

Data Augmentasi Untuk Mengatasi Keterbatasan Data Pada Model Penerjemah Bahasa Isyarat Indonesia (BISINDO)

Riestiya Zain Fadillah¹, Ade Irawan², Meredith Susanty³

^{1,2,3} Universitas Pertamina

Jl Teuku Nyak Arief, Simprug, Kebayoran Lama, Jakarta Selatan 12220, Indonesia

e-mail: ¹riestiyazainf@gmail.com, ²ade.irawan@universitaspertamina.ac.id,
³meredita.susanty@universitaspertamina.ac.id

Informasi Artikel

Diterima: 17-06-2021

Direvisi: 26-07-2021

Disetujui: 28-07-2021

Abstrak

Ada dua sistem bahasa isyarat yang digunakan di Indonesia; Sistem Isyarat Bahasa Indonesia (SIBI) dan Bahasa Isyarat Indonesia (Bisindo). Penggunaan bahasa isyarat di kelompok masyarakat tuli dan difabel rungu di Indonesia masih terpecah. Pemerintah mewajibkan penggunaan SIBI sebagai bahasa pengantar resmi di Sekolah Luar Biasa namun insan rungu Indonesia lebih gemar menggunakan Bisindo. Hal ini dikarenakan Bisindo memiliki akar kata yang berasal dari Bahasa Indonesia dan satu gerakan mewakili kata. Tidak seperti SIBI yang menggunakan gerakan isyarat berdasarkan tata bahasa orang mendengar. Gerakan untuk Kesejahteraan Tunarungu Indonesia (Gerkatin) telah meminta pemerintah untuk mengakui Bisindo sebagai bahasa pengantar resmi di Sekolah Luar Biasa namun upaya ini hingga kini belum berhasil. Upaya lain yang dilakukan Gerkatin adalah memberikan kelas pelatihan Bisindo bagi masyarakat umum membantu meningkatkan aksesibilitas Tuli dengan menambah jumlah penerjemah serta memperluas pemahaman Bisindo di masyarakat luas. Penelitian ini mencoba mendukung upaya tersebut dengan mengembangkan model penerjemah Bisindo yang menerjemahkan gestur bahasa isyarat menjadi teks menggunakan pendekatan *machine learning* dengan arsitektur *Convolutional Neural Network* (CNN). Karena tidak menjadi bahasa resmi, bahasa ini jarang digunakan di acara resmi yang biasanya ditampilkan di televisi. Akibatnya jumlah dataset Bisindo berupa gambar terbatas jika dicari di internet. Pada penelitian ini, keterbatasan dataset Bisindo diatasi dengan melakukan *data augmentation*. Upaya ini memberikan hasil performa model yang mencapai nilai akurasi sebesar 94.38%.

Kata Kunci: Bahasa Isyarat, Mesin Pembelajaran, Penerjemah

Abstract

There are two sign language systems used in Indonesia; Indonesian Sign Language System (SIBI) and Indonesian Sign Language (Bisindo). The use of sign language in the deaf and deaf community in Indonesia is still divided. The government recognize SIBI as the official language of instruction in special schools, but the Indonesian deaf prefers to use Bisindo. They prefer Bisindo because it is rooted in the Indonesian language. Furthermore, one movement represents the word in Bisindo, unlike SIBI, which uses gestures based on the grammar of the listener. The Movement for the Well-Being of Deaf Indonesians (Gerkatin) has asked the government to recognize Bisindo as the official language of instruction in Special Schools. However, this effort has so far been unsuccessful. To help improve the accessibility of the deaf by increasing the number of translators and increase Bisindo's understanding of the broader community, Gerkatin provides Bisindo training classes for the general public. This study tries to develop a Bisindo translator model that translates Bisindo gestures into text using a machine learning approach with Convolutional Neural Network (CNN) architecture to enable the broader community to learn sign language. Because it is not an official sign language, any official events shown on television rarely uses it. Hence, the image of Bisindo's dataset is limited on the internet. This study aims to address the limitations of the Bisindo dataset by performing data augmentation. As a result, the model's performance gets an accuracy value of 94.38%.

Keywords: Sign Language, Machine Learning, Translator



1. Pendahuluan

Bahasa Isyarat Indonesia (Bisindo) sudah ada sejak Indonesia belum merdeka. Sayangnya, saat itu literatur, penelitian dan kajian mengenai Bisindo masih sangat minim. Referensi yang sangat minim ini membuat Bisindo tidak populer di masyarakat luas termasuk pemerintah. Lantaran keberadaan Bisindo yang tidak muncul ke permukaan, pemerintah membuat sistem bahasa isyarat sendiri yang disebut SIBI dan mengesahkan penggunaannya di sekolah luar biasa maupun lembaga pada 1994. Pembuatan SIBI saat itu belum melibatkan kelompok masyarakat tuli, sehingga kurang dapat diterima luas oleh kelompok ini (Cheta Nilawaty P & Rini Kustiani, 2020b). Hingga kini, penggunaan bahasa isyarat di kelompok masyarakat tuli dan difabel rungu masih terpecah (Zulpicha, 2017). Musababnya, pemerintah masih mewajibkan penggunaan SIBI sebagai bahasa pengantar resmi di SLB, sedangkan bahasa isyarat Bisindo lebih mempresentasikan maksud masyarakat tuli, namun belum diterapkan di sekolah.

Keputusan dari Kementerian Pendidikan dan Budaya Nomor 0190/P/1994 tanggal 1 Agustus 1994 untuk membuat Kamus Sistem Isyarat Bahasa Indonesia (SIBI) menimbulkan perselisihan antara Komunitas Tuli, yaitu termasuk Gerakan untuk Kesejahteraan Tuna Rungu Indonesia (Gerkatin), dengan tim perumus Kamus SIBI (Abraham Utama, 2015; Ade Nasihudin Al Ansori, 2020). Dewan Pengurus Pusat Gerkatin mengangkat isu ini untuk didiskusikan bersama di Kongres Nasional keenam Gerkatin di Bali pada tahun 2002. Berdasarkan hasil keputusan dari Kongres Nasional tersebut, nama Bahasa Isyarat Indonesia ditetapkan secara resmi dan kemudian disingkat menjadi Bisindo dengan tujuan mempertahankan bahasa isyarat alamiah.

Di Indonesia terdapat lebih dari 2.500.000 tuli dan BISINDO adalah bentuk komunikasi yang paling efektif serta tidak terbatas hanya untuk Tuli tetapi juga untuk semua orang. Untuk mengurangi hambatan dalam berkomunikasi dan mendukung lingkungan yang inklusif, Gerkatin membuka kelas bahasa isyarat BISINDO untuk umum. Sebagai bentuk mendorong upaya tersebut, penelitian ini mencoba membuat model penerjemah Bisindo, yang jika berhasil dapat dimanfaatkan untuk membuat aplikasi penerjemah sehingga semakin banyak orang yang dapat belajar gestur Bisindo secara mandiri.

Bisindo digunakan sebagai bahasa isyarat dalam komunikasi sehari-hari bagi Tuli dengan menggunakan gerakan kedua tangan dan ekspresi wajah. Seperti bahasa daerah,


ungkapkan Bisindo memiliki keberagaman dalam penggunaan di setiap daerah. Berbeda dengan SIBI yang menggunakan pengejaan hingga tingkat imbuhan dan susunan kalimat sesuai dengan Ejaan Bahasa Indonesia (EBI), Bisindo tidak mengikuti kaidah EBI dan lebih mengedepankan kesederhanaan serta ekspresi yang menunjukkan kejadian yang sedang berlangsung. Ekspresi inilah yang menyebabkan isyarat berbeda-beda di setiap daerah karena isyarat terbentuk atas interaksi nilai-nilai dari tiap daerah (Cheta Nilawaty P & Rini Kustiani, 2020a; Gumelar et al., 2018; Yohanes et al., 2013). Meski beragam, terdapat isyarat-isyarat yang ditetapkan untuk memudahkan komunikasi Tuli seperti: alfabet. Alfabet merupakan dasar dari pembelajaran bahasa baik bahasa isyarat maupun bahasa verbal. Oleh karena itu, penelitian ini memilih alfabet Bisindo sebagai langkah awal untuk mengembangkan model pembelajaran yang dapat meningkatkan aksesibilitas Tuli pengguna Bisindo.

Karena bukan menjadi bahasa isyarat resmi di Indonesia, acara-acara di televisi maupun pada acara-acara resmi lainnya hanya menggunakan seorang penutur bahasa isyarat yang menggunakan SIBI. Hal ini mengakibatkan jumlah gambar bahasa isyarat BISINDO sedikit. Sebelumnya penelitian lain mengusulkan model penerjemah gestur Bisindo melalui implementasi visi komputer (*computer vision*) dengan translasi mesin menggunakan Hidden-Markov Model (HMM). Jumlah hidden state dihitung menggunakan Bayesian Inference Criterion (BIC). Data yang digunakan merupakan gestur Bisindo dari 25 kata yang dikumpulkan menggunakan Microsoft Kinect Xbox. Model tersebut berhasil memperoleh akurasi sebesar 60% (Handhika et al., 2018). Penelitian lain menggunakan arsitektur *Convolutional Neural Network* (CNN) berupaya menerjemahkan *American Sign Language* dan berhasil mencapai nilai akurasi 82.5% untuk gestur alfabet dan 97% untuk angka (Bheda & Radpour, 2017). Berbeda dengan keduanya, penelitian ini mencoba menerjemahkan Bisindo menggunakan arsitektur CNN dan mengatasi keterbatasan jumlah dataset Bisindo dengan melakukan *data augmentation*.

2. Metode Penelitian

Penelitian ini terdiri dari 3 tahapan seperti yang ditunjukkan pada Gambar 1, yakni pengumpulan data, pra-pemrosesan data, melatih model menggunakan data yang sudah melalui tahap pra-pemrosesan, dan terakhir melakukan validasi terhadap model menggunakan dataset *testing*.

Karena bukan bahasa isyarat resmi dan diajarkan secara informal, ketersediaan *dataset* Bisindo di internet terbatas. Karena itu dalam penelitian ini *dataset* Bisindo diambil melalui proses observasi. Dalam proses observasi, penggunaan alfabet Bisindo khususnya pada gerakan tangan didokumentasikan dalam bentuk gambar dengan alat bantu kamera. *Dataset* yang dihasilkan dari proses observasi ini adalah data tanpa *background clutter* dan data yang dikumpulkan adalah data positif yaitu gambar yang terkumpul hanya data yang memuat alfabet Bisindo. Karena sudut pandang umum yang digunakan dalam berkomunikasi menggunakan bahasa isyarat adalah tampak depan sehingga data gambar yang digunakan di penelitian ini juga memuat gestur Bisindo dari tampak depan.




Gambar 1. Metodologi Penelitian

Untuk mengatasi ketersediaan dataset Bisindo yang relatif sedikit, *data augmentation*

dilakukan sebagai upaya untuk meningkatkan jumlah data Bisindo yang digunakan untuk proses pembelajaran. Augmentasi data merupakan salah satu teknik yang dapat mengurangi *overfitting* dengan meningkatkan ukuran *dataset* dalam upaya yang seminimum mungkin. Data biasanya diaugmentasi dengan melakukan transformasi pada data atau dengan kata lain membuat salinan dari sumber data tanpa mengubah label yang tertera pada setiap bagian dari data tersebut. *Cropping* dan *flipping* merupakan dua transformasi yang paling sering digunakan dalam proses data augmentation (Krizhevsky et al., 2017). Pada penelitian ini, data diaugmentasi menggunakan tiga teknik transformasi gambar: *flip*, *rotate* dan memberikan *Gaussian Noise* (Shorten & Khoshgoftaar, 2019) pada gambar. Jumlah dataset ditingkatkan dengan membuat salinan baru dari gambar asal menggunakan ketiga teknik tersebut.


Pemberian label dilakukan dengan membuat array *images* dan label. Untuk setiap gambar dalam kelas yang sama, akan diberi label yang sama. Contoh untuk kelas huruf A, setiap gambar akan diberi label 0. Selanjutnya dilakukan penyesuaian ukuran atau resolusi gambar menjadi persegi ($n \times n$). Ukuran ini akan disesuaikan dengan ukuran *layer* pertama pada model. Tahapan terakhir pra-pemrosesan data adalah membagi data menjadi data latih, data validasi, dan data untuk pengujian dengan rasio 0.66:0.22:0.12.

Model yang digunakan untuk melakukan prediksi menggunakan arsitektur CNN (Ankile et al., 2020; Li et al., 2020) dengan enam *convolution layer*, tiga *max pooling layer*, satu *batch normalization layer*, satu *flatten* dan *dropout layer*, dua *layer dense* dengan fungsi aktivasi *ReLU* (Nair & Hinton, 2010) dan *Softmax*. Model di-*compile* menggunakan Adam *optimizer* dan *loss function Categorical Crossentropy* (Goodfellow et al., 2016) seperti yang diilustrasikan pada Gambar 2



Gambar 2. Arsitektur Model

Training merupakan proses model dalam mencari dan mempelajari *good values* (nilai yang memiliki error paling rendah) untuk setiap *weight* dan *bias* dari labeled data train. Pada penelitian ini, *training* dilakukan menggunakan *kernel* dan GPU dari Kaggle. Model ditraining menggunakan *kernel* Kaggle dengan *batch size* 64 dan 5 *epoch* menggunakan teknik *k-fold cross-validation* (Raschka, 2018). Teknik ini memungkinkan training dilakukan pada data dengan jumlah yang terbatas. Setiap sampel data dibagi menjadi k grup dengan jumlah data dalam satu fold sama besar. Grup k akan di-train sebagai validation data dan grup lainnya (1,.. k-1) sebagai training.



Gambar 3. Training model menggunakan *k-fold cross validation*


Gambar 3 menunjukkan pembagian training data dan validation data pada setiap round training. Contoh menggunakan $k=10$

sehingga data dibagi menjadi sepuluh kelompok dengan jumlah sama besar. Round pertama menggunakan grup pertama sebagai validation data dan seterusnya hingga grup ke-10. Akurasi akhir diperoleh melalui nilai rata-rata akurasi training dan validation dari seluruh round. Di akhir proses training, diperoleh akurasi *training* dan *validation accuracy* dari model. Untuk memastikan model yang dihasilkan mampu mengeneralisasi data untuk dapat mengenali gestur bahasa isyarat, model dijalankan kembali terhadap dataset *testing* yang berbeda dengan dataset *training*. dan *validation*.

3. Hasil dan Pembahasan

Dataset yang digunakan adalah gambar alfabet Bisindo dengan jumlah 2659 gambar (hasil augmentasi) yang disimpan dalam 26 folder, merepresentasikan kelas yang akan diklasifikasi yaitu alfabet (a-z). Pada penelitian ini dataset yang digunakan dibuat berdasarkan hasil observasi penggunaan Bisindo dari responden yang mempelajari Bisindo.

Proses augmentasi data dilakukan dengan memperbanyak gambar yang semula berjumlah 26 gambar (masing-masing alfabet satu gambar) menjadi 100 gambar pada tiap huruf menggunakan transformasi gambar: *flip*, *rotate* dan memberikan *Gaussian noise* pada gambar seperti yang ditunjukkan pada Gambar 4.



Gambar 4. Hasil *crop*, *rotate* dan *Gaussian Noise* terhadap gambar asli

Untuk pemberian label pada gambar, dua array dibuat untuk menyimpan informasi mengenai gambar dan label dari gambar

tersebut. Array X digunakan untuk menyimpan konten dari sebuah gambar. Array y dibuat untuk memuat label dari gambar tersebut. Untuk setiap

gambar dalam folder yang sama maka akan diberi label yang sama. Contoh array X[0] merupakan array berisi gambar isyarat huruf C maka y[0] berisi angka 2 sebagai label dari gambar tersebut yang ditulis dalam format hot vector (contoh untuk angka 3 : [0,0,1,0, ... , 0,0]) dengan menggunakan fungsi `to_categorical`.

Selanjutnya dilakukan *image reshaping*. Resolusi gambar yang disimpan adalah gambar yang resolusinya telah disesuaikan menggunakan fungsi transformasi `reshape` dari `skimage` dengan n sebesar 64. Setelah data berhasil diberi label, data kemudian dibagi dengan proporsi 0.66 untuk training, 0.22 untuk validation dan 0.12 untuk test. Pembagian dilakukan menggunakan fungsi `train_test_split`.

Hasil training model menggunakan *k-fold cross-validation* dengan k=3 ditunjukkan pada Gambar 5. Tidak ada aturan tertentu mengenai nilai k, umumnya pada angka 5-10. Karena jumlah dataset Bisindo yang digunakan sangat sedikit (2659 gambar), k yang tinggi akan menyebabkan jumlah gambar yang sedikit dalam satu grup dan tidak dapat merepresentasikan data dengan baik, oleh karena itu angka 3 dipilih sebagai k untuk melakukan *k-fold cross-validation*.

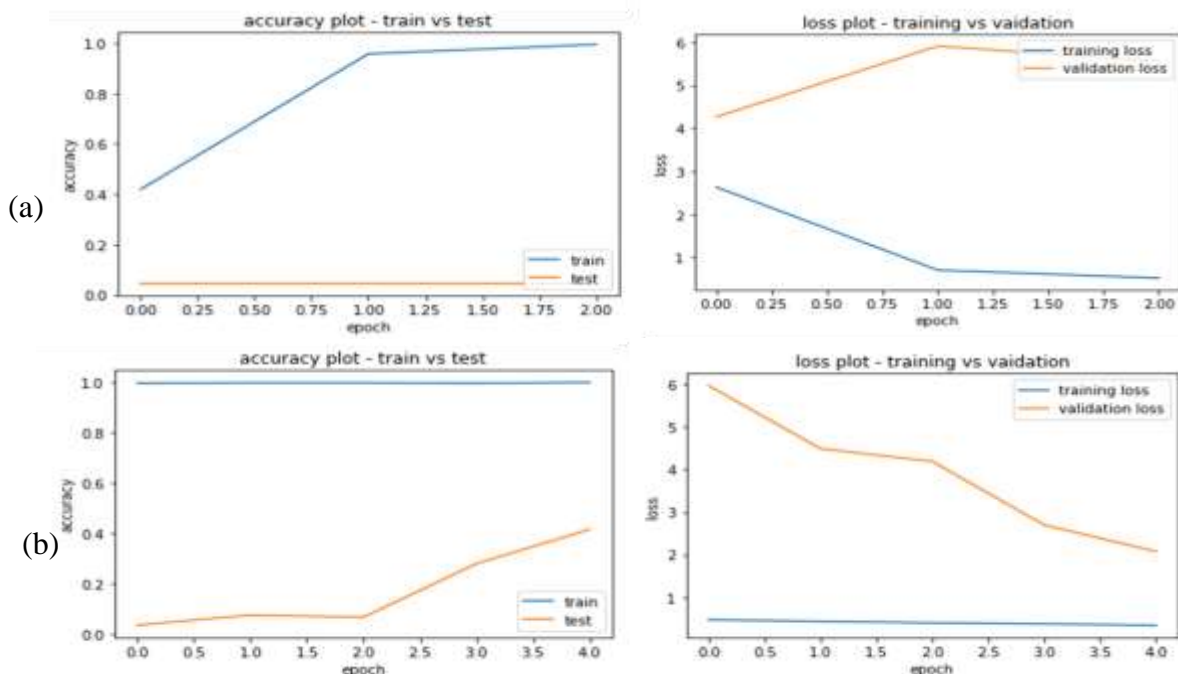
Tabel 1. Rata-rata *loss* dan *accuracy* untuk seluruh *round*

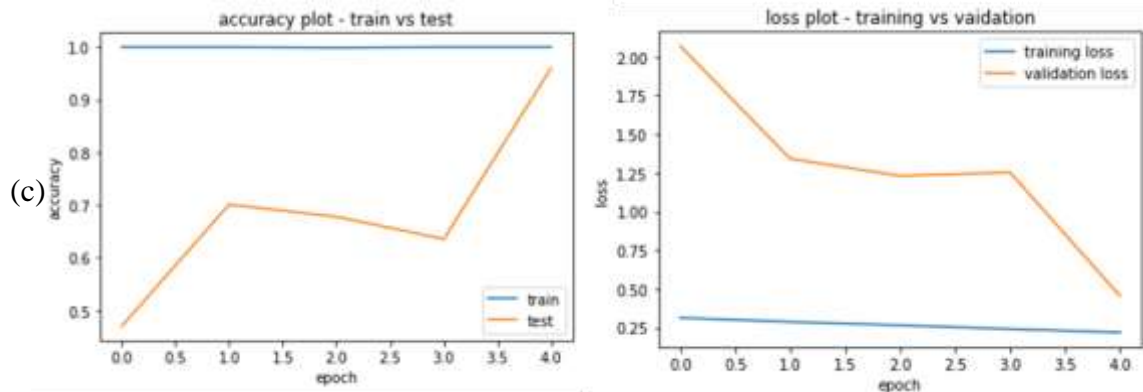
Metriks	Nilai
<i>train_accuracy</i>	0.46846

<i>train_loss</i>	2.71451
<i>val_accuracy</i>	0.47391
<i>val_loss</i>	2.69424

Pada Gambar 5 (a) dapat dilihat bahwa model tidak menghasilkan akurasi yang baik pada validasi dan proses training dihentikan pada *epoch* ke-2 akibat *callback* dari *early stopping*. Pada *round* selanjutnya dapat dilihat melalui Gambar 5 (b) dan 5 (c) *validation loss* berkurang seiring kenaikan *epoch*. Hal ini merupakan indikasi yang baik bagi model. Pada *round* dua dan tiga tidak terjadi *early stopping* sehingga dapat dikatakan bahwa *validation accuracy* mengalami peningkatan pada kedua *round* ini. Setelah melalui tiga *round training*, rata-rata *train* dan *validation accuracy* dari ketiga *round* dihitung untuk mengetahui kinerja rata – rata dari model. Berdasarkan Tabel 1 diperoleh rata – rata hasil akurasi yang tidak terlalu tinggi dikarenakan performa model di *round* pertama masih menghasilkan akurasi yang sangat rendah. Hasil akhir dari Model A yaitu *train accuracy* = 0.46846 dan *validation accuracy* = 0.47391.

Setelah proses *training*, model dievaluasi menggunakan fungsi `model.evaluate()`. Pada fungsi ini, model yang telah di-*training* dievaluasi dengan membandingkan hasil prediksi data test (X_test) dari model dengan label sebenarnya (Y_test). Hasil evaluasi menggunakan dataset testing diukur menggunakan metrik *accuracy*, *loss* dan *F1 score* ditunjukkan pada Tabel 2.





Gambar 5. Grafik akurasi dan *loss* model (a) *round* pertama (b) *round* kedua (c) *round* ketiga

Performa dari model dinilai berdasarkan akurasi saat *training* dan *testing*. Jika dilihat dari F1 score yang dihasilkan, menunjukkan keunggulannya pada test data yang hampir dapat memprediksikan huruf dengan akurat. Adapun huruf yang masih belum dapat diprediksi dengan akurat yaitu huruf O dan R. F1 score dari kedua huruf tersebut berturut-turut sebesar 0.5384 dan 0.6486. Kedua huruf tersebut memiliki F1 score yang kurang akurat dikarenakan minimnya kualitas data hasil sampel dalam pengumpulan data.

Sampel huruf O dikembangkan dengan melakukan augmentasi dari dua gambar asal yang keduanya hampir mirip satu sama lain. Gestur huruf O yang membentuk lingkaran juga mempengaruhi fitur yang terbentuk dari data hasil augmentasi, khususnya rotasi dari gambar asal. Karena huruf O membentuk lingkaran sehingga besar kemungkinan rotasi tidak dapat meningkatkan keberagaman fitur dalam sampel. Sampel huruf R dibuat dari hasil augmentasi gambar-gambar yang menangkap gerakan jentikan jari sebagai isyarat huruf R. Tentunya ketika gerakan jentikan jari disimpan dalam gambar mengakibatkan distribusi dari fitur yang semakin beragam sehingga dengan jumlah hasil augmentasi yang sama dengan kelas yang lain, model tidak dapat mempelajari dengan baik fitur dari huruf R.

Tabel 2. Hasil Evaluasi Model

Metriks	Nilai
<i>evaluation_accuracy</i>	0.9438
<i>evaluation_loss</i>	0.491370
F1 score Kelas A	1
F1 score Kelas B	1
F1 score Kelas C	1
F1 score Kelas D	1
F1 score Kelas E	1
F1 score Kelas F	1
F1 score Kelas G	1
F1 score Kelas H	1
F1 score Kelas I	0.90322581

F1 score Kelas J	0.93333333
F1 score Kelas K	1
F1 score Kelas L	1
F1 score Kelas M	0.95
F1 score Kelas N	0.9
F1 score Kelas O	0.53846154
F1 score Kelas P	1
F1 score Kelas Q	1
F1 score Kelas R	0.64864865
F1 score Kelas S	1
F1 score Kelas T	1
F1 score Kelas U	0.91666667
F1 score Kelas V	1
F1 score Kelas W	1
F1 score Kelas X	1
F1 score Kelas Y	0.96
F1 score Kelas Z	1

Model Bisindo yang menggunakan algoritma CNN dan pendekatan data augmentasi untuk meningkatkan jumlah dataset berhasil mendapatkan performa yang lebih baik dibanding penelitian sebelumnya yang hanya menggunakan 26 data (Handhika et al., 2018). Dengan melakukan data augmentasi, akurasi ini model yang awalnya hanya 30% menggunakan 26 gambar meningkat hingga mencapai 94%.

4. Kesimpulan

Penelitian ini menghasilkan model penerjemah alfabet Bisindo menggunakan implementasi algoritma CNN dengan akurasi 94.38% sebagai upaya untuk meningkatkan aksesibilitas Tuli pengguna Bisindo. Data augmentasi berhasil meningkatkan akurasi model yang menggunakan algoritma yang sama dengan jumlah data yang terbatas. Tanpa melakukan penambahan dataset menggunakan pendekatan data augmentasi, model hanya mencapai 30% akurasi. Luaran dari penelitian ini adalah model penerjemah yang disimpan dalam bentuk .h5. Bentuk ini tidak dapat digunakan secara praktis dalam berkomunikasi sehingga masih perlu dikembangkan dan dikemas dalam bentuk aplikasi agar dapat digunakan secara langsung oleh masyarakat.

Penelitian saat ini hanya terbatas pada menerjemahkan alfabet Bisindo, pengembangan yang mungkin dilakukan dari penelitian ini yaitu memperluas cakupan penerjemahan hingga pada penerjemahan kata dan kalimat. Penerjemahan kata dapat dikembangkan dengan menambah dataset kata. Setelah penerjemahan kata, penerjemahan kalimat dapat dibuat dengan menambahkan arsitektur LSTM dari model hasil penelitian ini.

Referensi

- Abraham Utama. (2015, September 29). *Penyandang Tunarungu Desak Pemerintah Aplikasikan Bisindo*. <https://www.cnnindonesia.com/nasional/20150928095727-20-81295/penyandang-tunarungu-desak-pemerintah-aplikasikan-bisindo>
- Ade Nasihudin Al Ansori. (2020, Oktober 26). *Penyandang Tuli Lebih Suka Menggunakan Bisindo Ketimbang SIBI, Mengapa? - Disabilitas Liputan6.com*. <https://www.liputan6.com/disabilitas/read/4389897/penyandang-tuli-lebih-suka-menggunakan-bisindo-ketimbang-sibi-mengapa>
- Ankile, L. L., Heggland, M. F., & Krange, K. (2020). *Deep Convolutional Neural Networks: A survey of the foundations, selected improvements, and some current applications*. <http://arxiv.org/abs/2011.12960>
- Bheda, V., & Radpour, D. (2017). *Using Deep Convolutional Networks for Gesture Recognition in American Sign Language*. <http://arxiv.org/abs/1710.06836>
- Cheta Nilawaty P, & Rini Kustiani. (2020a, Agustus 20). *Beda Bahasa Isyarat SIBI yang Digunakan Pemerintah dengan Bisindo yang Alami - Difabel Tempo.co*. <https://difabel.tempo.co/read/1377718/beda-bahasa-isyarat-sibi-yang-digunakan-pemerintah-dengan-bisindo-yang-alami>
- Cheta Nilawaty P, & Rini Kustiani. (2020b, Agustus 24). *Alasan Insan Tuli Memilih Bahasa Isyarat Bisindo Ketimbang SIBI - Difabel Tempo.co*. <https://difabel.tempo.co/read/1378989/alasan-insan-tuli-memilih-bahasa-isyarat-bisindo-ketimbang-sibi/full&view=ok>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
- Gumelar, G., Hafiar, H., & Subekti, P. (2018). *Bahasa Isyarat Indonesia Sebagai Budaya Tuli Melalui Pemaknaan Anggota Gerakan Untuk Kesejahteraan Tuna Rungu*. *Informasi*, 48(1), 65.
- Handhika, T., M Zen, R. I., Lestari, D. P., & Sari, I. (2018). *Gesture recognition for Indonesian Sign Language (BISINDO)*. *IOP Conf. Series: Journal of Physics: Conf. Series*, 1028. <https://doi.org/10.1088/1742-6596/1028/1/012173>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). *ImageNet Classification with Deep Convolutional Neural Networks*. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/https://doi.org/10.1145/3065386>
- Li, Z., Yang, W., Peng, S., & Liu, F. (2020). *A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects*. <http://arxiv.org/abs/2004.02806>
- Nair, V., & Hinton, G. E. (2010). *Rectified Linear Units Improve Restricted Boltzmann Machines*. In *undefined*.
- Raschka, S. (2018). *Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning*. <http://arxiv.org/abs/1811.12808>
- Shorten, C., & Khoshgoftaar, T. M. (2019). *A survey on Image Data Augmentation for Deep Learning*. *Journal of Big Data*, 6(1), 1–48. <https://doi.org/10.1186/s40537-019-0197-0>
- Yohanes, J. A., Arjawa, I. G. P. B. S., & Punia, I. N. (2013). *Bahasa Isyarat Indonesia Dalam Proses Interaksi Sosial Tuli dan “Masyarakat Dengar” di Kota Denpasar*. *OJS Unud*, 1–15.
- Zulpicha, E. (2017). *Konflik Kebijakan Penggunaan Sistem Bahasa Isyarat Indonesia di Lingkungan Pendidikan Formal* (Vol. 6, Nomor 1).