

BAB II

TINJAUAN PUSTAKA

II.1. Penelitian Terkait

Berdasarkan hasil penelitian yang dilakukan (Isnain et al., 2021), yang berjudul **Implementation of K-Nearest Neighbor (K-NN) Algorithm For Public Sentiment Analysis of Online Learning** diketahui 56,24% tweet positif dan 43,76% negatif dengan total dataset 1825. Algoritma K Nearest Neighbor memberi bobot pada kata TF-IDF dengan dataset 1825 data. Dataset dibagi menjadi dua data yaitu 80% data latih dan 20% data uji, sehingga akurasi uji K=10 adalah 84,93%. Meskipun tingkat precision mencapai 87%, namun recall adalah 87%, f measure 87%, dan tingkat kesalahannya adalah 0,12%.

Berdasarkan hasil penelitian yang dilakukan (Made et al., 2022) yang berjudul **Deteksi dini penyakit Hepatitis C dengan metode klasifikasi K-NearestNeighbor** dihasilkan akurasi testing sebesar 92%, presisi sebesar 92%, dan recall sebesar 99% dengan parameter metrik perhitungan jarak menggunakan metode Manhattan, pembobotan menggunakan distance, serta nilai K yaitu 11. Total percobaan yang dilakukan sebanyak 144 kali sehingga menghasilkan parameter terbaik dengan akurasi training sebesar 95%. Sehingga dapat disimpulkan bahwa kombinasi parameter terbaik untuk klasifikasi data penyakit Hepatitis C dengan menggunakan algoritma K-Nearest Neighbor (KNN) yaitu metrik perhitungan jarak menggunakan metode Manhattan, pembobotan menggunakan distance, serta nilai K= 11.

Berdasarkan hasil penelitian yang dilakukan (Anton et al., 2021) yang berjudul **Application of Deep Learning Using Convolutional Neural Network (CNN) Method for Women's Skin Classification** diketahui Hasil proses penelitian klasifikasi jenis kulit wanita memberikan nilai akurasi yang cukup tinggi dengan memiliki dataset sebanyak 20 citra dengan perbandingan penggunaannya menjadi 12 data latih dan 8 data validasi. Model CNN ini dijalankan sebanyak 150 epoch menggunakan library Keras dalam pemrograman Python dengan back-end tensorflow. Berdasarkan uji coba pada penelitian ini, perbandingan nilai akurasi yang diperoleh sebesar 67% dan nilai loss mencapai -9,2992. Hal ini menunjukkan bahwa hasil pengklasifikasian jenis kulit wajah wanita sudah baik namun masih perlu ditinjau kembali dengan penambahan sampel yang lebih banyak agar hasil nilai akurasinya bisa lebih besar.

Berdasarkan penelitian (Alzubaidi et al., 2021) yang berjudul **Review of deep learning: concepts, CNN architectures, challenges, applications, future directions** diketahui Eksploitasi kedalaman dan adaptasi struktural yang berbeda meningkat secara signifikan dalam kapasitas pembelajaran CNN. Dengan menggunakan metode CNN dapat membantu Mengganti konfigurasi lapisan tradisional dengan hasil blok dalam kemajuan signifikan dalam kinerja CNN, seperti yang telah ditunjukkan dalam literatur baru-baru ini. Saat ini, mengembangkan arsitektur blok baru dan efisien adalah tren utama dalam model penelitian baru arsitektur CNN. HRNet hanyalah salah satu contoh yang menunjukkan selalu adacara untuk meningkatkan arsitektur.

Berdasarkan penelitian (Suartika E. P, I Wayan, Wijaya Arya Yudhi, 2016) yang berjudul **Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101** diketahui Metode praproses dan metode klasifikasi dengan menggunakan Convolutional Neural Network cukup handal untuk menentukan kebenaran dari klasifikasi citra objek. Hal ini terbukti dengan hasil akurasi sebesar 20% - 50%.

Berdasarkan hasil penelitian yang dilakukan (Chia & Than, 2019) yang berjudul **Chest X-Ray Image Classification on Common Thorax Diseases using GLCM and AlexNet Deep Features** Menerapkan Metode Machine Learning dengan Metode ekstraksi fitur GLCM dan membandingkan dengan metode. klasifikasi menunjukkan bahwa pengklasifikasi k-NN memberikan akurasi tertinggi dibandingkan pengklasifikasi metode Zero R, PART, Naïve Bayes dan J48 Decision Tree, Dengan hasil akurasi 47,51% untuk metode ekstraksi fitur GLCM dan 47,18% untuk metode ekstraksi fitur AlexNet. Berdasarkan hasil klasifikasi, metode ekstraksi fitur GLCM menunjukkan akurasi klasifikasi yang lebih baik dari segi persentase akurasi dibandingkan dengan AlexNet.

Berdasarkan hasil penelitian yang dilakukan (Naufal et al., 2021) yang berjudul **Analisis Perbandingan Algoritma Klasifikasi Citra Chest X-ray Untuk Deteksi Covid-19** penelitian membandingkan performa algoritma CNN dan machine learning seperti Support Vector Machine (SVM), dan K-Nearest Neighbor (KNN) untuk mengetahui gap performa dan waktu eksekusi yang dibutuhkan. Berdasarkan hasil ujicoba yang dilakukan dapat disimpulkan bahwa

algoritma KNN, SVM, dan CNN cukup baik dalam melakukan klasifikasi citra Chest X-ray dengan menggunakan 5 cross validation pada data citra sebanyak 3886. Performa KNN dan SVM cukup bagus yaitu masing-masing memiliki akurasi 0,921 dan 0,93. Waktu eksekusi training KNN dan SVM juga cukup cepat yaitu masing-masing 49,49 dan 32,801 detik. CNN memiliki performa akurasi lebih bagus yaitu 0,9591 namun memiliki waktu eksekusi lebih lama yaitu 3102,562.

Berdasarkan hasil penelitian yang dilakukan (Pranata et al., 2022) yang berjudul **Segmentation of the Lungs on X-Ray Thorax Image with CNN Architecture U-Net** Hasil menggunakan metode CNN arsitektur U-Net pada data mendapatkan akurasi rata-rata 91,68%, sensitivitas 92,80%, dan spesifisitas 89,15%, presisi 95,07, dan F1-Score 93,92%. Berdasarkan hasil evaluasi kinerja, disimpulkan bahwa metode yang diusulkan dalam penelitian ini bagus dan valid pada segmentasi paru-paru pada citra X-Ray Thorax.

Berdasarkan hasil penelitian yang dilakukan (Alduaiji et al., 2022) yang berjudul **A Lightweight CNN and Class Weight Balancing on Chest X-ray Images for COVID-19 Detection** Pencapaian metode yang disarankan dinilai pada dua kumpulan data X-Ray Thorax. Efisiensi model yang disarankan dianalisis menggunakan kriteria seperti akurasi, spesifisitas, sensitivitas, dan skor F1. Metode yang disarankan mencapai akurasi masing-masing 94% kasus terburuk, 97% rata-rata, dan 100% kasus terbaik, dan skor F1 masing-masing 96% kasus terburuk, 98% rata-rata, dan 100% kasus terbaik.

Berdasarkan hasil penelitian yang dilakukan (Syahrir et al., 2021) yang berjudul **Klasifikasi penyakit paru-paru dengan Algoritma K-Nn (K-Nearest Neighbor) berdasarkan Fitur Tekstur GLCM** Metode *K-Nearest Neighbor* digunakan untuk melakukan klasifikasi penyakit pada paru-paru. Hasil dari sistem aplikasi ini yaitu Klasifikasi X-Ray antara paru-paru normal dan paru-paru yang memiliki penyakit, berdasarkan hasil dari perhitungan grayscale pada gambar X-Ray. Akurasi tertinggi didapat pada skema 7 (70% citra latih & 30% citra uji) yaitu sebesar 63%.

II.2. Data Mining

Data mining adalah teknik untuk pengolahan sejumlah data besar untuk mencari pola atau aturan tertentu sehingga menjadi informasi yang bermanfaat. *Data mining* juga dapat disebut sebagai rangkaian prosedur untuk menambang/menggali nilai tambah yaitu pengetahuan atau informasi yang tidak diketahui secara manual dari sekumpulan data yang sangat besar (Arga, Lestari dan Sutanta, 2017).

Data mining adalah Serangkaian proses untuk menggali nilai tambah berupa informasi dalam melakukan prediksi seperti hasil akhir peserta terhadap suatu kegiatan pembelajaran berdasarkan jumlah data yang selama ini tidak diketahui secara manual dari suatu basis data dengan melakukan penggalian pola-pola dari data dengan tujuan untuk memanipulasi data menjadi informasi yang lebih berharga yang diperoleh dengan cara mengekstraksi dan mengenali pola yang penting atau menarik dari data yang terdapat dalam basis data (Soares dkk, 2017).

Dalam pembahasan tentang *Data mining*, maka harus mengetahui terlebih dahulu definisi dari *Data mining*. Secara umum *Data mining* terbagi atas 2(dua) kata yaitu:

1. Data yaitu Kumpulan Fakta yang terekam atau sebuah entitas yang tidak memiliki arti dan selama ini terabaikan.
2. *Mining* yaitu proses Penambangan Sehingga *Data mining* itu dapat diartikan sebagai proses penambangan data yang menghasilkan sebuah *output* (keluaran) berupa pengetahuan.

Salah satu teknik yang dibuat dalam *Data mining* adalah bagaimana menelusuri data yang ada untuk membangun sebuah model, agar dapat mengenali pola data yang lain tidak berada dalam basis data yang tersimpan. Kebutuhan untuk prediksi juga memanfaatkan teknik ini. Dalam *Data mining*, pengelompokan data juga bisa dilakukan. Tujuannya adalah agar dapat mengetahui pola *universal* data- data yang ada. Pengertian data transaksi juga perlu dideteksi agar dapat mengetahui tindakan berikutnya yang dapat diputuskan. Semua hal tersebut bertujuan mendukung kegiatan operasional perusahaan sehingga tujuan akhir perusahaan diharapkan dapat tercapai (Affandi et al., 2021).

Istilah *Data mining* memiliki beberapa padanan, seperti *knowledge discovery* ataupun *pattern recognition*. Kedua istilah tersebut sebenarnya memiliki ketepatannya masing-masing. Istilah *knowledge discovery* benar digunakan karena tujuan utama dari *Data mining* adalah untuk mendapatkan pengetahuan yang masih tersembunyi dalam bongkahan data. Istilah *pattern*

recognition atau pengenalan pola tepat untuk digunakan karena pengetahuan yang hendak digali memang berbentuk pola-pola yang mungkin juga masih perlu digali dari dalam bongkahan data yang tengah dihadapi (Rokhmah & Rozaq Rais, 2022).

Kemajuan yang harus berlanjut dalam bidang *Data mining* didorong oleh beberapa faktor antara lain:


1. Pertumbuhan yang cepat dalam kumpulan data.
2. Penyimpanan data dalam gudang data, sehingga banyak perusahaan memiliki akses ke dalam database yang baik.
3. Adanya peningkatan akses data melalui navigasi web dan internet.
4. Perkembangan teknologi perangkat lunak untuk *Data mining* (ketersediaan teknologi).
5. Perkembangan yang hebat dalam kemampuan komputasi dan pengembangan kapasitas media penyimpanan.

Dari definisi-definisi yang telah disampaikan, hal yang terkait dengan *Datamining* adalah :

1. *Data mining* adalah suatu proses otomatis terhadap berbagai data yang telah ada.
2. Data yang akan diolah merupakan data yang sangat besar.

Tujuan dari *Data mining* adalah untuk mendapatkan hubungan atau pola yang mungkin memberikan indikasi yang bermanfaat.

Istilah *Data mining* atau yang juga disebut dengan *Knowledge Discovery(KDD)* memiliki beberapa tahapan dalam prosesnya. Adapun tahapan-tahapan dalam Seperti gambar berikut ini :



Gambar II.1 Tahapan *Knowledge Discovery in Database*

Tahap-tahap *data mining* ada 6 yaitu, sebagai berikut:

1. Pembersihan data (*Data Cleaning*)

Pembersihan data merupakan proses menghilangkan noise dan data yang tidak konsisten atau data tidak relevan. Pada umumnya data yang diperoleh, baik dari database suatu perusahaan maupun hasil eksperimen, memiliki isian - isian yang tidak sempurna seperti data yang hilang, data yang tidak valid atau juga hanya sekedar salah ketik. Selain itu, ada juga atribut - atribut data yang tidak relevan dengan hipotesa data mining yang dimiliki. Data - data yang tidak relevan itu juga lebih baik dibuang. Pembersihan data juga akan mempengaruhi performansi dari teknik data mining karena data yang ditangani akan berkurang jumlah dan kompleksitasnya.

2. Integrasi Data (*Data Integration*)

Integrasi data merupakan penggabungan data dari berbagai database ke dalam satu *database* baru. Tidak jarang data yang diperlukan untuk data mining tidak hanya berasal dari satu database tetapi juga berasal dari beberapa *database* atau file teks. Integrasi data dilakukan pada atribut - aribut yang mengidentifikasi entitas - entitas yang unik seperti atribut nama, jenis produk, nomor pelanggan dan lainnya. Integrasi data perlu dilakukan secara cermat karena kesalahan pada integrasi data bisa menghasilkan hasil yang menyimpang dan bahkan menyesatkan pengambilan aksi nantinya. Sebagai contoh bila integrasi data berdasarkan jenisproduk ternyata menggabungkan produk dari kategori yang berbeda maka akan didapatkan korelasi antar produk yang sebenarnya tidak ada.

3. Transformasi Data (*Data Transformation*)

Data diubah atau digabung ke dalam format yang sesuai untuk diproses dalam data mining. Beberapa metode data mining membutuhkan format data yang khusus sebelum bisa diaplikasikan. Sebagai contoh beberapa metode standar seperti analisis asosiasi dan clustering hanya bisa menerima input data kategorikal. Karenanya data berupa angka numerik yang berlanjut perlu dibagi-bagi menjadi beberapa interval. Proses ini sering disebut transformasi data.

4. Proses *Mining*

Merupakan suatu proses utama saat metode diterapkan untuk menemukan pengetahuan berharga dan tersembunyi dari data. *Data mining* adalah sebuah proses pencarian pola atau informasi menarik dalam data yang besar dengan

menggunakan algoritma atau metode tertentu. Penggunaan metode atau algoritma yang tepat sangat bergantung pada tujuan dan hasil proses KDD secara keseluruhan. Data Mining memiliki metode tersendiri berdasarkan tujuan dari pemanfaatan himpunan data yaitu estimasi, prediksi, klasifikasi, klusterisasi dan asosiasi (Tarigan et al., 2022).

5. Evaluasi Pola (*Pattern Evaluation*)

Untuk mengidentifikasi pola-pola menarik kedalam knowledge based yang ditemukan. Dalam tahap ini hasil dari teknik data mining berupa pola-pola yang khas maupun model prediksi dievaluasi untuk menilai apakah hipotesa yang ada memang tercapai. Bila ternyata hasil yang diperoleh tidak sesuai hipotesa ada beberapa alternatif yang dapat diambil seperti menjadikannya umpan balik untuk memperbaiki proses data mining, mencoba metode data mining lain yang lebih sesuai, atau menerima hasil ini sebagai suatu hasil yang di luar dugaan yang mungkin bermanfaat.

6. Presentasi Pengetahuan (*Knowledge Presentation*)

Merupakan visualisasi dan penyajian pengetahuan mengenai metode yang digunakan untuk memperoleh pengetahuan yang diperoleh pengguna. Tahap terakhir dari proses data mining adalah bagaimana memformulasikan keputusan atau aksi dari hasil analisis yang didapat. Ada kalanya hal ini harus melibatkan orang-orang yang tidak memahami data mining. Karenanya presentasi hasil data mining dalam bentuk pengetahuan yang bisa dipahami semua orang adalah satu tahapan yang diperlukan dalam proses data mining. Dalam presentasi ini, visualisasi juga bisa membantu mengkomunikasikan hasil data mining.

II.3. K-Nearest Neighbor

Algoritma K-Nearest Neighbor (K-NN) merupakan metode klasifikasi yang menentukan label (class) dari sebuah objek baru berdasarkan mayoritas class dari jarak terdekat k dalam kelompok data latih. (Wijaya & Ridwan, 2019)

Algoritma K- Nearest Neighbor (K-NN) merupakan algoritma untuk mengklasifikasi yang bekerja mengambil sejumlah K data terdekat (ketetanggaanya) sebagai acuan untuk menentukan kelas dari data baru. KNN ini cara mengklasifikasinya yaitu berdasarkan *similarity* atau kemiripan atau yang paling dekat terhadap data lainnya. Algoritma KNN data yang paling dekat disebut atau data poin yang berada berdekatan dikatakan “neighbor” atau “tetangga” (Afifah, 2020).

Secara umumnya algoritma KNN memiliki cara kerja sebagai berikut.

1. Menentukan jumlah tetangga (K) digunakan sebagai acuan pertimbangan penentuan kelas.
2. Menghitung data yang baru dimasukan ke masing-masing data poin dataset.
3. Mengambil beberapa jumlah K data terhadap jarak terdekat, lalu ditentukan kelas dari data yang baru.


$$d_i = \sqrt{\sum_{i=1}^p (x_{2i} - x_{1i})^2} \dots\dots\dots(2.8)$$

Dengan keterangan :

x_1 : sampel data

x_2 : data uji d : jarak

p : dimensi data i : variable data



Gambar II.2 Ilustrasi KNN

Dari gambar ilustrasi diatas, ada beberapa julah poin yang terdiri dari 2 poin yaitu poin A berwarna merah dan poin B berwarna biru. Misalkan ada data baru yang berwarna hitam yang akan diprediksi kelasnya dengan algoritma KNN. Dari contoh diatas, nilai K yang digunakan adalah 3. Setelah dihitung dari jarak warna hitam ke data poin lainnya, ada 3 titik terdekat yaitu 2 titik warna merah dan 1 titik warna biru.

Seperti yang sudah digambarkan dalam ilustrasi kotak warna hitam, maka dapat disimpulkan data baru poin hitam masuk ke kelas A data poin warna merah.


II.4. *Deep Learning*

Deep Learning adalah salah satu fungsi kecerdasan buatan yang meniru cara kerja otak manusia dalam memproses data dan menciptakan pola untuk digunakan dalam pengambilan keputusan. *Deep Learning* merupakan bagian dari Machine Learning. *Deep Learning* terdiri dari banyak kelas atau jenis, beberapa yang paling sering digunakan adalah *Convolutional Neural Network* (CNN), *Multilayer Perceptrons* (MLP), dan *Recurrent Neural Network* (RNN). Keunggulan deep

learning adalah memiliki performa terbaik dalam menyelesaikan masalah kompleks, mengurangi kebutuhan untuk rekayasa ciri, dan memiliki arsitektur yang mampu beradaptasi terhadap permasalahan baru dengan mudah. Sementara, kekurangan dari deep learning adalah membutuhkan banyak data, proses training yang memakan waktu, dan overfitting (Naufal et al., 2021).

Deep Learning merupakan salah satu bidang dari *machine learning* yang memanfaatkan jaringan syaraf tiruan untuk implementasi permasalahan dengan dataset yang besar. Teknik *deep learning* memberikan arsitektur yang sangat kuat untuk *supervised learning*. Dengan menambahkan lebih banyak lapisan maka model pembelajaran tersebut bisa mewakili data citra berlabel dengan lebih baik. Pada machine learning terdapat teknik untuk menggunakan ekstraksi fitur dari data pelatihan dan algoritma pembelajaran khusus untuk mengklasifikasi citra maupun untuk mengenali suara. Namun, metode ini masih memiliki beberapa kekurangan baik dalam hal kecepatan dan akurasi. Aplikasi konsep jaringan syaraf tiruan yang dalam (banyak lapisan) dapat ditanggguhkan pada algoritma *machine learning* yang sudah ada sehingga komputer sekarang bisa belajar dengan kecepatan, akurasi, dan skala yang besar. Prinsip ini terus berkembang hingga *deep learning* semakin sering digunakan pada komunitas riset dan industri untuk membantu memecahkan banyak masalah data besar seperti *Computer vision*, *Speech recognition*, dan *Natural Language Processing*. *Feature Engineering* adalah salah satu fitur utama dari *deep learning* untuk mengekstrak pola yang berguna dari data yang akan memudahkan model untuk membedakan kelas. *Feature Engineering* juga merupakan teknik yang paling penting untuk mencapai hasil yang baik pada tugas

prediksi. Namun, sulit untuk dipelajari dan dikuasai karena kumpulan data dan jenis data yang berbeda memerlukan pendekatan teknik yang berbeda juga. Dalam *deep learning*, metode CNN atau *Convolutional Neural Network* sangatlah bagus dalam menemukan fitur yang baik pada citra ke lapisan berikutnya untuk membentuk hipotesis nonlinier yang dapat meningkatkan kekompleksitasan sebuah model. Model yang kompleks tentunya akan membutuhkan waktu pelatihan yang lama sehingga di dunia *deep learning* penggunaan GPU sudah sangatlah umum.



Gambar II.3 Perbandingan *Neural Network* Sederhana Dengan *Deep Learning Neural Network*

Seperti yang tampak pada gambar diatas, *neural network* sederhana yang menggunakan jaringan *feed forward* hanya mempunyai satu atau dua *hidden layer*. Sedangkan pada *deep learning neural network* terdapat *hidden layer* yang jumlahnya diatas dua *layer* keatas yang bahkan bisa sampai ratusan *layer*. Penggunaan *hidden layer* yang banyak inilah yang memungkinkan *deep learning* mampu menganalisis data dari berbagai dimensi, sehingga dapat menarik kesimpulan dari suatu permasalahan dengan lebih akurat dan detail.

Sama seperti *neural network* pada umumnya, *layer* pada *deep learning neural network* terbagi atas tiga *layer* utama yakni *input layer*, *hidden layer*, dan *output layer*. Ketiga *layer* tersebut memiliki perannya masing-masing. *Input layer* berfungsi untuk menampung data mentah seperti suara, teks, atau gambar. *Hidden layer* bertugas untuk meneliti dan mengklasifikasikan data tersebut berdasarkan referensi yang sudah ada. *Output layer* berfungsi untuk menyajikan hasil penelitian dan klasifikasi dari suatu data. Algoritma *deep learning* terbagi lagi kedalam beberapa jenis, namun algoritma yang paling sering digunakan yakni *Convolutional Neural Network (CNN)*, *Recurrent Neural Network (RNN)*, dan *Long Short-Term Memory Network (LSTM)*. Pada penelitian ini, algoritma *deep learning* yang digunakan adalah *Convolutional Neural Network (CNN)*.


II.5. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu kelas dari *deep learning* yang mampu melakukan pengenalan gambar dan klasifikasi gambar.


Metode CNN merupakan suatu kelas pada *neural network* yang berspesialisasi dalam memproses data yang memiliki topologi seperti grid, misalnya gambar. Metode CNN dapat digunakan dalam pengenalan wajah, analisis dokumen, klasifikasi gambar, klasifikasi video, dsb.

Metode CNN mengklasifikasi gambar dengan memproses gambar yang diinput, kemudian mengklasifikasikannya pada kategori tertentu misalnya pada citra manusia, terdapat wajah, mata, bibir, hidung, tangan, dll. Gambar akan dibuat menjadi array berisi nilai pada setiap pixel dengan resolusi

tinggi*panjang*dimensi yang disebut channel. Dimana, channel ini biasanya terdiri dari 3 buah yang berarti citra merupakan gambar RGB dengan masing-masing lapisan (channel) merepresentasikan Red-Green-Blue atau 1 lapisan jika gambar grayscale. Akan tetapi, jumlah lapisan juga bisa melebihi 3, bahkan hingga ratusan yang merepresentasikan berbagai warna lainnya dengan arsitektur RGB.



Gambar II.4 Ilustrasi Convolutional Neural Network



Gambar II.5 Ilustrasi Arsitektur Convolutional Neural Network

Seperti yang ditampilkan pada Gambar II.4 dan Gambar II.5, Arsitektur CNN dibagi menjadi dua bagian besar, yaitu Feature Extraction Layer dan Fully


Connected Layer. Pada Feature Extraction Layer terjadi “encoding” dari sebuah image menjadi feature map yang berupa angka-angka yang merepresentasikan citra tersebut (Feature Extraction). Feature Extraction Layer terdiri dari convolution layer dan pooling layer. Convolution layer merupakan bagian utama pada metode CNN yang menjadi pembeda dengan neural network lainnya. Convolution layer adalah lapisan pertama yang mengekstraksi ciri dari citra yang dimasukkan. Proses Konvolusi (Convolution) menjaga hubungan antara pixel dengan mempelajari ciri citra menggunakan operasi matematis antara matriks citra dengan filter atau kernel. Kernel adalah sebuah operator yang diterapkan ke seluruh citra untuk mendapatkan nilai array dari sebuah Citra. Kernel adalah matriks biasanya berukuran 3*3 atau 5*5 yang berisi nilai acak antara -1 dan 1.

Contoh operasi matematis pada proses konvolusi digambarkan pada Gambar II.6 dibawah ini :

131	162	232	84	91	207
104	-1	0	+1	237	109
243	-2	0	+2	135	26
185	-1	0	+1	61	225
157	124	25	14	102	108
5	155	16	218	232	249

Gambar II.6 Contoh Operasi Matematis Proses Konvolusi

Hasil konvolusi matriks citra dengan filter (kernel) tersebut disebut feature map. Adapun, ReLU atau Rectified Linear Unit yang berfungsi untuk mengubah nilai negatif pada feature map menjadi positif, seperti ditampilkan pada Gambar II.5.



Gambar II.7. Contoh Penerapan Aktivasi ReLu

Pooling layer atau proses *Max-Pooling* merupakan lapisan yang berfungsi untuk mengurangi ukuran spasial untuk mengurangi jumlah parameter dan perhitungan ketika ukuran citra terlalu besar. *Pooling layer* beroperasi pada setiap *feature map* secara independen.

Fully Connected Layer merupakan bagian dimana hasil *feature map* dari *feature extraction layer* yang berbentuk *array* multi-dimensi diubah menjadi vektor agar dapat dibentuk menjadi *fully connected layer* seperti sebuah jaringan syaraf (*neural network*), proses ini disebut sebagai *Flatten*. Kemudian, semua ciri yang sudah terbentuk menjadi jaringan syaraf dikombinasikan untuk membuat suatu

model. Lalu, dengan fungsi aktivasi seperti *softmax* atau sigmoid digunakan untuk mengklasifikasikan output misalnya, mobil, wajah, kucing, macan, dll.

Singkatnya, cara kerja metode CNN yaitu, CNN akan melatih dan menguji setiap gambar melalui serangkaian proses. Dimulai dari pemecahan gambar menjadi gambar yang lebih kecil, kemudian memasukkan setiap gambar yang lebih kecil ke neural network yang lebih kecil, menyimpan hasil dari masing-masing gambar kecil ke dalam array baru, downsampling atau mengurangi ukuran spasial untuk mengurangi jumlah parameter dan perhitungan ketika ukuran citra terlalu besar, dan membuat prediksi.

Kelebihan dari metode CNN adalah dapat secara otomatis mengekstraksi ciri penting dari setiap citra tanpa bantuan manusia, selain itu metode CNN juga lebih efisien dibandingkan metode *neural network* lainnya terutama untuk memori dan kompleksitas. Sementara, kekurangan dari metode CNN adalah membutuhkan banyak data latih, proses pelatihan (*training*) yang memakan waktu, dan *overfitting*. *Overfitting* dapat terjadi dikarenakan terlalu banyak data latih maka algoritma kehilangan kemampuan untuk menggeneralisasi.

1. Keras

Keras merupakan *library* jaringan syaraf (*neural network*) *open- source* yang ditulis di Bahasa pemrograman *python*. Keras mampu berjalan pada *Tensor Processing Unit* (TPU) atau GPU yang besar, dan model Keras dapat diekspor untuk dijalankan pada *browser* atau *smartphone*.

2. Tensor Flow

TensorFlow merupakan *library* perangkat lunak *open-source* yang biasa digunakan untuk *dataflow* dan membedakan pemrograman dari berbagai tugas. TensorFlow menawarkan berbagai variasi dari *toolkit* yang berbeda yang memungkinkan untuk membangun model pada tingkat abstraksi yang kita inginkan.

3. *Optimizer Adam*

Optimizer Adam (Adaptive Moment Estimation) merupakan sebuah metode yang berfungsi untuk mengurangi loss dengan mengubah atribut pada jaringan syaraf (*neural network*) seperti *weight* dan *learning rate*. Kelebihan dari *optimizer Adam* yaitu cukup efisien secara komputasi dan cocok untuk permasalahan dengan data atau *parameter* yang besar.

II.6. *GLCM (Gray Level Co-Occurrence Matrix)*

GLCM merupakan metode ekstraksi ciri yang menggunakan perhitungan tekstur pada orde kedua yaitu memperhitungkan pasangan dua piksel citra asli, sedangkan pada orde pertama menggunakan perhitungan statistik berdasarkan nilai piksel citra asli dan tidak memperhatikan piksel ketetangaan. Kookurensi dapat diartikan sebagai kejadian bersama, berarti banyaknya kejadian pada satu level piksel yang bertetangga dengan nilai piksel yang lainnya berdasar jarak (d) dan orientasi suatu sudut (Θ). Jarak direpresentasikan sebagai piksel sedangkan orientasi direpresentasikan dalam derajat. Orientasi terbentuk dari empat arah sudut

dengan interval yaitu 0, 45, 90 dan 135 derajat dan jarak antar piksel ditentukan sebesar 1 piksel (Surya et al., 2017).

Analisis tekstur berdasarkan metode statistik memiliki dua orde perhitungan di mana orde kesatu merupakan perhitungan berdasarkan pada karakteristik histogram citra yang menunjukkan probabilitas kemunculan derajat keabuan pada suatu citra dengan mengabaikan hubungan ketetanggaan. Orde kedua merupakan perhitungan yang mempertimbangkan hubungan ketetanggaan pada citra. Dengan demikian maka dibutuhkan matriks kookurensi untuk pembentukan citra keabuan, atau dalam hal ini disebut GLCM. Analisa tekstur orde dua lebih baik dalam merepresentasikan tekstur citra dalam parameter-parameter terukur, seperti kontras, korelasi, homogenitas, entropi, dan energi. GLCM adalah matriks persegi yang dapat menjelaskan sifat - sifat tertentu dengan distribusi spasial. Matriks kookurensi yaitu suatu matriks antara yang merepresentasikan hubungan ketetanggaan antar piksel dalam citra pada berbagai arah orientasi dan jarak spasial. Seperti namanya maka hubungan ketetanggaan yang dimaksud adalah hubungan ketetanggaan berdasarkan *gray level*. *Gray level* adalah nilai yang menunjukkan kecerahan piksel, dimana piksel direpresenasikan dengan rentang nilai 0 sampai 255. Persamaan (1) merupakan persamaan yang digunakan untuk melakukan penentuan nilai *gray level*.

$$Gray\ level = \frac{max_value}{g}$$

Keterangan :

Max_value : nilai maksimal dari sebuah matriks

G : variasi nilai *gray level* (4, 8, 16, 32, dan 64)

Berikut adalah rumus untuk menghasilkan Nilai Contras, Entropy, Correlation dan Energy.


$$\begin{array}{ll}
 \text{Contrast} & \sum_{i=1}^N \sum_{j=1}^N (i - j)^2 P(i, j) \\
 \text{Entropy} & - \sum_{i=1}^N \sum_{j=1}^N P(i, j) \lg P(i, j) \\
 \text{Correlation} & \frac{\sum_{i=1}^N \sum_{j=1}^N (i - \bar{x})(j - \bar{y}) P(i, j)}{\sigma_x \sigma_y} \\
 \text{Energy} & \sum_{i=1}^N \sum_{j=1}^N P(i, j)^2
 \end{array}$$

II.7. Citra X-Ray Thorax

Rongent X-ray adalah proyeksi radiografi untuk mengetahui kondisi anatomi Rongent X-ray adalah proyeksi radiografi untuk mengetahui kondisi anatomi di dalam thorax(dada) yang meliputi organ jantung dan paru-paru dengan menggunakan radiasi X-ray. Pemeriksaan paru-paru pada umumnya menggunakan test Rongent X-ray, dikarenakan pemeriksaan yang dilakukan relatif cepat, mudah dilakukan, dan lebih murah daripada test MRI dan CT-Scan (Matheus Alvian Wikanargo, et al 2018).


Citra paru-paru dapat dikatakan normal apabila citra tersebut tidak memiliki bercak, tekstur citra halus, bentuk dan ukuran paru-paru tidak berubah. Sedangkan citra paru-paru dikatakan abnormal apabila citra tersebut memiliki bercak, tekstur citra tidak halus, bentuk dan ukuran paru-paru berubah. Bentuk dan ukuran citra paru berubah atau pun tidak dapat dilihat dari intensitas piksel pada objek (paru-

paru). Sample hasil Rongent X-ray yang digunakan pada penelitian ini dapat dilihat pada gambar berikut.



(sumber : Radiologi RS. Bunda Thamrin)


Gambar II.8 Hasil Rongent X-Ray Thorax Terpapar Bronkitis Gambaran radiologi kasar.



(sumber : Radiologi RS. Bunda Thamrin)

Gambar II.9 Hasil Rongent X-Ray Thorax sehat

II.8. Gambaran Radiologi Bronkitis



Gambaran menunjukkan adanya bayangan garis- garis yang paralel keluar dari hilus menuju basal paru dari corakan paru yang bertambah.

Gambar II.10 Hasil Rongent X-Ray Thorax Terpapar Bronkitis dan penjelasannya

II.9. Penelitian yang Relevan

Adapun rujukan penelitian sebelumnya yang digunakan peneliti untuk menyelesaikan permasalahan pada penelitian ini seperti tableberikut ini :

No	Penelitian	Metode	Tujuan	Kekurangan	Manfaat
1.	<i>Implementation of K-Nearest Neighbor (K-NN) Algorithm For Public Sentiment Analysis of Online Learning Auliya</i>	Menerapkan algoritma KNN (K-Nearest Neighbor) dalam melakukan sentimen analisis pengguna Twitter tentang isu terkait kebijakan pemerintah tentang Pembelajaran Daring.	Kurangnya jumlah data training yang digunakan dalam proses klasifikasi. Implementasi model data yang lebih besar.	Diketahui bahwa Implementasi model data sebanyak 56,24% tweet positif sedangkan tweet negatif sebanyak 43,76% dengan total data sebanyak 1825.	<i>Implementation of K-Nearest Neighbor (K-NN) Algorithm For Public Sentiment Analysis of Online Learning Auliya</i>
2.	Implementasi Algoritma K-Nearest Neighbor (K-NN) dalam Deteksi Dini Penyakit Hepatitis C	Classification, Machine Learning, K-Nearest Neighbor Algorithm.	Deteksi dini penyakit Hepatitis C dengan metode klasifikasi K-Nearest Neighbor dihasilkan.	Penelitian ini hanya untuk deteksi dini (deteksi awal) penyakit Hepatitis C dengan	Dalam mengimplementasikan metode klasifikasi K-Nearest Neighbor dalam deteksi dini penyakit Hepatitis C untuk mencapai akurasi yang optimal.
3.	<i>Application of Deep Learning Using Convolutional Neural Network (CNN) Method for Women's Skin Classification</i>	<i>Deep Learning, Convolutional Neural Network (CNN)</i>	Penggunaan metode CNN dalam pengenalan objek otomatis dalam membedakan jenis kulit sebagai bahan pertimbangan dalam menentukan objek citra.	Tidak adanya perbandingan metode CNN pada penelitian ini	Metode Convolutional Neural Network (CNN) merupakan metode yang tepat untuk mengklasifikasikan jenis kulit wanita usia 20–30 tahun berdasarkan

4.	Review of deeplearning: concepts,CNN architectures,challenges, applications, future directions	<i>Convolution neural network (CNN), Deep neural network architectures, Deep learning applications</i>	Melihat perkembangan penelitian menggunakan deep learning, machine learning dengan metode convolutional neural networks (CNNs), Medical image analysis, Supervised learning,FPGA,	Kekurangan penelitian ini hanya memfokuskan pada Medical image analysis saja	Menggunakan Deep learning, Machine learning, Convolution neural network (CNN), Deepneural network architectures, untuk di terapkan pada Medical image analysis.
5.	Klasifikasi Citra Menggunakan <i>Convolutional Neural Network(CNN)</i> pada Caltech101	Deep learning, ConvolutionNeural Network	Mengolah 390 citra pada data Caltech-101 yang didapat dari 150 citra adalah kategori Unggas dan sisanya adalah Crocodile, Cougar, dan Face masing-masing dari ketiga kategori tersebut 80 citra	Pada penelitian ini hanya Klasifikasi Kategori Cougar, Crocodile dan Face	Melakukan klasifikasi Emu, Flamingo, Ibis, Pigeon, dan Rooster yang terdiri dari 150 citra. Kategori lainnya, yaitu: Cougar (Cougar Body dan Cougar Face), Crocodile (Crocodile dan Crocodile Head) dan Face (Face dan Face Easy)
6.	<i>Chest X-Ray Image Classification on Common Thorax Diseases using GLCM and AlexNet Deep Features</i>	Menerapkan algoritma <i>Machine Learning</i> dalam membandingkan ekstraksi fitur metode <i>GLCM</i> denganmetode <i>AlexNet</i> .	Juan dari penelitian ini adalah menerapkan <i>Machine Learning</i> untuk mengetahui nilai akurasi hasil sifikasi empat belas penyakit. rax menggunakan gambar rtgen dada dari database Chest X- y menggunakan GrayLevel Co- currence Matrix (GLCM) dan straksi fitur AlexNet	Waktu pemrosesan ekstraksi fiturGLCM untuk 10.000gambar membutuhkan waktu lebih lama 3,8 jam sementara AlexNet membutuhkan waktu 3,4 jam.	<i>Machine Learning</i> mampu memberikan pendeteksian otomatis yang dapat digunakandalam pengembangan sistem diagnosis berbantuan komputeryang dapat membantu para ahlidalam melakukan diagnosis.

7.	Analisis Perbandingan Algoritma Klasifikasi Citra Chest X-ray Untuk Deteksi Covid-19	CNN, SVM, KNN	Penelitian ini bertujuan untuk membandingkan performa dan waktu eksekusi algoritma klasifikasi K-Nearest Neighbors (KNN), Support Vector Machine (SVM), dan CNN untuk mendeteksi Covid-19 berdasarkan citra chest X-Ray.	Fitur yang digunakan dalam melakukan klasifikasi adalah intensitas pixel.	Klasifikasi Citra Chest X-ray Untuk Deteksi Covid-19 dengan pengujian menggunakan 5 Cross Validation.
8.	<i>Segmentation of the Lungs on X-Ray Thorax Image with CNN Architecture U-Net</i>	Menggunakan Metode CNN	Pada penelitian ini disajikan metode segmentasi paru-paru dengan menggunakan metode CNN arsitektur U-Net Untuk mendiagnosis masalah yang terjadi pada paru-paru.	Hanya menggunakan metode CNN saja.	Berdasarkan hasil evaluasi kinerja, disimpulkan bahwa metode yang diusulkan dalam penelitian ini bagus dan valid pada segmentasi paru-paru pada citra X-Ray Thorax.
9.	<i>A Lightweight CNN and Class Weight Balancing on Chest X-ray Images for COVID-19 Detection</i>	Metode yang digunakan CNN	Tujuan dari makalah ini adalah untuk meningkatkan kapasitas CNN dalam menampilkan gambar Rontgen Dada ketika terjadi ketidakseimbangan kelas.	Penelitian ini memerlukan lebih banyak penyaringan dan validasi menggunakan data yang diperbarui dan set data gambar yang lebih besar.	Metode yang disarankan mencapai akurasi masing-masing 94% kasus terburuk, 97% rata-rata, dan 100% kasus terbaik, dan skor F1 masing-masing 96% kasus terburuk, 98% rata-rata, dan 100% kasus terbaik.
10.	Klasifikasi penyakit paru-paru dengan Algoritma K-Nn (K-Nearest Neighbor)	Metode yang digunakan K-NN dengan Ektaksi fitur GLCM	Tujuan penelitian adalah untuk identifikasi penyakit paru-paru dengan harapan agar	Penelitian sejenis diharapkan menambahkan fitur	Mendapatkan nilai Akurasi tinggi yang didapat pada skema 7 (70% citra latih &

	berdasarkan Fitur Tekstur GLCM		mengidentifikasi penyakit paru-paru menjadi optimal, efektif dan efisien.	yang digunakan dan juga citra target diperbanyak untuk meningkatkan akurasi ke depannya.	30% citra uji) yaitu sebesar 63%.
--	-----------------------------------	--	---	--	-----------------------------------