

BAB 2

DASAR TEORI

2.1 KAJIAN PUSTAKA

Penelitian yang dimaksudkan digunakan untuk tujuan memperoleh barang telah dilakukan dan didistribusikan secara lengkap di berbagai industri di Indonesia. Di masa lalu, penelitian telah menunjukkan bahwa ada persyaratan untuk menggunakan gambar digital untuk memfasilitasi pengguna dalam pemecahan masalah. Beberapa studi telah dilakukan pada masalah yang telah dijelaskan dalam paragraf sebelumnya dengan menggunakan teknik gambar resminya atau gambar resmenya. Penelitian yang disajikan di sini memeriksa metode pembelajaran mesin dan pembelajaran mendalam, yang keduanya memiliki potensi untuk memberikan manusia dengan berbagai fungsi yang berguna [15].

Sesuai dengan temuan penelitian yang dilakukan oleh [16], untuk mendeteksi mata uang asing, aplikasi untuk internet dan perangkat *mobile* telah dikembangkan untuk mengidentifikasi valuta asing. Parameter yang digunakan adalah denominasi mata uang dalam bentuk rupiah, dan itu Rs. 200, Rs. 500, dan Rs. 2000. Hal ini dilakukan untuk dapat meningkatkan akurasi yang tepat. Dengan menggunakan bantuan algoritma *Deep Neural Network*, sistem ini mampu mendeteksi mata uang asing dengan akurasi hingga 96,6% dan tingkat pembelajaran 0,001 [16].

Penelitian yang dilakukan oleh [17] di bawah judul "Counterfeit Currency Detection using *Deep Convolutional Neural Network*" didasarkan pada penelitian yang dilakukan [16] menggunakan metodologi *Deep Neural Networks*. Namun, tujuan penelitian ini adalah untuk mengembangkan aplikasi yang mampu mendeteksi nilai mata uang yang bukan rupiah atau palsu yang terkait dengan rupiah. Dataset ini dikumpulkan dengan menggunakan kamera smartphone yang dirancang khusus untuk tujuan mengevaluasi sistem yang mampu mendeteksi nilai moneter yang nyata atau palsu dengan tingkat akurasi yang tinggi. Salah satu parameter yang digunakan adalah Mata Uang Nasional, juga dikenal sebagai *Rupee*, dengan rentang denominasi yang berkisar dari 500 hingga 2000 pound.

Menurut temuan penelitian ini, sistem yang dibahas mampu mendeteksi nilai unit moneter, juga dikenal sebagai palsu, dengan tingkat akurasi 85,6% untuk pengumpulan data, 98,57% untuk validasi data, dan 96,55% untuk informasi longitudinal [16].

Sebagai bagian dari proyek penelitian berjudul “*Recognition of damaged Indonesian Rupiah banknote for denomination detection based on Convolutional Neural Network (CNN)*” para peneliti menganalisis penggunaan CNN untuk tujuan mengidentifikasi banknote yang telah rusak. Proses yang telah dilakukan dalam penelitian ini melibatkan ekstraksi fitur dan juga klasifikasi dengan bertujuan membangun sistem yang mampu mengklasifikasi tentang uang rupiah Indonesia yang rusak menggunakan algoritma *Convolutional Neural Network* melalui metode *Deep Learning* sebagai detektor denominasi mata uang. Proses yang sedang dilakukan dalam penelitian ini adalah untuk menentukan nilai rupiah Indonesia yang dibebaskan dari penerbitan pada tahun 2017 dengan denominasi Rp. 2.000, Rp. 5.000, dan Rp. 10.000. Penggunaan model arsitektur enam lapisan berturut-turut menghasilkan 600 citra data untuk setiap unit mata uang yang digunakan. Total lima filter tersedia untuk digunakan, dan mereka adalah sebagai berikut: 32, 64, 128, 256, dan 512. ReLU dan sigmoid adalah dua jenis fungsi yang digunakan. Sistem ini berhasil mendeteksi denominasi yang berasal dari rupiah Indonesia dengan nilai 100 persen dengan menggunakan metode CNN dengan ukuran inti tiga per tiga dan tingkat belajar seribu. Itu adalah [3].

Studi [1] menyelidiki "Klasifikasi Bank Indonesia Rupiah Nominal Tahun Emisi 2017 Menggunakan Algoritma Jaringan *Neural Convolutional*" MXNET digunakan untuk tujuan mendeteksi mata uang nominal dengan menggunakan sebuah teknik *Deep Learning* bersama dengan algoritma matematika *Convolutional Neural Network (CNN)*. Proses yang ingin dilakukan dalam penelitian ini melibatkan ekstraksi fitur dan klasifikasi dengan tujuan membangun sistem yang mampu mengklasifikasikan denominasi mata uang kertas menggunakan algoritma Jaringan *Neural Convolutional* yang diimplementasikan dengan MXNet. Dalam hal klasifikasi nilai tukar mata uang, tujuannya adalah untuk mencapai tingkat akurasi yang tinggi dalam nilai tukar mata uang. Parameter yang di gunakan adalah mata uang rupiah Indonesia yang

diperkenalkan pada tahun 2016 dengan denominasi berikut: Rp 1.000, Rp 2.000, Rp 5.000, Rp 10.000, Rp 20.000, Rp 50.000, dan Rp 100.000. Uang dibagi menjadi dua bagian: bagian pertama, yang mewakili mata uang nasional Indonesia, dan bagian kedua, yang melambangkan mata uang tradisional Indonesia. Kedua bagian ini menggambarkan mata uang nasional Indonesia. Sistem ini berhasil mendeteksi nilai kurs mata uang dengan akurasi 93.57%, Ini menggunakan arsitektur model CNN dengan ukuran inti 3x3 untuk konversi pertama, 2x2 untuk konvolusi kedua, dan total 20 filter lapisan. Jumlah iterasi yang digunakan adalah lima puluh [1].

Dalam konteks "Pengenalan Denominasi Mata Uang Kertas menggunakan *Backpropagation Artificial Neural Network*," sebuah studi yang dilakukan oleh [18] juga melakukan penelitian pada subjek denominasi mata uang kertas. Menggunakan jaringan saraf buatan *Backpropagation* dengan tingkat akurasi yang tinggi, tujuan penelitian ini adalah untuk mengembangkan sistem yang mampu menentukan nilai mata uang negara. Di antara parameter yang digunakan adalah nilai tukar mata uang rupiah Indonesia, yang dinyatakan dalam Rp. 20.000, Rp. 50.000, dan Rp. 100.000 masing-masing. Sistem ini berhasil mendeteksi Uang Tunai dengan tingkat akurasi 78,8% dan tingkat ketepatan 78,8%. Selain itu, sistem mendeteksi Rp. 20.000 di sekitar 96,67% kasus, Rp. 50.000 di sekitar 73,3% kasus, dan Rp 100.000 di 66,67 % kasus. Itu adalah [18].

Penelitian tentang nilai nominal rupiah Indonesia dilakukan oleh [19] mengenakan metode SURF dan FLANN untuk mengidentifikasi denominasi rupiah kertas yang didistribusikan pada tahun 2016 dengan variabel yang didasarkan pada rotasi. Untuk tujuan menerapkan dan menganalisis tingkat akurasi pengidentifikasi nominal uang rupiah Indonesia menggunakan metode SURF dan FLANN pada variabel rotasi, tujuan penelitian ini adalah untuk dilakukan. Dalam penelitian ini, parameter rupiah Indonesia yang diungkapkan pada tahun 2016 secara spesifik difokuskan pada denominasi berikut: Rp 1.000,00, Rp 2.000,00, RM 5.000,00 dan Rp 20.000.00. Perpustakaan Cepat untuk Tetangga Terdekat (FLANN) adalah metode yang digunakan dalam penelitian ini untuk mengidentifikasi karakteristik nilai tukar nominal rotasi. Tujuan dari penelitian ini adalah untuk mendeteksi variasi dalam nilai tukar nominal. Sistem

ini mampu secara akurat mendeteksi nilai mata uang berdasarkan variasi rotasi, dan dapat mencapai tingkat akurasi seratus persen [19].

Dalam paragraf berikutnya, penelitian "Klasifikasi Gambar Menggunakan Jaringan *Neural Convolutional* dan Validasi Jalur K-Fold" dilakukan oleh [20]. Tujuan penelitian ini adalah untuk menggunakan algoritma CNN untuk klasifikasi gambar dengan menggunakan perpustakaan Keras dan *TensorFlow* menggunakan *Python*. Dalam penyelidikan saat ini, dataset yang digunakan adalah koleksi gambar yang diperoleh dari *Google Images*. Koleksi ini terdiri dari 2.200 foto. Selain itu, ada 1400 gambar yang termasuk dalam kategori bunga mawar, 1400 foto yang termasuk kategori tulip, dan 1400 gambar milik kategori bunga matahari. tingkat akurasi tertinggi yang dihasilkan dari penelitian ini adalah 80.36%, dengan rata-rata ketepatan tertinggi datang di 76.49%, dan sistem ketepatannya datang ke 72.02%. Persentase tanah yang diterima sebagai kompensasi adalah 66.07%. Dengan tingkat prediksi rata-rata 60,31 persen dan nilai prediksi tertinggi 65,47 persen, sistem yang telah dibangun mampu membuat prediksi [20].

Penelitian berikutnya yang dilakukan oleh [21] dengan judul "Klasifikasi Gambar Buah Menggunakan Jaringan *Neural Convolutional*" menggunakan arsitektur CNN yang terdiri dari kombinasi tiga lapisan CNN dan dua lapis CNN yang terhubung satu sama lain. Teknik yang digunakan dikenal sebagai *Deep Learning*, dan langkah-langkah utama yang terlibat dalam proses penelitian adalah pengumpulan data, desain sistem, pelatihan, dan evaluasi. Dataset khusus ini berasal dari dataset Fruit-360, yang berisi total 11 dari 111 kelas. Untuk tujuan mengevaluasi model CNN kinerja yang berasal dari proses belajar, proses yang dijelaskan di sini menggunakan 345 gambar, yang terdiri dari 23 gambar dari 15 kelas gambar buah. Proses belajar memiliki tingkat keberhasilan seratus persen dan tingkat kegagalan nol dua belas. Selama proses pengembangan model CNN, 45 contoh yang berbeda dari gambar terang digunakan, dan tingkat akurasi adalah 97,97% [21].

Menurut temuan penelitian yang ditunjukkan sebelumnya, dapat disimpulkan bahwa CNN mampu secara efektif mengklasifikasikan gambar, mirip dengan apa yang disajikan oleh hasil analisis sensitivitas. Ada beberapa metode

yang berbeda yang dapat digunakan dalam sistem klasifikasi untuk nilai nominal rupiah Indonesia. Metode ini termasuk *FLANN*, *SURF*, *Backpropagation Artificial Neural Networks*, *Deep Neural Network*, dan *Convolutional Neural Networks*. (CNN). Namun, studi ini menyajikan model *Deep Learning* yang menggunakan metode CNN dengan dataset yang terdiri dari rupiah Indonesia setara dari tahun 2022 di mana penelitian ini dilakukan. Sebagai hasil dari fakta bahwa studi sebelumnya tidak menggunakan mata uang baru yang diperkenalkan pada tahun 2022, khususnya rupiah Indonesia dari tahun 2022 yang diterbitkan pada hari Kemerdekaan Indonesia, yaitu 17 Agustus 2022, sebagai parameter untuk evaluasi, studi ini dikembangkan. Akibatnya, tujuan penelitian ini adalah untuk menentukan apakah sistem ini mampu menentukan dengan akurat nilai baru mata uang rupiah Indonesia dari tahun 2022 ke depan.

Tabel 2. 1 Penelitian Terdahulu

| Penulis penelitian | Judul penelitian | Metode penelitian | Hasil penelitian |
|-------------------------------------|--|---|---|
| f. S. Burta [1] | Mengklasifikasi nominal uang kertas rupiah tahun emisi 2017 dengan algoritma <i>Convolutional Neural Network</i> (CNN) menggunakan mxnet | CNN (Ukuran <i>kernel</i> digunakan 3x3 untuk konvolusi pertama, 2x2 untuk konvolusi kedua, 20-layer) | Mendeteksi nominal pecahan uang kertas dengan akurasi terbaik 93,57% [1] |
| Octavian ery pamungkas [3] | <i>Classification of Rupiah to Help Blind with The Convolutional Neural Network (CNN) Method</i> | CNN (6-layer <i>sequential</i>) dengan filter 32, 64, 128, 256, 512; fungsi aktivasi <i>ReLU</i> dan sigmoid | Mendeteksi nominal pecahan uang Rupiah kertas rusak dengan akurasi 100% menggunakan <i>kernel</i> 3x3 dan <i>Learning Rate</i> 0.0001 |
| k.Horodecki and m. Stankiewicz [16] | Identifikasi nominal pada mata uang rupiah bagi penyandang tunanetra dengan algoritma <i>Convolutional Neural Network</i> berbasis android | Metode <i>Deep Neural Network</i> . | Mendeteksi tentang mata uang Rupee palsu dengan akurasi 96,6% menggunakan aplikasi berbasis web dan ponsel. Parameter: Pecahan mata uang Rupee palsu dengan nominal Rs 200, Rs 500, dan Rs 2000 ; <i>Learning Rate</i> 0,001 [15] |

| | | | |
|---|---|---|---|
| k. Kamble [17] | <i>Counterfeit Currency Detection.using Deep Convolutional Neural Network.</i> | <i>Deep Neural Network.</i> | Mendeteksi uang Rupee asli atau palsu dengan akurasi 85,6% (<i>Testing</i>), 98,57% (<i>validasi</i>), 96,55% (<i>Training</i>) |
| a. Peryanto, a. Yudhana, and r. Umar [18] | Pendeteksi Keaslian Mata Uang Rupiah Berbasis Android menggunakan Algoritma. <i>Convolutional Neural Network (CNN)</i> dengan <i>TensorFlow</i> | <i>Backpropagation Neural Network</i> | Mendeteksi nominal uang kertas dengan akurasi 78,8%, presisi pada uang Rp. 20.000 96,67%, Rp. 50.000 73,3%, dan Rp. 100.000 66,67% [17] |
| a. Priadana, a. W Murdiyanto, and a. W. Murdiyanto [19] | Metode SURF dan FLANN untuk Identifikasi Nominal Uang Kertas Rupiah Tahun Emisi 2016 pada Variasi Rotasi <i>Identification of Rupiah.Paper Currency Denomination using SURF dan FLANN Methods at Rotation Variation</i> | Metode SURF dan FLANN. | Mendeteksi variasi rotasi nominal uang kertas dengan akurasi 100% [18] |
| a. M. N. Hidayat and a. Antamil [20] | Klasifikasi Citra ini Menggunakan <i>Convolutional Neural Network (CNN)</i> dan <i>K Fold Cross Validation</i> | CNN dengan library Keras dan <i>TensorFlow</i> | Akurasi tertinggi 80,36%, rata-rata akurasi tertinggi 76,49%, akurasi sistem 72,02%, akurasi terendah 66,07% [19] |
| f. F. Maulana and n. Rochmawati [21] | Klasifikasi Citra Buah Menggunakan <i>Convolutional Neural Network</i> | CNN (3 CNN layer, 2 <i>Fully Connected</i> layer) | Akurasi 100% dan <i>Loss</i> 0,012 pada proses <i>Learning</i> ; akurasi 97,97% pada proses pengujian [20] |

2.2 DASAR TEORI

Selain itu, sebagai dasar teori, artikel ini mencakup beberapa teori dasar yang mendukung penelitian ini, seperti:

2.2.1 Uang Kertas Rupiah

Uang ialah suatu bentuk aset yang dapat dengan mudah diterima sebagai pembayaran dalam transaksi pembelian barang, jasa, dan hutang. Rupiah adalah

mata uang negara Republik Indonesia, dan penggunaannya tersebut dilindungi dengan adanya Undang-Undang Nomor 7 tahun 2011 [22]. Satu-satunya lembaga yang dapat melakukan penerbitan, distribusi, dan penarikan uang rupiah Indonesia adalah Bank Indonesia. Orang paling sering menggunakan uang untuk melakukan transaksi. Nilai nominal setiap mata uang digunakan untuk mengukur nilai barang dan jasa yang diperdagangkan.

Uang memiliki karakteristik yang berbeda dan fitur spesifik untuk mencegah penipuan. Upaya ini meliputi, Tanda air adalah gambar yang terlihat yang dapat diamati ketika dilihat terhadap cahaya. Benang Pengaman adalah sebuah mana-mana yang terlihat sebagai garis horizontal yang melintang dari atas ke bawah. Cetak intaligo adalah cetakan yang memiliki tekstur kasar saat disentuh, Garis interferensi adalah berbagai pola yang menghasilkan jejak pada permukaan depan dan belakang dan saling mengisi ketika diterangi dari arah tertentu. Tinta berubah berwarna adalah fenomena di mana warna tinta dapat berubah-ubah ketika perspektif yang berbeda. Penulisan mikroskopis menggambarkan teks yang lebih kecil yang dapat dibaca melalui kaca pembesaran. Ink tak terlihat adalah tinta yang tidak terlihat dengan mata telanjang tetapi menjadi terlihat di bawah sinar ultraviolet. Gambar tersembunyi mengacu pada teks tersembunyi yang dapat dilihat dari perspektif tertentu [15].

Untuk penelitian ini, akan digunakan uang kertas rupiah Indonesia dengan denominasi Rp. 1 juta, Rp. 2 juta, Rp. 5 juta, Rp. 10 juta, Rp. 20 juta, dan Rp. 50 juta. Koin ini memiliki dua sisi: bagian depan menampilkan pahlawan nasional Indonesia, dan bagian belakang menampilkan tarian tradisional Indonesia. Ini adalah gambar uang kertas rupiah : [23].



Gambar 2. 1 Uang Kertas Rupiah Yang Dirilis Pada Tahun Emisi 2022 [23]

Dalam penelitian ini, kami menggunakan rupiah Indonesia sebagai unit akuntansi untuk tahun 2022, dengan nilai Rp. 1000, Rp. 2000, Rp. 5.000, Rp.

10.000, Rp. 20.000, Rp. 50.000, dan Rp. 100.000. Di sebelah kiri, kita memiliki bendera nasional Indonesia, dan di sebelah kanan kita memiliki hidangan tradisional Indonesia yang digunakan sebagai alat pengukuran. Dilihat pada Gambar 2.1 menampilkan nilai tukar dengan nilai nominal yang telah berbeda dengan yang sebagian besar dalam keadaan murni atau dekat dengan edar. Ini tergantung pada beberapa faktor, seperti nilai tukar mata uang, harga tukar, dan kualitas mata uang yang diperdagangkan dalam mata uang kertas dan logam [24].

2.2.2 Ciri-Ciri Uang Kertas Rupiah

Keaslian atau orisinalitas uang rupiah Indonesia dapat diukur melalui atributnya. Beberapa atribut uang nyata dapat dilihat dari berbagai sudut pandang, seperti bahan yang digunakan, desain, dan ukuran uang, dan langkah terakhir dalam teknik uangtaktik. Secara fisik, uang mentah dapat dilihat dalam tiga dimensi, yaitu sebagai sfera, sfera dan sfera [25]. Bisa dilihat bahwa uang ini memiliki peringatan yang lebih terang dan jelas, bahwa ada pengaman benang, dan bahwa beberapa pecahan mata uang memiliki Optical Variable Ink (OVI). Mengenai metode perdagangan ini, uang sungguhan akan bernilai kurang saat perdagangan karena uang yang tidak dicetak memiliki nilai relief. Selain itu, ada kode buta, uang ini, juga dikenal sebagai kode netra, akan digunakan untuk membantu tunanetra dalam meningkatkan penggunaan uang kertas Indonesia. Cara terakhir adalah dengan menerawang. Dengan menerawang, Anda akan melihat Gambar Pahlawan sesuai dengan nominalnya, dan Rectoverso akan terlihat yang saling mengisi sisi depan dan belakang uang.

2.2.3 Citra Digital


Citra Citra adalah salah satu bentuk informasi yang dibutuhkan orang, selain teks, suara, gambar, dan video di internet. Hal ini dimungkinkan untuk informasi yang terkandung dalam satu kutipan dapat ditafsirkan dengan cara yang berbeda dari individu lain. Ada dua jenis citra yang dapat dibedakan satu sama lain: format analog dan digital. Alat akuisisi citra analog, yang misalnya mencakup manusia dan kamera analog, adalah sumber dari analog citra. Contoh kamera analog adalah seperangkat foto atau film yang ditangkap oleh kamera analog. Gambaran yang ditangkap oleh manusia juga merupakan jenis kamera

analog [25]. Bantuan baris dan kolom, penjudi analog diubah menjadi gambar transparan. Komputer dapat digunakan untuk menyebarkan informasi digital, dan komputer dapat disebarkan dalam bentuk angka-angka yang memberikan intensitas yang signifikan [21]. Pada saat ini, ada peningkatan yang nyata dalam kualitas hasil citra yang resolusi rendah, warna pudar, dan masalah lainnya. Sebagai pembuktian adalah perubahan yang terjadi dalam citra digital, adalah mungkin untuk mencapai ini dengan menggunakan metode konservasi informasi dengan menggunakan metadata dan augmentasi citra. Pengolahan citra, juga dikenal sebagai pemrosesan gambar, adalah proses yang melibatkan manipulasi gambar digital untuk meningkatkan kualitasnya. Hal ini dapat dilakukan untuk meningkatkan kualitas berbagai gambar, seperti meningkatkan kontras, mengubah peringatan, atau mengembalikan gambar; mengubah gambar dengan berbagai cara, seperti translasi, rotasi transformasi, skala, atau geometris; atau memperoleh gambar fitur atau gambar fitur [28], [26]. Dalam arti umum, transformasi digital dokumen dapat digambarkan sebagai representasi dua dimensi melalui penggunaan satu komputer. Citra digital adalah jenis array (larik) yang dapat digunakan untuk mewakili nilai dunia nyata serta nilai kompleks yang dapat diwakili menggunakan bit yang saat ini digunakan [21]. .

Dalam melakukan pemrosesan citra, dibutuhkan identifikasi dan klasifikasi ciri dari gambar sebagai langkah untuk membedakan dan mengelompokkannya. Berikut merupakan beberapa karakteristik mendasar dari citra [27][28].

1. Warna : Tiga komponen warna (r, g, dan b) dari histogram menunjukkan atribut warna ini [29].
2. Bentuk : Untuk mengekstrak ciri bentuk, informasi dapat diperoleh melalui tepi sketsa atau dengan memanfaatkan momen dari citra. Untuk mendapatkan ciri bentuk ini, beberapa langkah dapat diambil, seperti mendeteksi tepi, menggunakan threshold, segmentasi, dan menghitung momen, termasuk mean, median, dan standard deviasi dari setiap lokasi gambar. Besar momen yang umum digunakan untuk ciri bentuk ini adalah transformasi Fourier [30].
3. Tekstur : Ciri-ciri tekstur dalam citra pasti berkaitan dengan sifat-sifat seperti tingkat kekasaran, granularitas, dan keteraturan dari susunan struktur piksel.

Ciri-ciri yang akan digunakan dalam proses ini yaitu segmentasi, klasifikasi, dan interpretasi citra [31].



Gambar 2. 2 Representasi citra digital [32]

Pada gambar 2.2 menunjukkan contoh citra digital yang berukuran 200x200pixel. Pada gambar ini juga ditunjukkan nilai intensitas pixel pada koordinat $x = 100$ dan $y = 100$ adalah 35 [33].



Gambar 2. 3 Contoh citra digital [34]

2.2.4 Artificial Intelligent (AI)


Konsep kecerdasan buatan, juga dikenal sebagai kecerdasan, mengacu pada simulasi intelligen manusia di dalam mesin seperti model komputer atau robot. Mesin-mesin ini kemudian diprogram untuk melakukan tugas kognitif dalam hubungannya dengan kegiatan manusia lainnya, seperti belajar dan memecahkan masalah. *Artificial intelligence* adalah istilah umum yang digunakan untuk menggambarkan teknik yang dikembangkan untuk mengajar komputer

untuk melakukan tugas kognitif seperti belajar, menghukum, komunikasi, dan mengidentifikasi pikiran dan perasaan seseorang. Istilah "intelijen buatan" mengacu pada sebuah sistem yang dapat digambarkan sebagai "perangkat lunak" atau "perangkat keras," dan didefinisikan sebagai sistem yang dirancang oleh manusia dengan tujuan yang kompleks dalam pikiran. Sistem ini mampu memahami lingkungan melalui penggunaan data, menganalisis data yang baik terstruktur maupun tidak terstruktur, mengenali informasi yang berasal dari data, dan menentukan informasi yang paling tepat yang perlu dikomunikasikan untuk mencapai tujuan yang telah disediakan [29]. Di antara banyak sub bidang kecerdasan buatan, yang paling menonjol adalah pembelajaran mesin, pemrosesan bahasa alami, sistem ahli, bicara visi, perencanaan, dan robotika. Subfield ini secara kolektif membentuk tugas di tangan. Jenis kecerdasan buatan yang disebutkan di atas direkomendasikan untuk tujuan memperoleh ruang lingkup sepanjang proses belajar atau mengembangkan kecerdasan buatan. Ini disebabkan oleh fakta bahwa, menurut teori, kecerdasan buatan memiliki ruang lingkup yang sangat menguntungkan. Selain itu, dalam studi ini, *Deep Learning* ditempatkan sebagai subfield dari *Machine Learning*, yang menggunakan *Neural Networks* sebagai arsitekturnya untuk tujuan mengatasi masalah yang kompleks, seperti generasi gambar, generasi bicara, dan generasi bahasa yang dapat dimengerti [30].

2.2.5 *Deep Learning*

Deep Learning termasuk kedalam cabang pembelajaran mesin yang menggunakan satu set dari sebuah algoritma untuk membuat model tingkat ke yang lebih tinggi abstrak dari data dengan menggunakan beberapa interval dari implementasi dan struktur yang kompleks, atau alternatifnya, kombinasi beberapa transformasi *non-linear*. Melalui pembelajaran mendalam, komputer dapat belajar untuk secara otomatis mengklasifikasikan gambar, teks, grafis, atau video. Sebuah komputer dilatih menggunakan set data yang diberi label, yang ukurannya relatif besar. Ini memungkinkan komputer untuk kemudian mengkonversi data gambar dari gambar tertentu menjadi representasi internal, atau fitur vektor, yang dapat digunakan untuk pengenalan pola atau klasifikasi data input [3]. *Deep Learning* adalah metode belajar yang menggunakan beberapa tingkatan representasi.


Representasi dapat digunakan untuk membangun arsitektur syaraf multi-layer. Tiga lapisan dari model pembelajaran mendalam adalah lapisan sebuah input, kemudian lapisan tersembunyi, dan terakhir lapisan *output*. Banyak iterasi dapat dibuat di lapisan tersembunyi untuk memungkinkan sintesis algoritma yang tepat untuk meminimalkan kesalahan dalam *output*. Semakin banyak lapisan yang tercapai, semakin sedikit kesalahan yang dicapai. Untuk menghasilkan hasil yang lebih akurat.



Gambar 2. 4 Deep Learning

Pada Gambar 2.4 gambar Menurut apa yang diketahui, *Deep Learning* adalah salah satu jenis algoritma yang digunakan dalam pengajaran *Machine Learning*. Hal ini dapat digunakan untuk mengotomatisasi proses kerja manusia, dan juga memungkinkan klasifikasi gambar dalam format seperti format grafis, teks, dan video. Dalam kasus ini, metode instruksi didasarkan pada model abstrak dan menggunakan struktur kompleks yang berasal dari transformasi non-linear. Melalui penggunaan pendekatan pedagogis, informasi yang diperoleh dari data dapat dianalisis dengan menggunakan beberapa neuron sebagai unit analisis. Salah satu alasan mengapa *Deep Learning* begitu populer adalah karena menawarkan sejumlah manfaat, seperti kemampuan untuk dipelajari dengan mudah, disesuaikan dengan situasi tertentu, dan digunakan secara efisien. Dalam hal yang sama, pengetahuan yang diperoleh melalui instruksi manual seringkali membutuhkan penggunaan perhatian konsisten, tidak sangat dapat dimengerti, dan tidak mudah digunakan. Salah satu manfaat lain dari pembelajaran mendalam adalah bahwa itu menyediakan lingkungan kerja yang sangat serbaguna dan universal, dan dapat dipelajari untuk berkomunikasi materi yang baik visual dan linguistik. Selain itu, perlu untuk membagi perwakilan guru untuk mencapai generalisasi yang tidak terbatas pada tingkat lokal [28]. *Deep Learning* telah


menjadi semakin populer sebagai alat untuk menangani masalah data skala besar, seperti generasi bicara, pemahaman komputer, dan memahami bahasa [27].



Gambar 2. 5 Layer Deep Learning [35]

Gambar 2.5 di atas menunjukkan ilustrasi lapisan pembelajaran mendalam. Neuron diwakili oleh lingkaran putih. Setiap lapisan tersembunyi mengandung satu atau lebih neuron. Neuron ini akan terhubung langsung ke neuron lain di lapisan berikutnya. Neuron hanya berinteraksi antara dua lapisan, input dan output. Dalam lapisan yang sama, tidak ada koneksi, meskipun secara teknis mungkin untuk membuatnya. Komputasi model yang terdiri dari berbagai lapisan pemrosesan dapat mempelajari representasi data dengan berbagai tingkat abstraksi melalui pengajaran mendalam. Metode ini telah meningkatkan keadaan saat ini dalam pengenalan bicara, pengakuan objek visual, dan deteksi objek, serta penemuan lain seperti penemuan obat dan genomik. Dengan menggunakan algoritma *Backpropagation*, *Deep Learning* membantu menemukan struktur yang kompleks dan menantang dalam kumpulan data yang sangat besar. Algoritma ini mengajarkan mesin untuk mengubah parameter internalnya agar dapat menghasilkan representasi yang lebih baik pada setiap lapisan berdasarkan representasi pada lapisan sebelumnya [36]. *Convolutional Neural Network* (CNN) yang digunakan untuk klasifikasi gambar, *Deep Belief Network* (DBN) adalah jenis *Deep Neural Network* (DNN) yang digunakan untuk pengenalan suara, dan *Recurrent Neural Network* (RNN) adalah jenis *Deep Neural Network* (DNN) yang digunakan untuk terjemahan bahasa. Sederhanakan informasi dari beberapa dokumen. Sementara *Deep Belief Network* (DBN) digunakan untuk memperkirakan data berdasarkan waktu, *Conditional Restricted Boltzman Machine* (CRBM) memprediksi *Drug-Target Interaction* (DTI) [37].

Meskipun *Deep Learning* adalah jenis algoritma dalam pembelajaran mesin, cara mereka beroperasi berbeda secara signifikan. Gambar berikut menunjukkan perbedaan tersebut.

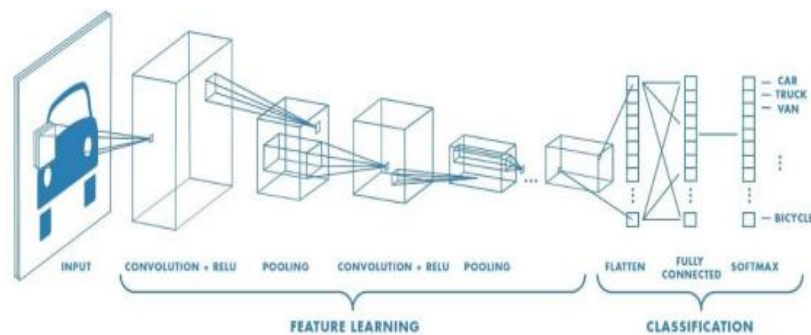


Gambar 2. 6 Perbedaan *Classical Machine Learning*

Dalam ilustrasi sebelumnya, pembelajaran mesin membutuhkan ekstraksi fitur untuk digunakan untuk mengidentifikasi karakteristik unik dari data. Ekstraksi Fitur, juga dikenal sebagai ekstraksi fitur, adalah proses mengurangi dimensionalitas dengan mengumpulkan atau mengklasifikasikan dataset awal menjadi grup dapat diproses, masalah umum yang muncul adalah bahwa seiring dengan meningkatnya ukuran Jaringan *Neural*, beban komputasi yang dibutuhkan juga meningkat. Namun, kehadiran GPU dapat mempercepat proses pelatihan data. Proses klasifikasi juga melibatkan memeriksa perilaku dan atribut data yang dikelompokkan dan didefinisikan. Ilustrasi di atas menunjukkan contoh klasifikasi yang digunakan untuk mengkategorikan input dalam bentuk gambar mobil. Dalam klasifikasi, jika hanya dua kelas yang diklasifikasikan, itu disebut klasifikasinya biner. Jika ada lebih dari dua kelas, itu disebut klasifikasi multiclass. Namun, ketika sebuah kelas tidak memiliki properti saling mengecualikan, itu disebut klasifikasi multi-label [27]. Karena perbedaan antara pembelajaran mesin standar dan pembelajaran mendalam, penggunaan mereka disesuaikan dengan kebutuhan spesifik. *Deep Learning* diperlukan ketika memproses data ukuran besar, membutuhkan infrastruktur high-end untuk pelatihan dalam jangka waktu yang wajar. Ini digunakan ketika introspeksi fitur kompleks dan dalam kasus seperti klasifikasi gambar, pemrosesan bahasa alami, dan pengenalan bicara.

2.2.6 Convolutional Neural Network (CNN)

CNN adalah tipe arsitektur *Neural Network* yang dikembangkan khusus untuk mengolah data seperti data citra. CNN menggunakan lapisan konvolusi untuk mengekstrak fitur dari data input, yang memungkinkan model untuk memahami pola spasial [33]. CNN sendiri merupakan sebuah arsitektur yang dapat dilatih yang terbagi menjadi tiga bagian yaitu konvolusi *layer* ditambah fungsi aktivasi *Rectified Linear Unit (ReLU)*, *pooling layer*, dan *fully connected layer* digunakan untuk menerima nilai dan mengklasifikasikan nilai tersebut pada salah satu kelas tertentu. Arsitektur ini sangat efektif dalam tugas pengenalan gambar, pengolahan citra, dan tugas-tugas lain yang melibatkan data *grid*. CNN telah berhasil diterapkan dalam berbagai aplikasi, seperti pengenalan wajah, klasifikasi objek, dan pemrosesan gambar medis. Berikut adalah jaringan arsitektur CNN [34]:



Gambar 2.7 Arsitektur CNN

2.2.7 Convolution Layer

Convolutional layer merupakan bagian dari tahap pada arsitektur CNN. Fungsi utamanya adalah mengekstraksi fitur-fitur dari input menggunakan operasi konvolusi. Lapisan ini terdiri dari sejumlah filter atau *kernel*, di mana setiap *kernel* melakukan operasi konvolusi pada input dan menghasilkan satu *channel* dalam *output* yang disebut sebagai *Feature Map*. Filter ini bergerak melintasi input, mengalikan nilai-nilai piksel dengan bobot-bobot (*weights*) filter, dan menghasilkan representasi-fitur yang berfokus pada pola-pola lokal dalam citra. Pada *Convolutional layer*, ReLU adalah salah satu fungsi aktivasi yang umum digunakan dalam CNN [33].

2.2.8 *Pooling Layers*

Pooling adalah proses pengurangan ukuran matriks dengan menerapkan operasi *pooling* yang biasanya dilakukan dengan mengambil nilai maksimum atau rata-rata dari sekumpulan nilai piksel. *Pooling Layer* digunakan untuk mengurangi dimensi spasial yang dihasilkan oleh lapisan konvolusi. Dua jenis *pooling* yang umum digunakan adalah *Max Pooling* dan *Average Pooling*. Dalam *Max Pooling*, nilai maksimum diambil dari setiap area beririsan di *Feature Map*, sementara dalam *Average Pooling*, rata-rata nilai diambil. Tujuan dari lapisan *pooling* adalah untuk mengurangi jumlah parameter dan komputasi, menjaga objek tetap sama meskipun posisinya bergeser secara translasi, dan memberikan kemampuan model untuk memfokuskan pada fitur-fitur penting dalam citra. Lapisan *pooling* membantu menjaga informasi penting dan mempercepat proses pelatihan [33]

2.2.9 *Fully Connected Layer*

Lapisan yang sepenuhnya terhubung adalah jenis lapisan dalam jaringan saraf di mana setiap *Neuron* terkoneksi dengan setiap *Neuron* di lapisan sebelumnya. Secara umum, ini juga difungsikan untuk menyampaikan CNN dan berfungsi sebagai komponen fungsi klasifikasi [28]. Lapisan saat ini terkait erat dengan semua kegiatan yang dijelaskan dalam lapisan sebelumnya. Sebelum melanjutkan ke lapisan berikutnya, perlu untuk mengubah setiap *Neuron* dalam lapisan *Convolutional* menjadi koleksi data satu dimensi [34]. Dalam kasus lapisan yang terhubung dengan *Neuron* lain, *Neuron* tersebut terhubungkan dengan *Neuron* lain. Di sisi lain, dalam kasus lapisan yang konvolut, *Neuron* hanya terhubung ke area yang sedang dimasukkan. Ada perbedaan dasar antara lapisan yang terhubung satu sama lain dan lapisan yang diatur dengan cara yang membingungkan. Itu adalah [28] Lapisan ini terhubung dengan semua kegiatan yang dilakukan pada lapisan yang datang sebelum itu. Begitu input diterima di halaman ini, perlu untuk menerapkan proses yang mengubah setiap *Neuron* dalam lapisan konvolusi menjadi data dengan satu dimensi yang lebih pendek dari yang sebelumnya [34]. Selama lapisan yang sepenuhnya terhubung, *Neuron* terhubungkan satu sama lain dengan cara yang langsung, namun selama lapisan konvolusi *Neuron* hanya terkoneksi dengan area yang sedang dimasukkan.

Keadaan yang disebutkan di atas merupakan perbedaan antara lapisan yang terhubung dengan penuh dan lapis yang konvolusi.

2.2.10 Fungsi Aktivasi

Fungsi aktivasi menunjukkan hubungan antara tingkat aktivitas internal (fungsi perhitungan). Hubungan ini dapat linear atau non-linear. Ini adalah cara untuk mengetahui apakah Neuron akan diaktifkan atau tidak. Dalam konteks *Neural Network* dan *Deep Learning*, fungsi aktivasi digunakan untuk mengintroduksi *non-linearitas* pada model. Tanpa fungsi aktivasi, lapisan-lapisan dalam *Neural Network* akan bersifat *linear*, dan rangkaian tersebut hanya akan dapat merepresentasikan transformasi *linear* dari input ke *Output*. Dengan adanya fungsi aktivasi, model dapat menangkap dan mempelajari pola-pola yang lebih kompleks dalam data. Beberapa fungsi aktivasi umum yang digunakan dalam *Deep Learning* diantaranya *ReLU*, *Binary Step*, *Sigmoid*, *Tanh*, dan lain sebagainya [38].

2.2.11 Fungsi Aktivasi *Rectified Linear Unit (ReLU)*

Fungsi-fungsi aktivasi sendiri digunakan sebagai fungsi yang menggambarkan hubungan antara fungsi summasi (*summation function*) dan tingkat aktivasi internal, tergantung apakah fungsi itu linear atau non-linear [35]. Berikut ini adalah pembagian hasil yang diperoleh dari aktivitas ReLU.


$$f(x) = \max(0, x)$$

Dimana

$f(x)$ = fungsi *ReLU*

x = nilai batasan *ReLU*

Berdasarkan informasi yang disajikan di atas, aktivasi ReLU dalam kasus ini memicu ambang batas yang berkisar dari nol hingga tak terbatas sehubungan dengan nilai pixel input.



Gambar 2. 8 Aktivasi *ReLU*

Pada Gambar 2.13 terdapat representasi graf yang terkait dengan aktivitas *ReLU*. Menurut grafik yang dibahas, mungkin untuk memahami bahwa jika nilai piksel negatif atau sedikit kurang dari nol, maka itu akan diklasifikasikan sebagai memiliki nilai nol. Di sisi lain, jika *output* dihitung positif atau lebih dari nol, maka *output* akan diklasifikasikan sesuai dengan hasil aktivitas itu sendiri. Dibandingkan dengan kegiatan lainnya, penggunaan *ReLU* memiliki sejumlah keuntungan. Hal ini disebabkan oleh fakta bahwa *ReLU* memiliki kemampuan untuk membantu dalam konfigurasi *Stochastic Gradient Descent (SGD)*, yang dibandingkan dengan deviasi sigmoid dan standar. Di sisi lain, menurut kelebihan yang disebutkan di atas, aktivitas *ReLU* memiliki kekurangan, yaitu bahwa ia memiliki kemampuan untuk membuat unit mati karena aktivitas pelatihan yang dimaksud sangat sederhana dan langsung [35].

2.2.12 Fungsi Aktivasi *Softmax*

Fungsi aktivasi *softmax* adalah fungsi yang digunakan dalam jaringan saraf tiruan, khususnya dalam *output* dari model klasifikasi multinomial. Fungsi logit, yang merupakan *output* dari kombinasi *linear*, diubah oleh *Softmax* menjadi probabilitas yang dapat ditingkatkan hingga 1. Fakta bahwa ini adalah kasus membuat *softmax* sangat berguna setiap kali kita ingin menentukan kelas yang berbeda dari input apapun. *Softmax* biasanya digunakan sebagai *output* dari model klasifikasi untuk menggambarkan distribusi kemungkinan sehubungan dengan sejumlah besar kelas. (Nwankpa dkk., 2018). Hasil yang dihasilkan oleh fungsi *Softmax* adalah representasi biner dari angka 0 dan 1, dengan jumlah probabilitas

yang sama dengan angka 1. Anda dapat menggunakan persamaan berikut dengan fungsi *softmax*:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$

Di mana:

- z adalah vektor dari logit.
- K adalah jumlah kelas.
- $\sigma(z)_i$ adalah probabilitas kelas ke- i .

Softmax sering digunakan bersama dengan fungsi *Loss* seperti *Cross-entropy* untuk mengoptimalkan model melalui *Backpropagation*, membuatnya esensial dalam tugas klasifikasi dengan banyak kelas, seperti pengenalan gambar, teks, dan suara.

2.2.13 *Training Set, Validation Set, dan Testing Set*

Terdapat dua istilah penting dalam pengembangan model *Deep Learning* yaitu pelatihan (*Training*) dan pengujian (*Testing*). Pelatihan merupakan proses membangun model, sementara pengujian adalah langkah untuk mengevaluasi performa model pembelajaran. *Dataset* merupakan kumpulan data yang berfungsi sebagai sampel dalam statistik. Sampel ini digunakan untuk membentuk model dan mengevaluasi model *Deep Learning*. *Dataset* dapat dikelompokkan menjadi tiga jenis yang tidak saling tumpang tindih, yang berarti satu sampel pada satu set tidak ada dalam set lainnya. Tiga jenis tersebut diantaranya terdiri dari [38]:

- 1) *Training set* adalah kumpulan data yang digunakan untuk melatih atau membangun model.
- 2) *Validation set* adalah kumpulan data yang digunakan untuk mengoptimalkan model selama pelatihan. Model dilatih menggunakan *Training set* dan kinerjanya dievaluasi menggunakan *Validation set*.
- 3) *Testing set* adalah kumpulan data yang digunakan untuk mengevaluasi model setelah proses latihan selesai. Penting dicatat bahwa *Testing set* adalah data yang belum pernah dilihat sebelumnya. Sehingga baik model maupun manusia

tidak seharusnya melihat sampel ini selama proses pelatihan karena dapat menyebabkan bias [36].

2.2.14 *Library Python*

Python adalah bahasa pemrograman yang memungkinkan Anda membuat banyak instruksi multiguna dan multi-Guna dengan cara yang sederhana (interpretatif) dengan menggunakan pengaturcaraan berorientasi objek. Selain itu, menggunakan parsing semantik untuk memberikan sintaks yang mudah dipahami. Bahasa pemrograman adalah salah satu bahasa yang sering digunakan di bidang pembelajaran mendalam. Misalnya, dalam penelitian ini, Para peneliti menggunakan bahasa pemrograman *Python*, yang dirilis melalui *Google Chrome's Google Colab*. Tujuannya adalah untuk membantu para peneliti mengembangkan sistem yang dapat mendeteksi nilai nominal rupiah dalam kondisi yang rusak. Untuk penelitian ini, beberapa perpustakaan digunakan, seperti sumber daya berikut:



Gambar 2. 9 Library Python

1. *Numerical Python (Numpy)*

Numerik *Python*, juga dikenal sebagai *Numpy*. *Numpy* adalah sebuah perpustakaan yang merupakan bagian dari bahasa pemrograman *Python* yang sering digunakan untuk tujuan melakukan perhitungan numerik. Perpustakaan ini memiliki kemampuan untuk membuat array objek dengan dimensi N. Array tertentu ini terdiri dari sejumlah kecil variabel yang memiliki jenis data yang sama. Penggunaan *Numpy* dalam konteks ini memiliki kemampuan untuk secara signifikan menyederhanakan operasi komputer pada data, dan juga dapat digunakan untuk melakukan akses secara acak. Versi baru *Numpy* menyediakan berbagai rutin untuk melakukan operasi pada array secara tepat

waktu. Rutin ini mencakup operasi matematika, operasi logis, manipulasi bentuk, pemangkasan, pemilihan, input/output operasi, transformasi Fourier diskrit, algebra linier dasar, operasi statistik dasar, simulasi acak, dan banyak lagi. Itu adalah [10].

2. *TensorFlow*

TensorFlow adalah perpustakaan *open source* yang digunakan oleh proyek pembelajaran mesin skala besar dan sistem komputasi numerik. Kerangka kerja *TensorFlow* menggabungkan sejumlah besar model dan algoritma pembelajaran mesin, termasuk *Deep Learning (Neural Network)*, di antara banyak lainnya. Api di tingkat tinggi Kerangka kerja *TensorFlow* dikembangkan berdasarkan 35 standar Keras API untuk mendefinisikan dan mempelajari jaringan saraf. Ini akan membuat proses pelatihan lebih mudah dan akan memungkinkan Anda untuk mendapatkan model terbaik yang mungkin [13].

3. Keras

Keras adalah *Application Programming Interface (API)* yang merupakan tingkat tertinggi dari Tensor Flow 2.0. Ini adalah antarmuka yang dapat didekati dan sangat produktif untuk mengidentifikasi masalah yang terkait dengan pembelajaran mesin, dengan penekanan khusus pada pembelajaran mendalam saat ini. Yang dimaksud keras memiliki tiga karakteristik, yaitu bahwa ia kuat, fleksibel, dan sederhana [24].

4. Matplotlib

Matplotlib Pada *library* ini digunakan untuk membuat sebuah visualisasi dari angka-angka dan memplotkannya ke dalam bentuk seperti diagram lingkaran, histogram, *scatterplot*, grafik, dan lain-lain, sehingga banyak digunakan untuk analisa data [19].

2.2.15 *Accuracy dan Loss*

Accuracy dan *Loss* adalah dua metrik yang paling dikenal dan dibahas dalam pembelajaran mesin. *Accuracy* dan *Loss* menjadi salah satu poin penting dalam klasifikasi citra. *Accuracy* merupakan metode untuk mengukur kinerja

model klasifikasi yang hasilnya dapat dinyatakan dalam persentase. *Accuracy* adalah jumlah prediksi di mana nilai prediksi sama dengan nilai sebenarnya. Ini bersifat biner (benar/salah) untuk sampel tertentu. *Loss* atau kesalahan diperoleh dari perhitungan pada *Training* dan *testing* yang hasilnya mencerminkan seberapa baik model saat melakukan *Training* dan *validation*. Nilai *loss* menunjukkan ukuran yang menunjukkan seberapa besar kesalahan dalam klasifikasi citra oleh model, dimana semakin rendah nilai *loss* maka semakin baik model yang dihasilkan. Namun hal tersebut tidak berlaku jika model mengalami *overfitting*. Nilai *loss* tidak dinyatakan dalam persen seperti *accuracy* karena menggambarkan jumlah kesalahan dari setiap contoh dalam validasi. Tujuan utama dari proses pembelajaran model adalah untuk mengurangi nilai *loss* dengan menyesuaikan *weight vector* melalui berbagai metode optimasi yang berbeda seperti *Backpropagation* pada *Neural Network* [38].

2.2.16 Confusion matrix

Matriks kebingungan atau matriks kebingungan, juga disebut sebagai matriks kesalahan, memberikan data tentang perbandingan hasil klasifikasi yang dihasilkan oleh model dengan hasil klasifikasi yang dihasilkan oleh model itu sendiri. Karena ini, semakin banyak masalah klasifikasi pada model, semakin meningkat kemampuan sistem untuk melakukan fungsi-fungsinya. Matriks kebingungan terdiri dari tabel data yang menampilkan kinerja model klasifikasi pada data yang digunakan. Berikutnya adalah matriks kebingungan yang berisi empat elemen yang berbeda berdasarkan nilai prediksi dan nilai aktual yang berbeda [19].

| | | Actual Values | |
|------------------|--------------|---|--|
| | | 1 (Positive) | 0 (Negative) |
| Predicted Values | 1 (Positive) | TP (True Positive) | FP (False Positive) <small>Type I Error</small> |
| | 0 (Negative) | FN (False Negative) <small>Type II Error</small> | TN (True Negative) |

Gambar 2. 10 Confusion matrix

Terdapat perhitungan yang dapat dilakukan secara manual dalam pengolahan akurasi yang ditunjukkan pada rumus dibawah ini [42] :

$$\text{Akurasi} = \frac{TP+TN}{(TP+TN+FP+FN)} \times 100\% \quad (2.2)$$

Untuk tujuan menentukan akurasi nilai, lihat rumus yang disajikan di atas. Di sisi lain, perhitungan rasio antara jumlah *True Positives* (TP) dan *True Negatives* (TN) dilakukan dengan menambahkan nomor *True Positive* (TP), ditambah dengan jumlah *True Negative*, ditambah jumlah *False Negative* (FN) ditambah nomor *False Positive* yang diperoleh dari analisis korelasi dan hasil dari kelas yang diprediksi dibandingkan dengan kelas yang sebenarnya dalam matriks kebingungan. Mengingat fakta bahwa akurasi dinyatakan dalam pers, hasil penelitian akan dihitung menjadi seratus persen. Akurasi merupakan jumlah dari prediksi yang benar dari keseluruhan nilai prediksi yang diuji, sehingga pada penelitian ini akurasi menunjukkan tingkat yang paling tepat dari sistem untuk mampu dalam mengklasifikasikan kondisi yang berlabel benar terklasifikasi kedalam kondisi benar.

Proses klasifikasi melibatkan perhitungan matriks data dengan memanfaatkan *confusion matrix* yang merepresentasikan hasil dari model klasifikasi yang digunakan. Pada tahap evaluasi akan menampilkan nilai-nilai seperti akurasi, presisi, *recall*, dan *f1-score* [35].

1) Akurasi

Matriks ini menunjukkan sejauh mana model berhasil memprediksi kelas dengan benar. Ini adalah metode yang paling umum digunakan, tetapi dapat menjadi tidak akurat ketika data tidak seimbang. Persamaan untuk matriks ini adalah sebagai berikut [35]:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.3)$$

2) Presisi

Matriks ini mengukur sejauh mana model secara akurat memprediksi kelas positif, namun tidak memberikan informasi tentang berapa banyak kasus positif yang diabaikan oleh prediksi model. Persamaan untuk matriks ini adalah sebagai berikut [35]:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2.4)$$

3) *Recall*

Matriks ini menunjukkan seberapa baik model memprediksi kelas positif yang sebenarnya. Namun, *recall* tidak memberikan gambaran tentang seberapa baik model memprediksi kasus positif secara keseluruhan. Persamaan untuk matriks ini adalah sebagai berikut [35]:

$$Recall = \frac{TP}{TP+FN} \quad (2.5)$$

4) *F1-score*

Matriks ini menggabungkan presisi dan *recall* untuk mengevaluasi kinerja kategori positif dengan menghitung rata-rata dari keduanya. *F1-score* tidak secara jelas dan terperinci menunjukkan peringkat kinerja yang buruk karena dua metrik sebelumnya terfokus pada klasifikasi positif. Persamaan untuk matriks ini adalah sebagai berikut [35]:

$$F1-score = \frac{2 \times Recall \times Precision}{Recall + Precision} \quad (2.6)$$