



Pengklasifikasian Citra Tulisan Anak melalui Metode CNN sebagai Pendukung Pendeteksian Dini Disgrafia

Rita Wiryasaputra*

Program Studi Informatika, Universitas Kristen Krida Wacana
Jl. Tanjung Duren Raya no. 4, Jakarta 11470, Indonesia
*Email Penulis Koresponden: rita.wiryasaputra@ukrida.ac.id

Abstrak:

Kegiatan menulis dengan tangan tetap eksis walaupun perkembangan teknologi dan digitalisasi mendominasi kehidupan manusia. Adanya korelasi antara beberapa unsur berkomunikasi secara tertulis dengan cara pengoptimalan fungsi otak menjadikan kegiatan menulis tangan termasuk dalam elemen penting dalam pendidikan anak usia dini. Dalam pembelajaran menulis anak usia dini, terkadang sejumlah anak mengalami disgrafia atau gangguan belajar pada pembentukan huruf, spasi, ejaan, dan kecepatan menulis. Anak dan lingkungan keluarga cenderung terintimidasi dan frustasi sebagai dampak gangguan disgrafia yang tidak terdeteksi secara dini. Pemeriksaan disgrafia secara konvensional yang terbatas dalam sisi waktu dan biaya, tidak dapat mengakomodir peningkatan jumlah penderita disgrafia. Mengatasi ketimpangan maka alternatif pendeteksian disgrafia dapat memanfaatkan *Convolutional Neural Network* sebagai subdomain *Deep Learning* yang efektif dalam pengenalan objek citra. Penelitian berfokus pada pengklasifikasian antara citra tulisan tangan anak penderita disgrafia dan bukan penderita disgrafia melalui pembentukan model arsitektur *Convolutional Neural Network*. Model arsitektur *convolution* dibangun dengan 4 lapisan fungsi aktivasi ReLU dan berkomposisi 80% data *training* berbanding 20% data *testing*. Berdasarkan model arsitektur, maka tingkat keakurasian pengklasifikasian mencapai 97% dengan 50 *epoch*. Hal ini mengilustrasikan bahwa alternatif pemeriksaan dini disgrafia sebagai sarana memperbaiki kemampuan komunikasi verbal menulis anak dapat diupayakan melalui pengklasifikasian citra tulisan tangan anak bermodelkan *Convolutional Neural Network*. Dengan demikian, kapasitas maksimal akademik siswa penderita disgrafia dapat dicapai melalui ketepatan bantuan dan dukungan pembelajaran.

This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license



Kata Kunci:

Citra;
Convolutional Neural Network;
Deep learning;
Disgrafia;

Riwayat Artikel:

Diserahkan 13 November 2021
Direvisi 15 Desember 2021
Diterima 20 Desember 2021
Dipublikasi 31 Desember 2021

DOI:

10.22441/incomtech.v11i3.13769

1. PENDAHULUAN

Unsur kognitif, perseptual, konsentrasi, linguistik dan ketrampilan motorik halus merupakan serangkaian unsur yang cukup kompleks dalam kegiatan menulis dengan tangan, dan kegiatan ini tetap eksis walaupun perkembangan teknologi dan digitalisasi mendominasi kehidupan manusia. Adanya korelasi antara beberapa unsur berkomunikasi secara tertulis dengan cara pengoptimalan fungsi otak menjadikan kegiatan menulis tangan termasuk dalam elemen penting dalam pendidikan anak usia dini [1]. Tidak ada perbedaan yang signifikan antara pembelajaran menulis di sekolah umum bagi siswa penderita disgrafia dengan non disgrafia, karena faktor tingkat kecerdasan tidak mempengaruhi gangguan disgrafia. Gangguan disgrafia mempengaruhi ekspresi tertulis dari simbol maupun kata-kata [2]. Gangguan disgrafia meliputi kesulitan dalam membentuk huruf, spasi, ejaan, dan kecepatan menulis. Tulisan tangan tidak jelas, tidak teratur dan tidak konsisten merupakan karakteristik tulisan tangan penderita disgrafia. Di samping itu pula, penderita disgrafia cenderung kesulitan memilih kata yang akan digunakan. Durasi waktu dan materi yang ditulis dalam proses menulis dapat menjadi parameter pengukur yang membedakan antara anak penderita disgrafia dengan non disgrafia. Beberapa kategori disgrafia yaitu disgrafia *dyslexic*, disgrafia *spatial*, dan disgrafia motorik. Disgrafia *dyslexic* dimana tulisan tidak terbaca ketika diproduksi secara spontanitas saat menduplikasi teks yang tersedia, sedangkan disgrafia *spatial* merupakan gangguan pada pemahaman spasi dan tulisan yang dikarakterisasi sebagai tulisan yang tidak layak walaupun kecepatan menulis tergolong normal saat diproduksi secara langsung maupun menyalin. Disgrafia motorik dimana terjadi gangguan motorik karena tidak dapat terbacanya teks yang ditulis secara spontan dan disalin dimana kecepatan penulisan abnormal [3]. Penelitian yang dilakukan oleh Sihwi menggradasikan disgrafia ke dalam 3 (tiga) gradasi yaitu ringan, sedang dan berat. Gradasi disgrafia ringan dilihat dari sudut pandang cara memegang alat tulis, ketidak idealan komposisi ukuran huruf, ketidak tegasan penulisan huruf. Lambatnya proses menulis menandakan anak menderita disgrafia tingkat sedang, sedangkan anak penderita disgrafia tingkat berat seringkali mengalami kelelahan dalam menulis [4]. Ditinjau dari jumlah penderita disgrafia, maka sekitar 5% hingga 30% anak di usia masa sekolah diperkirakan menderita disgrafia [5, 6]. Untuk di belahan dunia Eropa khususnya negara Jerman, ternyata lebih dari 17% jumlah anak sekolahnya menderita kesulitan membaca dan menulis [7]. Untuk belahan dunia Asia, diteliti bahwa penderita gangguan belajar pada negara Malaysia mengalami kenaikan yang cukup signifikan setiap tahun, dimana dari 1,679 penderita pada tahun 2014 menjadi 10,329 penderita pada tahun 2017 [8]. Peningkatan jumlah penderita disgrafia ini tidak selaras dengan hasil pemeriksaan gejala disgrafia dan penanganannya. Kecenderungan gangguan penulisan terjadi pada anak usia sekolah berjenis kelamin pria dan biasanya asesmen yang dilakukan pada klinik berkecenderungan kualitatif dan didasari oleh evaluasi pengamatan tim pemeriksa [9,10]. Adanya kebutuhan waktu yang relatif lama dalam pemeriksaan gejala disgrafia melalui *screening test* metode konvensional oleh ahli disleksia [11]. Anak dan keluarganya mengalami kecenderungan terintimidasi dan frustrasi sebagai dampak dari tidak

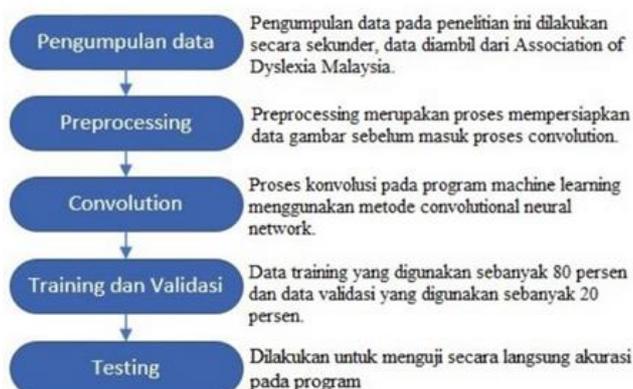
terdeteksinya gangguan disgrafia secara dini. Melihat fenomena ini, maka solusi pendeteksian atas gangguan disgrafia perlu dicari mendalam.

Pesatnya perkembangan teknologi kecerdasan buatan tercermin dengan maraknya penelitian-penelitian dan aplikasi bidang kesehatan yang didasari oleh kecerdasan buatan khususnya *Deep Learning*. Performansi aktifitas tulisan tangan dapat dipergunakan sebagai media pendiagnosaan dini suatu penyakit. Pendeteksian dini penyakit Parkinson melalui beragam *dataset* tulisan tangan pasien Parkinson yang telah diaugmentasi dengan beberapa teknik yaitu kontras, *flipping*, rotasi, *thresholding*, dan iluminasi berarsitektur CNN mencapai tingkat akurasi diatas 90% [12]. Berdasarkan hal tersebut, maka teknik augmentasi seperti rotasi digunakan pada penelitian yang diusulkan berobjek disgrafia ini. Pendeteksian disgrafia dapat dibantu dengan teknologi *Graphic Processing Unit* (GPU) sebagai salah satu teknologi yang mempengaruhi penilaian tingkat akurasi model jaringan saraf tiruan *Deep Learning*. Salah satu subdomain *Deep Learning* adalah *Convolutional Neural Network* (CNN), terkadang dikenal dengan nama *ConvNets* yang merupakan tipe model penganalisaan citra terefisien, baik dalam pengenalan pola dan segmentasi citra, terlebih dalam ketepatannya pada citra medik [13, 14]. Hal ini disebabkan karena pengembangan metode *Multi Layer Perceptron* (MLP) berupa *pooling layer*, *dense layer*, dan *fully connected layer* dan pemrosesan data bertopologi menyerupai grid pada *Convolutional Neural Network* (CNN) diimplementasikan berdasarkan sistem pengenalan citra pada *visual cortex* manusia [15]. Untuk mempermudah pengklasifikasian, maka pada lapisan konvolusi CNN akan timbul pola dari beberapa bagian citra berdasarkan citra yang dimasukkan [16]. Penelitian yang diusulkan akan menggunakan *fully connected layer* dan 4 (empat) lapisan konvolusi agar pengklasifikasian dapat lebih transparan. Penelitian yang dilakukan Drotar, mendeteksi disgrafia dengan menggunakan *machine learning* khususnya algoritma *Adaptive Boosting* (AdaBoost) menghasilkan tingkat akurasi mendekati 80% pada 120 orang anak berusia 8 (delapan) hingga 15 (lima belas) tahun tanpa memandang perbedaan usia, jenis kelamin dan penggunaan tangan kiri/kanan, 1176 fitur terproduksi dengan fungsi *non linear* sebagai model pendeteksian. Dimana pada penelitian tersebut, cara pengumpulan data adalah dengan meminta anak untuk menuliskan langsung pada layar *smartphone* dimana menimbulkan perbedaan pengaturan daripada penulisan langsung. Dampaknya adalah keterbatasan penelitian dengan jumlah data yang dimiliki tidak memadai dalam menjalankan klasifikasi pada *deep neural network* [17]. Hasil akurasi sebesar 90% diperoleh pada penelitian data dinamik pendeteksian disgrafia dengan *time-frame* pada model *Recurrent Neural Network* (RNN), dimana anak disgrafia diperiksa secara langsung dengan menggunakan *Evaluation Scale for Children's Handwriting BHK* bermedia Wacom tablet berukuran A5. Jika model RNN diterapkan dengan media digital lain selain Wacom, maka terdapat perbedaan nilai pengukuran akurasi [1]. Tingkat akurasi sebesar 72,23% diperoleh pada penelitian disleksia melalui metode CNN dengan representasi gambar 3D fMRI pada 55 otak anak yang sedang mengerjakan tugas [13]. Penelitian yang dilakukan oleh Sihwi dengan keterbatasan data tulisan tangan anak dapat mengidentifikasi gangguan disgrafia kedalam 4 (empat) kelas yaitu *normal*, *light*, *moderate*, dan *severe* dengan penggunaan metode *Support Vector Machine*. Dalam penelitian tersebut, anak diminta untuk menulis pada media layar *smartphone* Android langsung, adapun kendala yang dihadapi adalah ketidakakuratan klasifikasi ketika membandingkan

antara bentuk tulisan di kertas dengan bentuk tulisan langsung pada media *smartphone* android dimana layar *smartphone* cenderung licin [4]. Memandang sudut perspektif gangguan disgrafia dapat mempengaruhi tumbuh kembang anak dan gangguan tersebut dapat dipantau dari usia dini, maka penggunaan CNN pada penelitian Pallawi berfungsi ekstraksi dan menstabilisasi gangguan gerak saat merekonstruksi dan menyimpulkan ciri penggambaran dengan standarisasi Google Draw [18]. Penelitian yang dilakukan Ortac menyatakan bahwa 2-dimensi metode *Convolutional Neural Networks* dapat meliputi bidang *computer vision*, *image processing*, *image classification*, *object detection* dan estimasi mendalam dari citra tunggal. Penggunaan model CNN karena karakteristik penting dari model tersebut yang mampu mengekstraksi atribut secara langsung dari pemasukkan data awal [16]. Berdasarkan teknik pengambilan data, maka *dataset* pada penelitian ini menggunakan data statik sekunder berdimensi 2 sehingga keterbatasan data dapat ditanggulangi. Dalam lingkup *neural network* khususnya *Artificial Neural Network* (ANN), penelitian pendeteksian yang dikerjakan oleh Isa, mencapai nilai maksimum akurasi sebesar 70,83% dengan 4 lapisan *hidden* untuk mengklasifikasi penderita disleksia dalam 2 (dua) jenis tingkat resiko disgrafia yaitu rendah dan beresiko. Variasi rasio data *training*:*data validasi*:*data testing* sebesar 80%:10%:10% dibagi dalam objek disgrafia. Idealnya ANN memiliki range akurasi yang baik pada 80%-100% [9]. Tingginya tingkat akurasi (dengan rata-rata diatas 90%) merupakan karakteristik dari penelitian-penelitian pengenalan citra bermetode CNN [19]. Guna mencapai peningkatan akurasi yang lebih baik, maka penelitian pengklasifikasian citra 2D tulisan tangan yang diusulkan mengeksplorasi model arsitektur CNN berlapis 4 dengan pembagian *dataset* menjadi 2 kategori dan berfokus pada huruf abjad yang sering salah ditulis oleh siswa disgrafia berumur 7 hingga 12 tahun. Harapannya model arsitektur CNN usulan ini dapat dimanfaatkan untuk membantu pemeriksaan asesor dalam pendeteksian dini disgrafia karena pengklasifikasian antara anak penderita disgrafia dan non disgrafia melalui citra tulisan tangan sudah diproses dengan bantuan teknologi.

2. METODE

Beberapa strategi yang mencakup 4 (empat) tahap besar, pada Gambar 1 merupakan ilustrasi tahapan metodologi penelitian.



Gambar 1. Metodologi Penelitian

2.1 Pengumpulan Data

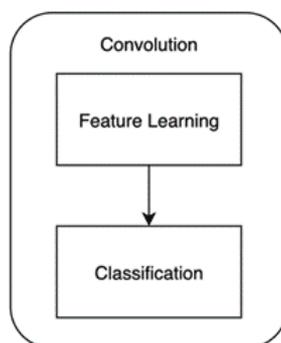
Pada proses pengumpulan data, maka langkah pertamanya adalah dengan menyusun dan melabelkan data sekunder [11] berupa data citra 2 dimensi berwarna hitam putih yang diambil melalui media *Optical Character Recognition* (OCR). Terdapat 200 data gambar tulisan tangan (citra) anak sekolah dasar berusia 7 (tujuh) hingga 12 (duabelas) tahun, dengan total 30 orang anak baik non disgrafia maupun disgrafia, tanpa memandang jenis kelamin, berfokus pada huruf yang sering salah ditulis oleh anak yaitu pada huruf b, huruf c, huruf f, huruf p.

2.2 Preprocessing

Tahap selanjutnya merupakan tahap preprocessing yaitu proses mempersiapkan data citra sebelum memasuki proses *convolution*. Terdapat 4 (empat) langkah yaitu merubah skala data citra, memutar citra, menggeser sudut citra, dan mengisi citra. Secara standar, maka skala data citra diatur menjadi 1/255 dimana nilai *input* masukkan bernilai 0 hingga 255. Nilai *input* masukkan bernilai 1 menandakan skala data citra diatur ulang, sedangkan *input* masukkan 0 berarti tidak ada pengaturan skala ulang. Setelah perubahan skala, maka citra diputar dalam 2 arah yaitu horizontal maupun vertikal sebanyak 20 derajat. Pergeseran sebesar 0,2 derajat juga dilakukan pada sudut citra. Langkah terakhir adalah dengan mengisi mode citra secara default dengan citra terdekat.

2.3 Convolution

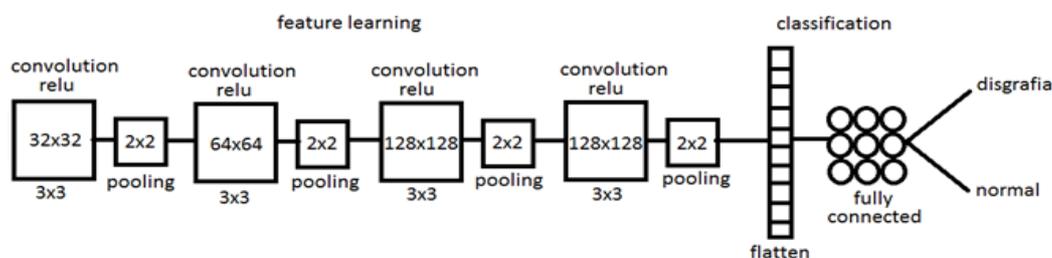
Secara garis besar proses *convolution* terdiri dari dua lapisan utama yaitu *feature learning* dan *classification*. Ditunjukkan pada Gambar 2.



Gambar 2. Convolution

Input berubah menjadi *feature* yang direpresentasikan dalam bentuk angka-angka vektor merupakan fungsi *Feature learning*. Lapisan pada *feature learning* terdiri dari: *Convolution Process*, *Activation Function*, *Pooling Process*. *Convolution Process* merupakan proses mengekstraksi objek citra input dengan sebuah kernel dengan ukuran tertentu. Jumlah kernel akan bergantung dari jumlah fitur yang dihasilkan. Selanjutnya *Activation Function* yang dapat berupa fungsi ReLU atau fungsi Sigmoid. Dalam penelitian ini parameter default diubah melalui fungsi ReLU dan dampaknya toleransi nilai ambang dapat menjadi bukan-nol, perubahan nilai aktivasi menjadi maksimum, serta penggunaan kelipatan bukan-nol dari input untuk nilai-nilai di bawah ambang batas. Sedangkan nilai antara 0 dan 1 akan dikembalikan oleh fungsi sigmoid. Adapun lapisan terakhir pada *Feature*

Learning adalah *Pooling Process*, lapisan ini digunakan untuk mengurangi *noise* yang ada dalam citra, sehingga mempercepat komputasi. *Pooling* yang biasa digunakan adalah *max pooling* dan *average pooling*. *Max pooling* untuk menentukan nilai maksimum tiap pergeseran filter, sementara *average pooling* akan menentukan nilai rata-ratanya. Model arsitektur CNN yang ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur *Convolution*

2.4 Training dan Validasi

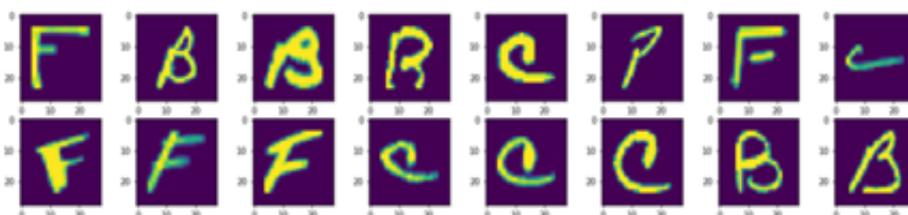
Proses *training* dan validasi data dilakukan dengan 2 kriteria pengujian. Pengujian pertama adalah keoptimalan untuk mengetahui banyak nilai *epoch* ideal untuk dipergunakan, selanjutnya adalah menguji seberapa banyak pelatihan dan validasi yang digunakan. *Epoch* merupakan momentum dalam satu putaran seluruh kumpulan data telah melalui proses pelatihan *neural network* bolak balik yaitu dari titik awal hingga titik akhir, lalu dikembalikan ke awal lagi.

2.5 Testing

Beberapa citra dipilih secara random dan diunggah satu per satu merupakan cara yang dilakukan pada tahap pengujian, dan selanjutnya sistem akan menyeleksi apakah citra terpilih merupakan kategori disgrafia atau non disgrafia.

3. HASIL DAN PEMBAHASAN

Dataset diunggah ke dalam Google Drive sebagai media penyimpanan yang digunakan. Citra dibagi kedalam 2 (dua) segmentasi yaitu disgrafia dan non disgrafia. Citra yang disegmentasi berupa 4 (empat) jenis citra huruf yang sulit diidentifikasi oleh penderita disgrafia seperti ditunjukkan pada Gambar 4. Agar terjadi kehomogenan maka pada setiap citra berukuran 28x28 pixel yang akan dilatih dengan citra yang akan divalidasi diubah secara *default* menjadi 150x150 pixel. Perubahan citra ini melalui beberapa proses yaitu *rescale*, *rotation range*, *horizontal flip*, *shear range* dan *fill mode*.



Gambar 4. Citra tulisan tangan

Framework Tensorflow dan penggunaan Keras sebagai *high level API* Tensorflow dipergunakan dalam implementasi penelitian. *Convolutional layer* yang digunakan adalah 4 (empat) lapisan yang terdiri dari 32x32, 64x64, 128x128, 128x128 dengan fitur ukuran kernel 3x3. Adapun fungsi aktivasi yang dipergunakan adalah *Rectified Linear Unit (ReLU)*, dimana *vanishing gradient* dihilangkan melalui fungsi aktivasi ini. Sebelum citra memasuki lapisan *flatten*, maka citra disaring melalui lapisan *max pooling* berukuran 2x2 sehingga nantinya citra yang dihasilkan menjadi rata.

Kompilasi konvolusi dilakukan untuk mengaktifkan pemrosesan konvolusi yang telah dilakukan sebelumnya. *Binary crossentropy* dipilih berlandaskan latar bahwa penelitian menggunakan dua objek citra yaitu citra tulisan anak disgrafia dan citra tulisan anak non disgrafia. Pada lapisan *dense*, proses *fully connected* terimplementasi dengan 512 neuron. Dalam pencarian akurasi, maka nilai *epoch* ideal diselidiki melalui perbandingan rasio antara data *training* dengan data *testing* yaitu 80%:20%.

Dari hasil uji coba ([Tabel 1](#)) dengan beberapa *epoch* diperoleh nilai akurasi pelatihan dan nilai akurasi validasi terbaik pada penggunaan *epoch* 50, dimana nilai akurasi dari pelatihan adalah sebesar 95% dan tingkat akurasi validasinya adalah 100%. Dengan demikian, maka selanjutnya *epoch* yang digunakan adalah 50. Berdasarkan nilai *epoch* yang diperoleh, maka persentase akurasi dapat ditentukan berdasarkan nilai komparatif antara training dan validasi.

Tabel 1. Nilai Epoch ideal

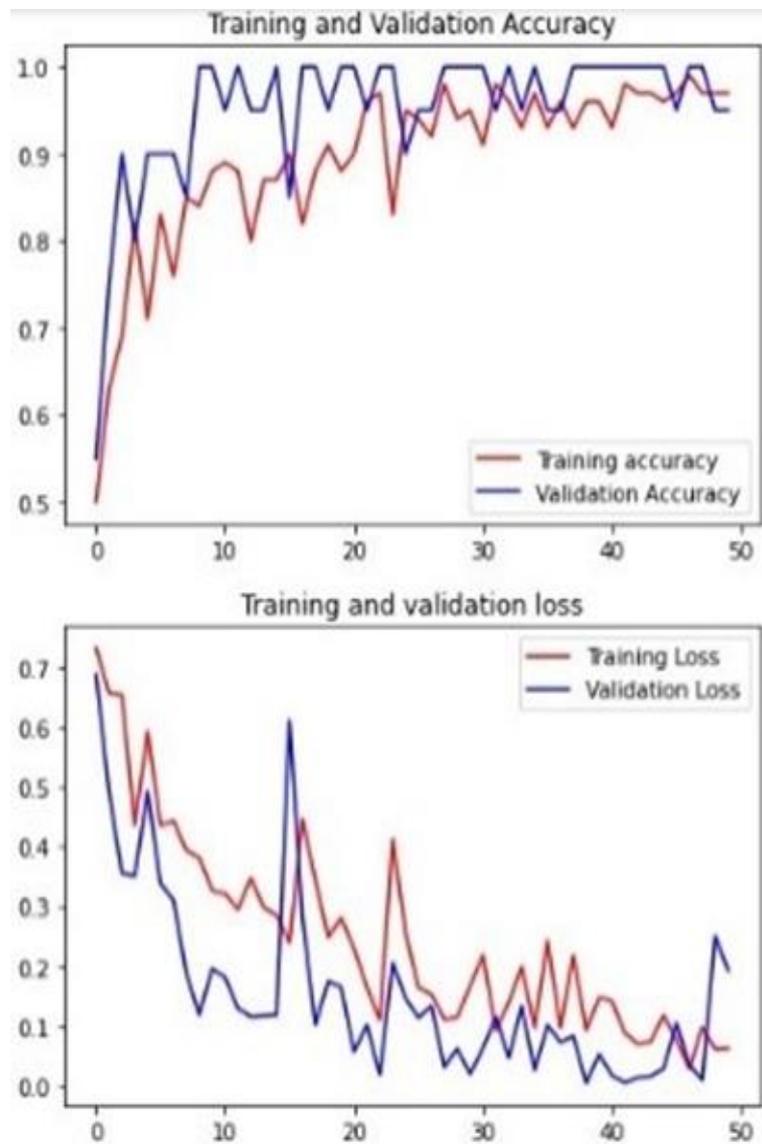
<i>Epoch Used</i>	<i>Accuracy of Training</i>	<i>Validation Accuracy</i>
10	80%	90%
20	94%	100%
30	91%	90%
40	97%	90%
50	95%	100%

Pada [Tabel 2](#), komposisi data training: data validasi sebesar 70%:30% atau 80%:20% menghasilkan nilai akurasi optimal, dimana terdapat kesamaan hasil persentase akurasi pelatihan (97%) dan akurasi validasi (95%) pada kedua rasio tersebut. Tingkat akurasi dan kesalahan divisualisasikan pada [Gambar 5](#) dimana untuk grafik nilai akurasi validasi rata-rata berada di atas 90%, sedangkan untuk nilai kegagalan validasi rata-rata berada dibawah nilai kegagalan training.

Pengujian terhadap keakurasian klasifikasi dilakukan, dari 8 buah citra baik huruf b, huruf c, huruf f dan huruf p masing-masing diunggah secara acak. Citra terpilih tersebut diseleksi oleh sistem dan digolongkan untuk citra berkategori disgrafia atau citra berkategori non disgrafia. [Tabel 3](#) merupakan hasil proses pendeteksian citra, dimana 4 buah citra yang sudah tersusun terklasifikasi normal atau 4 buah citra terklasifikasi disgrafia.

Tabel 2. Persentase tingkat akurasi

Data		Accuracy	
Train	Validation	Train	Validation
50%	50%	99%	80%
60%	40%	99%	80%
70%	30%	97%	95%
80%	20%	97%	95%
90%	10%	96%	95%



Gambar 5. Grafik akurasi dan kesalahan

Tabel 3. Hasil Pendeteksian Citra

<i>Image Code</i>	<i>Dysgraphic Image</i>	<i>Information</i>
B-457		<i>Dysgraphic</i>
C-115		<i>Dysgraphic</i>
F-213		<i>Dysgraphic</i>
P-475		<i>Dysgraphic</i>
B-11		Normal
C-129		Normal
F-218		Normal
P-483		Normal

4. KESIMPULAN

Klasifikasi citra tulisan tangan penderita disgrafia dengan non disgrafia berakurasi sebesar 97% untuk pola tulisan tangan 2D terimplementasi melalui pendekatan 4 lapisan *convolution* yang berkoneksi secara penuh pada arsitektur model CNN berbasis data *training*: data *testing* yaitu 80%:20% untuk 50 *epoch*. Asesor dapat terbantu dalam mengevaluasi dini anak penderita disgrafia, sehingga anak dapat dibantu dan kemampuan komunikasi verbal menuliskannya dapat diperbaiki. Kapasitas maksimal akademik siswa penderita disgrafia dapat dicapai melalui ketepatan bantuan dan dukungan pembelajaran.

REFERENSI

- [1] K. Zolna, T. Asselborn, C. Jolly, L. Casteran, W. Johal, and P. Dillenbourg "The Dynamics of Handwriting Improves the Automated Diagnosis of Dysgraphia," *arXiv preprint arXiv:1906.07576*, 2019.
- [2] P. Drotár and M. Dobeš, "Dysgraphia detection through machine learning," *Sci. Rep.*, vol. 10, no. 1, Dec. 2020, doi: 10.1038/s41598-020-78611-9.
- [3] T. Asselborn *et al.*, "Automated human-level diagnosis of dysgraphia using a consumer tablet," *npj Digit. Med.*, vol. 1, no. 1, p. 42, 2018, doi: 10.1038/s41746-018-0049-x.
- [4] S. W. Sihwi, K. Fikri, and A. Aziz, "Dysgraphia Identification from Handwriting with Support Vector Machine Method," *J. Phys. Conf. Ser.*, vol. 1201, p. 012050, May 2019, doi: 10.1088/1742-6596/1201/1/012050.
- [5] R. Kariyawasam, M. Nadeeshani, T. Hamid, I. Subasinghe and P. Ratnayake, "A Gamified Approach for Screening and Intervention of Dyslexia, Dysgraphia and Dyscalculia," 2019 *International Conference on Advancements in Computing (ICAC)*, 2019, pp. 156-161, doi: 10.1109/ICAC49085.2019.9103336.

- [6] R. Kariyawasam, M. Nadeeshani, T. Hamid, I. Subasinghe, P. Samarasinghe and P. Ratnayake, "Pubudu: Deep Learning Based Screening And Intervention of Dyslexia, Dysgraphia And Dyscalculia," *2019 14th Conference on Industrial and Information Systems (ICIIS)*, 2019, pp. 476-481, doi: 10.1109/ICIIS47346.2019.9063301.
- [7] D. Döhla and S. Heim, "Developmental Dyslexia and Dysgraphia: What can We Learn from the One About the Other?," *Front. Psychol.*, vol. 6, Jan. 2016, doi: 10.3389/fpsyg.2015.02045.
- [8] A. Z. A. Zainuddin, K. Y. Lee, W. Mansor and Z. Mahmoodin, "Extreme Learning Machine for Distinction of EEG Signal Pattern of Dyslexic Children in Writing," *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, 2018, pp. 652-656, doi: 10.1109/IECBES.2018.8626700.
- [9] M. Galli, V. Cimolin, G. Stella, M. F. De Pandis, A. Ancillao, and C. Condoluci, "Quantitative assessment of drawing tests in children with dyslexia and dysgraphia," *Hum. Mov. Sci.*, vol. 65, no. March 2018, pp. 51–59, 2019, doi: 10.1016/j.humov.2018.05.001.
- [10] P. J. Chung, D. R. Patel, and I. Nizami, "Disorder of written expression and dysgraphia: definition, diagnosis, and management," *Transl. Pediatr.*, vol. 9, no. S1, pp. S46–S54, Feb. 2020, doi: 10.21037/tp.2019.11.01.
- [11] I. S. Isa, W. N. Syazwani Rahimi, S. A. Ramlan, and S. N. Sulaiman, "Automated Detection of Dyslexia Symptom Based on Handwriting Image for Primary School Children," in *Procedia Computer Science*, 2019, vol. 163, doi: 10.1016/j.procs.2019.12.127.
- [12] I. Kamran, S. Naz, I. Razzak, and M. Imran, "Handwriting dynamics assessment using deep neural network for early identification of Parkinson's disease," *Futur. Gener. Comput. Syst.*, vol. 117, pp. 234–244, 2021, doi: 10.1016/j.future.2020.11.020.
- [13] S. Zahia, B. Garcia-Zapirain, I. Saralegui, and B. Fernandez-Ruanova, "Dyslexia detection using 3D convolutional neural networks and functional magnetic resonance imaging," *Comput. Methods Programs Biomed.*, vol. 197, p. 105726, Dec. 2020, doi: 10.1016/j.cmpb.2020.105726.
- [14] Felix, J. Wijaya, S. P. Sutra, P. W. Kosasih, and P. Sirait, "Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun," *J. SIFO Mikroskil*, vol. 21, no. 1, 2020.
- [15] K. H. Mahmud, Adiwijaya, and S. Al Faraby, "Klasifikasi Citra Multi-Kelas Menggunakan Convolutional Neural Network," *e-Proceeding Eng.*, vol. 6, no. 1, pp. 2127–2136, 2019.
- [16] G. Ortac and G. Ozcan, "Comparative study of hyperspectral image classification by multidimensional Convolutional Neural Network approaches to improve accuracy," *Expert Syst. Appl.*, vol. 182, no. June 2020, p. 115280, 2021, doi: 10.1016/j.eswa.2021.115280.
- [17] P. Drotár and M. Dobeš, "Dysgraphia detection through machine learning," *Sci. Rep.*, vol. 10, no. 1, pp. 1–11, 2020, doi: 10.1038/s41598-020-78611-9.
- [18] S. Pallavi, A. Kumar, and A. Ankur, "Suggestive GAN for supporting Dysgraphic drawing skills," *IAES Int. J. Artif. Intell.*, vol. 8, no. 2, Jun. 2019, doi: 10.11591/ijai.v8.i2.pp132-143.
- [19] R. Valentina, S. Rostianingsih, A. N. Tjondrowiguno, and J. S. Surabaya, "Pengenalan Gambar Botol Plastik dan Kaleng Minuman Menggunakan Metode Convolutional Neural Network," *J. Infra*, vol. 8, no. 1, 2020.