

BAB II

LANDASAN TEORI

2.1 *Machine Learning*

Machine learning (pembelajaran mesin) merupakan salah satu cabang dari *artificial intelligence* yang mengacu pada semua jenis program komputer yang dapat “belajar” dengan sendirinya tanpa harus diprogram secara eksplisit oleh manusia. Ide dasar dan ungkapan tersebut memiliki asal-usul beberapa dekade lalu sampai pada *paper* Alan Turing tahun 1950 berjudul *Computing Machinery and Intelligence* yang menampilkan bagian dari pembelajaran mesin yang dapat membodohi manusia agar percaya bahwa itu adalah nyata (Wehle, 2017). Secara umum *machine learning* dapat dibagi menjadi tiga tipe yang terdiri dari:

2.1.1 *Supervised Learning*

Tipe ini memiliki ciri dimana data yang digunakan oleh model merupakan *mapping* antara input dengan variabel target. Algoritma yang ada pada model belajar bagaimana merespon lebih akurat dengan membandingkan output yang dikeluarkan dengan input target yang ada (Jafar Alzubi, 2019). Permasalahan yang dihadapi oleh tipe ini merupakan permasalahan klasifikasi yang memprediksi *class* label dan regresi yang memprediksi *numeric* label.

2.1.2 *Unsupervised Learning*

Tipe ini memiliki ciri dimana model pembelajaran dimaksudkan untuk mendeskripsikan atau mencari pola/hubungan pada data. Tipe ini bergantung hanya pada input data tanpa variabel target (Jafar Alzubi, 2019). Beberapa permasalahan utama yang menggunakan tipe ini adalah *clustering* dan *density estimation*.

2.1.3 *Reinforcement Learning*

Tipe ini memiliki ciri dimana model pembelajaran tidak memiliki data latih tetap melainkan tujuan yang harus dicapai, serta tindakan yang mungkin dilakukan berdasarkan umpan balik yang didapat. Tipe ini juga dianggap sebagai jenis *intermediate learning* karena algoritma hanya diberi respon apakah keluarannya benar atau tidak. Algoritma pada model harus mengeksplorasi dan mengesampingkan berbagai kemungkinan untuk mendapatkan output yang benar (Jafar Alzubi, 2019).

2.2 CRNN

Convolutional Recurrent Neural Network (CRNN) merupakan salah satu jenis *neural network* yang terdiri dari paduan atau susunan *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN) dimana biasanya input RNN merupakan output dari CNN (Chatterjee, 2019).


2.3 Convolutional Neural Network (CNN)

CNN merupakan tipe spesial dari *multilayer neural network* atau arsitektur *deep learning* yang terinspirasi dari persepsi visual makhluk hidup (Ghosh, Sufian, Sultana, Chakrabarti, & De, 2020). Penelitian awal yang menjadi dasar CNN berawal dari Hubel dan Wiesel mengenai *virtual cortex* pada indera penglihatan kucing. Penelitian yang menjadi model teoritis CNN pertama diajukan oleh Kunihiko Fukushima pada 1980.

CNN merupakan salah satu jenis dari *Artificial Neural Network*, yang memiliki arsitektur *deep feed-forward* dan memiliki kemampuan generalisasi yang luar biasa serta dapat mempelajari fitur yang sangat abstrak terutama data spasial dan dapat diidentifikasi dengan lebih efisien. *Deep CNN* model terdiri dari beberapa lapisan pemrosesan yang dapat mempelajari berbagai fitur data input dengan beberapa tingkat abstraksi (Ghosh, Sufian, Sultana, Chakrabarti, & De, 2020), layer tersebut adalah:

2.3.1 Convolutional Layer

Convolutional layer merupakan salah satu tahap serta merupakan proses utama pada arsitektur CNN yang melakukan operasi konvolusi pada input. Konvolusi merupakan istilah matematis yang merupakan kombinasi dari dua fungsi yang menghasilkan fungsi ketiga (menggabungkan dua set informasi). Output dari konvolusi *layer* didapat dari konvolusi antara input dengan *filter* yang merupakan tumpukan dari *kernel* dan menghasilkan *feature map*.



Gambar 2.1 *Convolutional Layer* (Reynolds, 2019)

Berdasarkan gambar 2.1, input yang berbentuk *array* diambil *sample* sebanyak 3x3 menyesuaikan dengan bentuk filter kemudian dikalikan (*element-wise*) dengan *kernel weight* yang terinisialisasi selanjutnya dijumlahkan sehingga menghasilkan *feature map*. Persamaan untuk *convolutional layer* (PyTorch) dapat dijabarkan pada persamaan ke-1 berikut:


$$out(N_i, C_j) = bias(C_j) + \sum_{k=0}^{C_{in}-1} weight(C_j, k) * input(N_i, k)$$

Keterangan:

- N = *Batch*
- C_j = *Channel output*
- C_{in} = *Channel input*
- $out(N_i, C_j)$ = *Output ke i pada batch dan ke j pada channel*
- $bias(C_j)$ = *Bias pada channel ke j*
- $weight(C_j, k)$ = *Weight pada channel ke j dan ke k pada C_{in}*
- $*$ = *Operasi Cross-Correlation*
- $input(N_i, k)$ = *Input ke i pada batch dan ke k pada C_{in}*

2.3.2 Pooling Layer

Pooling atau operasi *pooling* merupakan pengurangan dimensi matriks dengan menggunakan *filter* dan *stride* (banyaknya pergeseran) yang telah ditentukan pada *feature map*. Terdapat beberapa teknik *pooling* seperti, *max pooling* untuk nilai terbesar, dan *average pooling* yang mengambil nilai rata-rata dengan memperhatikan ukuran input yang dinamis. Berikut merupakan penjelasan visualisasi sederhana dari *max pool* beserta persamaannya dengan *average pool*.



Gambar 2.2 MaxPool Layer dengan 2x2 filter dan stride 2 (Podareanu, Codreanu, Aigner, Leeuwen, & Weinberg, 2019)

MaxPool (PyTorch) sebagai persamaan ke-2:

$$out(N_i, C_j, h, w) = \max_{m=0, \dots, kH-1} \max_{n=0, \dots, kW-1} input(N_i, C_j, stride[0] \times h + m, stride[1] \times w + n)$$

AveragePool (PyTorch) sebagai persamaan ke-3:

$$out(N_i, C_j, h, w) = \frac{1}{kH * kW} \sum_{m=0}^{kH-1} \sum_{n=0}^{kW-1} input(N_i, C_j, stride[0] \times h + m, stride[1] \times w + n)$$

Keterangan:

$out(N_i, C_j, h, w)$ = Output ke i pada *batch*, ke j pada *channel*

kH = kernel size H (height image)


kW = kernel size W (height image)

stride = Langkah *window*

2.3.3 Activation Function

Tugas utama dari *activation function* pada model *neural network* adalah untuk memetakan input ke output, dimana nilai input didapat dari jumlah *weight* dari input *neuron* dan ditambah bias (jika ada), dengan kata lain, fungsi aktivasi memutuskan apakah *neuron* harus aktif atau tidak. fungsi aktivasi secara umum terbagi menjadi dua jenis, *Linear* dan *Non-Linear*. Beberapa jenis *Non-Linear* (Feng & Lu, 2019) diantaranya:

1. Sigmoid dan Tanh



Gambar 2.3 Sigmoid and Tanh Graph

Fungsi Sigmoid digunakan untuk regresi logistik dengan rentang 0 sampai 1 sedangkan fungsi Tanh memiliki rentang -1 sampai 1, kedua fungsi ini biasa digunakan untuk klasifikasi dua *class* atau kelompok data.

Sigmoid sebagai persamaan ke-4:

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

Tanh sebagai persamaan ke-5:


$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Keterangan:

e = Eksponen (*euler number*)

x = Input

2. Rectified Linear Unit (ReLU)




Gambar 2.4 ReLU Graph

Fungsi ReLU mencari nilai maksimum diantara dua *value* 0 dan X, dimana X memiliki batas positif tak hingga.

ReLU sebagai persamaan ke-6:

$$\begin{cases} 0 & \text{if } x \leq 0 \\ x & \text{if } x > 0 \end{cases} \\ = \max\{0, x\}$$

3. Leaky ReLU




Gambar 2.5 Leaky ReLU Graph

Fungsi Leaky ReLU memperbaiki fungsi ReLU dimana nilai *weight* negatif dihitung dengan *slope* $0.01 * X$.

LeakyReLU sebagai persamaan ke-7:

$$\begin{cases} 0.01x & \text{if } x \leq 0 \\ x & \text{if } x > 0 \end{cases}$$

4. Softmax



Gambar 2.6 Softmax Graph

Fungsi Softmax biasa digunakan pada output *layer* dari model *neural network* yang memprediksi distribusi probabilitas multinomial.

Softmax sebagai persamaan ke-8:


$$\frac{e^{x_i}}{\sum_{j=1}^J e^{x_j}} \text{ for } i = 1, \dots, J$$

2.4 Recurrent Neural Network (RNN)

RNN merupakan salah satu tipe dari *Multi-Layer Perceptron* (MLP) standar dengan *loop* tambahan, *network* pada RNN setidaknya berisi satu koneksi umpan balik, sehingga aktivasi dapat mengalir dalam satu lingkaran (*loop*), hal ini memungkinkan *network* untuk melakukan pemrosesan temporal

dan mempelajari urutan (*sequence*), misalnya permasalahan terkait pengenalan/reproduksi urutan, atau asosiasi/prediksi temporal.

RNN berkembang menjadi beberapa model populer dan banyak digunakan, salah satunya adalah *Long Short Term Memory* (LSTM):



Gambar 2.7 *Unfolded LSTM with CEC* (Sun, Su, Zhou, & Yu, 2017)

LSTM merupakan RNN yang memiliki kelebihan dalam menambahkan atau menghapus informasi pada *cell*. LSTM memiliki tiga *gate* yaitu *input gate* yang ditandai dengan **Gi** berfungsi memutuskan informasi relevan apa yang dapat ditambahkan pada *time step* saat ini, *forget gate* yang ditandai dengan **Gf** berfungsi untuk memutuskan informasi mana yang bisa diabaikan dan *output gate* yang ditandai **Go** berfungsi untuk finalisasi nilai *hidden state* berikutnya. LSTM memiliki kelebihan dalam akurasi pada dataset dengan *sequence* yang panjang. LSTM tanpa CEC sebagai persamaan ke-9 dapat dijabarkan sebagai berikut:

$$\begin{aligned}
i_t &= \sigma(W_{ii}x_t + b_{ii} + W_{hi}h_{t-1} + b_{hi}) \\
f_t &= \sigma(W_{if}x_t + b_{if} + W_{hf}h_{t-1} + b_{hf}) \\
g_t &= \tanh(W_{ig}x_t + b_{ig} + W_{hg}h_{t-1} + b_{gt}) \\
o_t &= \sigma(W_{io}x_t + b_{io} + W_{ho}h_{t-1} + b_{ho}) \\
c_t &= f_t \odot c_{t-1} + i_t \odot g_t \\
h_t &= o_t \odot \tanh(c_t)
\end{aligned}$$

Keterangan:

i_t, f_t, g_t, o_t = *input, forget, cell, dan output gate*

c_t, h_t = *cell dan hidden state*

t = *time step*

$W_{??}$ = *Weight i (input), dan h (hidden state) untuk masing-masing gate*

$B_{??}$ = *Bias untuk setiap operasi pada weight*


2.5 Batch Normalization (BN)

Batch Normalization (BN) merupakan teknik yang digunakan untuk standarisasi input pada *layer* untuk *mini-batch*. Proses ini mengakibatkan kestabilan dalam proses pelatihan dan mengurangi jumlah *epoch* yang dibutuhkan pada *Deep NN*.

BN digunakan untuk menyelesaikan permasalahan pada *Deep NN* dimana distribusi input setiap *layer* mengalami perubahan saat pelatihan karena parameter *layer* sebelumnya berubah, hal ini memperlambat pelatihan sehingga diperlukan penurunan *learning rate* dan inisialisasi parameter dengan cermat agar mempermudah pelatihan model yang memiliki *saturated nonlinearities* (Ioffe & Szegedy, 2015).

2.6 Dropout Regulation

Dropout merupakan teknik regulasi yang digunakan untuk mencegah *overfitting* ketika pembelajaran *neural network* dengan cara menonaktifkan *neuron* secara acak berdasarkan probabilitas yang ditentukan, hal ini mengakibatkan kontribusi pada *neuron* tersebut dihentikan serta *weight* baru tidak diterapkan pada saat *backpropagation* ketika model dalam pembelajaran, sedangkan ketika *testing* atau evaluasi regulasi *dropout* tidak diterapkan.



Gambar 2.8 *Dropout* (Srivastava, Hinton, Krizhevsky, Sutskever, & Salakhutdinov, 2014)

Poin **a** (kiri) pada gambar X.x merupakan contoh *neural net* standar dengan dua *hidden layer*, poin **b** (kanan) merupakan *neural net* setelah beberapa *neuron* dinonaktifkan.

2.7 Attention

Attention merupakan salah satu teknik yang meniru sistem kognitif manusia berupa “perhatian” (*Attention*), dimana sistem proses visual pada manusia berusaha untuk secara selektif fokus memilih beberapa bagian dari gambar dengan mengabaikan informasi tidak relevan lain yang dapat

membantu persepsi (Chaudhari, Polatkan, Ramanath, & Mithal, 2019). *Attention Model* (AM) pertama kali dikenalkan oleh Bahdanau (Bahdanau, Cho, & Bengio, 2015) pada *Encoder* dan *Decoder* untuk tugas *Neural Machine Translation* (NMT) dan memiliki beberapa variasi seiring berkembangnya *machine learning* seperti *attention*, *global attention*, *local attention* oleh Luong dan *self-attention* yang menjadi *state-of-the-art* untuk tugas penerjemahan bahasa dengan diterapkannya bersama model Transformer pada *paper Attention is All You Need* (Vaswani, et al., 2017).

Attention saat ini banyak digunakan bukan hanya untuk tugas NMT namun juga bidang lain seperti *image captioning* dan *image classification*.

2.8 Handwriting Recognition

Handwriting recognition atau pengenalan tulisan tangan merupakan teknik di mana sistem komputer dapat mengenali karakter dan simbol lain yang ditulis dengan tangan, dalam tulisan tangan alami didapat dari dokumen fisik tercetak, gambar, atau menggunakan tulisan tangan sebagai input langsung ke layar sentuh dan kemudian ditafsirkan sebagai teks (Priya, Mishra, Raj, Mandal, & Datta, 2016). Jenis tulisan tangan yang digunakan dibagi menjadi dua, yaitu:

1. *Offline*

Tulisan tangan ini memiliki ciri dalam bentuk wujud fisik, seperti manuskrip, buku tulis, dokumen fisik, maupun bentuk fisik lain yang dapat ditulis secara langsung tanpa peralatan digital. Secara umum bentuk ini

diubah kedalam bentuk digital dalam bentuk gambar menggunakan *scanner* atau kamera.

2. *Online*

Tulisan tangan *online* merupakan representasi digital dari gerakan pena yang menggambarkan informasi tentang posisi, kecepatan, percepatan dan sudut pena secara berurutan dalam dua koordinat.

Secara umum setelah tulisan tangan sudah dalam bentuk digital maka dilakukan *image preprocessing* dan segmentasi untuk digunakan sebagai input dataset atau input terhadap sistem pengenalan tulisan tangan.


2.9 *Bootstrap Confidence Interval*

Salah satu alat yang paling populer untuk pengujian statistik adalah perbandingan interval kepercayaan atau *confidence interval* (CI) dari metrik yang dipelajari seperti *word error rate*, *character error rate*, *accuracy*, dan lainnya. Terdapat beberapa cara untuk menghitung CI, tergantung dari asumsi yang dibuat tentang distribusi statistik, sayangnya asumsi tersebut tidak berlaku pada banyak skenario (Puigcerver, 2017), kekurangan ini membuat *non-parametrik bootstrap* perlu digunakan karena memiliki keuntungan dengan tidak membuat asumsi tentang distribusi. *Bootstrapping/Bootstrap* merupakan tes atau metrik apa pun yang menggunakan pengambilan sampel acak dengan penggantian serta menetapkan ukuran akurasi seperti CI ke estimasi sampel.

2.10 *Sundanese Palm Leaf Manuscript*

Sundanese palm leaf manuscript atau manuskrip lontar Sunda kuno merupakan salah satu warisan budaya yang memberikan kekayaan pengetahuan tentang masa lalu, masa kini, dan masa depan masyarakat Sunda. Ada berbagai nilai yang bermanfaat bagi generasi penerus, seperti sejarah dinasti Sunda, pertanian, pengobatan dan lainnya. Salah satu media yang digunakan untuk menulis tulisan tangan Sunda kuno adalah daun lontar yang disebut Lontar Sunda (Suryani, Paulus, Hadi, Darsa, & Burie, 2017). Manuskrip lontar Sunda kuno memiliki panjang sekitar 25-45 cm dan lebar sekitar 10-15 cm dengan lubang ditengahnya untuk tali. Tulisan pada manuskrip ditulis dengan *Peso Pangot* (pisau tulis) pada dua sisi daun.

Karakter yang tertulis terdiri dari huruf vokal (seperti a, i, u, e, o), karakter dasar (seperti ha, na, ca, ra, dll), nomor, tanda baca, diakritik (seperti panghulu, pangwisad, paneulung, panyuku, dll) dan karakter khusus.



Gambar 2.9 *Sample Sundanese Manuscript segmented to word*

2.11 Literature Review

Tabel 2.1 Literature Review

No	Peneliti / Tahun	Judul	Tujuan	Metode /Algoritma / Teknik	State-of-the-art / Keterbaruan
1	(Abhishek Bal, Rajib Saha, 2016)	<i>An Improved Method for Handwritten Document Analysis Using Segmentation, Baseline Recognition and Writing Pressure Detection</i>	Menganalisa kepribadian berdasarkan garis dan pola tulisan tangan pada dokumen (<i>document analysis</i>).	Metode: <i>Writing Pressure Detection, Baseline Recognition, Proposed Skew reorganization and normalization, Proposed Line and Word Segmentation.</i> Algoritma: <i>Rule-Base</i>	Terdapatnya metode baru untuk dokumen analisis dengan <i>text segmentation, skew recognition</i> dan <i>writing pressure detection</i> pada tulisan tangan dokumen.
2	(Joan Puigcerver, 2017)	<i>Are Multidimensional Recurrent Layers Really Necessary for Handwritten Text Recognition?</i>	Membuat alternatif dari model Multidimensional LSTM dengan bergantung hanya pada CNN dan satu dimensi RNN untuk pengenalan tulisan tangan.	Metode: <i>Data Augmentation</i> Model: <i>CNN, RNN, Dropout, Batch Normalization.</i>	Model dengan arsitektur (CRNN) yang diajukan berhasil menungguli <i>state-of-the-art</i> untuk <i>handwriting recognition</i> pada saat itu.

No	Peneliti / Tahun	Judul	Tujuan	Metode /Algoritma / Teknik	State-of-the-art / Keterbaruan
3	(Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Łukasz Kaiser, Illia Polosukhin, 2017)	<i>Attention is All You Need</i>	Membuat arsitektur yang hanya berdasarkan mekanisme mekanisme <i>attention</i> , menghilangkan perulangan dan konvolusi sepenuhnya.	Model: <i>Attention (Multi-Head), Position-wise Feed-Forward, Embeddings and Softmax, Positional Encoding.</i>	Metode baru yang dapat mengungguli <i>state-of-the-art</i> pada saat itu dalam hal akurasi dan waktu dalam pelatihan model.
4	(Nilanjana Bhattacharya, Umapada Pal, Partha Pratim Roy, 2017)	<i>Stroke-Order Normalization for Online Bangla Handwriting Recognition</i>	Melakukan normalisasi terhadap huruf Bangla <i>online</i> untuk pengenalan tulisan tangan.	Metode: <i>Slicing Algorithm, Level Combination Representation.</i> Model: <i>Hidden Markov Models</i>	Terdapat metode baru untuk normalisasi urutan garis pada skrip <i>Bangla</i> .
5	(Li Sun, Tonghua Su, Shengjie Zhou, Lijun Yu, 2017)	<i>GMU: A Novel RNN Neuron and its Application to Handwriting Recognition</i>	Menerapkan struktur <i>recurrent neuron</i> baru bernama <i>Gated Memory Unit (GMU)</i> dan penerapannya pada <i>handwriting recognition</i> .	Model: <i>Long Short-Term Memory (LSTM) Neuron, Gated Recurrent Unit (GRU) Neuron, Gated Memory Unit (GMU).</i>	Terdapat neuron RNN baru berupa GMU dan penerapannya serta perbandingannya dengan neuron RNN lain pada pengenalan tulisan tangan.

No	Peneliti / Tahun	Judul	Tujuan	Metode /Algoritma / Teknik	State-of-the-art / Keterbaruan
				Algoritma: AdaDelta	
6	(D Jayashree , M Geetha, Aadith P.Madapusi, Jayacharan Kolla, Jayasurya C, 2018)	<i>A Novel Hybrid Technique for Handwriting Recognition and Generation</i>	Penerapan gabungan RNN dan MDN sebagai pendekatan lain untuk melakukan <i>handwriting recognition</i> dan pembuatan data.	Model <i>Long Short-Term Memory</i> (LSTM), <i>Mixture Density Network</i> (MDN).	Menggunakan metode lain untuk mengenali tulisan dengan data tulisan yang lebih dinamis.
7	(Made Windu Antara Kesiman, Dona Valy, Jean-Christophe Burie, Erick Paulus, Mira Suryani, Setiawan Hadi, Michel Verleysen, Sophea Chhun dan Jean-Marc Ogier, 2018)	<i>Benchmarking of Document Image Analysis Tasks for Palm Leaf Manuscripts from Southeast Asia</i>	Tes komprehensif dalam analisis dokumen gambar manuskrip kuno asia tenggara meliputi binarisasi, segmentasi baris teks, pengenalan karakter atau <i>glyph</i> yang terisolasi, serta pengenalan kata dan transliterasi.	Metode Binarisasi: <i>Global thresholding, Local adaptive binarization</i> (Niblack's method), <i>Training based binarization</i> . Metode Segementasi: <i>Seam carving method, Adaptive path finding method</i> . Model/Metode pengenalan karakter	Meilibatkan banyak tugas serta terdapat perbandingan antar model atau metode yang dipakai pada masing-masing tugas.

No	Peneliti / Tahun	Judul	Tujuan	Metode /Algoritma / Teknik	State-of-the-art / Keterbaruan
				<p>atau <i>glyph</i> yang terisolasi: <i>Handcrafted feature extraction method, Unsupervised learning feature and Neural network, Convolutional Neural Network.</i></p> <p>Model pengenalan kata dan transliterasi: <i>Bidirectional LSTM</i></p>	
8	(Md. Fahim Sikder, 2019)	<i>Bangla Handwritten Digit Recognition and Generation</i>	Meningkatkan akurasi pengenalan tulisan tangan Bangla dengan arsitektur (CNN) yang diajukan, serta implementasi SGAN untuk digit generation.	Model: <i>Convolutional Neural Network (proposed research architecture), SGAN.</i>	Model arsitektur yang dibuat berdasarkan convolutional layer dalam pengenalan dan SGAN dalam generasi digit mampu membuat kenaikan tingkat akurasi pada pengenalan karakter tulisan Bangla.
9	(Anc Duc Le, Hung Tuan Nguyen, Masaki	<i>An End-to-End Recognition System for Unconstrained</i>	Meningkatkan akurasi pengenalan tulisan tangan <i>offline</i>	Model: <i>Attention, BI-LSTM, LSTM, DenseNet.</i>	Terdapat kombinasi model baru yang menggunakan AED

No	Peneliti / Tahun	Judul	Tujuan	Metode /Algoritma / Teknik	State-of-the-art / Keterbaruan
	Nakagawa, 2020)	<i>Vietnamese Handwriting</i>	<i>unconstrained</i> Vietnam dengan arsitektur berbasis AED yang diajukan.	Algoritma: <i>Normalized Edit Distance</i> (NED)	
10	(Ahmad Fathan Hidayatullah, Siwi Cahyaningtyas, Rheza Daffa Pamungkas, 2020)	<i>Attention-based CNN-BiLSTM for dialect identification on Javanese text</i>	Identifikasi dialek pada teks <i>online</i> bahasa Jawa.	Model: CNN, BI-LSTM, BI-GRU, <i>Word level Attention, Sentence level Attention.</i>	Penerapan dua level <i>attention</i> pada identifikasi dialek bahasa Jawa.
11	(Yang Li , Huahu Xu, Minjie Bian, Junsheng Xiao, 2020)	<i>Attention Based CNN-ConvLSTM for Pedestrian Attribute Recognition</i>	Pengenalan atribut pejalan kaki pada dataset PETA dan RAP.	Model: <i>Multi-label CNN, Channel Attention</i> (CAtt), <i>Convolutional LSTM</i> (ConvLSTM).	Terdapat metode baru untuk studi pengenalan atribut pejalan kaki.
12	(Abhishikth Ayyadevara. Sai, Teja. P N V Sai Ram, P. Bharath K, M. Rajesh, 2020)	<i>Handwritten Character Recognition Using Unique Feature Extraction Technique</i>	Mencoba menggabungkan tiga metode <i>feature extraction</i> (<i>Geometric, Zone-based hybrid, Gradient</i>) kemudian diterapkan pada beberapa <i>neural</i>	Metode: <i>Proposed Feature Extraction</i> (<i>Geometric, Zone-based hybrid, Gradient</i>). Model: <i>Multilayer Perceptron</i>	Terdapat metode ekstraksi fitur baru yang dapat diterapkan pada <i>neural network</i> lain.

No	Peneliti / Tahun	Judul	Tujuan	Metode /Algoritma / Teknik	State-of-the-art / Keterbaruan
			<i>network</i> untuk pengenalan karakter tulisan tangan.	<i>Network, Perceptron Network using Levenberg-Marquardt, CNN.</i>	
13	(Sourabh Sagar, Sunanda Dixit, B. V. Mahesh, 2020)	<i>Offline Cursive Handwritten Word Using Hidden Markov Model Technique</i>	Menggunakan HMM sebagai <i>segmentation model</i> serta SVM untuk pengenalan tulisan tangan <i>offline</i> .	Model: HMM, <i>Potential Segmentation Columns</i> (PSC), SVM.	Terdapatnya metode segmentasi baru dalam tulisan tangan <i>cursive</i> .
14	(Yutzil Poma, Patricia Melin, Claudia I. González and Gabriela E. Martinez, 2020)	<i>Optimal Recognition Model Based on Convolutional Neural Networks and Fuzzy Gravitational Search Algorithm Method</i>	Optimisasi CNN dengan metode FGSA sebagai model pengenalan tulisan tangan.	Model: CNN Algoritma: <i>Fuzzy Gravitational Search</i>	Terdapat algoritma lain yang dapat digunakan untuk optimasi CNN, serta dapat digunakan selain tugas pengenalan tulisan tangan.
15	(Jason Poulos, Rafael Valle, 2021)	<i>Character-Based Handwritten Text Transcription with Attention Networks</i>	Transkripsi teks tulisan tangan berbasis karakter.	Model: CNN, BI-LSTM, GRU, <i>Attention</i> .	Menggunakan kombinasi <i>layer</i> lain yang dapat unggul terhadap model lain tanpa menggunakan <i>language model</i> .

2.12 Penelitian Terdekat

Tabel 2.2 Penelitian berdasarkan studi kasus terdekat

No	Peneliti / Tahun	Judul	Tujuan	Metode /Algoritma / Teknik	State-of-the-art / Keterbaruan
1	(Made Windu Antara Kesiman, Dona Valy, Jean-Christophe Burie, Erick Paulus, Mira Suryani, Setiawan Hadi, Michel Verleysen, Sophea Chhun dan Jean-Marc Ogier, 2018)	<i>Benchmarking of Document Image Analysis Tasks for Palm Leaf Manuscripts from Southeast Asia</i>	Tes komprehensif dalam analisis dokumen gambar manuskrip kuno asia tenggara meliputi binarisasi, segmentasi baris teks, pengenalan karakter atau <i>glyph</i> yang terisolasi, serta pengenalan kata dan transliterasi.	Metode Binarisasi: <i>Global thresholding, Local adaptive binarization (Niblack's method), Training based binarization.</i> Metode Segementasi: <i>Seam carving method, Adaptive path finding method.</i> Model/Metode pengenalan karakter atau <i>glyph</i> yang terisolasi: <i>Handcrafted feature extraction method, Unsupervised learning</i>	Meilibatkan banyak tugas serta terdapat perbandingan antar model atau metode yang dipakai pada masing-masing tugas.

No	Peneliti / Tahun	Judul	Tujuan	Metode /Algoritma / Teknik	State-of-the-art / Keterbaruan
				<i>feature and Neural network, Convolutional Neural Network.</i> Model pengenalan kata dan transliterasi: <i>Bidirectional LSTM</i>	

Tabel 2.2 merupakan penelitian terdekat yang menjadi acuan terkait WER dalam studi kasus manuskrip lontar Sunda kuno dengan metode CRNN + *Attention*. Penelitian yang dilakukan (Kesiman, et al., 2018) terutama pada tugas pengenalan kata dan transliterasi menggunakan model BI-LSTM serta data sintesis tambahan untuk melatih model dalam pengenalan kata. Berdasarkan penelitian yang telah disebutkan maka diusulkan penelitian yang berjudul “*Convolutional Recurrent Neural Network dengan Attention untuk Pengenalan Tulisan Tangan Manuskrip Daun Lontar Sunda Kuno*” dengan tujuan untuk mengurangi WER pada pengenalan kata dalam studi kasus tersebut.

2.13 Matriks Penelitian

Tabel 2.3 Matriks penelitian

No	Peneliti / Tahun	Judul	Ruang Lingkup Penelitian						
			Model/Metode	Extra Data	Dataset Offline	Dataset Online	Tulisan Tangan	Attention	Word Level
1	(Abhishek Bal, Rajib Saha, 2016)	<i>An Improved Method for Handwritten Document Analysis Using Segmentation, Baseline Recognition and Writing Pressure Detection</i>	✓		✓		✓		
2	(Joan Puigcerver, 2017)	<i>Are Multidimensional Recurrent Layers Really Necessary for Handwritten Text Recognition?</i>	✓		✓		✓		✓
3	(Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Łukasz Kaiser, Illia Polosukhin, 2017)	<i>Attention is All You Need</i>	✓					✓	✓
4	(Nilanjana Bhattacharya, Umapada Pal, Partha Pratim Roy, 2017)	<i>Stroke-Order Normalization for Online Bangla Handwriting Recognition</i>	✓			✓	✓		✓

No	Peneliti / Tahun	Judul	Ruang Lingkup Penelitian						
			Model/Metode	Extra Data	Dataset Offline	Dataset Online	Tulisan Tangan	Attention	Word Level
5	(Li Sun, Tonghua Su, Shengjie Zhou, Lijun Yu, 2017)	<i>GMU: A Novel RNN Neuron and its Application to Handwriting Recognition</i>	✓			✓	✓		
6	(D Jayashree , M Geetha, Aadith P.Madapusi, Jayacharan Kolla, Jayasurya C, 2018)	<i>A Novel Hybrid Technique for Handwriting Recognition and Generation</i>	✓			✓	✓		
7	(Made Windu Antara Kesiman, Dona Valy, Jean-Christophe Burie, Erick Paulus, Mira Suryani, Setiawan Hadi, Michel Verleysen, Sophea Chhun dan Jean-Marc Ogier, 2018)	<i>Benchmarking of Document Image Analysis Tasks for Palm Leaf Manuscripts from Southeast Asia</i>	✓	✓	✓		✓		✓
8	(Md. Fahim Sikder, 2019)	<i>Bangla Handwritten Digit Recognition and Generation</i>	✓	✓	✓		✓		

No	Peneliti / Tahun	Judul	Ruang Lingkup Penelitian					Word Level	
			Model/Metode	Extra Data	Dataset Offline	Dataset Online	Tulisan Tangan		Attention
9	(Anc Duc Le, Hung Tuan Nguyen, Masaki Nakagawa, 2020)	<i>An End-to-End Recognition System for Unconstrained Vietnamese Handwriting</i>	✓			✓	✓		✓
10	(Ahmad Fathan Hidayatullah, Siwi Cahyaningtyas, Rheza Daffa Pamungkas, 2020)	<i>Attention-based CNN-BiLSTM for dialect identification on Javanese text</i>	✓			✓		✓	
11	(Yang Li , Huahu Xu, Minjie Bian, Junsheng Xiao, 2020)	<i>Attention Based CNN-ConvLSTM for Pedestrian Attribute Recognition</i>	✓		✓			✓	
12	(Abhishikth Ayyadevara. Sai, Teja. P N V Sai Ram, P. Bharath K, M. Rajesh, 2020)	<i>Handwritten Character Recognition Using Unique Feature Extraction Technique</i>	✓			✓	✓		
13	(Sourabh Sagar, Sunanda Dixit, B. V. Mahesh, 2020)	<i>Offline Cursive Handwritten Word Using Hidden Markov Model Technique</i>	✓		✓		✓		✓
14	(Yutzil Poma, Patricia Melin, Claudia I. González and Gabriela E. Martinez, 2020)	<i>Optimal Recognition Model Based on Convolutional Neural Networks and Fuzzy Gravitational Search Algorithm Method</i>	✓		✓		✓		

No	Peneliti / Tahun	Judul	Ruang Lingkup Penelitian						
			Model/Metode	<i>Extra Data</i>	<i>Dataset Offline</i>	<i>Dataset Online</i>	Tulisan Tangan	<i>Attention</i>	<i>Word Level</i>
15	(Jason Poulos, Rafael Valle, 2021)	<i>Character-Based Handwritten Text Transcription with Attention Networks</i>	✓		✓		✓	✓	
16	(Adi Sulaiman, 2021)	<i>Convolutional Recurrent Neural Network dengan Attention untuk Pengenalan Tulisan Tangan Manuskrip Daun Lontar Sunda Kuno</i>	✓		✓		✓	✓	✓