BAB III

METODE PENELITIAN

3.1 Desain Penelitian

Penelitian ini dilakukan dengan pendekatan *Design Research Methodology* (DRM) untuk menguji efektivitas arsitektur CRNN-CTC dalam rekognisi aksara Sunda kuno. Menurut Ebneyamini (2022) sangat berguna dan praktis sebagai metode desain penelitian dalam menentukan tujuan penelitian dan pemecahan solusinya. Blessing & Chakrabarti, (2009) menjabarkan DRM sebagai sebuah kerangka metodologi yang digunakan sebagai prosedur penelitian yang terarah dan efisien. DRM mencakup beberapa tahap prosedur seperti klarifikasi penelitian studi deskriptif I, studi preskriptif dan studi deskriptif II. Melalui pendekatan ini, diharapkan penelitian dapat memberikan data empiris mengenai efektivitas metode CRNN-CTC dalam pengenalan tulisan tangan aksara Sunda kuno. Adapun kerangka desain penelitian pada penelitian ini digambarkan pada Gambar 3.1.

Gambar 3.1 Diagram desain penelitian

3.1.1 Klarifikasi Penelitian

Pada tahapan ini penulis melakukan kajian literatur untuk menetapkan arah dan tujuan penelitian berdasarkan penelitian terdahulu berupa jurnal maupun artikel untuk mencari letak permasalahan atau kekurangan pada penelitian tersebut. Ruang lingkup kajian penelitian diantaranya seperti aksara Sunda rekognisi tulisan tangan, pembelajaran mesin, arsitektur CNN, RNN dan CTC

yang dilakukan pada penelitian terdahulu dengan studi kasus serupa. Kajian literatur mengenai teori-teori yang akan diterapkan pada penelitian ini juga dilakukan untuk mendapat hasil akurasi terbaik. Kajian yang menjadi acuan dari penelitian ini diantaranya teknik pra-pemrosesan dataset seperti data augmentasi, metrik evaluasi seperti CER dan WER sebagai tolak ukur efektivitas model dalam mengenal kata aksara Sunda kuno. Parameter untuk *tuning* menjadi kajian untuk optimasi model demi mendapat angka error serendah mungkin.

3.1.2 Studi Deskriptif I

Pada tahapan ini dilakukan penetapan rumusan masalah dan tujuan dari penelitian berdasarkan temuan celah dan kekurangan penelitian terdahulu. Fokus dari penelitian ini adalah evaluasi hasil akurasi dari arsitektur CRNN-CTC dalam konteks pengenalan kata dengan studi kasus aksara Sunda kuno media daun lontar berdasarkan metrik evaluasi yang relevan pada bidang penelitian ini.

3.1.3 Studi Preskriptif

Pada tahap ini dimulai dari pengumpulan dataset yang diperlukan, *pre-processing* dataset dan terakhir tahap pembuatan model. Detail dari tahapan ini dijelaskan sebagai berikut:

1. Persiapan Dataset

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari lembaga ICFHR 2018 dalam acaranya *Competition On Document Image Analysis Tasks for Southeast Asian Palm Leaf Manuscripts* pada bagian *Challenge D* yang bisa diakses publik. Dataset tersebut juga hasil dari penelitian (Suryani, dkk., 2017). Dataset aksara Sunda kuno yang berasal dari naskah daun lontar dari abad ke-15 tersebut dibagi menjadi dua set yaitu set pelatihan sebanyak 1426 gambar dan set uji sebanyak 317 gambar gambar serta pelabelan atau *ground truth*. Untuk hasil yang optimal dalam evaluasi pelatihan, pada penelitian ini set

training akan dibagi kembali persinya untuk kebutuhan set validasi dengan rasio 80:20 (Suhandi, Gustriansyah, Destria, Amalia, Kris, 2024).

2. *Pre-processing*

Teknik *preprocessing* pada dataset dilakukan dengan teknik *resize* dan *padding* untuk memastikan data inputan seragam dan sesuai bentuk input awal model. Teknik augmentasi data dilakukan dengan *grayscaleing*, *denoising*, *contrast enhancing*, *polarization* dan *Wolf's binarization* (Wolf, Jollion & Chassaing, 2002) yang dipilih sebagaimana diungkapkan oleh Mirza, Shiddiqi & Hussain, (2019) sebagai metode binarisasi paling unggul dibanding metode binarisasi lainnya.

3. *Modelling*

Model arsitektur yang digunakan pada penelitian ini adalah gabungan dari CNN dan RNN yaitu CRNN dengan *decoding* CTC sebagaimana model ini telah terbukti efektif menangani data *sequence* dan sifat dataset yang kompleks dengan konfigurasi dari penelitian sebelumnya sebagai referensi serta beberapa penyesuaian yang diterapkan pada studi kasus ini. CNN berperan dalam ekstraksi fitur gambar, RNN digunakan untuk menangani urutan konteks karakter dari output CNN dan CTC sebagai pelabelan akhir keluaran model berupa prediksi tiap karakter. Model ini terdiri dari beberapa lapisan konvolusi digunakan untuk mengekstraksi fitur visual dari gambar aksara. Lapisan ini terdiri dari tiga blok yang masing-masing melibatkan operasi konvolusi, *batch normalization* (Paulus, Hadi, Suryani, Suryana, Simanjuntak, 2018), *ReLU activation*, dan *max pooling* (Liu, dkk., 2023). *Dropout* diterapkan pada dua lapisan untuk mencegah *overfitting*. Pada bagian RNN, model menggunakan dua lapisan *Bidirectional LSTM (Long Short-Term Memory)*, untuk menangkap hubungan *temporal* antar fitur dalam urutan data (Zou, dkk., 2023). Lapisan LSTM ini memastikan bahwa konteks dari kedua arah (maju dan mundur) dapat diperhitungkan, meningkatkan kemampuan model untuk memahami hubungan antar karakter dalam tulisan tangan. Pada penelitian ini juga dibuat *character mapping* sebanyak 28 karakter berdasarkan

karakter yang mungkin muncul pada dataset berupa huruf latin kecil, tanda hubung (-) dan spasi. *Character mapping* ini nantinya akan digunakan untuk fungsi *decode* pada CTC.

3.1.3.1 *Hyperparameter Tuning* pada Model

Penyesuaian konfigurasi model dilakukan berdasarkan temuan untuk mendapat kinerja terbaik. *Hyperparameter tuning* dilakukan setelah model terbaik didapat untuk mendapat angka metrik paling optimal. Parameter *label_smoothing* dipilih menjadi parameter *tunable* karena terbukti efektif dalam meningkatkan hasil akurasi *training* data pada penelitian yang relevan (Yu, dkk., 2023). *Label smoothing* adalah metode untuk mencegah *overfitting* dan sekaligus meningkatkan generalisasi dengan menambahkan label *noise* pada fungsi CTC sehingga mengurangi bias pada label tertentu (*overconfidence*) (Yu, dkk., 2023). Pengujian dilakukan dengan pelatihan model di beberapa skenario dimana setiap skenario pelatihan angka dari parameter *label_smoothing* akan diturunkan bertahap dimulai dari angka *default* = 0,1 lalu kedua dengan 0,05 ketiga 0,001 dan terakhir pada 0,005. Untuk parameter lain akan dibiarkan dengan nilai yang sama dengan acuan pada penelitian yang relevan dengan nilai terbaik.

3.1.4 Studi Deskriptif II

Tahapan ini merupakan proses pengujian dan evaluasi terhadap model yang sudah dibuat sebelumnya. Pengujian dilakukan dengan beberapa metrik evaluasi sebagai penilaian kinerja model dalam pengenalan kata aksara Sunda kuno. Metrik CER dan WER digunakan untuk penilaian sebagaimana metrik tersebut relevan dalam konteks penelitian ini (Drobac & Lindén, 2020; Neudecker, dkk., 2021; Agarwal & Anastasopoulos, 2024) serta metrik akurasi (Faizullah, dkk., 2024). Beberapa metrik uji yang diukur diantaranya:

1. *Character Error Rate* (CER)

Character Error Rate (CER) adalah metrik turunan dari *Levenshtein distance* yang mengukur persentase kesalahan rekognisi pada tingkat karakter. Nilai CER diperoleh dengan membagi jumlah karakter yang mengalami perubahan

(penyisipan, penghapusan, atau substitusi) dengan jumlah total karakter pada *ground truth*. Detail perhitungannya dapat dilihat pada Persamaan (1).

2. *Word Error Rate* (WER)

Sama seperti perhitungan CER, *Word Error Rate* (WER) juga merupakan turunan dari *Levenshtein distance* dengan rumus yang sama hanya saja pada tingkat kata. Persamaan WER dengan detail dapat dilihat pada persamaan (2).

3. *Accuracy*

Accuracy dihitung untuk menilai kinerja model dalam pengenalan karakter dan kata secara benar pada keseluruhan data uji. Pada penelitian ini perhitungan jumlah karakter dan kata yang benar diperoleh dari jumlah total karakter dikurang CER dikali total karakter. Begitu pula untuk perhitungan tingkat kata. Persamaan perhitungan untuk mendapat jumlah karakter benar dari CER yang diketahui dijabarkan sebagai berikut:

$$\text{Correct Char} = \text{Total chars} - (\text{CER} * \text{Total chars}) \quad (4)$$

Persamaan untuk mendapat total kata yang benar dari WER yang diketahui sebagai berikut:

$$\text{Correct Words} = \text{Total words} - (\text{WER} * \text{Total words}) \quad (5)$$

Setelah mendapat jumlah karakter dan kata yang benar, maka perhitungan akurasi bisa dilakukan. Perhitungan detail untuk akurasi dijabarkan pada Persamaan (3).

3.2 Alat dan Bahan Penelitian

Penelitian ini menggunakan *Google Colab* sebagai alat komputasinya dan bahasa pemrograman *Python* untuk mengembangkan model CRNN-CTC. Adapun spesifikasi dari komputasi tersebut ditunjukkan pada Tabel 3.1. *Library* yang digunakan dalam proses pengembangan model ditunjukkan pada Tabel 3.2.

Tabel 3.1
Spesifikasi Google Colab

<i>System RAM</i>	12 GB
<i>GPU RAM</i>	15 GB
<i>Storage</i>	112 GB

Tabel 3.2
Library yang digunakan

<i>Library</i>	Deskripsi
<i>Os</i>	<i>Library</i> bawaan <i>Python</i> untuk menangani operasi <i>file</i> dan direktori, seperti membaca, menulis, dan memanipulasi <i>file</i> sistem.
<i>OpenCV</i>	<i>Library</i> untuk pengolahan gambar dan video, digunakan untuk membaca, memproses, dan memodifikasi dataset gambar aksara Sunda.
<i>Random</i>	<i>Library</i> bawaan <i>Python</i> yang digunakan untuk menghasilkan bilangan acak, berguna dalam pembagian dataset atau augmentasi data.
<i>Numpy</i>	<i>Library</i> fundamental untuk komputasi numerik, digunakan untuk operasi matriks dan <i>array</i> dalam pengolahan data gambar.
<i>Pandas</i>	<i>Library</i> untuk analisis dan manipulasi data dalam bentuk tabel (<i>DataFrame</i>), digunakan untuk

<i>Library</i>	Deskripsi
	mengorganisasi dataset dan label.
<i>Matplotlib</i>	<i>Library</i> visualisasi data, digunakan untuk membuat grafik atau menampilkan citra selama proses eksplorasi data.
<i>Zipfile</i>	<i>Library</i> bawaan <i>Python</i> untuk mengkompres atau mendekompres file dalam format ZIP.
<i>Tensorflow</i>	<i>Framework machine learning</i> yang digunakan sebagai <i>backend</i> utama dalam membangun dan melatih model CRNN-CTC.
<i>Keras</i>	<i>Library deep learning</i> yang bekerja di atas <i>TensorFlow</i> , menyediakan API sederhana untuk mendefinisikan dan melatih arsitektur model.