

BAB II

TINJAUAN PUSTAKA

2.1 State of Art

Penelitian terdahulu bertujuan untuk menganalisis dan memperkaya pembahasan penelitian yang sedang dilakukan serta membedakannya dengan penelitian yang sedang dilakukan. Dalam penelitian ini saya memasukkan empat jurnal nasional terkait Model pengenalan aksara jawa . Beberapa jurnal tersebut antara lain :

Penelitian yang berjudul “ Klasifikasi Citra *Menggunakan Convolutional Neural Network (CNN)*” dilakukan pada tahun 2016 oleh Wayan Suartika Eka Putra, Arya Yudhi Wijaya dan Rully Soelaiman dari Institut Teknologi Sepuluh Nopember bertujuan untuk mengklasifikasikan gambar pada *database Caltech 101* menggunakan metode *convolutional neural network (CNN)*. Metode CNN terdiri dari dua langkah, yaitu langkah *feedforward* untuk mengklasifikasikan citra dan langkah *backpropagation* untuk mengatur bobot dan bias pada saat proses pembelajaran. Selain itu, penelitian ini melibatkan pra-pemrosesan gambar menggunakan metode *wrapping* dan *cropping* untuk memfokuskan pada objek yang akan diklasifikasikan. Hasilnya menunjukkan CNN berhasil mengklasifikasikan gambar dengan rata-rata akurasi 85,5%.

Keunggulan penelitian ini adalah menggunakan metode CNN yang merupakan metode *deep learning* yang populer dan efektif untuk klasifikasi citra. Metode CNN dapat mengidentifikasi fitur-fitur penting dari citra tanpa memerlukan ekstraksi fitur tambahan. Metode CNN juga dapat menangani perubahan gambar seperti rotasi, penskalaan, dan pencahayaan.

Kelemahan penelitian ini adalah hanya menggunakan satu jenis *database* yaitu *Caltech 101* yang memiliki jumlah gambar per kategori yang terbatas dan

tidak seimbang. Penelitian ini juga tidak membandingkan kinerja metode CNN dengan metode klasifikasi citra lainnya seperti *K-nearest neighbours*, *support vector machine*, atau *random forest*.

Penelitian yang berjudul “Pengklasifikasian Aksara Jawa Metode *Convolutional Neural Network*” sebuah studi tahun 2023 yang dilakukan oleh Ivan Sukma Hanindria dan Hendry dari Universitas Kristen Satya Wacana bertujuan untuk mengevaluasi efektivitas algoritma *convolutional neural network* (CNN) dalam mengklasifikasikan gambar aksara dasar Jawa. Dataset yang digunakan dalam penelitian ini berisi 20 kategori data teks bahasa Jawa yang masing-masing kategori terdiri dari 108 gambar. Metode CNN yang digunakan pada penelitian ini melibatkan tiga lapisan konvolusional, dua lapisan *max pooling*, dan satu lapisan terhubung penuh. Hasil penelitian menunjukkan CNN mampu mengklasifikasikan gambar teks bahasa Jawa dengan akurasi 85%.

Keunggulan penelitian ini adalah menggunakan metode CNN yang dapat mengidentifikasi fitur-fitur penting dari gambar teks bahasa Jawa tanpa memerlukan ekstraksi fitur tambahan. Metode CNN juga dapat menangani perubahan gambar seperti rotasi, penskalaan, dan pencahayaan. Penelitian ini juga membandingkan kinerja metode CNN dengan metode KNN yang dijalankan menggunakan tool Orange, dan hasilnya menunjukkan bahwa metode CNN lebih unggul dalam hal akurasi.

Kelemahan penelitian ini adalah hanya menggunakan satu jenis data yaitu aksara jawa dasar, tidak termasuk aksara jawa jodoh, sandhangan, murda, swara, rekan, angka dan tanda baca. Penelitian ini juga tidak mempertimbangkan faktor lain yang mungkin mempengaruhi kinerja metode CNN, seperti jumlah dan ukuran filter, fungsi aktivasi, dan metode optimasi.

Penelitian yang berjudul “Pengenalan Aksara Jawa dengan Menggunakan Metode *Convolutional Neural Network*” dilakukan pada tahun 2018 oleh Christian Adi Pradhana, Untari Novia Wisesty dan Febryanthi Sthevanie dari Telkom University. Penelitian ini bertujuan untuk membuat sistem yang mampu mengenali

gambar teks bahasa Jawa yang ditulis tangan di atas kertas. Penelitian ini menggunakan algoritma CNN sebagai dasar pembuatan sistem dengan empat lapisan konvolusional, dua lapisan penggabungan maksimal, dan satu lapisan terhubung penuh. Penelitian ini menggunakan 20 kategori data teks bahasa Jawa yang masing-masing berisi 100 gambar. Hasil penelitian ini menunjukkan bahwa algoritma CNN mampu mengenali gambar teks bahasa Jawa tulisan tangan dengan akurasi 73%.

Keunggulan penelitian ini adalah menggunakan algoritma CNN yang dapat mengidentifikasi fitur-fitur penting dari gambar teks bahasa Jawa tulisan tangan tanpa memerlukan ekstraksi fitur tambahan. Algoritma CNN juga dapat menangani perubahan gambar seperti rotasi, penskalaan, dan pencahayaan. Penelitian ini juga menggunakan data dari tulisan tangan asli, yang lebih mewakili kenyataan.

Kelemahan penelitian ini adalah hanya menggunakan satu jenis data yaitu aksara jawa dasar, tidak termasuk aksara jawa jodoh, sandhangan, murda, swara, rekan, angka dan tanda baca. Penelitian ini juga tidak membandingkan kinerja algoritma CNN dengan algoritma pengenalan tulisan tangan lainnya seperti model *Markov* tersembunyi, pembengkokan waktu dinamis, atau memori jangka pendek.

Penelitian selanjutnya berjudul “Aplikasi Interaktif Pembelajaran Aksara Jawa” yang dilakukan oleh Ir. Ida Widiastuti, MT., dan Muhammad Khosyi’in, ST., MT. dari Dosen Fakultas Teknologi Industri menggunakan metode *Research and Development (R&D)*. Langkah-langkah penelitian meliputi analisis potensi dan masalah, pengumpulan data, desain produk, validasi desain dengan ahli media dan bahan, revisi desain, pengujian dan implementasi produk.

Kekurangan utama dari aplikasi ini adalah hanya berfokus pada materi sejarah aksara jawa dalam cerita ajisaka, aksara carakan dan pengiringnya, sandhangan, aksara murda, aksara swara, aksara rekan, angka jawa dan tanda baca. Materi lain seperti aksara wilangan, aksara rekan, dan aksara murda tidak disertakan dalam aplikasi ini. Selain itu, aplikasi ini menggunakan perangkat lunak

Macromedia Flash CS3, yang belum didukung oleh *Adobe* sejak tahun 2020 dan dapat menyebabkan masalah kompatibilitas dan keamanan.

Sisi positifnya, aplikasi memberikan kontribusi positif bagi dunia pendidikan, khususnya dalam pemanfaatan teknologi multimedia untuk melestarikan tulisan Jawa. Keunggulan lainnya adalah kemampuan aplikasi dalam membantu pembelajaran Aksara Jawa dengan menyajikan materi dalam format teks, audio dan visual sehingga lebih menarik dan interaktif bagi siswa.

2.2 Dasar Teori

2.2.1 Aksara Jawa

Aksara Jawa kuno yang dikenal dengan aksara Jawa telah digunakan sejak kerajaan Mataram pada abad ketujuh belas. Aksara-aksara ini kebanyakan ditulis tangan di atas batu dan digunakan untuk menulis sejarah Indonesia. Karakter ini terkadang masih digunakan oleh penduduk setempat sebagai model nama tempat, tempat wisata, pernikahan, batu nisan, dan lain-lain.

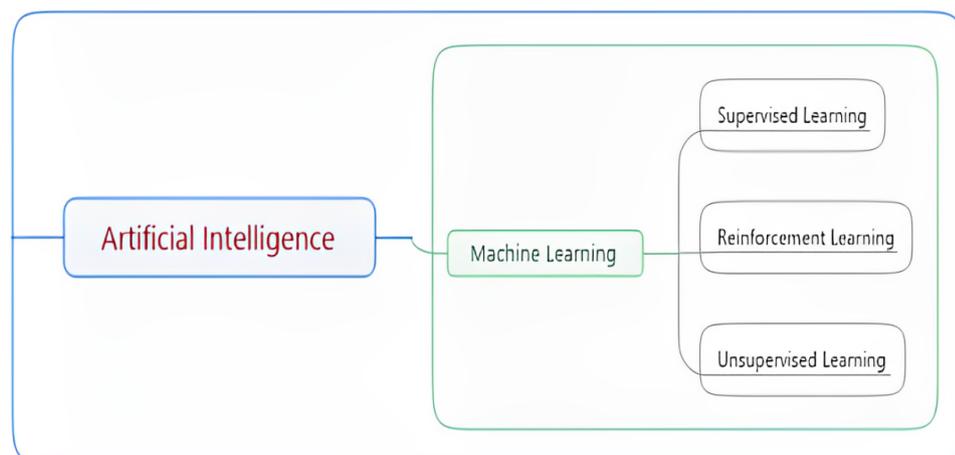
Dibandingkan dengan karkater Latin, aksara Jawa memiliki struktur dan bentuk yang berbeda. Basis dari aksara Jawa disebut dengan *Carakan* , yang mana terdiri dari 20 suku kata yang dinamakan dengan Dentawyanjana Gambar 2.1 adalah kumpulan aksara Jawa dasar yang di gunakan pada pelitian ini.

AKSARA JAWA				
ꦲ	ꦤ	ꦕ	ꦫ	ꦏ
ha	na	ca	ra	ka
ꦢ	ꦠ	ꦱ	ꦮ	ꦭ
da	ta	sa	wa	la
ꦥ	ꦢꦲ	ꦗ	ꦪ	ꦤꦪ
pa	dha	ja	ya	nya
ꦩ	ꦒ	ꦧ	ꦠ	ꦤꦒ
ma	ga	ba	tha	nga

Gambar 2. 1 Kumpulan Aksara Jawa

2.2.2 Machine Learning

Machine learning adalah sub-bidang dari kecerdasan buatan (*Artificial Intelligence*) yang telah menjadi fokus utama dalam berbagai penelitian dan aplikasi untuk menyelesaikan berbagai permasalahan. *Machine learning* juga dapat didefinisikan sebagai penerapan algoritma matematika pada komputer yang dikembangkan melalui proses pembelajaran dari data, dengan tujuan untuk menghasilkan prediksi di masa depan. Proses pembelajaran ini melibatkan dua tahap utama, yaitu pelatihan (*training*) dan pengujian (*testing*) Gambar 2.2 menunjukkan Skema *Artificial Intelligence* dan *Machine Learning* .



Gambar 2. 2 Skema *Artificial Intelligence* dan *Machine Learning*

Machine learning dapat dibagi menjadi tiga kategori utama: *Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning*. Diagram di atas menjelaskan hubungan antara *Artificial Intelligence* dan *machine learning*. Teknologi yang digunakan oleh *Supervised Learning* merupakan metode klasifikasi di mana seluruh data di beri *label* untuk mengklasifikasi kelas yang tidak di kenal. Sedangkan teknik *Unsupervised learning* atau sering juga disebut *cluster* dikarenakan tidak memerlukan label untuk kumpulan data, teknik pengajaran yang

diawasi digunakan untuk mengklasifikasikan kelas yang tidak dikenal. Namun, metode pengajaran yang tidak diawasi sering disebut sebagai kelompok karena tidak memerlukan label untuk kumpulan data dan hasilnya tidak dapat menemukan kelas yang telah ditentukan. *Reinforcement Learning* biasanya berada di antara pengajaran yang diawasi dan tidak diawasi. Metode ini bekerja dalam lingkungan yang dinamis di mana ide-ide harus menyelesaikan tujuan tanpa diberitahu langsung oleh komputer jika tujuan tersebut telah tercapai.

Machine learning adalah suatu pendekatan dalam pemecahan masalah yang melibatkan beberapa tahapan kunci. Pertama-tama, proses dimulai dengan pengumpulan data yang relevan terhadap permasalahan yang ingin dipecahkan. Data tersebut kemudian menjalani tahap pemrosesan, di mana dipreparasi dan disiapkan agar dapat digunakan oleh algoritma *machine learning*. Setelah data siap, langkah selanjutnya adalah pembelajaran model, di mana algoritma *machine learning* mempelajari pola-pola yang terdapat dalam data untuk membangun model yang dapat digunakan untuk prediksi atau klasifikasi. Pentingnya tahap evaluasi model tidak bisa diabaikan, di mana model yang telah dibangun dievaluasi menggunakan data yang tidak pernah dilihat sebelumnya untuk memastikan kinerjanya optimal. Terakhir, setelah model terlatih dengan baik, kita dapat menggunakannya dalam situasi nyata untuk memprediksi hasil baru atau mendukung pengambilan keputusan. Dengan demikian, proses ini menciptakan suatu siklus yang memungkinkan sistem untuk terus berkembang dan meningkatkan performanya seiring berjalannya waktu. Contoh pengaplikasian *Machine learning* di antaranya rekomendasi film, pemerapan *Machine learning* ini mempelajari kecenderungan pengguna berdasarkan data histori dan memberikan rekomendasi yang sesuai dan pengenalan tulisan di *Machine learning* belajar mengenali karakter tulisan tangan dari data pelatihan[2].

2.2.3 Python

Python adalah bahasa pemrograman yang sangat mudah digunakan dan dirancang untuk menjadi mudah dimengerti dengan fokus pada keterbacaan kode.

Bahasa ini memiliki banyak kemampuan dan memiliki sintaksis kode yang sangat jelas. Untuk mendukung fungsionalitasnya, *Python* juga dilengkapi dengan pustaka standar yang luas dan komprehensif. Selain itu, ia memiliki dukungan komunitas yang besar, yang membuatnya pilihan yang bagus untuk pengembang baru dan lama.

Python mendukung banyak gaya pemrograman, terutama pemrograman berorientasi objek, pemrograman *imperatif*, dan pemrograman fungsional. Yang menarik dari hal ini adalah bahwa ia membiarkan pengembang memilih pendekatan yang paling sesuai dengan proyek mereka daripada membatasi penggunaan gaya tertentu.

Python memiliki kemampuan sebagai bahasa pemrograman dinamis dengan manajemen memori otomatis, yang berarti bahwa itu dapat menangani sebagian besar tugas manajemen memori secara otomatis, mengurangi tanggung jawab pengembang. *Python* biasanya digunakan sebagai bahasa skrip, seperti bahasa pemrograman dinamis lainnya. Perlu diingat bahwa *Python* tidak hanya digunakan untuk *skrip*; bahasa ini juga digunakan dalam berbagai konteks pengembangan perangkat lunak.

Python memiliki kemampuan untuk berfungsi di berbagai platform sistem operasi, yang memungkinkan pengembang menggunakannya untuk membuat sistem operasi [3][4].

2.2.4 Image Segmentation

Segmentasi gambar adalah proses di mana komputer membagi dan memotong sebuah gambar menjadi bagian-bagian tertentu. Dalam penelitian ini, segmentasi gambar akan digunakan untuk memisahkan teks aksara Jawa menjadi potongan-potongan huruf. Proses segmentasi pada dasarnya didasarkan pada dua properti dasar dari nilai intensitas pada gambar, yaitu diskontinuitas dan kesamaan. Tujuannya adalah agar setiap huruf Jawa dalam dokumen dapat dikenali dengan mudah. Sebagai langkah pertama dalam proses pengenalan huruf Jawa, segmentasi

gambar ini sangat penting. Setelah selesai, kita akan dapat lebih memahami dan mengenali setiap huruf dengan lebih baik.[5].

2.2.5 Deep Learning

Deep Learning adalah metode pembelajaran mesin yang menggunakan jaringan saraf tiruan berlapis-lapis yang mirip dengan struktur otak manusia. Algoritma yang digunakan dalam pembelajaran mendalam melakukan banyak transformasi non-linier, yang membuatnya dianggap sebagai kombinasi antara pembelajaran mesin dan jaringan saraf tiruan.

Convolutional Networks, *Restricted Boltzmann Machine* (RBM), *Deep Belief Networks* (DBN), dan *Stacked Autoencoder* adalah beberapa algoritma *Deep Learning*. Karena menggunakan fungsi transformasi non-linear berlapis-lapis untuk menghasilkan representasi data abstrak tingkat tinggi, pembelajaran mendalam juga dikenal sebagai pembelajaran dalam atau pembelajaran struktural mendalam.

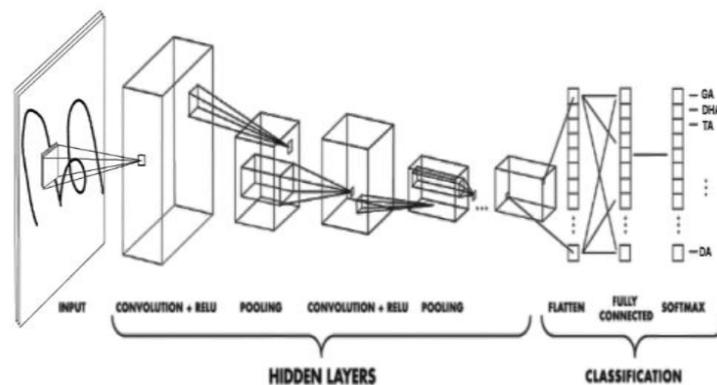
Metode ini bisa diterapkan pada pembelajaran terarah, tak terarah, dan semi-terarah. Contoh penerapannya mencakup pengenalan gambar, pengenalan suara, klasifikasi teks, dan lain-lain. *Deep Learning* unggul karena dapat secara otomatis mengekstraksi fitur-fitur relevan dari data input, sehingga mengurangi kebutuhan pemrograman untuk memilih fitur secara eksplisit.

Deep Learning menghasilkan output dengan memproses data melalui lapisan tersembunyi (*hidden layer*) dengan metadata sebagai input. Selain itu, algoritma ini dapat diterapkan dalam berbagai situasi, termasuk yang memerlukan pengawasan, tanpa pengawasan, dan semi-terawasi. Karena kemampuan untuk menangkap fitur secara otomatis, dia sangat penting untuk pengembangan AI[6].

2.2.6 Convolutional Neural Network

Convolutional Neural Network (CNN) ialah prosedur pemecahan pembelajaran mendalam yang dibuat buat memproses data gambar masukan. Ini memilih pentingnya (bobot serta bias yg bisa dipelajari) berasal aneka macam aspek

dalam sebuah gambar dan digunakan untuk membedakan satu objek asal objek lainnya. CNN ialah arsitektur jaringan saraf yang biasa digunakan buat analisis data gambar. intinya, CNN tak berbeda menggunakan jaringan saraf biasa. CNN terdiri berasal 2 lapisan arsitektur, yaitu lapisan pembelajaran fitur serta lapisan klasifikasi, seperti yang ditunjukkan di Gambar 2.3 .



Gambar 2. 3 Arsitektur Convolutional Neural Network

Pada bagian pembelajaran fitur terdapat lapisan yang dapat digunakan untuk menerima masukan gambar secara langsung di awal dan memprosesnya hingga menghasilkan data keluaran. Lapisan pada proses ini terdiri dari lapisan konvolusional dan *pooling*, dimana setiap proses lapisan akan menghasilkan peta fitur yang mewakili gambar secara digital, yang kemudian diteruskan ke lapisan klasifikasi.

Lapisan klasifikasi terdiri dari beberapa lapisan yang berisi neuron yang terhubung sepenuhnya ke lapisan lain. Lapisan ini menerima masukan dari lapisan keluaran bagian pembelajaran fitur kemudian diratakan dengan menambahkan beberapa lapisan tersembunyi pada lapisan yang terhubung penuh untuk menghasilkan keluaran berupa akurasi klasifikasi untuk setiap kategori. Tabel 2.1 menjelaskan bagian-bagian lapisan arsitektur CNN.

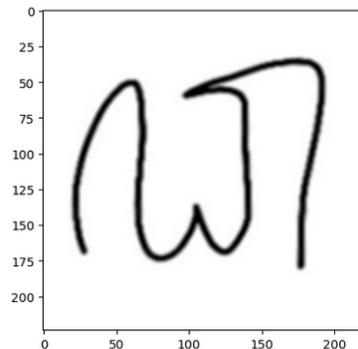
Tabel 2. 1 Bagian Lapisan Arsitektur CNN

Algoritma Proses Convolutioan Neural Network

	a. <i>Input Layer</i>
<i>Feature Learning</i>	b. <i>Convolution Layer</i>
	c. <i>Activation Layer</i>
	d. <i>Pooling Layer</i>
<i>Classification</i>	e. <i>Fully Connected Layer</i>
	f. <i>Output Layer</i>

a. *Input Layer*

Lapisan ini berguna untuk menampung pixel value dari citra yang diinputkan. Citra aksara Jawa yang telah diinputkan memiliki 3 channel warna RGB (*Red, Green, Blue*) pada penelitian ini data yang dipakai berupa aksara Jawa Dasar dan sebagai contoh saya akan mengambil data huruf Jawa “dha” yang di tunjukan pad Gambar 2.4 di bawah.

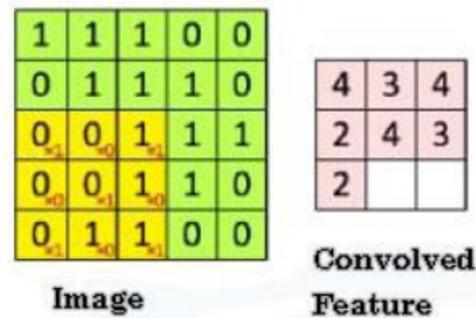


Gambar 2. 4 Gambar Aksara Jawa dha

b. *Lapisan konvolusi (Convolution Layer)*

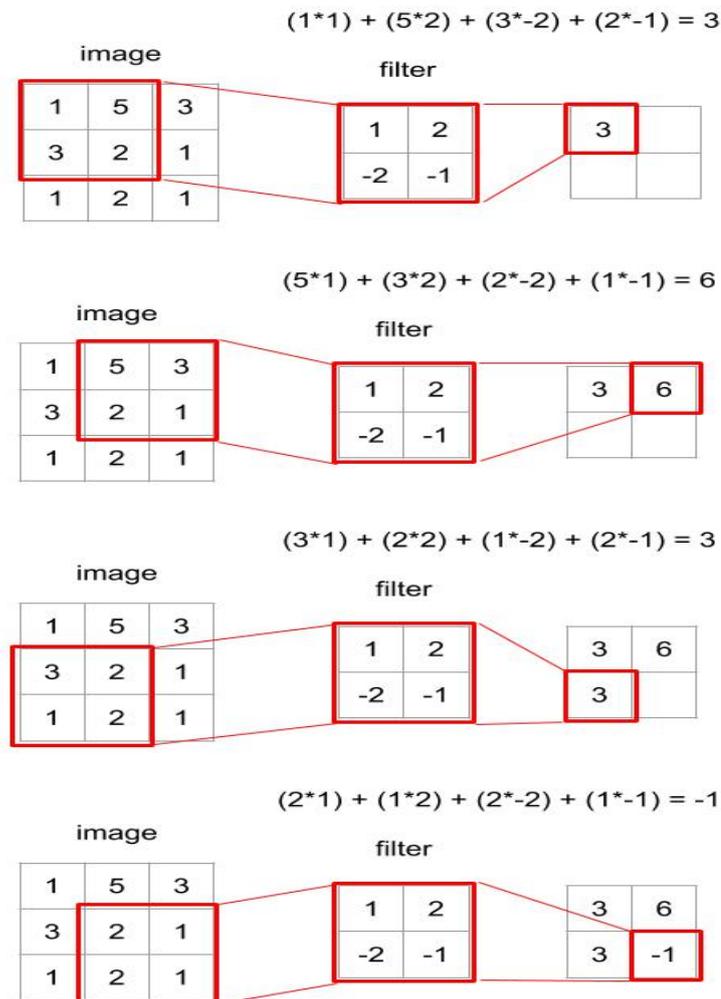
Lapisan konvolusional terdiri dari banyak *neuron* yang disusun secara khusus untuk membentuk *filter* yang memiliki panjang dan tinggi piksel. Proses konvolusi menggunakan *kernel* dan *stride* untuk membuat matriks nilai baru. Seperti yang ditunjukkan pada Gambar 2.5 di bawah, konvolusi dalam pengolahan gambar berarti penerapan inti, atau kotak

kuning, ke seluruh gambar dengan variasi *offset*. Hal ini memungkinkan pemrosesan data dan fitur yang lebih baik dari gambar.



Gambar 2. 5 Gambar Operasi Konvolusi

Secara keseluruhan area hijau merupakan citra yang akan mengalami proses konvolusi. Kernel berpindah dari pojok kiri atas ke pojok kanan bawah. Proses konvolusi data citra bertujuan untuk mengekstrak fitur dari citra masukan maksud fitur di sini adalah hasil keluaran konvolusi berupa garis tepi ataupun pola unik yang ada pada suatu gambar pada penelitian ini konvolusi berfungsi untuk mengambil fitur fitur penting pada tulisan jawa. Rumus yang digunakan untuk perhitungan *Convolutional Layer* dapat dilihat dari pada gambar 2.6 di bawah.



Gambar 2. 6 Gambar Proses konvolusi

c. lapisan aktivasi

lapisan aktivasi yang di gunakan pada penelitain saya meliputi penggunaan dua lapisan aktivasi yaitu lapisan aktivasi *Softmax* dan *Relu* (Rectified Linear Unit) untuk lebih jelsanya saya akan jelaskan.

- ***ReLU(Rectified Linear Unit)***

Aktivasi *ReLU* di gunakan karena ke efektifitasnya dalam pengerjaan dan kesederhaannya dalam jaringan saraf tiruan. *ReLU* mengubah input negatif menjadi nol dan membiarkan

input positif tidak berubah. Maka terbentuklah sebuah rumus di bawah ini.

$$f(x) = \max(0, x) = f(x) = \begin{cases} x, & x > 0 \\ 0, & x < 0 \end{cases}$$

Fungsi ini memperbaiki nilai input yang kurang dari nol sehingga memaksanya menjadi nol dan menghilangkan gradien hilang masalah yang diamati pada jenis fungsi aktivasi sebelumnya. Fungsi *ReLU* telah digunakan dalam unit tersembunyi dari jaringan saraf di lapisan keluaran jaringan dengan contoh umum yang ditemukan di objek klasifikasi .

- ***Softmax***

Softmax adalah fungsi aktivasi yang mengubah output dari lapisan terakhir jaringan saraf menjadi distribusi probabilitas yang jumlahnya sama dengan 1. Fungsi ini sangat cocok untuk tugas klasifikasi multikelas. Maka terbentuklah suatu rumus seperti di bawah ini.

$$f(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$$

Model akan membuat keputusan yang lebih dapat diandalkan dan akurat jika menggunakan *Softmax*. Kita dapat dengan cepat menentukan karakter mana yang paling mungkin cocok dengan gambar masukan dengan mengubah skor menjadi probabilitas. Dalam aplikasi yang melibatkan pengenalan karakter seperti pada proses pengenalan aksara Jawa.

Contoh Penggunaan *Softmax* Pada Model *CNN*

Misalkan model Anda memproses gambar aksara Jawa dan menghasilkan skor seperti berikut:

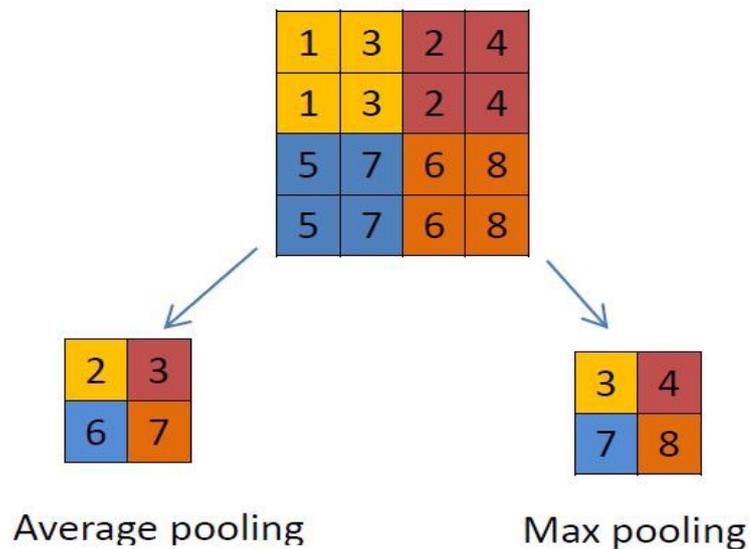
- 'ha': 2.0
- 'na': 1.0
- 'ca': 0.1

Fungsi *Softmax* mengubah skor ini menjadi probabilitas:

- 'ha': 0.65 (65%)
- 'na': 0.24 (24%)
- 'ca': 0.11 (11%)

Jadi, menurut model, gambar tersebut memiliki kemungkinan 65% untuk menjadi aksara 'ha', 24% untuk menjadi aksara 'na', dan 11% untuk menjadi aksara 'ca'. Karena 65% adalah yang tertinggi, model akan memilih 'ha' sebagai prediksi akhir[7].

d. Pooling layer

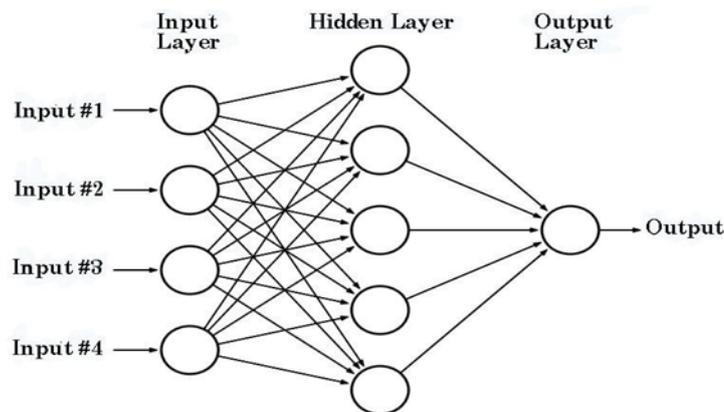


Gambar 2. 7 Pooling Layer

Pada gambar 2.7 di atas *Max pooling* dan *Average pooling* digunakan pada model pengenalan karakter Jawa Hanacaraka dengan CNN untuk memperkecil ukuran peta fitur, yang pada akhirnya mengurangi jumlah parameter dan komputasi dalam jaringan. Dengan pengumpulan maksimum yang mempertahankan fitur-fitur yang paling menonjol dan pengumpulan rata-rata memberikan representasi yang lebih rata-rata dari fitur-fitur tersebut, teknik ini membantu dalam menangkap informasi penting. Selain itu, penggabungan akan meningkatkan performa model dengan mengurangi overfitting dan memperkuat ketahanan model terhadap noise dan distorsi.

e. Fully connected layer

Lapisan padat, penuh dengan neuron aktivitas, biasanya disebut lapisan terhubung penuh dan menghubungkan semua neuron lapisan sebelumnya ke lapisan berikutnya seperti jaringan saraf tiruan Gambar 2.8 menunjukkan proses pada *fully connected layer*.



Gambar 2. 8 Fully Connected Layer

Pada penelitian saya yang berjudul “Model Pengenalan Karakter Aksara Jawa Hanacaraka dengan *Convolutional Neuran Network*”, fitur-fitur yang diekstrak dari lapisan konvolusi dan pooling digabungkan dengan lapisan yang terhubung penuh, yang kemudian memetakan fitur-fitur tersebut ke dalam kelas-kelas aksara tertentu. Lapisan ini penting untuk keberhasilan pengenalan karakter dalam model Anda karena

memungkinkan model membuat keputusan akhir tentang kelas karakter yang diidentifikasi.

f. Output layer

Setelah melalui berbagai tahap, mulai dari input data hingga ketahap klasifikasi dengan *softmax* pada akhirnya model dapat mengenali inputan aksara jawa dan memberikan hasil output berupa tulisan latin berdasarkan dataset yang telah di inputkan. Proses pelabelan dilakukan secara otomatis berdasarkan 20 nama *folder dataset* yang telah di inputkan [8].

2.2.7 Evaluasi Matrix

Dalam pengajaran mesin dan statistik, evaluasi matriks adalah alat yang digunakan untuk mengevaluasi kinerja model klasifikasi dan sebagai pengukur akurasi model. Perhitungan nilai akurasi bertujuan untuk memprediksi efektifitas suatu algoritma dengan menunjukkan nilai aktual terhadap keseluruhan label kelas. Dengan demikian, nilai akurasi suatu model yang telah di buat dapat menunjukkan keefektifan sebuah algoritma secara keseluruhan. Perhitungan akurasi dapat dilakukan dengan persamaan 1 di bawah ini.

$$Akurasi = \frac{TP + TN}{TP + FP + FN + TN} * 100\% \quad (1)[9]$$

True positive (TP) adalah jumlah sampel yang benar-benar positif dan juga diprediksi sebagai positif. *True negative* (TN) mengacu pada jumlah sampel negatif yang dengan benar diklasifikasikan sebagai negatif. *False positive* (FP) adalah jumlah sampel yang diprediksi sebagai positif tetapi sebenarnya negatif. *False negative* (FN) adalah jumlah sampel yang diprediksi sebagai negatif tetapi sebenarnya positif.

Tetapi jika dataset berbentuk *multiclass* maka rumus perhitungan akurasinya menjadi seperti di bawah ini

$$Akurasi = \frac{\Sigma TP}{Total\ Instances} = \frac{\Sigma Diagonal\ dari\ matrix}{Total\ Instances}$$

Dalam konteks confusion matrix, ini diwakili oleh jumlah *instance* yang terletak di sepanjang diagonal utama matrix. ΣTP (*Sum of True Positives*) adalah penjumlahan dari semua nilai pada diagonal tersebut, yang menggambarkan keseluruhan prediksi yang benar oleh model.

2.2.8 Tensorflow

TensorFlow adalah perangkat lunak sumber terbuka untuk pemrograman aliran data. Ini terkenal dalam aplikasi pembelajaran mesin, khususnya jaringan saraf, sebagai perpustakaan matematika simbolik. Dikembangkan oleh tim *Google Brain*, *TensorFlow* berjalan pada CPU dan GPU (unit pemrosesan grafis), memberikan fleksibilitas untuk menyelesaikan tugas-tugas komputasi yang intensif.

TensorFlow memulai debutnya pada 11 Februari 2017. Keunggulannya adalah dapat berjalan di berbagai *platform*, termasuk *Linux 64-bit*, *macOS*, *Windows*, dan platform komputasi seluler seperti *Android* dan *iOS*. Hal ini memungkinkan penggunaan dan adaptasi secara luas pada berbagai lingkungan.

Dengan *TensorFlow* ini, *developer* dapat dengan mudah mengimplementasikan dan melatih model *machine learning* yang kompleks, termasuk model *deep learning*. Hal ini menjadikannya alat yang sangat populer di komunitas pengembangan kecerdasan buatan dan pembelajaran mesin [10].

2.2.9 Keras

Membangun model yang efektif dan efisien untuk tugas pengenalan karakter dimungkinkan dengan penggunaan Keras dalam penelitian model pengenalan karakter Jawa Hanacaraka dengan CNN. Karena alat *Keras* yang sangat fleksibel

dan mudah digunakan, peneliti dapat berkonsentrasi pada pengembangan dan pengujian model daripada terlalu terlibat dalam detail teknis yang rumit[8].