

Implementasi *Deep Learning* pada Pengenalan Angka dalam *Sign Language*

Implementation of Deep Learning on Number Recognition in Sign Language

¹Fini Keni Celsia, ²Green Arther Sandag

Universitas Klabat, Jln. Arnold Mononutu, Airmadidi, Telp: 0431- 891035

³Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Klabat, Airmadidi
e-mail: 1s21710137@student.unklab.ac.id , greensandag@unklab.ac.id

Abstrak

Penderita tuna rungu dan tuna wicara sering merasa kesulitan untuk berkomunikasi dengan masyarakat umum. Era teknologi saat ini memerlukan sistem cerdas yang dapat membantu komunikasi para penderita tuna rungu dan wicara. Oleh karena itu pada penelitian ini peneliti membuat model dalam klasifikasi Bahasa isyarat menggunakan, Convolutional Neural Network (CNN) dan Artificial Neural Network (ANN). CNN merupakan metode yang banyak digunakan untuk mendeteksi bahasa isyarat, dimana setiap gerakan tangan bahasa isyarat dapat terdeteksi dan memberikan informasi. Hasil penelitian ini diambil dari tiga tahapan masing-masing sebanyak 100 epoch yang dilakukan pada proses train, dimana untuk proses train pertama mendapatkan hasil akurasi 99%, proses train kedua mendapatkan hasil akurasi 100%, dan proses train ketiga mendapatkan hasil akurasi 99%. Kesimpulan penelitian ini adalah pengklasifikasian bahasa isyarat menggunakan metode ANN dan CNN memberikan hasil akurasi yang tinggi. Hasil akurasi dengan rata-rata 94,5% di dapatkan pada penelitian ini, dengan hasil tersebut dapat membantu komunikasi antara penderita tuna rungu, tuna wicara, dan orang normal. Berdasarkan model yang kami buat menggunakan CNN dan ANN, memiliki performa yang baik sebesar 1-3 % lebih baik dengan algoritma yang lain.

Kata Kunci —ANN, CNN, akurasi, dan klasifikasi.

Abstract

Hearing impaired and speech impaired often find difficult to communicate with the general public. The current era of technology requires a smart system that can help communication of people with hearing and speech impairments. Therefore, in this study the researchers made a model in the classification of Sign Language using Convolution Neural Network (CNN) and Artificial Neural Network (ANN). CNN is a widely used method for detecting sign language, where every sign language hand gesture can be detected and provide information. The results of this study were taken from three stages of 100 epoch each carried out in the train process, where for the first train process got 99% accuracy results, the second train process got 100% accuracy results, and the third train process achieved 99% accuracy results. The conclusion of this study was the classifying of sign language using ANN and CNN method to provide high accuracy results. The results of accuracy with an average of 94.5% were obtained in this study, with these results can help communication between people who are deaf, speech

impaired, and normal people. Based on the model we created using CNN and ANN have a good performance which is 1-3% better than other algorithms

Keywords—ANN, CNN, accuracy, and classification.

1. PENDAHULUAN

Komunikasi merupakan bagian yang penting dari manusia sebagai makhluk sosial. Komunikasi merupakan pertukaran informasi dari satu atau kelompok individu ke individu lainnya [1]. Komunikasi dapat disampaikan melalui beberapa cara yaitu verbal dan nonverbal. Komunikasi verbal adalah jenis komunikasi yang mengandalkan kata-kata sebagai informasi baik melalui perkataan maupun berupa tulisan. Komunikasi nonverbal tidak menggunakan kata-kata tetapi lebih ke tindakan isyarat yang mempunyai makna yang menjadi informasi untuk orang lain [2].

Bahasa isyarat merupakan bahasa yang sering digunakan oleh orang yang memiliki gangguan pendengaran dan gangguan berbicara. Bahasa ini belum cukup dikenal dan dimengerti oleh orang-orang normal yang tidak memiliki gangguan apapun. Namun, bagaimana halnya dengan para penderita tuna rungu dan tuna wicara yang ingin berkomunikasi dengan orang disekitar mereka. Orang yang normal sampai saat ini membutuhkan penerjemah bahasa isyarat, untuk berkomunikasi dengan para tuna rungu dan tuna wicara. Penggunaan bahasa isyarat memberikan kemudahan untuk mengatakan apa yang dipikirkan melalui ekspresi, postur dan gesture manusia [2]. Bahasa isyarat di dunia memiliki standart yang berbeda-beda, dimana mengikuti standart dari setiap negara masing-masing.[3]. Menurut WHO terdapat sekitar 400 juta orang yang mengalami gangguan dalam pendengarannya serta terdapat 151.000 orang yang menggunakan bahasa isyarat sebagai cara untuk berkomunikasi dengan orang lain [4]. Artinya, banyak dari masyarakat diluar sana yang membutuhkan sebuah teknologi yang dapat memberikan manfaat serta membantu mereka untuk berkomunikasi dengan orang sekitar. Perkembangan teknologi saat ini begitu pesat, contohnya teknologi Artificial Intelligence. Dengan pemanfaatan teknologi AI, manusia dapat membuat sebuah sistem yang dapat menerjemahkan bahasa isyarat. Saat ini teknologi yang banyak digunakan untuk menerjemahkan bahasa isyarat, yaitu Sign Language Recognition (SLR). SLR adalah teknik yang sering dipakai dalam bidang computer vision yang digunakan untuk menerjemahkan setiap gerakan yang di input menjadi gambar, agar memudahkan setiap orang berkomunikasi [5] [6]. Dengan penggunaan SLR maka manusia dapat membedakan antara dialog bahasa isyarat dan cerita dengan cara mengamati postur tubuh dari orang yang bersangkutan [7].

Pada penelitian [8], menggunakan CNN untuk klasifikasi gambar untuk pengenalan bahasa isyarat dengan menggunakan library tensorflow. Pada penelitian ini menggunakan dataset bahasa isyarat Indonesia yang berisi 2659 gambar Bahasa Isyarat Indonesia (BISINDO) dua puluh enam (26) kategori huruf. Gambar dibagi menjadi set pelatihan dan validasi. Untuk hasil yang didapatkan, dataset untuk pelatihan mencapai 96,67% serta untuk dataset validasi mencapai 100%. Pada penelitian [9], pengenalan bahasa isyarat dilakukan berdasarkan segmentasi kulit serta menggunakan algoritma machine learning. Penggunaan deep learning untuk mengklasifikasikan gambar berdasarkan input yang diberikan kemudian setelah itu sistem akan menentukan arti dari input yang diberikan. Dalam penelitian ini memperoleh hasil tes akurasi sebesar 94.7%. Pada penelitian yang serupa juga oleh [5] , menggunakan Convolutional Neural Network (CNN) untuk memberikan proses ekstrasi fitur yang efisien, klasifikasi akurasi yang diperoleh pada penelitian ini adalah sebesar 94,57% yang mana hasil ini sangat signifikan untuk memperkenalakan SLR pada penyandang cacat sebagai hasil dari Human-Computer Interaction (HCI). Berdasar penelitian yang dilakukan oleh [10] untuk mengidentifikasi bahasa isyarat menggunakan *deep convolutional network* pada gambar bahasa isyarat Amerika yang mencakup huruf dan angka dan ditemukan bahwa algoritma DeepCNN yang merupakan salah satu jenis algoritma deep

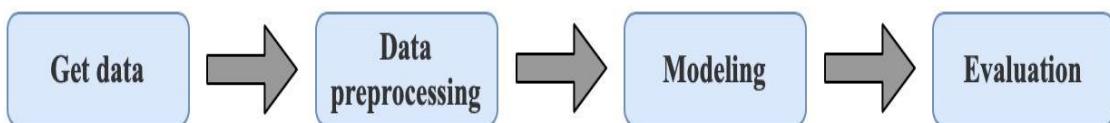
convolutional network memiliki tingkat keakuratan mencapai 80%.

Penelitian yang dilakukan oleh [11] dalam mengenali bahasa isyarat menggunakan *deep learning* pada gambar bahasa isyarat Amerika yang mencakup 26 huruf dan 10 angka menghasilkan tingkat akurasi sebesar 98.05%.

Penelitian yang akan dilakukan menggunakan metode dari Deep Learning, yaitu Convolutional Neural Network (CNN). CNN merupakan metode dari deep learning yang digunakan untuk mendekripsi gambar, dari setiap gambar yang di input. Algoritma CNN banyak digunakan dalam klasifikasi bahasa isyarat, dikarenakan tingkat akurasinya yang tinggi. CNN dalam pengklasifikasian bahasa isyarat untuk mendekripsi gerakan tangan yang di input [12]. Dengan demikian, peneliti menggunakan algoritma CNN dan ANN untuk mengklasifikasi gambar digit dalam Bahasa isyarat, sehingga penelitian ini dapat bermanfaat bagi masyarakat agar bisa berkomunikasi dengan penderita tuna rungu dan tuna wicara tanpa bantuan penerjemah bahasa isyarat.

2. METODE PENELITIAN

Metode dalam penelitian ini dibagi menjadi 4 tahapan penelitian yaitu *get data*, *data preprocessing*, *modeling*, dan *evaluation* seperti yang terlihat pada Gambar 1.



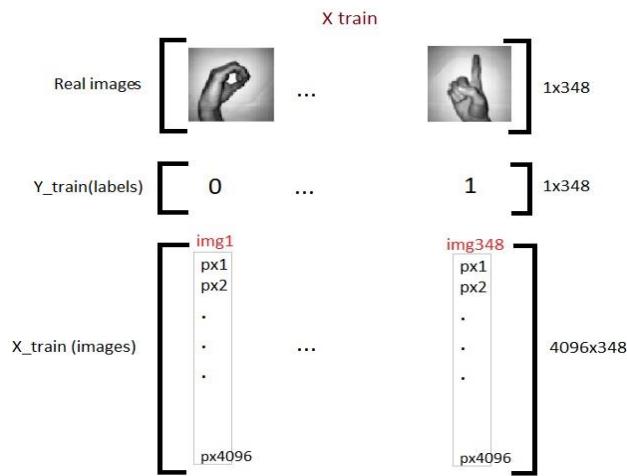
Gambar 1. Metode penelitian

2.1 *Get data*

Dataset yang digunakan dalam penelitian ini adalah *sign language digits* yaitu kumpulan data yang digunakan untuk setiap digit dari bahasa isyarat. Adapun terdapat 10 tanda unik yang telah ditetapkan yaitu berkisar antara angka 0 hingga 9 serta terdapat 2.062 gambar untuk setiap digit dari bahasa isyarat yang telah dimasukkan kedalam data. Dalam pengujian yang dilakukan digunakan tanda 0 dan 1, pemahaman dari data dapat pada gambar 2

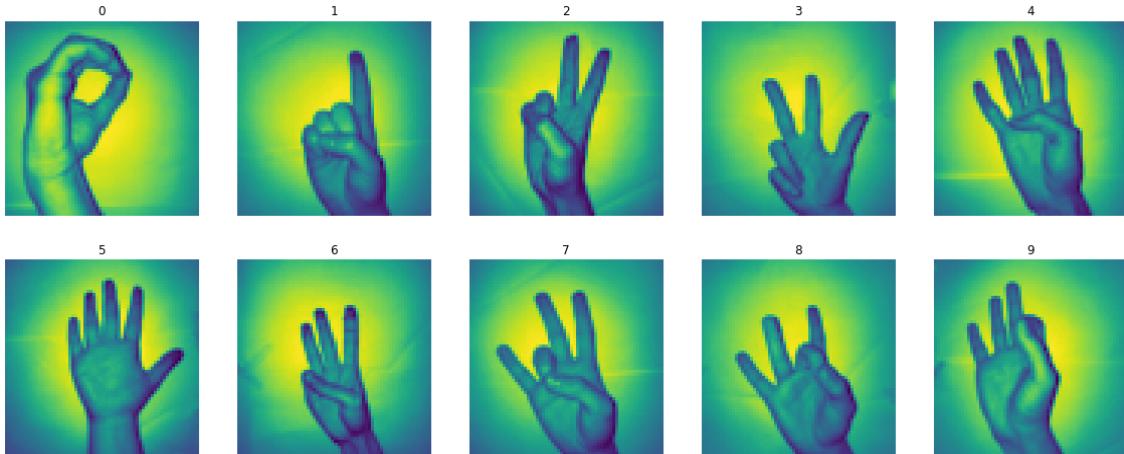
Tabel 1. Parameter Dataset

Index	Details	Value
0 - 203	the image represents a sign language which means the number 9	9
204 - 408	the image represents a sign language which means the number 0	0
409 - 614	the image represents a sign language which means the number 7	7
615 - 821	the image represents a sign language which means the number 6	6
822 - 1027	the image represents a sign language which means the number 1	1
1028 - 1235	the image represents a sign language which means the number 8	8
1236 - 1442	the image represents a sign language which means the number 4	4
1443 - 1648	the image represents a sign language which means the number 3	3
1649 - 1854	the image represents a sign language which means the number 2	2
1855 - 2061	the image represents a sign language which means the number 5	5



Gambar 2. Data Understand

Gambar 3 adalah Sample dataset sign language yang digunakan untuk data traning.



Gambar 3. Sample dataset sign language untuk data training

2.2 Data Preprocessing

Pada proses ini data yang digunakan sebanyak 205 sampel untuk gambar tanda nol dan tanda satu dari setiap kelas. Di dalam data, posisi dari gambar tanda nol berada antara indeks 204 dan 408 dan untuk gambar tanda satu berada antara 822 dan 1027. Dalam data terdapat variable X dan Y yang digunakan sebagai array, dimana X merupakan *Image array* (gambar tanda nol dan tanda satu) dan Y merupakan *Image label* (0 dan 1). Kemudian untuk membuat *Image array* akan digabungkan array dari gambar tanda nol dan juga gambar tanda 1 dan untuk *Image label* digunakan 0 untuk gambar tanda nol dan 1 untuk gambar tanda 1. Shape data X adalah (410, 64, 64) yang berarti 410 gambar, 64 berarti ukuran gambar (64×64 piksel) sedangkan untuk data Y (410,1) yang berarti 410 labels (0 dan 1). Kemudian data X dan Y dibagi menjadi data train dan test dengan presentasi 15% data test dan 75% data train.

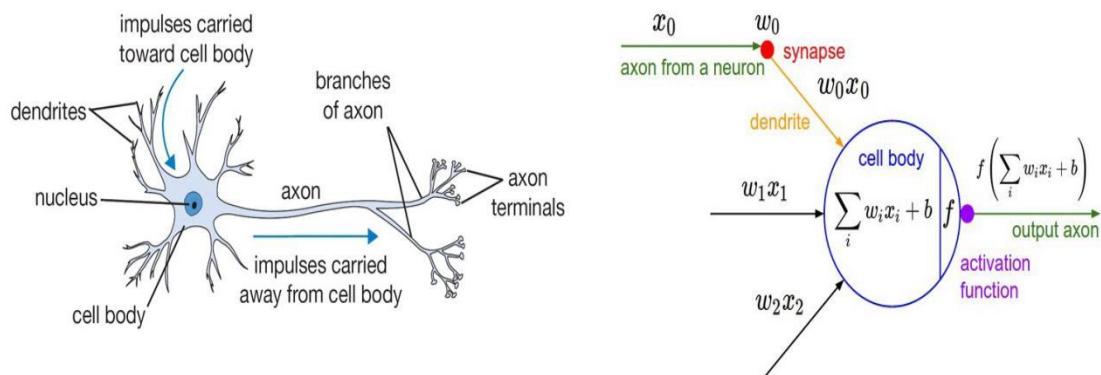
2.3 Modeling

Pada tahap ini berisi pembahasan mengenai model yang digunakan untuk penelitian. Disini akan dibahas tentang *deep learning*, *Artificial Neural Network*, *Convolutional Neural Network (CNN)*, *gradient descent*, dan *performance evaluation*

2.3.1 Deep learning

Deep learning adalah sub-bidang pembelajaran mesin yang berhubungan dengan algoritma yang terinspirasi oleh struktur dan fungsi otak yang disebut jaringan saraf tiruan. Dengan kata lain, ini mencerminkan fungsi otak kita [13]. Algoritma deep learning mirip dengan bagaimana sistem saraf terstruktur di mana setiap neuron terhubung satu sama lain dan menyampaikan informasi seperti yang ditunjukkan pada gambar 4. Model deep learning bekerja dalam beberapa lapisan dan model yang tipikal setidaknya memiliki tiga lapisan. Setiap lapisan menerima informasi sebelumnya dan meneruskannya ke lapisan berikutnya .

Penggunaan metode deep learning dalam penelitian ini adalah untuk mengklasifikasikan gambar yang akan dimasukkan dan mengkategorikannya ke sign tertentu dan menentukan arti dari sign yang dimasukkan, serta mengevaluasi performa model. Untuk melakukan proses klasifikasi gambar, diperlukan prosesor dan RAM yang memiliki tingkat kecepatan tinggi. Dalam rangka untuk memaksimalkan hasil dari pengenalan bahasa isyarat ini maka digunakan metode klasifikasi deep learning yaitu Convolutional Neural Network dan Artificial Neural Network (ANN).

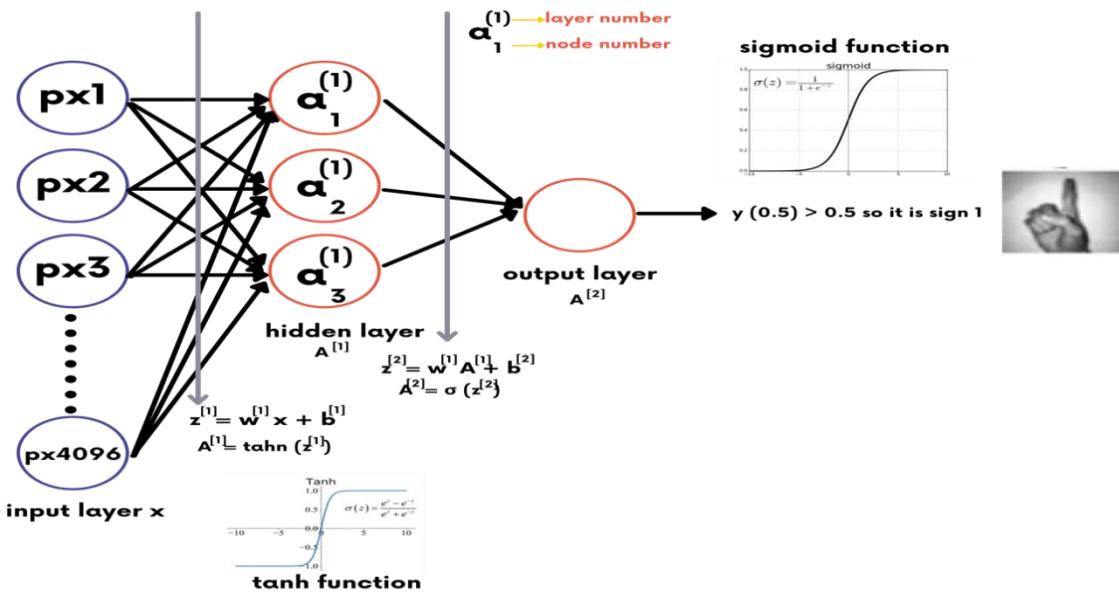


Gambar 4. Cara kerja *deep learning* dengan meniru cara kerja otak manusia [13]

ANN yang dikenal dengan nama Jaringan Syaraf Tiruan (JST) adalah sistem komputasi yang dirancang menyerupai sistem syaraf yang ada pada otak manusia. ANN dapat belajar dengan sendirinya yang memungkinkan hasil yang diberikan akan lebih baik jika data yang tersedia lebih banyak. Seperti sistem syaraf pada manusia, ANN juga mempunyai struktur yang mirip dengan itu. Ada beberapa lapisan yang ada pada ANN seperti yang ditunjukkan pada gambar 5. Dari lapisan-lapisan tersebut sebagian lapisan mempunyai bertanggung jawab untuk membawa informasi ke tempat pemrosesan yang nantinya akan dipelajari dan akan memberikan hasil. Lapisan lainnya adalah tempat dimana informasi diproses. Kemudian lapisan akhir adalah tempat dimana hasilnya dikeluarkan [14].

Hasil yang diberikan tentunya tergantung dari jumlah informasi yang didapatkan dan bagaimana mengolah informasi tersebut. Pada penelitian ini model ANN yang digunakan adalah model perceptron. Fungsi aktivasi yang digunakan adalah untuk hidden layer menggunakan fungsi tanh dimana fungsi ini outputnya akan mendekati nol atau rentang nilainya adalah -1 sampai 1 [15]. Pada hidden layer terdapat tambahan input yaitu nilai bias, untuk proses training pada deep learning terbagi 2 bagian yaitu, forward propagation dan backward propagation [16]. Forward propagation adalah proses pada data input atau image sign language akan melewati setiap

neuron pada hidden layer sampai kepada output layer yang nanti akan dihitung errornya, sedangkan proses pada backpropagation, error yang didapat pada proses sebelumnya akan digunakan untuk mengupdate setiap weight dan bias dengan learning rate tertentu. Metode optimasi yang digunakan adalah dengan menggunakan *Adam* dan penentuan nilai error menggunakan *categorical crossentropy*.



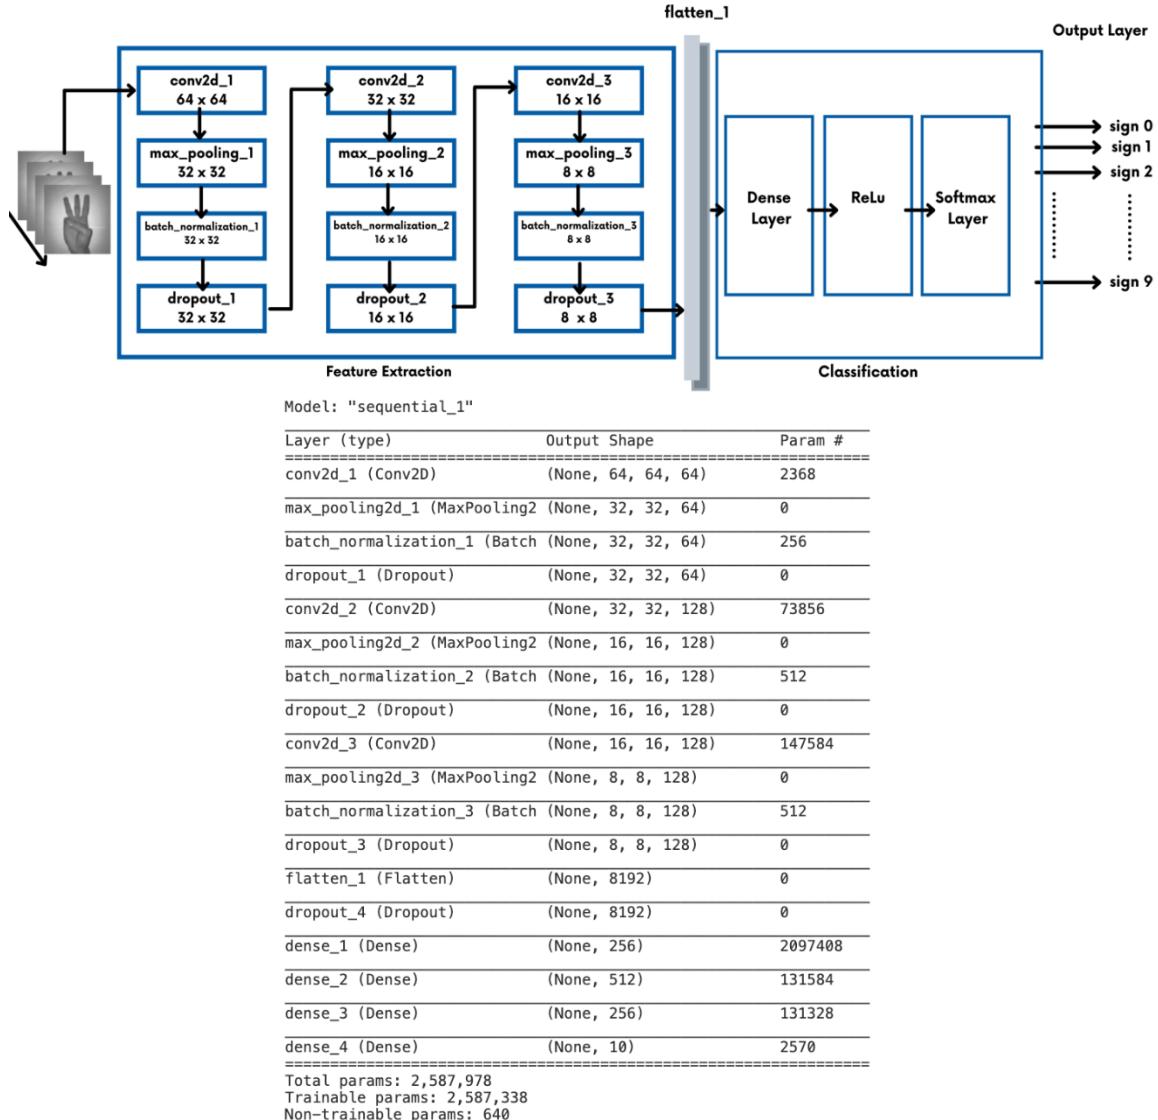
Gambar 5. Arsitektur ANN

2.3.2 Convolutional Neural Network (CNN)

Convolutional Neural Network merupakan sebuah metode yang digunakan untuk mengenali dan mendeteksi data yang terdapat pada gambar. Pada jaringan saraf normal manusia, neuron akan terhubung antara satu dengan lainnya. Namun, jika hal ini dilakukan dan dipelajari oleh komputer maka hal yang akan dilakukan yaitu dengan cara mengambil data-data dari gambar berupa pixel yang nanti akan dihubungkan ke neuron. Dalam proses CNN ini, tidak semua data dari gambar yang dimasukan dapat terpakai seperti latar background yang sebenarnya tidak memberi informasi apapun. Untuk itu, CNN terdiri dari beberapa lapisan yang berguna untuk menyaring informasi atau data yang diperlukan sehingga memungkinkan data yang masuk pada komputer adalah data yang benar-benar diperlukan untuk mempelajari objek yang terkait [17]. Perbedaan metode CNN dan deep learning biasa adalah arsitektur yang menyusun CNN dibagi menjadi 2 bagian yaitu feature extraction layer dan fully connected layer seperti yang ditunjukkan pada gambar 6. Feature extraction layer adalah proses untuk melakukan encoding dari sebuah image menjadi features yang berupa angka, layer ini terdiri dari convolutional layer dan pooling layer. Pada convolutional layer terdapat neuron yang membentuk sebuah filter gambar, stride yang merupakan parameter untuk menentukan pergeseran filter, dan padding yang merupakan parameter untuk menentukan jumlah pixels yang akan ditambahkan pada sisi input/image.

Implementasi Deep Learning pada Pengenalan Angka dalam Sign Language

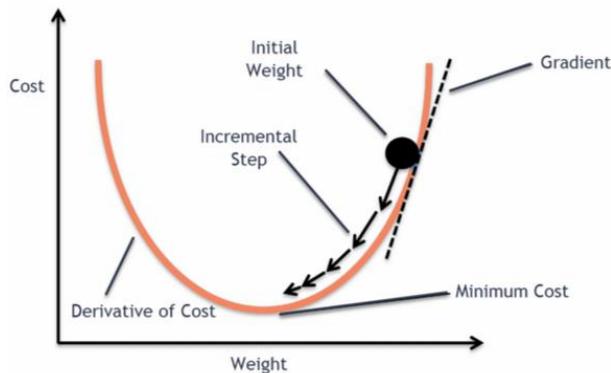
Pooling layer digunakan sebagai filter yang akan bergerak pada seluruh feature image dengan ukuran dan stride tertentu[18].



Gambar 6. Arsitektur CNN [13]

Gradient Descent

Pada tahap ini dilakukan optimasi algoritma dengan menggunakan *gradient descent*. Nilai gradien merupakan nilai kemiringan suatu fungsi yang membandingkan komponen x dengan komponen y seperti yang ditunjukkan pada gambar 7. Penurunan gradien berfungsi untuk menggambarkan sebuah perulangan yang dilakukan untuk mencari nilai yang optimal dari parameter. Parameter yang dimaksudkan yaitu pada koefisien dalam regresi linear dan weight dalam jaringan saraf. Dengan penggunaan teknik penurunan gradien akan memungkinkan untuk mempelajari parameter weight dan bias sehingga meminimalkan cost function [19]. Pada penelitian ini, peneliti mengupdate weight berdasarkan setiap Langkah untuk mengurangi kesalahan atau error.



Gambar 7. Gradient Descent [20]

2.4 Performance Evaluation

Validation merupakan sebuah teknik yang digunakan untuk mengevaluasi model dalam memperkirakan ke akuratannya dengan menggunakan *dataset* untuk melakukan pengujian pada tahap pelatihan [21]. Namun sebelumnya, sampel asli akan digunakan sebagai *train* dan sebuah *test* yang akan melakukan evaluasi. Pada pelatihan yang dilakukan didapatkan bentuk X adalah (410, 64, 64) dimana terdapat 410 gambar tanda nol dan satu dengan ukuran gambar 64x64 pixels. Adapun bentuk Y adalah (410, 1) artinya terdapat 410 label 0 dan 1. Dari hasil tersebut maka X dan Y akan dibagi menjadi train and test sets dengan persentase yang didapatkan yaitu train 75% dan test 15%. Dari proses tersebut didapatkan X yaitu Array dengan input 3D dan Y dengan input 2D sehingga perlu dilakukan perubahan pada X menjadi 2D. sehingga didapatkan train Array dengan hasil 348 gambar dengan ukuran 4096 pixels dan test Array dengan hasil 62 gambar dengan 4096 pixels.

Untuk pengukuran yang dianalisa pada penelitian ini yaitu berupa *accuracy*, *precision* dan *recall* dengan menggunakan persamaan berikut ini.

Rumus *Recall*:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (1)$$

Rumus *Precision*:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

Rumus *Accuracy*:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

Keterangan:

TP: *True Positive*

FP: *False Positive*

FN: *False Negative*

TN: *True Negative*

Accuracy merupakan sebuah pengukuran yang dilakukan untuk mengklasifikasi bahasa isyarat pada tanda nol dan satu. Untuk mengetahui nilai dari akurasi suatu pengujian maka

langkah yang dilakukan yaitu dengan menjumlahkan nilai *true positive* dan *true negative* kemudian keduanya dibagi dengan *true positive*, *true negative*, *false positive*, dan *false negative* yang dijumlahkan. *Precision* merupakan langkah yang dilakukan dengan cara mengambil data dari *true positive* kemudian dibagi dengan *true positive* lalu dijumlahkan dengan nilai *false positive*. *Recall* merupakan langkah yang dilakukan untuk menemukan contoh dari gambar yang diinput dalam dataset yang bersifat relevan. Cara untuk menghitung nilai dari *recall* yaitu jumlah nilai *true positive* kemudian dibagi dengan *true positive* lalu dijumlahkan dengan nilai dari *false negative* [20].

3. HASIL DAN PEMBAHASAN

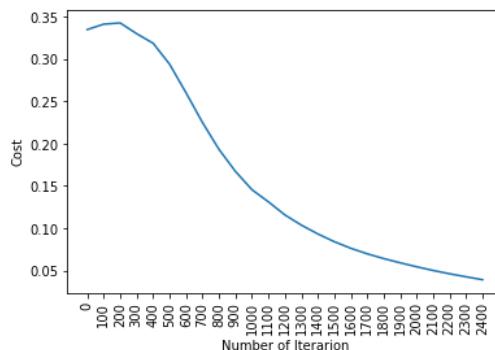
Pada penelitian ini menggunakan *dataset* bahasa isyarat yang dijalankan pada google colaboratory. Google colabotary merupakan perangkat lunak yang digunakan untuk mengolah data pada bidang *machine learning* menggunakan bahasa pemrograman phyton. Google colabs menyediakan beberapa keuntungan seperti akses secara gratis, tersedia akses *cloud* dengan spesifikasi yang tinggi, tidak memerlukan konfigurasi apapun serta adanya kemudahan untuk terhubung ke drive dan juga orang lain [22].

3. 1 Perbandingan algoritma *Convolutional Neural Network* dengan CNN pada penelitian sebelumnya menggunakan *train data*

Berdasarkan Tabel 2, menunjukkan performa antara algoritma *Convolutional Neural Network* (CNN) yang diusulkan peneliti dan algoritma CNN yang digunakan pada 3 penelitian sebelumnya, metode CNN peneliti bekerja sedikit lebih optimal dari CNN pada penelitian sebelumnya sekitar 1% - 3% pada bagian *accuracy*. Gambar 8 menunjukkan performa model menggunakan CNN pada data train dan data validation dengan 100 epoch, semakin besar nilai epoch maka performa model semakin baik, maka menghasilkan akurasi sebesar 99.7%.

Tabel 2. Perbandingan *performance* CNN dengan penelitian sebelumnya

Algorithm	Accuracy (%)
CNN	99.7
CNN_Islam [5]	94.57
CNN_Shahriar [9]	94.7
CNN Taskiran [11]	98.05



train accuracy: 99.71264367816092 %
test accuracy: 96.7741935483871 %

Gambar 8. Performa Algoritma CNN dalam klasifikasi digit image pada Bahasa isyarat

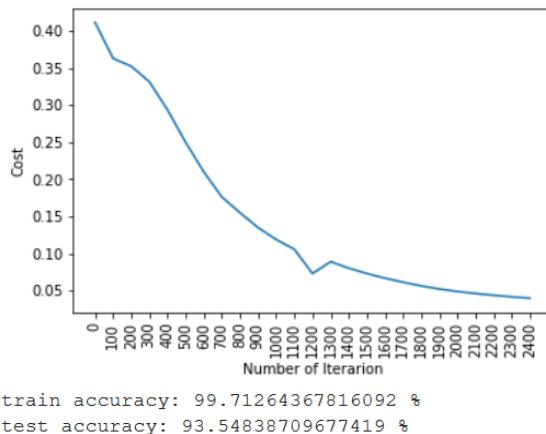
3.2 Perbandingan algoritma menggunakan *train data* terhadap klasifikasi *sign language*

Pada Tabel 3 memperlihatkan hasil *performance evaluation* dari algoritma klasifikasi tanpa menggunakan independent dataset. Dari hasil tersebut dapat dilihat bahwa algoritma ANN memiliki accuracy tertinggi dibandingkan dengan algoritma lain dengan nilai *accuracy* sebesar 99.7%.

Tabel 3. Perbandingan *performa model* menggunakan ANN

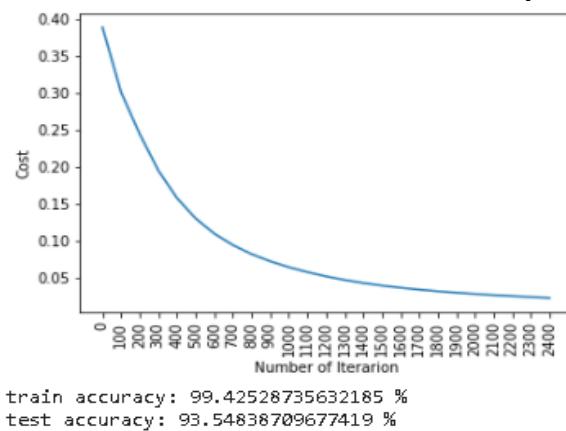
Algorithm	Accuracy (%)	Recall (%)	Precision (%)
Artificial Neural Network	99.71	98.54	98.8
Logistic Regression	92.8	90.23	93.1
L Layer Neural Network	99.42	98.32	99.1

Pada penelitian ini, *library* yang digunakan adalah *Keras*. Adapun proses *train* yang dilakukan sebanyak 100 *epoch*, pada setiap algoritma. Proses tersebut dilakukan untuk melihat dan memastikan performa model dari setiap algoritma.



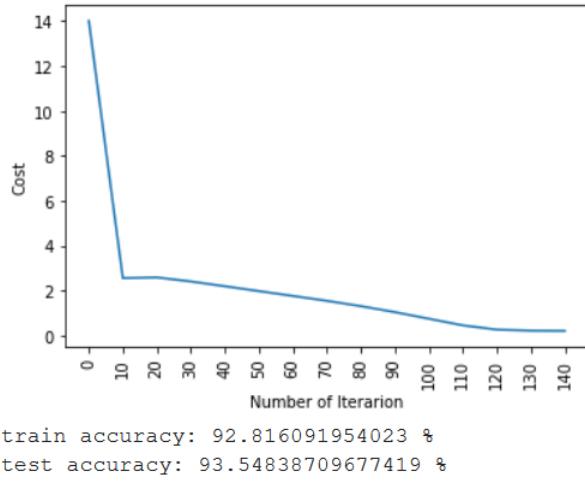
Gambar 9. Performa model menggunakan *Artificial Neural Network* (ANN)

Pada gambar 9 dilakukan beberapa perulangan dengan tujuan untuk memperkecil cost untuk mencapai hasil yang maksimal. Pada gambar ini memberikan informasi yaitu semakin sering dilakukan iterasi maka semakin rendah cost yang diperlukan. Pada hasil evaluasi train dan test berdasarkan dataset yang ada maka didapati rata-rata akurasi seperti yang terdapat pada gambar 6 yaitu untuk train sebesar 99.71% dan untuk akurasi tes yaitu sebesar 93.54%.



Gambar 10. Performa model menggunakan L Layer Neural Network

Pada gambar 10 menunjukkan penurunan error rate terhadap jumlah iterasi menggunakan algoritma L Layer Neural Network dengan akurasi sebesar 99.42% untuk data training dan 93.54% untuk data testing. Pada pengujian ini juga dilakukan update cost untuk mencari performa model yang terbaik dengan melakukan iterasi sebanyak 2400 kali.



Gambar 11. Performa model menggunakan Logistic Regression

Pada gambar 11 menunjukkan penurunan error rate terhadap jumlah iterasi menggunakan algoritma Logistic Regression dengan akurasi sebesar 92.81% untuk data training dan 93.54% untuk data testing. Pada pengujian ini juga dilakukan update cost untuk mencari performa model yang terbaik dengan melakukan iterasi sebanyak 140 kali. Berdasarkan hasil yang didapat maka algoritma CNN bekerja sedikit lebih optimal dari CNN pada penelitian sebelumnya sekitar 1% - 3% peningkatan *accuracy*.

4. KESIMPULAN

Penelitian ini digunakan untuk mengklasifikasikan bahasa isyarat dengan menggunakan CNN dan ANN, agar komunikasi yang dilakukan oleh penderita tuna rungu dan tuna wicara kepada orang normal menjadi lebih mudah. Dari 4 model algoritma yang telah dievaluasi yaitu *Convolutional Neural Network*, *Artificial Neural Network*, *Logistic Regression* dan *L Layer Neural Network* dapat disimpulkan bahwa algoritma *Artificial Neural Network* dan *Convolutional Neural Network* memiliki performa paling baik diantara algoritma yang lainnya dengan tingkat *accuracy* sebesar 99.7% atau 1% - 6.9% lebih baik dalam memprediksi *Sign Language*. Dari hasil yang didapat ini kiranya dapat membantu komunikasi yang terjadi antara tuna rungu, tuna wicara, dengan orang normal.

5. SARAN

Dalam penelitian ini masih terbatas pada penerjemahan bahasa isyarat berupa angka. Dengan begitu, diharapkan kemajuan teknologi saat ini khususnya dibidang *deep learning* dapat memberi manfaat lebih bagi yang membutuhkan. Untuk itu penelitian selanjutnya diharapkan untuk lebih mengembangkan penelitian ini dengan menambah cakupan seperti untuk menerjemahkan bahasa isyarat berupa kata dan kalimat serta dapat menambahkan jenis sample yang diambil agar membuat data yang dihasilkan lebih berkualitas. Untuk memperbaiki akurasi bisa menggunakan pretrained model atau pendekatan yang lainnya.

DAFTAR PUSTAKA

- [1]. Zheng, L., Liang, B., & Jiang, A. (2017, November). Recent advances of deep learning for sign language recognition. In *2017 International Conference on Digital Image Computing: Techniques and Applications (DICTA)* (pp. 1-7). IEEE.
- [2]. Das, A., Gawde, S., Suratwala, K., & Kalbande, D. (2018, January). Sign language recognition using deep learning on custom processed static gesture images. In *2018 International Conference on Smart City and Emerging Technology (ICSCET)* (pp. 1-6). IEEE.
- [3]. Tang, A., Lu, K., Wang, Y., Huang, J., & Li, H. (2015). A real-time hand posture recognition system using deep neural networks. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 6(2), 1-23.
- [4]. World Health Organization. (2018). *Addressing the rising prevalence of hearing loss*.
- [5]. Islam, M. R., Mitu, U. K., Bhuiyan, R. A., & Shin, J. (2018, September). Hand gesture feature extraction using deep convolutional neural network for recognizing American sign language. In *2018 4th International Conference on Frontiers of Signal Processing (ICFSP)* (pp. 115-119). IEEE.
- [6]. Rao, G. A., Syamala, K., Kishore, P. V. V., & Sastry, A. S. C. S. (2018, January). Deep convolutional neural networks for sign language recognition. In *2018 Conference on Signal Processing And Communication Engineering Systems (SPACES)* (pp. 194-197). IEEE.
- [7]. Gattupalli, S., Ghaderi, A., & Athitsos, V. (2016, June). Evaluation of Deep Learning Based pose estimation for sign language recognition. In *Proceedings of the 9th ACM International Conference On Pervasive Technologies Related To Assistive Environments* (pp. 1-7).
- [8]. Kembuan, O., Rorimpandey, G. C., & Tengker, S. M. T. (2020, October). Convolutional Neural Network (CNN) for Image Classification of Indonesia Sign Language Using Tensorflow. In *2020 2nd International Conference on Cybernetics and Intelligent System (ICORIS)* (pp. 1-5). IEEE.
- [9]. Shahriar, S., Siddiquee, A., Islam, T., Ghosh, A., Chakraborty, R., Khan, A. I., ... & Fattah, S. A. (2018, October). Real-time American Sign Language Recognition using skin segmentation and image category classification with convolutional neural network and deep learning. In *TENCON 2018-2018 IEEE Region 10 Conference* (pp. 1168-1171). IEEE.
- [10]. Bheda, V. and Radpour, N. D., "Using Deep Convolutional Networks for Gesture Recognition in American Sign Language," 2017.
- [11]. Taskiran, M., Killioglu, M., & Kahraman, N. (2018, July). A real-time system for recognition of American sign language by using deep learning. In *2018 41st International Conference on Telecommunications and Signal Processing (TSP)* (pp. 1-5). IEEE.
- [12]. Putro, E. C., Awangga, R. M., and Andarsyah, R., *Tutorial Object Detection People with Faster region-Based Convolutional Neural Network (Faster R-CNN)*. Kreatif, 2020.
- [13]. Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press.
- [14]. Oz, C., & Leu, M. C. (2011). American sign language word recognition with a sensory glove using artificial neural networks. *Engineering Applications of Artificial Intelligence*, 24(7), 1204-1213.
- [15]. Kumar, A., "Activation Functions, Loss Functions, and Optimizer:", Medium, 2020. [Online]. Available: <https://medium.com/@amitbalharakr93/activation-functions-loss-functions-and-optimizer-a5da4571e401>. [Accessed: 18- Aug- 2020].
- [16]. Das, A., Gawde, S., Suratwala, K., and Kalbande, D., "Sign Language Recognition Using Deep Learning on Custom Processed Static Gesture Images," in *2018 International Conference on Smart City and Emerging Technology (ICSCET)*, Mumbai, Jan. 2018, pp. 1-6, doi: 10.1109/ICSCET.2018.8537248.

- [17]. Bantupalli, K., & Xie, Y. (2018, December). American sign language recognition using deep learning and computer vision. In *2018 IEEE International Conference on Big Data (Big Data)* (pp. 4896-4899). IEEE.
- [18]. Pigou, L., Dieleman, S., Kindermans, P. J., & Schrauwen, B. (2014, September). Sign language recognition using convolutional neural networks. In *European Conference on Computer Vision* (pp. 572-578). Springer, Cham.
- [19]. Ruder, S. (2016). *An overview of gradient descent optimization algorithms*. arXiv preprint arXiv:1609.04747.
- [20]. M, R. (2019). The Ascent of Gradient Descent. Medium. Retrieved 11 June 2020, from <https://blog.clairvoyantsoft.com/the-ascent-of-gradient-descent-23356390836f>.
- [21]. Krasula, L., Fliegel, K., Le Callet, P., & Klíma, M. (2016, June). On the accuracy of objective image and video quality models: New methodology for performance evaluation. In *2016 Eighth International Conference on Quality of Multimedia Experience (QoMEX)* (pp. 1-6). IEEE.
- [22]. Carneiro, T., Da Nóbrega, R. V. M., Nepomuceno, T., Bian, G. B., De Albuquerque, V. H. C., & Reboucas Filho, P. P. (2018). *Performance analysis of google colaboratory as a tool for accelerating deep learning applications*. IEEE Access, 6, 61677-61685.