

ANALISIS EFISIENSI CNN DAN RNN DALAM KLASIFIKASI DOWN SYNDROME PADA USIA BALITA

1st Alfiansyah Ramadan
S1 Teknik Telekomunikasi
Universitas Telkom Purwokerto
Purwoketo, Indonesia
21101073@ittelkom-pwt.ac.id

2nd Naufal Khairul Luthfi
S1 Teknik Telekomunikasi
Universitas Telkom Purwokerto)
Purwoketo, Indonesia
21101097@ittelkom-pwt.ac.id

3rd Muhammad Rifqi Althaaf
S1 Teknik Telekomunikasi
Universitas Telkom Purwokerto)
Purwoketo, Indonesia
21101070@ittelkom-pwt.ac.id

4th Dadiek Pradana, S.T.,M.T.
S1 Teknik Telekomunikasi
Universitas Telkom Purwokerto
Purwoketo, Indonesia
Dadiek@ittelkom-pwt.ac.id

5th Zein Hanni Pradana
S1 Teknik Telekomunikasi
Universitas Telkom Purwokerto
Purwoketo, Indonesia
Zeindana@ittelkom-pwt.ac.id

Abstrak — Perkembangan teknologi kecerdasan buatan, khususnya *machine learning*, telah membuka peluang baru dalam bidang kesehatan, termasuk diagnosis dini *Down syndrome* pada balita. Penelitian ini bertujuan menganalisis efisiensi dua model *deep learning*, yaitu *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN), dalam mengklasifikasikan *Down syndrome* berdasarkan citra wajah. Metode yang digunakan meliputi pengumpulan data, pra-pemrosesan citra, pelatihan model, dan evaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan F1-score. Hasil penelitian menunjukkan bahwa CNN mencapai akurasi lebih tinggi (0.9383 pada data pelatihan), namun memiliki keterbatasan dalam mendeteksi kasus positif (*precision* 0.6772, *recall* 0.7044). Sementara itu, RNN menunjukkan kinerja lebih baik dalam mendeteksi *Down syndrome* (*recall* 0.9571, F1-score 0.8724), meskipun akurasinya lebih rendah (0.7757). Pada tahap validasi dan pengujian, RNN tetap unggul dalam *recall* (0.9832 dan 0.9928), menjadikannya lebih cocok untuk aplikasi medis yang memprioritaskan deteksi kasus positif. Penelitian ini menyimpulkan bahwa pemilihan model tergantung pada kebutuhan: CNN untuk akurasi umum, sedangkan RNN untuk deteksi komprehensif dengan risiko *false negative* minimal. Temuan ini memberikan kontribusi penting bagi pengembangan sistem diagnosis berbasis AI yang lebih akurat dan efisien.

Kata kunci— *Down syndrome*, CNN, RNN, klasifikasi citra, *machine learning*

I. PENDAHULUAN

Perkembangan pesat teknologi informasi dan kecerdasan buatan (AI), khususnya *machine learning*, telah mentransformasi sektor kesehatan[1]. Salah satu metode AI yang efektif adalah *Convolutional Neural Network* (CNN), yang terbukti mampu mengidentifikasi pola visual secara otomatis. CNN telah sukses diaplikasikan dalam deteksi penyakit kulit, kelainan mata, dan tumor otak. Kini, CNN juga mulai digunakan untuk klasifikasi wajah berbasis citra digital guna mendiagnosis kondisi medis seperti *Down syndrome*. [2]. *Down syndrome* adalah kelainan genetik paling umum akibat trisomi kromosom 21 (kelebihan satu salinan kromosom 21)[3]. Kondisi ini menyebabkan

gangguan perkembangan mental dan fisik, dengan ciri khas seperti wajah datar, mata sipit miring ke atas, hidung pesek, mulut kecil, serta jari tangan pendek dan lebar. Selain itu, otak penderita *Down syndrome* menunjukkan anomali struktural dan fungsional dalam morfogenesis. [3]. Dalam konteks yang lebih spesifik, klasifikasi wajah berbasis citra digital kini mulai dilirik sebagai pendekatan non-invasif untuk membantu proses diagnosis berbagai kondisi medis, salah satunya adalah *Down syndrome* [4] Penyebab *Down syndrome* meliputi infeksi virus teratogenik, paparan radiasi, dan penuaan sel telur ibu. Kondisi ini memengaruhi perkembangan fisik dan kognitif anak dengan tingkat keparahan bervariasi. Deteksi dini sangat krusial untuk perencanaan perawatan, tetapi diagnosis awal sering tidak pasti karena ciri-ciri fisik pada bayi/balita mungkin belum jelas atau mirip dengan kondisi lain, menimbulkan kebingungan dan kecemasan bagi orang tua. [5]. Ketidakjelasan ciri fisik *Down syndrome* pada tahap awal kehidupan (terutama bayi dan balita) menyulitkan diagnosis. Hal ini dapat menyebabkan keterlambatan intervensi medis dan psikologis, sehingga pendekatan berbasis AI seperti CNN diharapkan dapat meningkatkan akurasi deteksi dini[6].

II. KAJIAN TEORI

Penelitian ini mengembangkan sistem klasifikasi wajah anak ke dalam tiga kategori, yaitu *Down syndrome* jenis mosaik, trisomi 21, dan normal, yang lebih rinci dibandingkan penelitian sebelumnya yang hanya membedakan antara *Down syndrome* dan normal. Metode yang digunakan meliputi lima tahap pengolahan citra: pre-processing (*grayscale* dan peningkatan kontras), segmentasi dengan filter Gabor, ekstraksi fitur menggunakan invariant moment, dan klasifikasi dengan *Probabilistic Neural Network* (PNN). Hasil pengujian terhadap 22 data citra menunjukkan akurasi mencapai 91%, dengan rata-rata *recall* dan *precision* masing-masing 88%. Temuan ini membuktikan efektivitas metode tersebut dalam identifikasi awal jenis *Down syndrome* secara lebih detail. [7].

Penelitian ini mengevaluasi kinerja teknologi AI dalam sistem keamanan berbasis deteksi wajah, dengan fokus pada akurasi, kecepatan pemrosesan, dan ketahanan terhadap

tantangan seperti perubahan pencahayaan atau sudut pandang. Beberapa model CNN, termasuk *VGG-Face*, *FaceNet*, dan *MTCNN*, diuji menggunakan dataset gabungan publik dan internal. Hasilnya, *MTCNN* menonjol dalam hal akurasi dan kecepatan pemrosesan real-time, meskipun masih rentan terhadap manipulasi video berkualitas tinggi. Prototipe yang dikembangkan berhasil bekerja dengan cepat dan akurat, tetapi memerlukan peningkatan keamanan untuk mengatasi celah manipulasi[8].

Penelitian ini bertujuan menggantikan sistem akses konvensional seperti kartu dengan teknologi pengenalan wajah berbasis *deep learning*. Sistem ini dikembangkan menggunakan bahasa *Python* dan *framework* TensorFlow, dengan pelatihan pada 350 data foto dari 5 pegawai. Implementasi dilakukan pada perangkat keras sederhana seperti Raspberry Pi 4 yang terhubung ke kunci pintu. Hasil pengujian menunjukkan akurasi mencapai 95%, dan setelah perbaikan kualitas data, akurasi bahkan meningkat hingga 100%. Sistem ini mampu mengidentifikasi wajah terdaftar untuk memberikan akses, sementara wajah tidak dikenal ditandai sebagai "UNKNOWN", membuktikan efektivitasnya dalam meningkatkan keamanan dan efisiensi[9].

A. Down syndrome

Down syndrome merupakan suatu kondisi yang ditandai dengan keterlambatan perkembangan fisik dan mental, yang disebabkan oleh kelainan pada jumlah kromosom. Kondisi ini terjadi karena adanya gangguan pada proses pembelahan sel, di mana sepasang kromosom gagal berpisah secara normal. Akibatnya, individu dengan *Down syndrome* memiliki 47 kromosom dalam setiap sel tubuhnya, sementara jumlah kromosom normal pada manusia adalah 46

B. Karakteristik Down syndrome

Anak dengan *Down syndrome* umumnya memiliki karakteristik fisik yang khas dan mudah dikenali. Berikut ini merupakan hasil asesmen yang diperoleh dari Sekolah Luar Biasa (SLB) Yakut Purwokerto terkait karakteristik fisik anak dengan *Down syndrome* :



Gambar 2. 1 wajah anak pengidap *downsyndrom*

Pada gambar 2.1 merupakan hasil asesmen yang diperoleh dari Sekolah Luar Biasa (SLB) Yakut Purwokerto terkait karakteristik fisik anak dengan *Down syndrome* :

1. Benruk Wajah

Anak-anak dengan *Down syndrome* memiliki ciri khas pada bentuk wajah yang dapat dikenali secara visual. Dari depan, wajah mereka cenderung berbentuk bulat, sementara dari

samping, terlihat lebih datar dibandingkan anak-anak tanpa kondisi tersebut.

2. Bentuk kepala

Sebagian besar individu dengan *Down syndrome* memiliki bentuk kepala yang agak rata di bagian belakang. Kondisi ini dikenal dengan istilah *brachycephaly*.

3. Mata

Anak dengan *Down syndrome* memiliki ciri khas pada struktur mata yang menjadi salah satu penanda penting dalam identifikasi kondisi ini. Secara visual, mata mereka menunjukkan beberapa karakteristik khusus, antara lain jarak antar mata yang lebih lebar dibandingkan anak pada umumnya, dengan posisi mata yang sedikit miring ke atas dari sudut dalam ke sudut luar. Di sudut dalam mata sering terlihat lipatan kulit vertikal yang dikenal sebagai lipatan epikantus (*epicanthic fold*). Selain itu, pada bagian iris mata sering ditemukan bintik-bintik kecil berwarna putih atau kekuningan yang disebut bintik Brushfield, sebuah temuan klasik yang dinamai sesuai penemunya, Thomas Brushfield. Karakteristik mata ini merupakan bagian dari manifestasi fenotipik khas *Down syndrome* yang dapat membantu dalam proses skrining dan diagnosis awal kondisi tersebut

4. Rambut

Rambut anak dengan *Down syndrome* umumnya halus, lemas, dan tumbuh lurus.

5. Leher

Pada bayi baru lahir dengan *Down syndrome*, sering dijumpai kelebihan kulit di bagian belakang leher. Namun, seiring pertambahan usia, kondisi ini biasanya berkurang. Anak-anak dan orang dewasa dengan *Down syndrome* umumnya memiliki bentuk leher yang pendek dan lebar

6. Mulut

Anak dengan *Down syndrome* umumnya memiliki rongga mulut yang relatif kecil, sedangkan ukuran lidah cenderung lebih besar dari anak pada umumnya. Perbedaan proporsi ini sering menyebabkan sebagian anak memiliki kebiasaan menjulurkan lidah

7. Tangan

Tangan penderita *Down syndrome* biasanya tampak lebih lebar dengan jari-jari yang lebih pendek. Jari kelingking kadang hanya memiliki satu ruas sendi, dan sering kali tampak melengkung ke arah dalam menuju jari lainnya kondisi yang dikenal sebagai *clinodactyly*. Selain itu, telapak tangan umumnya hanya memiliki satu garis melintang (*simian crease*), dan jika terdapat dua garis, keduanya memanjang secara horizontal melintasi telapak tangan.

8. Kaki

Bentuk jari kaki cenderung pendek dan tebal, dengan jarak yang cukup lebar antara ibu jari kaki dan jari kedua. Sering ditemukan alur pendek pada telapak kaki yang bermula dari celah antar jari kaki dan memanjang ke arah tumit beberapa sentimeter.

Kelainan genetik yang kini dikenal sebagai *Down syndrome* pertama kali diidentifikasi pada tahun 1866 oleh Dr. John Langdon Down. Awalnya, kondisi ini disebut *mongolisme* karena ciri fisik penderitanya—seperti postur tubuh pendek, kepala berukuran kecil, dan hidung yang datar—dianggap menyerupai karakteristik ras Mongoloid. Namun, pada tahun 1970, istilah tersebut diubah secara resmi oleh komunitas medis Amerika dan Eropa sebagai bentuk penghormatan kepada Dr. Down, sekaligus menghindari stereotip yang tidak tepat. Sejak saat itu,


nama *Down syndrome* digunakan secara global untuk merujuk pada kondisi ini, menegaskan pentingnya terminologi yang akurat dan menghargai dalam dunia medis[10].

C. Machine learning

Machine learning, sebagai cabang penting dari kecerdasan buatan (AI), memungkinkan sistem komputer untuk belajar secara mandiri dari data, mengenali pola, dan mengambil keputusan tanpa instruksi eksplisit dari manusia. Bidang ini terbagi menjadi dua pendekatan utama: supervised learning (pembelajaran terarah) dan unsupervised learning (pembelajaran tak terarah). Perbedaan mendasar antara keduanya terletak pada penggunaan data berlabel. Pada *supervised learning*, data yang digunakan untuk pelatihan telah dilengkapi dengan label atau kategori yang jelas, sehingga model dapat belajar dengan panduan yang terstruktur. Sementara itu, *unsupervised learning* bekerja dengan data tanpa label, mengandalkan algoritma untuk menemukan pola atau pengelompokan alami dalam data. Kedua pendekatan ini memiliki aplikasi yang luas, mulai dari prediksi hingga analisis data kompleks, tergantung pada ketersediaan data berlabel dan tujuan penggunaannya.[11].

D. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu algoritma machine learning yang paling populer dan efektif untuk pemrosesan data visual. Sebagai jenis khusus dari jaringan saraf tiruan, CNN mengintegrasikan operasi konvolusi dalam arsitekturnya, yang memungkinkannya secara otomatis mempelajari dan mengekstraksi fitur dari data mentah tanpa memerlukan ekstraksi fitur manual. Keunggulan utama CNN terletak pada kemampuannya mengolah data dengan struktur spasial atau pola grid, seperti gambar digital, dimana jaringan ini dapat mengenali pola secara hierarkis mulai dari fitur tingkat rendah (seperti tepi dan tekstur) hingga fitur tingkat tinggi (seperti objek kompleks). Karakteristik ini menjadikan CNN sangat powerful untuk berbagai tugas pengolahan gambar, termasuk klasifikasi, deteksi objek, dan segmentasi gambar, dengan performa yang sering kali melampaui metode tradisional. Kemampuannya untuk memproses data mentah secara langsung dan belajar secara mandiri membuat CNN menjadi pilihan utama dalam berbagai aplikasi computer vision modern.




Gambar 2. 2 arsitektur CNN

Pada gambar 2.2 Terdapat tiga lapisan utama yang dimiliki oleh *Convolutional Neural Network* (CNN), yaitu sebagai berikut : *Convolutional Layer*, *Pooling Layer*, *Fully-Connected Layer*[12]

E. Recurrent Neural Network

Recurrent Neural Network (RNN) adalah salah satu jenis arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data sekuensial atau data deret waktu (*time-series*). Berbeda dengan jaringan saraf tiruan biasa (*feedforward neural networks*), RNN memiliki koneksi yang membentuk siklus (*loop*), memungkinkan informasi dari langkah waktu (*timestep*) sebelumnya untuk memengaruhi pemrosesan pada langkah waktu saat ini. Kemampuan untuk "mengingat" informasi masa lalu ini menjadikan RNN sangat efektif untuk tugas-tugas di mana konteks dari input sebelumnya sangat penting.



Gambar 2. 3 arsitektur RNN

Pada gambar 2.3 Terdapat beberapa komponen dan konsep utama dalam arsitektur *Recurrent Neural Network* (RNN), yaitu sebagai berikut:

1. Recurrent Unit

Inti dari cara kerja RNN terletak pada unit rekurensinya, yang memproses setiap elemen dalam suatu urutan data secara bertahap. Setiap unit tidak hanya menerima masukan baru, tetapi juga 'warisan' informasi dari status tersembunyi (*hidden state*) pada langkah sebelumnya. Mekanisme ini menciptakan semacam 'memori' dalam jaringan, memungkinkannya menggunakan data historis untuk pengambilan keputusan saat ini. Sebuah aspek penting adalah penggunaan parameter (bobot dan bias) yang seragam di seluruh unit rekuren, yang bermanfaat untuk generalisasi yang lebih baik dan mengurangi jumlah parameter yang perlu dipelajari oleh jaringan.

2. Hidden State

Hidden state berfungsi sebagai memori jaringan. Pada setiap langkah waktu t , *hidden state* h_t dihitung berdasarkan input saat ini x_t dan *hidden state* dari langkah waktu sebelumnya h_{t-1} . *Hidden state* ini menangkap informasi relevan dari semua input sebelumnya dalam sekuens hingga langkah waktu saat ini. Kemampuan untuk membawa informasi sepanjang sekuens inilah yang membedakan RNN dari jaringan saraf tiruan lainnya.

3. Output Layer

RNN dapat menghasilkan *output* pada setiap langkah waktu atau hanya pada langkah waktu terakhir dari sekuens. Lapisan *output* mengambil informasi dari *hidden state* untuk menghasilkan prediksi atau representasi yang diinginkan. Misalnya, dalam pemodelan bahasa, *output* bisa berupa probabilitas kata berikutnya dalam sebuah kalimat. Fungsi aktivasi seperti *sigmoid* atau *softmax* sering digunakan di lapisan *output*, tergantung pada jenis *output* yang diharapkan (misalnya, probabilitas biner atau probabilitas multikelas)

F. Evaluasi performa

Evaluasi performa merupakan tahapan krusial untuk menilai seberapa efektif suatu sistem atau model dalam menyelesaikan tugas tertentu. Dalam konteks pengembangan, evaluasi ini bertujuan untuk mengukur tingkat *accuracy*, efisiensi, dan efektivitas sistem dalam

menghasilkan *output* yang sesuai dengan harapan. Beberapa metrik yang umum digunakan dalam evaluasi performa antara lain *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* dihitung sebagai rasio antara jumlah prediksi yang benar dengan total seluruh prediksi. *Precision* mengukur seberapa besar proporsi hasil prediksi positif yang benar-benar sesuai, sementara *recall* menunjukkan seberapa banyak data positif yang berhasil dikenali oleh model. *F1-score* merupakan rata-rata harmonis dari *precision* dan *recall*, yang memberikan gambaran lebih seimbang terhadap kinerja sistem[13]

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$f1 - score = 2 \times \frac{precision \times recall}{precision + recall}$$

Keterangan :

TP : *True positive* (Prediksi positif yang benar)

TN : *True Negative* (Prediksi negatif yang benar)

FP : *False positive* (Prediksi positif yang salah)

FN : *False negative* (Prediksi negatif yang salah)


		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) Type II Error	Sensitivity $\frac{TP}{TP + FN}$
	Negative	False Positive (FP) Type I Error	True Negative (TN)	Specificity $\frac{TN}{TN + FP}$
		Precision $\frac{TP}{TP + FP}$	Negative Predictive Value $\frac{TN}{TN + FN}$	Accuracy $\frac{TP + TN}{TP + TN + FP + FN}$

Gambar 2. 4 rumus *confusion matrix*

Confusion matrix atau matriks kebingungan merupakan alat evaluasi penting untuk mengukur performa model klasifikasi biner dengan membandingkan hasil prediksi terhadap nilai aktual. Matriks ini terdiri dari empat komponen kunci: *True positive* (TP) yang menunjukkan prediksi positif yang benar sesuai kondisi aktual; *False negative* (FN) atau Type II Error yang terjadi ketika model gagal mendeteksi kasus positif sehingga berpotensi menyebabkan kesalahan kritis terutama dalam bidang medis; *False positive* (FP) atau Type I Error dimana model memprediksi positif padahal sebenarnya negatif sehingga menimbulkan alarm palsu; serta *True Negative* (TN) yang merepresentasikan prediksi negatif yang akurat. Analisis terhadap komponen-komponen ini memungkinkan pemahaman mendalam tentang kelebihan dan kelemahan model, terutama dalam konteks aplikasi sensitif yang membutuhkan presisi tinggi dengan meminimalkan kesalahan baik Type I maupun Type II[14].

III. METODE

Penelitian ini dilakukan menggunakan sistem klasifikasi citra berbasis *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN) yang mampu mengidentifikasi ciri khas wajah pengidap *Down syndrome* secara otomatis melalui pendekatan machine learning. Sistem dirancang untuk menerima masukan berupa citra wajah anak, melakukan pra-pemrosesan, ekstraksi fitur menggunakan model CNN atau RNN, dan kemudian menghasilkan klasifikasi kemungkinan *Down syndrome* beserta analisis efisiensi kedua model tersebut untuk tahapan penelitian ini dilustrasikan dalam gambar berikut :



Gambar 3. 1 Ilustrasi Tahapan Penelitian

Berdasarkan gambar 3.1 Tahapan dalam penelitian ini dijelaskan sebagai berikut:

A. Identifikasi Masalah

Identifikasi masalah merupakan langkah awal dalam penelitian yang bertujuan merumuskan permasalahan utama yang akan diselidiki. Proses ini diawali dengan pengumpulan informasi relevan untuk menemukan celah atau keterbatasan dari penelitian sebelumnya. Informasi tersebut menjadi dasar dalam memahami tantangan yang perlu diatasi, seperti *accuracy* deteksi dan efisiensi komputasi. Hasil dari tahap ini menghasilkan rumusan masalah yang jelas serta landasan awal yang kuat untuk penelitian selanjutnya.

B. Studi Literatur

Pada tahap ini, pencarian informasi dilakukan melalui berbagai sumber yang relevan dengan ide penelitian seperti informasi mengenai karakteristik pengidap *Down syndrome*

C. Tahapan Mengumpulkan dan Memahami Data

Mengumpulkan data citra wajah dari sumber terbuka dan memahami karakteristik, struktur, serta konteks data tersebut. Tujuannya adalah memastikan kualitas dan relevansi data untuk analisis. *Dataset* diperoleh dari *roboflow* dalam format *COCO* dan diubah ke dalam struktur klasifikasi gambar.

D. Tahap Pelatihan Data

Tahap pemrosesan dan persiapan data sangat penting untuk menjamin kualitas dan kesiapan data sebelum digunakan dalam analisis. Proses ini dimulai dengan pemeriksaan kualitas citra, seperti mengevaluasi tingkat blur

menggunakan teknik laplacian blur, serta menghapus gambar yang buram atau ambigu. Selanjutnya, dilakukan normalisasi piksel ke rentang 0–1 dan Penyesuaian ukuran gambar dilakukan dengan memilih antara ukuran 150×150 piksel atau 224×224 piksel. *Preprocessing* diperuntukan untuk meningkatkan kualitas data.

E. Pembuatan Model

Pada pembuatan model klasifikasi menggunakan dua model yaitu CNN dan RNN. CNN digunakan sebagai arsitektur utama karena kemampuannya dalam mengekstrak fitur spasial dari citra wajah. Pendekatan ini bertujuan untuk melihat apakah ada peningkatan *accuracy* dengan mempertimbangkan urutan fitur. Setelah arsitektur ditetapkan, model dilatih menggunakan *dataset* pelatihan, dengan proses pelatihan dilakukan selama beberapa *epoch* hingga performa model stabil.


F. Training Model

Pada tahap pelatihan, digunakan fungsi *binary cross-entropy* untuk mengukur *accuracy* prediksi dalam klasifikasi biner. *Optimizer* adam digunakan untuk menyesuaikan bobot model secara bertahap agar nilai *loss* menurun. Untuk meningkatkan efektivitas pelatihan, diterapkan beberapa *callback* seperti *farlystopping* untuk menghentikan pelatihan saat performa tidak meningkat, *ModelCheckpoint* untuk menyimpan model terbaik, dan *ReduceLROnPlateau* untuk menurunkan *learning rate* saat pelatihan *stagnan*.

G. Evaluasi Model

Metrik seperti *accuracy*, *precision*, *recall*, *F1-score*, dan *overfitting* dapat digunakan untuk mengevaluasi sejauh mana model dapat mengklasifikasikan gambar dengan benar pada set pengujian. Setelah melalui proses pelatihan dan evaluasi, model dapat digunakan untuk memprediksi kelas dari gambar baru yang belum pernah dilihat sebelumnya.

Berdasarkan uraian dari tahapan penelitian di atas. Penulis membuat ilustrasi preprocessing sistem yang dibuat. gambaran umum dari sistem yang dirancang dalam penelitian ini dapat dilihat pada Gambar 3.2



Gambar 3. 2 Flowchart Preprocessing

Berikut penjelasan setiap tahapannya dari gambar 3.2 terkait *Flowchart Preprocessing* :

A. Mounted Google Drive

Pada tahap awal penelitian, integrasi antara *Google Colab* dan *Google Drive* dilakukan. *Google Drive* bertindak sebagai repositori penyimpanan *dataset* dan output segmentasi, sementara *Google Colab* berperan sebagai lingkungan komputasi yang menangani semua tahap pemrosesan, termasuk pra-pemrosesan, training model, dan analisis evaluasi, didukung akselerasi GPU untuk efisiensi waktu.

B. Set Input dan Output

Menentukan direktori *input* (sumber gambar mentah) dan *output* (lokasi penyimpanan hasil konversi). Tahapan ini penting agar alur kerja memiliki jalur yang jelas untuk membaca dan menyimpan data.

C. Define Regex Pattern

Menentukan pola pencarian *file* menggunakan *regular expression (regex)* yang akan digunakan untuk mencari *file* gambar berdasarkan nama atau format tertentu.

D. Search Files by Pattern

Mencari *file* di dalam direktori input berdasarkan pola *regex* yang telah ditentukan. Proses ini bertujuan untuk menyaring hanya *file* yang relevan.

E. Pengecekan

Sistem kemudian mengecek apakah ada *file* yang cocok dengan pola pencarian, jika tidak ditemukan Sistem akan kembali ke langkah pencarian, Proses dilanjutkan ke konversi gambar jika ditemukan..

F. Convert Image

File yang ditemukan kemudian dikonversi sesuai kebutuhan *preprocessing*, misalnya mengubah ukuran, format, atau normalisasi citra.

H. Menampilkan Hasil

Setelah gambar dikonversi, hasilnya ditampilkan untuk memastikan proses berhasil dan *output* sesuai yang diinginkan.

IV. HASIL DAN PEMBAHASAN

Pada hasil percobaan yang akan diuji disini mengenai dari metode CNN dan RNN, dari kedua metode tersebut akan membahas terkait *grafik model accuracy*, *grafik Model loss*, *precision* dan *recall*. Selain itu, pada hasil percobaan ini membahas *confusion marix* yang terdapat kelas *down syndrom* dan *healthy*.

A. Hasil percobaan CNN

Histori pelatihan model CNN untuk klasifikasi *Down syndrome* ditunjukkan melalui grafik metrik-metrik utama selama 50 *epoch*. Grafik ini terdiri dari empat bagian utama: *accuracy*, *loss*, *precision*, dan *recall*, masing-masing menampilkan performa pada data pelatihan (*training*) dan data validasi (*validation*). Penjelasan masing-masing grafik adalah sebagai berikut:

Tabel 4.1 Hasil Evaluasi Training CNN

Metode	Accuracy	Precision	Recall	F1-score
CNN	0.9383	0.6772	0.7044	0.6898

Hasil dari evaluasi *training set* dalam penggunaan metode CNN menghasilkan nilai *confusion matrik* yaitu hasil evaluasi *training set* bahwa meskipun model mampu mencapai *accuracy* sebesar 0.9383, performanya dalam mendeteksi kasus *Down syndrome* masih tergolong rendah. Hal ini tercermin dari nilai *recall* yang hanya mencapai 0.7044, yang berarti sebagian besar kasus *Down syndrome* tidak berhasil dikenali dengan benar oleh model. Dengan kata lain, dari seluruh pasien yang sebenarnya mengidap *Down syndrome*, hanya sebagian kecil yang berhasil diklasifikasikan secara tepat.

Confusion Matrix

True Label \ Predicted Label	healthy	down
healthy	121	708
down	523	2812

Gambar 4. 1 Confusion matrik Training

Berdasarkan confusion matrix yang ditampilkan, matriks ini mengevaluasi performa model klasifikasi dalam membedakan antara kondisi "healthy" (sehat) dan "down" (*Down syndrome*). Dari data tersebut, terdapat 708 *true positive* (TP) dimana kasus *Down syndrome* berhasil diprediksi dengan benar, dan 121 *true negative* (TN) untuk kasus sehat yang teridentifikasi tepat. Namun, model juga membuat kesalahan dengan 523 *false negative* (FN) (kasus *Down syndrome* yang terlewat) dan 2812 *false positive* (FP) (kasus sehat yang salah diklasifikasikan sebagai *Down syndrome*). Angka FN yang tinggi menunjukkan model cenderung kurang sensitif dalam mendeteksi *Down syndrome*, sehingga berisiko melewati diagnosis. Sementara itu, FP yang signifikan mengindikasikan adanya alarm palsu yang bisa menyebabkan pemeriksaan tambahan yang tidak perlu. Performa ini mengisyaratkan kebutuhan untuk meningkatkan akurasi model, terutama dengan mengurangi kesalahan FN mengingat implikasi klinis yang serius jika kasus *Down syndrome* tidak terdeteksi.

Tabel 4.2 Hasil evaluasi *validation* CNN

Metode	Accuracy	Precision	Recall	F1-score
CNN	0.9021	0.9016	0.9021	0.8936

Hasil dari evaluasi *validation set* dalam penggunaan metode CNN menghasilkan nilai *confusion matrik* yaitu hasil evaluasi *validation set* bahwa meskipun model mampu mencapai *accuracy* sebesar 0.9021, performanya dalam mendeteksi kasus *Down syndrome* masih tergolong rendah. Hal ini tercermin dari nilai *recall* yang hanya mencapai 0.9021, yang berarti sebagian besar kasus *Down syndrome* tidak berhasil dikenali dengan benar oleh model. Dengan kata lain, dari seluruh pasien yang sebenarnya mengidap *Down syndrome*, hanya sebagian kecil yang berhasil diklasifikasikan secara tepat.

Confusion Matrix

True Label \ Predicted Label	healthy	down
healthy	60	44
down	7	410

Gambar 4. 2 confusion matrik validation CNN


Berdasarkan confusion matrix yang ditampilkan, matriks ini mengevaluasi performa model klasifikasi dalam membedakan antara kondisi "healthy" (sehat) dan "down" (*Down syndrome*). Dari data tersebut, terdapat 708 *true positive* (TP) dimana kasus *Down syndrome* berhasil diprediksi dengan benar, dan 60 *true negative* (TN) untuk kasus sehat yang teridentifikasi tepat. Namun, model juga membuat kesalahan dengan 7 *false negative* (FN) (kasus *Down syndrome* yang terlewat) dan 410 *false positive* (FP) (kasus sehat yang salah diklasifikasikan sebagai *Down syndrome*). Angka FN yang tinggi menunjukkan model cenderung kurang sensitif dalam mendeteksi *Down syndrome*, sehingga berisiko melewati diagnosis. Sementara itu, FP yang signifikan mengindikasikan adanya alarm palsu yang bisa menyebabkan pemeriksaan tambahan yang tidak perlu. Performa ini mengisyaratkan kebutuhan untuk meningkatkan akurasi model, terutama dengan mengurangi kesalahan FN mengingat implikasi klinis yang serius jika kasus *Down syndrome* tidak terdeteksi.

Tabel 4.3 Hasil evaluasi Test CNN

Metode	Accuracy	Precision	Recall	F1-score
CNN	0.8733	0.8662	0.8733	0.8619

Hasil dari evaluasi *test set* dalam penggunaan metode CNN menghasilkan nilai *confusion matrik* yaitu hasil evaluasi *test set* bahwa meskipun model mampu mencapai *accuracy* sebesar 0.8733, performanya dalam mendeteksi kasus *Down syndrome* masih tergolong rendah. Hal ini tercermin dari nilai *recall* yang hanya mencapai 0.8733, yang berarti sebagian besar kasus *Down syndrome* tidak berhasil dikenali dengan benar oleh model. Dengan kata lain, dari

seluruh pasien yang sebenarnya mengidap *Down syndrome*, hanya sebagian kecil yang berhasil diklasifikasikan secara tepat.



Gambar 4. 3 confusion matrik test CNN

Berdasarkan confusion matrix yang ditampilkan, matriks ini mengevaluasi performa model klasifikasi dalam membedakan antara kondisi "healthy" (sehat) dan "down" (*Down syndrome*). Dari data tersebut, terdapat 708 *true positive* (TP) dimana kasus *Down syndrome* berhasil diprediksi dengan benar, dan 52 *true negative* (TN) untuk kasus sehat yang teridentifikasi tepat. Namun, model juga membuat kesalahan dengan 14 *false negative* (FN) (kasus *Down syndrome* yang terlewat) dan 403 *false positive* (FP) (kasus sehat yang salah diklasifikasikan sebagai *Down syndrome*). Angka FN yang tinggi menunjukkan model cenderung kurang sensitif dalam mendeteksi *Down syndrome*, sehingga berisiko melewatkan diagnosis. Sementara itu, FP yang signifikan mengindikasikan adanya alarm palsu yang bisa menyebabkan pemeriksaan tambahan yang tidak perlu. Performa ini mengisyaratkan kebutuhan untuk meningkatkan akurasi model, terutama dengan mengurangi kesalahan FN mengingat implikasi klinis yang serius jika kasus *Down syndrome* tidak terdeteksi.


B. Hasil percobaan RNN

Histori pelatihan model RNN untuk klasifikasi *Down syndrome* ditunjukkan melalui grafik metrik-metrik utama selama 50 *epoch*. Grafik ini terdiri dari empat bagian utama: *accuracy* dan *loss*, masing-masing menampilkan performa pada data pelatihan (*training*) dan data validasi (*validation*). Penjelasan masing-masing grafik adalah sebagai berikut:

Tabel 4.4 Hasil Evaluasi Training RNN

Metode	Accuracy	Precision	Recall	F1-score
RNN	0.7757	0.8014	0.9571	0.8724

Hasil dari *Training Set Evaluation* dalam penggunaan metode RNN menghasilkan nilai *confusion matrik* yaitu model RNN menunjukkan *accuracy* validasi 0.7757, *precision* 0.8014, *recall* 0.9571 dan *F1-Score* 0.8724. Meskipun *accuracy* cukup, kemampuan model untuk mengenali kelas minoritas (*Down syndrome*) sangat terbatas




Gambar 4. 4 Confusion matrik Train RNN

Hasil menunjukkan *training test* model RNN bahwa meskipun model mampu mencapai *accuracy* sebesar 0.78, sebagian besar kasus *Down syndrome* tidak berhasil dikenali dengan benar oleh model. *Overfitting* memperlihatkan model terhadap dua kelas, model mampu mengenali data sehat dengan baik yaitu 38 data berhasil diklasifikasikan dengan benar. Namun, dari total 3.335 data pengidap *Down syndrome* yaitu 3.192 yang diklasifikasikan dengan benar sementara sisanya sejumlah 143 data salah diklasifikasikan sebagai normal.

Tabel 4.5 Hasil evaluasi Validation

Metode	Accuracy	Precision	Recall	F1-score
RNN	0.8273	0.8316	0.9832	0.9011

hasil evaluasi model RNN menunjukkan bahwa *recall* untuk klasifikasi kelas *Down syndrome* sangat tinggi, yang berimplikasi pada banyaknya kasus yang terdeteksi oleh model. Hasil dari *Validation Set Evaluation* dalam penggunaan metode RNN menghasilkan nilai *confusion matrik* yaitu model RNN menunjukkan *accuracy* validasi 0.8273, *precision* 0.8316, dan *recall* 0.9832 dan *F1-Score* 0.9011. Meskipun *accuracy* cukup, kemampuan model untuk mengenali kelas minoritas (*Down syndrome*) sangat terbatas.



Gambar 4. 5 Confusion matrik validation RNN

Hasil *overfitting* menunjukkan *Validation Set* model RNN bahwa meskipun model mampu mencapai *accuracy* sebesar 0.59, sebagian besar kasus *Down syndrome* tidak berhasil dikenali dengan benar oleh model. *Overfitting* memperlihatkan model terhadap dua kelas, model mampu mengenali data sehat dengan baik yaitu 0.20 data berhasil diklasifikasikan dengan benar. Namun, dari total 1.00 data pengidap *Down syndrome* yaitu 0.98 yang diklasifikasikan

dengan benar sementara sisanya sejumlah 0.02 data salah diklasifikasikan sebagai normal.


Evaluasi	Model	Accuracy	Precision	Recall	F1-score
Train	CNN	0.9383	0.6772	0.7044	0.6898
	RNN	0.7757	0.8014	0.9571	0.8724
Validation	CNN	0.9021	0.9016	0.9021	0.8936
	RNN	0.8273	0.8316	0.9832	0.9011
Test	CNN	0.8733	0.8662	0.8733	0.8619
	RNN	0.8311	0.8297	0.9928	0.9039

Tabel 4.6 hasil Evaluasi test RNN

Metode	Accuracy	Precision	Recall	F1-score
RNN	0.8311	0.8297	0.9928	0.9039

Hasil evaluasi model RNN menunjukkan bahwa *recall* untuk klasifikasi kelas *Down syndrome* sangat tinggi, yang berimplikasi pada banyaknya kasus yang terdeteksi oleh model. Hasil dari *Test Set Evaluation* dalam penggunaan metode RNN menghasilkan nilai *confusion matrik* yaitu model RNN menunjukkan *accuracy* validasi 0.8311, *precision* 0.8297, dan *recall* 0.9928 dan *F1-Score* 0.9039. Meskipun *accuracy* cukup, kemampuan model untuk mengenali kelas minoritas (*Down syndrome*) sangat terbatas.

Confusion Matrix- Test Set



Gambar 4. 6 Confusion matrik test RNN

Hasil *overfitting* menunjukkan *Test Set* model RNN bahwa meskipun model mampu mencapai *accuracy* sebesar 0.83, sebagian besar kasus *Down syndrome* tidak berhasil dikenali dengan benar oleh benar. *Overfitting* memperlihatkan model terhadap dua kelas, model mampu mengenali data sehat dengan baik yaitu 19 data berhasil diklasifikasikan dengan benar. Namun, dari total 417 data pengidap *Down syndrome* yaitu 414 yang diklasifikasikan dengan benar sementara sisanya sejumlah 3 data salah diklasifikasikan sebagai normal.

C. Hasil Perbandingan

Tabel 4.7 Hasil perbanding

Hasil evaluasi terhadap model CNN dan RNN menunjukkan perbedaan karakteristik performa yang signifikan di setiap tahap pengujian. CNN mencatat akurasi pelatihan yang tinggi sebesar 0.9383, namun nilai *precision* dan *recall* yang relatif rendah (0.6772 dan 0.7044) mengindikasikan keterbatasan dalam mengidentifikasi kasus positif secara menyeluruh. Sebaliknya, RNN dengan akurasi pelatihan 0.7757 menunjukkan keunggulan dalam *recall* (0.9571) dan *F1-score*

(0.8724), membuktikan kemampuannya yang lebih baik dalam menangkap pola data secara komprehensif. Pada tahap validasi, kedua model menunjukkan performa stabil dengan CNN mencapai akurasi 0.9021 dan RNN unggul dalam *recall* (0.9832) serta *F1-score* (0.9011), mengindikasikan kemampuan generalisasi yang kuat dari RNN terhadap data baru. Di tahap pengujian, CNN mempertahankan konsistensi dengan akurasi 0.8733 dan *F1-score* 0.8619, sementara RNN kembali menunjukkan keunggulan dengan *recall* tertinggi (0.9928) dan *F1-score* 0.9039, membuktikan keandalannya dalam mengenali pola data baru. Secara keseluruhan, CNN cocok untuk aplikasi yang memprioritaskan kestabilan dan akurasi prediksi, sedangkan RNN lebih unggul dalam kasus-kasus kritis seperti klasifikasi medis yang membutuhkan deteksi menyeluruh terhadap kasus positif dengan risiko minimal *false negative*. Perbedaan karakteristik ini memberikan pilihan strategis dalam penerapan model sesuai dengan kebutuhan spesifik dan prioritas performa.

V. KESIMPULAN

Berdasarkan penelitian mengenai analisis efisiensi CNN dan RNN dalam klasifikasi *Down syndrome* pada balita, dapat disimpulkan bahwa kedua model memiliki keunggulan dan kelemahan masing-masing. CNN menunjukkan performa yang lebih baik dalam hal akurasi secara keseluruhan, tetapi kurang optimal dalam mendeteksi kasus *Down syndrome* secara spesifik, terlihat dari nilai *precision* dan *recall* yang relatif rendah. Di sisi lain, RNN meskipun memiliki akurasi yang lebih rendah, mampu mendeteksi kasus *Down syndrome* dengan lebih baik, ditunjukkan oleh nilai *recall* dan *F1-score* yang tinggi. Hal ini membuat RNN lebih cocok untuk aplikasi medis yang membutuhkan deteksi komprehensif dengan risiko *false negative* minimal. Secara keseluruhan, pemilihan model tergantung pada kebutuhan spesifik, di mana CNN lebih sesuai untuk aplikasi umum dengan akurasi tinggi, sedangkan RNN lebih unggul dalam deteksi kasus-kasus kritis seperti *Down syndrome*. Hasil penelitian ini memberikan dasar untuk pengembangan sistem diagnosis berbasis AI yang lebih akurat dan efisien di masa depan.

REFERENSI

[1]

M. Dierssen, M. Fructuoso, M. Martínez De Lagrán, M. Perluigi, and E. Barone, “Down syndrome Is a Metabolic Disease: Altered Insulin Signaling Mediates Peripheral and Brain Dysfunctions,” *Front. Neurosci.*, vol. 14, p. 670, Jul. 2020, doi: 10.3389/fnins.2020.00670.

[2]

S. Urohmah and Y. Firda Nadhirah, “Memahami Anak Down Syndrom di SKH Negeri 1 Kota Serang,” *J. Ilm. PGSD FKIP Univ. Mandiri*, vol. 10 No. 4, no. 477–5673, p. 11, Desember 2024.

[3]

Imam Fathurrahman, Mahpuz, Muhammad Djamaluddin, Lalu Kerta Wijaya, and Ida Wahidah, “Pengembangan Model Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Kulit Berbasis Citra Digital,” *Infotek J. Inform. Dan Teknol.*, vol. 8, no. 1, pp. 298–308, Jan. 2025, doi: 10.29408/jit.v8i1.28655.

- [4] Lola, "PERANCANGAN IDENTIFIKASI WAJAH PENGIDAP *DOWN SYNDROME* MENGGUNAKAN MODEL CNN," *J. Ismetek*, vol. 16 No. 1, p. 5, Desember Tahun 2023.
- [5] A. Tjahjo Nugroho, Y. Wulandari, and B. Eko Cahyono, "Klasifikasi *Down syndrome* Menggunakan Tekstur LBP dengan Tiga Variasi Distance Classifiers _ Nugroho _ STRING (Satuan Tulisan Riset dan Inovasi Teknologi)," *STRING Satuan Tulisan Ris. Dan Inov. Teknol.*, vol. 7 No. 1, p. Agustus 2022
- [6] S. Budiarti, "KLASIFIKASI WAJAH ANAK - ANAK *DOWN SYNDROME* MELALUI CITRA WAJAH MENGGUNAKAN ALGORITMA PROBABILISTIC NEURAL NETWORK (PNN) SKRIPSI
- [7] E. Setyati, S. Az, S. P. Hudiono, and F. Kurniawan, "CNN based Face Recognition System for Patients with Down and William Syndrome," *Knowledge Engineering and Data Science (KEDS)*, vol. 4, no. 2, pp. 138-144, Dec. 2021
- [8] H. M. Metavia and R. Widyana, "Pengaruh *Down syndrome* terhadap Perkembangan Akademik Anak di Indonesia," *J. Wacana Kesehat.*, vol. 7, no. 2, p. 54, Dec. 2022, doi: 10.52822/jwk.v7i1.403.
- [9] I. Septian and H. Septanto, "Pengembangan Model Pendeteksian Gambar Alat Musik dengan Metode Faster R-CNN dengan Library Keras," vol. 8, no. 1, 2022.
- [10] J. Gu *et al.*, "Recent Advances in Convolutional Neural Networks," Oct. 19, 2017, *arXiv*: arXiv:1512.07108. doi: 10.48550/arXiv.1512.07108.
- [11] I. D. Mienye, T. G. Swart, and G. Obaido, "Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications," Aug. 12, 2024, *Computer Science and Mathematics*. doi: 10.20944/preprints202408.0748.v1.
- [12] R. V. Talumepa, D. A. Putra, and H. Soetanto, "Sistem Presensi Pendeteksi Wajah menggunakan Metode Modified Region Convolutional Neural Network dan PCA," *Edumatic J. Pendidik. Inform.*, vol. 8, no. 1, pp. 46–55, Jun. 2024, doi: 10.29408/edumatic.v8i1.25207.
- [13] J. K S and D. S. David, "A Novel Based 3d Facial Expression Detection Using Recurrent Neural Network," *Int. J. Sci. Res. Comput. Sci. Eng. Inf. Technol.*, pp. 48–53, Mar. 2020, doi: 10.32628/CSEIT20622.
- [14] S. Swaminathan and B. R. Tantri, "Confusion Matrix-Based Performance Evaluation Metrics," *African Journal of Biomedical Research*, vol. 27, no. 4s, pp., 2024