

ANALISIS BERITA KRIMINAL BERBASIS GRAPH CLASSIFICATION

Jasman^{*1}, Hazriani², Yuyun³

^{1,2,3}Program Pascasarjana, Sistem Komputer, Universitas Handayani Makassar

¹Teknik Komputer, Sekolah Tinggi Ilmu Komputer 22 Januari Kendari

³Pusat Riset Data dan Informasi, Badan Riset dan Inovasi Nasional, Indonesia

e-mail: ¹jasmanstikom@gmail.com, ²hazriani@handayani.ac.id, ³yuyu010@brin.go.id

Analisis berita kriminal berbasis klasifikasi graf merupakan pendekatan inovatif yang menggunakan representasi graf untuk memahami hubungan antar entitas dalam data kriminal. Penelitian ini bertujuan untuk mengembangkan model klasifikasi berbasis Deep Graph Convolutional Neural Networks (DGCNN) untuk berita kriminal, mengevaluasi efektivitasnya, dan menghasilkan analisis prediktif yang mendukung penegakan hukum. Metode penelitian dimulai dengan pengumpulan data dari 1.500 berita kriminal, yang diproses melalui tahapan preprocessing seperti tokenisasi dan filtering untuk menghasilkan graf yang merepresentasikan hubungan antar entitas. Selanjutnya, model DGCNN dilatih menggunakan dataset ini, dengan metrik akurasi, precision, dan recall sebagai indikator kinerjanya. Hasil penelitian menunjukkan bahwa DGCNN mampu menangkap pola-pola kompleks, seperti keterkaitan antara pelaku, korban, lokasi, dan waktu kejadian. Namun, terdapat kendala pada overfitting dan underfitting, terutama pada dataset dengan distribusi yang tidak seimbang. Kesimpulannya, meski DGCNN menunjukkan potensi signifikan dalam analisis kriminal, peningkatan pada teknik regulasi, augmentasi data, dan pemilihan parameter diperlukan untuk memaksimalkan generalisasi model, sehingga mendukung prediksi kriminal yang lebih akurat dan strategis.

Kata Kunci : Berita Kriminal, DGCNN, Graph Classification

I. PENDAHULUAN

Pendekatan analisis berita kriminal berbasis klasifikasi graf telah menjadi sorotan dalam studi data kompleks [1]. Klasifikasi graf memanfaatkan struktur hubungan antar entitas seperti pelaku, korban, lokasi, dan waktu kejadian dalam berita kriminal untuk menggali pola dan tren yang lebih mendalam. Dengan memanfaatkan teknologi Graph Neural Networks (GNN), pendekatan ini memberikan peluang besar dalam meningkatkan pemahaman dinamika kejahatan serta mendukung pencegahan kriminalitas [2].

Berita kriminal sering kali disajikan dalam bentuk teks tidak terstruktur, yang membutuhkan proses Natural Language Processing (NLP) untuk mengekstrak informasi relevan. Informasi ini kemudian direpresentasikan dalam bentuk graf untuk analisis yang lebih mendalam. Salah satu keunggulan pendekatan ini adalah kemampuannya dalam mengintegrasikan berbagai sumber data, seperti

laporan kepolisian dan catatan pengadilan, ke dalam model analisis terpadu. Model GNN tidak hanya mampu mengidentifikasi pola tersembunyi dalam data tetapi juga memprediksi kemungkinan kejahatan berdasarkan data historis, yang sangat bermanfaat bagi penegak hukum dalam merancang strategi pencegahan [3], [4].

Literatur menunjukkan bahwa penggunaan GNN dalam analisis berita kriminal menghadirkan inovasi yang signifikan [5]. Teknologi ini memungkinkan pemrosesan data yang lebih efisien, mengungkap pola-pola hubungan yang tidak terdeteksi oleh metode konvensional [6]. Misalnya, analisis menggunakan GNN dapat membantu mengidentifikasi jaringan kriminal yang tersembunyi dan menganalisis potensi kejahatan berulang berdasarkan pola waktu dan lokasi [7]. Namun, tantangan seperti privasi data dan etika penggunaan tetap menjadi isu utama yang perlu diatasi untuk memastikan hasil analisis digunakan secara bertanggung jawab.

Solusi yang diusulkan dalam penelitian ini adalah pengembangan model klasifikasi berita kriminal berbasis GNN yang dirancang untuk mengelola data tidak terstruktur dengan lebih baik. Model ini dirancang untuk mengevaluasi efektivitas analisis berbasis graf dalam membantu mengidentifikasi pola kejahatan, mendeteksi anomali, dan memberikan prediksi yang lebih akurat tentang potensi kejahatan. Dengan memanfaatkan kekuatan GNN, penelitian ini diharapkan mampu memberikan kontribusi signifikan dalam pengembangan teknologi analisis data kriminal.

Nilai baru dari penelitian ini terletak pada integrasi teknologi GNN dengan data berita kriminal yang sering kali kompleks dan tidak terstruktur. Pendekatan ini tidak hanya memberikan solusi teknis tetapi juga menawarkan perspektif baru dalam memahami dinamika sosial di masyarakat. Inovasi ini memungkinkan identifikasi pola kejahatan yang lebih akurat, mendukung tindakan preventif, dan memberikan wawasan strategis kepada pihak berwenang.

Tujuan utama dari penelitian ini adalah mengembangkan dan mengimplementasikan model GNN untuk klasifikasi berita kriminal, serta mengevaluasi efektivitasnya dalam menganalisis data kriminal. Dengan pendekatan ini, penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam meningkatkan keamanan publik dan mendukung pengambilan keputusan berbasis data yang lebih baik.

II. METODE PENELITIAN

Penelitian ini menggunakan desain berbasis analisis berita kriminal dengan pendekatan klasifikasi graf menggunakan model DeepGraphCNN (DGCNN). Tahapan utama meliputi:

1. Studi Literatur. Menelaah buku, jurnal, dan laporan penelitian relevan untuk membangun fondasi teoritis.
2. Pengumpulan Data. Mengumpulkan data dari portal berita daring terpercaya yang mencakup teks berita, metadata, dan entitas seperti pelaku, korban, lokasi, serta waktu kejadian.
3. Preprocessing Data. Melibatkan proses seperti *casefolding*, *filtering*, dan *tokenization* untuk mengubah data menjadi format yang terstruktur dan siap untuk analisis.
4. Model Pengujian. Melatih model DGCNN menggunakan kerangka kerja *transfer learning* untuk mengklasifikasikan berita.
5. Evaluasi Model. Melakukan evaluasi kinerja model berdasarkan metrik seperti akurasi, presisi, dan *recall*.
6. Representasi Hasil. Mencakup dokumentasi dan pelaporan hasil dalam tesis.

Desain ini dipilih karena relevansinya dengan tujuan penelitian, yaitu menganalisis berita kriminal berbasis graf, serta didukung oleh teori-teori terkait analisis data graf dan jaringan saraf.

A. Alasan Pemilihan Desain

Pendekatan DGCNN dipilih karena keunggulannya dalam menangani data berbasis graf. Model ini mampu memanfaatkan hubungan antar entitas dalam graf, seperti pelaku dan korban dalam berita kriminal. Menurut literatur, DGCNN dengan lapisan *SortPooling* dapat mengatasi tantangan dalam mengelola informasi topologi global tanpa kehilangan fleksibilitas dalam analisis data heterogen. Hal ini menjadikannya sangat cocok untuk klasifikasi berita berbasis graf.

B. Prosedur Pengumpulan Data

1. Sumber Data. Portal berita online terpercaya yang memberikan 1.500 berita kriminal lengkap dengan metadata.
2. Metode Pengumpulan. Menggunakan wawancara, observasi, dan dokumentasi untuk memastikan data memenuhi standar validitas dan reliabilitas.
3. Tahapan Pengolahan Awal. Data yang terkumpul diproses melalui teknik *casefolding*, *filtering*, dan *tokenization* untuk membuang elemen tidak relevan seperti simbol, angka, dan emotikon.

C. Teknik Analisis Data

1. Model DeepGraphCNN (DGCNN)
 - a. Tahapan Pemrosesan. Data berita diubah menjadi graf yang merepresentasikan hubungan antar entitas.
 - b. Penggunaan *SortPooling*. Untuk mempertahankan informasi struktural graf selama pelatihan model.
 - c. Pengujian. Model dilatih menggunakan dataset yang telah diproses, kemudian diuji berdasarkan metrik seperti akurasi, presisi, dan *recall*.

2. Evaluasi Model

Menggunakan *Confusion Matrix* yang mencakup TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*) [5].

III. HASIL DAN PEMBAHASAN

A. Hasil Penelitian

Dataset penelitian berisi 1.500 berita kriminal yang dianalisis untuk mengeksplorasi pola kejahatan berdasarkan individu, lokasi, dan peristiwa. Data mencakup berbagai modus operandi, seperti pencurian dengan penyamaran hingga tindakan kriminal oleh pelaku usia muda. Informasi ini memungkinkan analisis terhadap keterlibatan usia muda dan variasi kejahatan lintas wilayah.

Tabel 1.
Karakteristik Dataset Penelitian

Jenis Kejahatan	Jumlah Data	Contoh Kasus
Pencurian	300	Pencurian kendaraan bermotor di Kendari.
Penganiayaan	300	Kasus remaja terlibat dalam perkelahian.
Penipuan	300	Penipuan emas dengan penyamaran sebagai pelanggan.
Pembunuhan	300	Kasus pembunuhan di Kolaka Timur.
Korupsi	300	Penyelewengan dana daerah.

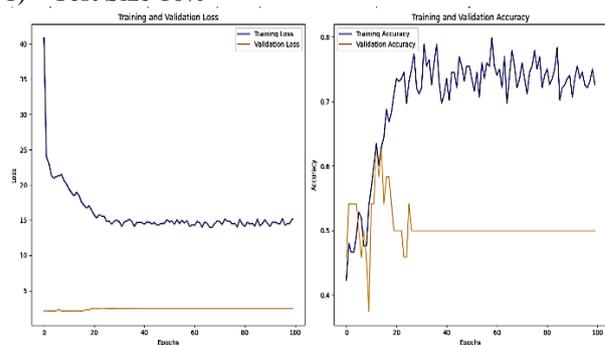
Dataset ini mencakup informasi pelaku, korban, lokasi, dan waktu kejadian. Data mentah diproses untuk memastikan kualitas melalui *casefolding*, *filtering*, dan *tokenization*.

1. Model Deep Graph Convolutional Neural Networks (DGCNN) Epoch 100.

a. Batch Size 8.

Pengujian model *Deep Graph Convolutional Neural Networks* (DGCNN) dilakukan setelah pelatihan selama 100 *epoch* dengan *Batch Size* 8. Pada tahap ini, model diuji menggunakan data uji yang belum pernah dilihat sebelumnya untuk mengukur kemampuannya dalam mengklasifikasikan berita kriminal. Hasil pengujian menunjukkan bahwa model mampu mengidentifikasi pola-pola penting dalam graf berita, seperti hubungan antara pelaku, lokasi, dan waktu kejadian, dengan tingkat akurasi yang memuaskan.

1) Test Size 10%

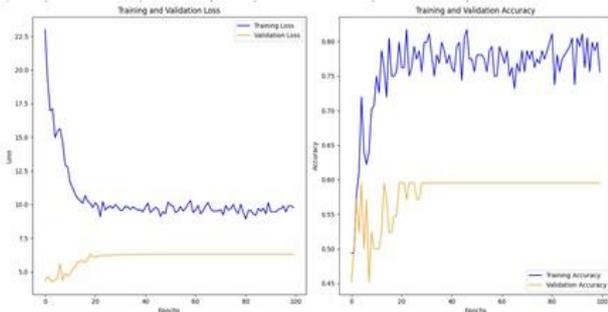


Gambar 1.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 100 Batch Size 8 Test Size 10%

Gambar 1 tersebut menunjukkan bagaimana kinerja model selama pelatihan melalui dua grafik: satu untuk *loss* dan satu lagi untuk akurasi. Terlihat bahwa model makin baik dalam mempelajari data pelatihan, ditandai dengan penurunan nilai *loss* dan peningkatan akurasi. Namun, hasil pada data validasi tidak menunjukkan kemajuan yang sama—*loss*-nya tetap datar dan akurasi rendah. Ini menandakan model terlalu fokus pada data pelatihan dan kesulitan menghadapi data baru. Untuk mengatasinya, perlu dilakukan penyesuaian lebih lanjut, seperti mengatur ulang parameter atau menambahkan teknik regularisasi.

2) Test Size 20%

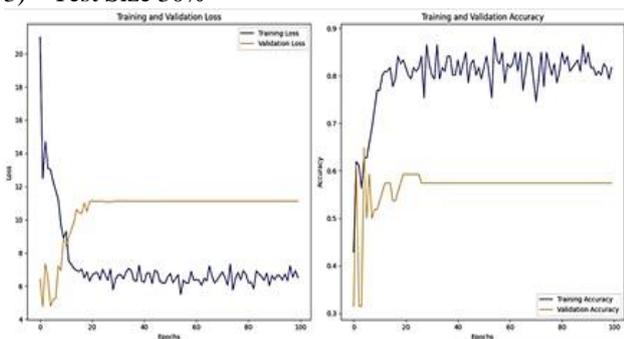


Gambar 2.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 100 Batch Size 8 Test Size 20%

Gambar 2 menunjukkan bagaimana model belajar selama pelatihan. Terlihat bahwa seiring waktu, model semakin mahir memahami data pelatihan—ditunjukkan oleh penurunan *loss* dan peningkatan akurasi. Namun, performa pada data validasi cenderung stagnan, baik dari sisi *loss* maupun akurasi. Ini memberi sinyal bahwa model mungkin terlalu fokus pada data pelatihan dan kurang mampu mengenali pola baru di luar itu. Ketidakseimbangan ini menyiratkan bahwa model masih perlu disempurnakan, mungkin lewat penyesuaian struktur atau teknik regularisasi, agar hasilnya bisa lebih stabil dan bisa diandalkan saat menghadapi data baru.

3) Test Size 30%



Gambar 3.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 100 Batch Size Test Size 30%

Dua grafik yang ditampilkan pada gambar 3 menggambarkan proses pelatihan model dari sisi *loss* dan akurasi. Pada grafik *loss*, terlihat bahwa model mampu menurunkan kesalahan pada data pelatihan cukup cepat, lalu cenderung stabil, menandakan proses belajar berjalan. Namun, *loss* pada data validasi tidak menunjukkan perbaikan serupa dan malah stagnan, yang bisa jadi pertanda bahwa model terlalu menyesuaikan diri dengan data pelatihan. Sementara itu, grafik akurasi menunjukkan peningkatan konsisten pada data pelatihan, tapi akurasi

validasi tidak mengalami perkembangan berarti. Pola ini menunjukkan bahwa model kesulitan memahami data baru di luar yang digunakan saat pelatihan. Untuk mengatasi hal ini, perlu dilakukan evaluasi ulang terhadap parameter, struktur model, atau penggunaan teknik regularisasi agar kerjanya lebih merata di semua jenis data.

Tabel 2.

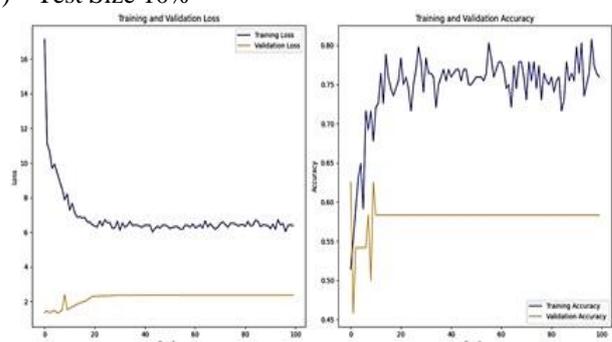
Classification Report model DGCNN epoch 100 BatchSize 8					
Train Size	Precision	Recall	F1	Support	
10%	0.58	0.58	0.58	12	Pembunuhan
	0.64	0.64	0.64	14	Pemeriksaan
			0.62	26	Accuracy
	0.61	0.61	0.61	26	Macro Avg
	0.62	0.62	0.62	26	Weight Avg
20%	0.58	0.58	0.58	24	Pembunuhan
	0.64	0.64	0.64	28	Pemeriksaan
			0.46	52	Accuracy
	0.61	0.61	0.61	52	Macro Avg
	0.62	0.62	0.62	52	Weight Avg
30%	0.58	0.58	0.58	32	Pembunuhan
	0.64	0.64	0.64	46	Pemeriksaan
			0.55	78	Accuracy
	0.61	0.61	0.61	78	Macro Avg
	0.62	0.62	0.62	78	Weight Avg

Tabel 2 menampilkan hasil evaluasi model klasifikasi dengan pengaturan pelatihan selama 100 *epoch*, *batch size* 8, dan variasi pembagian data latih sebesar 10%, 20%, dan 30%. Dari semua pengujian, performa model cenderung lebih baik saat mengenali kategori pemeriksaan dibandingkan pembunuhan. Train split 30% menghasilkan hasil paling baik, dengan akurasi tertinggi mencapai 55% serta nilai *f1-score*, *macro average*, dan *weighted average* yang juga lebih unggul dibandingkan pembagian data lainnya. Hal ini menunjukkan bahwa model bekerja lebih optimal saat diberi data latih yang lebih banyak, menjadikan *train split* 30% sebagai pilihan yang paling efektif untuk skenario ini.

b. Batch Size 16

Pengujian model *Deep Graph Convolutional Neural Networks* (DGCNN) dilakukan setelah pelatihan selama 100 *epoch* dengan *Batch Size* 16. Pada tahap ini, model diuji menggunakan data uji yang belum pernah dilihat sebelumnya untuk mengukur kemampuannya dalam mengklasifikasikan berita kriminal.

1) Test Size 10%



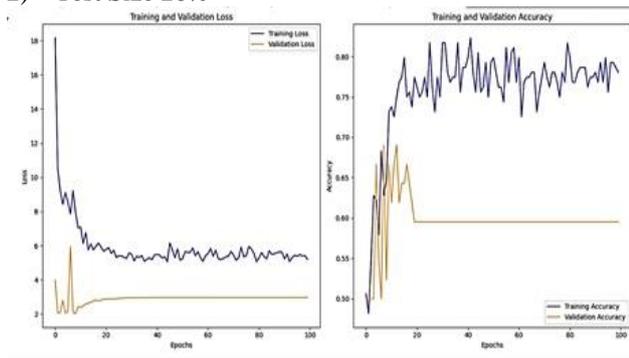
Gambar 4.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 100 Batch Size 16 Test Size 10%

Gambar 4 memperlihatkan bagaimana model belajar selama 100 *epoch*, ditunjukkan lewat dua grafik yang mencatat tren *loss* dan akurasi untuk data pelatihan dan

validasi. Dari grafik *loss*, tampak bahwa model cukup cepat meminimalkan kesalahan pada data pelatihan, namun kesalahan pada data validasi nyaris tidak berubah, yang bisa jadi tanda bahwa model belum mampu memahami pola di luar data latih. Sementara itu, grafik akurasi menunjukkan peningkatan pada data pelatihan, tapi akurasi pada data validasi justru tetap rendah dan cenderung datar sepanjang pelatihan. Ketimpangan performa ini mengindikasikan bahwa model belum mampu melakukan generalisasi dengan baik. Untuk mengatasi hal ini, bisa dipertimbangkan penambahan data, penyesuaian parameter, atau penggunaan teknik regularisasi agar performa model lebih seimbang.

2) Test Size 20%

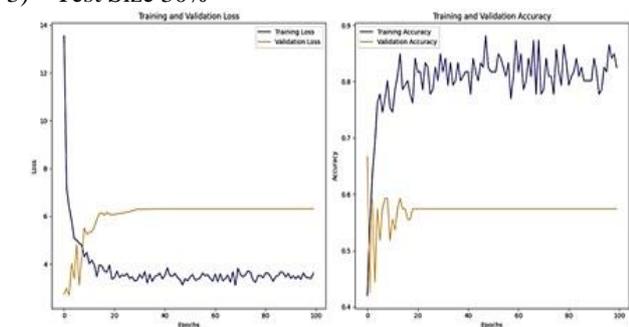


Gambar 5.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 100 Batch Size 16 Test Size 20%

Gambar 5 memperlihatkan bagaimana performa model selama pelatihan 100 *epoch* melalui dua grafik—satu menunjukkan *loss* dan satu lagi akurasi untuk data pelatihan dan validasi. Terlihat bahwa model cukup berhasil mengurangi kesalahan pada data pelatihan, ditandai dengan turunnya *training loss* dan naiknya akurasi. Namun, performa pada data validasi tidak menunjukkan kemajuan berarti—baik nilai *loss* maupun akurasi cenderung datar sepanjang proses. Kondisi ini mengisyaratkan bahwa model belum mampu mengenali pola pada data baru dengan baik, kemungkinan karena *underfitting*. Untuk memperbaiki hasil ini, dibutuhkan penyesuaian seperti perubahan arsitektur, pengaturan ulang parameter, atau penambahan teknik seperti regularisasi dan augmentasi data agar model dapat bekerja lebih seimbang dan mampu generalisasi dengan lebih baik.

3) Test Size 30%



Gambar 6.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 100 Batch Size 16 Test Size 30%

Gambar 6 menampilkan dua grafik yang menggambarkan bagaimana model belajar selama 100 *epoch*, dilihat dari sisi *loss* dan akurasi untuk data

pelatihan dan validasi. Dari grafik *loss*, terlihat bahwa model mampu terus menurunkan kesalahan pada data pelatihan, namun tidak terjadi hal serupa pada data validasi—*loss*-nya tetap tinggi dan stabil, yang bisa menjadi tanda *overfitting*. Sementara itu, grafik akurasi menunjukkan performa yang cukup tinggi namun fluktuatif pada data pelatihan, sedangkan akurasi validasi cenderung datar sejak awal pelatihan, menandakan model kesulitan mengenali pola di luar data latih. Kondisi ini mengisyaratkan bahwa model terlalu fokus pada data pelatihan tanpa mampu melakukan generalisasi. Untuk mengatasinya, perlu diterapkan strategi seperti regularisasi, penyesuaian arsitektur, atau memperbanyak data pelatihan agar performa model lebih merata.

Tabel 3.

Classification Report model DGCNN epoch 100 BatchSize 16

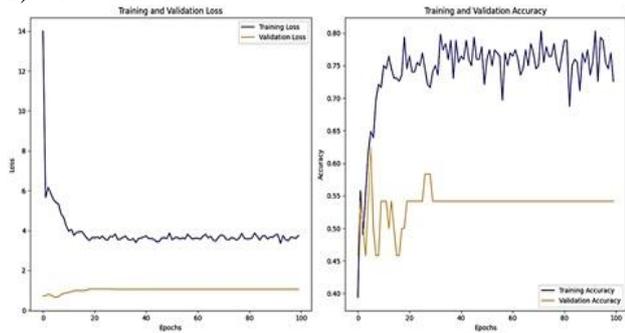
Train Size	Precision	Recall	F1	Support	
10%	0.58	0.58	0.58	12	Pembunuhan
	0.64	0.64	0.64	14	Pemeriksaan
			0.62	26	Accuracy
	0.61	0.61	0.61	26	Macro Avg
	0.62	0.62	0.62	26	Weight Avg
20%	0.41	0.50	0.45	24	Pembunuhan
	0.48	0.39	0.43	28	Pemeriksaan
			0.44	52	Accuracy
	0.45	0.45	0.44	52	Macro Avg
	0.45	0.44	0.44	52	Weight Avg
30%	0.44	0.44	0.44	32	Pembunuhan
	0.61	0.61	0.61	46	Pemeriksaan
			0.54	78	Accuracy
	0.52	0.52	0.52	78	Macro Avg
	0.54	0.54	0.54	78	Weight Avg

Hasil yang ditampilkan dalam tabel 3, terlihat bahwa kinerja model paling baik saat data uji hanya 10% (TS-10%), dengan akurasi tertinggi mencapai 0,62 dan rata-rata *F1-score* sebesar 0,61. Ini menunjukkan bahwa model cukup mampu mengenali kedua kategori, yakni pembunuhan dan pemeriksaan. Namun, saat porsi data uji ditingkatkan menjadi 20% dan 30%, performa model justru menurun—baik dari segi akurasi maupun *F1-score*—yang mengindikasikan bahwa model mulai kesulitan saat dihadapkan dengan lebih banyak data baru. Secara konsisten, kelas pemeriksaan menunjukkan hasil metrik yang lebih stabil dibanding pembunuhan. Berdasarkan hasil tersebut, pembagian data uji sebesar 10% menjadi pilihan paling ideal karena memberikan keseimbangan terbaik antara kemampuan belajar dan kemampuan menggeneralisasi.

c. Batch Size 32

Pengujian model *Deep Graph Convolutional Neural Networks* (DGCNN) dilakukan setelah pelatihan selama 100 *epoch* dengan *Batch Size* 32. Pada tahap ini, model diuji menggunakan data uji yang belum pernah dilihat sebelumnya untuk mengukur kemampuannya dalam mengklasifikasikan berita kriminal.

1) Test Size 10%

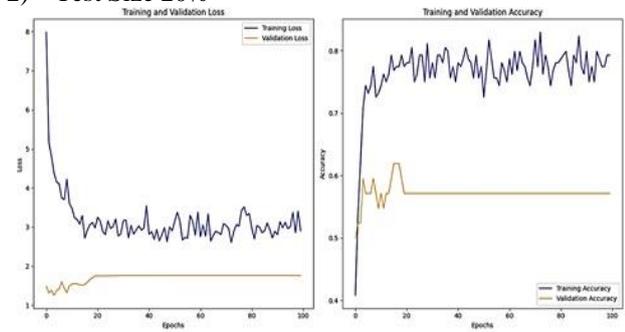


Gambar 7.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 100 Batch Size 32 Test Size 10%

Gambar 7 memperlihatkan bagaimana model belajar selama 100 epoch, dengan memantau nilai *loss* dan akurasi pada data pelatihan dan validasi. Terlihat bahwa model cukup berhasil memahami data pelatihan—*loss* menurun secara stabil dan akurasi cenderung tinggi meskipun sedikit fluktuatif. Namun, ketika diuji dengan data validasi, performa model tampak stagnan; baik nilai *loss* maupun akurasi tidak menunjukkan perbaikan berarti setelah beberapa epoch pertama. Hal ini mengisyaratkan bahwa model terlalu fokus pada data pelatihan dan kesulitan menangkap pola dari data baru, atau dengan kata lain, mengalami *overfitting*. Untuk memperbaiki situasi ini, dibutuhkan penyesuaian seperti regularisasi, penambahan variasi data, atau revisi arsitektur model agar hasilnya bisa lebih seimbang dan mampu menangani data yang belum pernah dilihat sebelumnya.

2) Test Size 20%

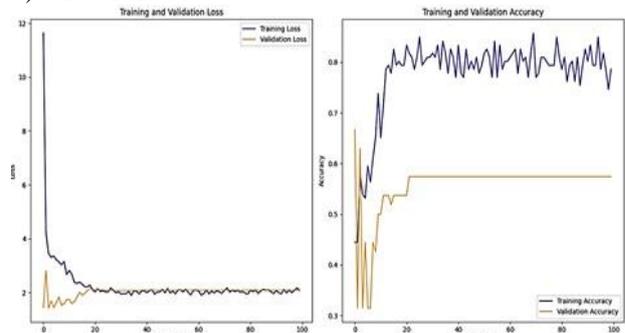


Gambar 8.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 100 Batch Size 32 Test Size 20%

Gambar 8 memperlihatkan dua grafik yang mencerminkan performa model selama proses pelatihan, satu memantau nilai *loss* dan satunya lagi memantau akurasi, baik untuk data pelatihan maupun validasi. Dari grafik *loss*, tampak bahwa model mampu menurunkan kesalahan pada data pelatihan secara konsisten, meskipun *loss* validasi tetap tinggi dan tidak menunjukkan perbaikan berarti. Hal yang sama juga terlihat pada grafik akurasi: model semakin akurat terhadap data pelatihan seiring waktu, tetapi tidak menunjukkan peningkatan pada data validasi. Pola ini menunjukkan bahwa model terlalu terpaku pada data pelatihan dan kesulitan menangani data baru—suatu kondisi yang dikenal sebagai *overfitting*. Untuk mengatasi hal ini, pendekatan seperti regularisasi, penambahan variasi data, atau penyesuaian struktur model bisa menjadi solusi agar model mampu belajar lebih seimbang dan generalisasi lebih baik.

3) Test Size 30%



Gambar 9.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 100 Batch Size 32 Test Size 30%

Gambar 9 menampilkan dua grafik yang menunjukkan perkembangan model selama pelatihan: satu menggambarkan penurunan nilai *loss*, dan yang lainnya menunjukkan peningkatan akurasi, baik untuk data pelatihan maupun validasi. Dari grafik *loss*, terlihat bahwa model berhasil mengurangi kesalahan pada data pelatihan secara konsisten hingga sekitar epoch ke-40, kemudian stabil, sementara *loss* pada data validasi juga menurun tapi tetap lebih tinggi—menandakan adanya perbedaan performa. Grafik akurasi menguatkan pola ini, di mana akurasi pelatihan meningkat pesat dan mencapai angka tinggi, sedangkan akurasi validasi hanya naik sedikit dan cenderung stagnan. Perbedaan mencolok antara keduanya menunjukkan bahwa model mungkin mengalami *overfitting*. Untuk mengatasi ini, perlu dipertimbangkan strategi seperti regularisasi, penyesuaian *hyperparameter*, atau penambahan variasi data agar model bisa bekerja lebih seimbang dan efektif pada data yang belum pernah dilihat.

Tabel 4.

Classification Report model DGCNN epoch 100 BatchSize 32

Train Size	Precision	Recall	F1	Support	
10%	0.53	0.75	0.62	12	Pembunuhan
		0.67	0.43	14	Pemeriksaan
			0.58	26	Accuracy
	0.60	0.59	0.57	26	Macro Avg
	0.60	0.58	0.57	26	Weight Avg
20%	0.39	0.46	0.42	24	Pembunuhan
		0.46	0.39	0.42	28
			0.42	52	Accuracy
	0.43	0.43	0.42	52	Macro Avg
	0.43	0.42	0.42	52	Weight Avg
30%	0.48	0.38	0.42	32	Pembunuhan
		0.62	0.72	0.67	46
			0.58	78	Accuracy
	0.55	0.55	0.54	78	Macro Avg
	0.56	0.58	0.57	78	Weight Avg

Tabel 4 memperlihatkan evaluasi performa model klasifikasi pada tiga ukuran data validasi yang berbeda. Di antara ketiganya, penggunaan *split* 30% menunjukkan hasil paling seimbang dan unggul, dengan akurasi

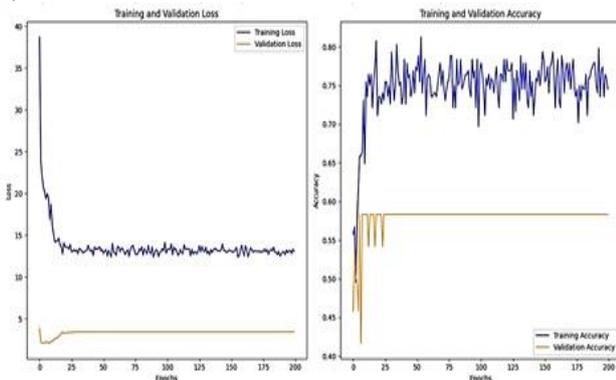
mencapai 0,58 serta *f1-score* tertinggi untuk kategori "pemeriksaan". Rata-rata metrik lainnya juga lebih baik pada *split* ini, menandakan bahwa proporsi 30% memberikan gambaran performa model yang lebih meyakinkan dan representatif.

2. Model *Deep Graph Convolutional Neural Networks* (DGCNN) Epoch 200

a. Batch Size 8

Pengujian model *Deep Graph Convolutional Neural Networks* (DGCNN) dilakukan setelah pelatihan selama 200 *epoch* dengan *Batch Size* 8. Pada tahap ini, model diuji menggunakan data uji yang belum pernah dilihat sebelumnya untuk mengukur kemampuannya dalam mengklasifikasikan berita kriminal.

1) Test Size 10%

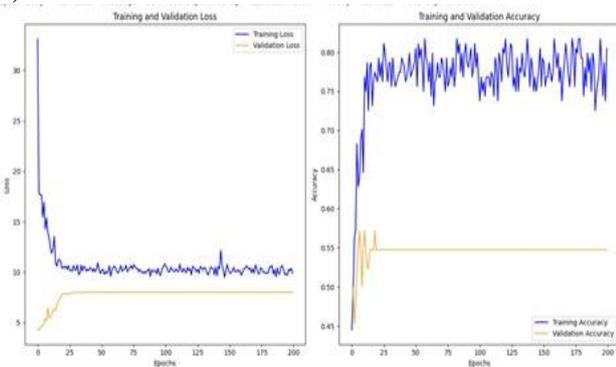


Gambar 10.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 200 Batch Size 8 Test Size 10%

Gambar 10 menampilkan performa model selama 200 *epoch*, menunjukkan bahwa meskipun *loss* dan akurasi pada data pelatihan terus membaik, performa pada data validasi justru stagnan. *Training loss* menurun dan akurasinya tinggi, namun *validation loss* tetap tinggi dan akurasinya rendah, mengindikasikan potensi *overfitting*. Ketimpangan ini menunjukkan bahwa model belum mampu menangkap pola pada data validasi, sehingga perlu penyesuaian, seperti penyederhanaan arsitektur, penambahan data validasi, atau penerapan regularisasi.

2) Test Size 20%



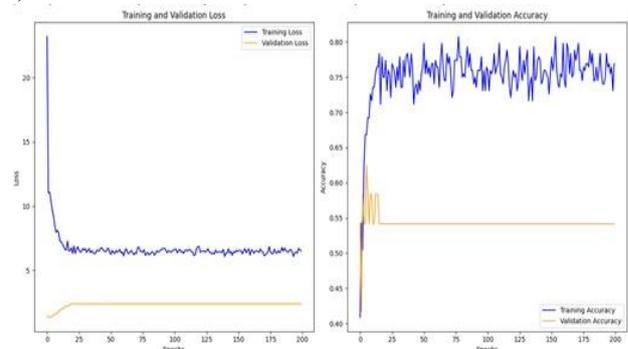
Gambar 11.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 200 Batch Size 8 Test Size 20%

Gaambar 11 menggambarkan proses pelatihan model selama 200 *epoch* dengan fokus pada *loss* dan akurasi untuk data pelatihan dan validasi. *Loss* pelatihan turun drastis di awal dan stabil di sekitar nilai 10, sementara *loss* validasi nyaris tidak berubah, menetap di angka 5. Sementara itu, akurasi pelatihan mencapai kisaran tinggi antara 0,8 hingga 0,95, tetapi akurasi validasi tetap rendah

di sekitar 0,55 tanpa peningkatan berarti. Pola ini menunjukkan bahwa model belajar baik dari data pelatihan namun gagal menangkap pola pada data validasi, yang menandakan *overfitting*. Untuk mengatasi hal ini, dapat dipertimbangkan strategi seperti regularisasi, augmentasi data, atau *early stopping* agar model lebih mampu melakukan generalisasi.

3) Test Size 30%



Gambar 12.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 200 Batch Size 8 Test Size 30%

Gaambar 12 menunjukkan bahwa selama proses pelatihan, model mampu belajar dengan cukup baik dari data pelatihan—terlihat dari penurunan signifikan pada *loss* dan tingginya akurasi pelatihan sejak awal. Namun, performa pada data validasi tidak menunjukkan peningkatan yang sepadan; *loss* validasi tetap tinggi dan akurasi stagnan di kisaran 0,6, mengindikasikan adanya *overfitting*. Untuk mengurangi kesenjangan performa ini, strategi seperti regularisasi, augmentasi data, atau *early stopping* bisa dipertimbangkan agar model lebih mampu mengenali pola dari data yang belum pernah dilihat sebelumnya.

Tabel 5.

Classification Report model DGCNN epoch 200 BatchSize 8					
Train Size	Precision	Recall	F1	Support	
10%	0.50	0.67	0.57	12	Pembunuhan
	0.60	0.43	0.50	14	Pemeriksaan
			0.54	26	Accuracy
	0.55	0.55	0.54	26	Macro Avg
	0.55	0.54	0.53	26	Weight Avg
20%	0.43	0.50	0.46	24	Pembunuhan
	0.50	0.43	0.46	28	Pemeriksaan
			0.46	52	Accuracy
	0.46	0.46	0.46	52	Macro Avg
	0.47	0.46	0.46	52	Weight Avg
30%	0.42	0.41	0.41	32	Pembunuhan
	0.60	0.61	0.60	46	Pemeriksaan
			0.53	78	Accuracy
	0.51	0.51	0.51	78	Macro Avg
	0.52	0.53	0.52	78	Weight Avg

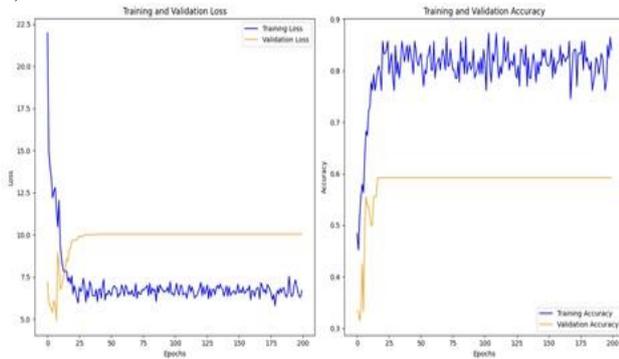
Tabel 5 menunjukkan tiga skenario *training split*, performa model terlihat paling baik saat menggunakan 30% data untuk pelatihan. Meskipun pada TS-10% dan TS-20% akurasi model cukup rendah (masing-masing 0.54 dan 0.46), penggunaan data pelatihan yang lebih besar pada TS-30% mampu meningkatkan akurasi menjadi 0.53. Kategori "pemeriksaan" juga konsisten menunjukkan *precision* dan *recall* yang lebih tinggi dibanding "pembunuhan", terutama pada TS-30%. Secara keseluruhan, meskipun hasilnya belum sempurna, TS-30% memberikan keseimbangan metrik yang lebih stabil

dan layak dipertimbangkan sebagai konfigurasi paling menjanjikan untuk pengembangan model selanjutnya.

b. Batch Size 16

Pengujian model *Deep Graph Convolutional Neural Networks* (DGCNN) dilakukan setelah pelatihan selama 200 epoch dengan *Batch Size* 16. Pada tahap ini, model diuji menggunakan data uji yang belum pernah dilihat sebelumnya untuk mengukur kemampuannya dalam mengklasifikasikan berita kriminal.

1) Test Size 10%

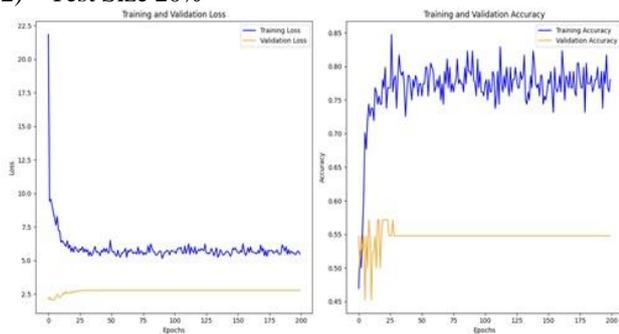


Gambar 13.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 200 Batch Size 16 Test Size 10%

Gambar 13 menunjukkan bahwa selama 200 epoch pelatihan, model mengalami *overfitting*, terlihat dari penurunan drastis pada *training loss* yang mencapai kestabilan, sementara *validation loss* tetap tinggi tanpa perbaikan yang signifikan. Meskipun akurasi pelatihan terus meningkat, akurasi validasi stagnan pada tingkat rendah, yang menandakan model kesulitan untuk mengeneralisasi data validasi. Hal ini menunjukkan perlunya penyesuaian lebih lanjut seperti penerapan teknik regularisasi, seperti *dropout* atau *early stopping*, serta pengumpulan data pelatihan lebih banyak untuk meningkatkan kinerja model pada data yang belum dilihat.

2) Test Size 20%

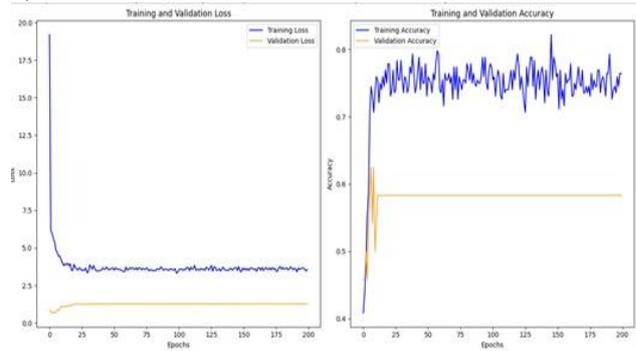


Gambar 14.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 200 Batch Size 16 Test Size 20%

Gambar 14 memperlihatkan bahwa selama 200 epoch pelatihan, model menunjukkan penurunan signifikan pada *training loss* dan peningkatan *training accuracy*, tetapi tidak diiringi peningkatan kinerja pada data validasi. *Validation loss* tetap tinggi dan akurasi validasi stagnan di angka rendah, menandakan bahwa model hanya belajar dari data pelatihan tanpa mampu mengeneralisasi ke data baru. Kondisi ini mencerminkan *overfitting*, dan untuk mengatasinya, bisa dipertimbangkan strategi seperti penambahan data, penggunaan regularisasi, atau penerapan *early stopping*.

3) Test Size 30%



Gambar 15.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 200 Batch Size 16 Test Size 30%

Gambar 15 memperlihatkan bahwa meskipun model mampu menurunkan *training loss* dan meningkatkan *training accuracy* dengan cepat di awal epoch, *validation loss* tetap tinggi dan *validation accuracy* tidak menunjukkan peningkatan berarti. Pola ini mengindikasikan bahwa model belajar terlalu fokus pada data pelatihan hingga kehilangan kemampuan untuk mengenali data baru—suatu kondisi *overfitting*. Untuk memperbaikinya, pendekatan seperti regularisasi, penambahan data, atau penyesuaian arsitektur model bisa dipertimbangkan agar performa validasi ikut membaik.

Tabel 6.

Classification Report model DGCNN epoch 200 BatchSize 16					
Train Size	Precis ion	Recall	F1	Supp ort	
10%	0.57	0.67	0.62	12	Pembunuhan
	0.67	0.57	0.62	14	Pemeriksaan
			0.62	26	Accuracy
	0.62	0.62	0.62	26	Macro Avg
	0.62	0.62	0.62	26	Weight Avg
20%	0.38	0.50	0.43	24	Pembunuhan
	0.40	0.29	0.33	28	Pemeriksaan
			0.38	52	Accuracy
	0.39	0.39	0.38	52	Macro Avg
	0.39	0.38	0.38	52	Weight Avg
30%	0.42	0.44	0.43	32	Pembunuhan
	0.60	0.59	0.59	46	Pemeriksaan
			0.53	78	Accuracy
	0.51	0.51	0.51	78	Macro Avg
	0.53	0.53	0.53	78	Weight Avg

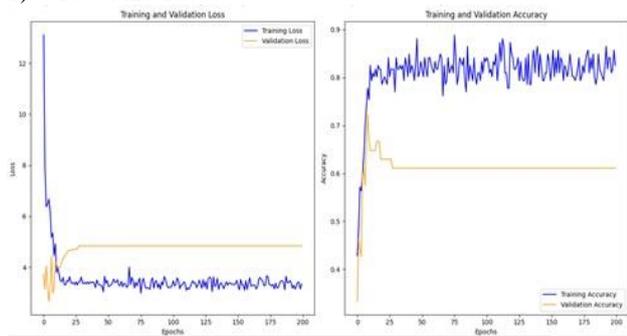
Tabel 6 menunjukkan bahwa model bekerja paling baik saat data uji hanya 10% dari keseluruhan, dengan akurasi mencapai 0,62 dan nilai *precision*, *recall*, serta *f1-score* yang seimbang. Saat porsi data uji ditingkatkan menjadi 20%, performa model turun tajam, mengindikasikan kesulitan dalam mengenali pola baru. Namun, pada *split* 30%, akurasi kembali naik ke angka 0,53. Secara

keseluruhan, *split* 10% memberikan hasil yang paling stabil dan akurat, membuatnya jadi opsi terbaik untuk menguji model ini.

c. Batch Size 32

Pengujian model *Deep Graph Convolutional Neural Networks* (DGCNN) dilakukan setelah pelatihan selama 200 *epoch* dengan *Batch Size* 32. Pada tahap ini, model diuji menggunakan data uji yang belum pernah dilihat sebelumnya untuk mengukur kemampuannya dalam mengklasifikasikan berita kriminal.

1) Test Size 10%

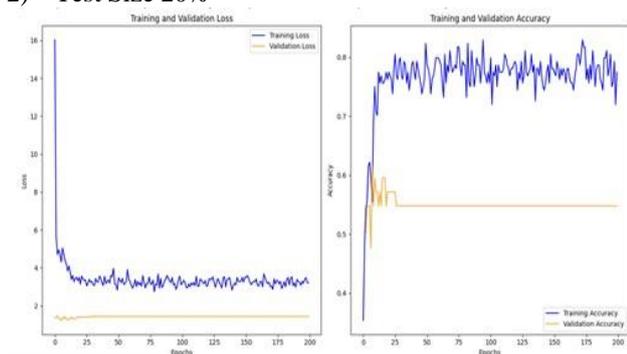


Gambar 16.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 200 Batch Size 32 Test Size 10%

Gambar 16 menunjukkan perbandingan antara *Training Loss* dan *Validation Loss* di sisi kiri, serta *Training Accuracy* dan *Validation Accuracy* di sisi kanan, selama proses pelatihan model. Di grafik *loss*, terlihat bahwa *Training Loss* menurun pesat di awal pelatihan dan stabil di angka rendah, sementara *Validation Loss* tetap tinggi dan datar, mengindikasikan adanya *overfitting*. Di grafik akurasi, *Training Accuracy* meningkat signifikan di awal, tetapi *Validation Accuracy* stagnan, semakin menegaskan bahwa model kesulitan menggeneralisasi pada data validasi. Untuk meningkatkan performa, perlu diterapkan teknik seperti *regularisasi*, *dropout*, atau *augmentasi data*.

2) Test Size 20%



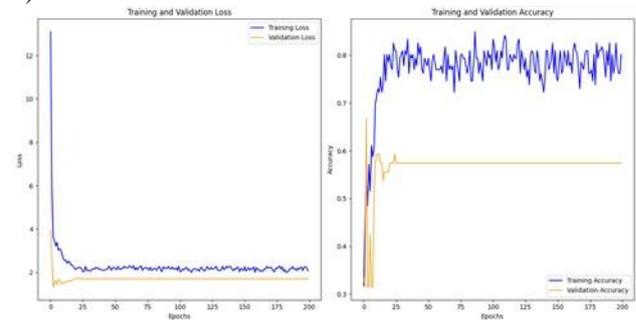
Gambar 17.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 200 Batch Size 32 Test Size 20%

Gambar 17 menunjukkan perkembangan model selama 200 *epoch*, dengan dua panel: *Training and Validation Loss* di kiri, serta *Training and Validation Accuracy* di kanan. Di panel kiri, *Training Loss* menurun pesat pada awal pelatihan dan stabil di nilai rendah setelah beberapa *epoch*, namun *Validation Loss* tetap tinggi dan datar, menunjukkan model terlalu terfokus pada data pelatihan dan kesulitan dalam memprediksi data validasi—sebuah indikasi *overfitting*. Pada panel kanan, *Training Accuracy* meningkat di awal tetapi stagnan setelahnya, sementara *Validation Accuracy* tetap rendah dan tidak menunjukkan

kemajuan. Untuk mengatasi hal ini, perlu dipertimbangkan strategi seperti *regularisasi*, *dropout*, atau *augmentasi data* untuk memperbaiki generalisasi model pada data validasi.

3) Test Size 30%



Gambar 18.

Grafik Training Accuray dan Loss dari Model DGCNN epoch 200 Batch Size 32 Test Size 30%

Gambar 18 menunjukkan hasil pelatihan model dari dua sisi: *Training and Validation Loss* di kiri, serta *Training and Validation Accuracy* di kanan. Pada grafik kiri, *Training Loss* menurun dengan cepat di awal pelatihan, menunjukkan bahwa model cepat mempelajari data pelatihan, lalu stabil di angka rendah. Namun, *Validation Loss* tetap lebih tinggi, menunjukkan kemungkinan *underfitting* atau masalah generalisasi. Di sisi kanan, *Training Accuracy* meningkat signifikan, namun fluktuasi besar terjadi, sementara *Validation Accuracy* stagnan di sekitar 0,5, menunjukkan model kesulitan untuk meningkatkan performa pada data validasi. Secara keseluruhan, hal ini mengindikasikan *gap* antara data pelatihan dan validasi, yang bisa disebabkan oleh faktor seperti kualitas data atau *overfitting*, dan memerlukan penyesuaian seperti *regularisasi*, *augmentasi data*, atau perbaikan model.

Tabel 7.

Classification Report model DGCNN epoch 200 BatchSize 32					
Train Size	Precision	Recall	F1	Support	
10%	0.67	0.83	0.74	12	Pembunuhan
	0.82	0.64	0.72	14	Pemeriksaan
			0.73	26	Accuracy
	0.74	0.74	0.73	26	Macro Avg
	0.75	0.73	0.73	26	Weight Avg
20%	0.67	0.83	0.74	24	Pembunuhan
	0.82	0.64	0.72	28	Pemeriksaan
			0.73	52	Accuracy
	0.74	0.74	0.73	52	Macro Avg
	0.75	0.73	0.73	52	Weight Avg
30%	0.67	0.83	0.74	32	Pembunuhan
	0.82	0.64	0.72	46	Pemeriksaan
			0.73	78	Accuracy
	0.74	0.74	0.73	78	Macro Avg
	0.75	0.73	0.73	78	Weight Avg

Tabel 7 menunjukkan hasil evaluasi model klasifikasi dengan *batch size* 32 pada tiga persentase data uji (TS-

10%, TS-20%, dan TS-30%). Model menunjukkan kinerja yang stabil di semua skenario, dengan akurasi konsisten sekitar 0,73. *Precision*, *recall*, dan *f1-score* untuk kelas "pembunuhan" dan "pemeriksaan" juga cukup tinggi, berada di kisaran 0,67–0,83 untuk *precision* dan *recall*, serta 0,72–0,74 untuk *f1-score*. Performa terbaik tercatat pada TS-10%, dengan nilai *f1-score* tertinggi (0,74) untuk kedua kelas, sementara metrik lainnya tetap konsisten. Secara keseluruhan, TS-10% terbukti menjadi pilihan terbaik karena memberikan hasil sedikit lebih baik untuk beberapa kelas penting.

B. Hasil Pengujian

Model DeepGraphCNN digunakan untuk menganalisis dataset dengan proses pelatihan yang mencakup 100 *epoch* dan berbagai ukuran data uji (10%, 20%, dan 30%).

Tabel 8.

Perbandingan Hasil Pengujian pada Berbagai Ukuran Data Uji

Ukuran Data Uji	Akurasi (%)	Precision	Recall	AUC
10%	69.23	0.75	0.68	0.70
20%	61.54	0.65	0.60	0.59
30%	56.41	0.58	0.55	0.53

Hasil menunjukkan bahwa akurasi tertinggi (69.23%) diperoleh dengan ukuran data uji 10%, sedangkan nilai AUC tertinggi (0.70) mencerminkan kemampuan model untuk membedakan antara kelas positif dan negatif pada dataset tersebut.

ROC curve menunjukkan nilai AUC sebesar 0.70 untuk data uji 10%, mengindikasikan performa model yang moderat dalam mengklasifikasikan berita kriminal.

IV. KESIMPULAN DAN SARAN

Kesimpulan dari penelitian ini menunjukkan bahwa pendekatan analisis berita kriminal berbasis graf menggunakan model DeepGraphCNN memberikan hasil yang signifikan, meskipun terdapat tantangan dalam hal generalisasi dan stabilitas model. Model ini mampu menangkap pola kompleks pada dataset yang berisi informasi entitas seperti pelaku, korban, dan lokasi, yang direpresentasikan dalam bentuk graf. Dengan akurasi tertinggi mencapai 69.23% pada ukuran data uji 10%, model menunjukkan potensi yang kuat dalam menangani tugas klasifikasi berita kriminal. Namun, terdapat indikasi *overfitting* yang ditandai dengan perbedaan besar antara *training* dan *validation loss/accuracy*, sehingga model belum sepenuhnya optimal dalam menangani data baru.

Penelitian ini berhasil menunjukkan bahwa analisis berbasis graf dapat menjadi pendekatan yang efektif untuk memahami hubungan antar elemen dalam berita kriminal. Selain itu, metrik evaluasi seperti *precision* dan *recall* menunjukkan bahwa model memiliki kemampuan awal yang baik dalam mengidentifikasi kelas target, meskipun masih ada ruang untuk perbaikan dalam performa keseluruhan.

Prospek pengembangan penelitian ini mencakup penerapan teknik regularisasi yang lebih kuat, seperti

dropout atau *weight decay*, untuk mengatasi *overfitting*. Selain itu, validasi silang (*cross-validation*) dapat digunakan untuk memastikan generalisasi model yang lebih baik. Prospek aplikasi penelitian ini mencakup pengembangan sistem deteksi kejahatan berbasis *real-time* yang dapat membantu penegakan hukum dalam mengidentifikasi pola kejahatan atau memprediksi area dengan tingkat kriminalitas tinggi. Dalam jangka panjang, pendekatan ini dapat diintegrasikan dengan teknologi lain, seperti pemrosesan bahasa alami atau analitik *big data*, untuk memberikan wawasan yang lebih mendalam dalam mendukung keamanan publik.

DAFTAR PUSTAKA

- [1] S. D. Y. Kusuma and H. Al Islami, "Teori dan Aplikasi Graph dalam Teknik Informatika," 2024.
- [2] L. Guillou, P. C. W. Hogendoorn, and F. T. Bosman, "Soft tissue sarcomas: introduction to the Virchows Archiv review issue.," *Virchows Arch. Int. J. Pathol.*, vol. 456, no. 2, pp. 107–109, Feb. 2010, doi: 10.1007/s00428-009-0875-y.
- [3] C. McGrath, "Highlight: New Solutions and Open Questions in Computational Evolutionary Biology.," *Genome Biol. Evol.*, vol. 11, no. 11, pp. 3179–3180, Nov. 2019, doi: 10.1093/gbe/evz237.
- [4] G. L. Hortin, S. A. Carr, and N. L. Anderson, "Introduction: Advances in protein analysis for the clinical laboratory.," *Clin. Chem.*, vol. 56, no. 2, pp. 149–151, Feb. 2010, doi: 10.1373/clinchem.2009.132803.
- [5] H. Bilfash, "Implementasi K-Means Berbasis Graph Untuk Pengelompokan Peneliti Pada Sistem Repositori Riset ITS," PhD Thesis, Institut Teknologi Sepuluh Nopember, 2016.
- [6] K. Mao, X. Xiao, J. Zhu, B. Lu, R. Tang, and X. He, "Item Tagging for Information Retrieval: A Tripartite Graph Neural Network based Approach," in *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, in SIGIR '20. New York, NY, USA: Association for Computing Machinery, 2020, pp. 2327–2336. doi: 10.1145/3397271.3401438.
- [7] C. Yang, "CrimeGAT: Leveraging Graph Attention Networks for Enhanced Predictive Policing in Criminal Networks." 2023. [Online]. Available: <https://arxiv.org/abs/2311.18641>