

Pengenalan Alfabet SIBI Menggunakan Convolutional Neural Network sebagai Media Pembelajaran Bagi Masyarakat Umum

Zahrah Fadhilah^{*}, Noveri Lysbetti Marpaung²

¹Jurusan Teknik Informatika, Fakultas Teknik, Universitas Riau, Pekanbaru

²Jurusan Teknik Informatika, Fakultas Teknik, Universitas Riau, Pekanbaru

^{1,2}Kampus Bina Widya, Kota Pekanbaru, 28293, Indonesia

email: ¹zahrahfadhilah.zf@gmail.com, ²noveri.marpaung@eng.unri.ac.id

Abstract – SIBI is one of the Sign Languages used in Indonesia and has been widely used in the community, especially the school (SLB). Communication limitations of the deaf and speech community cause limited communication with the general public, especially many general public who do not know Sign Language or SIBI. For this reason, this research was conducted in order to become a learning media for the general public in recognizing the SIBI alphabet so that it can support communication with the deaf and speech community. This research was conducted to become a medium that can be used as a learning medium in the introduction of the SIBI alphabet. The method used in this research is CNN. CNN is used because it is a deep learning method that has the most significant results in image recognition. The data used is 2,600 images which are divided into 80% training data and 20% validation data. Training was done ten times by comparing the parameters that produce the best accuracy. The parameters used are batch size and epoch. From ten trials, the best accuracy is obtained using batch size 8 and epoch 50. The best accuracy produced is 85% training accuracy and 87% validation accuracy.

Keywords: Sign Language, SIBI, CNN

Abstrak – SIBI merupakan salah satu Bahasa Isyarat yang digunakan di Indonesia dan telah dipergunakan secara luas di lingkungan masyarakat terutama lingkungan sekolah (SLB). Keterbatasan komunikasi dari komunitas tunarungu dan tunawicara menyebabkan terbatasnya komunikasi dengan masyarakat umum, terlebih banyak masyarakat umum yang belum mengenal Bahasa Isyarat ataupun SIBI. Untuk itu, dilakukan penelitian ini agar bisa menjadi media pembelajaran bagi masyarakat umum dalam mengenal alfabet SIBI sehingga dapat menunjang komunikasi dengan komunitas tunarungu dan tunawicara. Penelitian ini dilakukan untuk menjadi media yang dapat digunakan sebagai media pembelajaran dalam pengenalan alfabet SIBI. Metode yang digunakan dalam penelitian ini adalah CNN. CNN digunakan karena merupakan metode *Deep Learning* yang memiliki hasil paling signifikan dalam pengenalan citra. Data yang digunakan sebanyak 2.600 citra yang dibagi menjadi 80% untuk data training dan 20% untuk data validasi. Pelatihan dilakukan sebanyak sepuluh kali percobaan dengan membandingkan parameter yang menghasilkan akurasi terbaik. Parameter yang digunakan adalah batch size dan epoch. Dari sepuluh kali percobaan, didapat akurasi terbaik yang menggunakan 8 batch size dan 50

epoch. Akurasi terbaik yang dihasilkan sebesar 85% untuk training accuracy dan 87% untuk validasi accuracy.

Kata Kunci – Bahasa Isyarat, SIBI, CNN.

I. PENDAHULUAN

Bahasa Isyarat adalah bahasa yang menggunakan gesture (gerakan tangan) dan dilihat secara visual yang digunakan sebagai salah satu alternatif yang digunakan oleh komunitas penyandang disabilitas terutama tunarungu dan tunawicara untuk berkomunikasi dan berinteraksi. Kata-kata yang tidak memiliki isyarat dalam bahasa isyarat, dapat dipresentasikan menggunakan bahasa Isyarat Alfabet. Bahasa Isyarat Alfabet adalah sarana dasar yang digunakan oleh para pengajar penyandang disabilitas untuk mengenal huruf alfabet [1].

Di Indonesia, Bahasa Isyarat yang digunakan oleh kalangan tunarungu dikategorikan menjadi dua jenis, yaitu Bahasa Isyarat Indonesia (BISINDO) dan Sistem Isyarat Bahasa Indonesia (SIBI). BISINDO merupakan bahasa isyarat yang secara alamiah lahir dengan mengadopsi nilai budaya asli Indonesia dan lebih mudah dipergunakan di kehidupan sehari-hari oleh kalangan tunarungu [2]. SIBI merupakan bahasa isyarat yang mengacu pada American Sign Language (ASL) dan telah digunakan secara luas [3]. SIBI merupakan bahasa isyarat yang diadaptasi dari bahasa lisan, yang sudah ditetapkan oleh pemerintah melalui Keputusan Mendikbud RI Nomor 0161/U/1994 dan telah dipergunakan di SLB yang ada di Indonesia [4].

Sulitnya komunikasi antara para penyandang tunarungu dan tunawicara terhadap masyarakat umum menyebabkan terbatasnya interaksi sosial antara penyandang disabilitas tersebut dan masyarakat umum [5]. Terutama bagi masyarakat yang belum pernah mengenal dan mempelajari SIBI ataupun Bahasa Isyarat sulit membedakan alfabet pada SIBI, sehingga komunikasi menjadi semakin sulit dilakukan.

Pada beberapa tahun terakhir, *Deep Learning* populer dan banyak digunakan dalam mengidentifikasi objek. *Deep Learning* merupakan cabang dari *Machine Learning* yang memiliki *performance* yang sangat baik. *Deep Learning* digunakan karena lebih baik dalam mengolah dan menangani *big data* dibanding dengan *traditional machine learning* [6]. Kelas algoritma *Deep Learning* yang paling umum digunakan untuk analisis pengenalan pola spasial adalah *Convolutional Neural Networks* (CNNs atau ConvNets) [7].

^{*}) penulis korespondensi: Noveri Lybesti Marpaung
Email: noveri.marpaung@eng.unri.ac.id

Convolutional Neural Network (CNN) merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang dirancang untuk mengolah data 2D. Performanya yang bagus dalam banyak tipe data terutama dalam menganalisis data gambar dalam jumlah yang besar, membuat CNN menjadi sangat populer saat ini [8]. CNN memiliki keuntungan yang dapat mengklasifikasikan data gambar dan mencapai hasil yang paling signifikan dalam pengenalan objek [9].

Dengan menggunakan CNN yang merupakan metode dari *Deep Learning*, dapat diterapkan untuk mengenali dan membedakan alfabet SIBI pada citra, sehingga memungkinkan masyarakat umum untuk secara praktis dan cepat belajar mengenali alfabet SIBI tanpa memerlukan instruktur ataupun manusia secara langsung. Hal ini dapat meningkatkan aksesibilitas pembelajaran dan memberikan kesempatan bagi lebih banyak orang untuk mempelajari dan menggunakan SIBI dalam komunikasi sehari-hari. Dengan adanya media pembelajaran yang menggunakan CNN, masyarakat umum dapat berlatih dan meningkatkan keterampilan pengenalan alfabet SIBI secara mandiri dan fleksibel.

Berdasarkan Latar Belakang yang telah diuraikan, penelitian ini akan menggunakan metode *Convolutional Neural Network* (CNN) dan mengangkat judul Pengenalan Alfabet SIBI menggunakan *Convolutional Neural Network* sebagai Media Pembelajaran bagi Masyarakat Umum. Metode CNN digunakan pada penelitian ini, dikarenakan CNN memiliki kemampuan ekstraksi fitur gambar yang sangat baik dan dapat dilakukan secara otomatis sehingga menghemat waktu dan tenaga [10]. Penelitian ini diharapkan membantu mengidentifikasi huruf alfabet Bahasa Isyarat khususnya SIBI.

II. PENELITIAN YANG TERKAIT

Penelitian Terkait merupakan pedoman dari penelitian yang telah dilakukan sebelumnya yang dijadikan sebagai acuan dalam penelitian ini. Berikut beberapa penelitian yang terkait dengan topik yang digunakan.

Penelitian yang dilakukan oleh Mutiara Sholawati, Karina Auliasari, dan FX. Ariwibisono pada tahun 2022 dengan judul Pengembangan Aplikasi Pengenalan Bahasa Isyarat SIBI Menggunakan Metode *Convolutional Neural Network* (CNN) menggunakan Metode CNN untuk melakukan pengenalan abjad bahasa isyarat SIBI dan berhasil mengenali kelas abjad. *Dataset* yang digunakan pada penelitian ini berjumlah 416 citra yang ditraining dengan 50 epoch, 32 batch size, menggunakan *loss function categorical cross entropy*, *Optimizer Adam* dan *Optimizer metrics Accuracy*. Arsitektur pada penelitian ini menggunakan beberapa layer antara lain dua *convolution layer*, dua *MaxPooling layer*, dan *fully connected layer*, sehingga dihasilkan model yang memiliki *training accuracy* 90.05%. Hasil perhitungan evaluasi didapatkan akurasi sebesar 80.76%.

Pada tahun yang sama, penelitian berjudul Klasifikasi Citra Sistem Isyarat Bahasa Indonesia (SIBI) dengan Metode *Convolutional Neural Network* pada Perangkat Lunak berbasis *Android* yang dilakukan oleh Sherryl Sugiono Sindarto, Dian Eka Ratnawati, dan Issa Arwani tahun 2022 menggunakan *Convolutional Neural Network* (CNN) dengan *transfer learning* sebagai metode untuk mengklasifikasikan citra. Data yang digunakan dalam penelitian tersebut

berjumlah 300 citra SIBI yang terdiri dari 15 kelas dan terdapat 20 citra pada setiap kelasnya. Citra SIBI yang digunakan adalah alfabet, kata ganti orang, kata benda, kata ekspresi dan kata kerja. Penelitian ini menggunakan *EfficientDet-Lite4* sebagai arsitektur model yang digunakan untuk *transfer learning*. Arsitektur dari model tersebut terdapat tiga jaringan yang terdiri dari jaringan *backbone*, jaringan *Bi-directional Feature Pyramid Network* (BiFPN), serta jaringan prediksi kelas dan kotak. *Dataset* yang digunakan dibagi menjadi 85% data *training* dan 15% data *testing* yang ditraining dengan 100 epoch, dan delapan *batch size*. *Training* menghasilkan *loss* sebesar 43% (0.43) dan *val_loss* sebesar 60% (0.60). Akurasi rata-rata yang didapat untuk klasifikasi 15 kelas SIBI adalah 0,88 (88%).

Penelitian berjudul Pengenalan Angka Sistem Isyarat Bahasa Indonesia Dengan Menggunakan Metode *Convolutional Neural Network* pada tahun 2019 yang dilakukan oleh Mochamad Bagus Setiyo Bakti dan Yuliana Melita Pranoto menggunakan *LeNet* sebagai struktur CNN. Data yang digunakan adalah citra angka SIBI sebanyak 450 citra yang dikategorikan menjadi 10 kelas yaitu angka nol sampai sembilan. Data dibagi menjadi dua bagian, 80% data *training* dan 20% data *testing*. *Training* dilakukan sebanyak tiga kali percobaan yaitu, menggunakan 25 *epoch*, 50 *epoch*, dan 100 *epoch*. Percobaan pertama *training* dilakukan menggunakan 25 *epoch* mendapat akurasi sebesar 67.66% dengan *loss* sebesar 0.95%. Percobaan dilakukan prediksi terhadap 20% data *testing* dan mendapat akurasi sebesar 79.23%. Percobaan kedua, data ditraining dengan menggunakan 50 *epoch* dan mendapatkan akurasi sebesar 89.44% dan *loss* 0.37%. Kemudian dilakukan prediksi pada data *testing* dan mendapat akurasi sebesar 90.44%. Percobaan ketiga dilakukan *training* data menggunakan 100 *epoch* dan mendapat akurasi 96.44% dan *loss* 0.13%. Kemudian dilakukan prediksi menggunakan data *testing* dan mendapat akurasi sebesar 98.89%.

Penelitian yang dilakukan oleh Olivia Kembuan, Gladly Caren Rorimpandey, dan Soenandar Milian Tomponu Tengker pada tahun 2020 yang berjudul *Convolutional Neural Network (CNN) for Image Classification of Indonesia Sign Language Using Tensorflow* menggunakan dataset BISINDO yang terdiri dari 2659 citra dan dikategorikan menjadi 26 kelas. Data dibagi menjadi 2113 gambar data *training* (80%) dan 546 gambar data validasi (20%). Gambar untuk setiap kelas alfabet terdapat 102 hingga 104 gambar dalam *standard RGB images* dan menggunakan kertas putih yang ditempatkan dibelakang tangan sebagai *background*. Metode yang digunakan pada penelitian ini adalah CNN serta *TensorFlow* sebagai *programming library*. Struktur model CNN yang digunakan dalam penelitian ini terdiri dari empat *convolution layer*, empat *maxpooling layer*, dan *fully connected layer*. Data dilatih sebanyak 100 *step* per *epoch* menggunakan *batch size* 10 dan 5 *epoch* data. Akurasi yang didapat sebesar 96,67% untuk data train dan 100 % untuk dataset validasi setelah berakhir pada *epoch* ke-5.

Penelitian berjudul *Classification of Hand Gesture in Indonesian Sign Language System using Naive Bayes* yang dilakukan oleh Eko Pramunanto, Surya Sumpeno, dan Rafiidha Selyna Legowo pada tahun 2017 menggunakan algoritma komputasi *Gaussian Naive Bayes* dalam mengklasifikasikan sepuluh kata isyarat SIBI yang dibaca


menggunakan *leap motion*. Pada awal *learning process*, data disegmentasi berdasarkan kelasnya kemudian rata-rata dan variannya dihitung untuk setiap fitur. Data yang digunakan sebanyak 250 data yang terdiri dari sepuluh kata isyarat yang diambil 25 kali. Sepuluh kata isyarat yang digunakan adalah 5, Halo, B, Ajak, C, Kacau, D, Mana, U, dan Bukan. Akurasi yang didapat sebesar 80.53% dari data terlatih dan 70.67% dari data tidak terlatih, meskipun terdapat beberapa data jari yang tumpang tindih dalam pembacaan data. Pada penelitian ini, kecepatan gerakan ketika pengujian dan intensitas cahaya pada tempat pengujian dapat mempengaruhi akurasi.

Berdasarkan penelitian-penelitian tersebut, penelitian ini juga akan menggunakan metode CNN untuk melakukan pengenalan terhadap 26 kelas alfabet SIBI. Data yang digunakan sebanyak 2.600 citra data alfabet SIBI yang akan dibagi menjadi 80% data *training* dan 20% data *testing*. Data yang digunakan akan diaugmentasi sebelum dilakukan pelatihan pada model. Arsitektur model yang digunakan terdiri dari tiga *convolution layer*, tiga *maxpooling layer*, dan *fully connected layer*. Pada proses pelatihan, akan dilakukan sepuluh kali percobaan pelatihan dengan membandingkan parameter untuk mencari parameter yang menghasilkan akurasi terbaik. Model terbaik dari sepuluh percobaan tersebut akan dievaluasi menggunakan confusion matrix dan kemudian akan diimplementasi pada sebuah website sederhana sehingga bisa digunakan untuk pengenalan alfabet SIBI dan dapat digunakan sebagai salah satu media pembelajaran dalam mengenal alfabet SIBI.

III. METODE PENELITIAN

A. Tahapan Penelitian

Model penelitian yang dilakukan adalah *Research and Development* (R&D) dengan tahapan-tahapan penelitian yang dilakukan dalam penelitian ini digambarkan dalam Gbr 1.



Gbr 1. Tahapan Penelitian

Tahapan penelitian dimulai dengan melakukan Observasi dan Wawancara, kemudian Identifikasi Masalah, Studi Literatur menggunakan beberapa jurnal dan buku,

Pengumpulan dataset dari 26 Alfabet SIBI yang kemudian dilakukan preprocessing terhadap dataset tersebut. Setelah dilakukan preprocessing, kemudian dilakukan perancangan model. Model yang telah dirancang akan dilakukan training menggunakan dataset *training* untuk melihat akurasi yang didapat. Setelah didapat akurasi yang diharapkan, model kemudian diuji menggunakan *confusion matrix*. Jika akurasi yang didapat pada tahap pengujian tidak mencapai 80%, maka akan dilakukan perancangan ulang model dengan parameter yang berbeda. Jika akurasi pada pelatihan model sudah mencapai 80%, tahap selanjutnya model dengan akurasi diatas 80% tersebut akan diimplementasikan ke web sederhana agar model dapat digunakan untuk mengidentifikasi alfabet SIBI.

B. Dataset

Metode pengumpulan data dilakukan dengan melalui dua tahap, yaitu dengan mengambil data dari internet dan pengambilan data secara langsung. Data yang diambil dari internet didapat melalui website dataset *Kaggle*. Pengambilan data secara langsung dilakukan dengan mengambil data citra secara mandiri menggunakan kamera *smartphone* pribadi yang mengumpulkan setiap 26 huruf alfabet SIBI.


Data pada penelitian ini terdiri dari 26 kelas yang merupakan 26 huruf alfabet SIBI. Data yang dikumpulkan sebanyak 2.600 citra alfabet SIBI dan dibagi menjadi 2.080 citra untuk data *training* dan 250 citra untuk data *testing* dengan perbandingan jumlah 80% untuk data *training* dan 20% untuk data *testing*. Sehingga citra yang ada pada setiap kelas pada data *training* berjumlah 80 citra dan citra untuk data *testing* berjumlah 20 citra.

C. Preprocessing

Setelah mengumpulkan dataset dilakukan *Preprocessing*. Dataset kemudian diolah dengan dilakukan augmentasi data dan resize citra. Pada *preprocessing*, citra akan diaugmentasi dengan dilakukannya *flip*, *zoom*, *Width Shift* dan *Height Shift* pada citra dataset. Citra juga akan diresize menjadi 200 x 200 pixels. Citra asli yang sebelum melalui preprocessing dan setelah dilakukannya preprocessing dapat dilihat pada Tabel I.

TABEL I
CITRA SETELAH DAN SEBELUM PREPROCESSING


Preprocessing	Citra Asli	Setelah Preprocessing
Zoom		
Flip (horizontal)		



Tabel I merupakan tabel yang menunjukkan citra sebelum dilakukan preprocessing dan setelah melalui preprocessing. Pada tahap preprocessing, Dataset akan diaugmentasi dengan diperbesar (Zoom) sebesar 30%, Horizontal Flip, Pergeseran Lebar (Width Shift), dan Pergeseran Tinggi (Height Shift) sebesar 20% yang bertujuan untuk menambah variasi dataset. Pada Preprocessing, citra juga akan diresize menjadi ukuran 200 x 200 pixels.

D. Arsitektur Model

Arsitektur model yang akan digunakan terdiri dari tiga layer *Convolution*, tiga *Pooling Layer* dan *Fully Connected*. Kemudian digunakan Fungsi Aktivasi pada setiap *Convolutional Layer*. Arsitektur model pada penelitian ini dapat dilihat pada Gbr 2



Gbr 2. Arsitektur CNN pada Penelitian

Gbr 2. merupakan gambar dari Arsitektur CNN yang digunakan dalam penelitian ini untuk mengidentifikasi alfabet SIBI. *Convolution Layer* yang diimplementasikan menggunakan *kernel size* 3x3 dengan Fungsi Aktivasi ReLu. *Convolution Layer* merupakan layer pertama yang menerima input citra pada arsitektur CNN yang mengekstraksi citra input menggunakan filter atau kernel [11]. *Convolution Layer* memiliki parameter yang bisa diubah untuk memodifikasi sifat setiap lapisan, yaitu ukuran *filter*, *padding* dan *stride* [12]. Setiap filter pada *Convolution Layer* akan mengalami pergeseran dan melakukan operasi *dot* antara data input dan

nilai dari *filter* [13].

Pada umumnya, *Pooling Layer* digunakan setelah *Convolution Layer*. Untuk mendapatkan *features map* dengan ukuran yang diinginkan dilakukan proses *convolution* dan *pooling* beberapa kali [14]. *Pooling Layer* yang digunakan adalah *MaxPooling* dengan *kernel size* 2x2. *Max Pooling* menggunakan nilai maksimal dari sebuah *grid* atau bagian kecil dari *convolutional layer* untuk menyusun citra sehingga citra tersebut tereduksi[15]. Proses yang terjadi pada *Convolution Layer* dan *Pooling Layer* disebut *Feature Learning*. pada *Feature Learning* akan dihasilkan *Feature Map*. Setelah dilakukan *Feature Learning*, proses selanjutnya adalah klasifikasi dengan menggunakan *flatten* untuk mengubah dimensi *matrix Feature Map* menjadi vektor satu dimensi. Kemudian ditambahkan *Fully Connected Layer* yang terdapat *Dropout* dan *Dense Layer*. *Fully Connected Layer* Memiliki *multiple hidden layer*, fungsi aksi, *output layer* dan fungsi *loss* yang digunakan untuk melakukan klasifikasi [11]. Pada *Fully Connected Layer*, neuron dari lapisan sebelumnya akan diambil semua dan dihubungkan ke setiap neuron di lapisan saat ini. Tidak ada informasi spasial yang disimpan dalam *Fully Connected Layer*, dan lapisan terakhir dari *Fully Connected Layer* diikuti oleh *output layer* [16]. Selanjutnya digunakan Fungsi Aktivasi *Softmax* yang berfungsi untuk menentukan probabilitas pada setiap kelas.

Dropout merupakan salah satu cara yang dapat dilakukan untuk mencegah terjadinya *overfitting* dan dapat mempercepat proses learning. *Overfitting* adalah keadaan dimana hampir seluruh data yang telah *training* mencapai persentase yang baik, namun pada proses prediksi terjadi ketidaksesuaian [13]. *Dropout* akan menghilangkan neuron yang dianggap *noise* untuk sementara secara acak untuk mencegah terjadinya *overfitting* [17].

Activation Function atau Fungsi Aktivasi digunakan untuk menentukan apakah suatu neuron diaktifkan berdasarkan *weighted sum* dari *input* [1]. ReLu merupakan salah satu Fungsi Aktivasi dan memiliki fungsi untuk menghilangkan nilai *negative* pada citra dengan cara mengganti nilai *negative* pada *feature maps* atau citra menjadi 0 [18]. *Softmax* biasanya digunakan untuk klasifikasi yang memiliki banyak kelas [19]. Nilai probabilitas softmax berada dalam rentang 0 sampai 1 dan jumlah keseluruhan nilai probabilitas = 1 [20].

Nilai dari Fungsi *Loss* harus diperkecil hingga nilai prediksi dapat mendekati nilai yang sebenarnya. Jadi, semakin kecil Fungsi *Loss*, maka nilai prediksi akan semakin mendekati benar[21]. Fungsi *Loss* yang baik adalah fungsi yang menghasilkan kesalahan yang diharapkan terendah [22]. Fungsi *Loss* yang digunakan dalam penelitian ini adalah *Categorical Cross Entropy*. *Categorical Cross Entropy* merupakan *Loss function Cross Entropy* yang digunakan untuk melakukan klasifikasi *multiclass* [23].

Optimizer berfungsi untuk mengoptimalkan proses pembelajaran algoritma *Neural Network* untuk mendapatkan hasil maksimal dan pengoptimalan akan berhenti bekerja setelah titik pembelajaran optimal tercapai. Dalam algoritma CNN, proses belajar untuk mendapatkan nilai optimal disebut *learning rate* [21]. Adam merupakan salah satu algoritma optimasi (*optimizer*) yang bertujuan untuk mendapatkan nilai bobot yang optimal, meningkatkan akurasi serta mengurangi kesalahan [17]. Adam memiliki keunggulan seperti hemat memori, efisien dan komputasi dan cocok untuk berbagai

masalah optimasi *non-convex* pada *Machine Learning* Adadelta [24].

E. Tuning Hyperparameter

Tuning Hyperparameter merupakan proses untuk mengatur parameter yang akan digunakan saat merancang model pada CNN yang bertujuan agar model yang dihasilkan tidak *underfitting* maupun *overfitting* [21]. *Hyperparameter* yang akan dituning pada penelitian ini adalah *epoch* dan *batch size*. Hal ini dilakukan karena, menurut penelitian yang dilakukan oleh Olivia Kembuan dkk pada tahun 2020, fase terpenting dalam penelitian tersebut adalah ketika menentukan jumlah *Epoch* dan *Batch Size* untuk *dataset training* [25]. *Epoch* adalah jumlah iterasi yang dilakukan pada *Neural Network* [20]. *Batch size* adalah jumlah sub *dataset* yang akan dipisahkan untuk dimodelkan [21].

IV. HASIL DAN PEMBAHASAN

Pada penelitian ini, dilakukan sepuluh kali percobaan *training* menggunakan beberapa parameter yang berbeda untuk membandingkan dan mendapatkan model yang terbaik dengan target akurasi yang diinginkan.


TABEL III
PERCOBAAN PELATIHAN

no	epoch	Batch Size	Accuracy		Loss	
			Train	Valid	Train	Valid
1	25	64	0.6304	0.6995	1.1004	1.0734
2	25	32	0.6683	0.7548	0.9697	0.7180
3	25	20	0.6935	0.7861	0.8733	0.7686
4	25	10	0.7794	0.8149	0.6594	0.6178
5	25	8	0.7212	0.7837	0.7736	0.6418
6	50	64	0.8125	0.7933	0.5341	0.6694
7	50	32	0.8089	0.8317	0.5655	0.5402
8	50	20	0.8233	0.8341	0.5105	0.4913
9	50	10	0.7758	0.8726	0.6496	0.4078
10	50	8	0.8534	0.8654	0.4229	0.3882

Berdasarkan Tabel II, model terbaik yang dihasilkan pada sepuluh percobaan pelatihan adalah model pada percobaan pelatihan ke-10. Pelatihan yang menggunakan 50 *epoch* dan 8 *batch size*. *Training accuracy* dihasilkan sebesar 0.8534 (85%) dan *Validasi accuracy* sebesar 0.8654 (87%). Nilai *Loss* yang dihasilkan pada percobaan pelatihan ke-10 untuk *training loss* sebesar 0.4229 (42%) dan *validasi loss* sebesar 0.3882 (39%).

Berdasarkan 10 percobaan yang dilakukan, hasil terbaik didapat pada *batch size* paling kecil yaitu 8 dan *epoch* yang lebih besar yaitu 50. Hal ini terjadi karena pada *batch size* yang lebih kecil membuat data latih yang digunakan dalam 1 *epoch* lebih banyak. Sehingga pada saat menggunakan *epoch* besar data dilatih telah beberapa kali melewati proses pelatihan yang menyebabkan akurasi lebih baik, sehingga mengakibatkan akurasi lebih baik dibanding pelatihan yang menggunakan *batch size* lebih besar. Pada *batch size* yang besar, *dataset* yang digunakan belum semua melalui proses pelatihan yang menyebabkan akurasi lebih rendah, karena beberapa data belum dikenali.

Grafik *accuracy* dan *loss* dari percobaan pelatihan ke-10 dapat dilihat pada Gbr 3.




Gbr 3. Grafik Accuracy dan Loss Percobaan Pelatihan ke-10

Gbr 3 merupakan gambar dari grafik yang dihasilkan dari pelatihan ke-10. Grafik *Accuracy* dan *Loss* untuk melihat dan mengevaluasi kinerja model saat proses pelatihan. Grafik *accuracy* digunakan untuk melihat seberapa baik model dalam memprediksi pada tiap *epoch* dan iterasi. Grafik *Loss* digunakan untuk melihat seberapa baik model ketika belajar dalam meminimalisir *loss* selama proses *training*.

Berdasarkan Gbr3, Grafik validasi *accuracy* dan *training accuracy* mengalami peningkatan yang signifikan pada setiap *epoch*. Validasi *accuracy* memiliki akurasi tertinggi pada *epoch* terakhir, yaitu sebesar 0.8654 dan *training accuracy* juga memiliki akurasi tertinggi pada *epoch* terakhir, yaitu sebesar 0.8654. Grafik *loss* pada Pelatihan 10 juga mengalami penurunan yang signifikan. Validasi *loss* berakhir pada nilai 0.3882 dan *training loss* berakhir pada nilai 0.4229. Berdasarkan kedua grafik tersebut, model yang dihasilkan pada Pelatihan 10 dapat dikatakan model yang baik. Berdasarkan grafik yang dihasilkan pada Pelatihan 10, model yang dihasilkan dapat dikatakan model yang baik dan tidak mengalami *overfitting* maupun *underfitting*. Hal ini juga dapat dilihat dari jarak grafik *training* dan validasi yang berdekatan dan hampir berhimpitan. Pelatihan 10 merupakan percobaan pelatihan yang menghasilkan model paling baik diantara pelatihan lainnya.

Tahapan selanjutnya yang dilakukan setelah mendapatkan model terbaik adalah dengan menguji dan mengevaluasi kinerja model. *Confusion Matrix* digunakan dalam penelitian ini untuk menguji dan mengevaluasi kinerja model yang telah dihasilkan pada proses *training*. *Confusion Matrix* adalah metode yang digunakan untuk mengevaluasi kinerja klasifikasi dari objek [25]. *Confusion Matrix* bisa digunakan untuk mengukur kinerja dari sebuah *machine learning*. Untuk mempresentasikan hasil dari proses klasifikasi, digunakan empat istilah, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* [26]. Hasil pengujian *confusion matrix* pada penelitian ini dilihat pada Gbr 4.



Gbr 4. Hasil Pengujian Confusion Matrix

Berdasarkan Gbr 4. didapatkan hasil dari pengujian confusion matrix dengan akurasi sebesar 87,9%. Model yang digunakan untuk pengujian ini adalah model yang dihasilkan dari percobaan pelatihan ke-10. Tahap selanjutnya yang dilakukan adalah mengimplementasikan model tersebut ke *website* sederhana. Implementasi web dilakukan bertujuan agar model dapat digunakan untuk mengidentifikasi citra dari alfabet SIBI. Tampilan dari pengimplementasian model pada *website* sederhana dilihat pada Gbr 5.



Gbr 5. Implementasi Web

Berdasarkan Gbr 5. model yang sudah dilatih dan diuji dapat digunakan dan diimplementasikan pada web sederhana. Model juga berhasil mengenali dan memprediksi citra dengan hasil akurasi baik. Pada Gbr 5, model dicobakan pada web sederhana dan berhasil mengenali citra alfabet F yang mendapat akurasi sangat baik, yaitu sebesar 98,77%.

V. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat diambil beberapa kesimpulan berikut:

1. Metode CNN yang digunakan dalam penelitian ini berhasil mengenali citra Alfabet SIBI. Model dihasilkan dari pelatihan menggunakan 2.600 citra dengan arsitektur yang terdiri dari tiga *Convolution Layer*, tiga *Pooling*

Layer, dan *Fully Connected Layer*. Model terbaik yang dihasilkan adalah model yang dihasilkan pada percobaan pelatihan ke-10 yang menggunakan 50 *epoch* dan *batch size* 8 dengan akurasi sebesar 87% untuk validasi *accuracy* dan 85% untuk *training accuracy*.

2. Pelatihan 10 mendapatkan hasil terbaik karena kesesuaian *batch size* dan *epoch* sehingga menghasilkan akurasi terbaik. Hal ini karena pada *epoch* yang besar dan *batch size* yang lebih kecil, memungkinkan semua data latih yang digunakan telah melewati proses pelatihan pada setiap *epoch*, sehingga akurasi yang dihasilkan lebih baik.
3. Pada proses pengujian, data berhasil mengenali 457 data dari 520 data *testing* dan mendapat akurasi rata-rata sebesar 87.9%.

Saran yang dapat diberikan untuk penelitian berikutnya adalah dengan menambah jumlah *dataset* dan variasi parameter lainnya untuk melatih model sehingga akurasi yang dihasilkan bisa lebih meningkat. Selain itu juga, diharapkan untuk penelitian selanjutnya bisa mencoba mengembangkan penelitian ini ke platform lain, tidak hanya pada web melainkan juga pada *mobile*.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen pembimbing yang telah membimbing penulis dalam menyelesaikan penelitian ini.

DAFTAR PUSTAKA

- [1] D. Yolanda, K. Gunadi, and E. Setyati, "Pengenalan Alfabet Bahasa Isyarat Tangan Secara Real-Time dengan Menggunakan Metode Convolutional Neural Network dan Recurrent Neural Network," *J. Infra*, vol. 8, no. 1, pp. 203–208, 2020, [Online]. Available: <https://publication.petra.ac.id/index.php/teknik-informatika/article/view/9791>
- [2] A. Breva Yunanda, F. Mandita, and A. Primasetya Armin, "Pengenalan Bahasa Isyarat Indonesia (BISINDO) Untuk Karakter Huruf Dengan Menggunakan Microsoft Kinect," *Fountain Informatics J.*, vol. 3, no. 2, p. 41, 2018, doi: 10.21111/fij.v3i2.2469.
- [3] E. Premunanto, S. Sumpeno, and R. S. Legowo, "Classification of hand gesture in Indonesian sign language system using naive bayes," *Proc. - 2017 Int. Semin. Sensor, Instrumentation, Meas. Metrol. Innov. Adv. Compet. Nation, ISSIMM 2017*, vol. 2017-Janua, pp. 187–191, 2017, doi: 10.1109/ISSIMM.2017.8124288.
- [4] J. A. Yohans, I. G. P. B. S. Arjawa, and I. N. Punia, "Bahasa Isyarat Indonesia Dalam Proses Interaksi Sosial Tuli dan 'Masyarakat Dengar' di Kota Denpasar," *OJS Unud*, pp. 1–15, 2019.
- [5] L. Khotimah, "INTERAKSI SOSIAL ANAK TUNARUNGU DI SEKOLAH STUDY KASUS DI TK ALVENVER SURABAYA," 2019.
- [6] H. Liu and B. Lang, "Machine learning and deep learning methods for intrusion detection systems: A survey," *Appl. Sci.*, vol. 9, no. 20, 2019, doi: 10.3390/app9204396.
- [7] T. Kattenborn, J. Leitloff, F. Schiefer, and S. Hinz, "Review on Convolutional Neural Networks (CNN) in vegetation remote sensing," *ISPRS J. Photogramm. Remote Sens.*, vol. 173, no. November 2020, pp. 24–49, 2021, doi: 10.1016/j.isprsjprs.2020.12.010.
- [8] A. R. Syulistyo, D. S. Hormansyah, and P. Y. Saputra, "SIBI (Sistem Isyarat Bahasa Indonesia) translation using Convolutional Neural Network (CNN)," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 732, no. 1, 2020, doi: 10.1088/1757-899X/732/1/012082.
- [9] D. F. Ningsih, "KLASIFIKASI JENIS PENYAKIT DAUN KENTANG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) MODEL ARSITEKTUR GOOGLNET," 2021.

- [10] M. R. R. Allaam and A. T. Wibo, "KLASIFIKASI GENUS TANAMAN ANGGREK MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) Program Studi Sarjana Informatika Fakultas Informatika Universitas Telkom Bandung," *e-Proceeding Eng.*, vol. 8, no. 2, pp. 3147–3179, 2021.
- [11] O. Dwi Nurhayati, D. Eridani, and M. Hafiz Tsalavin, "Sistem Isyarat Bahasa Indonesia (Sibi) Metode Convolutional Neural Network Sequential Secara Real Time," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 4, pp. 819–828, 2022, doi: 10.25126/jtig.202294787.
- [12] E. N. Arrofiqoh and H. Harintaka, "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi," *Geomatika*, vol. 24, no. 2, p. 61, 2018, doi: 10.24895/jig.2018.24-2.810.
- [13] P. A. Nugroho, I. Fenriana, and R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia," *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [14] N. Nana, D. Iskandar Mulyana, A. Akbar, and M. Zikri, "Optimasi Klasifikasi Buah Anggur Menggunakan Data Augmentasi dan Convolutional Neural Network," *Smart Comp Jurnalnya Orang Pint. Komput.*, vol. 11, no. 2, pp. 148–161, 2022, doi: 10.30591/smartcomp.v11i2.3527.
- [15] B. W. Kurniadi, H. Prasetyo, G. L. Ahmad, B. Aditya Wibisono, and D. Sandya Prasvita, "Analisis Perbandingan Algoritma SVM dan CNN untuk Klasifikasi Buah," *Semin. Nas. Mhs. Ilmu Komput. dan Apl. Jakarta-Indonesia*, no. September, pp. 1–11, 2021.
- [16] T. Guo, J. Dong, H. Li, and Y. Gao, "Simple convolutional neural network on image classification," *2017 IEEE 2nd Int. Conf. Big Data Anal. ICBDA 2017*, pp. 721–724, 2017, doi: 10.1109/ICBDA.2017.8078730.
- [17] M. Sholawati, K. Auliasari, and F. Ariwibisono, "Pengembangan Aplikasi Pengenalan Bahasa Isyarat Abjad Sibi Menggunakan Metode Convolutional Neural Network (Cnn)," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 6, no. 1, pp. 134–144, 2022, doi: 10.36040/jati.v6i1.4507.
- [18] Ridho Aji Pangestu, Basuki Rahmat, and Fetty Tri Anggraeny, "Implementasi Algoritma Cnn Untuk Klasifikasi Citra Lahan Dan Perhitungan Luas," *J. Inform. dan Sist. Inf.*, vol. 1, no. 1, pp. 166–174, 2020.
- [19] M. B. S. Bakti and Y. M. Pranoto, "Pengenalan Angka Sistem Isyarat Bahasa Indonesia Dengan Menggunakan Metode Convolutional Neural Network," *Semin. Nas. Inov. Teknol.*, pp. 11–16, 2019.
- [20] N. K. Qudsi, R. A. Asmara, and A. R. Syulistyo, "Identifikasi Citra Tulisan Tangan Digital Menggunakan Convolutional Neural Network (CNN)," *Semin. Inform. Apl. Polinema*, pp. 48–53, 2020.
- [21] I. Saputra and D. A. Kristiyanti, *Machine Learning Untuk Pemula*. Bandung: Informatika, 2022.
- [22] I. Wulandari, H. Yasin, and T. Widiari, "Klasifikasi Citra Digital Bumbu Dan Rempah Dengan Algoritma Convolutional Neural Network (Cnn)," *J. Gaussian*, vol. 9, no. 3, pp. 273–282, 2020, doi: 10.14710/j.gauss.v9i3.27416.
- [23] M. F. Naufal and S. F. Kusuma, "Pendeteksi Citra Masker Wajah Menggunakan CNN dan Transfer Learning," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 6, p. 1293, 2021, doi: 10.25126/jtiik.2021865201.
- [24] A. Nasuha, T. A. Sardjono, and M. H. Purnomo, "Pengenalan Viseme Dinamis Bahasa Indonesia Menggunakan Convolutional Neural Network," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 7, no. 3, pp. 258–265, 2018, doi: 10.22146/jnteti.v7i3.433.
- [25] O. Kembuan, G. Caren Rorimpandey, and S. Milian Tomponu Tengker, "Convolutional Neural Network (CNN) for Image Classification of Indonesia Sign Language Using Tensorflow," *2020 2nd Int. Conf. Cybern. Intell. Syst. ICORIS 2020*, no. 26, 2020, doi: 10.1109/ICORIS50180.2020.9320810.
- [26] S. F. Handono, F. T. Anggraeny, and B. Rahmat, "Implementasi Convolutional Neural Network (Cnn) Untuk Deteksi Retinopati Diabetik," *J. Inform. dan Sist. Inf.*, vol. 1, no. 1, pp. 669–678, 2020.