

BAB II

TINJAUAN PUSTAKA

Bab tinjauan pustaka ini akan membahas perbandingan berbagai penelitian sebelumnya yang memiliki topik dan metode serupa, serta menguraikan teori-teori yang berkaitan langsung dengan penelitian ini.

2.1 Kajian Relevan

Penggunaan teknologi informasi dalam pengawasan peralatan tegangan tinggi sangat penting untuk meningkatkan deteksi dan klasifikasi tingkat kerusakan, *seperti corona discharge*, yang dapat mengganggu kinerja sistem. Menghadapi tantangan dalam mendeteksi dan mengklasifikasikan kerusakan pada peralatan tegangan tinggi yang masih menggunakan metode manual. Hal ini menyebabkan keterlambatan dalam pemeliharaan peralatan yang berisiko tinggi terhadap gangguan operasional. Oleh karena itu, dibutuhkan sistem berbasis TI yang dapat mengotomatisasi deteksi dan klasifikasi tingkat *corona discharge* pada peralatan tegangan tinggi menggunakan teknologi seperti YOLOv8.

Tabel 2. 1 Kajian Relevans

Peneliti	Judul	Metode	Hasil	Keterkaitan
(Maulana et al., 2023)	Analisis Penggunaan Model YOLOv8 terhadap Deteksi Citra Senjata Berbahaya	YOLOv8	YOLOv8 mencapai precision 84%, recall 77%, mAP 84%, dan F1-score 88%. Model mampu mendeteksi senjata berbahaya meskipun	Keterkaitan terletak pada penerapan YOLOv8 untuk mendeteksi objek dengan presisi tinggi dalam citra yang beragam, yang juga relevan dalam mendeteksi fenomena corona discharge pada

			pada kondisi citra yang beragam.	peralatan tegangan tinggi.
(Rismayanti et al., 2025)	Deteksi dan Klasifikasi Tingkat Kematangan Buah Mangga Harum Manis Menggunakan YOLOv8	<i>YOLOv8</i>	Hasil akhir menunjukkan bahwa YOLOv8 mampu memberikan kinerja yang stabil dengan Precision 81,1%, Recall 81,5%, dan mAP50–95 sebesar 79,8%. Kinerja terbaik dicapai pada kategori “belum matang” dengan mAP 82,2%, sedangkan “setengah matang” menjadi kategori yang paling menantang	Teknik yang sama, YOLOv8, digunakan dalam penelitian Penulis untuk mendeteksi dan mengklasifikasikan tingkat corona discharge pada peralatan tegangan tinggi.

			dengan mAP 76,6%.	
(FIKRI et al., 2022)	Clustering Fenomena <i>Corona Discharge</i> Berdasarkan Suara Menggunakan Metode <i>LPC</i> dan <i>Euclidean Distance</i>	Metode <i>Linear Predictive Coding</i> (LPC) dan <i>Euclidean Distance</i>	Akurasi training 100% dan testing 85,15%. Dapat digunakan untuk deteksi dini kegagalan isolasi akibat CD.	Pendekatan berbasis citra yang Penulis gunakan dengan YOLOv8 bisa melengkapi teknik ini dalam mendeteksi corona discharge, memberikan alternatif yang lebih visual terhadap deteksi berbasis suara.
(PASRA et al., 2023)	Deteksi Suara Corona Discharge berdasarkan <i>Noise</i> menggunakan Metode <i>LPC</i> dan <i>Euclidean Distance</i>	Metode <i>Linear Predictive Coding</i> (LPC) dan <i>Convolution Neural Network</i> (CNN)	Meneliti identifikasi fenomena corona discharge bukan berdasarkan suara, melainkan berdasarkan citra visual menggunakan pendekatan Convolutional Neural Network (CNN). Dalam	Keterkaitannya dengan penelitian Penulis terletak pada penggunaan citra visual untuk mendeteksi corona discharge.

			jurnal tersebut, fenomena corona discharge pada kubikel tegangan menengah dideteksi melalui pola visual yang terekam pada citra peralatan listrik, di mana CNN digunakan untuk mengekstraksi fitur-fitur citra yang menunjukkan adanya gejala corona discharge seperti cahaya kebiruan atau pola ionisasi di sekitar terminal kabel	
(Riba & Bas-Calopa, 2022)	<i>Use of DSLR and Sonic Cameras to</i>	<i>Experimental</i>	DSLR dan kamera sonic berhasil	Memberi dasar bahwa citra foto corona dapat

	<i>Detect and Locate High-Voltage Corona Discharges</i>		mendeteksi dan memetakan lokasi corona secara visual; kamera sonic mampu mendeteksi cepat bahkan di kondisi terang	digunakan untuk deteksi dan lokasi corona pada peralatan tegangan tinggi, mendukung justifikasi penggunaan citra dalam penelitian ini
Muhammad Wahyu Ilham (2026)	Deteksi dan Klasifikasi Tingkat Corona Discharge Pada Peralatan Tegangan Tinggi menggunakan YOLOv8	YOLOv8	-	-

Penelitian pertama membahas kemampuan deteksi corona discharge pada peralatan tegangan tinggi melalui pengamatan visual menggunakan kamera optik. Penelitian ini dilakukan secara eksperimental di laboratorium dengan membangkitkan corona discharge pada sistem elektroda tegangan tinggi. Fenomena corona direkam menggunakan beberapa jenis kamera, termasuk kamera DSLR dan kamera berbasis sensor cahaya, untuk membandingkan kemampuan masing-masing perangkat dalam menangkap cahaya corona yang muncul di sekitar elektroda. Hasil penelitian menunjukkan bahwa corona discharge dapat dideteksi secara jelas melalui citra visual, terutama pada kondisi pencahayaan rendah. Intensitas dan sebaran cahaya corona meningkat seiring dengan kenaikan tegangan yang diberikan pada elektroda. Selain itu,

penelitian ini juga menemukan bahwa karakteristik visual corona—seperti luas area pendaran dan tingkat kecerahan—dapat digunakan sebagai indikator tingkat keparahan corona discharge. Keterkaitan dengan penelitian ini terletak pada pemanfaatan informasi visual sebagai dasar analisis corona discharge. Jika penelitian Riba dan Bas-Calopa masih mengandalkan pengamatan visual dan analisis manual terhadap citra, maka penelitian ini mengembangkan pendekatan tersebut dengan menerapkan YOLOv8 untuk melakukan deteksi dan pengelompokan tingkat corona discharge secara otomatis. Dengan demikian, penelitian ini melanjutkan gagasan bahwa perbedaan intensitas corona yang relatif halus dapat dianalisis secara lebih objektif dan efisien melalui model deep learning berbasis citra (Riba & Bas-Calopa, 2022).

Penelitian kedua menjelaskan bahwa efektivitas YOLOv8 dalam mendeteksi objek berisiko tinggi (senjata api) dari citra visual. Dataset digunakan dari Roboflow dan diolah menggunakan data augmentation (rotasi, blur, grayscale). Hasil evaluasi menunjukkan precision 84%, recall 77%, mAP 84%, dan F1-score 88%. Model berhasil mengenali objek berbahaya meski citra mengalami gangguan pencahayaan atau kebisingan visual. Keterkaitan dengan penelitian yaitu deteksi senjata yang merupakan ancaman keselamatan, fenomena corona discharge juga merupakan indikator bahaya potensial dalam sistem kelistrikan. YOLOv8, yang terbukti mampu mengenali pola bahaya visual dengan presisi tinggi, sangat sesuai digunakan untuk deteksi dini potensi kegagalan isolasi akibat corona discharge (Maulana et al., 2023).

Penelitian ketiga menjelaskan bahwa Penelitian ini mengembangkan sistem otomatis berbasis YOLOv8 untuk mendeteksi dan mengklasifikasikan tingkat kematangan buah mangga harum manis ke dalam tiga kategori: belum matang, setengah matang, dan matang. Dataset terdiri dari 540 citra yang dianotasi melalui Roboflow, dengan pembagian 87% untuk pelatihan, 8% validasi, dan 4% pengujian. Model dilatih selama 50 epoch, dengan batch size 16 dan resolusi gambar 500 piksel. Hasil akhir menunjukkan bahwa YOLOv8 mampu memberikan kinerja yang stabil dengan Precision 81,1%, Recall 81,5%, dan mAP_{50–95} sebesar 79,8%. Kinerja terbaik dicapai pada kategori “belum matang” dengan mAP 82,2%, sedangkan “setengah matang” menjadi kategori yang paling menantang dengan mAP 76,6%. Peneliti menekankan bahwa performa model dapat ditingkatkan melalui augmentasi data dan penambahan variasi pencahayaan serta sudut pengambilan gambar. Keterkaitan penelitian yaitu sama seperti

mangga yang diklasifikasikan berdasarkan warna kulit (indikator tingkat kematangan), corona discharge juga menunjukkan variasi visual cahaya dengan tingkat intensitas berbeda. Ini berarti pendekatan klasifikasi YOLOv8 dapat langsung diadaptasi untuk mendeteksi tingkat keparahan corona discharge dari citra visual (Rismayanti et al., 2025).

Penelitian keempat menjelaskan bahwa kajian awal tentang corona discharge berbasis analisis sinyal akustik. Menggunakan metode Linear Predictive Coding (LPC) dan Euclidean Distance, penelitian ini berhasil mengelompokkan fenomena discharge pada tegangan 20–33 kV dengan akurasi training 100% dan testing 85,15%. Analisis menunjukkan bahwa suara corona discharge memiliki pola khas yang dapat dijadikan parameter diagnosis dini kegagalan isolasi. Keterkaitan dengan penelitian yaitu Studi ini memperkuat dasar ilmiah bahwa fenomena corona discharge memiliki pola khas yang dapat dikenali secara matematis, baik dari suara maupun dari citra. Penelitian ini memperluas pendekatan ke ranah visual detection berbasis deep learning, yang lebih intuitif dan dapat diimplementasikan secara lapangan menggunakan kamera (FIKRI et al., 2022).

Penelitian kelima menjelaskan bahwa identifikasi fenomena corona discharge bukan berdasarkan suara, melainkan berdasarkan citra visual menggunakan pendekatan Convolutional Neural Network (CNN). Dalam jurnal tersebut, fenomena corona discharge pada kubikel tegangan menengah dideteksi melalui pola visual yang terekam pada citra peralatan listrik, di mana CNN digunakan untuk mengekstraksi fitur-fitur citra yang menunjukkan adanya gejala corona discharge seperti cahaya kebiruan atau pola ionisasi di sekitar terminal kabel. Metode CNN diterapkan karena kemampuannya mengenali struktur spasial dan hierarki fitur gambar, yang sangat relevan dengan deteksi pola visual. Sistem ini melatih jaringan CNN untuk mengenali perbedaan antara citra normal dan citra yang menunjukkan indikasi corona discharge. Hasilnya, sistem dapat mendeteksi anomali secara otomatis sehingga kerusakan isolasi dapat dicegah lebih awal. Keterkaitan dengan penelitian yaitu YOLOv8 merupakan pengembangan dari CNN untuk deteksi objek secara real-time dengan performa yang lebih tinggi. Artinya, penelitian CNN visual seperti pada jurnal ini merupakan fondasi metodologis bagi penelitian ini. Peneliti mengembangkan pendekatan yang lebih mutakhir dari konsep dasar CNN dari sekadar klasifikasi citra menjadi deteksi spasial objek secara cepat dan presisi, yang

memungkinkan sistem bekerja secara real-time untuk mengenali area terjadinya corona discharge dengan akurasi lebih tinggi (PASRA et al., 2023).

Penelitian keenam menjelaskan bahwa mengembangkan sistem deteksi otomatis berbasis YOLOv8 (You Only Look Once versi 8) untuk mengidentifikasi dan menghitung ketersediaan produk pada rak secara real-time melalui aplikasi bergerak. Dua varian model digunakan dalam penelitian ini, yaitu YOLOv8n (nano) dan YOLOv8s (small), karena keduanya memiliki keseimbangan optimal antara kecepatan deteksi dan tingkat akurasi yang tinggi. Dataset yang digunakan merupakan citra rak produk yang telah dilabeli menggunakan LabelImg, kemudian diproses melalui tahapan training, validation, dan testing dengan parameter yang dioptimalkan agar sesuai dengan keterbatasan perangkat mobile. Hasil pengujian menunjukkan bahwa model YOLOv8s memberikan performa terbaik dengan nilai mean Average Precision (mAP50) sebesar 0.962, lebih unggul dibandingkan YOLOv8n yang memperoleh mAP 0.947. Selain itu, kecepatan inferensi model diukur menggunakan perangkat Samsung A54, dan hasilnya menunjukkan waktu deteksi rata-rata hanya 0.075 detik per frame, yang berarti model mampu bekerja secara real-time bahkan pada perangkat dengan kemampuan komputasi menengah. Keterkaitan dengan penelitian yaitu membuktikan bahwa YOLOv8 mampu mendeteksi objek berukuran kecil dan kompleks dengan kecepatan tinggi, yang relevan untuk kasus deteksi corona discharge di peralatan tegangan tinggi karena fenomena tersebut juga berupa cahaya kecil dengan pola visual khas yang sulit dideteksi secara manual (Andaru, 2024).

Penelitian ketujuh menjelaskan bahwa dalam *Energies* membahas penerapan *deep learning* untuk mendeteksi cacat (*defect*) pada peralatan tegangan tinggi menggunakan *infrared thermography* (IRT). Penelitian ini menyoroti bahwa peningkatan suhu internal akibat faktor seperti korosi, koneksi lemah, dan ketidakseimbangan arus dapat menimbulkan gangguan serius pada sistem tenaga listrik. Dengan demikian, deteksi dini melalui citra inframerah sangat penting untuk mencegah kegagalan besar pada peralatan listrik. Dalam metode yang digunakan, citra inframerah dari transformator, pemutus sirkuit, arrester, dan isolator dianalisis menggunakan *Convolutional Neural Network* (CNN) untuk ekstraksi fitur, kemudian diklasifikasikan menggunakan *Random Forest* (RF) dan *Support Vector Machine* (SVM). CNN yang dipakai berbasis *AlexNet pretrained* model, sehingga mampu mengekstraksi fitur termal penting dari citra tanpa pelatihan dari

nol. Hasil eksperimen menunjukkan bahwa model CNN–RF mencapai akurasi 96%, lebih unggul dibandingkan SVM dan metode klasik lainnya seperti Naïve Bayes. Keterkaitan dengan penelitian yaitu keduanya sama-sama mengangkat deteksi visual berbasis citra pada peralatan tegangan tinggi dengan deep learning. Jurnal ini berfokus pada deteksi termal anomali (defect) melalui infrared imaging, sedangkan penelitian Anda mengembangkan ke arah deteksi visual fenomena corona discharge dengan YOLOv8, yang merupakan versi lanjutan dari arsitektur CNN dengan kemampuan object detection real-time. Model YOLOv8 akan mampu menentukan lokasi dan tingkat intensitas corona discharge secara langsung pada citra visual, bukan hanya mengklasifikasikan ada/tidaknya cacat seperti pada AlexNet (Ullah et al., 2020b).

Penelitian kedelapan menjelaskan bahwa meneliti spektrum ultraviolet (UV) dan cahaya tampak dari corona discharge serta electric arc di udara dalam rentang tekanan 10–100 kPa, yang mewakili kondisi lingkungan aeronautika seperti kabin pesawat dan area tidak bertekanan. Tujuan utama penelitian ini adalah untuk memahami bagaimana tekanan udara yang rendah memengaruhi karakteristik spektral dari pelepasan listrik dan membantu dalam pemilihan sensor optik yang tepat untuk mendeteksi discharge dini sebelum terjadi kerusakan besar pada sistem isolasi listrik. Hasil eksperimen menunjukkan bahwa spektrum emisi corona discharge dan electric arc sebagian besar berada pada wilayah UV dekat (290–420 nm) dan ungu dari spektrum cahaya tampak. Fenomena ini terutama dihasilkan oleh transisi energi molekul nitrogen (N_2) yang menjadi komponen utama udara. Dengan demikian, intensitas dan distribusi spektrum yang dihasilkan sangat bergantung pada komposisi gas dan tekanan atmosfer. Keterkaitan dengan penelitian yaitu keduanya membahas fenomena corona discharge dari perspektif visual dan optik. Studi Riba (2022) memberikan dasar ilmiah eksperimental mengenai karakteristik spektral dan perilaku optik dari corona discharge di udara bertekanan rendah kondisi yang juga relevan dengan sistem tenaga tinggi di darat. Penelitian ini yang menggunakan YOLOv8 melanjutkan arah ini dengan mengotomatisasi proses deteksi dan klasifikasi corona discharge berdasarkan citra visual (Riba, 2022b).

Penelitian kesembilan menjelaskan analisis spektrum ultraviolet (UV) dan cahaya tampak yang dihasilkan oleh fenomena corona discharge dan electric arc di udara pada kondisi tekanan rendah antara 10–100 kPa, yang merepresentasikan lingkungan aeronautika serta sistem kelistrikan yang beroperasi pada ketinggian tinggi. Tujuan utama

penelitian ini adalah untuk mengidentifikasi karakteristik spektral pelepasan listrik guna mendukung pemilihan sensor optik yang tepat dalam mendeteksi aktivitas corona sejak tahap awal sebelum berkembang menjadi electric arc yang dapat menyebabkan kegagalan sistem isolasi. Hasil penelitian menunjukkan bahwa emisi cahaya corona discharge dan electric arc didominasi oleh spektrum UV dekat hingga wilayah ungu cahaya tampak, dengan rentang panjang gelombang utama sekitar 290–420 nm. Spektrum ini terutama berasal dari transisi energi molekul nitrogen (N_2) yang merupakan komponen dominan udara, sehingga karakteristik spektral sangat dipengaruhi oleh komposisi gas dan tekanan atmosfer. Keterkaitan dengan penelitian ini terletak pada kesamaan pendekatan visual dan optik dalam mengamati fenomena corona discharge. Studi Jordi-Roger Riba (2022) memberikan landasan eksperimental yang kuat mengenai perilaku optik corona discharge pada kondisi tekanan rendah, sedangkan penelitian ini melanjutkan arah tersebut dengan mengotomatisasi proses deteksi dan klasifikasi corona discharge berbasis citra visual menggunakan YOLOv8, sehingga memungkinkan pemantauan yang lebih cepat, objektif, dan aplikatif (Liu et al., 2022).

2.2 Landasan Teori


Landasan teori akan membahas teori-teori dari studi kepustakaan yang disusun secara sistematis sesuai dengan penelitian ini, termasuk definisi dan penjelasan lengkap secara mendalam. Landasan teori ini diharapkan dapat membuat penelitian menjadi lebih jelas dan terarah.

2.2.1 Corona Discharge

Corona discharge merupakan salah satu bentuk pelepasan muatan listrik parsial yang terjadi di sekitar elektroda bertegangan tinggi ketika kuat medan listrik di permukaan elektroda melebihi nilai kritis udara, namun belum cukup besar untuk membentuk loncatan listrik penuh (*breakdown*). Fenomena ini umumnya muncul pada elektroda dengan geometri tidak seragam, seperti elektroda jarum, kawat, atau permukaan dengan radius kelengkungan kecil, karena kondisi tersebut menyebabkan konsentrasi medan listrik yang tinggi di area lokal.

Berdasarkan penelitian yang dilaporkan dalam jurnal (Skubis & Kozioł, 2021b), *corona discharge* dibangkitkan secara eksperimental menggunakan konfigurasi elektroda tegangan tinggi di udara. Tegangan diberikan secara bertahap hingga terjadi ionisasi

molekul udara di sekitar elektroda aktif. Proses ini diawali dengan percepatan elektron bebas oleh medan listrik kuat, yang kemudian menumbuk molekul udara dan menghasilkan ion positif serta elektron tambahan. Akumulasi proses ionisasi ini membentuk zona plasma non-termal yang terlihat sebagai pendaran cahaya di sekitar elektroda..



Gambar 2. 1 Corona Discharge


Penelitian tersebut menunjukkan bahwa *corona discharge* secara fisik berlokasi di sekitar permukaan elektroda, khususnya pada daerah dengan gradien medan listrik tinggi. Intensitas dan bentuk pendaran *corona* sangat dipengaruhi oleh besar tegangan yang diterapkan, jenis polaritas, serta bentuk elektroda yang digunakan. Semakin tinggi tegangan yang diberikan, semakin luas dan terang area pendaran cahaya yang terbentuk di sekitar elektroda. Selain sebagai fenomena listrik, *corona discharge* juga memiliki karakteristik visual yang dapat diamati secara langsung menggunakan kamera optik. Jurnal tersebut menegaskan bahwa cahaya corona yang muncul merupakan hasil dari eksitasi dan relaksasi molekul gas yang terionisasi di sekitar elektroda. Oleh karena itu, informasi visual seperti intensitas cahaya, distribusi pendaran, dan perubahan warna dapat digunakan sebagai indikator keberadaan dan tingkat keparahan *corona discharge*.

Dengan demikian, secara teoritis dapat disimpulkan bahwa *corona discharge* tidak terjadi secara acak di ruang bebas, melainkan terlokalisasi di sekitar elektroda bertegangan tinggi sebagai sumber medan listrik. Hal ini menjadi dasar penting dalam penelitian ini, di mana elektroda tegangan tinggi diperlakukan sebagai objek utama pembangkitan *corona*, dan citra visual yang dihasilkan digunakan sebagai data untuk proses deteksi dan analisis lanjutan..

2.2.2 Machine Learning

Machine learning adalah cabang dari *Artificial Intelligence* (Kecerdasan Buatan) yang fokus pada pengembangan sistem yang dapat mempelajari pola atau informasi dari data tanpa memerlukan intervensi manusia secara terus-menerus. Sistem ini dapat meningkatkan kinerjanya seiring berjalannya waktu dengan memanfaatkan data yang tersedia untuk memperbaiki prediksi atau keputusan yang diambil. Proses pelatihan (training) pada machine learning dilakukan dengan memberi sistem data yang relevan, sehingga sistem dapat mengenali pola dan hubungan dalam data tersebut (K, 2017).

Salah satu karakteristik penting dari *machine learning* adalah kemampuannya untuk belajar dan beradaptasi dengan informasi baru tanpa perlu diprogram ulang secara manual setiap kali ada data baru. Meskipun demikian, aplikasi *machine learning* biasanya terbatas pada masalah tertentu, yang berarti sistem yang dibangun dengan pendekatan ini sering kali hanya efektif dalam konteks atau domain spesifik dan tidak dapat digunakan secara universal untuk menyelesaikan berbagai jenis permasalahan.



Gambar 2. 2 Machine Learning


Machine learning dikategorikan sebagai salah satu teknik dasar dalam AI selain *Searching*, *Reasoning*, dan *Planning*. Tujuan *machine learning* adalah untuk mengembangkan sistem yang dapat belajar dari data dan menggeneralisasi pengalaman tersebut untuk memecahkan masalah baru secara efisien (Soebroto, 2019).

Machine learning digunakan sebagai dasar pengembangan produk AI yang dapat diterapkan dalam berbagai bidang di masyarakat dan industri secara luas. Gambaran cakupan *machine learning* meliputi algoritma untuk klasifikasi, regresi, pengelompokan, optimasi, dan lain-lain, yang bertujuan memudahkan penyelesaian masalah dengan pendekatan pembelajaran dari data (Soebroto, 2019).

2.2.3 Deep Learning

Deep learning adalah cabang dari machine learning yang menggunakan jaringan saraf buatan (*artificial neural networks*) yang memiliki banyak lapisan (*layers*) untuk menganalisis dan memahami data secara kompleks (Soebroto, 2019). Deep learning memungkinkan komputer belajar secara otomatis melalui pengalaman yang diberikan, sehingga sistem dapat mengenali pola yang rumit dalam data tanpa perlu diprogram secara spesifik untuk setiap tugas.

Jaringan neural buatan pada deep learning terinspirasi oleh struktur otak manusia, terdiri dari beberapa lapisan neuron buatan yang saling terhubung. Setiap neuron menerima input data, melakukan komputasi matematika, lalu mengirimkan output ke neuron lain di lapisan berikutnya. Dengan banyaknya lapisan tersembunyi (*hidden layers*), deep learning mampu mempelajari representasi fitur yang sangat kompleks dan abstrak dari data mentah.



Gambar 2. 3 Deep Learning

Deep learning menggunakan algoritma pembelajaran yang disebut *backpropagation* untuk mengoptimalkan parameter jaringan agar output yang dihasilkan semakin akurat. Beberapa jenis algoritma deep learning yang umum dipakai meliputi *convolutional neural networks* (CNN) untuk pengolahan citra, *recurrent neural networks* (RNN) untuk data sekuensial seperti teks dan suara, serta *long short-term memory* (LSTM) yang merupakan varian RNN untuk menangani masalah ketergantungan jangka panjang.

Deep learning banyak diterapkan dalam berbagai bidang seperti pendidikan, kesehatan (misalnya diagnosis medis dari gambar CT scan dan MRI), ekonomi, pengenalan suara, pengenalan wajah, dan kendaraan otonom, karena kemampuannya dalam memproses data tidak terstruktur secara efisien dan mengenali pola yang tersembunyi dalam data besar (Soebroto, 2019).

2.2.4 *Computer Vision*

Computer Vision (visi komputer) adalah bidang studi yang bertujuan mengembangkan teknik agar komputer dapat melihat, memahami, dan menganalisis konten gambar digital seperti foto dan video layaknya mata dan otak manusia. Visi komputer sangat penting dan luas penerapannya, misalnya dalam pengawasan cerdas, kesehatan, robotika, kendaraan otonom, dan pengenalan pola pada berbagai aplikasi sehari-hari seperti deteksi penggunaan masker, scanner rumus matematika, atau estimasi tinggi badan menggunakan kamera. Komputer melakukan ekstraksi informasi dari

gambar digital melalui proses seperti pengolahan sinyal citra, klasifikasi citra, segmentasi objek, dan rekonstruksi citra (Marpaung et al., 2022).

2.2.5 Python

Python adalah bahasa pemrograman yang sangat populer dan banyak digunakan dalam pengembangan kecerdasan buatan (AI) serta machine learning. Python pertama kali dirilis pada tahun 1991 dan sejak itu berkembang pesat hingga menjadi salah satu bahasa pemrograman utama di dunia, termasuk masuk dalam tiga besar bahasa pemrograman setelah Java dan C pada tahun 2018.

Python dipilih karena sintaksnya yang sederhana dan fleksibel, sehingga memudahkan programmer untuk menulis kode yang mudah dibaca dan dipahami. Selain itu, Python memiliki ekosistem pustaka (library) yang sangat lengkap dan kaya, khususnya untuk kebutuhan machine learning dan data science, seperti NumPy, Pandas, Scikit-learn, TensorFlow, dan Keras (Wahyono, 2018).

2.2.6 Image Processing


Image processing adalah salah satu tahap penting dalam cabang ilmu computer vision. *Image processing* adalah proses manipulasi dan analisis citra digital untuk memperbaiki kualitas gambar, mengekstrak fitur penting, dan menyiapkan data citra agar dapat dianalisis lebih lanjut oleh sistem.

Di computer vision, *image processing* mencakup beberapa tahapan utama seperti *image acquisition* (pengambilan citra), *enhancement* (peningkatan kualitas citra), *restoration* (pemulihan citra), *segmentation* (pemisahan bagian citra), dan *feature extraction* (penarikan ciri-ciri penting dari citra). Tujuannya adalah menghasilkan data citra yang lebih mudah dipahami dan diinterpretasikan oleh algoritma kecerdasan buatan (Diah, 2015.).

2.2.7 Segmentasi Data

Segmentasi Data merujuk pada proses membagi dataset yang besar atau kompleks menjadi bagian-bagian yang lebih kecil atau subgrup berdasarkan kriteria tertentu. Tujuan dari segmentasi data adalah untuk memahami pola, tren, atau karakteristik tertentu dalam setiap kelompok, yang mungkin tidak terlihat ketika melihat keseluruhan dataset. Segmentasi ini dapat dilakukan berdasarkan berbagai parameter seperti demografi,

perilaku, atau atribut lainnya yang relevan dengan analisis yang dilakukan. Dalam konteks machine learning dan analisis data, segmentasi juga sering digunakan untuk meningkatkan akurasi model prediktif dengan memisahkan data ke dalam kelompok yang lebih homogen..




Gambar 2. 4 Segmentasi Data.

2.2.8 Algoritma YOLO (*You Only Look Once*)

YOLO (*You Only Look Once*) adalah sebuah algoritma deteksi objek yang menggunakan pendekatan jaringan saraf konvolusional (*Convolutional Neural Network*) tunggal untuk melakukan deteksi objek secara *real-time*. YOLO membagi gambar input menjadi grid dan setiap grid bertugas mendeteksi objek jika pusat objek jatuh ke dalam area grid tersebut. Setiap sel grid memprediksi *bounding box* (kotak pembatas) beserta nilai *confidence score* yang menunjukkan keyakinan model terhadap keberadaan objek dan probabilitas kelas objek tersebut secara langsung dalam satu kali evaluasi jaringan.

YOLO menggunakan 24 lapisan konvolusi diikuti oleh 2 lapisan *fully connected* pada arsitekturnya. Algoritma ini dikenal lebih cepat dan akurat dibanding metode deteksi objek lain karena memproses seluruh gambar sekaligus, bukan memindai bagian per bagian gambar. Dalam prosesnya, YOLO memprediksi beberapa *bounding box* pada setiap sel grid dengan koordinat pusat x dan y, lebar dan tinggi, serta *nilai confidence* yang menilai seberapa yakin algoritma bahwa *bounding box* tersebut berisi objek.

Penggunaan *non-maximum suppression* (NMS) membantu memilih bounding box terbaik dengan mengeliminasi tumpang tindih kotak yang kurang tepat.



Gambar 2. 5 Arsitektur YOLOv8

1. Backbone

Backbone bertugas mengekstraksi fitur visual dari input citra. Input awal berupa gambar dengan resolusi 640×640×3 akan diproses secara bertahap melalui operasi konvolusi dan blok C2f. Untuk setiap layer konvolusi, ukuran output dihitung menggunakan rumus:

$$O = \left\lceil \frac{i + 2p - k}{s} \right\rceil + 1$$

Keterangan: :

O : Ukuran *output* (*height/width*)

i : Ukuran *input* (*height/width*)

k : Ukuran kernel (filter), biasanya 3×3

s : *Stride* (langkah pergeseran filter)

p : *Padding* (jumlah piksel yang ditambahkan di tepi)

2. Neck

Bagian *neck* pada arsitektur YOLOv8 berfungsi untuk menggabungkan (aggregate) fitur dari berbagai skala yang telah diekstraksi oleh backbone. Proses ini melibatkan pengolahan fitur dari beberapa tingkat resolusi, yang memungkinkan model memperoleh representasi yang lebih kaya terhadap objek dengan ukuran yang bervariasi. Dengan mengintegrasikan informasi dari lapisan yang berbeda, *neck* meningkatkan kemampuan deteksi terhadap objek kecil maupun besar. YOLOv8 memang menggunakan struktur *neck* berbasis FPN + PANet untuk menggabungkan fitur multi-skala secara efisien.

3. Head

Bagian *head* pada YOLOv8 mengalami peralihan dari pendekatan deteksi berbasis *anchor tradisional* menuju desain *anchor-free*, dengan mengadopsi arsitektur terpisah (*decoupled architecture*) yang memproses tugas klasifikasi dan regresi secara independen. Pemisahan ini memungkinkan optimasi yang lebih spesifik pada masing-masing tugas, sehingga meningkatkan performa deteksi. Kombinasi ini tidak hanya memperbaiki akurasi lokalisasi *bounding box*, tetapi juga meningkatkan efisiensi komputasi dalam proses deteksi objek. Koordinat *bounding box* merupakan representasi numerik yang digunakan untuk menentukan posisi dan ukuran kotak pembatas objek dalam citra. Dalam arsitektur YOLOv8, parameter ini biasanya direpresentasikan dalam format pusat kotak, yaitu (x,y,w,h) di mana x dan y menunjukkan posisi pusat kotak relatif terhadap ukuran gambar, sedangkan w (width) dan h (height) merepresentasikan lebar dan tinggi kotak relatif terhadap dimensi gambar (Li et al., 2026).

Intersection Over Union (IoU)

Intersection over Union (IoU) merupakan sebuah metrik yang digunakan untuk menghitung tingkat tumpang tindih atau persilangan antara bounding box prediksi dengan bounding box sebenarnya. Metrik ini berfungsi untuk menilai seberapa akurat model dalam mendeteksi atau mengenali objek dengan cara membandingkan area yang diprediksi dengan area yang sesungguhnya. Semakin besar nilai IoU, maka semakin baik kualitas deteksi yang dihasilkan (Rezatofighi et al., 2019).

Secara matematis, IoU didefinisikan sebagai:

$$IoU = \frac{Area\ of\ Overlap}{Area\ of\ Union}$$

Keterangan:

Area of Overlap : luas area yang merupakan irisan antara bounding box prediksi dan ground truth.

Area of Union : total area gabungan dari bounding box prediksi dan ground truth, yang dihitung dengan

Output Tensor

Output tensor merupakan representasi numerik hasil prediksi model yang berisi informasi posisi bounding box, skor keberadaan objek, dan probabilitas kelas untuk setiap kotak pada semua grid cell di skala tertentu (Terven dkk., 2023). Output tensor dapat dihitung dengan rumus.

$$S \times S \times (nB \times 5 + nC)$$

Keterangan:

$S \times S$: Jumlah *grid cell* pada skala gambar

nB : Jumlah *bounding box* yang diprediksi pada setiap *grid cell*

5 : Jumlah parameter per bounding box (4 koordinat + 1 objek)

nC : Jumlah Kelas

NMS (*Non-Maximun Supression*)

NMS merupakan algoritma post-processing yang esensial dalam bidang computer vision, khususnya pada tugas deteksi objek. Algoritma ini berfungsi untuk merapikan hasil prediksi model dengan menghilangkan bounding box yang berlebih dan saling bertumpukan, sehingga setiap objek hanya terdeteksi satu kali. Pada saat model deteksi objek seperti Ultralytics YOLO melakukan prediksi, 22 biasanya dihasilkan beberapa bounding box di sekitar objek yang sama dengan nilai confidence score yang berbeda-beda. NMS berperan dalam memilih satu bounding box terbaik dengan skor tertinggi dan menyingkirkan bounding box lainnya yang memiliki tumpang tindih dan tidak memenuhi kriteria maksimal (Ultralytics, 2025).

Pada model YOLO-Segmentation, terdapat proses tambahan yang dilakukan pada bagian Prediction Head, yaitu komponen akhir dalam arsitektur jaringan yang berfungsi menghasilkan keluaran deteksi dan segmentasi objek. Bagian ini menerima fitur yang telah diekstraksi oleh backbone dan dipadukan melalui neck, kemudian memetakan fitur tersebut ke dalam bentuk prediksi yang mencakup koordinat bounding box, nilai confidence, kategori kelas objek, serta mask segmentasi.

1. Koordinat *Bounding Box*

Koordinat *Bounding Box* Empat parameter prediktif utama yaitu:

bx: koordinat pusat kotak prediksi pada sumbu-x

by: koordinat pusat kotak prediksi pada sumbu-y

bw: lebar bounding box relatif terhadap dimensi gambar

bh: tinggi bounding box relatif terhadap dimensi gambar.

2. Koefisien Vektor Mask (Mask Coefficients)

Untuk segmentasi objek, YOLO-Seg menghasilkan vektor mask berukuran 32 dimensi (R^{32}) untuk setiap objek yang terdeteksi. Vektor ini disebut sebagai mask coefficient, dan akan dikombinasikan dengan tensor prototype mask yang memiliki dimensi tetap, misalnya $160 \times 160 \times 32$, untuk membentuk segmentasi akhir secara piksel demi piksel.

Proses segmentasi pada YOLO-Seg mengadopsi konsep *instance segmentation* berbasis prototype. Pendekatan ini memisahkan representasi global dan spesifik objek,

di mana setiap objek direpresentasikan oleh sebuah vektor koefisien, sementara informasi spasial global disimpan dalam bentuk *prototype feature maps*. Kombinasi keduanya dilakukan melalui operasi linier berupa *dot product*, sehingga mampu menghasilkan mask objek yang presisi pada tingkat piksel .

Konsep pemisahan antara *prototype mask* dan *mask coefficient* ini pertama kali diperkenalkan secara sistematis pada metode YOLACT, yang menunjukkan bahwa segmentasi dapat dilakukan secara efisien dengan mengombinasikan peta fitur global dan vektor mask objek melalui operasi linier sederhana (Bolya et al., 2019). Dalam implementasi YOLO-Seg, setiap objek yang terdeteksi menghasilkan sebuah vektor mask coefficient berdimensi tetap, misalnya 32 dimensi (R^{32}). Secara paralel, jaringan juga menghasilkan sebuah tensor *prototype mask* global berukuran $H \times W \times C$, misalnya $160 \times 160 \times 32$, yang berlaku untuk seluruh citra. Mask akhir kemudian dibentuk melalui kombinasi linier antara *mask coefficient* dan *prototype mask* tersebut, sehingga diperoleh hasil segmentasi objek secara *pixel-wise* yang efisien dan akurat x (Ultralytics, 2025).

1. Perkalian Linier antara *Mask Coefficient* dan *Prototype Mask*

Setiap objek hasil deteksi memiliki sebuah vektor *mask coefficient* :

$$c = [c_1, c_2, \dots, c_3]$$

yang kemudian dikombinasikan dengan tensor *prototype mask*

$$P \in R^{H \times W \times 32}$$

melalui operasi linier secara *channel-wise*. Untuk setiap posisi piksel (x,y), nilai mask awal dihitung menggunakan operasi *dot product* sebagai berikut:

$$M_{(x,y)} = \sum_{i=1}^{32} c_i \cdot P_i(x, y)$$

di mana $P_i(x, y)$ merepresentasikan nilai *prototype mask* pada kanal ke- i di koordinat (x,y).

2. Penerapan Fungsi Aktivasi

Hasil dari operasi linier tersebut kemudian dilewatkan ke dalam fungsi aktivasi sigmoid untuk memetakan nilai mask ke dalam rentang probabilitas $[0, 1]$:

$$M_{x,y} = \frac{1}{1 + e^{-M_{x,y}}}$$

3. Thresholding

Tahap akhir dilakukan dengan menerapkan nilai ambang (*threshold*), misalnya 0,5, untuk menghasilkan *mask* biner, di mana piksel dengan nilai di atas ambang diklasifikasikan sebagai bagian objek, sedangkan sisanya dianggap sebagai latar belakang.

2.2.9 Confusion Matrix

		Predicted		
		165	NO	YES
Actual	NO	50 [TN]	10 [FP]	60
	YES	5 [FN]	100 [TP]	105
		55	110	

Gambar 2. 6 Confusion Matrix

Confusion matrix adalah alat analisis yang menggambarkan secara rinci bagaimana model klasifikasi membuat keputusan, dengan menunjukkan hitungan hasil prediksi benar dan salah dalam tiap kelas. Ini memungkinkan evaluasi yang komprehensif terhadap akurasi dan kesalahan model, sehingga dapat digunakan untuk memperbaiki algoritma dan menyesuaikan strategi pelatihan. Dengan membantu melihat pola kesalahan prediksi, *confusion matrix* menjadi fondasi penting dalam pengukuran performa klasifikasi model sehingga pengembang dapat melakukan tuning parameter dan memilih pendekatan terbaik untuk aplikasi nyata (Fadillah Grandis & Arumsari, 2021)

Berikut adalah beberapa rumus yang digunakan dalam *confusion matrix* :

1. Rumus menghitung Presisi:

$$Precision = \frac{TP}{TP + FP}$$

2. Rumus menghitung Recall :

$$Recall = \frac{TP}{TP + FN}$$

3. Rumus menghitung f1-score :

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

2.2.10 Mean Average Precision (mAP)

mean Average Precision (mAP) adalah metrik evaluasi yang sering digunakan untuk menilai kinerja model deteksi objek seperti YOLO. mAP merupakan rata-rata dari Average Precision (AP) pada beberapa kelas objek yang dideteksi. Average Precision (AP) sendiri adalah pengukuran presisi rata-rata pada berbagai tingkat recall (tingkat keberhasilan dalam mendeteksi semua objek) selama proses evaluasi model. Dengan kata lain, AP mengukur seberapa baik model dalam mendeteksi objek yang benar pada berbagai ambang batas deteksi, lalu mAP adalah rata-rata AP dari keseluruhan kelas objek yang diprediksi (Komputer et al., 2024).

Rumus untuk menghitung nilai mAP

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$


Keterangan :

N = Jumlah total kelas

AP = *Average Precision*

I = Indeks Kelas

2.2.11 Metode CRISP-DM (*Cross-Industry Standard Process for Data Mining*)



Gambar 2. 7 CRISP-DM

CRISP-DM merupakan pedoman komprehensif yang membantu para praktisi data mining menavigasi seluruh siklus hidup proyek data mining dengan langkah-langkah yang terstruktur dan praktis. Dimulai dari memahami tujuan bisnis secara mendalam, mengenali kondisi dan kualitas data yang ada, hingga mempersiapkan data dengan cermat sebelum membangun model yang sesuai. Setelah model diuji dan dievaluasi secara ketat agar hasil sesuai harapan, kemudian hasilnya dipakai untuk pengambilan keputusan bisnis yang konkret. Pendekatan iteratif ini memungkinkan perbaikan berkelanjutan dan penyesuaian dengan kebutuhan bisnis yang dinamis. Dengan CRISP-DM, risiko kesalahan dalam proyek data mining berkurang dan peluang keberhasilan proyek menjadi lebih tinggi (Irawan Budiman, 2012).

1. *Business Understanding* merupakan tahap berfokus pada pemahaman tujuan dan kebutuhan bisnis yang ingin dicapai dengan proyek data mining. Aktivitas utama meliputi identifikasi masalah bisnis, penentuan tujuan penelitian, serta perencanaan strategi dan jadwal proyek. Tahap ini sangat penting karena hasil data mining harus relevan dan berguna dalam konteks bisnis yang sebenarnya.

2. *Data Understanding* merupakan tahap yang bertujuan mengumpulkan data awal, mengenal karakteristik data, dan mengidentifikasi masalah kualitas data yang mungkin ada. Eksplorasi awal data membantu mengungkap pola, anomali, dan informasi menarik untuk menyempurnakan hipotesis dan pemahaman domain.
3. *Data Preperation* merupakan tahap untuk dilakukan pemurnian data dan diproses agar sesuai untuk pemodelan data mining, termasuk pembersihan data, transformasi, integrasi dari berbagai sumber, serta pemilihan subset data yang relevan. Tahap ini sering kali paling padat karya dan memakan waktu, namun sangat menentukan keberhasilan hasil akhir.
4. *Modelling* merupakan tahap teknik data mining dipilih dan diterapkan pada data yang telah disiapkan untuk menemukan pola yang diinginkan. Parameter model dioptimalkan untuk meningkatkan kinerja. Tahap ini dapat melibatkan berbagai teknik seperti clustering, klasifikasi, dan regresi.
5. *Evaluation* merupakan tahap yang bertujuan menilai performa model yang dibuat terhadap tujuan bisnis awal. Evaluasi juga mengecek apakah model layak dan dapat diandalkan untuk digunakan dalam pengambilan keputusan. Jika diperlukan, model dapat diperbaiki atau diulang kembali tahap sebelumnya.
6. *Deployment* merupakan hasil akhir dari proyek data mining disiapkan dalam bentuk laporan, presentasi visual, atau integrasi ke dalam sistem operasional bisnis untuk digunakan secara nyata. Tahap ini memastikan bahwa pengetahuan yang diperoleh dapat memberikan nilai tambah bagi organisasi.

2.2.12 Roboflow

Roboflow dapat dianggap sebagai solusi *end-to-end* yang menyederhanakan dan mengotomatisasi seluruh proses pengolahan data dan pengembangan model deep learning berbasis citra digital. Dengan Roboflow, para peneliti dan praktisi dapat lebih cepat melakukan anotasi dan pelabelan data secara visual, mempersiapkan dataset berkualitas tinggi, serta langsung melatih dan menguji model dengan metrik evaluasi yang transparan dan mudah dipahami. Kelebihan ini sangat menguntungkan terutama untuk proyek-proyek yang memerlukan segmentasi dan deteksi objek secara presisi dan real-time, seperti aplikasi medis untuk diagnosis otomatis dari citra diagnostik, termasuk radiografi





panoramik gigi yang membutuhkan akurasi tinggi dan kecepatan proses. *Roboflow* juga mendukung penggunaan algoritma canggih seperti YOLOv8, yang terkenal dengan kecepatan dan ketepatannya, sehingga menghadirkan platform yang kuat dan intuitif untuk mengembangkan solusi AI yang bisa diaplikasikan secara luas dengan efisiensi tinggi (Mahdiyah et al., 2025).

2.2.13 Google Colab

Google Colab merupakan alat yang sangat membantu bagi peneliti dan praktisi data karena menyederhanakan seluruh proses analisis dan pengembangan model dengan antarmuka notebook yang ramah pengguna serta kemampuan komputasi tingkat tinggi secara gratis. Colab memungkinkan pengguna fokus pada pemrosesan data dan analisis tanpa terbebani oleh keterbatasan perangkat keras lokal atau instalasi software rumit. Fitur kolaborasi real-time juga memfasilitasi kerja tim dari lokasi berbeda secara mudah dan efisien.

Dengan fasilitas GPU gratis, Google Colab sangat diminati untuk kebutuhan machine learning dan deep learning yang memerlukan komputasi intensif. Platform ini ideal untuk eksperimen, pengembangan model, hingga presentasi hasil riset secara interaktif dan berbagi dengan mudah melalui Google Drive. Secara keseluruhan, Google Colab mempercepat dan mempermudah eksplorasi data dan pengembangan solusi cerdas berbasis Python di era data saat ini (Farid et al., 2024).

2.2.14 Flowchart


	Flow Direction symbol Yaitu simbol yang digunakan untuk menghubungkan antara simbol yang satu dengan simbol yang lain. Simbol ini disebut juga connecting line.		Simbol Manual Input Simbol untuk pemasukan data secara manual on-line keyboard
	Terminator Symbol Yaitu simbol untuk permulaan (start) atau akhir (stop) dari suatu kegiatan		Simbol Preparation Simbol untuk mempersiapkan penyimpanan yang akan digunakan sebagai tempat pengolahan di dalam storage.
	Connector Symbol Yaitu simbol untuk keluar - masuk atau penyambungan proses dalam lembar / halaman yang sama.		Simbol Predefine Proses Simbol untuk pelaksanaan suatu bagian (sub-program)/prosedure
	Connector Symbol Yaitu simbol untuk keluar - masuk atau penyambungan proses pada lembar / halaman yang berbeda.		Simbol Display Simbol yang menyatakan peralatan output yang digunakan yaitu layar, plotter, printer dan sebagainya.
	Processing Symbol Simbol yang menunjukkan pengolahan yang dilakukan oleh komputer		Simbol disk and On-line Storage Simbol yang menyatakan input yang berasal dari disk atau disimpan ke disk.
	Simbol Manual Operation Simbol yang menunjukkan pengolahan yang tidak dilakukan oleh computer		Simbol magnetik tape Unit Simbol yang menyatakan input berasal dari pita magnetik atau output disimpan ke pita magnetik.
	Simbol Decision Simbol pemilihan proses berdasarkan kondisi yang ada.		Simbol Punch Card Simbol yang menyatakan bahwa input berasal dari kartu atau output ditulis ke kartu
	Simbol Input-Output Simbol yang menyatakan proses input dan output tanpa tergantung dengan jenis peralatannya		Simbol Dokumen Simbol yang menyatakan input berasal dari dokumen dalam bentuk kertas atau output dicetak ke kertas.

Gambar 2. 8 Flowchart

Flowchart atau diagram alir adalah jenis diagram yang menggambarkan algoritma atau langkah-langkah instruksi berurutan dalam sebuah sistem. Flowchart digunakan oleh analis sistem sebagai alat dokumentasi untuk menjelaskan gambaran logis sistem yang akan dibangun kepada programmer. Flowchart digambarkan menggunakan simbol-simbol khusus yang mewakili proses tertentu, dan setiap simbol dihubungkan dengan garis untuk menunjukkan alur proses. Dengan flowchart, proses sistem dapat divisualisasikan dengan jelas, serta memudahkan penambahan proses baru dan pemahaman sistem secara keseluruhan.

2.3 Kerangka Pemikiran

Gambar dibawah merupakan kerangka pemikiran dari penelitian ini :



Gambar 2. 9 Kerangka Pemikiran

2.3.1 Input

Bagian pertama adalah input yang berisi dataset *corona discharge*. Dataset ini merupakan data mentah yang berisi gambar atau data terkait fenomena *corona discharge* yang akan dianalisis oleh sistem.

2.3.2 Process

Bagian kedua adalah "Process" yang menunjukkan tahap pemrosesan data. Pada tahap ini, algoritma YOLOv8 digunakan untuk menganalisis dataset, melakukan deteksi dan klasifikasi pola *corona discharge* secara otomatis.

2.3.3 Measurement

Tahap "Measurement" menampilkan metrik yang digunakan untuk mengevaluasi kinerja hasil proses klasifikasi. Metrik tersebut meliputi Presisi, Recall, F1-score. Ketiga metrik ini digunakan untuk menilai seberapa baik model mendeteksi dan mengklasifikasikan corona discharge dari dataset yang diberikan.

2.3.4 Output

Bagian akhir adalah "Output" yang menunjukkan hasil akhir dari sistem, yaitu model tingkat corona discharge yang sudah dilatih dan dievaluasi.