

Integrasi Pembelajaran Mendalam YOLOv9m dan Penglihatan Komputer Klasik bagi Pengenalpastian Struktur Gelembung Plasma Khatulistiwa daripada Keogram ROTI

(Integration of YOLOv9m Deep Learning and Classical Computer Vision for Equatorial Plasma Bubble Structure Identification from ROTI Keograms)

Idahwati Sarudin^{a*}, Mohamad Haniff Junos^{b*}, Nurul Shazana Abdul Hamid^{c,d}, Mardina Abdullah^{d,e}, & Logesh Kumar Selvakumar^a

^a*School of Physics, Universiti Sains Malaysia, 11800 USM, Pulau Pinang, Malaysia,*

^b*School of Aerospace Engineering, Tuanku Syed Sirajuddin Engineering Campus, Universiti Sains Malaysia, 14300 Nibong Tebal, Pulau Pinang, Malaysia*

^c*Department of Applied Physics, Faculty of Science and Technology,*

^d*Space Science Centre (ANGKASA), Institute of Climate Change,*

^e*Department of Electrical, Electronic and Systems Engineering, Faculty of Engineering and Built Environment, Universiti Kebangsaan Malaysia, 43600 Bangi, Malaysia*

^{*}*Corresponding author: idahwati@usm.my, haniffjunos@usm.my*

Received 13 November 2025, Received in revised form 30 April 2026

Accepted 30 May 2026, Available online 30 August 2026

ABSTRAK

Aplikasi pembelajaran mendalam untuk mengenal pasti gelembung plasma khatulistiwa (EPB) daripada keogram Kadar Perubahan Jumlah Kandungan Elektron (ROTI) masih kurang diterokai. Kajian ini membentangkan pendekatan hibrid yang menggabungkan pembelajaran mendalam dan penglihatan komputer klasik untuk mengenal pasti struktur EPB dalam keogram ROTI. Kaedah yang dicadangkan menggunakan model YOLOv9m untuk mengesan EPB dalam data imej, menghasilkan kotak sempadan di sekitar kawasan yang dikesan. Teknik penapisan warna kemudiannya digunakan untuk mengeluarkan hingar latar belakang dan mengecualikan EPB bertindih dalam satu pengesanan, memastikan pengasingan tepat untuk EPB yang utama. Analisis pasca pengesanan mendedahkan contoh berbilang komponen dalam kotak sempadan tunggal, dengan jarak antara komponen yang diukur antara 9.22 hingga 148.82 piksel. Tambahan pula, EPB yang dikenal pasti mempamerkan kelajuan hanyut yang berbeza-beza: EPB 1 menunjukkan gerakan hampir pantas (purata sesaran: 47.67 piksel/30 min jangka hayat: >300 minit), EPB 2 memaparkan gerakan pantas (58.00 piksel/30 min; jangka hayat: >180 minit) dan EPB 3 menunjukkan gerakan perlahan (30.80 piksel/30 min; jangka hayat >180 minit). Berdasarkan hasil pengesanan dan pencerian awal yang diperolehi daripada set latihan 462 data ini, kerja masa hadapan akan menumpukan pada analisis menyeluruh untuk menilai secara kuantitatif ciri-ciri EPB menggunakan model pembelajaran mendalam yang dibentangkan.

Kata kunci: Gelembung plasma khatulistiwa; pembelajaran mendalam; YOLO; pengesanan warna

ABSTRACT

The application of deep learning for identifying equatorial plasma bubbles (EPBs) from Rate of Total electron content Index (ROTI) keograms remains underexplored. This study presents a hybrid approach combining deep learning and classical computer vision to identify EPB structures in ROTI keograms. The proposed method employs the YOLOv9m model to detect EPBs in image data, generating bounding boxes around detected regions. A color filtering technique is then applied to remove background noise and exclude overlapping EPBs within a single detection, ensuring accurate isolation of the primary EPB. Post-detection analysis revealed instances of multiple components within single bounding boxes, with measured inter-component distances ranging from 9.22 to 148.82 pixels. Furthermore, identified EPBs exhibited varying drift speeds: EPB 1 showed near-fast motion (average displacement: 47.67 pixels/30 min; lifespan: >300 min), EPB 2 displayed fast motion (58.00 pixels/30 min; lifespan: >180 min) and EPB 3 showed slow motion (30.80 pixels/30 min; lifespan >180 min). Based on the detection and initial thinning results obtained from this 462-image dataset, future work will focus on comprehensive analysis to quantitatively evaluate EPB characteristics using the proposed deep learning model.

>300 minutes), EPB 2 displayed fast motion (58.00 pixels/30 min; lifespan: >180 minutes), and EPB 3 demonstrated slow motion (30.80 pixels/30 min; lifespan: >180 minutes). Building upon these initial detection and characterization results obtained from a 462-data training set, future work will focus on extensive analysis to quantitatively assess EPB characteristics using the presented deep learning model.

Keywords: Equatorial plasma bubbles; deep learning; YOLO; color detection

PENGENALAN

Gelembung plasma khatulistiwa (EPB) ialah struktur ionosfera berskala besar yang dicirikan oleh pengurangan ketumpatan elektron yang ketara, selalunya memanjang sehingga ~1500 km sepanjang garis medan magnet. Lazimnya diperhatikan di kawasan khatulistiwa dan latitud rendah selepas Matahari terbenam (Sarudin et al. 2024). Tingkah laku EPB telah disiasat menggunakan pelbagai instrumen, termasuk *ionosonde* (Rastogi, 1980 mengenai sebaran khatulistiwa yang bermusim, Saito dan Maruyama, 2002 mengenai kebolehubahan harian, dan Wang et al. 2019 mengaitkan sintilasi dengan data dari pelbagai instrumen), penderia in situ, satelit, radar, dan bacaan sintilasi yang membawa kepada kajian meluas tentang tempoh evolusi dan pembangunan ruang. Pengimej dihadkan oleh keadaan cuaca (Ma et al. 2023) dan satelit memberikan liputan global, pengukuran mereka adalah in situ dan bergantung kepada laluan. *Ionosonde* dan radar berasaskan dasar juga mempunyai had ruang (Barros et al. 2018). Akibatnya, banyak kajian menggunakan pelbagai teknik pengesanan EPB untuk meningkatkan kebolehpercayaan dan liputan pengukuran. Data daripada sistem satelit navigasi global (GNSS) turut digunakan untuk mengenal pasti kejadian EPB, khususnya melalui analisis parameter seperti keogram ROTI (Githio et al. 2024). Kajian ini membentangkan pendekatan hibrid yang menggabungkan kaedah pembelajaran mendalam dan teknik penglihatan komputer klasik bagi mengenal pasti struktur EPB dalam keogram kadar perubahan jumlah kandungan elektron (ROTI) yang diperoleh daripada data cerapan GPS.

Penggunaan teknik pembelajaran mendalam telah menjadi alat yang berkuasa dalam memajukan pengesanan, pengelasan, ramalan dan analisis kajian EPB. Pendekatan terdahulu kebanyakannya bergantung pada pemprosesan pasca imej cahaya teja (*airglow images*) yang diperoleh daripada pengimej seluruh langit (ASI) menggunakan perisian seperti MATLAB dan SCILAB (Srisamoodkham et al. 2021). Selain itu, penyelidik membangunkan kaedah untuk menukar imej piksel ASI kepada koordinat geografi untuk menambah baik analisis ruang (Srisamoodkham et al. 2021).

Rangkaian neural konvolusi (CNN) telah diperkenalkan untuk mengautomasikan pengesanan EPB dalam imej ASI dengan model seperti YOLOv3-tiny telah mencapai output yang menjanjikan (Srisamoodkham et al. 2021). Mesin vektor sokongan (SVM), selalunya digabungkan dengan teknik seperti penguraian nilai tunggal (SVD) atau ciri berasaskan CNN, telah digunakan untuk mengklasifikasikan EPB dalam imej pandangan pantas radar frekuensi yang sangat tinggi (VHF) (Thanakulketsarat et al. 2023). Model CNN juga dicadangkan untuk mengesan dan mengklasifikasikan jenis EPB daripada imej ionogram rangkaian penderia ionosfera latitud rendah (LISN) radar ionosfera berdenyut tumbukan menegak (VIPIR), mencapai ketepatan tinggi dan model garis dasar yang mengatasi prestasi seperti VGG16, VGG19, *Res-Net18* dan *Inception-V3* (Yacoub et al. 2024).

Selain pengesanan, ramalan ciri EPB juga telah diterokai menggunakan model pembelajaran mesin. Model hutan rawak (RF) telah digunakan untuk menganggarkan halaju hanyutan zonal dan meramalkan kedalaman EPB berdasarkan input seperti hari dalam setahun, masa sejagat, foF2, dan indeks suria (Githio et al. 2024; Adawa et al. 2025). Model lain seperti rangkaian memori jangka pendek panjang (LSTM), XGBoost, dan pendekatan pembelajaran mendalam menggunakan data okultasi radio (RO), telah menunjukkan peningkatan dalam meramal dan mengklasifikasikan parameter berkaitan EPB berbanding kaedah tradisional (Adawa et al. 2025; Chen 2025). Walaupun trend semasa menunjukkan peralihan ke arah automasi penuh menggunakan model pembelajaran mendalam end-to-end, penggunaan kaedah penglihatan komputer klasik dalam kajian ini kekal kritikal. Integrasi teknik klasik seperti penapisan warna dan analisis komponen bersambung (CCA) berfungsi sebagai kekangan pengetahuan domain yang memperhalusi output pengesanan. Pendekatan hibrid ini bukan sahaja mengekalkan tahap automasi sistem, malah memberikan kelebihan dari segi ketepatan penempatan dan kebolehjelasan fizikal yang lebih tinggi berbanding model *black box* sepenuhnya, terutamanya dalam menapis ralat positif palsu akibat gangguan latar belakang yang kompleks.

Secara keseluruhannya, organisasi penyelidikan yang semakin berkembang menyerlahkan kepentingan

pembelajaran mendalam dalam mengautomatiskan kajian EPB. Usaha termasuk meramalkan indeks gelembung ionosfera (IBI) (Reddy et al. 2023), meningkatkan pengesanan dan anggaran kedalaman menggunakan teknik lanjutan (Adawa et al. 2025), dan menyiasat faktor luaran seperti aktiviti geomagnet dan suria yang mempengaruhi pembangunan EPB (Githio et al. 2024). Ringkasnya, kandungan literatur tentang EPB adalah luas, menggunakan pelbagai teknik pemerhatian dan kaedah analisis. Terdapat penekanan yang semakin meningkat pada pembelajaran mendalam untuk mengautomatiskan pengesanan, mengelaskan kejadian, meramalkan tingkah laku EPB, dan menganggar parameter utama seperti halaju dan kedalaman hanyutan.

Pendekatan hibrid yang menggabungkan pembelajaran mendalam dengan teknik penglihatan komputer klasik menawarkan alternatif yang praktikal dan boleh ditafsirkan untuk sistem AI berlapis dalam analisis pengimejan. Kaedah pemprosesan imej konvensional seperti perduaan, analisis komponen bersambung, pengesanan gumpalan, segmentasi morfologi, dan ambang warna telah digunakan secara meluas dalam pemprosesan imej untuk pelbagai tujuan penglihatan komputer (Szeliski 2022). Beberapa kajian baru-baru ini telah menunjukkan bahawa gabungan model pembelajaran mendalam dengan teknik pemprosesan imej boleh mengekstrak ciri struktur dan parameter objek dengan ketepatan tinggi (Chitale et al. 2020; Mushtaq et al. 2023; KT et al. 2025). Teknik penglihatan komputer tradisional dalam kaedah hibrid menawarkan kelebihan dari segi kerumitan pengiraan yang lebih rendah, keperluan data yang lebih sedikit, serta lebih mudah untuk ditafsir dan dilaksanakan (Mellouli et al. 2019; Georgiou et al. 2020; O'Mahony et al. 2020). Struktur ini juga membolehkan penambahbaikan pantas terhadap bahagian tertentu dalam saluran pemprosesan tanpa perlu melatih semula keseluruhan rangkaian, yang sangat berguna apabila menyesuaikan sistem kepada set data atau kaedah pengimejan yang baharu (O'Mahony et al. 2020). Walaupun penggunaan AI secara berlapis kekal sebagai strategi berdaya maju dalam aplikasi yang memerlukan penaakulan berbilang langkah atau pengekstrakan ciri yang sangat abstrak, kaedah hibrid menyediakan keseimbangan antara prestasi dan kebolehtafsiran dalam domain seperti penyelidikan EPB di mana pemahaman fizikal dan ketelusan metodologi sering diutamakan.

Walaupun teknik hibrid telah menunjukkan peningkatan dalam pengesanan EPB, isu kehilangan maklumat semasa pengekstrakan ciri dan beban pengiraan yang tinggi masih menjadi cabaran utama. Bagi meningkatkan keberkesanan model hibrid yang dicadangkan, kajian ini menyepadukan YOLOv9m sebagai algoritma pengekstrakan ciri dan pengesanan teras. Melalui integrasi blok konvolusi yang diparameter semula seperti

RepNCSPeLAN, model ini berupaya menangkap perincian tekstur EPB yang kompleks dengan lebih berkesan. Keupayaan YOLOv9m dalam mengesan objek bersaiz kecil dan sederhana tanpa meningkatkan beban komputasi secara drastik menjadikannya calon yang ideal untuk memastikan ketepatan pengesanan yang tinggi berbanding model-model sebelumnya.

KAEDAH DAN ANALISIS KAJIAN

Bahagian ini menggariskan pendekatan yang digunakan untuk mengesan dan memperhalusi pengecaman EPB menggunakan model pembelajaran mendalam dan penapisan warna. Bahagian 2.1 meninjau secara ringkas set data EPB yang digunakan dalam eksperimen, termasuk butiran tentang anotasi. Bahagian 2.2 menerangkan penggunaan model YOLOv9m untuk pengesanan awal EPB, memfokuskan pada output pengesanan dan penjaan kotak sempadan. Bahagian 2.3 memperkenalkan proses penyempurnaan tiga langkah untuk mengasingkan EPB utama dalam setiap pengesanan, meningkatkan tafsiran tempoh melalui segmentasi saluran warna, dan menganalisis perkembangan serta taburan EPB sepanjang masa.

PENYEDIAAN SET DATA

Kajian ini melaporkan kaedah automasi dalam menyiasat kejadian EPB menggunakan ukuran kadar perubahan jumlah kandungan elektron (ROTI), yang diperoleh daripada kira-kira 127 stesen dalam rangkaian GPS di seluruh Asia Tenggara (SEA), termasuk rangkaian sistem satelit navigasi global (GNSS) Malaysia (MyRTKnet), bagi tempoh antara 2011 hingga 2013. Metodologi pemprosesan data ini adalah selari dengan prosedur yang telah diperincikan dalam kajian Sarudin et al. (2024), yang berfungsi sebagai rujukan utama bagi instrumen dan stesen yang terlibat. Melalui pendekatan ini, keogram ROTI menyediakan maklumat penting seperti longitude geografi ($95^{\circ} - 120^{\circ} \text{ T}$), variasi jumlah kandungan elektron (TEC), waktu sejagat (00 – 20 UTC), dan jarak mendatar (0 – 2500 km). Dalam spektrum warna data asal, sebarang nilai HSV yang setara dengan 0.3 hingga 1.0 TECU/min pada skala ROTI diklasifikasikan sebagai EPB, manakala nilai HSV di luar julat tersebut dianggap sebagai hingar. Set data terdiri daripada 462 imej, di mana setiap EPB dianotasi secara manual menggunakan perisian *Labelimg*. Proses anotasi dilakukan berdasarkan kriteria kotak sempadan paling padat di mana setiap kotak dilukis merangkumi keseluruhan struktur fizikal EPB bagi meminimumkan ruang latar belakang yang tidak berkaitan dalam anotasi tersebut. Set data dibahagikan kepada set latihan (70%)

dan set pengesahan (30%) untuk pembangunan dan penilaian model.

PENGESANAN EPB MENGGUNAKAN MODEL YOLOV9M

1. Gambaran Keseluruhan Model YOLOv9m


Kajian ini menggunakan model YOLOv9m (Wang et al. 2024), iaitu varian bersaiz sederhana yang direka untuk mengimbangi kecekapan pengiraan dengan ketepatan tinggi bagi mengesan EPB yang mempunyai variasi saiz serta tekstur kompleks. Seni bina model ini seperti yang ditunjukkan dalam Rajah 1, terdiri daripada tiga komponen utama yang dilaraskan mengikut keperluan pengesanan tersebut.

Rangka utama bertanggungjawab untuk mengekstrak ciri hierarki daripada imej input, bermula dengan lapisan konvolusi asas dan seterusnya melalui modul-modul lanjutan seperti blok RepNCSPeLan4 dan AConv. Modul RepNCSPeLan4 merupakan evolusi dari modul asal Rangkain Agregasi Lapisan Cepak (ELAN) (Wang et al. 2023). Komponen ini meningkatkan perwakilan ciri dan mengekalkan butiran ruang yang penting bagi memastikan struktur fizikal EPB dapat dibezakan daripada latar belakang yang serupa. Di bahagian bawah tulang belakang, modul SPPELAN mengukuhkan lagi ciri ruang dengan memperoleh maklumat terperinci dan global (Wang et al. 2024).

Bahagian leher berfungsi untuk mengagregatkan ciri berskala dengan mencantumkan output dari pelbagai peringkat yang berbeza dalam rangka utama. Operasi penyambungan dan pensampelan semula memastikan ciri-ciri penting dikekalkan untuk mengesan objek EPB yang kecil atau yang berada pada jarak jauh. Struktur leher mengadaptasi konsep Rangkaian Agregasi Laluan (PAN) (Liu et al. 2018) yang disatukan dengan blok RepNCSPeLan dan AConv. Integrasi komponen ini bertujuan untuk memperhalusi pengekstrakan ciri-ciri imej sebelu dihantar ke bahagian kepala pengesanan. Bagi mengoptimumkan pengesanan objek pada pelbagai skala, YOLOv9m menggunakan struktur bahagian kepala terpisah yang terdiri daripada tiga lapisan output sepadan dengan resolusi berbeza iaitu 52×52 , 26×26 , dan 13×13 (Ge et al. 2021). Integrasi ciri pada pelbagai skala ini amat kritikal memandangkan saiz fizikal EPB dalam imej mungkin berbeza bergantung kepada jarak kamera. Lapisan ini mengeluarkan kotak sempadan, label kelas dan skor keyakinan untuk output pengesanan akhir.

2. Penilaian Prestasi

Pelbagai metrik prestasi digunakan untuk menilai keberkesanan pengesanan EPB yang berpandukan imej keogram ROTI. Kepekaan mengukur kebarangkalian mengesan objek sebenar dengan tepat, manakala kepersisan menilai ketepatan ramalan yang dikenal pasti. Lengkung kepersisan-kepekaan secara berkesan menggambarkan pertukaran antara kepersisan dan kepekaan. Takrifan untuk kepekaan dan kepersisan dinyatakan dalam Persamaan 1 dan 2. Skor F1, yang dilambangkan dalam Persamaan 3, menggabungkan kedua-dua kepersisan dan kepekaan menjadi satu purata harmonik. Positif benar (TP) merujuk kepada objek yang dikenal pasti dengan tepat, manakala positif palsu (FP) mewakili objek yang dikenal pasti secara tidak tepat, dan negatif palsu (FN) menunjukkan objek yang tidak dikenal pasti sama sekali. Kawasan di bawah lengkung kepersisan-kepekaan pada pelbagai ambang pengesanan ditentukan oleh kepersisan purata (AP), yang dikira menggunakan Persamaan 4. Selain itu, saiz model menunjukkan keperluan penyimpanannya, manakala operasi titik terapung giga (GFLOPs) mengukur kerumitan pengiraan yang dikaitkan dengan model.



RAJAH 1. Seni bina model YOLOv9m.

$$\text{Kepekaan} = \frac{TP}{TP + FN} \quad (1)$$

$$\text{Kepersisan} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Skor } F1 = \frac{2 \times \text{Kebersihan} \times \text{Kepekaan}}{\text{Kebersihan} + \text{Kepekaan}} \quad (3)$$

$$AP = \int_0^1 \text{Kebersihan}(\text{Kepekaan}) d\text{Kepekaan} \quad (4)$$

3. Persediaan Eksperimen

Eksperimen pengesanan EPB telah dijalankan menggunakan Google Colab T4 GPU. Rangka kerja Ultralytics telah digunakan untuk melatih model berasaskan YOLO. Untuk memastikan konsistensi dalam output eksperimen, hiperparameter piawai telah digunakan terhadap semua model berasaskan YOLO. Imej input telah diubah saiznya kepada 416×416 piksel, dan saiz kelompok 64 telah dipilih. Kadar pembelajaran, momentum dan pereputan masing-masing ditetapkan pada 0.001, 0.937, dan 0.0005. Proses latihan menggunakan pengoptimum Anggaran Momen Adaptif dengan Pereputan Pemberat (AdamW), dan model telah dilatih selama 200 kitaran latihan.

PENAMBAHBAIKAN EPB DAN PENAPISAN TEMPOH MASA

PENYINGKIRAN HINGAR LATAR BELAKANG DAN PENAPISAN EPB BERTINDIH


Subseksyen ini membentangkan teknik pasca pemprosesan yang digunakan untuk memperhalusi output pengesanan. Kaedah penapisan berasaskan warna digunakan untuk menyekat elemen latar belakang dan menghapuskan EPB tambahan yang dikesan secara salah dalam satu kotak sempadan, bagi memastikan hanya EPB utama diasingkan untuk tujuan analisis.

Peringkat awal melibatkan proses kunci kroma, yang menghilangkan hingar latar belakang dan mengasingkan EPB yang muncul sebagai satu gumpalan dalam imej. Hingar latar belakang mengandungi warna yang mempunyai keamatan piksel yang serupa dengan warna EPB. Oleh itu, menapis hingar ini akan meningkatkan proses pengesanan warna dalam langkah seterusnya. Pertama, imej merah, hijau, biru (RGB) ditukar kepada ruang warna HSV. Dalam ruang ini, julat warna tertentu yang mewakili warna latar belakang dan kawasan bukan nombor (NaN) (seperti biru

langit, putih, kelabu dan hitam) ditukar kepada putih. Proses ini menjadikan warna yang disasarkan, iaitu warna EPB, kelihatan hitam. Menggunakan fungsi dalam julat OpenCV, warna yang ditentukan diberikan warna putih, manakala semua warna lain dijadikan hitam, seterusnya menghasilkan lapisan binari. Dalam lapisan ini, EPB kelihatan hitam, manakala kawasan bukan EPB juga kelihatan hitam.

Seterusnya, lapisan binari ini diterbalikkan menggunakan operasi *bitwise* OpenCV 'NOR,' yang menukar warna kawasan putih menjadi hitam, dan kawasan hitam menjadi putih. Akibatnya, warna EPB bertukar putih, manakala semua warna yang tidak diingini dipaparkan sebagai hitam. Selepas itu, imej binari terbalik menjalani penapisan kedekatan untuk mengekstrak struktur EPB yang sah dalam kotak sempadan tertentu yang dijana oleh model YOLOv9m. Proses ini bertujuan untuk menghapuskan EPB yang bertindih di dalam kotak sempadan. Mula-mula, garisan pepenjuru dilukis dari sudut Barat Daya ke sudut Timur Laut di dalam kotak sempadan. Orientasi pepenjuru ini dianggap sebagai orientasi tipikal struktur EPB kerana ia selari dengan sifat fizikal EPB yang terpesong ke arah Timur semasa ia meningkat naik ke altitud yang lebih tinggi, akibat daripada interaksi antara hanyutan plasma ke arah Timur dan rintangan atmosfera.

Garis pepenjuru ini berfungsi sebagai garis rujukan utama untuk memilih EPB yang betul dan menapis EPB yang bertindih. Untuk mencapai matlamat ini, analisis komponen bersambung (CCA) digunakan untuk mengesan semua gumpalan putih, kemudian menetapkan titik pusat untuk setiap gumpalan, dan jarak setiap titik pusat ke garisan pepenjuru dikira. Gumpalan yang mempunyai jarak terpendek ke garis pepenjuru dianggap sebagai EPB sebenar, seperti yang ditunjukkan dalam Rajah 2. Walau bagaimanapun, beberapa gumpalan tidak disambungkan, walaupun data mentah adalah sebahagian daripada satu struktur EPB. Untuk memasukkan gumpalan ini, operasi morfologi seperti penutupan digunakan untuk menggabungkan struktur yang berdekatan untuk memastikan hanya gumpalan yang berterusan secara ruang dan konsisten dari segi arah yang kekal. Selepas gumpalan yang betul dikesan menggunakan kedekatannya dengan garis pepenjuru, gumpalan lain menjadi hitam. Kaedah ini secara berkesan menapis EPB bertindih yang tidak eksklusif untuk kotak sempadan yang diberikan. Imej binari akhir kemudiannya dilapis dengan kroma untuk menghasilkan imej RGB akhir.



RAJAH 2. Penapisan EPB bertindih

PENSAMPELAN LAJUR DAN PENGESANAN GUMPALAN BERASASKAN RONA BERBILANG SALURAN

Dalam langkah ini, lajur piksel tertentu dipilih untuk pemprosesan imej selanjutnya. Setiap lajur piksel dipisahkan dengan selang 30 minit apabila diperhatikan dalam imej asal. Potongan lajur ini kemudiannya tertakluk kepada paparan saluran berbilang rona, yang kemudiannya diduakan. Saluran warna termasuk merah, kuning (gabungan merah dan hijau), hijau, sian (gabungan hijau dan biru), dan biru. Dalam konteks ini, merah, hijau dan biru mewakili saluran tulen, manakala kuning dan sian ialah saluran komposit yang dicipta untuk tujuan pemprosesan. Imej RGB divisualisasikan dalam setiap saluran, mempamerkan rona yang paling ketara; contohnya, dalam saluran merah, warna yang paling menonjol ialah merah. Setiap saluran warna diduakan menggunakan nilai ambang masing-masing: 195 untuk merah, 146 untuk kuning, 190 untuk hijau, 207 untuk sian dan 238 untuk biru. Sebarang keamatan warna yang berada di bawah ambang akan dipaparkan sebagai hitam, manakala keamatan yang melebihi ambang akan dipaparkan sebagai putih, menghasilkan imej binari khas untuk setiap saluran. Akibatnya, warna-warna sasaran akan muncul sebagai gumpalan putih dalam imej binari masing-masing. Contohnya, dalam imej binari saluran merah, warna merah diwakili sebagai gumpalan putih; perkara yang sama berlaku untuk warna kuning, hijau, sian dan biru. Pendekatan ini memudahkan pengesanan warna kepada masalah pengesanan gumpalan tradisional.

Pengesanan gumpalan melalui analisis komponen bersambung (CCA) kemudiannya digunakan untuk mengenal pasti warna dalam semua lajur piksel yang dipilih. Proses ini bermula dengan saluran merah dan diteruskan secara berurutan ke saluran biru. Mula-mula, lajur diimbas dalam imej binari saluran merah untuk memeriksa sebarang gumpalan putih. Jika gumpalan putih

dikesan, titik pusat gumpalan itu ditandakan dan pemeriksaan warna selanjutnya ditamatkan. Jika tiada gumpalan putih dikesan dalam saluran merah binari, prosedur yang sama digunakan pada saluran kuning, diikuti dengan saluran hijau, sian dan biru mengikut urutan. Setelah gumpalan warna dikenal pasti dalam mana-mana saluran terdahulu, tiada pemeriksaan warna tambahan dilakukan. Kaedah ini digunakan serentak pada semua lajur piksel, membolehkan pengesanan yang cekap bagi warna paling ketara dalam lajur tertentu. Walau bagaimanapun, setiap lajur hendaklah hanya mempunyai satu penanda. Oleh itu, langkah seterusnya diperlukan bagi memastikan perkara ini.

PENAPISAN LONJAKAN LUAR BIASA DAN ANOTASI GARIS TRAJEKTORI SETIAP 30 MINIT

Fasa terakhir memfokuskan pada menapis nilai luar biasa, membuat anotasi dan menggambarkan perkembangan EPB yang dikesan. Bagi setiap gumpalan berwarna yang dikesan, satu titik putih yang diisi diletakkan pada titik pusat pada imej asal EPB. Untuk mengekalkan trend bermakna bagi titik-titik yang dikesan yang menghampiri bentuk sebenar EPB, penapis jarak menegak digunakan pada penanda berturut-turut untuk membuang nilai luar dengan anjakan kedudukan yang mendadak. Khususnya, sebarang lonjakan melampau dalam kedudukan penanda, sama ada lonjakan yang sangat tinggi (lonjakan positif) atau sangat rendah (lonjakan negatif), akan ditapis keluar sebagai penanda palsu yang berpotensi menggunakan dua mekanisme rujukan.

Mekanisme pertama menangani lonjakan positif dengan memeriksa penanda yang paling hampir dengan garis rujukan pepenjuru. Penanda terdekat akan dipilih sebagai penanda yang sah. Untuk mengendalikan lonjakan negatif, kedudukan penanda dari lajur sebelumnya digunakan sebagai nilai ambang; ini bermakna penanda dalam lajur berikutnya mestilah lebih tinggi daripada penanda dalam lajur sebelumnya. Jika mana-mana penanda diletakkan jauh lebih rendah daripada penanda lajur sebelumnya, ia akan disingkirkan kerana ia mungkin mewakili pengesanan anomali. Bagi mengukuhkan lagi penapis ini, penanda dalam lajur pertama dan terakhir hendaklah lebih dekat dengan sudut kiri bawah dan sudut kanan atas kotak sempadan. Keperluan tambahan ini membantu memastikan anomali dalam penanda pertama tidak melebihi proses penapisan terpencil. Secara keseluruhan, proses penapisan menghapuskan kedudukan penanda abnormal yang disebabkan oleh hingar atau struktur yang tidak berkaitan.

Setelah semua titik yang sah ditentukan, ia disambungkan secara berturutan menggunakan garis lurus,

dengan berkesan menjejak laluan EPB merentasi bingkai. Output yang dianotasi yang menunjukkan kedua-dua titik pengesanan terpisah dan trajektori berterusan memberikan visualisasi pergerakan EPB yang jelas dan intuitif. Selain itu, kepingan lajur yang diekstrak dengan pengesanan bertindih disusun menjadi paparan komposit untuk analisis perbandingan. Output dwi-panel yang terhasil (imej asal dan ringkasan berasaskan lajur) kemudiannya dieksport untuk pemeriksaan saintifik lanjut dan pengarkiban set data.

KEPUTUSAN DAN PERBINCANGAN

ANALISIS PENGESANAN EPB

Bahagian ini menilai prestasi pengesanan bagi pelbagai model pengesanan objek berasaskan YOLO ringan, termasuk YOLOv5, YOLOv6, YOLOv8s, YOLOv8m, YOLOv9s, YOLOv9m, YOLOv10s dan YOLOv10m seperti yang ditunjukkan dalam Jadual 1. Dalam kalangan model ini, YOLOv9m menyerlah sebagai varian ringan yang berprestasi terbaik, dengan menunjukkan keseimbangan yang optimum antara ketepatan pengesanan dan kecekapan pengiraan. Model YOLOv9m mencapai kepersisan pengesanan tertinggi antara semua model ringan yang dipertimbangkan dalam perbandingan ini. Khususnya, ia mencapai kepersisan tertinggi 0.816, kepekaan 0.781, dan skor F1 0.80. Keputusan ini menunjukkan bahawa YOLOv9m memberikan prestasi yang baik dalam mengesan objek dengan tepat serta meminimumkan positif palsu, menjadikannya model yang berprestasi tinggi dan boleh dipercayai bagi tugas pengesanan objek yang dikaji. Tambahan pula, YOLOv9m mencapai AP tertinggi (0.831), mengatasi model kompetitif lain seperti YOLOv8s (0.823), YOLOv8m (0.829), YOLOv9s (0.817) dan YOLOv10m (0.816). Nilai AP yang lebih tinggi menunjukkan bahawa YOLOv9m berupaya mengesan objek dengan ketepatan dan keyakinan yang lebih tinggi, sekaligus memastikan prestasi pengesanan yang lebih teguh dan konsisten.

Di samping ketepatan pengesanan yang tinggi, YOLOv9m mengekalkan kos pengiraan yang munasabah. Model ini beroperasi pada 76.5 GFLOP, iaitu lebih rendah daripada YOLOv8m (78.7 GFLOPs) tetapi lebih tinggi sedikit daripada YOLOv8s (28.4 GFLOPs) dan YOLOv10s (24.4 GFLOPs). Walaupun memerlukan lebih banyak sumber pengiraan daripada beberapa model yang lebih kecil, YOLOv9m menawarkan ketepatan pengesanan yang

jauh lebih baik, menjadikan pertukaran ini wajar. Selain itu, saiz model YOLOv9m ialah 40.8 MB, yang kekal terurus dan sesuai untuk aplikasi masa nyata. Saiz yang agak padat ini memastikan model boleh digunakan dengan cekap pada peranti tepi tanpa storan atau kekangan memori yang berlebihan.

Dalam membandingkan YOLOv9m dengan model ringan yang lain, beberapa pemerhatian utama boleh dibuat. YOLOv5 dan YOLOv6 mempamerkan prestasi pengesanan yang jauh lebih rendah merentas semua metrik, dengan nilai skor AP dan F1 yang lebih rendah, menunjukkan bahawa ia kurang berkesan untuk tugas pengesanan objek berketepatan tinggi. Sebaliknya, YOLOv8s dan YOLOv8m menunjukkan prestasi yang agak baik tetapi tidak melebihi YOLOv9m dalam kepersisan, kepekaan atau AP. Selain itu, YOLOv9s, sebagai varian yang lebih kecil, tidak mencapai tahap ketepatan yang sama seperti YOLOv9m. Akhir sekali, sementara YOLOv10s dan YOLOv10m menunjukkan kecekapan dalam kos pengiraan, prestasi keseluruhannya masih tidak menandingi YOLOv9m, terutamanya dari segi kepekaan dan skor F1, yang sangat penting untuk pengesanan objek yang boleh dipercayai.

Rajah 3 membentangkan lengkung kepersisan-kepekaan bagi pelbagai variasi model YOLO. Lengkung ini menggambarkan imbalan yang wujud antara kepersisan dan kepekaan apabila nilai ambang keyakinan diubah suai. Antara model ringan yang diuji, YOLOv9m mempamerkan prestasi yang paling unggul dengan lengkung yang lebih menghampiri sudut kanan atas graf, yang menunjukkan keupayaan model mengekalkan tahap kepersisan dan kepekaan yang tinggi secara serentak. Keluasan di bawah lengkung ini dikuantitikan melalui metrik kepersisan purata (AP), yang bertindak sebagai penunjuk utama kepada luas di bawah lengkung (AUC) bagi tugas pengesanan objek. Nilai AP yang lebih tinggi pada YOLOv9m secara langsung mencerminkan kawasan di bawah lengkung yang lebih besar berbanding model lain, sekali gus mengesahkan ketepatan pengesanan yang lebih jitu merentas pelbagai skala objek sasaran.

PENYINGKIRAN HINGAR OLEH RONA, KEAMATAN, NILAI (HSV)

Dalam proses kunci kroma, ruang warna imej ditukar daripada merah, hijau, biru (RGB) kepada rona, keamatan, nilai (HSV). Kemudian, pelbagai julat warna HSV yang mewakili hingar telah bertukar menjadi hitam tulen [0, 0, 0] dengan menggunakan beberapa kombinasi lapisan binari. Penapis binari pertama menapis piksel yang

mempunyai nilai rona merah-dekat dalam julat antara 0 hingga 125 ($0 \leq H \leq 125$), sementara penapis kedua menapis piksel yang berada dalam julat keamatan merah-jauh iaitu antara 170 hingga 180 ($170 \leq H \leq 180$). Penapis-penapis ini digabungkan menggunakan operasi logik 'ATAU' supaya semua piksel dalam julat rona merah dekat dan jauh digabungkan dalam satu kelas rona merah. Selain itu, terdapat penapis tambahan yang menapis piksel berdasarkan tahap keamatan minimum iaitu 63 ($S \geq 63$) dan tahap nilai minimum iaitu 102 ($V \geq 102$), yang memastikan hanya piksel yang cukup tepu dan cukup

terang dipilih, sekaligus menghilangkan piksel yang terlalu pudar atau gelap untuk dianggap sebagai warna yang sah. Semua penapis binari yang dicipta akan digabungkan menggunakan operasi logik 'DAN' untuk memastikan hanya piksel yang memenuhi semua syarat ini akan diambil kira. Penapis gabungan ini digunakan untuk menyalin piksel asal daripada imej asal ke imej akhir yang mempunyai latar belakang hitam. Dengan cara ini, hanya kawasan yang memenuhi kriteria HSV yang akan dipaparkan dalam warna asalnya, manakala kawasan lain akan menjadi hitam dan hanya warna EPB ditetapkan.

JADUAL 1. Perbandingan prestasi pengesanan


Model	Saiz input	Kepersisan	Kepekaan	Skor-F1	AP	GFlops	Saiz (MB)
YOLOv5	416	0.792	0.710	0.75	0.776	7.0	5.3
YOLOv6	416	0.791	0.684	0.74	0.754	11.8	8.7
YOLOv8s	416	0.841	0.739	0.79	0.823	28.4	22.5
YOLOv8m	416	0.809	0.795	0.80	0.829	78.7	52.0
YOLOv9s	416	0.788	0.775	0.78	0.817	26.7	15.2
YOLOv9m	416	0.816	0.781	0.80	0.831	76.5	40.8
YOLOv10s	416	0.792	0.754	0.78	0.824	24.4	16.5
YOLOv10m	416	0.816	0.741	0.78	0.816	63.4	33.5

JADUAL 2. Julat warna hingar HSV

Nama warna	Ruang warna	[Rona, Keamatan, Nilai] (HSV)
Kegelapan umum		[0, 0, 0] → [180, 60, 60]
Kelabu rendah		[0, 0, 0] → [50, 50, 50]
Ungu/Magenta		[130, 60, 60] → [165, 255, 255]
Putih terang		[0, 0, 180] → [180, 40, 255]
Kelabu pertengahan		[0, 0, 60] → [180, 30, 180]
Coklat kemerahan		[5, 40, 40] → [30, 255, 180]
Merah jambu samar		[140, 20, 20] → [170, 80, 80]
Pinggir biru-magenta		[130, 100, 10] → [170, 255, 100]
Ungu tepu		[120, 40, 40] → [160, 255, 255]

JADUAL 3. Julat HSV rona EPB

Nama rona	Ruang rona	[Rona, Keamatan, Nilai] (HSV)
Merah terang → merah menyala		[0, 60, 60] → [10, 255, 255]
Merah gelap		[160, 60, 60] → [180, 255, 255]
Jingga & kuning		[10, 60, 60] → [30, 255, 255]
Kuning → hijau muda		[30, 60, 60] → [60, 255, 255]
Hijau → sian		[60, 60, 60] → [113, 255, 255]
Coklat tanah		[5, 50, 20] → [25, 255, 150]




RAJAH 3. Perbandingan lengkung kepersisan-kepekaan

Kesemua warna bukan EPB iaitu hingar ditapis dan ditukarkan kepada warna hitam. Julat warna hingar HSV ini diperincikan dalam Jadual 2. Selepas proses kunci kroma ini diaplikasikan, semua hingar yang tidak memenuhi syarat julat HSV bukan EPB akan bertukar menjadi warna hitam [0, 0, 0], dan warna EPB yang

memenuhi syarat penapis binari akan bertukar putih dalam imej binari. Imej binari akhir akan mempunyai kawasan EPB putih dan kawasan bukan EPB menjadi hitam. Seterusnya, piksel berwarna putih akan kembalikan kepada warna imej asal dan piksel warna hitam kekal hitam. Ini akan mengembalikan warna EPB. Julat HSV bagi rona

EPB dirujuk dalam Jadual 3. Proses kekunci kroma ini dapat mengasingkan EPB dan membuang hingar dan artifak yang boleh mengganggu proses selanjutnya. Perbandingan sebelum dan selepas proses kekunci kroma boleh dilihat dalam Rajah 4. Proses seterusnya adalah untuk menapis struktur EPB bertindih yang tidak tergolong dalam kotak sempadan dan hanya meninggalkan EPB sebenar untuk analisis selanjutnya.




RAJAH 4. Sebelum dan selepas kekunci kroma, pemerhatian pada 2 September 2011

Penapis kedekatan digunakan untuk menapis struktur EPB yang bertindih. Dalam imej binari, struktur EPB muncul sebagai komponen bersambung bagi piksel putih. Penapis ini berfungsi dengan mengukur jarak setiap titik pusat komponen dari garis rujukan pepenjur sebagai mana boleh dilihat dalam Rajah 5d. Pelbagai komponen muncul dalam satu kotak sempadan dan jarak masing-masing adalah seperti berikut: Komponen 1: 130.98 piksel, Komponen 2: 9.91 piksel, Komponen 3: 9.22 piksel, Komponen 4: 11.83 piksel, Komponen 5: 10.63 piksel, Komponen 5: 10.63 piksel, 51 piksel. Komponen 7: 13.14 piksel, Komponen 8: 58.09 piksel, Komponen 9: 53.92 piksel, Komponen 10: 60.35 piksel dan Komponen 11: 148.82 piksel. Komponen yang cukup hampir (dalam ambang 5 piksel) telah digabungkan, dan satu komponen sahaja dikekalkan berdasarkan jarak paling hampir dengan garis rujukan pepenjur.

Komponen 3 dipilih sebagai yang paling hampir dengan pepenjur, dengan jarak 9.22 piksel, kerana ia mempunyai nilai jarak terkecil. Penapis kehampiran ini memastikan bahawa hanya komponen yang paling hampir dengan garis rujukan pepenjur disimpan untuk pemprosesan selanjutnya, manakala komponen lain yang berdekatan telah digabungkan dengan komponen yang dipilih. Sebagaimana yang boleh dilihat dalam Rajah 5, output akhir menggabungkan hasil output kekunci kroma (Rajah 5b) dan penapisan jarak dalam bentuk binari (Rajah 5c) ke dalam satu imej output yang memaparkan komponen EPB dengan warna asalnya serta latar belakang hitam (Rajah 5f).

Saluran warna telah dipisahkan dan diduakan untuk mengasingkan warna berdasarkan keamatan EPB. Piksel

yang mempunyai warna tertentu dalam saluran masing-masing kelihatan sebagai putih kerana perduaan. Bagi semua warna, keamatan dan nilai dihadkan dalam julat $150 \leq S \leq 255$ dan $150 \leq V \leq 255$ untuk memastikan hanya piksel dengan keamatan warna yang cukup terang dan jelas disertakan. Warna yang tidak terang dan jelas kebiasannya hingar yang bukan sebahagian daripada EPB. Nilai ambang rona pula ditakrifkan




RAJAH 5. Proses penapis jarak gumpalan dan gabungan imej untuk imej akhir

secara khusus bagi setiap rona warna berdasarkan kedudukan mereka dalam roda warna HSV. Bagi rona Merah, disebabkan kedudukannya yang berada hampir pada sudut 0° dan 180° , dua julat rona merah isaitu merah dekat dan merah jauh digabungkan: $0 \leq H \leq 21$ dan $170 \leq H \leq 180$. Bagi rona Kuning, julatnya ialah $21 \leq H \leq 46$. Rona Hijau ditakrifkan dengan julat $52 \leq H \leq 86$, manakala sian merangkumi $85 \leq H \leq 107$. Akhir sekali, Biru dipisahkan dalam julat $115 \leq H \leq 125$. Ambang-ambang ini memastikan pengesanan piksel untuk warna berbeza dilakukan dengan efektif. Sebarang piksel yang mempunyai nilai di luar julat ambang untuk saluran tertentu tersebut ditetapkan sebagai hitam $[0, 0, 0]$. Selepas ambang ini digunakan, jumlah piksel yang dikesan dalam setiap saluran rona adalah seperti berikut: 6,795 piksel rona merah dalam saluran rona merah, 2,697 piksel rona kuning dalam saluran rona kuning, 7,858 piksel rona hijau dalam saluran hijau, 8,016 piksel sian dalam saluran rona sian, dan 8673 piksel rona biru dalam saluran rona biru. Binaris saluran setiap rona digabungkan dengan imej asal untuk tujuan visualisasi pengasingan warna dalam saluran rona masing-masing seperti dalam Rajah 6.

Rajah 7 menunjukkan pengesanan warna berlaku dalam setiap lajur piksel yang dipisahkan pada selang masa

30 minit pada imej EPB. Jadual 4 menunjukkan maklumat terperinci untuk EPB1-EPB3. Setelah pengesanan, purata sesaran bagi setiap kelompok EPB diukur berdasarkan jarak di antara pusat komponen putih dalam unit piksel. Perlu diterangkan bahawa nilai ini berfungsi sebagai spesifikasi teknikal bagi algoritma pemprosesan imej dalam ruang koordinat imej dan tidak merujuk kepada jarak atau ruang geografi sebenar. Melalui analisis tersebut, didapati bahawa EPB 1 mempunyai purata sesaran sebanyak 47.11 piksel/30 min yang menunjukkan pergerakan pada kelajuan hampir pantas dengan jangka hayat selama 300 minit. Warna dominan bagi EPB 1 adalah hijau diikuti oleh sian, yang mencerminkan keamatan antara 0.5 hingga 0.8 TECU/min. Seterusnya, EPB 2 telah diproses menggunakan algoritma

pengesanan warna pada setiap lajur piksel dengan selang masa 30 minit. Hasil pengesanan menunjukkan EPB 2 mempunyai purata sesaran yang lebih tinggi iaitu 58.60 piksel/30 min, sekali gus dikategorikan sebagai EPB bergerak pantas dengan jangka hayat 180 minit. Imej bagi EPB 2 didominasi oleh warna merah dan hijau dengan sedikit warna sian, menunjukkan julat keamatan antara 0.5 hingga 1.0 TECU/min. Akhir sekali, EPB 3 mencatatkan purata sesaran sebanyak 30.20 piksel/30 min, yang dikategorikan sebagai EPB bergerak perlahan dengan jangka hayat 180 minit. Warna dominan bagi EPB 3 adalah sian dengan sedikit biru, yang diterjemahkan kepada keamatan sekitar 0.3 hingga 0.5 TECU.



RAJAH 6. Saluran rona keamatan EPB

JADUAL 4. Maklumat terperinci untuk EPB1-EPB3

EPB	Jumlah Jangka Hayat (~min)	Purata Sesaran EPB (piksel/30min)	Saluran	Koordinasi Imej		Rona Dominan	Rona	
				x	y		Minimum	Maksimum
1	300	47.11	1	23	466	Sian	106	107
			2	46	423	Hijau	77	86
			3	69	401	Hijau	52	86
			4	92	367	Hijau	83	86
			5	115	307	Hijau	70	86
			6	139	234	Hijau	69	86
			7	162	206	Kuning	36	46
			8	185	130	Hijau	80	86
			9	208	82	Hijau	76	86
			10	231	42	Sian	100	107
2	180	58.60	1	26	355	Merah	0	179
			2	52	303	Merah	0	179
			3	78	266	Merah	0	179
			4	105	194	Hijau	63	86
			5	131	116	Hijau	69	86
			6	157	62	Sian	99	107

continue...


...cont.

			1	15	168	Sian	104	107
			2	31	154	Sian	92	107
			3	47	138	Sian	93	107
3	180	30.20	4	62	87	Sian	97	107
			5	78	59	Sian	103	107
			6	94	17	Biru	115	117

KESIMPULAN

Kajian semasa ini telah membentangkan pendekatan hibrid yang menggabungkan pembelajaran mendalam dan penglihatan komputer klasik untuk mengenal pasti struktur EPB berdasarkan keogram ROTI. Kami berjaya menjalankan pengesanan terhadap struktur EPB dengan jarak antara komponen yang diukur iaitu 9.22 hingga 148.82 piksel. EPB yang dikenal pasti mempamerkan kelajuan hanyut yang berbeza-beza: EPB 1 menunjukkan

gerakan hampir pantas (purata sesaran: 47.67 piksel/30 min dengan jangka hayat 300 minit), EPB 2 memaparkan gerakan pantas (58.00 piksel/30 min dengan jangka hayat lebih 180 minit) dan EPB 3 menunjukkan gerakan perlahan (30.80 piksel/30 min dengan jangka hayat lebih 180 minit). Daripada hasil pengesanan dan pencirian awal kajian ini didapati analisis yang terperinci akan dilakukan pada masa hadapan dengan menilai secara kuantitatif ciri-ciri EPB menggunakan model pembelajaran mendalam yang dibentangkan.



RAJAH 7. Lajur piksel yang dijarakkan dalam selang masa 30 minit pada imej EPB.

PENGHARGAAN

Kajian ini disokong oleh Universiti Sains Malaysia, Geran Bridging dengan No. Projek: R501 - LR - RND003 - 0000001578 – 0000. Penulis juga ingin merakamkan setinggi-tinggi penghargaan kepada Pusat Sains Angkasa, Institut Perubahan Iklim, Universiti Kebangsaan Malaysia atas penyediaan data GPS yang telah diproses.

PENGISYTIHARAN KEPENTINGAN BERSAING

Tiada.

RUJUKAN

- Adawa, I., Otsuka, Y., Abdelwahab, M. & Mahrous, A. 2025. Advanced detection methods and machine learning analysis of temporal and spatial patterns of equatorial plasma bubble depth. *Journal of Atmospheric and Solar-Terrestrial Physics* 270: 106495. <https://doi.org/10.1016/j.jastp.2025.106495>
- Chen, S. P. et al. 2025. Machine learning detection of radio occultation electron density profiles perturbed by the equatorial plasma bubbles. *IEEE Transactions on Geoscience and Remote Sensing* 63: 1–13. <https://doi.org/10.1109/TGRS.2025.3543427>
- Chitale, P. A., Kekre, K. Y., Shenai, H. R., Karani, R. & Gala, J. P. 2020. Pothole detection and dimension estimation system using deep learning (YOLO) and image processing. *2020 35th International Conference on Image and Vision Computing New Zealand (IVCNZ)*, 1–6. IEEE.
- Githio, L., Liu, H., Arafa, A. A. & Mahrous, A. 2024. A machine learning approach for estimating the drift velocities of equatorial plasma bubbles based on All-Sky Imager and GNSS observations. *Advances in Space Research* 74(11): 6047–6064. <https://doi.org/10.1016/j.asr.2024.08.067>
- Ge, Z., Liu, S., Wang, F., Li, Z. & Sun, J. 2021. YOLOX: Exceeding YOLO series in 2021.
- Georgiou, T., Liu, Y., Chen, W. & Lew, M. 2020. A survey of traditional and deep learning-based feature descriptors for high dimensional data in computer vision. *International Journal of Multimedia Information Retrieval* 9: 135–170.
- Liu, S., Qi, L., Qin, H., Shi, J. & Jia, J. 2018. Path aggregation network for instance segmentation.
- Mushtaq, F., Ramesh, K., Deshmukh, S., Ray, T., Parimi, C., Tandon, P. & Jha, P. K. 2023. Nuts&bolts: YOLO-v5 and image processing based component identification system. *Engineering Applications of Artificial Intelligence* 118: 105665.
- Mellouli, D., Hamdani, T. M., Sanchez-Medina, J. J., Ayed, M. B. & Alimi, A. M. 2019. Morphological convolutional neural network architecture for digit recognition. *IEEE Transactions on Neural Networks and Learning Systems* 30(9): 2876–2885.
- O'Mahony, N., Campbell, S., Carvalho, A., Harapanahalli, S., Hernandez, G. V., Krpalkova, L. & Walsh, J. 2020. Deep learning vs. traditional computer vision. In *Advances in Computer Vision: Proceedings of the 2019 Computer Vision Conference (CVC), Volume 1*, 128–144. Springer International Publishing.
- Prakash, K. T. N., Prasad, N. & Singh, B. M. K. 2025. Red blood cell segmentation and classification using hybrid image processing-SqueezeNet model. *Multimedia Tools and Applications*: 1–21.
- Reddy, S. A. et al. 2023. Predicting swarvequatorial plasma bubbles via machine learning and Shapley values. *Journal of Geophysical Research: Space Physics* 128(6): 1–11. <https://doi.org/10.1029/2022JA031183>
- Sarudin, I., Hamid, N. S. A., Abdullah, M., Buhari, S. M., Otsuka, Y., Perwitasari, S. & Yatini, C. Y. 2024. Permulaan gelembung plasma khatulistiwa semasa angin neutral kuat dan lemah di Asia Tenggara. *Jurnal Kejuruteraan* 36(3): 1281–1289.
- Srisamoodkham, W., Shiokawa, K., Otsuka, Y., Ansari, K. & Jamjareegulgarn, P. 2022. Detecting equatorial plasma bubbles on All-Sky Imager images using convolutional neural network. *Communications in Computer and Information Science* 461: 481–487. https://doi.org/10.1007/978-981-19-2130-8_38
- Szeliski, R. 2022. *Computer Vision: Algorithms and Applications*. Springer Nature.
- Thanakulketsarat, T., Supnithi, P., Myint, L. M. M., Hozumi, K. & Nishioka, M. 2023. Classification of the equatorial plasma bubbles using convolutional neural network and support vector machine techniques. *Earth, Planets and Space* 75(1). <https://doi.org/10.1186/s40623-023-01903-7>
- Wang, C. Y., Liao, H. Y. M. & Yeh, I. H. 2024. YOLOv9: Learning what you want to learn using programmable gradient information. *arXiv preprint arXiv:2402.13616*.
- Wang, C. Y., Bochkovskiy, A. & Liao, H. Y. M. 2023. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors.
- Yacoub, M., Pacheco, E. E., Abdelwahab, M., De La Jara, C. & Mahrous, A. 2025. Automatic detection and classification of Spread-F in ionograms using convolutional neural network. *Journal of Atmospheric and Solar-Terrestrial Physics* 270: 106504. <https://doi.org/10.1016/j.jastp.2025.106504>