

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Teknologi dalam Pendidikan

Kemajuan teknologi informasi dan komunikasi telah mengubah cara belajar-mengajar di berbagai bidang, termasuk pendidikan. Dengan teknologi digital, metode pembelajaran kini dapat menjadi lebih interaktif, personal, dan efisien. Misalnya, aplikasi edukasi daring memungkinkan siswa untuk belajar di mana saja dan kapan saja, memberikan pengalaman belajar yang lebih dinamis dan disesuaikan dengan kebutuhan individu (Anggraeni dkk., 2024).

Dalam pendidikan bahasa, teknologi semakin memainkan peran penting dengan menyediakan alat bantu untuk mempermudah proses belajar-mengajar. Inovasi seperti kecerdasan buatan (*Artificial Intelligence/AI*) mampu menghadirkan solusi atas berbagai tantangan, seperti pengenalan pola dan pengolahan citra. Teknologi ini sangat relevan dalam pembelajaran bahasa dengan sistem penulisan yang kompleks, seperti bahasa Jepang.

2.1.2 Hiragana

Hiragana adalah salah satu dari tiga jenis huruf utama dalam sistem penulisan bahasa Jepang. Sistem ini terdiri dari 46 karakter dasar yang berbentuk lebih melengkung dan lembut. Hiragana berfungsi untuk menulis kata-kata asli Jepang, partikel, serta *infleksi gramatikal*. Sebagai contoh, kata kerja dan kata sifat sering ditulis dengan kombinasi Kanji dan Hiragana untuk menunjukkan akhiran

tata bahasa. Dalam konteks informal atau ketika Kanji tidak diketahui, Hiragana juga dapat digunakan sebagai pengganti Kanji.

Namun, bagi pembelajar *non-native*, Hiragana sering menjadi tantangan karena kemiripan visualnya dengan Katakana. Salah satu contoh kemiripan karakter adalah "か" (ka) dalam Hiragana yang terlihat serupa dengan "カ" (ka) dalam Katakana. Hal ini membuat pembelajaran Hiragana membutuhkan fokus tidak hanya pada penghafalan, tetapi juga pada pengenalan pola serta pemahaman konteks penggunaan karakter.

2.1.3 Katakana

Katakana juga terdiri dari 46 karakter dasar yang berbentuk lebih kaku dan geometris dibandingkan Hiragana. Katakana digunakan untuk menulis kata-kata serapan dari bahasa asing, nama ilmiah, istilah teknis, serta onomatope. Contohnya adalah “コンピュータ” (*konpyūta*) yang berarti "komputer," yang diserap dari bahasa Inggris "*computer*."

Meskipun fungsinya berbeda, Katakana memiliki kemiripan suara dengan Hiragana. Tantangan terbesar bagi pembelajar *non-native* adalah kemiripan visual antara karakter Katakana dan Hiragana. Sebagai contoh, "カ" (ka) dalam Katakana memiliki bentuk yang hampir identik dengan "か" (ka) dalam Hiragana, hanya berbeda dalam jumlah dan posisi guratan.

2.1.4 Lembaga Pelatihan Kerja (LPK) Bahasa Jepang di Indonesia

Lembaga Pelatihan Kerja (LPK) Bahasa Jepang di Indonesia memiliki peran penting dalam membantu masyarakat Indonesia mempelajari bahasa Jepang, baik untuk tujuan pendidikan, karier, maupun ujian JLPT (*Japanese Language*

Proficiency Test). LPK memberikan pelatihan bahasa Jepang secara intensif, yang mencakup keterampilan berbicara, menulis, membaca, dan mendengarkan, serta pemahaman tentang budaya Jepang. Selain itu, lembaga ini juga menyiapkan peserta untuk dapat beradaptasi dengan kehidupan dan pekerjaan di Jepang, dengan mengajarkan keterampilan yang diperlukan dalam lingkungan kerja di negara tersebut (Azwita dkk., 2023).

Namun, dalam praktiknya, LPK di Indonesia sering menghadapi beberapa kendala yang menghambat efektivitas pembelajaran. Salah satunya adalah keterbatasan waktu dan jumlah pengajar, yang memengaruhi kualitas pengajaran dan perhatian yang dapat diberikan kepada setiap peserta. Selain itu, banyak siswa yang mengalami kesulitan dalam mengenali dan memahami karakter bahasa Jepang, seperti huruf Hiragana dan Katakana, terutama karena keterbatasan latar belakang mereka dalam pembelajaran sebelumnya. Untuk mengatasi keterlambatan pemahaman tersebut, penelitian ini dimaksudkan untuk membantu siswa belajar secara mandiri dengan memanfaatkan teknologi berbasis *convolutional neural network* (CNN). Pendekatan ini diharapkan dapat memberikan solusi pembelajaran yang lebih fleksibel dan adaptif sesuai kebutuhan masing-masing siswa.

Dalam konteks ini, teknologi berbasis kecerdasan buatan (AI), khususnya penggunaan algoritma *Convolutional Neural Networks* (CNN), menawarkan solusi yang efektif untuk mengatasi berbagai tantangan yang dihadapi oleh LPK. CNN telah terbukti menjadi salah satu pendekatan yang sangat efektif dalam mengenali karakter tulisan tangan, seperti huruf Hiragana dan Katakana, dengan tingkat akurasi yang sangat tinggi. CNN mampu memproses gambar tulisan tangan dengan

cara yang efisien, dan dapat memberikan hasil yang objektif, cepat, serta akurat dalam menilai kemampuan siswa.

Menurut penelitian oleh Hendriati dkk. (2024) pemanfaatan aplikasi digital dalam pembelajaran bahasa Jepang dapat meningkatkan efisiensi dan kualitas pembelajaran. Aplikasi seperti *Padlet* memungkinkan pengguna untuk mengakses materi pembelajaran kapan saja dan di mana saja, meningkatkan interaksi antara dosen dan mahasiswa melalui fitur diskusi dan umpan balik online, serta menyediakan berbagai macam latihan dan permainan yang mendukung pembelajaran aktif dan menyenangkan. Meskipun demikian, pembelajaran digital perlu diimbangi dengan metode konvensional untuk mencapai hasil pembelajaran yang optimal.

Dengan demikian, penerapan teknologi AI dalam LPK Bahasa Jepang tidak hanya akan meningkatkan efisiensi pembelajaran dan evaluasi, tetapi juga memberikan kontribusi besar terhadap kualitas pengajaran bahasa Jepang di Indonesia, serta mempersiapkan siswa untuk menghadapi tantangan dunia kerja, baik di dalam negeri maupun di Jepang.

2.1.5 Klasifikasi

Klasifikasi adalah proses dalam pembelajaran mesin yang bertujuan untuk memetakan input ke dalam kategori atau kelas tertentu berdasarkan pola yang telah dipelajari. Proses ini melibatkan penggunaan algoritma yang dilatih dengan data berlabel untuk mengenali pola-pola yang ada pada data tersebut sehingga dapat digunakan untuk memprediksi kelas dari data baru. Klasifikasi memiliki peran penting dalam membantu sistem komputer membuat keputusan yang tepat

berdasarkan data yang diberikan. Selain itu, metode ini menjadi dasar dalam pengembangan berbagai aplikasi cerdas yang memerlukan kemampuan pengenalan pola secara otomatis.

Klasifikasi biasanya digunakan dalam berbagai aplikasi, seperti pengenalan tulisan tangan, deteksi spam, serta klasifikasi citra dan objek (Kurniawan, 2021). Dalam pengenalan tulisan tangan, sistem klasifikasi memungkinkan komputer untuk membaca dan memahami tulisan manusia yang bervariasi dalam bentuk dan gaya. Sementara itu, pada deteksi spam, klasifikasi digunakan untuk membedakan antara email yang relevan dan yang tidak diinginkan dengan menganalisis isi serta pola pengirimannya. Pada klasifikasi citra dan objek, teknologi ini banyak dimanfaatkan dalam bidang medis, keamanan, dan transportasi, seperti dalam mendeteksi penyakit melalui citra medis, pengenalan wajah untuk keamanan, serta identifikasi kendaraan di jalan raya.

2.1.6 *Artificial Intelligence*

Artificial Intelligence (AI) atau kecerdasan buatan merujuk pada teknologi yang memungkinkan mesin atau sistem komputer untuk melaksanakan tugas-tugas yang biasanya memerlukan kecerdasan manusia, seperti pengambilan keputusan, pemecahan masalah, dan pemahaman bahasa alami. AI mencakup kemampuan untuk belajar (*machine learning*), memahami Bahasa alami, mengenali pola, serta membuat keputusan berbasis data (Supriadi dkk., 2022). AI diterapkan untuk menciptakan sistem yang dapat secara otomatis melakukan analisis, pengambilan keputusan, dan memberikan solusi optimal berdasarkan data yang tersedia. Dalam konteks pendidikan, AI dimanfaatkan untuk mendukung proses pembelajaran yang

lebih personal, interaktif, dan inovatif. Dalam penelitian ini, AI berperan sebagai teknologi utama yang mendasari sistem klasifikasi huruf Hiragana dan Katakana. Dengan menggunakan AI, sistem dapat menganalisis dan mengenali pola tulisan tangan secara otomatis, sehingga memudahkan proses identifikasi huruf yang ditulis oleh tangan manusia. Pendekatan ini memungkinkan peningkatan akurasi klasifikasi yang lebih tinggi dibandingkan dengan metode konvensional, serta mengurangi ketergantungan pada pengolahan manual yang rentan terhadap kesalahan.

2.1.7 *Machine Learning*

Machine learning (ML) adalah salah satu cabang dalam kecerdasan buatan yang bertujuan untuk menciptakan sistem yang mampu mempelajari dan membuat keputusan secara otonom berdasarkan informasi yang tersedia. Dengan algoritma yang dirancang khusus, sistem ini mampu mengidentifikasi pola dan melakukan prediksi secara otomatis tanpa perlu diprogram secara eksplisit (Roihan dkk., 2019). Secara lebih spesifik, ML berhubungan dengan teknik yang memungkinkan suatu sistem untuk meningkatkan kemampuannya dalam melakukan tugas tertentu, dengan belajar dari data yang sudah ada. Hal ini dapat dilakukan dengan mempelajari pola-pola dalam data yang diberikan, dan semakin banyak data yang digunakan, semakin baik pula model dalam membuat prediksi (Brunton dkk., 2020).

2.1.8 *Deep Learning*

Deep learning merupakan cabang dari pembelajaran mesin (*machine learning*) yang berfokus pada pengembangan algoritma yang menyerupai jaringan saraf biologis manusia. *Deep learning* memanfaatkan jaringan saraf tiruan

(*artificial neural networks*) yang terdiri dari banyak lapisan (*deep neural networks*) untuk mengidentifikasi dan mempelajari pola-pola kompleks dalam data. Menurut Abadi dkk., (2016) *deep learning* mampu secara otomatis belajar dari data yang tidak terstruktur, seperti gambar, suara, dan teks, tanpa memerlukan fitur yang dirancang secara manual. Setiap lapisan dalam jaringan saraf tiruan berturut-turut menjawab untuk menangkap representasi data yang semakin abstrak, memungkinkan model untuk melakukan tugas-tugas seperti klasifikasi, deteksi objek, atau prediksi dengan akurasi tinggi. Salah satu keunggulan utama *deep learning* adalah kemampuannya untuk memanfaatkan data dalam jumlah besar dan komputasi yang tinggi, sehingga cocok untuk digunakan dalam aplikasi modern seperti pengenalan gambar, pemrosesan bahasa alami, dan pengenalan suara. Dengan pendekatan ini, sistem dapat melakukan generalisasi lebih baik terhadap data baru, terutama ketika didukung oleh teknik seperti *transfer learning* untuk meningkatkan efisiensi pelatihan model.

2.1.9 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu bentuk pengembangan dari Multilayer Perceptron (MLP) yang dirancang untuk mengolah data dua dimensi, seperti gambar atau citra. CNN termasuk dalam jenis jaringan saraf mendalam (*deep neural network*) karena memiliki struktur jaringan dengan banyak lapisan. Keunggulan utama CNN terletak pada kemampuannya untuk mengenali pola spasial dan hierarkis dalam data, sehingga sering dimanfaatkan dalam berbagai aplikasi, seperti pengenalan objek, klasifikasi gambar, dan segmentasi citra. Berbeda dengan MLP yang memperlakukan setiap piksel gambar

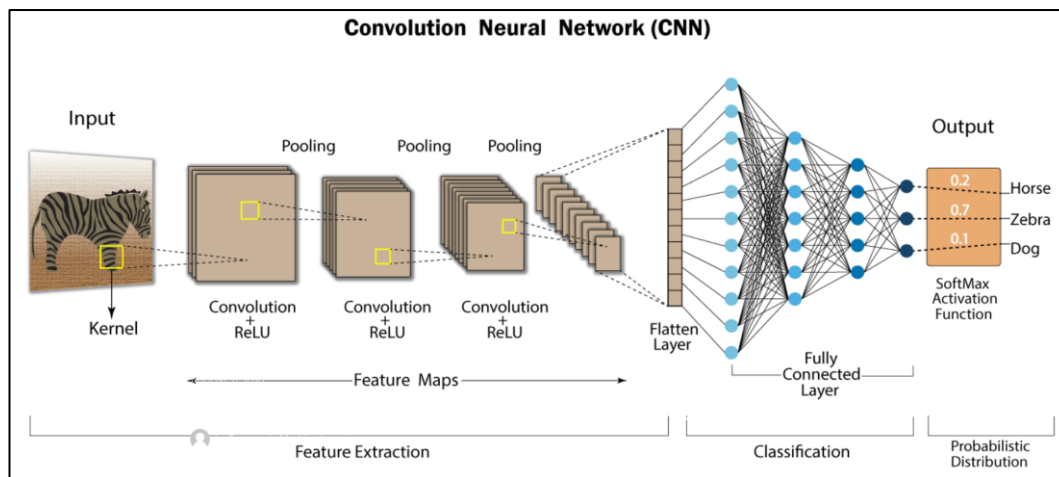
sebagai fitur independen, CNN mampu mempertahankan informasi spasial. Hal ini membuat CNN lebih unggul dalam menganalisis citra karena dapat memahami hubungan antar-piksel yang penting untuk mengenali pola visual.(Suartika E dkk., 2016)

Konsep dasar CNN pertama kali diperkenalkan oleh Kunihiko Fukushima pada tahun 1980 melalui model bernama *NeoCognitron*, yang dirancang untuk mengenali pola visual dengan pendekatan hierarkis. Penelitian ini yang selanjutnya dikembangkan lebih lanjut oleh Yann LeCun di tahun 1990-an melalui model yang dikenal sebagai *LeNet*, yang sukses digunakan dalam tugas pengenalan angka dan tulisan tangan (Lecun dkk., 1998). Penerapan CNN semakin populer setelah Alex Krizhevsky dan timnya memenangkan kompetisi *ImageNet Large Scale Visual Recognition Challenge (ILSVRC)* tahun 2012 menggunakan model *AlexNet*. Prestasi ini menunjukkan bahwa CNN mampu mengungguli metode pembelajaran mesin tradisional, seperti *Support Vector Machine (SVM)*, khususnya dalam tugas pengenalan dan klasifikasi citra (Krizhevsky dkk., 2012). Selain itu, keberhasilan ini juga memicu perkembangan pesat dalam riset dan penerapan deep learning di berbagai bidang teknologi.

A. Arsitektur CNN

Convolutional Neural Network (CNN) merupakan jenis arsitektur neural network yang dirancang khusus untuk memproses data yang memiliki topologi mirip *grid*, seperti gambar 2.1. CNN telah menjadi sangat populer dalam berbagai aplikasi pengenalan gambar dan visi komputer. Hal ini disebabkan oleh kemampuannya dalam mengekstraksi fitur secara otomatis melalui lapisan

konvolusi dan pooling, sehingga dapat mengenali pola-pola penting pada data visual. Selain itu, CNN juga mampu mengurangi kompleksitas data tanpa kehilangan informasi penting, yang membuatnya efisien dalam menangani data berukuran besar seperti citra dan video.



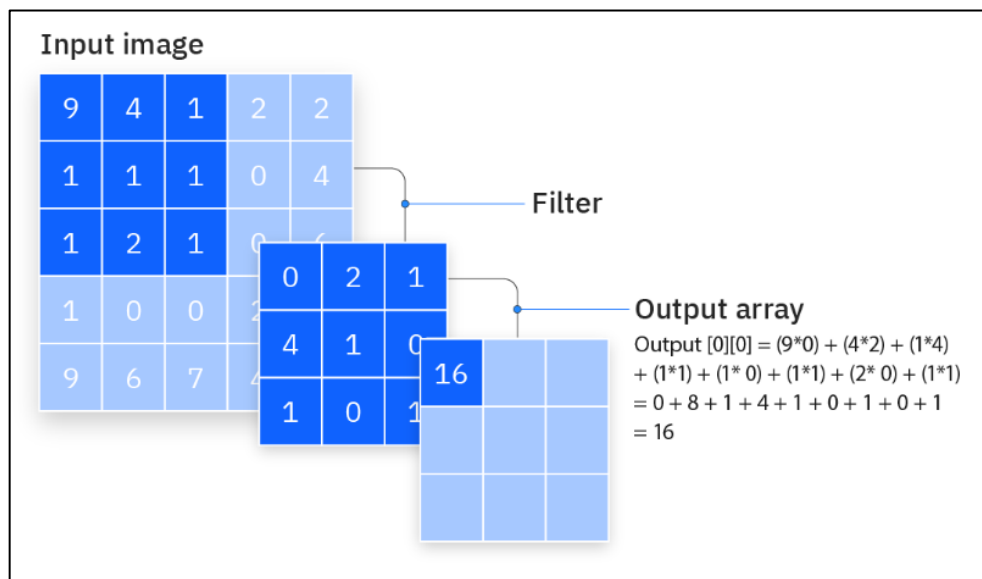
(Sumber: <https://developersbreach.com/convolution-neural-network-deep-learning/>)

Gambar 2. 1 Arsitektur CNN

Arsitektur CNN terdiri dari beberapa lapisan utama yang memiliki peran berbeda namun saling mendukung pengenalan pola visual:

1. *Convolutional Layer*

Lapisan konvolusi atau *Convolution layer* adalah komponen utama dalam CNN yang bertugas mengekstraksi fitur dari gambar. Pada lapisan ini, dilakukan proses konvolusi dengan menerapkan filter pada gambar (Handoko dkk., 2024).



(Sumber: <https://www.ibm.com/id-id/topics/convolutional-neural-networks>)

Gambar 2. 2 Operasi Konvolusi

2. Pooling Layer

Pooling layer adalah komponen krusial dalam arsitektur *Convolutional Neural Network* (CNN) yang berperan dalam mengurangi dimensi data tanpa menghilangkan informasi penting yang ada pada *feature map*. Tujuan utama dari lapisan ini adalah untuk mengurangi kompleksitas komputasi dan membantu mencegah *overfitting*. Dengan mengurangi dimensi data, *pooling layer* memungkinkan model untuk lebih fokus pada fitur-fitur yang paling relevan, sehingga efisiensi komputasi dapat meningkat. Ada dua jenis pooling yang sering digunakan, yaitu:

a. Max Pooling

Pada *max pooling*, nilai maksimum dari area tertentu pada *feature map* diambil. Teknik ini sangat efektif dalam mempertahankan fitur yang paling menonjol pada

citra, sehingga membantu model mengenali pola-pola yang lebih penting dengan lebih baik.

b. Average Pooling

Average pooling menghitung rata-rata nilai dari area tertentu pada feature map. Teknik ini menghasilkan representasi yang lebih halus dari fitur yang ada, namun terkadang kurang efektif dibandingkan *max pooling* dalam mempertahankan fitur-fitur yang paling signifikan.

Pooling layer berperan penting dalam memperkuat informasi utama sambil menghilangkan detail yang kurang signifikan. Hal ini esensial dalam proses pengenalan pola visual, karena memungkinkan model untuk lebih fokus pada fitur yang relevan dan meningkatkan performa keseluruhan.

Menurut penjelasan dari (Goodfellow, 2016), Lapisan pooling digunakan untuk mengurangi dimensi spasial dari *volume input*, Hal ini membantu menurunkan jumlah parameter dan beban komputasi dalam jaringan, serta mencegah terjadinya *overfitting*. Dua jenis pooling yang paling sering digunakan adalah *max pooling*, yang mengambil nilai tertinggi dari sekumpulan nilai, dan *average pooling*, yang menghitung nilai rata-rata.

3. Fully Connected Layer

Fully Connected Layer (FCL) adalah bagian akhir dari arsitektur *Convolutional Neural Network* (CNN) yang bertugas menghubungkan semua neuron dari lapisan sebelumnya secara penuh. Lapisan ini bertindak sebagai pengklasifikasi utama yang mengintegrasikan semua fitur yang telah diekstraksi oleh *convolutional* dan *pooling layer* untuk menghasilkan output akhir. Pada lapisan ini, setiap *neuron* pada

layer fully connected terhubung langsung ke semua *neuron* pada layer sebelumnya, memungkinkan transfer informasi yang lebih lengkap dan menyeluruh. Fungsi utama dari FCL adalah untuk memproses dan menginterpretasikan fitur yang telah diringkas dan diekstraksi, sehingga dapat menghasilkan prediksi atau klasifikasi yang akurat.

2.1.10 Pengenalan Karakter dengan *Convolutional Neural Network* (CNN)

Convolutional Neural Network (CNN) merupakan algoritma deep learning yang dirancang untuk mengolah data citra. CNN memiliki keunggulan luar biasa dalam mendeteksi pola dan fitur visual, sehingga banyak diterapkan dalam berbagai bidang, seperti deteksi wajah, identifikasi objek, dan pengenalan karakter tulisan tangan. Hal ini sejalan dengan penelitian yang menyebutkan bahwa CNN dirancang khusus untuk pengolahan data citra dan pengenalan pola visual (Rachmawanto & Andono, 2022).

2.1.11 TensorFlow

TensorFlow adalah platform yang memungkinkan pengguna untuk melakukan berbagai jenis komputasi, termasuk pengolahan data, pelatihan model machine learning, dan penerapan model tersebut dalam aplikasi nyata. *TensorFlow* menggunakan struktur data yang disebut tensor, yang merupakan *array* multidimensi, untuk merepresentasikan data dan model (TensorFlow, 2021). Salah satu keunggulan utama *TensorFlow* adalah kompatibilitasnya dengan berbagai bahasa pemrograman, termasuk *Python*, *C++*, dan *JavaScript*, sehingga memudahkan integrasi dalam berbagai aplikasi. Selain itu, *TensorFlow* mendukung

eksekusi pada berbagai platform, mulai dari perangkat *mobile* hingga pusat data besar, memungkinkan penerapan model *machine learning* secara luas.

2.1.12 Transfer Learning

Transfer Learning merupakan metode dalam machine learning yang memungkinkan penggunaan pengetahuan dari model yang telah dilatih sebelumnya pada dataset yang besar untuk menyelesaikan tugas baru yang terkait. Dengan pendekatan ini, proses pelatihan dapat dilakukan lebih cepat dibandingkan pelatihan dari awal (*training from scratch*) (Faturrahman dkk., 2023), karena model hanya perlu menyesuaikan beberapa parameter pada lapisan tertentu. *Transfer Learning* bekerja dengan cara mempertahankan parameter dari lapisan awal model yang sudah dilatih sebelumnya dan hanya melakukan pelatihan ulang pada lapisan terakhir sesuai dengan kebutuhan dataset baru.

2.1.13 Confusion Matrix

Confusion Matrix merupakan alat yang digunakan dalam evaluasi performa model klasifikasi, terutama dalam pembelajaran mesin. Matriks ini menyajikan informasi tentang prediksi yang dihasilkan oleh model dibandingkan dengan nilai sebenarnya dalam bentuk tabel. *Confusion Matrix* membantu memberikan wawasan tentang bagaimana model melakukan klasifikasi terhadap setiap kelas secara lebih rinci. Struktur *Confusion Matrix* terdiri dari empat elemen utama, yaitu:

1. *True Positive (TP)* : Jumlah sampel yang berhasil diidentifikasi secara akurat sebagai bagian dari kelas positif. Contohnya, jika sebuah model mendeteksi huruf "A" yang sebenarnya memang "A," maka itu dihitung sebagai *True Positive*.

2. *True Negative* (TN): Jumlah sampel yang berhasil diidentifikasi secara tepat sebagai bagian dari kelas negatif. Misalnya, model mengidentifikasi sebuah huruf bukan "A" dan hasil sebenarnya memang bukan "A."
3. *False Positive* (FP) (*Type I Error*): Jumlah sampel yang secara salah diklasifikasikan sebagai kelas positif. Misalnya, model memprediksi huruf "A," padahal sebenarnya bukan "A."
4. *False Negative* (FN) (*Type II Error*): Jumlah sampel yang secara salah diklasifikasikan sebagai kelas negatif. Misalnya, model menganggap huruf tersebut bukan "A," padahal sebenarnya itu adalah "A."

2.3 Landasan Penelitian

Tabel 2. 1 Landasan Penelitian

No.	Judul Penelitian	Peneliti	Nama Jurnal	Hasil/Isi Penelitian
1.	Deteksi Karakter Hiragana Menggunakan Metode <i>Convolutional Neural Network</i>	(Rachmawanto & Andono, 2022)	Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)	Algoritma <i>Convolutional Neural Network</i> (CNN) untuk pengenalan tulisan tangan huruf Hiragana menunjukkan akurasi tertinggi sebesar 86,5% dengan perbandingan data 70:30, dan 83% dengan perbandingan 60:40. Penelitian menyimpulkan bahwa semakin besar jumlah data pelatihan yang digunakan, semakin tinggi tingkat akurasi yang dapat diraih.
2.	Identifikasi Tulisan Tangan Aksara Jepang Hiragana Menggunakan Metode <i>CNN</i> Arsitektur <i>VGG-16</i>	(Willyanto dkk., 2021)	Jurnal Algoritme	Dengan menggunakan arsitektur CNN <i>VGG-16</i> , akurasi pengenalan huruf Hiragana tulisan tangan mencapai lebih dari 90%. Namun, penelitian mencatat bahwa kesalahan klasifikasi sering terjadi pada huruf yang memiliki bentuk mirip.
3.	Identifikasi Aksara Katakana Menggunakan Metode <i>Convolutional Neural Network</i> Arsitektur <i>LeNet</i>	(Winardi & Hartati, 2022)	Jurnal Algoritme	Penelitian ini mencapai akurasi optimal dengan CNN ketika menggunakan <i>optimizer Adam</i> . Hasil menunjukkan bahwa Katakana yang memiliki bentuk serupa memerlukan lebih banyak data untuk meminimalkan tingkat kesalahan.

No.	Judul Penelitian	Peneliti	Nama Jurnal	Hasil/Isi Penelitian
4.	Implementasi <i>Convolutional Neural Network</i> (CNN) Untuk Pengenalan Tulisan Tangan Aksara Bima	(Handoko dkk., 2024)	Smatika Jurnal	Hasil penelitian menunjukkan bahwa penggunaan <i>learning rate</i> 0.001 menghasilkan akurasi validasi tertinggi sebesar 97,34% dan akurasi pelatihan sebesar 94,36% dengan kombinasi <i>hyperparameter</i> yang optimal, yaitu <i>epoch</i> 100, <i>batch size</i> 32, dan <i>optimizer Adam</i> . Selain itu, terdapat beberapa perhatian terkait. Selain itu, ada beberapa hal yang perlu diperhatikan terkait Kekurangan tersebut meliputi nilai presisi terendah yang ditemukan pada aksara ke-6 (ca) sebesar 83%, serta nilai <i>recall</i> dan <i>f1-score</i> terendah yang terjadi pada aksara ke-10 (la) dengan masing-masing sebesar 75% dan 84%.
5.	Hiragana Character Classification Using <i>Convolutional Neural Networks Methods based on Adam, SGD, and RMSProp Optimizer</i>	(Utomo dkk., 2024)	Scientific Journal of Informatics	Hasil penelitian ini mengevaluasi kinerja <i>Convolutional Neural Network</i> (CNN) untuk pengenalan karakter Hiragana menggunakan tiga <i>optimizer</i> : Adam, <i>SGDM</i> , dan <i>RMSP</i> . Hasilnya menunjukkan bahwa <i>Adam</i> mencapai akurasi tertinggi 99,87%, diikuti <i>SGDM</i> 99,25%, dan <i>RMSP</i> 99,31%. <i>Optimizer RMSP</i> mencatat <i>F1-score</i> tertinggi 99,70%. Metode ini mengungguli penelitian sebelumnya dengan akurasi antara 86,5% hingga 96,95%. Penelitian ini menekankan pentingnya pemilihan <i>optimizer</i> yang tepat dan mengusulkan eksplorasi teknik <i>transfer learning</i> untuk perbaikan di masa depan.
6.	Handwritten alphabet classification in Tamil language using convolution neural network	(Ravi, 2024)	International Journal of Cognitive Computing in Engineering	Penelitian ini berfokus pada pengenalan huruf tulisan tangan menggunakan pendekatan deep learning, khususnya <i>Convolutional Neural Networks</i> (CNN), untuk alfabet Tamil. Tiga model CNN dikembangkan, yaitu <i>THAC-CNN1</i> , <i>THAC-CNN2</i> , dan <i>THAC-CNN3</i> , yang diuji pada dataset gabungan benchmark dan dataset khusus dengan total lebih dari 2800 gambar setelah augmentasi data. Hasil menunjukkan bahwa model <i>THAC-CNN1</i> mencapai akurasi 97% pada data latih dan 92.5% pada data uji, jauh lebih baik dibandingkan model pre-trained <i>VGG-11</i> dan <i>VGG-16</i> yang hanya mencapai akurasi sekitar

No.	Judul Penelitian	Peneliti	Nama Jurnal	Hasil/Isi Penelitian
				72% pada data latih dan 73.5% pada data uji. Hal ini menyoroti keunggulan pendekatan yang dirancang khusus untuk alfabet regional.
7.	Recognition Of Hiragana Japanese Handwriting Characters Using Support Vector Machine And Scale Invariant Feature Transform	(Raditha dkk., 2024)	Jurnal Informatika dan Teknologi Informasi	Penelitian ini menyajikan solusi untuk pengenalan offline karakter Jepang, termasuk Hiragana, Katakana, dan Kanji, dengan menggunakan fitur seperti <i>minutiae</i> yang diekstrak dari gambar tulisan tangan. Solusi ini dirancang untuk mengenali karakter individual, termasuk karakter kuno dari dokumen atau karya seni. Sistem klasifikasi menggabungkan <i>Neural Networks</i> dan lima jenis pengklasifikasi dasar: <i>k-nearest neighbour</i> , <i>decision tree</i> , <i>support vector machine</i> , <i>logistic regression</i> , dan <i>Gaussian Naive Bayes</i> . Menggunakan dataset ETL9G, penelitian ini mencapai akurasi sangat tinggi sebesar 99.934%. Pendekatan ini adalah salah satu algoritma pertama yang menggunakan <i>minutiae</i> untuk mengenali tulisan tangan Jepang.
8.	Recognition of Handwritten Japanese Characters Using Ensemble of Convolutional Neural Networks	(Solis dkk., 2023)	Department of Computer Science, University of Colorado Colorado Springs	Penelitian ini mengevaluasi kinerja <i>ensemble</i> dari tiga jaringan saraf tiruan (CNN) untuk mengenali karakter Jepang tulisan tangan di empat set data: MNIST, K-MNIST, Kuzushiji-49, dan K-Kanji. <i>Ensembl</i> CNN mencapai akurasi rata-rata 96% dengan masing-masing model berkinerja antara 91,8% dan 99,4%. Hasil penelitian ini menyoroti keefektifan metode ansambel dan pembelajaran transfer dalam meningkatkan akurasi klasifikasi, terutama untuk dataset K-Kanji yang menantang, sekaligus menjawab kebutuhan akan sistem yang dapat diandalkan dalam mengenali karakter Jepang untuk pelestarian budaya dan analisis literatur.
9.	Handwritten Character Recognition from Images using CNN-ECOC	(Bora dkk., 2020)	Procedia Computer Science	Penelitian ini membahas metode untuk pengenalan karakter tulisan tangan yang mengintegrasikan <i>Convolutional Neural Networks</i> (CNN) dengan Error-Correcting Output Codes (ECOC) untuk

No.	Judul Penelitian	Peneliti	Nama Jurnal	Hasil/Isi Penelitian
				meningkatkan akurasi klasifikasi. Dokumen ini menyoroti keefektifan pembelajaran mendalam dalam tugas-tugas Optical Character Recognition (OCR), merinci berbagai arsitektur CNN yang digunakan untuk ekstraksi fitur dan menunjukkan bahwa pendekatan CNN-ECOC melampaui pengklasifikasi CNN tradisional dalam hal akurasi. Penelitian ini divalidasi menggunakan dataset gambar karakter tulisan tangan NIST, yang menunjukkan peningkatan kinerja yang signifikan, terutama dengan arsitektur AlexNet.
10.	Improved Arabic Alphabet Characters Classification Using Convolutional Neural Networks (CNN)	(Wagaa dkk., 2022)	Computational Intelligence and Neuroscience	Penelitian ini membahas arsitektur dan proses pembelajaran Jaringan Syaraf Tiruan (JST) secara khusus untuk mengenali karakter tulisan tangan Arab. Dokumen ini merinci komponen-komponen utama seperti operasi penggabungan, penggabungan, lapisan-lapisan yang terhubung secara penuh, dan proses pembelajaran berulang yang melibatkan feedforward dan backpropagation. Berbagai algoritma optimasi, terutama pengoptimal Adam dan variannya, dieksplorasi bersama dengan teknik augmentasi data untuk meningkatkan kinerja model. Studi ini menyajikan hasil dari set data yang berbeda, menyoroti keefektifan model CNN yang diusulkan dalam mencapai tingkat akurasi yang tinggi dibandingkan dengan metode yang sudah ada.

Penelitian yang dilakukan oleh Utomo dkk. (2024) dengan judul “*Hiragana Character Classification Using Convolutional Neural Networks Methods based on Adam, SGD, and RMSProps Optimizer*” adalah penelitian serupa dengan penelitian ini. Penelitian tersebut menggunakan metode *Convolutional Neural Networks* (CNN) untuk klasifikasi huruf Hiragana dengan mengevaluasi kinerja berbagai algoritma optimasi, seperti *Adam*, *SGD*, dan *RMSProp*. Hasil penelitian

menunjukkan akurasi tertinggi sebesar 99,87% menggunakan *optimizer Adam*, diikuti oleh *SGD* sebesar 99,25% dan *RMSProp* sebesar 99,31%. Selain itu, penelitian ini juga menyarankan eksplorasi teknik transfer learning untuk meningkatkan performa model, yang relevan dengan pendekatan yang digunakan pada skripsi ini.

Penelitian relevan lainnya adalah yang dilakukan oleh Willyanto dkk. (2021) yang berjudul “Identifikasi Tulisan Tangan Aksara Jepang Hiragana Menggunakan Metode CNN Arsitektur *VGG-16*”. Dalam penelitian ini, mereka menerapkan metode CNN dengan arsitektur VGG-16 untuk mengidentifikasi tulisan tangan aksara Hiragana Jepang. Hasil penelitian menunjukkan akurasi pengenalan mencapai lebih dari 90%, namun terdapat tantangan dalam membedakan huruf dengan bentuk yang mirip. Hal ini relevan dengan penelitian ini, terutama dalam menghadapi tantangan klasifikasi huruf Hiragana dan Katakana yang memiliki bentuk serupa.

Penelitian ini memiliki perbedaan dengan penelitian sebelumnya, terutama pada fokusnya yang mengklasifikasikan huruf Hiragana dan Katakana secara bersamaan, bukan hanya salah satu jenis aksara. Selain itu, penelitian ini mengadopsi pendekatan transfer learning dengan memanfaatkan model yang telah dilatih sebelumnya, yang belum diterapkan secara eksplisit dalam penelitian sebelumnya. Dataset yang digunakan juga akan berbeda dan lebih variatif, sehingga memberikan kontribusi baru dalam evaluasi kinerja model. Penelitian ini juga bertujuan untuk mengatasi masalah klasifikasi pada huruf yang memiliki bentuk mirip, dengan pendekatan yang lebih efektif dibandingkan penelitian sebelumnya.