

**ANALISIS TEKSTUR CITRA CT-SCAN DENGAN METODE GLCM (
GRAY LEVEL CO-OCCURRENCE MATRIX) DAN DNN (DEEP NEURAL
NETWORK) UNTUK DETEKSI TINGKAT KEPARAHAN STROKE**

SKRIPSI

Oleh :
HALIIM PAMUNGKAS HARJO SUYONO
NIM. 19640025



**PROGRAM STUDI FISIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2023**

HALAMAN PENGANTAR

**ANALISIS TEKSTUR CITRA CT-SCAN DENGAN METODE GLCM (GRAY
LEVEL CO-OCCURRENCE MATRIX) DAN DNN (DEEP NEURAL
NETWORK) UNTUK DETEKSI TINGKAT KEPARAHAN STROKE**

SKRIPSI

Diajukan kepada:
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Sarjana Sains (S.Si)

Oleh:
HALIIM PAMUNGKAS HARJO SUYONO
NIM. 19640025

**PROGRAM STUDI FISIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2023**

HALAMAN PERSETUJUAN

**ANALISIS TEKSTUR CITRA CT-SCAN DENGAN METODE GLCM (GRAY
LEVEL CO-OCCURRENCE MATRIX) DAN DNN (DEEP NEURAL NETWORK)
UNTUK DETEKSI TINGKAT KEPARAHAN STROKE**

SKRIPSI

Oleh:

HALIIM PAMUNGKAS HARJO SUYONO

NIM. 19640025

**Telah diperiksa dan disetujui untuk diuji
Pada tanggal , 8 November 2023**

Pembimbing I



Dr. H. Agus Mulyono, M.Kes

NIP. 19750808 199903 1 003

Pembimbing II



Mubasyiroh, S.S., M.Pd.I

NIDT. 19790502 20180201 2 208

Mengesahkan

Ketua Program Studi



Dr. Imam Tazi, M.Si

NIP. 19740730 200312 1 002

HALAMAN PENGESAHAN





ANALISIS TEKSTUR CITRA CT-SCAN DENGAN METODE GLCM (GRAY
LEVEL CO-OCCURRENCE MATRIX) DAN DNN (DEEP NEURAL
NETWORK) UNTUK DETEKSI TINGKAT KEPARAHAN STROKE

SKRIPSI

Oleh:

HALIIM PAMUNGKAS HARJO SUYONO
NIM. 19640025

Telah Dipertahankan Di Depan Dewan Penguji
Dan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Sains (S.Si)
Pada Tanggal, 11 November 2023

Penguji Utama :	<u>Dr. H. Mokhamad. Tirono, M.Si</u> NIP. 19641211 199111 1 001	
Ketua Penguji :	<u>Muthmainnah, M.Si</u> NIP. 19811119 200801 2 009	
Sekretaris Penguji :	<u>Dr. H. Agus Mulyono, M.Kes</u> NIP. 19750808 199903 1 003	
Anggota Penguji :	<u>Mubasyiroh, S.S. M.Pd.I</u> NIDT. 19790502 20180201 2 208	

Mengesahkan,

Ketua Program Studi



Dr. Irfan Tazi, M.Si
NIP. 19740730 200312 1 002

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan dibawah ini:

Nama : Haliim Pamungkas Harjo Suyono
NIM : 19640025
Jurusan : Fisika
Fakultas : Sains dan Teknologi
Judul Penelitian : Analisis Tekstur Citra Dengan Metode GLCM (Gray Level Co- Occurrence Matrix) Dan DNN (Deep Neural Network) Untuk Deteksi Tingkat Keparahan Stroke.

Menyatakan dengan sebenar-benarnya bahwa hasil skripsi yang saya buat ini benar-benar hasil karya saya sendiri, tidak terdapat unsur-unsur penjiplakan karya penelitian atau karya ilmiah orang lain, kecuali yang tertulis dalam naskah ini disebutkan dengan menyertakan sumber atau kutipan penulis dan daftar pustaka. Skripsi ini hasil dari pengambilan data penelitian dan menulis skripsi ini berdasarkan sumber atau referensi yang saya gunakan. Apabila kemudian hari hasil penelitian dan tulisan ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan ini.

Malang, 12 Desember 2023

Yang membuat Pernyataan



Haliim pamungkas H.S
NIM.19640025

MOTTO

"You underestimated me. You didn't look at me. You saw me, but you didn't really look." — Assane Diop

"Jika kau bahkan pernah bermimpi untuk mengalahkanku, lebih baik kau bangun dan meminta maaf." — Muhammad Ali

HALAMAN PERSEMBAHAN

Alhamdulillah puja dan puji syukur saya panjatkan kehadiran ALLAH SWT atas segala rahmat, dan hidayahnya, sehingga dapat menyelesaikan skripsi ini. Dan tak lupa Sholawat serta salam senantiasa terlimpahkan kepada Nabi Muhammad SAW, para sahabat, dan segenap orang yang mengikuti jejaknya. Dengan rasa hormat dan kasih sayang, karya skripsi yang masih jauh dari kata sempurna ini saya persembahkan kepada:

1. Kedua orang tua saya, ibu kardjiyem dan bapak suyono yang senantiasa memberikan dukungan motivasi, semangat, materil serta do'a yang tiada hentinya sampai ada di titik ini.
2. Kepada kedua kakak saya, mbak Lintang Dwi dan mbak Meta Epsi yang selalu memberikan motivasi serta dukungan materil serta doa dan nasihat yang tiada hentinya.
3. Kepada adik saya Hawa Shajida, yang selalu memberikan bantuan di sela-sela sibuk tugas kuliah.
4. Novita Sari, satu dari sekian banyak orang yang punya andil cukup besar selama penulis berada di kampus, terimakasih atas dedikasi dan bantuannya. Semoga akan terus baik sampai nanti.
5. Teman-teman kost putra abah tony yang bisa jadi tempat *healing* dikala kesusahan dengan data.

Terimakasih diucapkan, kepada pihak-pihak yang telah andil dan memberikan semangat, semoga apa yang dicitakan dan diinginkan dapat tergapai sesuai keinginan, Aamiin.

KATA PENGANTAR

Alhamdulillah, puja dan puji syukur saya panjatkan kepada ALLAH SWT atas limpahan rahmat dan kasih sayangNya, sehingga penulis dapat menyelesaikan skripsi dengan judul “Analisis tekstur citra CT-SCAN dengan menggunakan metode GLCM(Gray Level Co-occurrence Matrix) dan DNN(Deep Neural Network) untuk deteksi tingkat keparahan stroke”. Sholawat serta salam senantiasa tercurahkan kepada junjungan Nabi Muhammad SAW yang telah mengantarkan kita dari zaman kegelapan ke zaman yang terang benderang serta sahabat, dan pengikutnya. Penulis dengan penuh kesadaran, menyadari bahwa dalam penyusunan skripsi ini tidak akan selesai tanpa adanya bantuan oleh dari berbagai pihak. Oleh sebab itu penulis ingin mengucapkan terimakasih kepada:

1. Allah SWT atas limpahan rahmat, rezeki, dan kasih sayangNya sehingga penulis dapat menyelesaikan skripsi ini.
2. Bapak,Ibu,Kakak,Adik atas segala bantuan materil dan doa sehingga penulis dapat dengan tenang dan lancar dalam menyelesaikan skripsi ini.
3. Prof. Dr. H. M. Zainuddin, M.A selaku Rektor Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang.
4. Dr. Sri Harini, M.Si selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang.
5. Dr. Imam Tazi, M.Si selaku Ketua Jurusan Fisika Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang.
6. Dr.H. Agus Mulyono, M.Kes, selaku dosen pembimbing yang senantiasa memberikan dan meluangkan waktu di sela kesibukan, serta memberikan

ilmu kepada penulis. Sampai dengan akhirnya penulis bisa menyelesaikan skripsi kali ini.

7. Segenap dosen, laboran serta admin Jurusan Fisika UIN Maulana Malik Ibrahim Malang yang senantiasa selalu memberikan semangat dan arahan positif.
8. Serta semua pihak yang terlibat yang telah banyak memberikan bantuan secara sukarela.

Masih terdapat kesalahan dan kekeliruan yang mungkin dengan tidak sengaja penulis lakukan, maka dengan besar hati penulis mengharapkan kritik dan saran yang membangun. Demikian yang penulis dapat sampaikan, semoga skripsi ini bisa menjadi salah satu manfaat bagi penelitian dan pengetahuan selanjutnya

Malang, 28 November 2023

Penulis

DAFTAR ISI

COVER	i
HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAM PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiii
DAFTAR LAMPIRAN	xiv
ABSTRAK	xv
ABSTRACT	xvi
مستخلص البحث	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Batasan Masalah	6
1.5 Manfaat Penelitian	6
BAB II DASAR TEORI	7
2.1 Ischemia Stroke	7
2.2 Intrcranial Hemorrhage	8
2.3 Pengolahan Citra	9
2.3.1 Citra CT-SCAN	9
2.3.2 Preprocessing	10
2.4 Aspek Fisika	11
2.5 Tekstur Citra	15
2.6 GLCM	16
2.7 DNN	24
2.8 Active Contour	26
BAB III METODE PENELITIAN	29
3.1 Kerangka Konseptual	29
3.2 Jenis Penelitian	30
3.3 Waktu dan Tempat penelitian	30
3.4 Alat dan Bahan	31

3.4.1	Alat Penelitian	31
3.4.2	Bahan Penelitian.....	31
3.5	Variabel Penelitian	31
3.6	Diagram Penelitian	32
3.7	Prosedur Penelitian	33
3.8	Pengumpulan Data	35
3.9	Analisis Data	36
BAB IV HASIL DAN PEMBAHASAN		39
4.1	Gambaran umum penelitian	39
4.2	Hasil Analisis data	41
4.2.1	Active Contour	41
4.2.2	Analisis <i>epoch</i> 250,500,1000	42
4.3	Pembahasan.....	46
4.3.1	Analisis Fitur GLCM	46
4.3.1.1	Fitur Contrast	46
4.3.1.2	Fitur Correlation.....	49
4.3.1.3	Fitur Homogenitas.....	51
4.3.1.4	Fitur Entropy	53
4.3.1.5	Fitur Energy	55
4.3.1.6	Fitur Dissimilarity	57
4.3.1.7	Fitur Sum variance	59
4.3.1.8	Fitur Sum Average	61
4.3.2	Akurasi DNN Dengan Epoch 250	63
4.3.3	Akurasi DNN Dengan Epoch 500	65
4.3.4	Akurasi DNN Dengan Epoch 1000	66
4.3.5	Uji F1-Score Pada Model DNN	67
4.4	Integrasi Al-Quraan Dan Keterkaitan Dengan Prespektif Islam	69
BAB V PENUTUP.....		70
5.1	Kesimpulan	70
5.2	Saran	71
DAFTAR PUSTAKA.....		72
LAMPIRAN.....		78

DAFTAR GAMBAR

Gambar 2.1	Skema akuisisi Citra CT-Scan	12
Gambar 2.2	Model biner dan matriks co-occurrence yang sesuai	18
Gambar 2.3	Arstiektur jaringan DNN	25
Gambar 2.4	Fungsi aktivasi pada algoritma DNN	26
Gambar 3.1	Kerangka konseptual	30
Gambar 3.2	Diagram penelitian	33
Gambar 4.1	Citra normal	43
Gambar 4.2	Citra segmentasi normal	43
Gambar 4.3	Citra hemorrhage	43
Gambar 4.4	Citra segmentasi hemorrhage	43
Gambar 4.5	Citra iskemik	43
Gambar 4.6	Citra segmentasi iskemik	43

DAFTAR TABEL

Tabel 3.1	Tabel hasil klasifikasi DNN	36
Tabel 4.1	Data klasifikasi citra normal	43
Tabel 4.2	Data klasifikasi citra hemorrhage	44
Tabel 4.3	Data klasifikasi citra iskemik	45
Tabel 4.4	Tabel nilai contrast pada masing masing data tes	47
Tabel 4.5	Range nilai contrast	48
Tabel 4.6	Tabel nilai correlation pada masing masing data tes	49
Tabel 4.7	Range nilai correlation	50
Tabel 4.8	Tabel nilai homogenitas	52
Tabel 4.9	Range nilai homogenitas	53
Tabel 4.10	Tabel nilai entropy pada masing masing data tes	54
Tabel 4.11	Range nilai entorpy	55
Tabel 4.12	Tabel nilai energy pada masing masing data tes	56
Tabel 4.13	Range nilai energy	56
Tabel 4.14	Tabel nilai dissimilarity pada masing masing data tes	58
Tabel 4.15	Range nilai dissimilarity	59
Tabel 4.16	Tabel nilai sum variance pada masing masing data tes	60
Tabel 4.17	Range nilai sum variance	61
Tabel 4.18	Tabel nilai sum average pada masing masing data tes	61
Tabel 4.19	Range nilai sum average	63

DAFTAR LAMPIRAN

Lampiran 1. Program Ekstrak Citra GLCM	80
Lampiran 2. Program Input GLCM	80
Lampiran 3. Segmentasi Active Contour	81
Lampiran 4. Kode program DNN dan GLCM	81
Lampiran 5. Tabel Hasil ekstraksi Fitur GLCM Citra Normal	88
Lampiran 6. Tabel Hasil Ekstraksi Fitur GLCM Citra Hemorrhage	89
Lampiran 7. Tabel Hasil Ekstraksi Fitru GLCM Citra Iskemik	90

ABSTRAK

Pamungkas, Haliim. 2023. **Analisis tekstur citra CT-SCAN dengan menggunakan metode GLCM (Grey Level Co-occurrence Matrix) dan DNN (Deep Neural Network) Untuk deteksi tingkat keparahan stroke**, Skripsi. Program Studi Fisika. Fakultas Sains dan Teknologi. Universitas Islam Negeri Maulana Malik Ibrahim Malang. Dosen Pembimbing (I) Dr. H. Agus Mulyono, M.Kes, (II) Mubasyiroh, M.Pd.I.

Kata Kunci: GLCM, Stroke, DNN, F1-SCORE, Normal, Hemorrhage, Iskemik, Active Contour, Akurasi, Presisi

Stroke merupakan salah satu dari sekian banyak penyakit mematikan di dunia, dimana diperkirakan ada sebanyak 3.4 juta kasus stroke per tahun antara tahun 2012 sampai 2030 dikarenakan banyaknya penduduk yang mendekati usia produktif. Penelitian ini ditunjukkan menggunakan pendekatan yang mengintegrasikan metode Gray Level Co-occurrence Matrix (GLCM) dan Deep Neural Network (DNN) untuk mendeteksi tingkat keparahan stroke pada citra CT-SCAN.

GLCM digunakan untuk mengekstrak fitur tekstur dari citra, sementara DNN digunakan untuk memodelkan dan mengklasifikasikan tingkat keparahan stroke. Pada tahap awal, citra CT-SCAN dengan masing-masing klasifikasi diekstraksi menggunakan GLCM untuk didapatkan hasil fitur. Hasil ekstraksi fitur digunakan sebagai masukan untuk jaringan DNN dilatih menggunakan dataset besar citra CT-SCAN dengan berbagai tingkat keparahan stroke untuk memastikan generalisasi yang baik. Hasil eksperimen menunjukkan bahwa pendekatan dengan metode yang diusulkan memberikan tingkat akurasi deteksi keparahan stroke yang tinggi. Selain itu, model yang dihasilkan juga mampu mengklasifikasikan tingkat keparahan stroke dengan sensitivitas dan spesifitas yang memuaskan.

Dimana hasil akurasi pada model DNN dengan epoch 500 didapatkan rata-rata akurasi dari jumlah masing-masing klasifikasi sebesar 81.23% sedangkan hasil rata-rata hasil nilai uji presisi didapatkan sebesar 74.2% dan pada hasil rata-rata uji F1-Score didapatkan hasil sebesar 0.73. Dari hasil yang didapatkan pendekatan menggunakan kedua metode ini memiliki potensi untuk digunakan sebagai alat bantu klinis dalam menilai tingkat keparahan stoke pada pasien citra CT-SCAN.

ABSTRACT

Pamungkas, Haliim. 2023. **Analisis tekstur citra CT-SCAN dengan menggunakan metode GLCM (Grey Level Co-occurrence Matrix) dan DNN (Deep Neueal Network) Untuk deteksi tingkat keparahan stroke**, Skripsi. Program Studi Fisika. Fakultas Sains dan Teknologi. Universitas Islam Negeri Maulana Malik Ibrahim Malang. Dosen Pembimbing (I) Dr. H. Agus Mulyono, M.Kes, (II) Mubasyiroh, M.Pd.I.

Kata Kunci: GLCM, Stroke, DNN, F1-SCORE, Normal, Hemorrhage, Iskemik, Active Contour, Acuration, Precision

Stroke is one of the many deadly diseases in the world, with an estimated 3.4 million cases of stroke per year expected between 2012 and 2030 due to the increasing population approaching the productive age. This research employs an approach that integrates the Gray Level Co-occurrence Matrix (GLCM) method and Deep Neural Network (DNN) to detect the severity level of strokes in CT-SCAN images.

GLCM is used to extract texture features from the images, while DNN is used to model and classify the severity level of strokes. In the initial stage, CT-SCAN images with respective classifications are extracted using GLCM to obtain feature results. The extracted feature results are used as input for the DNN network, which is trained using a large dataset of CT-SCAN images with various severity levels of strokes to ensure good generalization. Experimental results show that the proposed method yields a high accuracy rate in detecting stroke severity. Furthermore, the generated model is capable of classifying the severity level of strokes with satisfactory sensitivity and specificity.

The accuracy results for the DNN model with 500 epochs show an average accuracy of 81.23% for each classification. The average precision test results yield a value of 74.2%, and the average F1-Score test results yield a value of 0.73. Based on these findings, the approach utilizing both methods has the potential to be used as a clinical tool in assessing the severity of strokes in patients' CT-SCAN images.

مستخلص البحث

فاموغكاس حلیم. 2023. تحليل نسيج صورل ct-scan باستخدام طرق GLCM (مصفوفة الحدوث المشترك للمستوى الرمادي) وDNN (الشبكة العصبية العميقة) للتعرف على مدى خطورة السكتة الدماغية. أطروحة. برنامج دراسة الفيزياء. كلية العلوم والتكنولوجيا. جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج المشرف الأول (1) دكتور أجوس موليونو، ماجستير في الصحة (2) ميشرة ماجستري

الكلمات الرئيسية: GLCM, سكتة دماغية, DNN, F1-SCORE, طبيعي, نرف, ترويه, محيط نشط

تعتبر السكتة الدماغية واحدة من الأمراض الفتاكة العديدة في العالم، حيث تشير التقديرات إلى أنه سيكون هناك ٣.٤ مليون حالة إصابة بالسكتة الدماغية سنويًا بين عامي ٢٠١٢ و ٢٠٣٠ بسبب اقتراب عدد كبير من السكان من سن الإنتاج. يهدف هذا البحث إلى استخدام نهج يدمج مصفوفة الحدوث المشترك للمستوى الرمادي وطرق الشبكة العصبية العميقة للكشف عن شدة السكتة الدماغية في صور يتم استخدامها لاستخراج ميزات النسيج من الصور، بينما يتم استخدام لنمذجة وتصنيف شدة السكتة الدماغية. في المرحلة الأولية، يتم استخراج صور مع كل تصنيف باستخدام للحصول على نتائج الميزات تم استخدام نتائج استخراج الميزات كمدخلات لشبكة التي تم تدريبها باستخدام مجموعة كبيرة من صور بمستويات مختلفة من شدة السكتة الدماغية لضمان تعميم جيد وتظهر النتائج التجريبية أن النهج المقترح يوفر مستوى عال من الدقة في الكشف عن شدة السكتة الدماغية. بالإضافة إلى ذلك، فإن النموذج الناتج قادر أيضًا على تصنيف شدة السكتة الدماغية بحساسية ونوعية مرضية. حيث أظهرت نتائج الدقة لنموذج بالعصر ٥٠٠ أن متوسط دقة عدد كل تصنيف بلغ ٨١.٢٣ ، في حين بلغ متوسط نتائج اختبار الدقة ٧٤.٢ ومتوسط نتائج اختبار من النتائج التي تم الحصول عليها، فإن النهج الذي يستخدم هاتين الطريقتين لديه القدرة على استخدامه كأداة سريرية في تقييم شدة السكتة الدماغية لدى المرضى على صور

BAB I

PENDAHULUAN

1.1 Latar belakang

Stroke merupakan penyebab tertinggi kecacatan seumur hidup bagi orang dewasa dan lima teratas penyebab kematian di amerika serikat, dengan kasus pertahun nya mendekati 759.000 kasus dalam kurun waktu setahun. Dimana perkiraan meningkatnya kasus stroke sebanyak 3.4 juta orang akan terjadi diantara tahun 2012 sampai 2030 diakibatkan banyaknya penduduk yang mendekati usia tidak produktif serta ditambah dengan penurunan kasus kematian setelah stroke, meskipun kematian yang diakibatkan oleh stroke telah menurun di amerika dalam waktu 2 tahun terakhir, trend menunjukkan kasus kematian akibat stroke telah merata dan mungkin akan meningkat kembali (Boehme et al., 2017).

Sumber daya manusia merupakan kekuatan terbesar dalam pengelolaan seluruh sumber daya yang terdapat di bumi. Karena pada dasarnya seluruh ciptaan Allah yang ada dimuka bumi ini sengaja diciptkaan Allah untuk kemaslahatan umat manusia. Hal ini sangat jelas telah ditegaskan oleh Allah dalam Q.S Al-Jatsiyah ayat 13:

وَسَخَّرَ لَكُمْ مَا فِي السَّمَاوَاتِ وَمَا فِي الْأَرْضِ جَمِيعًا مِنْهُ إِنَّ فِي ذَلِكَ لَآيَاتٍ
لِّقَوْمٍ يَتَفَكَّرُونَ

Artinya : “Dan Dia telah menundukkan untukmu apa yang di langit dan apa yang di bumi semuanya, (sebagai rahmat) daripada-Nya. Sesungguhnya pada yang demikian itu benar-benar terdapat tanda-tanda (kekuasaan Allah) bagi kaum yang berfikir.” (Q.S Al-Jatsiyah 45 : 13)

Menurut M.Quraish Shihab dalam (*Tafsir Al-Mishbah Jilid 13 -Dr. M. Quraish Shihab, n.d.*) penundukan langit dan bumi dipahami dalam arti semua

bagian – bagian alam yang terjangkau dan berjalan atas dasar satu sistem yang pasti, kait berkait dan dalam bentuk konsisten. Allah menetapkan hal tersebut dan dari saat ke saat mengilhami manusia tentang pengetahuan fenomena alam yang dapat mereka manfaatkan untuk kemsalahatan dan kenyamanan hidup manusia.

Allah menundukan semua untuk manusia, agar manusia tidak tunduk kepada yang ditundukkan itu, tetapi hanya kepada yang menundukkan. Sungguh buruk seseorang tunduk kepada siapa yang ditundukkan buat dirinya. Demikian komentar sementara ulama. *Sesungguhnya pada yang demikkian itu benar-benar terdapat ayat-ayat* yakni tanda dan bukti-bukti yang sangat jelas tentang kesan serta kekuasaan allah bagi kaum yang mau berpikir merenungkan ayat-ayat ini.

Dan Dia menundukan untukmu apa yang ada di langit dan apa yang ada di bumi semuanya memiliki arti, karunia dan kebaikan tersebut mencakup semua yang ada di langit dan bumi, berupa matahari, bulan, bintang, meteor dan lainnya yang terdapat pada di langit serta berbagai macam barang tambang dan lain sebagainya yang dipersiapkan untuk kepentingan dan kebutuhan pokok manusia (Tafsir as-Sa'di).

Oleh karena itu sumber daya yang ada harus dikelola dengan benar karena ini merupakan amanah yang akan dimintai pertanggung jawabanya kelak. Untuk mendapatkan pengelolaan yang baik, ilmu sangatlah diperlukan untuk menopang pemberdayaan dan optimalisasi manfaat sumber daya yang ada. Ada empat landasan untuk mengembangkan sumber daya manusia menurut pandangan islam, yaitu: *kebenaran, kejujuran, keterbukaan, dan keahlian.*(Kementrian Agama RI, Al-Quran Mushaf Alwasim).

Pada hasil foto sinar-X, citra merupakan struktur yang terlihat sebagai pola tertentu. Penggunaan perubahan struktur dari tulang yang digunakan sebagai diagnosis penyakit atau kelainan diperkenalkan pada tahun 1960 dimana foto yang digunakan merupakan bagian sinar-X femur proksimal.

Pengolahan citra tampak menjanjikan sebagai suatu metode yang digunakan untuk mengatasi keterbatasan pemeringkatan oleh pengamat, salah satu teknik yang cocok digunakan dalam analisis citra adalah analisis tekstur. Analisis tekstur digunakan untuk menghitung ciri dari pola struktur citra yang terekam pada foto sinar-X menggunakan ekstraksi ciri (Wahyuni, 2015).

Citra merupakan representasi dari sebuah objek yang disinari oleh sebuah sumber radiasi, yang pada dasarnya citra dilihat terdiri atas berkas-berkas cahaya yang dipantulkan dengan benda-benda disekitarnya, secara alamiah fungsi dari intensitas cahaya merupakan fungsi sumber cahaya yang menerapi objek, serta jumlah cahaya yang dipantulkan oleh objek yang akan dinotasikan (Fajri & Anifah, 2018).

Berdasarkan penelitian sebelumnya bahwa dengan menggunakan dataset berisi diagnosis pasien seperti tingkat hipertensi, kelainan jantung, dan glukosa yang dilatih menggunakan deep learning dapat menghasilkan hasil prediksi yang lebih baik, dimana telah ditentukan model arsitektur DNN dengan kombinasi pre processing *SMOTE* dan *tomek links* dapat menghasilkan *Performance accuracy*, *fi score*, dan *AUC sebesar 0.96, 0.9611, dan 0.981*. Hasil tersebut lebih tinggi dibandingkan penelitian sebelumnya (Faisal & Subekti, 2021).

GLCM merupakan metode untuk menganalisis suatu tekstur citra berdasarkan prosedur arimatika yang secara umum dapat menghilangkan artefak

secara efektif, metode GLCM juga dapat membedakan tekstur dengan jelas. GLCM dapat menentukan frekuensi pixel khususnya dalam area yang berbeda (Yunianto et al., 2021). Dalam penelitian mengenai klasifikasi kanker paru paru menggunakan naïve bayes dengan variasi filter dan ekstraksi ciri gray level co-occurrence matrix (GLCM) didapatkan hasil dari 120 data citra CT Scan mampu di klasifikasi dengan tingkat akurasi sebesar 88,3 %.

Namun, belum adanya penelitian tentang pendeteksian tingkat stroke menggunakan analisis tekstur GLCM dan klasifikasi menggunakan DNN. Sehingga, peneliti ingin melakukan penelitian ini untuk mengetahui tingkat akurasi dari hasil klasifikasi menggunakan DNN jika inputan yang diberikan merupakan hasil tekstur dari citra pasien yang didapatkan melalui analisa GLCM. Sehingga diharapkan penelitian ini bisa dijadikan salah satu acuan untuk dikembangkan pada penelitian selanjutnya.

1.2 Rumusan masalah

Rumusan masalah penelitian ini antara lain :

1. Bagaimana model DNN dengan gabungan data GLCM mampu mendeteksi tingkat keparahan stroke dengan tingkat akurasi yang tinggi?
2. Bagaimana tingkat akurasi dan f1-score yang didapatkan pada masing-masing epoch menggunakan metode GLCM dan DNN dalam menentukan tingkat stroke?
3. Bagaimana performa dari kombinasi metode DNN dan GLCM dalam klasifikasi tingkat keparahan stroke?

1.3 Tujuan penelitian

Tujuan penelitian ini antara lain :

1. Untuk mengetahui model DNN dengan gabungan metode GLCM dapat melakukan klasifikasi citra untuk mendeteksi tingkat keparahan stroke.
2. Untuk mengetahui tingkat akurasi pada hasil klasifikasi data ciri tekstur menggunakan DNN dan GLCM.
3. Untuk mengetahui performa masing masing epoch yang digunakan dalam melakukan klasifikasi tingkat keparahan stroke.

1.4 Batasan masalah

Batasan masalah pada penelitian berikut antara lain :

1. Citra yang digunakan adalah citra berformat jpg sehingga citra yang dilatih hanya bisa berasal dari satu sumber alat scanning
2. Penelitian didasarkan pada data diagnosis dan letak pendarahan
3. Segmentasi citra didasarkan pada penggunaan teknik active countour
4. Citra yang digunakan merupakan diagnosis subtype dari stroke hemoragik yaitu *intrcranial hemorrhage* dan stroke iskemik serta citra normal.

1.5 Manfaat penelitian

Manfaat pada penelitian ini antara lain :

1. Manfaat teoritis

Pada penelitian ini diharapkan dapat diketahui bagaimana teknik pengolahan citra menggunakan metode deep learning serta penggunaan GLCM sebagai teknik untuk menganalisis suatu tekstur citra ,sehingga dapat diketahui tingkat akurasi ketepatan percobaan melalui algoritma deep neural network serta metode GLCM untuk pendeteksian tingkat stroke.

2. Manfaat praktis

Untuk mahasiswa/pendidik diharapkan penelitian ini dapat menjadi salah satu sumber acuan bahan pelajaran dalam dunia fisika medis ataupun rekonstruksi citra serta dapat digunakan sebagai bahan pengembangan aplikasi yang mendukung proses diagnosis citra sehingga memudahkan

dalam dunia medis.

BAB II

DASAR TEORI

2.1 Ischemic Stroke

Penyebab utama stroke iskemik adalah infark serebral. Dengan suplai darah yang tidak cukup memadai ke dalam jaringan otak akan menyebabkan hilangnya fungsi jaringan reversibel dan dengan waktu yang cukup akan menghilangkan neuron dan struktur pendukung di sekitar otak.

Iskemia dapat memicu serangkaian peristiwa yang dimulai dengan hilangnya aliran listrik dan berkembang menjadi gangguan fungsi membran dengan masuknya kalsium yang menyebabkan excitotoxicity, generasi spesies oksigen reaktif, dan akhirnya hancurnya sel membran dan lisis sel (Feske, 2021).

Emboli merupakan mekanisme stroke yang paling umum. Sebagian besar emboli terjadi karena adanya gumpalan darah yang dihasilkan dari hati (kardioemboli) akibat penyakit jantung. Gangguan jantung umum yang menyebabkan stroke termasuk fibrilasi atrium, penyakit jantung katup, dan kardiomiopati dari infark miokard atau hipertensi (Feske, 2021).

Tidak seperti infark miokard, yang hampir selalu disebabkan oleh penyakit arteroklerotik pembuluh darah besar yang mempengaruhi arteri koroner, indentifikasi faktor risiko stroke diperumit oleh fakta bahwa stroke memiliki beragam banyak jenis.

Pada tingkat paling dasar, stroke dibagi menjadi stroke hemoragik dan iskemik. Mayoritas 80% stroke adalah iskemik, meskipun beberapa kasus relatif mengarah kepada stroke hemoragik dan stroke iskemik bervariasi di antara populasi yang berbeda. Stroke hemoragik dapat terjadi terutama pada

intraparenkim atau subarchnoid. Stroke iskemik dapat dibagi lagi menjadi dua bagian subtype atau kategori etiologi (Boehme et al., 2017).

2.2 ICH (intracranial hemorrhage)

ICH (intracranial hemorrhage) merupakan penyebab paling umum kedua stroke terhitung sebanyak 10% hingga 15% dari semua stroke. Meskipun hasil fungsional jangka panjang untuk penderita stroke serupa di antara kohort hemoragik dan iskemik. ICH membawa risiko kematian yang jauh lebih tinggi dibandingkan dengan stroke iskemik, dengan perkiraan 5 kali lebih besar daripada kematian untuk kejadian iskemik. Perbedaan kelangsungan hidup paling menonjol segera setelah stroke, dengan risiko kematian 4 kali lipat lebih tinggi (Smith & Eskey, 2011).

Hipertensi merupakan penyebab utama paling umum dari ICH yang terjadi secara spontan pada orang dewasa, mekanisme yang mendasari terjadinya ICH terkait dengan efek dari tekanan darah sistemik pada arteri, penetrasi kecil yang muncul dari pembuluh inkranial utama secara khusus dimana pembuluh-pembuluh ini disebut sebagai arteri lentikulostriata yang muncul dari arteri serebral tengah (Smith & Eskey, 2011).

Pendarahan hipertensi yang berasal dari ganglia basalis dan batang otak cenderung untuk meluas ke sistem ventrikel terdekat. Darah intraventikular secara khas tampak hiperdens pada hasil CT Scan, dan volume dapat berkisar dari lapisan tipis yang bergantung pada pengisian lengkap satu atau semua ventrikel.

2.3 Pengolahan citra

Pada bidang medis pengolahan suatu citra dikenal sebagai medical imaging (pencitraan medis) atau dengan nama lain Medical imging processing.

Pencitraan Medis merupakan langkah atau proses yang digunakan dalam proses membuat gambar tubuh manusia (organ dalam tubuh) untuk tujuan klinis (Nurhasanah, 2012).

Pengolahan citra digunakan pada suatu citra untuk mendapatkan citra yang memiliki kualitas yang lebih baik dibandingkan citra semula. Proses pengolahan citra dalam proses radioterapi sangat penting dimana proses ini digunakan dalam diagnosis kondisi penyakit tanpa harus melakukan pembedahan dan juga langkah perencanaan pengobatan selanjutnya (Nurhasanah, 2012).

2.3.1 Citra CT scan

CT Scan digunakan untuk menghasilkan citra organ internal (struktur anatomi). Dimana ct-scan mampu mendefinisikan volume target dan membantu penempatan dan pembentukan radiation beam. Sistem pemrosesan citra merupakan salah satu bagian yang secara langsung berhadapan dengan obyek yang diamati (pasien). Bagian ini terdiri dari sumber sinar-X, sistem kontrol, detektor dan akuisisi data.

Sinar-X merupakan radiasi yang bergerak merambat lurus, dan hal ini tidak dipengaruhi oleh medan listrik dan medan magnet. Sinar-X yang dihasilkan menembus zat padat dengan daya tembus yang tinggi. Untuk dapat mengetahui seberapa banyak sinar-X dikeluarkan atau dipancarkan ke tubuh pasien, maka dalam peralatan ct-scan dilengkapi sistem kontrol yang mendapat input dari komputer.

Analisis citra pada dasarnya terdiri dari tiga tahapan, ekstraksi ciri (feature extraction), segmentasi dan klasifikasi. Berdasarkan hal tersebut faktor

utama dalam mengekstraksi ciri adalah kemampuan mendeteksi keberadaan tepi (edge) dari objek di dalam citra (Nurhasanah, 2012).

2.3.2 Preprocessing

Preprocessing merupakan proses awal dilakukannya perbaikan suatu citra untuk menghilangkan noise. Preprocessing dilakukan untuk menghilangkan bagian-bagian yang tidak diperlukan pada gambar input untuk proses selanjutnya. Beberapa proses yang dilakukan dalam tahap preprocessing adalah, proses binerisasi, segmentasi, dan normalisasi (Rohpandi et al., 2015).

1. Binerisasi

Pada tahap binerisasi, gambar citra akan dikonversi menjadi citra biner. Citra biner (binary image) adalah citra yang hanya mempunyai dua nilai derajat keabuan: hitam dan putih. Pada pixel-pixel objek bernilai 1, dan pixel-pixel latar belakang bernilai 0. Sehingga latar belakang akan tampak berwarna putih, sedangkan objek akan berwarna hitam.

2. Segmentasi

Segmentasi pada citra memiliki tujuan untuk mengumpulkan pixel-pixel objek menjadi wilayah yang merepresentasikan suatu objek dengan cara memisahkan area atau objek dari latar belakangnya tujuan segmentasi citra digunakan untuk mendapatkan area atau obyek yang diinginkan pada suatu citra.

3. Normalisasi

Pada tahap normalisasi digunakan untuk mengurangi resolusi citra yang berguna saat proses pengenalan citra dan juga meningkatkan

akurasi pengenalan. Proses yang digunakan pada tahap normalisasi ini adalah proses penskalaan citra.

2.4 Aspek fisika dalam citra CT-Scan

Dalam CT-Scan aspek perlakuan fisika meliputi dari berbagai bagian seperti akuisisi data dan rekontruksi citra.

1. Akuisisi Data


Akuisisi data merupakan kumpulan hasil perhitungan transmisi sinar-X setelah sinar-X melalui tubuh pasien. Pada saat sinar-X melakukan penetrasi terhadap tubuh pasien, berkas tersebut akan diterima oleh detektor khusus yang menghitung nilai transmisi atau nilai atenuasi (penyerapan).

Penghitungan pada transmisi atau data harus terekam sebagai salah satu syarat rekontruksi citra. Pada skema kumpulan data pada saat pertama kali tabung dan detektor sinar-X bergerak pada garis lurus melewati kepala pasien, akan didapatkan hasil perhitungan transmisi selama pergerakan dari kiri ke kanan. Lalu sinar-X berotasi 1 derajat dan mulai lagi melewati kepala pasien, kali ini dengan arah sebaliknya (Alit Nur Cahyani, 2015).

Tahap pertama pada akuisisi data adalah proses scanning, pada proses ini tabung sinar-X dan detektor bergerak mengelilingi pasien untuk mendapatkan data atenuasi pasien. Detektor menangkap radiasi yang diteruskan melalui pasien dari beberapa lokasi dan dari berbagai sudut. Nilai atenuasi dan transmisi relatif dapat dihitung sebagai berikut (Kalman, 1976)

$$I = \frac{\log}{I_0} \quad (2.1)$$

Dengan I_0 merupakan jumlah intensitas sinar-X pada tabung dan I merupakan intensitas sinar-X pada detektor.



Gambar 2.1 Skema akuisisi data CT-Scan

Pada Gambar 2.1 sinar-X mengalami atenuasi setelah menembus objek yang akan ditangkap oleh detektor yang berhadapan dengan sumber sinar yang letaknya berada tepat di belakang objek. Pada waktu yang bersamaan detektor yang menerima berkas dari sinar-X yang berasal dari sumber sinar, berkas radiasi sinar-X tersebut oleh detektor akan dirubah menjadi bentuk digital. Pada tahap selanjutnya data tersebut dikirim ke komputer dan melalui proses matematis data-data tersebut mengalami rekonstruksi dan akan ditampilkan kembali pada layar monitor berupa citra dengan skala keabuan (grayscale) (Alit Nur Cahyani, 2015).

2. Rekontruksi citra

Menurut pandangan islam, rekonstruksi citra merupakan sebuah tindakan yang dinilai berdasarkan niat,tujuan,serta dampak moral. Prinsip-prinsip islam yang menekankan pentingnya suatu kebenaran,keadilan,dan etika dalam setiap tindakan. Oleh karena itu, rekonstruksi citra yang dilakukan untuk

mengembalikan citra yang rusak atau kabur dengan tujuan memperoleh informasi yang akurat atau membantu dalam kepentingna medis dapat dianggap sesuai nilai-nilai islam. Selain itu, rekonstruksi citra juga dapat diartikan sebagai usaha kreatif dalam memanfaatkan potensi teknologi untuk tujuan yang positif dan produktif, selama tindakan tersebut tidak bertentangan dengan prinsip-prinsip etika islam.

Namun, dalam melaksanakan rekonstruksi citra, perlu dijaga agar tidak melanggar nilai-nilai privasi, mencemarkan nama baik, atau menyesatkan orang dengan hasil rekonstruksi yang tidak akurat. Islam mendorong menjaga kehormatan individu dan masyarakat, serta menghindari segala bentuk manipulasi atau penipuan. Dalam hal ini, rekonstruksi citra harus dilakukan dengan penuh tanggung jawab, menjunjung tinggi nilai-nilai moral, dan memastikan bahwa hasil akhirnya bermanfaat dan sesuai dengan etika islam.

Allah SWT menjelaskan bahwa Dialah yang mengendalikan malam dan siang, serta matahari dan bulan. Semua itu untuk kepentingan manusia sebagai nikmat yang diciptakan Allah untuk mereka. Allah mengendalikan siang dan malam secara berganti-ganti. Malam sebagai waktu untuk beristirahat dan tidur agar tenang pikirannya di siang hari. Sedang siang adalah waktu untuk berusaha mencari rezeki guna memenuhi kebutuhan hidup, selaras dengan firman Allah SWT An-nahl (16) : 12

وَسَخَّرَ لَكُمُ اللَّيْلَ وَالنَّهَارَ وَالشَّمْسَ وَالْقَمَرَ وَالنُّجُومَ مُسَخَّرَاتٍ بِأَمْرِهِ إِنَّ فِي ذَلِكَ لَآيَاتٍ لِّقَوْمٍ يَعْقِلُونَ

Artinya : “Dan Dia menundukkan malam dan siang, matahari dan bulan untukmu. Dan bintang-bintang itu ditundukkan (untukmu) dengan perintah-Nya. Sesungguhnya pada yang demikian itu benar-benar ada tanda-tanda (kekuasaan Allah) bagi kaum yang memahaminya)”(QS.An-nahl 16 : 12)

Ayat diatas menegaskan bahwa matahari, bulan, dan binatang itu menjadi tanda bukti yang jelas bagi mereka yang mau memikirkan tanda-tanda kekuasaan Allah dan dapat meamhami hukum-hukum yang berlaku di alam ini. Hal ini mengandung pengertian bahwa memikirkan tanda-tanda kekuasaan Allah yang terdapat di angkasa tidaklah diperoleh dengan pengluhatan selintas saja melainkan dengan merenungkan dan memikirkan dengan akal yang sehat (Kementrian Agama RI, Al-Quran Mushaf Alwasim).

Setelah proses perhitungan transmisi, data yang didapatkan dikirim ke komputer untuk melalui tahap selanjutnya. Komputer menggunakan tehnik khusus dalam melakukan rekonstruksi citra CT-Scan tahap ini dinamakan sebagai rekonstruksi algoritma. Sebagai contoh, rekonstruksi algoritma yang dipakai oleh hounsfield dalam mengembangkan CT-Scan pertama dikenal dengan *algebraic reconstruction technique*.

Beberapa metode digunakan untuk merekontruksi gambar tomografi, mulai dengan *back projection* sampai konvolusi. Untuk mendapatkan gambar yang lebih baik maka digunakan metode konvolusi. Proses rekonstruksi dalam tahap konvolusi dapat dinyatakan dalam bentuk matematik yaitu transformasi fourier. Dengan menggunakan konvolusi dan transformasi fourier maka bayangan yang didapatkan radiografer dapat dimanipulasi dan dikoreksi sehingga menghasilkan gambar yang lebih baik.

Rekonstruksi matrik merupakan deretan baris dan kolom dari picture element (pixel) dalam proses rekonstruksi gambar. Rekonstruksi matrik ini adalah salah satu struktur elemen dari dalam memori komputer yang berfungsi untuk merekonstruksi gambar. Jumlah ukuran matrik yang dapat digunakan dalam

scanning citra yaitu 80 x 80, 128 x 128, 256 x 256, 512 x 512, dan 1024 x 1024. Pada proses ini resolusi gambar akan terpengaruh dimana semakin tinggi matrik yang digunakan maka semakin tinggi resolusi yang dihasilkan (Alit Nur Cahyani, 2015).

Pada rekonstruksi citra pada CT-Scan menggunakan data proyeksi. Algoritma proyeksi balik yang difilter (FPB) akan menghasilkan gambar berkualitas tinggi ketika ada proyeksi cukup lengkap (Arndt et al., 2021).

Pada algoritma rekonstruksi citra ini memiliki dua pilar yaitu akurasi dan stabilitas, sementara pada algoritma deep learning telah ditunjukkan rekonstruksi yang akurat, sedangkan pada pilar stabilitas masih belum ada dalam algoritma berbasis deep learning saat ini untuk rekonstruksi gambar citra (Arndt et al., 2021).

Tiga isu penting ketidakstabilan metode deep learning dalam rekonstruksi citra meliputi :

1. Ketidakstabilan mengenai gangguan terkecil dalam gambar citra.
2. Ketidakstabilan mengenai perubahan struktural kecil (perubahan citra otak dengan atau tanpa tumor otak).
3. Ketidakstabilan mengenai perubahan jumlah sampel.

Pentingnya stabilitas pada metode rekonstruksi gambar yang akurat dalam pencitraan medis dianggap sebagai kebutuhan yang stabil dan andal dalam mendiagnosis suatu penyakit (Arndt et al., 2021).

2.5 Tekstur Citra

Tekstur pada citra didefinisikan sebagai bentuk distribusi spasial dari derajat keabuan didalam sekumpulan pixel yang bertetangga. Tekstur pada citra

tidak dapat diidentifikasi untuk sebuah pixel, melainkan tekstur pada suatu citra dianggap sebagai suatu kesatuan. Dapat juga dikatakan bahwa tekstur pada suatu citra merupakan sifat – sifat atau karakteristik yang dimiliki oleh suatu daerah yang cukup besar sehingga sering disebut sifat tersebut dapat berulang dalam daerah tertentu.

Pengertian tentang tekstur dalam hal ini adalah keteraturan pola – pola yang terbentuk melalui susunan pixel – pixel dalam citra. Suatu permukaan dinyatakan mempunyai informasi tekstur, jika luasnya dapat diperbesar tanpa mengubah skala citra, maka sifat – sifat permukaan hasil perluasan akan memiliki sifat kemiripan dengan permukaan asalnya (Permadi & Murinto, 2015).

Analisis tekstur cukup lazim dimanfaatkan sebagai proses untuk melakukan klasifikasi serta interpretasi citra. Suatu proses klasifikasi citra berbasis analisis tekstur seringkali membutuhkan tahapan ekstraksi ciri, dimana proses ini memiliki tiga macam metode yaitu metode statistik, metode spektral dan metode struktural.

Metode statistik digunakan untuk menghitung statistik distribusi derajat keabuan (histogram) dengan mengukur tingkat kontras, granularitas, dan kekasaran suatu daerah dari hubungan ketetanggaan antar piksel dalam citra. Paradigma pada statistik ini penggunaannya tidak terbatas, sehingga sesuai untuk tekstur – tekstur alami yang tidak terstruktur dari sub pola dan himpunan aturan (Permadi & Murinto, 2015).

2.6 GLCM (Gray level co-occurrence matrix)

Pada ekstrak fitur menggunakan metode GLCM akan mewakili serangkaian fitur untuk mengurangi kesalahan klasifikasi gambar citra, GLCM

dapat menjelaskan banyaknya penyesuaian dalam kecerahan piksel nilai dalam gambar citra. GLCM mewakili setiap frekuensi semua pasangan lapisan abu-abu yang dibagi dengan jarak dalam arah nodul I dan j . karakter dasar GLCM digunakan untuk meskalakan, mengkarakterisasi fitur-fitur kelengkungan. Fitur-fitur ini didefinisikan sebagai (Jony et al., 2019).

1. Area

Area merupakan nilai skalar bilangan real dari piksel aktual dalam sebuah ROI (Region of interest) yang telah diekstraksi. Dalam sebuah ROI array dihasilkan melalui transformasi yang berisi piksel dengan nilai 255.

2. Perimeter

Perimeter merupakan nilai linear yang menyimpan pixel nodul, pada bagian ini akan digunakan untuk mengekstrak panjang batas ROI. Pada bagian ini akan mengubah fungsi untuk membuat array di tepi yang pikselnya berisi 255 nilai, setidaknya ada satu pixel yang menyimpan nilai 0.

Pada fungsi GLCM digunakan untuk mencirikan tekstur dari gambar dengan menghitung seberapa sering pasangan piksel dengan nilai tertentu. Fitur-fitur ini digunakan untuk menghitung masing-masing matriks co-occurrence yang diperoleh dengan menggunakan arah 0° , 45° , 90° , dan 135° kemudian empat nilai dari arah tersebut dirata-ratakan (Korchiyne et al., 2014).

1	0	0	0	0
1	1	0	0	0
1	1	1	0	0
1	1	1	1	0
1	1	1	1	1

0	0	1
0	6	0
1	4	10

Gambar 2.2 Model biner dan matriks co-occurrence yang sesuai

Haralick menggambarkan dalam co-occurrence matriks beberapa fitur statistik yang dapat dihitung untuk menggambarkan tekstur sebuah citra sebanyak 22 fitur (Haralick, 1979). Dimana pada penelitian ini menggunakan 13 fitur yang didapatkan dari hasil citra yang tersegmentasi :

1. Contrast

Kontras akan mengembalikan nilai ukuran kontras intensitas antara piksel dan sebelahnya di atas seluruh gambar Menunjukkan ukuran penyebaran (momen inersia) elemen-elemen matriks citra. Jika letaknya jauh dari diagonal utama, nilai kekontrasan besar. Secara visual, nilai kekontrasan adalah ukuran variasi antar derajat keabuan suatu daerah citra.

$$cont = \sum_{i,j=0}^{N-1} P_{ij} (i - j)^2 \quad (2.1)$$

Nilai kontras juga dikenal sebagai varian dan inertia.

2. Correlation

Nilai correlation mengembalikan nilai korelasi antara pixel dengan pixel yang lainnya di seluruh gambar Menunjukkan ukuran ketergantungan linear derajat keabuan citra sehingga dapat memberikan petunjuk adanya struktur linear dalam citra.

$$corr = \sum_{i,j=0}^{N-1} \frac{(i - \mu)(j - \mu)}{\alpha^2} \quad (2.2)$$

Dimana nilai correlation memiliki range = [-1 1], nilai correlation adalah 1 atau -1 untuk citra yang berkorelasi positif atau negatif sempurna.

3. Energy

Nilai energi akan mengembalikan jumlah elemen kuadrat dalam GLCM. Pada fitur ini akan mengembalikan nilai yang digunakan untuk menggunakan untuk mengukur konsentrasi pasangan intensitas pada matriks GLCM.

$$eng = \sum_{i,j=0}^{N-1} (P_{ij})^2 \quad (2.3)$$

Dimana :

P = matriks GLCM normalisasi

i = indeks baris matriks P

J = indeks kolom matriks P

4. Homogeneity

Pada nilai homogenitas akan mengembalikan nilai yang mengukur kedekatan distribusi elemen matrix dalam GLCM ke diagonal GLCM

$$hom = \sum_{i,j=0}^{N-1} \frac{P_{ij}}{1 + (i - j)^2} \quad (2.4)$$

P_{ij} = Element i,j dari GLCM yang simetris dan telah ternormalisasi

N = Jumlah tingkat keabuan pada gambar

5. Entropy

Nilai entropy merupakan nilai yang didapatkan melalui pengukuran terhadap tingkat gangguan pada citra semakin besar nilai entropy maka semakin besar juga noise yang terdapat pada citra, nilai entropy akan berbanding terbalik dengan nilai ASM (angular second moment) (Singh et al., 2014).

$$ent = \sum_{i,j=0}^{N-1} P_{ij} \ln P_{ij} \quad (2.5)$$

6. Dissimilarity

Nilai dissimilarity didapatkan melalui ukuran jarak antara masing – masing objek piksel di wilayah yang diinginkan dan mengukur linear variasi lokal dalam gambar.

$$Diss = i - j + p(i,j) \quad (2.6)$$

Dimana :

P = matriks GLCM normalisasi

i = indeks baris matriks P

J = indeks kolom matriks P

7. Autocorrelation

Nilai pada autocorrelation akan mengembalikan nilai yang digunakan untuk mengukur hubungan pengamatan antara titik waktu yang berbeda, dan dengan demikian mencari pola atau tren selama deret waktu.

$$Auc = i.j.M_{ij} \quad (2.7)$$

i = indeks baris matriks P

J = indeks kolom matriks P

M_{ij} = elemen dari I,j yang telah dinormalisasi

8. Cluster Shade

Pada fitur ini digunakan untuk mengukur kemiringan dari sebuah matriks dan untuk digunakan mengukur persepsi dari konsep uniformitas.

$$cshade = M_{ij} (i + j - \mu_x - \mu_y)^3 \quad (2.8)$$

Dimana :

i = indeks baris matriks P

J = indeks kolom matriks P

M_{ij} = elemen dari i,j yang telah dinormalisasi

μ = GLCM mean (estimasi nilai dari intensitas semua pixel yang berhubungan dan berkontribusi dalam GLCM)

9. Sum variance

Nilai pada fitur ini akan mengembalikan nilai ukuran heterogenitas yang menempatkan bobot lebih tinggi pada pasangan pixel tetangga yang menyimpang dari nilai rata-rata.

$$Svar = (n - save)^2 \cdot p_{x+y}(n) \quad (2.9)$$

Dimana :

n = jumlah pasangan data

$save$ = sum of average

px = rata – rata kumpulan data

10. Sum average

Nilai pada fitur ini akan mengembalikan nilai rata rata semua nilai dari pixel bertetangga.

$$\text{Avg} = (n \cdot p_{x+y}^{(n)}) \quad (2.10)$$

Dimana :

n = jumlah pasangan data

px = rata – rata kumpulan data

11. Cluster prominenece

Nilai pada fitur ini akan mengembalikan ukuran asimetri. Ketika nilai dari cluster prominence ini menunjukkan nilai yang tinggi maka citra menjadi kurang simetris, selain itu. Ketika nilai keunggulan klaster rendah, ada puncak dalam matriks GLCM di sekitar nilai rata – rata. Untuk gambar ultrasound, nilai cluster prominence yang rendah menunjukkan variasi kecil dalam skala abu – abu.

$$pro = (i + j - \mu_x - \mu)^4 p(i, j) \quad (2.11)$$

Dimana :

i = indeks baris matriks P

J = indeks kolom matriks P

μ = GLCM mean (estimasi nilai dari intensitas semua pixel yang berhubungan dan berkontribusi dalam GLCM)

12. Maximum probability

Nilai pada fitur ini akan mengembalikan nilai respon terkuat dari co-occurrence matrix. Nilai ini meyakinkan tingkat keteraturan dari suatu citra, semakin tinggi nilai maximum probability maka semakin teratur teksturnya.

$$MP = \max(p(i, j)) \quad (2.12)$$

Dimana :

p_x = rata – rata kumpulan data

i = indeks baris matriks P

J = indeks kolom matriks P

13. Difference entropy

Pada fitur ini akan mengembalikan nilai dari perbedaan nilai entropy pada piksel yang bertetangga.

$$Dent = (n - \mu_x - y)^2 \cdot p_x - y(n) \quad (2.13)$$

Dimana :

n = jumlah pasangan data

p_x = rata – rata kumpulan data

μ = GICM mean (estimasi nilai dari intensitas semua pixel yang

berhubungan dan berkontribusi dalam GLCM

2.7 DNN (Deep neural network)

Jaringan syaraf tiruan (JST) merupakan salah satu bagian dari pembelajaran mesin yang digunakan untuk mempelajari fungsi pemetaan antara vektor input dan output arbitrer. Diantara metode paling baik deep neural network adalah salah satu jaringan syaraf tiruan yang memiliki lebih banyak lapisan

dibandingkan dengan metode yang sejenis. Publikasi terbaru menunjukkan bahwa DNN dapat mempelajari pemetaan yang lebih rumit dengan mudah dan tampil lebih baik dibandingkan dengan jst dengan hanya satu lapisan (Liu et al., 2019).

Sebuah jaringan syaraf konvolusi dalam (CNN) adalah DNN yang memiliki spesialisasi dalam mempelajari fungsi pemetaan antara gambar dan fitur dalam vektor, seperti label, segmentasi, dan gambar lainnya. DNN yang terlatih dapat melakukan tugas-tugas seperti pengenalan objek, segmentasi, dan generasi gambar tergantung pada pemetaan yang diinginkan (Liu et al., 2019).


Banyaknya model DNN juga berguna untuk segmentasi gambar dan jaringan syaraf konvolusi yang dapat digunakan untuk memetakan gambar lain dari masing-masing pixel gambar tersebut, selain dari model yang banyak, kunci keberhasilan dari sebuah DLM (deep learning model) adalah bagaimana DLM dapat memiliki set data pelatihan sebanyak mungkin. Sebuah survey studi yang menggunakan DLM untuk citra medis segmentasi sejak 2015 menggambarkan bahwa telah banyak menggunakan algoritma untuk melatih lebih dari 100 sample (Liu et al., 2019).

Pengenalan model DLM (deep learning model) telah merubah paradigma dalam otomatisasi tugas di radiasi onkologi. DLM bekerja dengan melatih data dalam jumlah besar, dan mampu mengetahui pola kompleks dalam data. DLM dapat dilatih untuk mengenali pola dengan kebutuhan tanpa campur tangan manusia selama periode pelatihan dan mampu menghasilkan prediksi yang baik secara akurat (Liu et al., 2019).

Dalam DNN terjadi proses algoritma yang digunakan untuk meniru proses jaringan syaraf dalam mengestrak informasi yang berguna untuk mengenali pola

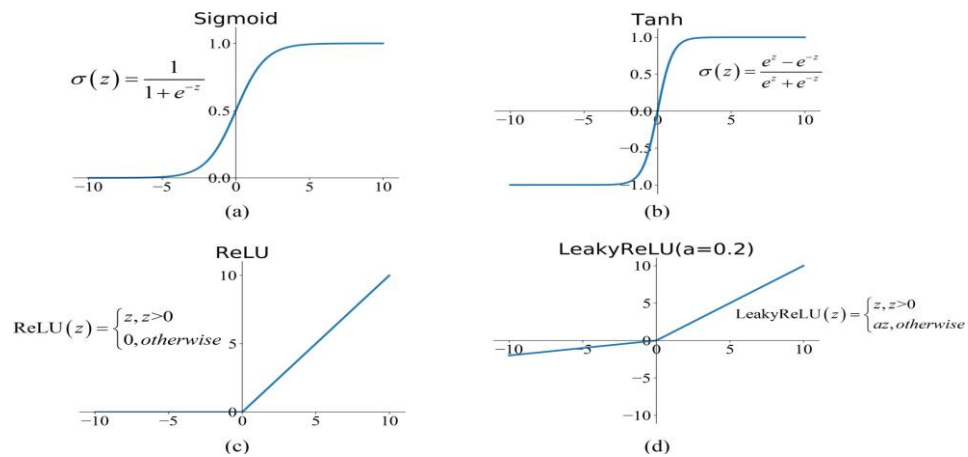
dari informasi yang diberikan. Deep Neural Network memerlukan sebuah desain jaringan syaraf tiruan yang didalamnya berisi lapisan-lapisan yang berisi lapisan pengestrasi fitur dengan metode seperti konvolusi, lapisan pengelompokan informasi seperti pooling, serta lapisan node syaraf yang akan dilatih sehingga dapat mengenali sebuah pola informasi dari data yang diberikan (Faisal Rifiarrasyid et al., 2021).

Pada deep learning atau yang lebih dikenal dengan metode *deep neural network* sendiri didalamnya terdapat sebuah arsitektur dan *hypermater* jaringan yang harus dilakukan *setup* untuk mendapatkan nilai yang lebih maksimal. Pada pemodelan DNN menggunakan *library* Keras dan *Back-end* Tensorflow (Faisal & Subekti, 2021).



Gambar 2.3 Arsitektur jaringan DNN

Pada setiap layer pada jaringan DNN selalu diikuti oleh beberapa fungsi, yang sering disebut sebagai fungsi aktivasi yaitu fungsi sigmoid, fungsi relu dan fungsi tanh.



Gambar 2.4 Fungsi aktivasi yang sering digunakan pada algoritma DNN

Pada **Gambar 2.3** sebuah algoritma DNN umumnya akan terdiri dari beberapa lapisan input, beberapa lapisan tersembunyi, dan lapisan output. Setiap lapisan ini terdiri dari banyak neuron, dalam matematika klasik perhitungan y neuron ditulis sebagai :

$$y = ((x, W) + b) \quad (2.14)$$

Dimana $f(-)$ merupakan fungsi nonlinear yang disebut fungsi aktivasi, dan W dan b adalah nilai bobot dan nilai bias yang terkait dengan neuron. Tujuan penggunaan fungsi aktivasi untuk memperkenalkan jaringan syaraf yang memungkinkan untuk mengatasi masalah nonlinear yang cukup kompleks (Feng et al., 2019).

2.8 Active Contour

Segmentasi citra menggunakan active contour memiliki beberapa variasi salah satunya merupakan segmentasi *active contour* berbasis wilayah dimana metode ini akan mengekstrak objek dengan meminimalkan fungsi energi di atas wilayah selain kurva. Fungsi energi akan selalu didefinisikan sebagai integral dari sebuah wilayah dari beberapa fitur statistik di dalam semua objek. Dalam

beberapa pendekatan secara statistik dan variasi akan menggunakan kriteria bayes/MDL yang digeneralisasi, yang juga merupakan fungsi mumford-shah yang digeneralisasi (Shang et al., 2008).

Active contour merupakan model kurva tertutup yang secara eksplisit dapat di representasikan dalam bidang(x,y) sebagai berikut :

$$C(s) = (x(s),y(s)) \quad (2.15)$$

Dimana s merupakan panjang yang telah dinormalisasi, $s \in [0,1]$ merupakan nilai parameter. Dalam *contour* memiliki total energy yang direpresentasikan melalui ($E(C)$) yang merupakan jumlah dari dua energi internal dan eksternal yang di representasikan.

$$E(C) = E_{INT} + E_{EXT} \quad (2.16)$$

E_{int} merupakan fungsi energi dalam dimana energi ini berhubungan dengan contour itu sendiri, energi ini akan mengontrol panjang dan derajat kehalusan. Dan dengan demikian dapat direpresentasikan kembali ke dalam persamaan berikut

$$E_{int} = E_{Elast} + E_{Bind} \quad (2.17)$$

Active countour tradisional memberikan identifikasi yang cukup akurat dari tepi objek yang disegmentasi hanya jika digambar dekat tepi, artinya diperlukan pengetahuan sebelumnya tentang bentuk objek karena menggunakan informasi lokal untuk kontur dan ini salah satu masalah yang sulit selain itu *active contour tradisional* akan mempertahankan struktur yang sama selama pengembangan kontur, sehingga tidak dapat menemukan lebih dari satu batas pada satu waktu,

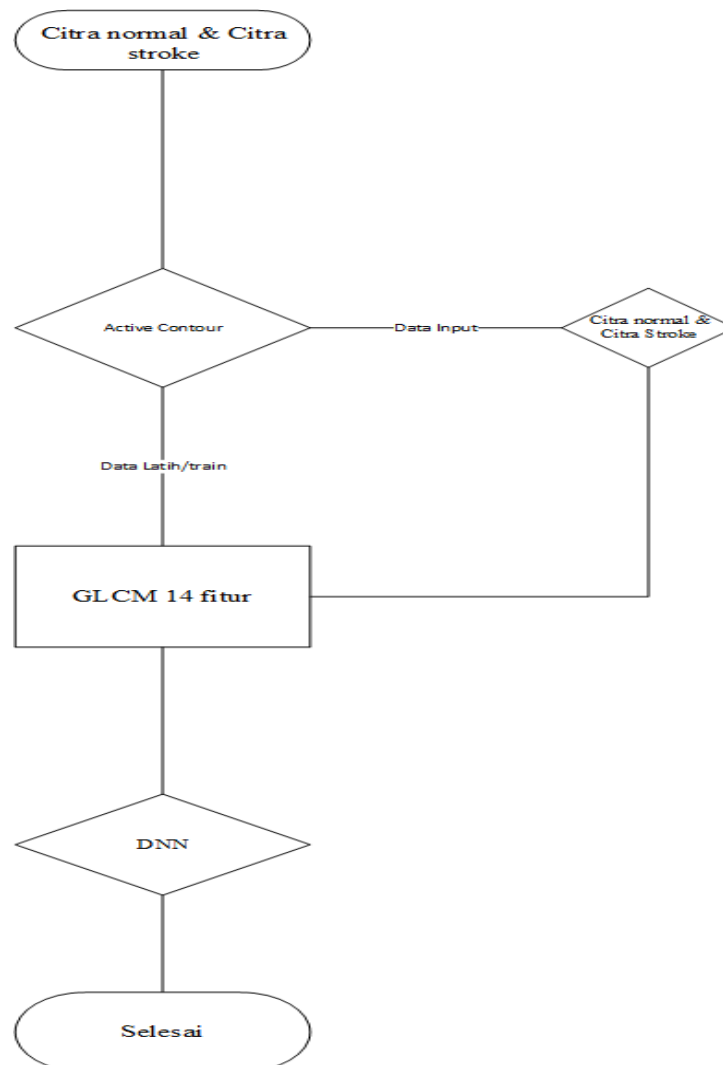
asrtinya tidak dapat dibagi menjadi beberapa batas atau terdiri dari penggabungan beberapa garis primer (Radhi & Kamil, 2021).

BAB III METODE PENELITIAN

3.1 Kerangka Konseptual

Adapun pada penelitian ini menggunakan hasil ekstraksi tekstur pada citra yang memiliki 3 klasifikasi normal, hemorrhage, iskemik, hasil ekstraksi tekstur tersebut kemudian dilatih menggunakan algoritma deep neural network.

Kerangka konsep pada penelitian ini adalah sebagai berikut :



Gambar 3.1 Kerangka konseptual

1. Pada proses pertama citra normal dan citra yang terdiagnosis hemoragik dan iskemik beberapa diantaranya tidak terlihat perbedaannya secara langsung sehingga dibutuhkan analisa lebih dalam sehingga dilakukan analisa tekstur pada citra tersebut
2. Sebelum masuk pada proses ekstraksi menggunakan GLCM citra yang telah dipersiapkan akan dilakukan segmentasi menggunakan segmentasi active contour sesuai dengan letak pendarahan.
3. Setelah proses segmentasi pada hasil segmentasi di lakukan analisis tekstur menggunakan GLCM.
4. Setelah analisis tekstur didapatkan maka dilanjutkan dengan klasifikasi citra menggunakan algoritma DNN.

3.2 Jenis Penelitian

Jenis penelitian ini merupakan jenis uji eksperimental dimana citra yang sudah diakuisisi yang didapatkan pada database physionet.org yang merupakan sebuah website clinical radiology dibawah pengawasan MIT laboratory akan dianalisis tekstur citra pada data tersebut menggunakan metode GLCM setelah melalui uji tekstur maka akan dilanjutkan klasifikasi menggunakan algoritma DNN.

3.3 Waktu dan Tempat Penelitian

Lokasi pada penelitian ini dilakukan bertempat di lab.komputer fakultas sains dan teknologi jurusan fisika UIN MALANG. Menggunakan laptop dengan spesifikasi Intel Core™ i5-10210U processor (6 MB Smart Cache, up to 4.2 GHz) dan kartu grafis nvidia MX250 dengan RAM (*random acces memory*) sebesar 4 GB.

3.4 Alat dan Bahan

Adapun alat dan bahan yang akan digunakan dalam penelitian kali ini yaitu :

3.4.1 Alat Penelitian

1. Komputer windows/linux dengan spesifikasi i5 1020 ram 4 gb menggunakan kartu grafis nvidia mx250
2. Software Matlab
3. Software Visual studio code
4. Software ImageJ

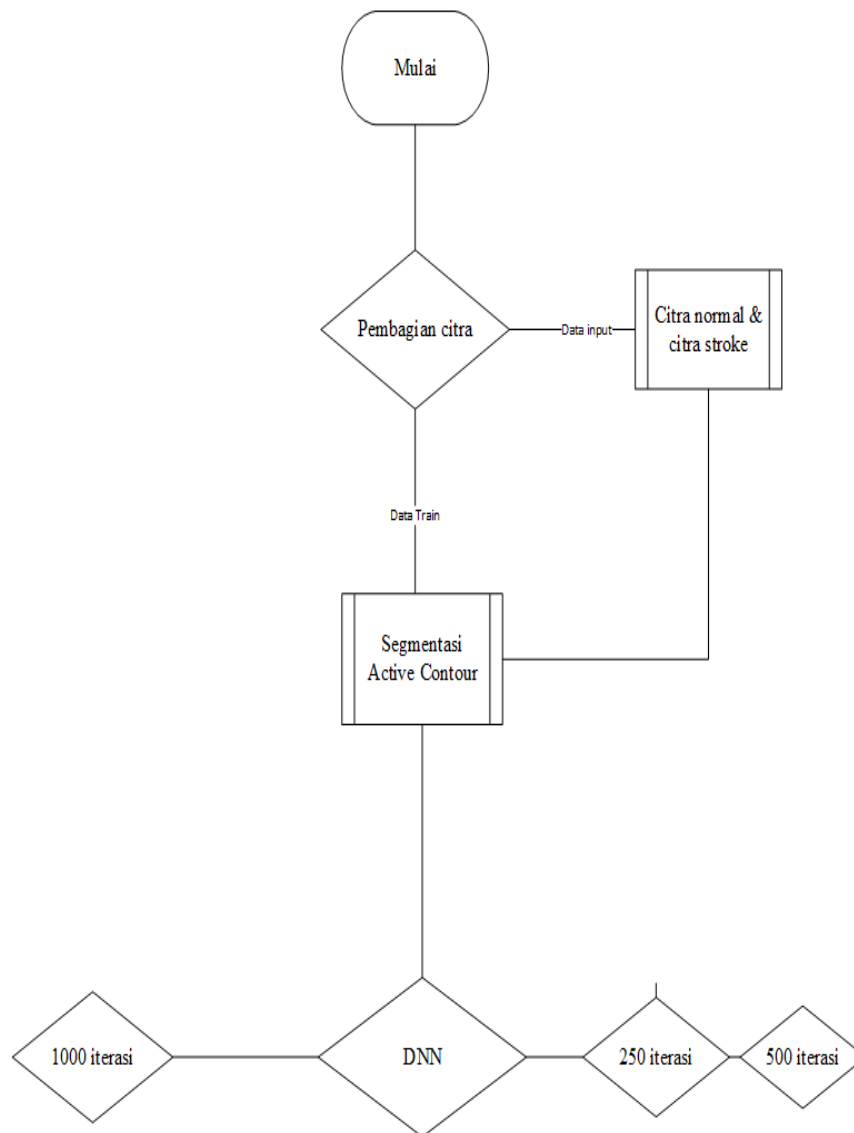
3.4.2 Bahan Penelitian

1. Gambar citra bagian kepala hasil akuisisi data CT-Scan yang didapatkan pada database physio.org dibawah pengawasan MIT laboratory
2. Library Tensorflow
3. Library Graycomatrix

3.5 Variabel Penelitian

Pada penelitian ini terdapat dua variabel pada variabel pertama yaitu variabel bebas berupa Citra Ct-Scan normal dan stroke yang meliputi stroke dengan diagnosa hemorrhage dan iskemik dengan ketebalan slice 5 mm serta pada variabel terikat merupakan hasil analisa tekstur dari GLCM dan klasifikasi DNN.

3.6 Diagram penelitian



Gambar 3.2 Diagram penelitian

1. Pada langkah awal citra yang berisi diagnosis hemorrhage dan iskemik maupun citra normal dipisah menjadi 2 bagian, pertama data citra untuk dijadikan test, kedua merupakan data citra yang dijadikan data training.
2. Setelah data terkumpul masing masing citra akan diberikan teknik segmentasi area active contour untuk menentukan daerah yang terjadi pendarahan.

3. Setelah hasil segmentasi maka citra dijadikan dalam bentuk biner yaitu antara rentang (0,1) dimana nilai 1 adalah daerah yang dikehendaki sedangkan pada nilai 0 akan diabaikan.
4. Setelah melalui proses segmentasi maka akan dilakukan analisis tekstur menggunakan metode GLCM dengan 13 fitur statistik yang dimiliki, 13 fitur ini dihitung dari arah $0^\circ, 45^\circ, 90^\circ, 180^\circ$ kemudian hasil yang telah didapat dirata rata.
5. Setelah melalui proses analisis tekstur hasil yang telah dibagi menjadi dua, data pertama merupakan data training, data kedua merupakan data tes.
6. Pada proses ini data training akan dilatih menggunakan algoritma DNN dengan *epoch* sebanyak 250,500,1000 , kemudian setelah data dilatih maka diberikan inputan baru dari data tes yang merupakan data analisis tekstur menggunakan GLCM. Pada bagian ini data tes tidak diberi diagnosis apakah citra itu normal,iskemik maupun mengalami hemorrhage

3.7 Prosedur Penelitian

3.7.1 Pengambilan data dan pengelompokan

1. Pengambilan data melalui rekam medis CT-Scan
2. Citra yang digunakan citra dengan diagnosis Stroke hemoragik, stroke iskemik dan normal
3. Citra berbentuk file Jpg yang belum mengalami pre processing pada citra
4. Citra memiliki matriks sebesar 650 x 650
5. Citra yang didapatkan dikelompokkan menjadi 3 bagian

6. Citra normal berisi 10 rekam medis dengan masing-masing rekam medis memiliki jumlah citra sebanyak 3 gambar
7. Citra stroke hemoragik dan iskemik berisikan 10 rekam medis dengan masing-masing rekam medis memiliki jumlah citra sebanyak 3 gambar
8. Masing masing rekam medis tersebut diambil nilai fiturnya.

3.7.2 Proses ekstrasi fitur GLCM

1. Pembuatan code menggunakan visual studio code
2. Dipersiapkan masing-masing 10 citra normal dan 10 citra hemorrhage dan iskemik
3. Pembuatan code fitur GLCM
4. Dihitung analisis tekstur citra menggunakan GLCM dari arah $0^{\circ}, 45^{\circ}, 90^{\circ}, 180^{\circ}$ dan dirata-ratakan.
5. Hasil ekstrasi masing – masing citra dimasukkan ke dalam file csv.

3.7.3 Pembuatan GUI algoritma DNN dan GLCM menggunakan python

1. Dipersiapkan software visual studio code yang sudah terinstall bahasa python
2. Download library tensorflow, numpy, keras yang akan digunakan sebagai klasifikasi dari inputan fitur GLCM
3. Pembuatan code

3.7.4 Proses inputan ke dalam algoritma DNN

1. Pada tahap pertama dataset yang berisi nilai fitur dipanggil menggunakan library keras
2. Pada arsitektur DNN `batch_size` di set sebesar 10
3. Selanjutnya input dataset yang memiliki jumlah 14 kolom dengan 1 kolom nya berupa hasil diagnosis dengan nilai (1,0)
4. Nilai 1 untuk citra dengan diagnosis hemorrhage
5. Nilai 0 untuk citra dengan diagnosis normal
6. Nilai 2 untuk citra dengan diagnosis iskemik
7. Selanjutnya pada algoritma DNN di set untuk *epoch* sebanyak 250, 500, 1000 iterasi

3.8 Pengumpulan Data

Pada penelitian ini hasil uji tekstur pada citra dimasukkan dalam tabel berikut, dimana pada tabel berikut merupakan hasil analisis tekstur pada data citra yang akan di tes dengan GLCM serta hasil klasifikasi menggunakan DNN nilai *rate* merupakan nilai tingkat keberhasilan DNN dalam mengklasifikasi citra sedangkan pada nilai status merupakan nilai yang berhasil di klasifikasikan.

Tabel 3.1 Tabel hasil klasifikasi DNN

GLCM									DNN	
Sample	Con	Corr	Hom	Eng	Ent	Diss	S.var	S.avrg	Rate (%)	Status
1										
2										
3										
4										
5										
6										
7										
8										
9										
10										

3.9 Analisis Data

Pada data yang telah didapatkan dari hasil klasifikasi DNN berdasarkan nilai tekstur GLCM akan dianalisis menggunakan nilai uji akurasi dan uji presisi, nilai pada true positive merupakan nilai yang keluar saat proses klasifikasi memberikan nilai yang benar sedangkan nilai false positive dan false negative memberikan informasi ketika proses klasifikasi memberikan nilai yang salah, nilai akurasi merupakan penggambaran seberapa akurat suatu sistem dapat mengklasifikasikan data secara benar, dalam kata lain nilai akurasi merupakan

perbandingan antara data yang terklasifikasi benar dengan keseluruhan data. Nilai akurasi dapat diperoleh dengan persamaan:

$$akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (3.1)$$

TP = Jumlah data positif yang secara benar diklasifikasikan sebagai positif oleh model.

TN = Jumlah data negatif yang secara benar diklasifikasikan sebagai negatif oleh model.

FP = Jumlah data negatif yang salah diklasifikasikan sebagai positif oleh model.

FN = jumlah data positif yang salah diklasifikasikan sebagai negatif oleh model.

Sedangkan nilai uji presisi merupakan nilai yang didapatkan dari jumlah data positif dan kateofir positif yang diklasifikasikan secara benar dibagi dengan total jumlah data negatif yang diklasifikasi sebagai positif dan jumlah positif, nilai uji presisi didapatkan melalui persamaan berikut :

$$presisi = \frac{TP}{FP+TP} \times 100\% \quad (3.2)$$

TP = Jumlah data positif yang secara benar diklasifikasikan sebagai positif oleh model.

FP = Jumlah data negatif yang salah diklasifikasikan sebagai positif oleh model.

Pada pengujian terakhir yaitu untuk mendapatkan nilai *F1-Score* uji ini dilakukan untuk memberikan ukuran tunggal dalam mempertimbangkan baik kualitas prediksi positif maupun kemampuan sistem dalam mengambil kemabali contoh positif yang relevan. *F1-Score* khususnya berguna dalam situasi ketika

terdapat ketidakseimbangan antara jumlah contoh positif dan negatif dalam dataset, uji ini didaaptkan melalui persamaan:

$$\frac{1}{F1} = \frac{1}{2} \left(\frac{1}{Presisi} + \frac{1}{Recall} \right) \quad (3.3)$$

BAB IV

HASIL DAN PEMBAHASAN

4.1 Gambaran Umum Penelitian

Penelitian ini memiliki tujuan untuk melakukan analisis citra CT-SCAN otak menggunakan metode GLCM (Grey Level Co-occurrence Matrix) dan DNN (Deep Neural Network) guna mendeteksi tingkat keparahan stroke.

Pada metode GLCM digunakan untuk melakukan analisis tekstur citra CT-SCAN dengan mengukur hubungan spasial antara piksel dengan nilai keabuan yang berdekatan dalam citra. Dengan menggunakan GLCM, informasi tekstur yang terkandung dalam citra CT-SCAN dapat diekstraksi untuk mendapatkan fitur-fitur pada nilai citra. Fitur-fitur yang digunakan pada penelitian ini berjumlah 13 fitur yaitu : *Contrast, Correlation, Energy, Homogeneity, Entropy, dissimilarity, Autocorrelation, Cluster Shade, Sum Variance, Sum Average, Cluster Prominance, Maximum Probabiliy, Difference Entropy.*

Metode DNN pada penelitian ini digunakan sebagai instrumen untuk mempelajari representasi fitur yang kompleks dari data citra. DNN merupakan sebuah jaringan syaraf tiruan yang terdiri dari banyak lapisan dan dapat digunakan untuk mengenali pola-pola yang rumit dalam citra. Dengan melatih model DNN menggunakan dataset yang tersedia hasil dari fitur-fitur GLCM yang telah dikumpulkan, maka model DNN dapat dikembangkan untuk memprediksi tingkat keparahan stroke dengan akurasi yang tinggi.

Pada penelitian ini juga akan melibatkan pengumpulan data citra CT-SCAN dari pasien-pasien dengan riwayat stroke. Data tersebut didapatkan melalui web medis physionet.org yang merupakan web khusus penyedia citra medis untuk

digunakan khusus penelitian. Citra yang telah didapatkan akan diproses secara pra-pemrosesan untuk memperbaiki kualitas citra, mengurangi noise, dan meningkatkan kontras sebelum analisis lebih lanjut menggunakan GLCM.

Setelah itu, citra yang sudah didapatkan lalu di segmentasi menggunakan segmentasi *active contour* yang bertujuan untuk memisahkan bagian stroke dengan bagian yang tidak, setelah didapatkan bagian yang diinginkan citra tersebut akan dihitung fitur-fiturnya menggunakan GLCM. Fitur-fitur tersebut akan digunakan sebagai dataset dan masukan untuk model DNN yang akan dilatih dan divalidasi menggunakan teknik pembagian dataset. Dalam evaluasi hasil, performa model DNN akan diukur menggunakan metrik-metrik seperti akurasi, presisi, recall, serta F1-Score.

Uji akurasi dihitung menggunakan persamaan:

$$akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (4.1)$$

TP = Jumlah data positif yang secara benar diklasifikasikan sebagai positif oleh model.

TN = Jumlah data negatif yang secara benar diklasifikasikan sebagai negatif oleh model.

FP = Jumlah data negatif yang salah diklasifikasikan sebagai positif oleh model.

FN = jumlah data positif yang salah diklasifikasikan sebagai negatif oleh model.

Uji presisi dihitung menggunakan persamaan:

$$presisi = \frac{TP}{FP+TP} \times 100\% \quad (4.2)$$

TP = Jumlah data positif yang secara benar diklasifikasikan sebagai positif oleh model.

FP = Jumlah data negatif yang salah diklasifikasikan sebagai positif oleh model.

Uji *F1-Score* dihitung menggunakan persamaan:

$$F1 = 2 \frac{(Recall * Precision)}{(Recall + Precision)} \quad (4.3)$$


4.2 Hasil Analisis Data

4.2.1 Active Contour


Pada tahap ini segmentasi *Active contour* digunakan untuk melakukan proses segmentasi objek pada citra, metode ini menggambarkan pendekatan interaktif untuk menemukan kontur atau tepi objek sebuah citra. Menurut (Shang et al., 2008) *active contour* merupakan segmentasi berbasis wilayah yang mengekstraksi objek dengan meminimalkan fungsi energi pada wilayah, selain kurva.

Proses awal segmentasi dimulai dengan menginisialisasi kontur awal yang diletakkan di sekitar objek yang ingin di segmentasi dalam citra. Kontur awal kemudian akan diperbarui dalam iterasi berulang dengan mengoptimalkan fungsi energi yang terdiri dari berbagai komponen.

Proses segmentasi dilakukan pada aplikasi MATLAB menggunakan iterasi atau perulangan sebanyak 20, setelah semua perulangan tercapai maka citra yang sudah tersegmentasi akan ditampilkan. Berikut merupakan hasil citra yang telah melalui segmentasi *active contour*:





Gambar 4.1 Citra Normal



Gambar 4.2 Citra segmentasi

Gambar 4.3 Citra *Hemorrhage*

Gambar 4.4 Citra segmentasi

Gambar 4.5 Citra *Iskemik*

Gambar 4.6 Citra segmentasi

4.2.2 Analisis DNN *epoch* 250,500,1000

Pengujian DNN dengan *epoch* (250, 500, 1000) yang dilakukan di Laboratorium komputer jurusan Fisika Universitas Islam Negeri Maulana Malik Ibrahim Malang, diperoleh hasil sebagai berikut:

Tabel 4.1 Data klasifikasi citra Normal menggunakan epoch 250,500,1000

250		500		1000	
Rate	Status	Rate	Status	Rate	Status
91.76	0	77.65	0	90.59	1
92.94	1	77.65	0	91.76	2
76.74	0	78.82	0	91.76	1
76.47	1	92.94	1	91.76	1
76.47	2	90.59	0	95.29	0
72.94	0	78.82	0	80.00	0
78.82	0	80.00	1	91.76	1
95.29	1	89.41	2	91.76	2
91.76	0	76.47	0	91.76	2
76.47	2	92.94	0	80.00	0
91.76	2	77.65	0	91.76	2
77.65	0	91.76	2	91.76	2
91.76	0	90.59	0	90.59	2
77.65	0	77.65	0	94.12	2
78.82	1	78.82	0	81.18	0

Pada pengujian akurasi model DNN tabel 4.1.1 pada citra normal didapatkan hasil sebesar 56.57% pada epoch 250, pada epoch 500 didapatkan hasil akurasi sebesar 80.4% dan epoch 1000 didapatkan hasil sebesar 41.6%.

Pengujian selanjutnya dilakukan untuk mengetahui presisi dari model DNN, pengujian ini digunakan untuk sejauh mana hasil prediksi yang positif (positif dalam hal ini mengacu pada klasifikasi yang dianggap sebagai hasil yang diinginkan) pada tabel 4.1.1 didapatkan hasil presisi sebesar 47.1% dengan menggunakan epoch 250, pada epoch 500 didapatkan hasil sebesar 57.1%, sedangkan pada epoch 1000 didapatkan nilai presisi sebesar 46.2%. Hal ini menunjukkan bahwa algoritma DNN pada data citra normal pada epoch 250 dan

1000 masih belum optimal dalam melakukan prediksi dikarenakan masih terdapat beberapa data yang diklasifikasikan salah sedangkan pada epoch 500 hasil yang didapatkan cukup baik dimana hasil yang didapatkan cukup tinggi untuk nilai presisi ini menunjukkan bahwa data normal pada epoch 500 60% benar diklasifikasikan.

Tabel 4.2 Data klasifikasi citra Hemorrhage menggunakan DNN epoch 250,500,1000

250		500		1000	
Rate	Status	Rate	Status	Rate	Status
91.76	2	80.76	1	92.94	2
78.82	1	91.76	1	90.59	0
76.47	2	76.47	1	91.76	0
77.65	1	77.65	1	92.94	2
76.47	1	91.76	1	92.14	0
76.47	1	76.47	0	76.47	1
91.76	0	91.76	1	94.12	1
77.65	2	91.76	1	91.76	1
80.00	1	77.65	1	77.65	1
76.47	1	91.76	0	91.76	0
94.12	1	78.82	1	92.94	2
91.76	2	92.94	0	91.76	1
77.65	1	78.82	1	92.94	2
94.12	0	91.76	0	90.59	0
76.47	1	92.94	1	85.88	1

Pada pengujian akurasi model DNN untuk data hemorrhage pada tabel 4.1.2 didapatkan hasil sebesar 64.71% pada epoch 250, berikutnya pada epoch 500 didapatkan hasil sebesar 76.7%, dan 50% pada epoch 1000.

Pengujian kedua yaitu untuk mengetahui tingkat presisi algoritma DNN pada data hemorrhage dalam masing-masing epoch, didapatkan hasil sebesar 57.1% pada epoch 250, berikutnya pada epoch 500 didapatkan hasil sebesar 64.7%, terakhir pada epoch 1000 didapatkan hasil sebesar 42.9%.

Pengujian terakhir yaitu uji F1-Score digunakan untuk mengetahui sejauh mana model DNN nilainya seimbang antara presisi dan recall. Pada tabel 4.1.2 untuk data hemorrhage didapatkan hasil sebesar 0.24 pada epoch 250, selanjutnya pada epoch 500 didapatkan hasil 0.68, lalu pada epoch 1000 didapatkan nilai sebesar 0.41.

Tabel 4.3 Data klasifikasi citra Iskemik menggunakan DNN pada epoch 250,500,1000

250		500		1000	
Rate	Status	Rate	Status	Rate	Status
77.65	0	91.76	2	91.76	0
91.76	2	90.59	2	90.59	0
76.47	0	91.76	2	77.65	2
76.47	1	90.59	1	95.29	1
78.82	2	91.76	2	80.00	2
77.65	0	92.94	1	92.94	1
90.59	1	91.76	2	90.59	1
76.47	0	91.76	1	92.94	2
77.65	0	91.76	2	91.76	0
78.82	0	91.76	2	94.12	0
94.12	2	91.76	2	90.59	1
91.76	2	91.76	2	92.94	2
90.59	2	90.59	1	92.94	0
90.59	2	94.12	2	80.00	2
76.47	0	90.59	2	94.12	1

Pada pengujian akurasi model DNN untuk data iskemik pada tabel 4.1.3 didapatkan hasil sebesar 57.89% pada epoch 250, berikutnya pada epoch 500 didapatkan hasil sebesar 84.6%, dan 50% pada epoch 1000.

Pengujian kedua yaitu untuk mengetahui tingkat presisi algoritma DNN pada data iskemik dalam masing-masing epoch, didapatkan hasil sebesar 46.2% pada epoch 250, berikutnya pada epoch 500 didapatkan hasil sebesar 84.6%, terakhir pada epoch 1000 didapatkan hasil sebesar 42.9%.

Pengujian terakhir yaitu uji F1-Score digunakan untuk mengetahui sejauh mana model DNN memiliki nilai yang seimbang antara presisi dan recall. Pada tabel 4.1.3 untuk data iskemik didapatkan hasil sebesar 0.28 pada epoch 250, selanjutnya pada epoch 500 didapatkan hasil 0.78, lalu pada epoch 1000 didapatkan nilai sebesar 0.41

4.3 Pembahasan

4.3.1 Analisis nilai fitur GLCM

4.3.1.1 Fitur contrast

Tekstur merupakan keteraturan pola-pola tertentu yang terbentuk melalui susunan pixel-pixel dalam citra. Dimana pola-pola teratur muncul secara berulang-ulang dengan interval jarak dan arah yang tertentu. Suatu permukaan tak berwarna dalam suatu citra dapat mengandung informasi tekstur bila permukaan itu mempunyai pola-pola tertentu (Rohpandi et al., 2015).

Tabel 4.4 Tabel nilai *Contrast* pada masing-masing data tes

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
1	6.307	14.960	3.446
2	5.397	15.818	4.876
3	7.803	15.031	4.486
4	6.177	3.371	2.470
5	6.762	3.238	4.746
6	7.217	20.057	4.291
7	5.852	21.824	4.681
8	5.852	26.585	5.006
9	6.307	37.279	3.316
10	6.307	40.335	4.876
11	7.152	36.523	5.917
12	6.372	17.209	3.966
13	6.632	20.414	3.055
14	4.031	20.752	3.836
15	5.787	11.871	3.771

Fitur-fitur GLCM yang digunakan pada masing-masing tes dapat memberikan informasi apakah citra tersebut normal, hemorrhage, maupun iskemik, pada tabel 4.2 dapat terlihat citra yang mengalami pendarahan, tekstur citra tersebut akan terlihat lebih gelap dibandingkan area yang tidak mengalami pendarahan. Hal ini disebabkan adanya pendarahan pada bagian otak yang mempengaruhi nilai contrast pada citra tersebut, pada tabel 4.1.4 bagian hemorrhage lebih tinggi dibandingkan tabel citra lainya dimana ini disebabkan oleh adanya darah yang terakumulasi atau pendarahan di dalam jaringan otak, dimana daerah pendarahan ini memiliki intensitas yang lebih tinggi atau lebih rendah secara signifikan dibandingkan dengan jaringan normal.

Tabel 4.5 Range nilai fitur contrast

NO	Status	Range	Mid point	\geq Mid Point	$<$ Mid point
1	Normal	4.032 – 7.803	5.9175	Gelap	Terang
2	Hemorrhage	7.803 – 40.335	24.069	Gelap	Terang
3	Iskemik	2.470 – 5.917	4.1935	Terang	Terang

Pada tabel 4.1.5 Citra yang berada dibawah midpoint 5.9175 dapat diklasifikasikan memiliki tekstur citra berwarna lebih gelap yang menandakan citra yang memiliki rentang diatas midpoint tersebut memiliki tekstur citra berwarna lebih gelap Rentang kontras yang bervariasi dalam citra menandakan adanya persebaran intensitas piksel pada satu bagian otak yang lebih rendah sehingga warna yang dihasilkan lebih gelap.

Pada bagian normal dan iskemik masing masing memiliki rentang yang mendekati ini mengindikasikan citra pada rentang dan midpoint yang telah didapati menunjukkan tekstur citra berwarna lebih terang.

Pada citra normal memiliki warna contrast yang lebih terang dikarenakan tidak adanya kelainan atau perubahan yang signifikan dalam distribusi intensitas piksel. Dalam citra normal, intensitas piksel cenderung lebih merata dan tidak ada area yang menonjol dengan intensitas yang rendah atau tinggi. Sebagai hasilnya, warna yang dihasilkan cenderung lebih terang dan tidak ada kontras antar area yang berbeda.

Namun pada bagian citra iskemik rentang yang didapatkan menghasilkan nilai contrast yang lebih rendah dari citra normal ini mengindikasikan warna pada citra tersebut lebih terang, karena ketidakseimbangan atau perubahan distribusi intensitas piksel. Hal ini membuat tidak adanya perbedaan antara citra iskemik dan

normal sehingga nilai contrast tidak dapat berdiri sendiri untuk melakukan klasifikasi.

4.3.1.2 Fitur correlation

Menurut (Haralick, 1979) correlation pada GLCM menggambarkan hubungan linear antara intensitas piksel dalam jarak dan arah tertentu. Fitur correlation akan mengukur sejauh mana intensitas piksel di satu arah berkorelasi dengan intensitas piksel di arah lainya. Correlation pada GLCM dapat memberikan informasi tentang tekstur citra, seperti tingkat ketergantungan linear antara piksel-piksel dalam arah yang dianalisis. Nilai correlation yang lebih tinggi menunjukkan adanya keteraturan dalam tekstur, sementara nilai correlation yang lebih rendah menunjukkan tekstur yang lebih acak atau tidak beraturan

Tabel 4.6 Tabel nilai *Correlation* pada masing-masing data tes

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
1	13.557	87.195	15.378
2	747.787	74.213	682.762
3	8.258	86.939	1.593
4	9.526	22.769	10.664
5	4.551	23.168	11.737
6	3.543	104.432	1.639
7	16.191	104.086	8.843
8	14.890	142.242	14.272
9	9.461	181.840	7.380
10	9.981	230.293	15.508
11	5.332	194.044	12.972
12	9.818	104.182	13.427
13	11.509	115.029	12.387
14	11.054	104.209	13.492
15	7.250	68.152	13.395

Nilai correlation menggambarkan keadaan dimana nilai correlation rendah yang terlihat pada tabel 4.1.6 bagian normal menunjukkan adanya hubungan linear yang lebih lemah atau bahkan tidak ada hubungan yang signifikan antara intensitas piksel, di mana tidak ada kelainan patologis dalam citra normal yang biasanya akan memiliki tekstur yang lebih kasar atau acak, di mana intensitas piksel tidak menunjukkan pola atau struktur yang jelas dalam arah yang dianalisis.

Pada bagian hemorrhage terlihat lebih tinggi dibandingkan citra iskemik dan normal ini menunjukkan pola tekstur yang lebih teratur dan konsisten dalam distribusi intensitas piksel. Misalnya, pendarahan yang konsisten dalam bentuk atau pola tertentu, atau tumpukan darah yang menghasilkan pola yang terlihat secara visual dalam citra. Di mana pendarahan hemorrhage sering kali ditandai oleh adanya area yang padat atau konsisten dalam citra. Kepadatan yang homogen ini dapat menghasilkan nilai correlation yang tinggi antara piksel dalam arah yang dianalisis.

Tabel 4.7 Range nilai correlatiom

NO	Status	Range	Mid point	\geq Mid Point	$<$ Mid point
1	Normal	3.543-747.787	375.665	teratur	acak
2	Hemorrhage	22.769-230.293	126.531	teratur	acak
3	Iskemik	1.593-15.378	8.485	acak	acak

Terlihat pada tabel 4.1.7 nilai hemorrhage memiliki rentang yang tinggi tapi terbatas dimana hal ini menunjukkan keberadaan pendarahan yang dapat menghasilkan perubahan intensitas yang signifikan pada daerah yang mengalami pendarahan, sama halnya dengan citra iskemik yang menggambarkan kondisi iskemia atau kurangnya aliran darah, yang juga dapat mempengaruhi intensitas piksel. Oleh karena itu, kelompok data hemorrhage dan iskemik memiliki rentang

nilai correlation yang lebih terbatas sehingga hal ini dapat mengindikasikan citra yang dihasilkan beragam antara citra yang memiliki tekstur acak dan teratur sehingga hasil nilai correlation pada bagian yang terdapat gangguan juga beragam antara rendah dan tinggi.

Perbedaan paling mendasar terdapat pada bagian normal nilai, pada bagian ini dapat terlihat nilai pada bagian normal memiliki nilai yang mencakup semua rentang antara tinggi rendah sehingga pada beberapa citra normal didapatkan beberapa tekstur yang berbeda antara acak dan teratur.

4.3.1.3 Fitur Homogenitas

Menurut (Haralick, 1979) nilai homogenitas dalam GLCM menggambarkan tingkat kehomogenan atau konsistensi intensitas piksel dalam citra. Fitur homogenitas dalam GLCM mengukur sejauh mana distribusi intensitas piksel dalam suatu citra cenderung seragam dan homogen. Pada fitur ini digunakan untuk mengukur keseragamannya atau konsistensi tekstur citra. GLCM adalah sebuah matriks yang merepresentasikan hubungan spasial antara pasangan nilai keabuan pada citra

Pada penelitian ini didapatkan nilai homogenitas sebagai berikut:

Tabel 4.8 Tabel nilai *Homogenitas* pada masing-masing data tes

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
1	0.9998	0.9990	0.9998
2	0.9998	0.9989	0.9997
3	0.9997	0.9990	0.9997
4	0.9998	0.9998	0.9998
5	0.9998	0.9998	0.9997
6	0.9997	0.9975	0.9997
7	0.9998	0.9984	0.9998

Lanjutan Tabel 4.8

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
8	0.9998	0.9984	0.9998
9	0.9998	0.9980	0.9998
10	0.9998	0.9968	0.9998
11	0.9997	0.9966	0.9997
12	0.9998	0.9970	0.9998
13	0.9998	0.9984	0.9998
14	0.9998	0.9980	0.9997
15	0.9998	0.9980	0.9998

Pada tabel 4.1.8 nilai homogenitas pada bagian hemorrhage terlihat nilai yang didapat tidak konsisten ini menunjukkan pendarahan juga dapat menyebabkan variasi nilai homogenitas pada citra. Ketika terjadi pendarahan, darah yang keluar dapat memiliki intensitas piksel yang berbeda dari sekitarnya. Hal ini dapat menghasilkan perbedaan nilai keabuan yang signifikan dan mengakibatkan variasi dalam nilai homogenitas.

Pendarahan yang lebih intens atau luas dapat menghasilkan nilai homogenitas yang rendah karena perbedaan intensitas yang besar antara daerah pendarahan dan daerah sekitarnya. Sebaliknya, pada pendarahan yang lebih kecil atau kurang intens, nilai homogenitas akan lebih tinggi karena perbedaan intensitas yang lebih kecil antara darah yang keluar dan jaringan sekitarnya.

Tabel 4.9 Range nilai homogenitas

NO	Status	Range	Mid point	\geq Mid Point	$<$ Mid point
1	Normal	0.9997-0.9998	0.9975	seragam	acak
2	Hemorrhage	0.9966-0.9998	0.9982	seragam	acak
3	Iskemik	0.9997-0.9998	0.9975	seragam	acak

Terlihat pada tabel 4.1.9 bagian normal memiliki range 0.9997 – 0.9998 menunjukkan nilai homogenitas yang tinggi ini mengindikasikan citra normal memiliki tekstur yang lebih seragam dalam arah yang dihitung, dibandingkan dengan range yang didapat bagian hemorrhage. Dimana nilai yang didapatkan pada bagian hemorrhage menandakan adanya persebaran intensitas piksel yang acak sehingga nilai yang didapatkan pada tabel 4.1.9 bagian hemorrhage mengalami ketidak konsistenan.

Pada bagian iskemik didapatkan range nilai yang serupa dengan range yang didapatkan pada citra normal ini menunjukkan adanya kesalahan dalam ekstraksi fitur sehingga fitur nilai homogenitas tidak dapat berdiri sendiri dalam melakukan klasifikasi.

4.3.1.4 Fitur Entropy

Menurut (Haralick, 1979) nilai entropy digunakan untuk mengukur tingkat ketidakpastian atau kompleksitas tekstur dalam citra. Entropy mengukur sejauh mana distribusi kemunculan pasangan nilai keabuan(gray-level) dalam citra.

Entropi dihitung berdasarkan probabilitas kemunculan pasangan piksel dengan nilai keabuan tertentu dalam citra. Semakin beragam dan kompleks distribusi kemunculan pasangan piksel, semakin tinggi nilai entropy. Sebaliknya, jika distribusi kemunculan pasangan piksel lebih terkonsentrasi dan homogen, nilai entropy lebih rendah.

Dalam penelitian (Yunita Prastyaningsih, 2016) nilai entropy digunakan untuk mengukur ketidakaturan aras keabuan dalam citra, nilai entropy tinggi jika elemen-elemen GLCM mempunyai nilai yang relatif sama. Nilai rendah jika elemen-elemen GLCM dekat dengan nilai 0 atau

Tabel 4.10 Tabel nilai *entropy* pada masing-masing data tes

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
1	-2.307	-13.841	-3.860
2	-2.407	-11.551	-1.702
3	-2.180	-11.787	-1.667
4	-2.211	-2.810	-1.688
5	-2.219	-3.032	-1.738
6	-2.230	-16.986	-1.715
7	-4.505	-17.240	-1.611
8	-2.364	-22.748	-3.792
9	-2.209	-33.631	-1.617
10	-2.214	-40.270	-3.800
11	-2.198	-35.235	-3.760
12	-2.212	-15.437	-3.839
13	-2.240	-18.234	-1.743
14	-2.277	-18.433	-3.846
15	-2.213	-10.378	-3.847

Terlihat pada tabel 4.2 nilai entropy pada bagian hemorrhage lebih tinggi, dimana hasil ini menunjukkan bahwa citra tersebut memiliki tekstur yang lebih kompleks dan variasi intensitas piksel yang lebih tinggi. Citra hemorrhage sering kali mengandung daerah dengan intensitas piksel yang berbeda-beda akibat adanya pendarahan. Darah yang mengalir membentuk pola yang kompleks dan menyebabkan variasi intensitas yang tinggi, yang kemudian mempengaruhi nilai entropy.

Hemorrhage seringkali memiliki tekstur yang berbeda dari jaringan normal di sekitarnya. Tekstur yang lebih kompleks pada daerah hemorrhage dapat

menyebabkan variasi intensitas piksel yang lebih tinggi dan nilai entropy yang tinggi.

Sementara itu, nilai pada bagian iskemik lebih tinggi dibandingkan normal, itu menunjukkan bahwa citra iskemik memiliki tekstur yang lebih kompleks dan variasi intensitas yang lebih tinggi. Faktor-faktor seperti perubahan aliran darah, nekrosis jaringan, atau perubahan struktural pada daerah iskemik dapat menyebabkan variasi intensitas piksel yang tinggi dan meningkatkan nilai entropy.

Tabel 4.11 Range nilai entropy

NO	Status	Range	Mid point	\geq Mid Point	$<$ Mid point
1	Normal	(-2.180)-(-4.505)	-3.342	beragam	homogen
2	Hemorrhage	2.810) – (-40.270)	-21.540	beragam	homogen
3	Iskemik	(-1.611) – (-3.860)	-2.735	beragam	homogen

4.3.1.5 Fitur energy

Dalam analisis citra menggunakan GLCM, nilai energy merupakan salah satu ukuran yang menggambarkan intensitas tekstur dalam citra. Energy juga dikenal sebagai Angular Second Moment (ASM) karena dihitung dengan menjumlahkan kuadrat elemen-elemen dalam matriks GLCM.

Konsep dasar di balik nilai energy adalah untuk mengukur sejauh mana intensitas tekstur dalam citra. Nilai energy mencerminkan kekuatan atau kejelasan tekstur yang ada dalam citra. Semakin tinggi nilai energy, semakin kuat intensitas tekstur dalam citra.

Tabel 4.12 Tabel nilai *energy* pada masing-masing data tes

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
1	610.000	9.820	434.000
2	688.000	10.680	512.000
3	489.000	11.311	282.000
4	416.000	3.729	535.000
5	529.000	3.997	314.000
6	664.000	12.058	447.000
7	267.000	12.583	453.000
8	751.000	15.771	506.000
9	710.000	16.501	476.000
10	558.000	19.114	432.000
11	395.000	18.002	520.000
12	503.000	11.933	520.000
13	663.000	12.676	392.000
14	519.000	11.516	256.000
15	466.000	10.378	427.000

Tabel 4.13 Range nilai *energy*

NO	Status	Range	Mid point	\geq Mid Point	$<$ Mid point
1	Normal	267.000 – 751.000	509.000	Seragam	Seragam
2	Hemorrhage	3.729 – 19.114	11.421	Seragam	Acak
3	Iskemik	256.000 – 535.000	395.500	Seragam	Acak

Nilai *energy* dapat terlihat pada tabel 4.2.3 dimana pada tabel normal nilai *energy* berada di rentang antara 267.000 – 751.000 ini menunjukkan bahwa citra normal memiliki nilai *energy* yang tinggi dan dapat disimpulkan bahwa citra normal cenderung memiliki tekstur yang lebih seragam dan konsisten sehingga memiliki nilai energi yang lebih tinggi. Begitupun juga pada citra iskemik juga memiliki nilai

energi yang tinggi meskipun nilai energi pada iskemik tidak setinggi nilai citra normal dimana citra iskemik memiliki tekstur yang lebih seragam, hal ini tergantung sejauh mana area yang terkena iskemik mengalami perubahan yang signifikan.

Sedangkan nilai citra hemorrhage pada tabel 4.2.3 memiliki nilai yang sangat kecil, hal ini menunjukkan bahwa pendarahan yang terjadi akan menyebabkan citra tersebut akan memiliki tekstur citra yang lebih kompleks atau acak, dimana pada daerah yang terkena pendarahan akan menyebabkan perubahan tajam dalam intensitas piksel di area yang terkena.

4.3.1.6 Fitur Dissimilarity

Nilai dissimilarity digunakan untuk mengukur tingkat perbedaan atau ketidakseragaman intensitas piksel antara dua piksel yang berdekatan dalam citra. Ini memberikan informasi tentang seberapa jauh dua piksel berbeda dalam hal intensitas.

Nilai dissimilarity dapat membantu membedakan antara daerah dengan tekstur halus dan kasar. Jika dua piksel yang berdekatan memiliki intensitas yang sangat berbeda, nilai dissimilarity akan tinggi, menunjukkan tekstur yang kasar atau berbeda dalam daerah tersebut. Sebaliknya, jika intensitas piksel yang berdekatan serupa, nilai dissimilarity akan rendah, menunjukkan tekstur yang halus atau seragam.

Tabel 4.14 Tabel nilai *dissimilarity* pada masing-masing data tes

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
1	24.735	77.711	13.515
2	21.165	81.887	19.215
3	30.600	78.570	17,595
4	24.225	18.026	9.690
5	26.520	17.300	18.615
6	28.305	102.563	16.830
7	22.950	112.024	18.360
8	22.950	138.154	19.635
9	24.735	190.304	13.005
10	24.735	210.409	19.215
11	28.050	192.930	23.205
12	24.990	90.632	15.555
13	26.010	106.803	11.985
14	15.810	107.015	15.045
15	22.695	62.180	14.790

Terlihat pada tabel 4.2.4 bagian hemorrhage nilainya lebih tinggi dibandingkan dengan bagian citra yang lain, ini menandakan terdapat variasi intensitas piksel yang signifikan antara piksel-piksel yang berdekatan dalam daerah hemorrhage. Hal ini mengindikasikan perbedaan yang kuat dalam tingkat kecerahan atau warna antara piksel-piksel dalam daerah tersebut.

Ketika terjadi pendarahan, struktur jaringan normal biasanya terganggu. Daerah hemorrhage cenderung memiliki tekstur yang tidak seragam atau heterogen. Oleh karena itu, nilai *dissimilarity* yang tinggi pada citra hemorrhage mencerminkan tingkat ketidakteraturan atau kompleksitas tekstur dalam daerah tersebut.

Tabel 4.15 Range nilai dissimilarity

NO	Status	Range	Mid point	\geq Mid Point	$<$ Mid point
1	Normal	15.810 – 30.600	24.211	kasar	halus
2	Hemorrhage	17.300 – 210.409	108.593	kasar	kasar
3	Iskemik	9.690 – 23.205	16.735	halus	halus

Rentang nilai pada kelompok normal menunjukkan nilai dissimilarity yang relatif kecil ini menunjukkan citra normal cenderung memiliki tingkat keseragaman yang lebih tinggi.

Sementara itu, pada rentang kelompok hemorrhage memiliki variasi yang cukup tinggi, ini menunjukkan adanya perbedaan signifikan antara nilai terendah dan tertinggi dalam kelompok hemorrhage, yang menunjukkan ketidakseragaman tekstur pada citra hemorrhage.

4.3.1.7 Fitur sum variance

Nilai sum variance pada ekstraksi fitur GLCM digunakan untuk mengetahui variasi atau dispersi nilai-nilai tingkat keabuan dalam citra. Sum variance merupakan salah satu statistik yang dapat dihitung dari GLCM. Statistik ini menggambarkan variabilitas jumlah kemunculan pasangan piksel dengan tingkat keabuan yang berbeda dalam citra.

Sum variance dapat memberikan informasi tentang seberapa jauh pasangan piksel tersebar di sekitar nilai rata-rata. Semakin tinggi nilai sum variance, semakin besar variasi tingkat keabuan dalam citra. Jika nilai sum variance rendah, itu menunjukkan adanya keseragaman atau keterkonsistenan nilai tingkat keabuan.

Pada penelitian ini didapatkan nilai sum variance seperti berikut:

Tabel 4.16 Tabel nilai sum variance pada masing-masing data tes

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
1	29.066	334.971	178.983
2	1.242	1.849	708.783
3	583.930	1.702	308.483
4	104.367	660.634	387.749
5	4.551	1.112	575.349
6	1.184	19.454	108.332
7	1.709	1.396	508.633
8	1.709	685.957	892.417
9	29.066	1.742	892.417
10	29.066	60.616	708.783
11	1.251	1.724	1.776
12	95.782	55.336	225.250
13	362.649	108.442	1.159
14	158.533	216.224	358.683
15	1.642	1.564	425.400

Kenaikan dan nilai yang tinggi dapat terlihat pada bagian iskemik ini menunjukkan adanya keheterogenan dalam distribusi piksel pada citra tersebut. Dalam kasus iskemia, terjadi gangguan aliran darah ke daerah tertentu di otak, yang menyebabkan variasi dalam tingkat keabuan dan tekstur citra.

Sedangkan pada bagian hemorrhage terlihat nilai pada bagian hemorrhage tidak konsisten ini menunjukkan adanya pola dan distribusi tingkat keabuan yang tidak teratur. Ini bisa terjadi karena adanya pendarahan yang tidak terkendali atau adanya pendarahan dalam berbagai lokasi dalam citra. Variasi tingkat keabuan yang tidak konsisten dapat mengindikasikan adanya titik-titik pendarahan yang tersebar secara acak.

Kondisi nilai yang tidak teratur dan tidak konsiten pada citra hemorrhage juga bisa menunjukkan adanya kerusakan lesi pada jaringan yang terkena pendarahan. Pendarahan dalam jaringan dapat menyebabkan kerusakan struktural yang menciptakan variasi tingkat keabuan yang tidak konsisten.

Tabel 4.17 Range nilai sum variance

NO	Status	Range	Mid point	\geq Mid Point	$<$ Mid point
1	Normal	29.066 – 583.930	84.303	inkonsisten	Konsisten
2	Hemorrhage	650.634 – 685.957	135.438	inkonsisten	Konsisten
3	Iskemik	573.349 – 892.417	395.117	inkonsisten	inkonsisten

4.3.1.8 Fitur sum average

Nilai sum average pada GLCM digunakan untuk mengukur rata-rata kemunculan pasangan piksel dengan tingkat keabuan yang berbeda dalam citra. Dalam GLCM, pasangan piksel dengan tingkat keabuan yang berbeda dihitung dengan kemunculannya direkam dalam matrik GLCM. Sum average adalah salah satu statistik yang dapat dihitung dari matrik GLCM. Statistik ini menggambarkan rata rata jumlah kemunculan pasangan piksel dengan tingkat keabuan yang berbeda dalam citra.

Pada penelitian ini didapatkan nilai sum average seperti berikut:

Tabel 4.18 Tabel nilai sum average pada masing-masing data tes

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
1	131.070	765.474	134.130
2	27.030	667.606	24.480
3	95.270	764.248	30.900
4	98.940	197.548	93.330
5	-197.657	-199.926	110.670
6	56.100	926.474	108.120

Lanjutan Tabel 4.18

No	<i>Normal</i>	<i>Hemorrhage</i>	<i>iskemik</i>
7	149.940	933.228	87.720
8	139.740	1.260	70.890
9	98.940	1.742	70.890
10	103.320	2.026	140.760
11	69.870	-35.325	124.950
12	102.000	912.306	120.870
13	116.280	1.014	109.140
14	102.510	929.782	120.870
15	79.560	599.730	119.850

Terlihat pada bagian hemorrhage memiliki nilai lebih tinggi dibandingkan bagian yang lain ini menunjukkan adanya hubungan yang lebih kuat antara kemunculan pasangan dengan nilai intensitas lebih rendah dan kemunculan pasangan pixel dengan nilai intensitas lebih tinggi dalam citra. Dapat diartikan bahwa citra hemorrhage memiliki lebih banyak area dengan perbedaan intensitas yang signifikan antara piksel-piksel yang memiliki nilai intensitas rendah dan tinggi.

Ketika nilai dari sum average meningkat, ini mengindikasikan adanya transisi yang lebih tajam atau perbedaan yang lebih kontras antara piksel-piksel dalam citra hemorrhage. Ini bisa terjadi dikarenakan adanya perubahan atau perbedaan yang lebih tegas antara area dengan pendarahan dan area tanpa pendarahan.

Tabel 4.19 Tabel nilai sum average pada masing-masing data tes

NO	Status	Range	Mid point	\geq Mid Point	$<$ Mid point
1	Normal	197.657 – 149.940	82.499	teratur	Teratur
2	Hemorrhage	199.926 – 933.238	552.048	Tidak teratur	Tidak teratur
3	Iskemik	24.480 – 140.760	102.710	Tidak teratur	Teratur

4.3.2 Akurasi DNN dengan *epoch* 250

Berdasarkan pengujian yang telah dilakukan terhadap citra data tes yang didalamnya terdapat 45 citra dengan 3 klasifikasi normal, hemorrhage, iskemik didapatkan hasil pada model DNN yang menggunakan *epoch* 250 uji akurasi pertama dilakukan pada tabel 4.1.1 yang mendapatkan hasil nilai akurasi sebesar 56.64% pada tabel 4.1.2 yaitu merupakan tabel tes citra hemorrhage didapatkan nilai akurasi sebesar 64.71% dan pada tabel 4.1.3 merupakan tabel tes citra iskemik didapatkan nilai dari hasil uji akurasi sebesar 57.89% ini mengindikasikan bahwa model DNN dengan menggunakan *epoch* 250 menunjukkan peningkatan kinerja setelah melalui pelatihan sebanyak 250 *epoch*.

Hal ini terlihat pada tabel 4.1.1 dimana model awal menghasilkan akurasi sebesar 56.64%. Namun, setelah melalui proses pelatihan tambahan model berhasil meningkatkan hasil akurasi yang lebih tinggi pada tabel 4.1.2 dan 4.1.3.

Pada tabel 4.1.2 yang merupakan tes citra hemorrhage, model DNN mencapai tingkat akurasi sebesar 64.71% ini menunjukkan kemampuan model dalam mengenali kasus-kasus pendarahan dalam citra hemorrhage dengan tingkat keberhasilan yang lebih baik setelah proses pelatihan. Sementara itu, pada tabel 4.1.3 yaitu citra iskemik, model justru mengalami penurunan akurasi menjadi 57.89%, meskipun mengalami penurunan tingkat akurasi namun model masih dapat

mampu mengenali kasus-kasus iskemia dengan tingkat keberhasilan yang signifikan.

Hal ini menunjukkan bahwa ketiga citra yaitu normal, hemorrhage, iskemik memiliki beberapa ciri tekstur yang berbeda, sehingga akurasi yang dihasilkan berbeda. Tabel 4.1.2 menunjukkan nilai akurasi yang tinggi disebabkan letak pendarahan pada citra dapat terlihat jelas, sedangkan pada tabel 4.1.1 dan 4.1.3 hampir terlihat sama sehingga akurasi yang dihasilkan rendah.

Selanjutnya dilakukan pengujian presisi terhadap model DNN dengan menggunakan *epoch 250*, uji presisi digunakan untuk mengetahui sejauh mana model dapat mengklasifikasikan dengan benar citra-citra dalam kategori tertentu. Dalam konteks ini, pengujian presisi dapat memberikan pemahaman yang lebih dalam tentang kemampuan model DNN dalam mengenali dengan tepat citra-citra normal, hemorrhage dan iskemik.

Pada tabel 4.1.1 didapatkan hasil uji presisi sebesar 47.1%, pada tabel 4.1.2 didapatkan hasil sebesar 57.1% dan pada tabel 4.1.3 didapatkan hasil sebesar 46.2% ini mengindikasikan bahwa model DNN masih memiliki tingkat kesalahan prediksi yang cukup besar, dimana nilai *false positive* dan *false negative* lebih besar sehingga hasil dari uji presisi nya menjadi rendah. dari semua hasil dapat disimpulkan bahwa kinerja model DNN dengan menggunakan *epoch 250* memiliki tingkat kesalahan yang masih cukup signifikan, baik dalam mengklasifikasikan hasil positif yang sebenarnya (presisi rendah) maupun dalam mengidentifikasi semua *instance* positif yang ada (recall rendah).

4.3.3 Akurasi DNN dengan *epoch* 500

Pengujian kedua menggunakan model DNN dengan *epoch* sebesar 500 memberikan hasil yang maksimal dibandingkan dengan model dengan *epoch* 250 dan *epoch* 1000 pada pengujian pertama yaitu pengujian tingkat akurasi. Pada tabel 4.1.1 pada bagian *epoch* 500 didapatkan nilai akurasi sebesar 80.4% dan pada tabel 4.1.2 didapatkan nilai akurasi sebesar 76.7% sedangkan pada tabel 4.1.3 didapatkan nilai akurasi sebesar 86.6%.

Hasil dari pengujian akurasi ini menunjukkan bahwa model mengalami peningkatan yang signifikan dalam melakukan prediksi dimana ini menunjukkan model dapat mengenali data yang belum dilihat sebelumnya dengan tepat.

Pengujian kedua dilakukan guna melihat sejauh mana hasil presisi dari model DNN yang menggunakan *epoch* sebesar 500, pada tabel 4.1.1 didapatkan nilai presisi sebesar 73.3% pada tabel 4.1.2 didapatkan nilai presisi sebesar 64.7% dan pada tabel 4.1.3 didapatkan hasil sebesar 84.6% .

Dari hasil pengujian dapat diketahui bahwa model mengalami kenaikan tingkat akurasi yang signifikan dengan menggunakan *epoch* 500 dimana pada data citra normal tingkat akurasi meningkat sebesar 41.93% dan pada data citra hemorhage 18.52% dan data tes citra iskemik mengalami kenaikan akurasi sebesar 49.64%.

Sedangkan pada pengujian presisi pada model DNN didapatkan ketiga tes juga mengalami kenaikan tingkat presisi dimana pada tabel 4.1.1 mengalami kenaikan sebesar 55.62% dan pada tabel 4.1.2 mengalami kenaikan presisi sebesar 13.32% dan pada tabel 4.1.3 nilai presisi naik sebesar 83.12%

Hal ini menunjukkan bahwa model pada DNN secara signifikan mengalami kenaikan akurasi dan presisi seiring dengan ditambahkan jumlah *epoch* yang digunakan, ini menunjukkan bahwa model dengan jumlah *epoch* yang dinaikkan akan memiliki kesempatan untuk mempelajari pola dalam data yang disediakan dan akan menangkap representasi yang lebih baik dari data. Hal ini dapat mengarah pada model yang lebih kompleks dan kuat dalam mengklasifikasikan citra dengan akurasi yang lebih tinggi. Pada penelitian (Wasil et al., 2022) disebutkan penggunaan *epoch* pada model klasifikasi dapat memberikan peningkatan akurasi. Dimana *epoch* digunakan sebagai perulangan dan pembelajaran untuk model. Dimana semakin banyak *epoch* yang digunakan semakin baik juga akurasi yang akan didapatkan. Namun didalam data set terdapat maksimal akurasi yang bisa didapat dimana pada batas *epoch* tertentu data akan mengalami overfitting.

4.3.4 Akurasi DNN dengan *epoch* 1000

Pada pengujian ketiga menggunakan model DNN dengan *epoch* 1000 didapatkan nilai akurasi pada ketiga tabel menurun, dimana pada tabel 4.1.1 nilai akurasi pada bagian epoch 1000 yang didapatkan sebesar 41.6% pada tabel 4.1.2 didapatkan nilai akurasi sebesar 50% sedangkan pada tabel 4.1.3 didapatkan hasil akurasi sebesar 50%. Pada pengujian uji presisi hal yang sama juga terjadi yaitu model DNN mengalami penurunan hasil yang cukup signifikan dimana pada tabel 4.1.1 model mendapatkan nilai presisi sebesar 31.9% pada tabel 4.1.2 model mendapatkan nilai presisi sebesar 42.9% sedangkan tabel 4.1.3 menghasilkan nilai presisi sebesar 42.9%, ini mengindikasikan bahwa nilai false positive dan false negative pada model DNN dengan menggunakan *epoch* 1000 cukup besar hal ini menyebabkan tingkat akurasi dan presisi pada model menurun.

Pada uji akurasi model DNN mengalami penurunan sebesar 38.8% pada tabel 4.1.1 bagian epoch 1000 kemudian pada tabel 4.1.2 mengalami penurunan sebesar 26.7% dan 36.6% pada tabel 4.1.3.

Kemudian pada uji presisi juga mengalami penurunan yang signifikan jika dibandingkan dengan *epoch* sebelumnya, pada tabel 4.1.1 didapatkan penurunan sebesar 41.4%, pada tabel 4.1.2 mengalami penurunan sebesar 21.8% dan pada tabel 4.1.3 mengalami penurunan sebesar 41.7%.

Dengan hasil tersebut, diketahui bahwa model DNN pada *epoch* 1000 mengalami overfitting dimana model berakhir dengan menggambarkan atau mengklasifikasikan data terlalu baik, sehingga model hanya “menghafal” pola yang dianalisis dari masa lalu, dan dengan demikian tidak benar-benar “mempelajari” (Firmansyach et al., 2023) sehingga disaat model “terbiasa” dengan data pelatihan yang digunakan untuk melatihnya sehingga tidak mampu menggeneralisasi dengan baik data yang belum pernah dilihat sebelumnya. Hal ini menyebabkan performa model menjadi buruk pada data uji.

4.3.5 Uji F1-Score pada model DNN

Pengujian F1-Score pada model DNN dilakukan untuk mengevaluasi kinerja dalam suatu model saat melakukan klasifikasi, terutama disaat adanya ketidakseimbangan kelas atau ketika nilai false positive dan false negative memiliki dampak yang berbeda. Menurut (Fiqih Satria et al., 2020) nilai akurasi yang kecil tidak menunjukkan bahwa model algoritma tidak baik. Akurasi sangat bagus jika digunakan sebagai acuan performansi model algoritma jika dataset memiliki jumlah data false negative dan false positive yang seimbang, namun jika jumlah keduanya tidak mendekati, maka menggunakan F-Measure (F1-Score) sebagai acuan karena

menggunakan presisi atau akurasi saja dalam pengukuran sebuah model dapat menimbulkan bias yang sangat fatal.

F1-Score diperoleh dengan menghitung harmonic mean dari presisi dan recall, pada nilai F1-Score memiliki rentang nilai 0 hingga 1. Nilai F1-Score yang semakin mendekati 1 dianggap semakin menunjukkan kinerja yang baik dalam memprediksi kelas positif, dengan mengoptimalkan keseimbangan antara presisi dan recall.

Dalam uji F1-Score didapatkan nilai yang beragam dari model DNN yang menggunakan masing-masing *epoch* yang berbeda, pada model dengan *epoch 250* didapatkan nilai untuk tabel 4.1.1 sebesar 0.24 dan tabel 4.1.2 sebesar 0.28 sedangkan pada tabel 4.1.3 didapatkan nilai F1-Score sebesar 0.41.

Pada model DNN menggunakan *epoch 500* didapatkan hasil F1-Score sebesar 0.73 pada tabel 4.1.1 dan tabel 4.1.2 didapatkan nilai sebesar 0.68 sedangkan pada tabel 4.1.3 sebesar 0.78.

Pada uji F1-Score model DNN dengan *epoch 1000* hasil pengukuran menunjukkan penurunan tingkat dibandingkan dengan *epoch 500* dimana pada tabel 4.1.1 pada bagian epoch 1000 didapatkan nilai sebesar 0.32 dan 4.1.2 didapatkan nilai sebesar 0.41 sedangkan tabel 4.1.3 juga memiliki nilai sebesar 0.41.

Dari ketiga pengujian pada model DNN yang menggunakan *epoch* berbeda dapat diketahui nilai pada *epoch 250* tidak cukup baik dalam melakukan klasifikasi dimana nilai yang didapatkan hampir mendekati 0, ini mengartikan adanya underfitting pada model dengan *epoch 250*, menurut (Firmansyach et al., 2023) underfitting terjadi jika sebuah model memiliki kondisi ciri-ciri nilai false yang berlebihan dan akurasi yang rendah. Model underfitting tidak cukup rumit dan terlalu

sedikit fokus pada data pelatihan. Akibatnya, membuat pola yang sangat buruk pada saat menggunakan data pelatihan.

Sedangkan pada model DNN dengan *epoch 500* dapat terlihat nilai F1-Score naik secara signifikan dibandingkan dengan *epoch* sebelumnya pada saat ini model benar-benar mempelajari pola-pola tertentu yang ada pada nilai fitur-fitur GLCM yang dilatih. Sehingga saat melakukan sebuah tes model DNN pada *epoch* ini dengan baik dapat memprediksi dengan tepat, hasil yang didapatkan jika dibandingkan pada penelitian (Faisal & Subekti, 2021) dimana pada penelitian ini didapatkan nilai F1-Score sebesar 0.96, hasil penelitian tersebut dibandingkan dengan penelitian kali ini memiliki selisih sebesar 0.23 dimana hal ini terjadi dikarenakan adanya perbedaan besar dataset yang digunakan serta perlakuan optimalisasi *Adam*, pada penelitian (Faisal & Subekti, 2021) digunakan dataset sebesar 4861 dataset dengan kategori normal dan 286 dataset dengan kategori stoke dan perbedaan seperti penggunaan *batch size* untuk membagi dataset menjadi batch batch kecil dimana pada penelitian kali ini hanya menggunakan *batch size* sebesar 10 dan pada penelitian sebelumnya digunakan *batch size* sebesar 96 hal ini juga merupakan salah satu perbedaan variabilitas yang menyebabkan hasil penelitian kali ini memiliki selisih sebesar 0,23

4.4 Integrasi Al-Qur'an Dan Keterkaitan Hasil Penelitian Dalam Prespektif Islam

Berdasarkan penelitian ini didapatkan hasil bahwa model DNN pada *epoch 500* dengan baik melakukan prediksi dengan akurasi yang cukup tinggi dibandingkan dengan model dengan DNN dengan *epoch* lainnya. Dengan hasil yang ditunjukkan, dapat diambil arti bahwasanya pemanfaatan teknologi dan pengetahuan sebagai suatu hal yang bisa dimanfaatkan untuk kehidupan manusia, hal ini selaras dengan firman Allah SWT dalam surat AL-Imran (3) : 190

إِنَّ فِي خَلْقِ السَّمَاوَاتِ وَالْأَرْضِ وَاخْتِلَافِ اللَّيْلِ وَالنَّهَارِ لآيَاتٍ
لِّأُولِي الْأَلْبَابِ

Artinya : “*Sesungguhnya dalam penciptaan langit dan bumi, dan silih bergantinya malam dan siang terdapat tanda-tanda bagi orang-orang yang berakal*” (QS. AL-Imran 3 : 190)

Menurut tafsir al misbah menerangkan salah satu bukti kebenaran, mengundang manusia untuk berpikir, karena sesungguhnya dalam penciptaan, yakni kejadian benda-benda angkasa seperti matahari, bulan dan jutaan gugusan bintang-bintang yang terdapat di langit atau dalam pengaturan sistem kerja langit yang sangat teliti serta kejadian dan perputaran bumi dan porosnya, yang melahirkan silih bergantinya malam dan siang perbedaannya baik dalam masa, maupun dalam panjang dan pendeknya terdapat tanda-tanda kemahakuasaan Allah bagi *ulul albab* yakni orang-orang yang memiliki akal yang murni.

Kata (الْأَلْبَابِ) *al-albab* adalah bentuk jamak dari (لُبِّ) *lubb* yaitu saripati sesuatu. Kacang, misalnya memiliki kulit yang menutupi isinya. Isi kacang dinamai *lubb*. *Ulul Allbab* adalah orang-orang yang memiliki akal yang murni, yang tidak diselubungi oleh “kulit”, yakni kabut ide, yang dapat melahirkan kerancuan dalam berpikir. Yang merenungkan tentang fenomena alam raya akan dapat sampai kepada bukti yang sangat nyata tentang keesaan dan kekuasaan Allah swt.

Dengan memikirkan pergantian siang dan malam, mengikuti terbit dan terbenamnya matahari, siang lebih lama dari malam dan sebaliknya. Semuanya itu menunjukkan atas kebesaran dan kekuasaan penciptanya bagi orang-orang yang berakal. Memikirkan terciptanya langit dan bumi, pergantian siang dan malam secara teratur dengan menghasilkan waktu tertentu bagi kehidupan manusia merupakan satu tantangan tersendiri bagi kaum intelektual beriman. Mereka diharapkan menjelaskan

scara akademik fenomena alam itu, sehingga dapat diperoleh kesimpulan bahwa tuhan tidaklah menciptakan semua fenomena itu dengan sia-sia.

Pemanfaatan teknologi untuk melakukan prediksi suatu penyakit memiliki manfaat yang sangat besar untuk kehidupan manusia, sebagai umat muslim hal ini sejalan dengan ajaran islam yang mendorong manusia untuk mencari ilmu dan memanfaatkannya untuk kemaslahatan umat manusia. Dalam Al-Qura'an, Allah SWT mengajak umat manusia untuk berpikir, mengamati alam untuk mendapatkan pengetahuan dan pemahaman yang lebih baik.

Dalam konteks penggunaan teknologi untuk prediksi penyakit, hal ini dapat membantu umat muslim dalam menjaga dan meningkatkan kesehatan mereka. Dengan memanfaatkan teknologi yang ada, umat muslim dapat mengambil langkah-langkah yang preventif, mendapatkan diagnosis yang lebih akurat, dan merencanakan perawatan yang efektif, hal ini selaras dengan firman Allah SWT surah AL-A'raf (7) : 31

يٰۤاِبْنَٓ اٰدَمَ خُذْ وَاٰدَمَ خُذُوْا زِيْنَتَكُمْ عِنْدَ كُلِّ مَسْجِدٍ وَكُلُوْا وَاشْرَبُوْا وَلَا تُسْرِفُوْا اِنَّهٗ لَا يُحِبُّ
الْمُسْرِفِيْنَ

Artinya : “Hai anak Adam, pakailah pakaianmu yang indah di setiap (memasuki) mesjid, makan dan minumlah, dan janganlah berlebih-lebihan. Sesungguhnya Allah tidak menyukai orang-orang yang berlebih-lebihan”. (QS. Al-A'raf 7 : 31)

Kata al-musrifin yang berarti melampau batas atau berlebihan. Sesuatu hal yang dilakukan diluar batas normal disebut israf. Allah SWT tidak menyukai seseorang yang melampau batas atau berlebihan dalam makan dan minum. Karena berlebihan dalam makan dan minum salah satu penyebab datangnya penyakit dan menurunkan kualitas hidup. Maka makanlah ketika merasa lapar dan berhenti

sebelum terlalu kenyang, begitu pula dengan minum, minumlah saat merasa haus dan berhenti setelah hilang rasa haus (Nahar & Hidayatulloh, 2021).

Menurut tafsir al-Misbah (*Tafsir-Al-Mishbah-5-Quraish-Shihab-Z-Library*, n.d.) penggalan akhir pada ayat tersebut merupakan salah satu prinsip yang diletakkan agama menyangkut kesehatan dan diakui pula oleh para ilmuwan terlepas apapun pandangan hidup atau agama mereka.

Perintah makan dan minum, selagi tidak berlebih-lebihan, yakni tidak melampaui batas, merupakan tuntunan yang harus disesuaikan dengan seseorang, boleh jadi telah dinilai melampaui batas atau belum cukup buat orang lain. Atas dasar itu, kita dapat berkata bahwa penggalan ayat tersebut mengajarkan sikap proporsional dalam makan dan minum.

Dalam konteks berlebih-lebihan ditemukan pesan Nabi SAW : “Tidak ada wadah yang dipenuhi manusia, lebih buruk dari perut. Cukuplah bagi putra-putri Adam beberapa suap yang dapat meneggakan tubuhnya. Makanannya, sepertiga untuk minumannya, dan sepertiga untuk pernafasannya.”(HR. at-Tirmidzi, Ibnu Majah, dan Ibnu Hibban melalui Miqdam Ibnu Ma’dikarib). Ditemukan juga pesan menyatakan: “Termasuk berlebih-lebihan bila anda makan apa yang selera anda tidak tertuju padanya.”

BAB V

PENUTUP

5.1 Kesimpulan

Dari hasil penelitian yang sudah dilakukan dapat diambil kesimpulan sebagai berikut:

1. Pada pengujian deteksi tingkat stroke dengan menggabungkan metode DNN serta GLCM didapatkan hasil yang cukup baik dengan rerata akurasi sebesar 81.23 % ini menunjukkan bahwa DNN dan GLCM dapat dijadikan salah satu opsi untuk melakukan klasifikasi citra.
2. Didapatkan hasil uji akurasi serta uji f1-score masing-masing epoch, pada epoch 250 didapatkan hasil akurasi sebesar 59.75% sedangkan nilai uji f1 - score yang didapatkan adalah sebesar 0.31. Sedangkan pada epoch 500 didapatkan hasil akurasi sebesar 81.23% dengan uji f1-score sebesar 0.73 serta pada epoch 1000 didapatkan hasil akurasi sebesar 47.2% dan uji f1-score sebesar 0.38
3. Didapatkan performa algoritma DNN dengan gabungan metode GLCM sebesar 81.23% pada epoch 500 hasil ini menunjukkan bahwa algoritma dapat belajar dengan baik hanya dengan menggunakan inputan nilai tekstur dari GLCM

5.2 Saran

Adapun saran yang dapat diberikan pada penelitian ini adalah :

1. Memperluas sampel data, penggunaan data yang lebih besar dan beragam dapat membantu dalam menguji dan memvalidasi model yang dikembangkan.
2. Hasil yang didapatkan sudah cukup baik, perlu ditambahkan validasi eksternal untuk membantu mengidentifikasi apakah model dapat digeneralisasi pada populasi yang berbeda dan memberikan keyakinan lebih dalam hasil penelitian.
3. Memperbesar batch size untuk mendapatkan kestabilan dalam pelatihan dan generalisasi model.

DAFTAR PUSTAKA

- Alit Nur Cahyani, A. A (2015). “*Prinsip fisika pada computed tomography.*”
- Arndt, C., Güttler, F., Heinrich, A., Bürckenmeyer, F., Diamantis, I., & Teichgräber, U. (2021). *Deep Learning CT Image Reconstruction in Clinical Practice*. *RoFo Fortschritte Auf Dem Gebiet Der Rontgenstrahlen Und Der Bildgebenden Verfahren*, 193(3), 252–261. <https://doi.org/10.1055/a-1248-2556>
- Boehme, A. K., Esenwa, C., & Elkind, M. S. V. (2017). *Stroke Risk Factors, Genetics, And Prevention*. In *Circulation Research* (Vol. 120, Issue 3, pp. 472-495). Lippincott Williams and Wilkins. <https://doi.org/10.1161/CIRCRESA.HA.116.308398>
- Faisal, A., & Subekti, A. (2021). *Deep Neural Network untuk Prediksi Stroke*. *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 7(3), 443. <https://doi.org/10.26418/jp.v7i3.50094>
- Faisal Rifiarrasyid, M., Arif Setyawan, D., & Maulana, H. (2021). *Klasifikasi Kesegaran Daging Sapi Menggunakan Metode Gray Level Cooccurrence Matrix dan DNN*. In *JIFTI-Jurnal Ilmiah Teknologi Informasi dan Robotika* (Vol. 3). <https://www.kaggle.com/crowww/meat-quality-assessment->
- Fajri, M. I., & Anifah, L. (2018). *Deteksi Status Kanker Paru-Paru Pada Citra Ct Scan Menggunakan Metode Fuzzy Logic*. *Teknik Elektro*, 7 no. 3.
- Feng, J., He, X., Teng, Q., Ren, C., Chen, H., & Li, Y. (2019). *Reconstruction of porous media from extremely limited information using conditional generative adversarial networks*. *Physical Review E*, 100(3), 33308. <https://doi.org/10.1103/PhysRevE.100.033308>
- Feske, S. K. (2021). *Ischemic Stroke*. In *American Journal of Medicine* (Vol. 134, Issue 12, pp. 1457–1464). Elsevier Inc.
- Firmansyach, W. A., Hayati, U., & Wijaya, Y. A. (2023). *Analisa Terjadinya Overfitting Dan Underfitting Pada Algoritma Naïve Bayess Dan Decision Tree Dengan Teknik Cross Validation*. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 7, Issue 1).
- Fiqih Satria, Zamhariri, & M. Apun Syaripudin. (2020). *Prediksi Ketepatan Waktu Lulus Mahasiswa Menggunakan Algoritma C4.5 Pada Fakultas Dakwah Dan Ilmu Komunikasi UIN Raden Intan Lampung*. *Jurnal Ilmiah MATRIK*, Vol.22No.1, April 2020, 22, 28–35.
- Haralick, R. M. (1979). *Statistical and structural approaches to texture*. *Proceedings IEE*, 67(5), 786–804. <https://doi.org/10.1109/PROC.1979.11328>

- Jony, M. H., Tuj Johora, F., Khatun, P., & Rana, H. K. (2019). *Detection of Lung Cancer from CT Scan Images using GLCM and SVM*. 1st International Conference on Advances in Science, Engineering and Robotics Technology 2019, ICASERT 2019, May, 1–6.
- Kalman, P. (1976). *Radiologic Science for Technologists. Physics, Biology and Protection by S.C. Bushong Medical Physics*, 3(2).
- Korchiyne, R., Farssi, S. M., Sbihi, A., Touahni, R., & Tahiri Alaoui, M. (2014). *A Combined Method of Fractal and GLCM Features for MRI and CT Scan Images Classification*. *Signal & Image Processing : An International Journal*, 5(4), 85–97. <https://doi.org/10.5121/sipij.2014.5409>
- Liu, C., Gardner, S. J., Wen, N., Elshaikh, M. A., Siddiqui, F., Movsas, B., & Chetty, I. J. (2019). *Automatic Segmentation of the Prostate on CT Images Using Deep Neural Networks (DNN)*. *International Journal of Radiation Oncology Biology Physics*, 104(4).
- Nurhasanah. (2012). *Pendeteksian Tepi Citra CT Scan dengan Menggunakan Laplacian of Gaussian (LOG)*. *Positron*, II(1), 17–22.
- Nahar, M. H., & Hidayatulloh, M. K. (2021). *Diet In Islamic Persprective*. *Jurnal AlifLam Journal of Islamic Studies and Humanities*, 2(2), 206–215. <https://doi.org/10.51700/aliflam.v2i2.224>
- Permadi, Y., & Murinto, . (2015). *Aplikasi pengolahan citra untuk identifikasi kematangan mentimun berdasarkan tesktur kult buah menggunakan meotde ekstrak ciri statistik* *Jurnal Informatika*, 9(1).
- Radhi, E. A., & Kamil, M. Y. (2021). *Breast Tumor Detection Via Active Contour Technique*. *International Journal of Intelligent Engineering and Systems*, 14(4), 561–570.
- Rohpandi, D., Sugiharto, A., & Winara, G. A. (2015). *Aplikasi Pengolahan Citra Dalam Pengenalan Pola Huruf Ngalagena Menggunakan MATLAB*. *Konferensi Nasional Sistem & Informatika*, 772–777.
- Shang, Y., Yang, X., Zhu, L., Deklerck, R., & Nyssen, E. (2008). *Region Competition Based Active Contour For Medical Object Extraction*. *Computer ized Medical Imaging and Graphics*, 32(2), 109–117.
- Singh, M., Malhi, Y., & Bhagwat, S. (2014). *Evaluating land use and aboveground biomass dynamics in an oil palm–dominated landscape in Borneo using optical remote sensing*. *Journal of Applied Remote Sensing*, 8(1), 083695. <https://doi.org/10.1117/1.jrs.8.083695>
- Smith, S. D., & Eskey, C. J. (2011). Hemorrhagic stroke. In *Radiologic Clinics of North America* (Vol. 49, Issue 1, pp. 27–45).
- Tafsir Al-Mishbah Jilid 13 -Dr. M. Quraish Shihab. (n.d.).*

Tafsir-Al-Mishbah-5-Quraish-Shihab-Z-Library. (n.d.).

Wahyuni, S. (2015). *Penentuan Kondisi Tulang Femur Menggunakan Analisis Tekstur Pada Citra Digital*. *Elkawanie*, 1(2).

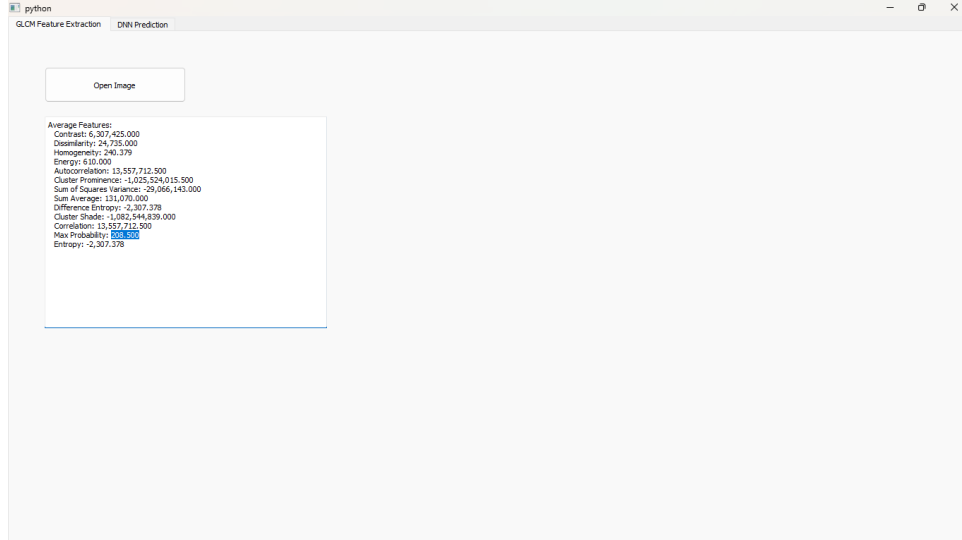
Wasil, M., Harianto, H., & Fathurrahman, F. (2022). *Pengaruh Epoch pada Akurasi menggunakan Convolutional Neural Network untuk Klasifikasi fashion dan Furniture*. *Infotek: Jurnal Informatika Dan Teknologi*, 5(1), 53–61. <https://doi.org/10.29408/jit.v5i1.4393>

Yunianto, M., Soeparmi, S., Cari, C., Anwar, F., Septianingsih, D. N., Ardyanto, T. D., & Pradana, R. F. (2021). *Klasifikasi Kanker Paru Paru menggunakan Naïve Bayes dengan Variasi Filter dan Ekstraksi Ciri GLCM*. *Indonesian Journal of Applied Physics*, 11(2), 256.

Yunita Prastyaningsih. (2016). *GLCMsum. Tesis, PROGRAM MAGISTER* .

LAMPIRAN


Lampiran 1. Program Ekstrak Citra GLCM



Lampiran 2. Program Input DNN



Lampiran 3. Segmentasi Active Contour



Lampiran 4. Kode Program klaifikasi tingkat keparahan stroke menggunakan GLCM dan DNN

```
import sys
from PyQt5.QtWidgets import QApplication, QWidget, QVBoxLayout,
QLabel, QPushButton, QLineEdit, QFileDialog, QMainWindow,
QMessageBox, QTextEdit, QTabWidget, QComboBox
from PyQt5.QtCore import Qt
from numpy import loadtxt, argmax, array
import pandas as pd
import cv2
from sklearn.model_selection import train_test_split
from sklearn.metrics import roc_auc_score
from matplotlib import pyplot as plt
import numpy as np
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense

class GLCMWindow(QMainWindow):
    def __init__(self):
        super().__init__()

        self.setWindowTitle("GLCM Feature Extraction")
```

```

self.button_open = QPushButton("Open Image", self)
self.button_open.setGeometry(50, 50, 200, 50)
self.button_open.clicked.connect(self.open_image)

self.result_text = QTextEdit(self)
self.result_text.setGeometry(50, 120, 400, 300)
self.result_text.setReadOnly(True)

def open_image(self):
    options = QFileDialog.Options()
    options |= QFileDialog.DontUseNativeDialog
    file_path, _ = QFileDialog.getOpenFileName(self, "Open
Image", "", "Image Files (*.png *.jpg *.jpeg)", options=options)
    if file_path:
        image = cv2.imread(file_path)
        image_gray = cv2.cvtColor(image, cv2.COLOR_BGR2GRAY)

        distances = [1]
        angles = [0, np.pi/4, np.pi/2, 3*np.pi/4]
        levels = np.max(image_gray) + 1
        glcm_features = []
        for angle in angles:
            glcm = self.calculate_glcm(image_gray, distances,
angle, levels)
            angle_deg = int(np.rad2deg(angle))
            glcm_features.append(self.calculate_glcm_features(gl
cm))

        self.display_results(glcm_features)

def calculate_glcm(self, image_gray, distances, angle, levels):
    glcm = np.zeros((levels, levels), dtype=np.uint8)
    rotated_image = np.rot90(image_gray, k=int(angle //
(np.pi/4)), axes=(0, 1))

    for i in range(len(rotated_image) - 1):
        for j in range(len(rotated_image[i]) - 1):
            p = rotated_image[i][j]
            q = rotated_image[i][j+1]
            glcm[p][q] += 1

    return glcm

def calculate_glcm_features(self, glcm):
    results = {}

```

```

        contrast = np.sum(glcm *
np.square(np.subtract.outer(range(len(glcm)), range(len(glcm))))))
        contrast = round(contrast, 4)

        dissimilarity =
np.sum(np.abs(np.subtract.outer(range(len(glcm)), range(len(glcm))))
* glcm)
        dissimilarity = round(dissimilarity, 4)

        homogeneity = np.sum(glcm / (1 +
np.abs(np.subtract.outer(range(len(glcm)), range(len(glcm)))) +
np.finfo(float).eps))
        homogeneity = round(homogeneity, 4)

        energy = np.sum(np.square(glcm))
        energy = round(energy, 4)

        sum_of_squares_variance = np.sum(glcm *
np.square(np.subtract.outer(range(len(glcm)), range(len(glcm)))) **
2)
        sum_of_squares_variance = round(sum_of_squares_variance, 4)

        sum_average = np.sum(glcm * np.add.outer(range(len(glcm)),
range(len(glcm))))
        sum_average = round(sum_average, 4)

        difference_entropy = -np.sum(glcm * np.log2(glcm + 1e-10))
        difference_entropy = round(difference_entropy, 4)

        autocorrelation = np.sum(glcm * np.outer(range(len(glcm)),
range(len(glcm))))
        autocorrelation = round(autocorrelation, 4)

        cluster_prominence = np.sum(glcm *
np.outer(range(len(glcm)), range(len(glcm))) ** 2)
        cluster_prominence = round(cluster_prominence, 4)

        entropy = -np.sum(glcm * np.log2(glcm + 1e-10))
        entropy = round(entropy, 4)

        cluster_shade = np.sum(np.power(glcm -
np.outer(range(len(glcm)), range(len(glcm))), 3))
        cluster_shade = round(cluster_shade, 4)

        correlation = np.sum(glcm * np.outer(range(len(glcm)),
range(len(glcm))))

```

```

correlation = round(correlation, 4)

max_probability = np.max(glcm)
max_probability = round(max_probability, 4)

results = {
    'Contrast': float(contrast),
    'Dissimilarity': float(dissimilarity),
    'Homogeneity': float(homogeneity),
    'Energy': float(energy),
    'Autocorrelation': float(autocorrelation),
    'Cluster Prominence': float(cluster_prominence),
    'Sum of Squares Variance':
float(sum_of_squares_variance),
    'Sum Average': float(sum_average),
    'Difference Entropy': float(difference_entropy),
    'Cluster Shade': float(cluster_shade),
    'Correlation': float(correlation),
    'Max Probability': float(max_probability),
    'Entropy': float(entropy)
}

return results

def display_results(self, glcm_features):
    self.result_text.clear()

    # Menghitung nilai rata-rata dari semua sudut
    total_features = len(glcm_features)
    average_features = {}
    for feature in glcm_features[0].keys():
        feature_sum = sum(glcm_features[i][feature] for i in
range(total_features))
        average_features[feature] = feature_sum / total_features

    self.result_text.append("Average Features:")
    for feature, value in average_features.items():
        value_str = '{:,.3f}'.format(value) # Format nilai
dengan tanda pemisah ribuan dan 3 digit desimal
        self.result_text.append(f"    {feature}: {value_str}")

class MLWindow(QWidget):
    def __init__(self):
        super().__init__()

        self.layout = QVBoxLayout()

```

```

        self.glcm_labels = [
            "Contrast", "Dissimilarity", "Homogeneity", "Energy",
            "Autocorrelation", "Cluster Prominence", "Sum of Squares
Variance",
            "Sum Average", "Difference Entropy", "Entropy", "Cluster
Shade",
            "Correlation", "Max Probability"
        ]
        self.glcm_inputs = []

        for label in self.glcm_labels:
            glcm_label = QLabel(label)
            glcm_input = QLineEdit()
            self.glcm_inputs.append(glcm_input)
            self.layout.addWidget(glcm_label)
            self.layout.addWidget(glcm_input)

        self.result_label = QLabel("Hasil GLCM:")
        self.layout.addWidget(self.result_label)

        self.dnn_result_label = QLabel("Hasil Prediksi DNN:")
        self.layout.addWidget(self.dnn_result_label)

        self.accuracy_label = QLabel("Akurasi: ")
        self.layout.addWidget(self.accuracy_label)

        self.epoch_label = QLabel("Jumlah Epoch:")
        self.layout.addWidget(self.epoch_label)

        self.epoch_combo = QComboBox()
        self.epoch_combo.addItem("250")
        self.epoch_combo.addItem("500")
        self.epoch_combo.addItem("1000")
        self.layout.addWidget(self.epoch_combo)

        self.dnn_button = QPushButton("Latih dan Uji Model DNN")
        self.dnn_button.clicked.connect(self.train_and_test_dnn_mode
1)
        self.layout.addWidget(self.dnn_button)

        self.setLayout(self.layout)

    def train_and_test_dnn_model(self):
        # Load dataset
        DataP = np.loadtxt('TES.csv', delimiter=',', skiprows=1)

        # Split into x and y

```

```

x = DataP[:, 0:13]
y = DataP[:, 13]

# Define the DNN model
model = Sequential()
model.add(Dense(12, input_shape=(13,), activation='relu'))
model.add(Dense(8, activation='relu'))
model.add(Dense(3, activation='softmax'))

# Compile
model.compile(loss='sparse_categorical_crossentropy',
optimizer='adam', metrics=['accuracy'])

# Get selected epoch value from combo box
selected_epoch = int(self.epoch_combo.currentText())

# Fit the model
history = model.fit(x, y, epochs=selected_epoch,
batch_size=10, verbose=0, validation_split=0.2)

# Evaluate accuracy
_, accuracy = model.evaluate(x, y)
accuracy_percentage = accuracy * 100

# Print accuracy
print('accuracy: %.2f%%' % accuracy_percentage)

# Update GUI with accuracy value
self.accuracy_label.setText(f"Akurasi:
{accuracy_percentage:.2f}%")

# Get GLCM input values from GUI
glcm_input_values = [float(glcm_input.text()) for glcm_input
in self.glcm_inputs]

# Convert GLCM input values to 3x3 matrix
#image_gray = np.array(glcm_input_values).reshape(3, 3)

# Make prediction using DNN model

```

```
Xnew = np.array([glcm_input_values])
ynew = model.predict_classes(Xnew)

# Determine prediction label
if ynew[0] == 0:
    prediction_label = "Prediction: Normal"
elif ynew[0] == 1:
    prediction_label = "Prediction: Pendarahan"
elif ynew[0] == 2:
    prediction_label = "Prediction: Iskemik"
else:
    prediction_label = "Prediction: Unknown"

# Display GLCM values
self.result_label.setText(f"Hasil GLCM:
{glcm_input_values}")

# Display prediction result
self.dnn_result_label.setText(prediction_label)

if __name__ == "__main__":
    app = QApplication(sys.argv)

    tab_widget = QTabWidget()

    glcm_window = GLCMWindow()
    ml_window = MLWindow()

    tab_widget.addTab(glcm_window, "GLCM Feature Extraction")
    tab_widget.addTab(ml_window, "DNN Prediction")

    tab_widget.setGeometry(50, 50, 500, 500)
    tab_widget.show()

    sys.exit(app.exec_())
```

Lampiran 5. Tabel hasil ekstraksi fitur GLCM Citra Normal

GLCM								
Sample	Con	Corr	Hom	Eng	Ent	Diss	S.var	S.avrg
1	6.307	13.557	0.9998	610.000	-2.307	24.735	29.066	131.070
2	5.397	747.787	0.9998	688.000	-2.407	21.165	-1.242	27.030
3	7.803	8.258	0.9997	489.000	-2.180	30.600	583.93	95.370
4	6.177	9.526	0.9998	416.000	-2.211	24.225	104.367	98.940
5	6.762	4.551	0.9998	529.000	-2.219	26.520	4.551	-197.657
6	7.217	3.543	0.9997	664.000	-2.230	28.305	1.184	56.100
7	5.852	16.191	0.9998	267.000	-4.505	22.950	-1.709	139.740
8	5.852	14.890	0.9998	751.000	-2.364	22.950	-1/709	139.740
9	6.307	9.461	0.9998	710.000	-2.209	24.735	-29.066	98.940
10	6.307	9.981	0.9998	558.000	-2.214	24.735	-29.066	103.020
11	7.152	5.332	0.9997	395.000	-2.198	28.050	1.251	69.870
12	6.372	9.818	0.9998	503.000	-2.212	24.990	-95.782	102.000
13	6.632	11.509	0.9998	663.000	-2.240	26.010	-362.649	116.280
14	4.031	11.054	0.9998	519.000	-2.277	15.810	158.533	102.510
15	5.787	7.250	0.9998	466.000	-2.213	22.695	-1.642	79.560

Lampiran 6. Tabel Hasil Ekstraksi fitur GLCM Citra Hemorrhage

GLCM								
Sample	Con	Corr	Hom	Eng	Ent	Diss	S.var	S.avg
1	14.960	13.557	0.9998	610.000	13.841	77.711	334.971	765.474
2	15.818	747.787	0.9998	688.000	11.551	81.887	1.849	667.606
3	15.031	8.258	0.9997	489.000	11.787	78.570	1.702	764.248
4	3.371	9.526	0.9998	416.000	-3.032	17.300	-650.634	197.548
5	3.238	4.551	0.9998	529.000	-2.810	18.026	-1.122	-199.926
6	20.057	3.543	0.9997	664.000	-16.986	102.863	-19.454	926.474
7	21.824	16.191	0.9998	267.000	17.240	112.024	1.396	933.228
8	26.585	14.890	0.9998	751.000	-22.748	138.154	685.957	1.260
9	37.279	9.461	0.9998	710.000	-33.631	190.304	1.742	1.624
10	40.355	9.981	0.9998	558.000	-40.270	210.409	-60.516	2.026
11	36.355	5.332	0.9997	395.000	-35.325	192.930	1.724	-35.325
12	17.209	9.818	0.9998	503.000	-15.437	90.632	-55.336	912.306
13	20.414	11.509	0.9998	663.000	-18.234	106.803	108.442	1.014
14	20.752	11.054	0.9998	519.000	-18.433	107.015	-216.224	929.782
15	11.871	7.250	0.9998	466.000	-10.738	62.180	-1.564	599.730

Lampiran 7. Tabel Hasil Ekstraksi fitur GLCM Citra Iskemik

GLCM								
Sample	Con	Corr	Hom	Eng	Ent	Diss	S.var	S.avrg
1	3.446	15.378	0.9998	434.000	-2.307	24.735	29.066	0.9998
2	4.876	682.762	0.9997	512.000	-2.407	21.165	-1.242	0.9998
3	4.486	1.593	0.9997	282.000	-2.180	30.600	583.93	0.9997
4	2.470	10.664	0.9998	535.000	-2.211	24.225	104.367	0.9998
5	4.746	11.737	0.9997	314.000	-2.219	26.520	4.551	0.9998
6	4.291	1.639	0.9997	447.000	-2.230	28.305	1.184	0.9997
7	4.681	8.843	0.9998	453.000	-4.505	22.950	-1.709	0.9998
8	5.006	14.272	0.9998	506.000	-2.364	22.950	-1/709	0.9998
9	3.316	7.380	0.9998	476.000	-2.209	24.735	-29.066	0.9998
10	4.876	15.508	0.9998	432.000	-2.214	24.735	-29.066	0.9998
11	5.917	12.972	0.9997	520.000	-2.198	28.050	1.251	0.9997
12	3.966	13.427	0.9998	520.000	-2.212	24.990	-95.782	0.9998
13	3.056	12.387	0.9998	392.000	-2.240	26.010	-362.649	0.9998
14	3.836	13.492	0.9997	256.000	-2.277	15.810	158.533	0.9998
15	3.771	13.395	0.9998	427.000	-2.213	22.695	-1.642	0.9998

JURNAL BIMBINGAN SKRIPSI/TESIS/DISERTASI

MAHASISWA

- : 19640025
- : HALIIM PAMUNGKAS HARJO SUYONO
- : SAINS DAN TEKNOLOGI
- : FISIKA
- : Dr. H. AGUS Mulyono, S.Pd., M.Kes
- : MUBASYIROH, S.S., M.Pd.I
- : ANALISIS TEKSTUR CITRA CT-SCAN DENGAN METODE GLCM DAN DNN UNTUK DETEKSI TINGKAT KEPARAHAN STROKE

Pembimbing 1
Pembimbing 2
Skrripsi/Tesis/Disertasi

REKORD BIMBINGAN

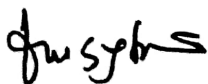
Tanggal Bimbingan	Nama Pembimbing	Deskripsi Proses Bimbingan	Tahun Akademik	Status
07 September 2022	Dr. H. AGUS Mulyono, S.Pd., M.Kes	Konsultasi judul	Genap 2022/2023	Sudah Dikoreksi
15 September 2022	Dr. H. AGUS Mulyono, S.Pd., M.Kes	KONSULTASI BAB 1	Genap 2022/2023	Sudah Dikoreksi
19 September 2022	Dr. H. AGUS Mulyono, S.Pd., M.Kes	KONSULTASI BAB 1 DAN BAB 2	Genap 2022/2023	Sudah Dikoreksi
13 Oktober 2022	Dr. H. AGUS Mulyono, S.Pd., M.Kes	KONSULTASI BAB 3	Genap 2022/2023	Sudah Dikoreksi
06 April 2023	Dr. H. AGUS Mulyono, S.Pd., M.Kes	KONSULTASI BAB 4	Ganjil 2023/2024	Sudah Dikoreksi
10 April 2023	Dr. H. AGUS Mulyono, S.Pd., M.Kes	KONSULTASI BAB 4	Ganjil 2023/2024	Sudah Dikoreksi
12 April 2023	Dr. H. AGUS Mulyono, S.Pd., M.Kes	KONSULTASI BAB 4	Ganjil 2023/2024	Sudah Dikoreksi
21 Juni 2023	Dr. H. AGUS Mulyono, S.Pd., M.Kes	KONSULTASI SEMUA BAB	Ganjil 2023/2024	Sudah Dikoreksi
30 Juli 2023	MUBASYIROH, S.S., M.Pd.I	KONSULTASI INTEGRASI BAB 1	Ganjil 2023/2024	Sudah Dikoreksi
16 Agustus 2023	MUBASYIROH, S.S., M.Pd.I	KONSULTASI BAB 2 DAN 4	Ganjil 2023/2024	Sudah Dikoreksi
21 Agustus 2023	MUBASYIROH, S.S., M.Pd.I	KONSULTASI ABSTRAK, INTEGRASI BAB 1,2,4	Ganjil 2023/2024	Sudah Dikoreksi

Telah disetujui
Untuk mengajukan ujian Skripsi/Tesis/Desertasi

Malang, 14-12-2023
Dosen Pembimbing 1


Dr. H. AGUS Mulyono, S.Pd., M.Kes

Dosen Pembimbing 2



MUBASYIROH, S.S., M.Pd.I

