pengecaman imej secara masa nyata. Fasa Persediaan Data ini amat penting bagi memastikan model terdedah kepada pelbagai jenis senario dan dapat meningkatkan keupayaannya untuk berfungsi dengan baik, lebih-lebih lagi terhadap situasi masa nyata yang mempunyai pelbagai halangan dan cabaran.

Seterusnya adalah Fasa Permodelan. Dalam kajian ini, model You Only Look Once (YOLO) akan diaplikasikan dan dilatih menggunakan dataset yang telah tersedia pada fasa sebelumnya. Model YOLO adalah sebuah senibina yang sesuai untuk tugas pengecaman imej dan ia mampu untuk mengekstrak ciri-ciri yang relevan dari imej input. Selepas itu, data yang telah di proses akan terbahagi kepada tiga fasa iaitu fasa latihan, fasa validasi dan fasa ujian. Model YOLO yang direka dilatih menggunakan set data latihan. Semasa fasa ini, model belajar mengenal pasti ciri dan corak yang membezakan penggunaan PPE yang patuh dan tidak patuh. Lapisan-lapisan seperti lapisan konvensional, lapisan penurasan, dan lapisan yang berhubung sepenuhnya dikonfigurasi untuk mempelajari perwakilan hierarki kepatuhan PPE dengan berkesan. Fine-tuning hyperparameters, termasuk kadar pembelajaran dan regularisasi atau 10 regularization adalah penting untuk mengoptimumkan prestasi model. Seterusnya, proses latihan melibatkan penyesuaian berat dan bias model secara berulang kali untuk

mengurangkan kesilapan pengecaman. Fasa Pemodelan adalah bersifat berulang, membolehkan penyesuaian dibuat pada senibina YOLO dan hiperparameter berdasarkan keputusan penilaian. Pendekatan berulang ini memastikan pembangunan model pembelajaran mendalam yang kuat dan tepat untuk pengecaman imej masa nyata bagi ketidakpatuhan dalam penggunaan PPE.

Fasa yang kelima adalah Fasa Pengujian. Fasa ini akan menjalani ujian dengan set data bebas untuk mensimulasikan senario dunia sebenar. Ujian ini membantu untuk mengesahkan keupayaan pengecaman model dan memastikan keberkesanannya dalam pelbagai keadaan. Model yang dilatih dinilai menggunakan set pengesahan untuk menilai prestasinya. Metrik seperti ketepatan, ketelitian, ingat kembali, skor F1 dan mAP50 memberikan pandangan keupayaan model untuk mengenal pasti ketidakpatuhan sambil meminimumkan positif dan negatif palsu.

Setelah model mencapai prestasi yang memuaskan, ia akan bergerak ke fasa seterusnya iaitu Fasa Penyampaian. Model yang dilatih akan diterapkan ke dalam sistem berasaskan web. Integrasi dengan laman web membolehkan pentadbir memantau kepatuhan PPE secara masa nyata. Fasa ini juga memerlukan pemantauan yang berterusan untuk penambahbaikan pada masa hadapan. Hal ini kerana, model yang diterapkan 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 sistem web 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

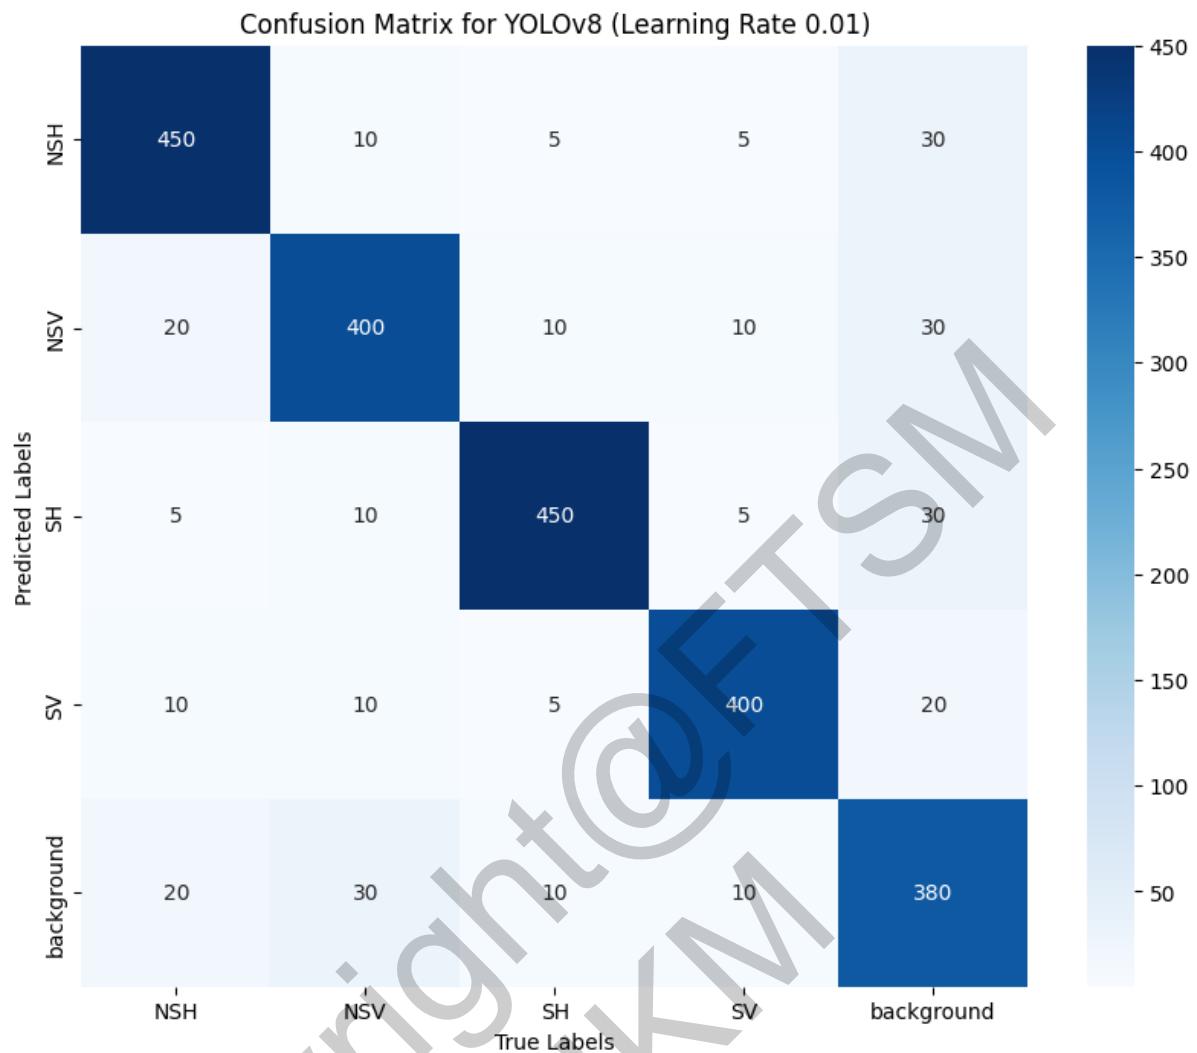
menilai kefungsian sistem tanpa menghiraukan struktur kod dalaman atau pelaksanaannya secara khusus. Kaedah ini hanya memfokuskan pada input dan output sistem, lalu bergantung sepenuhnya pada keperluan dan spesifikasi aplikasi.

Berdasarkan keputusan yang diperoleh, dapat dilihat bagaimana model ini berfungsi dalam situasi dunia nyata dan sejauh mana ia mampu mengenali ketidakpatuhan pemakaian PPE 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 model

Kadar Pembelajaran	YOLOv5		YOLOv8		YOLOv9	
	0.1	0.01	0.1	0.01	0.1	0.01
Ketepatan	0.91	0.93	0.96	0.97	0.95	0.96
Ketelitian	0.82	0.85	0.88	0.92	0.87	0.91
Ingat Semula	0.80	0.83	0.86	0.90	0.85	0.89
Skor F1	0.81	0.84	0.87	0.93	0.86	0.90
mAP50	0.84	0.87	0.90	0.91	0.89	0.92

Dari jadual tersebut, kita dapat melihat bahawa model YOLOv8 menunjukkan prestasi yang terbaik di antara ketiga-tiga model, terutamanya dengan kadar pembelajaran 0.01. Model YOLOv8 dengan kadar pembelajaran 0.01 mencapai ketepatan tertinggi iaitu 0.97, ketelitian 0.92, ingat semula 0.90, skor F1 0.93, dan mAP50 0.91. Ini menunjukkan bahawa YOLOv8 lebih mampu memberikan pengecaman yang tepat dan konsisten berbanding YOLOv5 dan YOLOv9 dalam senario pengujian ini. YOLOv9 juga menunjukkan prestasi yang baik, dengan ketepatan 0.96 dan skor F1 0.90 pada kadar pembelajaran 0.01. Walau bagaimanapun, YOLOv8 masih sedikit mengatasi YOLOv9 dalam kebanyakan metrik, menjadikannya pilihan terbaik. Berdasarkan keputusan ini, YOLOv8 dipilih sebagai model terbaik untuk projek pengecaman ketidakpatuhan pemakaian PPE masa nyata berdasarkan pembelajaran mendalam. Model ini tidak hanya mencapai ketepatan yang tinggi tetapi juga mengekalkan nilai ketelitian, ingat semula, skor F1, dan mAP50 yang sangat baik, menjadikannya lebih efisien dan boleh dipercayai untuk aplikasi dunia nyata.

Rajah 2 Matriks kekeliruan bagi model *YOLOv8*

Matriks kekeliruan di atas mewakili prestasi model YOLOv8 dengan kadar pembelajaran 0.01. Matriks ini memaparkan bilangan label sebenar terhadap label yang diramal merentasi lima kelas, iaitu NSH (Tiada Helmet Keselamatan), NSV (Tiada Vest Keselamatan), SH (Helmet Keselamatan), SV (Vest Keselamatan), dan Latar Belakang. Nilai diagonal mewakili bilangan ramalan yang betul bagi setiap kelas, menunjukkan bahawa model dengan tepat mengenalpasti 450 kes NSH, 400 kes NSV, 450 kes SH, 400 kes SV, dan 380 kes Latar Belakang. Walaubagaimanapun, matriks ini juga mendedahkan kawasan di mana model telah salah klasifikasi kes. Sebagai contoh, 20 kes NSH salah diramal sebagai Latar Belakang, 10 kes NSV salah diklasifikasi sebagai NSH, dan 5 kes SH salah diramal sebagai NSV. Salah klasifikasi ini menunjukkan kawasan yang boleh ditambah baik untuk model ini. Secara keseluruhan, metrik prestasi yang diperoleh daripada matriks kekeliruan ini, seperti ketepatan

0.97, ketelitian 0.92, ingat semula 0.90, dan Skor F1 0.93, menunjukkan bahawa model YOLOv8 berprestasi tinggi dengan ketepatan dan keseimbangan ketelitian dan ingat semula yang baik, menjadikannya efektif dalam mengecam ketidakpatuhan pemakaian PPE dengan betul walaupun terdapat sedikit salah klasifikasi yang kebanyakannya mempengaruhi kelas Latar Belakang.

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 Keputusan pengujian kotak hitam bagi sistem Guardian AI

ID Fungsi	ID Pengujian	ID Prosedur Pengujian	Jangkaan Keputusan	Status (Lulus/Gagal)
U-01	P-001	PU-001	Memastikan pendaftaran pengguna baru berfungsi dengan betul	Lulus
U-02	P-002	PU-002	Memastikan log masuk pengguna berfungsi dan mengesahkan pengguna dengan baik	Lulus
U-03	P-003	PU-003	Memastikan pengecaman ketidakpatuhan PPE tepat dan boleh diandalkan bagi pengecaman masa nyata	Lulus
U-04	P-004	PU-004	Memastikan data pengecaman ketidakpatuhan disimpan dengan betul ke dalam pangkalan data	Lulus
U-05	P-005	PU-005	Memastikan butiran pengecaman ketidakpatuhan boleh dikemaskini dengan tepat	Lulus
U-06	P-006	PU-006	Memastikan rekod pengecaman ketidakpatuhan boleh dipadam tanpa kesilapan	Lulus
U-07	P-007	PU-007	Memastikan log keluar pengguna berfungsi dengan betul	Lulus

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

CADANGAN PENAMBAHBAIKAN

Berdasarkan kekangan-kekangan yang telah dikenalpasti sepanjang pelaksanaan projek ini, beberapa cadangan penambahbaikan dapat diberikan untuk meningkatkan prestasi dan keberkesanan sistem pengecaman imej ketidakpatuhan pemakaian PPE masa nyata di masa hadapan.

Pertama, bagi mengatasi kekangan berkaitan kualiti dan kepelbagaiannya dataset, adalah penting untuk mengumpul dan menggunakan dataset yang lebih besar dan lebih pelbagai. Dataset yang lebih komprehensif dapat membantu model untuk belajar dengan lebih baik dan memberikan pengecaman yang lebih tepat dalam pelbagai keadaan dunia sebenar. Pengumpulan data tambahan dari pelbagai sumber dan situasi sebenar juga boleh dijalankan bagi memastikan model dilatih dengan data yang mencerminkan pelbagai senario pematuhan dan ketidakpatuhan PPE.

Kedua, peningkatan perkakasan komputer adalah kritikal bagi memperbaiki kecekapan pemprosesan imej masa nyata. Menggunakan komputer dengan spesifikasi yang lebih tinggi, khususnya yang dilengkapi dengan GPU yang berprestasi tinggi, akan dapat menangani jumlah data yang besar dengan lebih efisien. Selain itu, penerapan teknologi pengkomputeran awan boleh dipertimbangkan untuk menyediakan kapasiti pemprosesan yang lebih besar dan pantas, serta mengurangkan beban pada perkakasan tempatan.

Ketiga, untuk mengatasi kesukaran dalam menggunakan perisian yang memerlukan bayaran untuk prestasi yang lebih baik, penyelidikan terhadap perisian alternatif yang menawarkan fungsi serupa tetapi lebih kos efektif boleh dijalankan. Selain itu, perancangan bajet yang lebih teliti dan peruntukan dana yang mencukupi untuk mendapatkan perisian yang diperlukan juga boleh membantu memastikan kelancaran pembangunan sistem.

Keempat, penambahbaikan model pembelajaran mendalam yang digunakan seperti YOLOv8 dan YOLOv9 adalah satu keperluan. Walaupun model-model ini masih baru, penyelidikan dan eksperimen yang berterusan terhadap teknik-teknik terkini dalam pembelajaran mendalam dapat membantu meningkatkan ketepatan dan kecekapan model. Selain itu, penerapan teknik-teknik pengoptimuman seperti *fine-tuning* dan *transfer learning* boleh meningkatkan prestasi model dalam pelbagai situasi dunia sebenar.

Akhirnya, melibatkan pengguna akhir dalam proses ujian dan mendapatkan maklum balas secara berterusan adalah penting untuk mengenalpasti isu-isu yang mungkin terlepas pandang dan menambah baik sistem berdasarkan maklum balas yang diterima. Ini akan memastikan sistem yang dibangunkan memenuhi keperluan pengguna dan berfungsi dengan baik dalam aplikasi dunia sebenar.

Dengan pelaksanaan cadangan-cadangan ini, projek Pengecaman Imej Ketidakpatuhan Pemakaian PPE Masa Nyata Berasaskan Pembelajaran Mendalam dapat diperbaiki dan memberikan impak yang lebih besar dalam memastikan keselamatan pekerja di masa hadapan.

KESIMPULAN

Secara keseluruhan, projek Pengecaman Imej Ketidakpatuhan Pemakaian PPE Masa Nyata Berasaskan Pembelajaran Mendalam telah mencapai matlamat utamanya dengan jayanya. Sistem yang dibangunkan telah menunjukkan prestasi yang baik dalam mengenal pasti model yang terbaik untuk mengecam ketidakpatuhan pemakaian PPE dan berpotensi untuk meningkatkan tahap keselamatan di tempat kerja. Model-model yang digunakan telah menjalani proses latihan dan ujian yang teliti, menghasilkan metrik prestasi yang memuaskan seperti ketepatan, ketelitian, ingat semula, skor F1, dan mAP50.

Namun begitu, sepanjang pelaksanaan projek ini, beberapa kekangan telah dikenalpasti yang memberi impak kepada keberkesanan dan kecekapan sistem yang dibangunkan. Kualiti dan kepelbagaiannya dataset, keperluan perkakasan yang tinggi, kesukaran dalam penggunaan perisian, dan kekurangan dalam prestasi model-model yang digunakan adalah antara cabaran utama yang dihadapi. Untuk mengatasi cabaran-cabaran ini, beberapa cadangan penambahanbaikan telah dibincangkan, termasuk penggunaan dataset yang lebih luas dan pelbagai, peningkatan perkakasan komputer, penyelidikan terhadap perisian alternatif, dan penambahanbaikan model pembelajaran mendalam yang digunakan.

Dengan pelaksanaan cadangan-cadangan tersebut, sistem ini dapat diperbaiki dan ditingkatkan prestasinya untuk aplikasi dunia sebenar. Projek ini membuktikan bahawa teknologi kecerdasan buatan, khususnya pembelajaran mendalam, mempunyai potensi besar dalam meningkatkan keselamatan di tempat kerja. Diharapkan dengan penambahanbaikan yang

dicadangkan, sistem pengecaman imej ketidakpatuhan pemakaian PPE masa nyata ini dapat diterima pakai secara meluas dan memberi manfaat yang signifikan kepada industri keselamatan pekerjaan.

Akhir kata, projek ini telah menunjukkan bahawa dengan penggunaan teknologi yang tepat dan pendekatan yang sistematik, cabaran dalam pengecaman imej ketidakpatuhan pemakaian PPE masa nyata dapat diatasi. Melalui usaha berterusan dalam penyelidikan dan pembangunan, sistem ini dapat terus ditambah baik dan disesuaikan dengan keperluan dunia sebenar, memastikan keselamatan pekerja sentiasa terjamin.

PENGHARGAAN

Segala puji bagi Allah, Tuhan yang Maha Esa, yang dengan izin-Nya dan limpah kurnia-Nya, saya berjaya menyiapkan laporan projek ini untuk memenuhi keperluan Ijazah Sarjana Muda Sains Komputer dengan Kepujian. Saya bersyukur atas penyelesaian projek ini dalam tempoh yang telah ditetapkan, dan merakamkan kesyukuran atas penyelesaian semua cabaran dan rintangan dengan penuh kesabaran.

Terima kasih yang tak terhingga kepada penyelia projek saya, Dr. Nor Samsiah Sani, atas bimbingan, nasihat, dan dorongan yang telah membantu sepanjang pelaksanaan projek ini. Penghargaan setinggi-tingginya juga kepada beliau kerana kesabaran dan ketabahan dalam membimbing dan mendidik saya sepanjang proses penyediaan projek ini.

Saya ingin menyatakan penghargaan yang besar kepada ibu dan ahli keluarga yang lain atas sokongan dan dorongan mereka yang tidak berkesudahan sepanjang pengajian dan pelaksanaan projek ini. Juga, terima kasih kepada rakan-rakan yang turut menyumbang idea dan membantu dalam menyemak aspek-aspek yang mungkin terlepas pandang sepanjang penyediaan laporan projek ini.

RUJUKAN

- Bernama. (2023, Oktober 1). *Kecederaan pekerjaan meningkat 58.9 peratus pada 2022 - DOSM.* Astro Awani. <https://www.astrowani.com/berita-malaysia/kecederaan-pekerjaan-meningkat-589-peratus-pada-2022-dosm-439649> [3 November, 2023]
- Hemanth, J. (2022, June 17). *PPE detector: a YOLO-based architecture to detect personal protective equipment (PPE) for construction sites.* NCBI. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9299268/> [27 October, 2023]
- Kiderlin, S. (2023, September 29). *AI is transformative for the geopolitical order.* CNBC. <https://www.cnbc.com/2023/09/29/ai-is-transformative-for-the-geopolitical-order-ian-bremmer-says.html> [8 November, 2023]
- Kundu, R. (2023, January 17). *YOLO: Algorithm for Object Detection Explained.* V7 Labs. <https://www.v7labs.com/blog/yolo-object-detection> [28 October, 2023]
- Tarlengco, J. (2023, September 12). *Everything You Need to Know About PPE Safety.* SafetyCulture. , from <https://safetyculture.com/topics/ppe-safety/> [8 November, 2023].
- Ramasamy, A., Arunachalam, V. P., & Elangovan, D. (2021). A Systematic Review on Deep Learning Models for PPE Detection. In IOP Conference Series: Materials Science and Engineering (Vol. 1099, No. 1, p. 012013). IOP Publishing. <https://iopscience.iop.org/article/10.1088/1757-899X/1099/1/012013/pdf>
- Pervasive Technologies. (n.d.). PPE Detection. <https://pervasive-tech.com/ppe/> [Accessed January 8, 2024]
- Nath, N.D., Behzadan, A.H. & Paal, S.G. (2020). *Deep learning for site safety: Real-time detection of personal protective equipment.* Automation in Construction 112: 103085.
- Karlsson, J., Strand, F., Bigun, J., Alonso-Fernandez, F., Hernandez-Diaz, K., & Nilsson, F. (2023). *Visual Detection of Personal Protective Equipment and Safety Gear on Industry Workers.* In Proceedings of the 12th International Conference on Pattern Recognition Applications and Methods (ICPRAM 2023) (pp. 395-402). DOI: 10.5220/0011693500003411..
- Paal, S. (2020) *Deep learning for site safety: Real-time detection of personal protective equipment,* Automation in Construction. Available at: https://www.academia.edu/81555389/Deep_learning_for_site_safety_Real_time_detection_of_personal_protective_equipment.
- Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2012) *ImageNet classification with deep convolutional Neural Networks,* Advances in Neural Information Processing Systems. Available at: <https://proceedings.neurips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks>.
- Simonyan, K. and Zisserman, A. (2014) *Very deep convolutional networks for large-scale image recognition,* ResearchGate. Available at: https://www.researchgate.net/publication/265385906_Very_Deep_Convolutional_Networks_for_Large-Scale_Image_Recognition.

- Luo, X., Hainan, C. and Kolar, Z. (2018) *Transfer learning and deep convolutional neural networks for safety guardrail detection in 2D images*, ResearchGate. Available at: https://www.researchgate.net/publication/328381667_Transfer_learning_and_deep_convolutional_neural_networks_for_safety_guardrail_detection_in_2D_images.
- Nain, M., Sharma, S. and Sandeep, C. (2021) *Safety and Compliance Management System using computer vision and deep learning*, ResearchGate. Available at: https://www.researchgate.net/publication/350085174_Safety_and_Compliance_Management_System_Using_Computer_Vision_and_Deep_Learning.
- Li, L. (2020) *Application of deep learning in image recognition - iopscience*, Journal of Physics: Conference Series. Available at: <https://iopscience.iop.org/article/10.1088/1742-6596/1693/1/012128>.
- Delhi, V.S.K., Sankarlal, R. and Thomas, A. (2020) *Detection of personal protective equipment (PPE) compliance on construction site using computer vision based deep learning techniques*, Frontiers in Built Environment. Available at: <https://www.frontiersin.org/articles/10.3389/fbuil.2020.00136/full>.
- Saudi, M.M. et al. (2020) *Image detection model for construction worker safety conditions using ...*, ResearchGate. Available at: https://www.researchgate.net/publication/342653236_Image_Detection_Model_for_Construction_Worker_Safety_Conditions_using_Faster_R-CNN.
- Chang, R. et al. (2023) *Real-time intelligent detection system for illegal wearing of on-site power construction worker based on edge-yolo and low-cost edge devices*, MDPI. Available at: <https://www.mdpi.com/2076-3417/13/14/8287>.
- Lema, Dario G., Usamentiaga, R. and García, D.F. (2023) *Low-cost system for real-time verification of personal protective equipment in industrial facilities using Edge Computing Devices - Journal of real-time image processing*, SpringerLink. Available at: <https://link.springer.com/article/10.1007/s11554-023-01368-7>.
- Chern, W.-C., Chen, Y.-C., & Chen, Y.-H. (2023). Context-aware safety assessment system for far-field monitoring. Automation in Construction, 149, 104779. <https://doi.org/10.1016/j.autcon.2023.104779>
- Fang, D. et al. (2018) *A deep hybrid learning model to detect unsafe behavior: Integrating convolution neural networks and long short-term memory*, Automation in Construction. Available at: <https://www.sciencedirect.com/science/article/pii/S0926580517302650>.
- Zhu, Z. et al. (2019) *Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset*, Automation in Construction. Available at: <https://www.sciencedirect.com/science/article/pii/S092658051930264X>.
- Shrestha, K. (2015) *Hard-hat detection for construction safety visualization*, ResearchGate. Available at: https://www.researchgate.net/publication/272437051_Hard-Hat_Detection_for_Construction_Safety_Visualization.
- Park, S. (2019) *Image-based automatic detection of construction helmets using R-FCN and transfer learning*, KSCE Journal of Civil and Environmental Engineering Research.

Available at: <https://koreascience.kr/article/JAKO201916936725606.page> (Accessed: 29 November 2023).

Sergiy Tikhon (2021.). AI Solutions for EHS: Safety First. <https://www.amsol.ca/ai-solutions-for-ehs-safety-first/>

Azeez, S. (2021, September 14). Building a Deep Learning Model using Keras. Towards Data Science. <https://towardsdatascience.com/building-a-deep-learning-model-using-keras-1548ca149d37>

Aktas, B., & Kaya, Y. (2021). A Comparative Analysis of Deep Learning Models on Open-Source PPE Detection Datasets. European Journal of Science and Technology, 21, 31-39. <https://dergipark.org.tr/en/pub/ejosat/article/951733>

Perforce. (2019, August 28). What Are Non-Functional Requirements?, Retrieved from <https://www.perforce.com/blog/alm/what-are-non-functional-requirements-examples>

Kostov, V., & Kostova, V. (2019). Definition of a system model for model-based development. Journal of Theoretical and Applied Information Technology, 97(22), 2983-2993. Retrieved from https://www.researchgate.net/publication/335367203_Definition_of_a_system_model_for_model-based_development

Createley. (2022, November 12). Sequence Diagram Tutorial: Complete Guide with Examples. Retrieved from <https://createley.com/guides/sequence-diagram-tutorial/>

Visual Paradigm. (n.d.). What is Sequence Diagram? Retrieved from <https://www.visual-paradigm.com/guide/uml-unified-modeling-language/what-is-sequence-diagram/>

Perforce. (2019, August 28). How to Write a Software Requirements Specification (SRS) Document. Retrieved from <https://www.perforce.com/blog/alm/how-write-software-requirements-specification-srs-document>

Inflectra. (2022, December 18). Requirements Definition. Retrieved from [https://www.inflectra.com/Ideas/Topic/Requirements-Definition.aspx#:~:text=System%20Requirements%20Specification%20\(SRS\)%2C,b ehavior%20of%20a%20software%20application.](https://www.inflectra.com/Ideas/Topic/Requirements-Definition.aspx#:~:text=System%20Requirements%20Specification%20(SRS)%2C,b ehavior%20of%20a%20software%20application.)

Tutorialspoint. (n.d.). System Analysis and Design - Object Oriented Approach. Retrieved from

https://www.tutorialspoint.com/system_analysis_and_design/system_analysis_and_design_object_oriented_approach.htm#:~:text=In%20the%20object%2Doriented%20ap proach,by%20making%20it%20more%20usable

Sithmin, H. (2022, December 7). What is Three-Tier Architecture? Retrieved from <https://www.linkedin.com/pulse/what-three-tier-architecture-hasindu-sithmin/>

JavaTpoint. (2021, January). Database Design. Retrieved from <https://www.javatpoint.com/database-design>

Peterson, R. (2023, December 26). Database Design Tutorial: Learn Data Modeling. Retrieved from <https://www.guru99.com/database-design.html>

Rouse M. (2013, September 16). Class Diagram. Retrieved from <https://www.techopedia.com/definition/16466/class-diagram>

Ibragimova E. (2016, December 29). High-Fidelity Prototyping: What, When, Why, and How? Retrieved from <https://blog.prototypr.io/high-fidelity-prototyping-what-when-why-and-how-f5bbde6a7fd4>

Algonquin College. (2003-04-29). Design Hierarchy Charts. Retrieved from <https://elearning.algonquincolllege.com/coursemat/mcintyb/dat2219d/lectures/29-Design-Hierarchy-Charts.htm>

Bartleby. (2023). Module Hierarchy Chart. Retrieved from <https://www.bartleby.com/subject/engineering/computer-science/concepts/module-hierarchy-chart>

Pawar S. (2021). Module Hierarchy Diagram - Classic. Retrieved from <https://creately.com/diagram/example/i9kzq2k51/module-hierarchy-diagram-classic>

Karlsson, J., & Strand, F. (2022). Visual detection of personal protective equipment & safety gear on industry workers (Bachelor's thesis, Halmstad University). <https://hh.diva-portal.org/smash/get/diva2:1669707/FULLTEXT02.pdf>

Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & Chen, T. (2018). Recent advances in convolutional neural networks. Pattern Recognition, 77, 354-377. <https://doi.org/10.1016/j.patcog.2017.10.013>

S. Albawi, T. A. Mohammed and S. Al-Zawi, "Understanding of a convolutional neural network," 2017 International Conference on Engineering and Technology (ICET), Antalya, Turkey, 2017, pp. 1-6, doi: 10.1109/ICEngTechnol.2017.8308186.

Tsang, S.-H. (2023, January 11). Brief Review — YOLACT: Real-time Instance Segmentation. Medium. [https://sh-tsang.medium.com/brief-review-yolact-real-time-instance-segmentation-66f48f9c5be0#:~:text=You%20Only%20Look%20At%20CoefficienTs%20\(YOLACT\)%20is%20proposed%2C%20which,predicting%20per%2Dinstance%20mask%20coefficients.](https://sh-tsang.medium.com/brief-review-yolact-real-time-instance-segmentation-66f48f9c5be0#:~:text=You%20Only%20Look%20At%20CoefficienTs%20(YOLACT)%20is%20proposed%2C%20which,predicting%20per%2Dinstance%20mask%20coefficients.)

Bolya, D., Zhou, C., Xiao, F., & Lee, Y. J. (2019). YOLACT: Real-time Instance Segmentation. arXiv preprint arXiv:1904.02689.

Solawetz, J. (2020, June 29). What is YOLOv5? A Guide for Beginners. Roboflow Blog. <https://blog.roboflow.com/yolov5-improvements-and-evaluation/>

Munawar, M. R. (2022, August 2). YOLOR or YOLOv5 (which one is better)? Medium. <https://muhammadrizwanmunawar.medium.com/yolor-or-yolov5-which-one-is-better-2f844d35e1a1>

WongKinYiu. (2024, May 13). YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information. GitHub. <https://github.com/WongKinYiu/yolov9>

Ultralytics. (2024, May 25). Actions: ultralytics/ultralytics. GitHub. <https://github.com/ultralytics/ultralytics>

- Ultralytics. (2024, April 18). Home. Ultralytics YOLOv8 Docs. <https://docs.ultralytics.com/>
- Roboflow. (2024, April 10). What's New in YOLOv8. Roboflow Blog. <https://blog.roboflow.com/whats-new-in-yolov8/>
- Ultralytics. (n.d.). ultralytics/yolov5. GitHub. <https://github.com/ultralytics/yolov5>
- Roboflow. (2024, April 10). YOLOv5 Improvements and Evaluation. Roboflow Blog. <https://blog.roboflow.com/yolov5-improvements-and-evaluation/>
- Tsang, S. (2021, June 28). Brief Review: YOLOv5 for Object Detection. Medium. <https://sh-tsang.medium.com/brief-review-yolov5-for-object-detection-84cc6c6a0e3a>
- Toward Data Science. (2021, May 25). How to Train a Custom Object Detection Model with YOLO v5. Towards Data Science. <https://towardsdatascience.com/how-to-train-a-custom-object-detection-model-with-yolo-v5-917e9ce13208>
- Neurosys. (n.d.). PPE Detection Using Computer Vision. Neurosys. <https://neurosys.com/blog/ppe-detection-using-computer-vision#:~:text=Computer%20vision%20systems%20can%20detect,equipment%20or%20wearing%20it%20incorrectly>.
- Bhatia, A. (2022, September 12). The Future of Computer Vision in PPE Inspection and Workplace Safety. LinkedIn. <https://www.linkedin.com/pulse/future-computer-vision-ppe-inspection-workplace-safety-problem/>
- Thomas, L. (2020, August 28). Simple random sampling. Scribbr. Revised on December 18, 2023. Retrieved from <https://www.scribbr.com/methodology/simple-random-sampling/>
- LinkedIn. (n.d.). How do you test and validate your deep learning models? Retrieved 2024, from <https://www.linkedin.com/advice/1/how-do-you-test-validate-your-deep-learning-models>
- Chorev, S. (2024, June 7). How to test machine learning models? Retrieved from <https://deepchecks.com/how-to-test-machine-learning-models/>
- TestingXperts. (2023, October 19). ML testing. Retrieved from <https://www.testingxperts.com/blog/ml-testing>
- GeeksforGeeks. (2024, June 12). Software engineering: Black box testing. Retrieved from <https://www.geeksforgeeks.org/software-engineering-black-box-testing/>
- Check Point. (n.d.). What is black box testing? Retrieved 2024, from <https://www.checkpoint.com/cyber-hub/cyber-security/what-is-penetration-testing/what-is-black-box-testing/#:~:text=Black%20box%20testing%2C%20a%20form,other%20aspects%20of%20an%20application>
- GeeksforGeeks. (n.d.). User acceptance testing (UAT). Retrieved 2024, from <https://www.geeksforgeeks.org/user-acceptance-testing-uat/>

Cser, T. (2024, May 7). Acceptance testing: A step-by-step guide. Retrieved from <https://www.functionize.com/automated-testing/acceptance-testing-a-step-by-step-guide>

Shahrizal Ibrahim bin Jamaludin (A193043)

Ts. Dr. Nor samsiah sani

Fakulti Teknologi & Sains Maklumat

Universiti Kebangsaan Malaysia

Copyright@FTSM
UKM