

**IDENTIFIKASI RELASI KORBAN DENGAN PELAKU TINDAK KEKERASAN
ANAK BERBASIS *TEXT CLASSIFICATION* MENGGUNAKAN *NEURAL
NETWORK***

SKRIPSI

Oleh :
EKA MIRA NOVITA SUBROTO
NIM. 210605110056



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**IDENTIFIKASI RELASI KORBAN DENGAN PELAKU TINDAK
KEKERASAN ANAK BERBASIS *TEXT CLASSIFICATION*
MENGUNAKAN *NEURAL NETWORK***

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh:
EKA MIRA NOVITA SUBROTO
NIM. 210605110056

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN

IDENTIFIKASI RELASI KORBAN DENGAN PELAKU TINDAK KEKERASAN ANAK BERBASIS *TEXT CLASSIFICATION* MENGUNAKAN *NEURAL NETWORK*


SKRIPSI

Oleh:
EKA MIRA NOVITA SUBROTO
NIM. 210605110056

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 5 Juni 2025


Pembimbing I,

Pembimbing II,


Dr. Cahyo Crysdian, M.Cs
NIP. 19740424 200901 1 008


Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

IDENTIFIKASI RELASI KORBAN DENGAN PELAKU TINDAK KEKERASAN ANAK BERBASIS *TEXT CLASSIFICATION* MENGUNAKAN *NEURAL NETWORK*

SKRIPSI

Oleh:

EKA MIRA NOVITA SUBROTO
NIM. 210605110056

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 16 Juni 2025



Susunan Dewan Penguji

Ketua Penguji : A'la Syauqi, M.Kom
NIP. 19771201 200801 1 007

Anggota Penguji I : Roro Inda Melani, M.T, M.Sc
NIP. 19780925 200501 2 008

Anggota Penguji II : Dr. Cahyo Crysdian, M.Cs
NIP. 19740424 200901 1 008


Anggota Penguji III : Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Eka Mira Novita Subroto
NIM : 210605110056
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Identifikasi Relasi Korban dengan Pelaku Tindak
Kekerasan Anak Berbasis *Text Classification*
Menggunakan *Neural Network*

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 16 Juni 2025
Yang membuat pernyataan,



Eka Mira Novita Subroto
NIM. 210605110056

MOTTO

“Rencana aja gak guna tanpa ada action, jadi mulai aja dulu”

“Manusia itu tugasnya berusaha dan berdoa, untuk hasil serahin semuanya sama Allah karena kadang menurutmu baik belum tentu baik menurut-Nya, begitupun sebaliknya”

“Man Jadda Wajada, Siapa yang bersungguh-sungguh pasti akan berhasil”

HALAMAN PERSEMBAHAN

Alhamdulillah rabbil 'alamin puji syukur kepada Allah SWT karena berkat rahmat dan petunjuk-Nya penulis dapat menyelesaikan skripsi ini. Shalawat serta salam selalu tercurahkan kepada Rasulullah SAW yang telah membawa kita dari zaman jahiliyah menuju addinul Islam.

Penulis mempersembahkan karya ini kepada diri penulis sendiri, orang tua, para dosen, kerabat, teman, sahabat, serta orang-orang yang telah membantu, mendoakan, serta menyemangati penulis dalam menuntaskan skripsi ini.

KATA PENGANTAR

Assalamualaikum warahmatullahi wabarakatuh

Puji syukur penulis anjatkan kepada Allah SWT yang telah melimpahkan nikmat serta karunia-Nya sehingga penulis mampu menyelesaikan penelitian skripsi yang berjudul “Identifikasi Relasi Korban dengan Pelaku Tindak Kekerasan Anak Berbasis *Text Classification* Menggunakan *Neural Network*” dengan baik dan tepat waktu. Dalam penulisan skripsi ini, penulis menyadari telah mendapat banyak bantuan, bimbingan, dan dukungan dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan terima kasih kepada:

1. Prof. Dr. H.M. Zainuddin, MA., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Prof. Dr. Sri Hariani, M.Si., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang
3. Dr. Ir. Fachrul Kurniawan, M.MT., IPU, selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Dr. Cahyo Crysdian, M.Cs selaku Dosen Pembimbing I yang telah membimbing dan memberikan arahan serta motivasi dalam proses penelitian dan penyusunan skripsi ini dari awal hingga selesai.
5. Dr. Zainal Abidin, M.Kom selaku Dosen Pembimbing II yang telah memberikan banyak dukungan dan bimbingan dalam penulisan skripsi ini.
6. A’la Syauqi, M.Kom selaku Ketua Penguji yang telah meluangkan waktunya untuk menguji dan memberikan arahan untuk menyelesaikan skripsi ini.

7. Roro Inda Melani, M.T, M.Sc selaku Dosen Penguji II yang telah meluangkan waktunya untuk menguji dan memberikan arahan serta masukan dalam penulisan skripsi ini.
8. Seluruh Dosen dan Jajaran Staf Program Studi Teknik Informatika yang telah memberikan banyak bantuan dalam skripsi ini
9. Kedua orang tua yang penulis sayangi, Bapak Subroto dan Ibu Herni yang selalu mendoakan, memberi dukungan, motivasi, materi, serta candaan sehingga penulis dapat melewati juga menyelesaikan pendidikan dan skripsi ini dengan perasaan bahagia.
10. Nenek penulis, Ibu Mutaslimah yang selalu mendoakan dan memberikan dukungan di setiap langkah penulis.
11. Dedek Nasywaa yang cuek tetapi selalu mendoakan dan menghibur penulis, menjadi sumber semangat tersendiri di tengah tekanan dan kelelahan selama proses penyusunan skripsi ini.
12. Radina Mutia Haira, sahabat karib dan teman seperjuangan penulis yang selalu ada dan saling membantu, mendukung, juga tak lupa menghibur dalam keadaan apapun termasuk dalam menuntaskan skripsi ini.
13. Sahabat-sahabat penulis, Vivin, Shafira, Heny, Tata, Marinda, dan Julfa yang selalu menyemangati, membantu, memberikan opini, dan mendoakan penulis.
14. Kak Fahrendra Khoirul Ihtada dan Kak Yoga Pratama yang telah membantu penulis memahami materi penulisan skripsi ini, saran-saran, dan semangat sehingga skripsi ini dapat selesai.

15. Teman-teman Angkatan 2021 Teknik Informatika "ASTER" yang telah memberikan dukungan, semangat, dan kebersamaan selama masa studi dan penyusunan skripsi ini.
16. Penulis sendiri yang telah berusaha dengan keras dalam memahami semua materi yang sebelumnya belum familiar hingga akhirnya menjadi paham dan mampu menyelesaikan skripsi ini.
17. Ima Madani, Tere Liye, dan penulis buku lainnya yang karyanya menemani penulis selama penulis mengerjakan skripsi ini, memberikan semangat dan motivasi melalui tulisan-tulisan mereka yang inspiratif.
18. Seluruh pihak dan teman-teman penulis lainnya yang tidak dapat penulis sebutkan satu persatu, yang secara tidak langsung juga turut serta memberikan kontribusi, saran, dan dukungan dalam pengerjaan skripsi ini.

Sebagai penutup, penulis mengakui bahwa skripsi ini masih terdapat banyak kekurangan. Penulis berharap bahwa skripsi ini dapat membawa manfaat bagi para pembaca dan tentunya penulis sendiri. *Aamiin yaa robbal 'alamin. Wassalamualaikum Warahmatullahi Wabarakatuh.*

Malang, 16 Juni 2025

Penulis

DAFTAR ISI

HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	xi
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL	xv
ABSTRAK	xvi
ABSTRACT	xvii
مستخلص البحث.....	xviii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Pernyataan Masalah	6
1.3 Tujuan Penelitian	6
1.4 Batasan Masalah.....	7
1.5 Manfaat Penelitian	7
BAB II STUDI PUSTAKA	8
2.1 Kasus Kekerasan Pada Anak.....	8
2.2 Penerapan <i>Machine Learning</i> dalam Analisis Kekerasan Pada Anak	9
2.3 Penggunaan <i>Neural Network</i> dalam Klasifikasi Teks.....	13
BAB III DESAIN DAN IMPLEMENTASI	15
3.1 Pengumpulan Data	15
3.2 Desain Sistem.....	16
3.2.1 <i>Data Cleaning</i>	16
3.2.2 <i>Text Preprocessing</i>	18
3.2.2.1 <i>Punctuation Removal</i>	18
3.2.2.2 <i>Case Folding</i>	19
3.2.2.3 <i>Tokenization</i>	20
3.2.2.4 <i>Stopword Removal</i>	20
3.2.2.5 <i>Stemming</i>	21
3.2.3 Ekstraksi Fitur <i>Word2Vec</i>	22
3.2.3.1 Alur <i>Neural Network Word2Vec</i>	25
3.2.3.2 Agregasi Vektor	31
3.2.4 <i>Neural Network</i>	33
3.2.4.1 Proses <i>Training Neural Network</i>	37
BAB IV UJI COBA DAN PEMBAHASAN	41
4.1 Skenario Pengujian.....	41

4.2 Hasil Uji Coba.....	46
4.2.1 Model X1	47
4.2.2 Model X2	49
4.2.3 Model X3	51
4.2.4 Model Y1	53
4.2.5 Model Y2	55
4.2.6 Model Y3	57
4.2.7 Model Z1.....	59
4.2.8 Model Z2.....	61
4.2.9 Model Z3.....	63
4.3 Pembahasan.....	65
BAB V KESIMPULAN DAN SARAN	78
5.1 Kesimpulan	78
5.2 Saran.....	78
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 1.1 Grafik Kasus Kekerasan Anak di Indonesia	2
Gambar 3.1 Desain Sistem.....	16
Gambar 3.2 Distribusi Data Setiap Kategori Pelaku Kekerasan Anak	17
Gambar 3.3 <i>Flowchart</i> Tahap <i>Data Cleaning</i>	17
Gambar 3.4 Diagram Alur Tahap <i>Text Preprocessing</i>	18
Gambar 3.5 <i>Flowchart</i> Tahap <i>Punctuation Removal</i>	19
Gambar 3.6 <i>Flowchart</i> Tahap <i>Case Folding</i>	19
Gambar 3.7 <i>Flowchart</i> Tahap <i>Tokenization</i>	20
Gambar 3.8 <i>Flowchart</i> Tahap <i>Stopword Removal</i>	21
Gambar 3.9 <i>Flowchart</i> Tahap <i>Stemming</i>	21
Gambar 3.10 Arsitektur <i>WordVec</i> Model <i>Skip-Gram</i>	24
Gambar 3.11 Arsitektur <i>Neural Network Word2Vec</i> Model <i>Skip-Gram</i>	25
Gambar 3.12 <i>Flowchart Neural Network</i> pada Model <i>Skip-Gram</i>	29
Gambar 3.13 Grafik <i>Loss</i> Proses <i>Training Word2vec Skip-Gram</i>	30
Gambar 3.14 <i>t-SNE Plot</i> untuk 100 Kata dengan Frekuensi Tertinggi.....	33
Gambar 3.15 Arsitektur <i>Neural Network</i>	34
Gambar 3.16 <i>Flowchart</i> Proses <i>Neural Network</i>	40
Gambar 4.1 Grafik <i>Loss</i> dan <i>Accuracy (Training & Validation)</i> Model X1	47
Gambar 4.2 <i>Confusion Matrix</i> Model X1	47
Gambar 4.3 <i>Accuracy, Precision, Recall, dan F1-Score</i> Model X1	48
Gambar 4.4 <i>Accuracy</i> Setiap <i>Fold</i> Model X1	48
Gambar 4.5 Grafik <i>Loss</i> dan <i>Accuracy (Training & Validation)</i> Model X2	49
Gambar 4.6 <i>Confusion Matrix</i> Model X2	49
Gambar 4.7 <i>Accuracy, Precision, Recall, dan F1-Score</i> Model X2	50
Gambar 4.8 <i>Accuracy</i> Setiap <i>Fold</i> Model X2.....	50
Gambar 4.9 Grafik <i>Loss</i> dan <i>Accuracy (Training & Validation)</i> Model X3	51
Gambar 4.10 <i>Confusion Matrix</i> Model X3	51
Gambar 4.11 <i>Accuracy, Precision, Recall, dan F1-Score</i> Model X3	52
Gambar 4.12 <i>Accuracy</i> Setiap <i>Fold</i> Model X3	52
Gambar 4.13 Grafik <i>Loss</i> dan <i>Accuracy (Training & Validation)</i> Model Y1	53
Gambar 4.14 <i>Confusion Matrix</i> Model Y1	53
Gambar 4.15 <i>Accuracy, Precision, Recall, dan F1-Score</i> Model Y1	54
Gambar 4.16 <i>Accuracy</i> Setiap <i>Fold</i> Model Y1	54
Gambar 4.17 Grafik <i>Loss</i> dan <i>Accuracy (Training & Validation)</i> Model Y2	55
Gambar 4.18 <i>Confusion Matrix</i> Model Y2	55
Gambar 4.19 <i>Accuracy, Precision, Recall, dan F1-Score</i> Model Y2	56
Gambar 4.20 <i>Accuracy</i> Setiap <i>Fold</i> Model Y2.....	56
Gambar 4.21 Grafik <i>Loss</i> dan <i>Accuracy (Training & Validation)</i> Model Y3	57
Gambar 4.22 <i>Confusion Matrix</i> Model Y3	57
Gambar 4.23 <i>Accuracy, Precision, Recall, dan F1-Score</i> Model Y3	58

Gambar 4.24 <i>Accuracy</i> Setiap <i>Fold</i> Model Y3	58
Gambar 4.25 Grafik <i>Loss</i> dan <i>Accuracy</i> (<i>Training & Validation</i>) Model Z1.....	59
Gambar 4.26 <i>Confusion Matrix</i> Model Z1.....	59
Gambar 4.27 <i>Accuracy</i> , <i>Precision</i> , <i>Recall</i> , dan <i>F1-Score</i> Model Z1.....	60
Gambar 4.28 <i>Accuracy</i> Setiap <i>Fold</i> Model Z1	60
Gambar 4.29 Grafik <i>Loss</i> dan <i>Accuracy</i> (<i>Training & Validation</i>) Model Z2.....	61
Gambar 4.30 <i>Confusion Matrix</i> Model Z2.....	61
Gambar 4.31 <i>Accuracy</i> , <i>Precision</i> , <i>Recall</i> , dan <i>F1-Score</i> Model Z2.....	62
Gambar 4.32 <i>Accuracy</i> Setiap <i>Fold</i> Model Z2	62
Gambar 4.33 Grafik <i>Loss</i> dan <i>Accuracy</i> (<i>Training & Validation</i>) Model Z3.....	63
Gambar 4.34 <i>Confusion Matrix</i> Model Z3.....	63
Gambar 4.35 <i>Accuracy</i> , <i>Precision</i> , <i>Recall</i> , dan <i>F1-Score</i> Model Z3.....	64
Gambar 4.36 <i>Accuracy</i> Setiap <i>Fold</i> Model Z3	64
Gambar 4.37 <i>Wordcloud</i> Kelas Keluarga	71
Gambar 4.38 <i>Wordcloud</i> Kelas Pengasuh.....	72
Gambar 4.39 <i>Wordcloud</i> Kelas Tenaga Pendidik	72
Gambar 4.40 <i>Wordcloud</i> Kelas Teman.....	73
Gambar 4.41 <i>Wordcloud</i> Kelas Tenaga Orang Asing.....	73

DAFTAR TABEL

Tabel 2.1 Penerapan <i>Machine Learning</i> dalam Analisis Kekerasan Pada Anak ..	12
Tabel 3.1 Dataset Berita Kekerasan Anak	15
Tabel 3.2 Hasil Proses <i>Data Cleaning</i>	18
Tabel 3.3 Hasil Tahap <i>Text Preprocessing</i>	22
Tabel 3.4 Hasil Vektor Embedding.....	31
Tabel 3.5 Hasil Agregasi Vektor.....	32
Tabel 3.6 Jumlah <i>Layer</i> , <i>Node</i> , dan Fungsi Aktivasi Model <i>Neural Network</i>	35
Tabel 4.1 Skenario Pengujian	42
Tabel 4.2 <i>Confusion Matrix</i>	44
Tabel 4.3 <i>Confusion Matrix</i> Kelas Keluarga.....	44
Tabel 4.4 <i>Confusion Matrix</i> Kelas Pengasuh.....	44
Tabel 4.5 <i>Confusion Matrix</i> Kelas Tenaga Pendidik	45
Tabel 4.6 <i>Confusion Matrix</i> Kelas Teman	45
Tabel 4.7 <i>Confusion Matrix</i> Kelas Orang Asing.....	45
Tabel 4.8 Hasil Proses <i>Training</i>	65
Tabel 4.9 Hasil Proses <i>Testing</i>	67
Tabel 4.10 Hasil <i>K-Fold Cross Validation</i>	69

ABSTRAK

Subroto, Eka Mira Novita. 2025. **Identifikasi Relasi Korban dengan Pelaku Tindak Kekerasan Anak Berbasis *Text Classification* Menggunakan *Neural Network***. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Cahyo Crys dian, M.Cs (II) Dr. Zainal Abidin, M.Kom.

Kata kunci: Kekerasan Anak, Klasifikasi Teks, *Neural Network*.

Kasus kekerasan terhadap anak di Indonesia terus mengalami peningkatan setiap tahunnya dengan mayoritas pelaku berasal dari lingkungan terdekat korban. Permasalahan ini merupakan isu serius karena berdampak jangka panjang terhadap perkembangan fisik, psikologis, sosial, dan emosional anak, serta dapat mengganggu kualitas hidup anak di masa depan. Berita *online* banyak memuat informasi terkait kasus-kasus tersebut sehingga dapat dimanfaatkan untuk mengidentifikasi pola hubungan antara pelaku dan korban kekerasan anak. Penelitian ini bertujuan untuk mengidentifikasi relasi antara pelaku dan korban kekerasan anak dengan mengklasifikasikan berita kekerasan anak berdasarkan pelaku menggunakan *neural network*. Data diklasifikasikan ke dalam lima kategori pelaku: keluarga, pengasuh, tenaga pendidik, teman, dan orang asing. Proses penelitian dimulai dari *data cleaning* yang menghasilkan 975 data, dilanjutkan dengan *text preprocessing*, ekstraksi fitur menggunakan Word2Vec model *skip-gram*, dan klasifikasi menggunakan *neural network*. Sembilan model diuji berdasarkan variasi jumlah *node* pada *hidden layer* pertama (10, 30, 60) serta *learning rate* (0,001, 0,005, 0,01). Model Z2 dengan *node hidden layer* pertama sebanyak 60 dan *learning rate* sebesar 0,005 menunjukkan performa terbaik dengan akurasi 80,61% dan *F1-score* 68,94% pada tahap *testing*, serta rata-rata akurasi tertinggi sebesar 82,98% dan standar deviasi terendah yaitu 0,0306 pada uji *k-fold cross validation*. Peningkatan jumlah *node* pada *hidden layer* pertama mempercepat konvergensi dan meningkatkan akurasi, sementara *learning rate* 0,005 menghasilkan performa paling stabil. Meskipun sebagian model menunjukkan gejala *overfitting*, metode *neural network* terbukti efektif dan andal dalam mengklasifikasikan relasi pelaku dan korban kekerasan anak berbasis teks berita *online* yang ditunjukkan oleh rentang akurasi seluruh model sebesar 75,5–82,6% dan *F1-score* 62,6–72,6%. Sistem klasifikasi ini berpotensi mendukung upaya pencegahan yang lebih tepat sasaran.

ABSTRACT

Subroto, Eka Mira Novita. 2025. **Identifying the Relationship Between Victims and Perpetrators of Child Abuse Based on Text Classification Using Neural Networks**. Undergraduate Thesis. Department of Informatics Engineering Faculty of Science and Technology Maulana Malik Ibrahim State Islamic University Malang. Supervisor: (I) Dr. Cahyo Crysdian, M.Cs (II) Dr. Zainal Abidin, M.Kom.

Keywords: Child Abuse, Text Classification, Neural Network.

Cases of violence against children in Indonesia continue to increase every year, with the majority of perpetrators coming from the victim's immediate environment. This problem is a serious issue because it has a long-term impact on children's physical, psychological, social, and emotional development and can interfere with children's quality of life in the future. Online news contains a lot of information related to these cases so that it can be used to identify patterns of relationships between perpetrators and victims of child abuse. This study aims to determine the relationship between perpetrators and victims of child abuse by classifying child abuse news based on perpetrators using neural networks. The data is classified into five perpetrator categories: family, caregivers, educators, friends, and strangers. The research process starts with data cleaning, which produces 975 data, followed by text preprocessing, feature extraction using the Word2Vec skip-gram model, and classification using a neural network. Nine models were tested based on variations in the number of nodes in the first hidden layer (10, 30, and 60) and learning rate (0.001, 0.005, and 0.01). Model Z2, with the first hidden layer node of 60 and a learning rate of 0.005, showed the best performance with an accuracy of 80.61% and an F1-score of 68.94% on the testing, as well as the highest average accuracy of 82.98% and the lowest standard deviation of 0.0306 on the k-fold cross validation test. Increasing the number of nodes in the first hidden layer accelerated convergence and improved accuracy, while a learning rate of 0.005 produced the most stable performance. Although some models showed symptoms of overfitting, the neural network method proved to be effective and reliable in classifying the relationship between perpetrators and victims of online news text-based child abuse, as shown by the accuracy range of all models of 75.5-82.6% and F1-score of 62.6-72.6%. This classification system has the potential to support more targeted This classification system has the potential to help more targeted child abuse prevention strategies.

مستخلص البحث

سوبوتو، إيكاميرا نوفيتا. 2025. تحديد العلاقة بين ضحايا ومرتكبي العنف ضد الأطفال بناءً على تصنيف النصوص باستخدام الشبكة العصبية. الأطروحة. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: د. جاهيو كريسديان، الماجستير. المشرف الثاني: د. زين العابدين، الماجستير.

الكلمات الرئيسية: إساءة معاملة الأطفال، التصنيف النصوص، الشبكة العصبية.

لا تزال حالات العنف ضد الأطفال في إندونيسيا في ازدياد كل عام، وغالبية الجناة من البيئة المباشرة للضحية. وتعد هذه المشكلة مشكلة خطيرة لأن لها تأثيراً طويلاً الأمد على نمو الأطفال الجسدي والنفسي والاجتماعي والعاطفي ويمكن أن تؤثر على نوعية حياة الأطفال في المستقبل. تحتوي الأخبار المنشورة على الإنترنت على الكثير من المعلومات المتعلقة بهذه الحالات بحيث يمكن استخدامها لتحديد أنماط العلاقات بين الجناة وضحايا إساءة معاملة الأطفال. تهدف هذه الدراسة إلى تحديد العلاقة بين الجناة وضحايا الاعتداء على الأطفال من خلال تصنيف أخبار الاعتداء على الأطفال بناءً على الجناة باستخدام الشبكات العصبية. تم تصنيف البيانات إلى خمس فئات من الجناة: الأسرة ومقدمي الرعاية والمربين والأصدقاء والغرباء. تبدأ عملية البحث بتنظيف البيانات، والتي تنتج 975 بياناً، تليها المعالجة المسبقة للنص، واستخراج السمات باستخدام نموذج Word2Vec لتخطي الجرام، والتصنيف باستخدام شبكة عصبية. تم اختبار تسعة نماذج بناءً على الاختلافات في عدد العُقد في الطبقة المخفية الأولى (10 و30 و60) ومعدل التعلم (0.001 و0.005 و0.01). أظهر النموذج Z2، مع عقدة الطبقة المخفية الأولى 60 ومعدل تعلم 0.005، أفضل أداء مع دقة بلغت 80.61% ودرجة F1 بلغت 68.94% في الاختبار، بالإضافة إلى أعلى متوسط دقة بلغت 82.98% وأقل انحراف معياري بلغ 0.0306 في اختبار التحقق التبادلي k-fold. أدت زيادة عدد العُقد في الطبقة المخفية الأولى إلى تسريع التقارب وتحسين الدقة، في حين أن معدل التعلم البالغ 0.005 أنتج الأداء الأكثر استقراراً. على الرغم من أن بعض النماذج أظهرت أعراض الإفراط في الملاءمة، إلا أن طريقة الشبكة العصبية أثبتت فعاليتها وموثوقيتها في تصنيف العلاقة بين الجناة والضحايا في الأخبار النصية على الإنترنت التي تستند إلى إساءة معاملة الأطفال عبر الإنترنت، كما يتضح من نطاق دقة جميع النماذج الذي يتراوح بين 75.5 و82.6% ودرجة F1 التي تتراوح بين 62.6 و72.6%. هذا النظام التصنيفي لديه القدرة على دعم استراتيجيات أكثر استهدافاً لهذا النظام التصنيفي لديه القدرة على المساعدة في وضع استراتيجيات أكثر استهدافاً لمنع الاعتداء على الأطفال.


BAB I

PENDAHULUAN

1.1 Latar Belakang

Kekerasan terhadap anak di Indonesia telah menjadi permasalahan serius dan memerlukan perhatian khusus. Kekerasan terhadap anak dapat mengakibatkan dampak yang luas tidak hanya fisik saja, tetapi memengaruhi psikologis, sosial, dan perilaku. Anak-anak yang mengalami kekerasan cenderung memiliki kepribadian yang tidak stabil, agresif, dan mudah marah, bahkan berpotensi mengulangi tindakan serupa. Selain itu, dari segi sosial, anak yang menjadi korban kekerasan kerap mengalami kesulitan dalam berinteraksi dan tak jarang membuat mereka terjebak dalam pergaulan negatif (Kurniasari, 2019).

Data dari Sistem Informasi Online Perlindungan Perempuan dan Anak (SIMFONI-PPA) menunjukkan bahwa kasus kekerasan anak terus meningkat secara signifikan dalam lima tahun terakhir dengan mayoritas korban adalah perempuan (SIMFONI-PPA, 2024). Pada tahun 2021, kasus kekerasan terhadap anak mengalami kenaikan yang cukup tinggi sebesar 28,24% dibandingkan tahun 2020. Kemudian, pada tahun 2022 kasus terus melonjak mencapai 11,49%. Tren ini berlanjut dengan penambahan kasus sebesar 12,84% di tahun 2023 dan 7,99% di tahun 2024. Kenaikan kasus kekerasan anak ini mengindikasikan bahwa upaya untuk mencegah dan menangani kekerasan anak masih perlu ditingkatkan.



Gambar 1.1 Grafik Kasus Kekerasan Anak di Indonesia

Pola pengasuhan yang tidak tepat dapat menjadi faktor penyumbang terjadinya kekerasan anak, seperti penggunaan kekerasan dalam mendidik, kurangnya komunikasi, serta lemahnya penanaman nilai moral dan spiritual dalam keluarga. Islam telah memberikan panduan yang jelas bagaimana mengasuh dan mendidik anak. Al-Quran memberikan teladan mendalam melalui nasihat Luqman kepada anaknya dalam QS. Luqman ayat 16 – 18 yang berbunyi:

يٰٓبُنَيَّ اِنَّمَا اِنْ تَكُ مِثْقَالَ حَبَّةٍ مِّنْ خَرْدَلٍ فَتَكُنْ فِيْ صَحْرَةٍ اَوْ فِي السَّمٰوٰتِ اَوْ فِي الْاَرْضِ يٰٓاْتِ بِهَا اللّٰهُ اِنَّ اللّٰهَ لَطِيْفٌ خَبِيْرٌ ﴿١٦﴾ يٰٓبُنَيَّ اَقِمِ الصَّلٰوةَ وَاْمُرْ بِالْمَعْرُوْفِ وَانْهَ عَنِ الْمُنْكَرِ وَاَصْبِرْ عَلٰى مَا اَصَابَكَ اِنَّ ذٰلِكَ مِنْ عَزْمِ الْاُمُوْر ﴿١٧﴾ وَلَا تُصَعِّرْ خَدَّكَ لِلنَّاسِ وَلَا تَمْشِ فِي الْاَرْضِ مَرَحًا اِنَّ اللّٰهَ لَا يُحِبُّ كُلَّ مُخْتَالٍ فَخُوْرٍ ﴿١٨﴾

"(Luqman berkata,) "Wahai anak-ku! Sungguh jika ada (suatu perbuatan) seberat biji sawi, dan berada dalam batu atau di langit, atau di bumi, niscaya Allah akan memberinya (balasan). Sesungguhnya Allah Mahahalus lagi Mahateliti. Wahai anakku! Laksanakanlah salat dan suruhlah (manusia) berbuat yang makruf dan cegahlah (mereka) dari yang mungkar serta bersabarlah terhadap apa yang menimpamu, sesungguhnya yang demikian itu termasuk perkara yang penting. Dan janganlah kamu memalingkan wajah dari manusia (karena sombong) dan janganlah berjalan di bumi dengan angkuh. Sungguh, Allah tidak menyukai orang-orang yang sombong dan membanggakan diri. " (Q.S Luqman: 16 – 18) (Baihaqi et al., 2015).

Menurut tafsir Al-Misbah pada ayat 16-18 berisi nasihat Luqman yang mencakup akidah, syariat, dan akhlak yang merupakan tiga unsur ajaran dalam Al-Quran. Ayat 16, Luqman menanamkan kesadaran mengenai pentingnya kejujuran bahwa sekecil apa pun perbuatan akan diketahui dan dibalas oleh Allah SWT (Shihab, 2002a). Ibnu Katsir menjelaskan bahwa Allah Mahahalus artinya tidak ada segala sesuatu pun yang tersembunyi darinya sekalipun kecil, halus, dan lembut. Pada ayat 17, Luqman memanggil anaknya dengan mesra dan menasihatnya untuk menegakkan sholat, serta amal-amal kebajikan yang tercermin dalam *amr ma'ruf nahi mungkar* juga nasihat untuk sabar dan tabah (Al-Syeikh, 2004b). Sementara itu, ayat 18 berkaitan dengan akhlak dan sopan santun dengan sesama manusia. Ketiga ayat ini mencerminkan pola asuh Luqman yang menanamkan tanggung jawab, kepedulian sosial, dan kerendahan hati sebagai bagian dari karakter seorang mukmin.

Pemerintah telah melakukan berbagai upaya dalam menangani kasus kekerasan terhadap anak, mulai dari penetapan Stranas PKTA, pengembangan program Kabupaten/Kota Layak Anak (KLA), Sekolah Ramah Anak (SKA), hingga layanan konseling melalui Pusat Pembelajaran Keluarga (PUSPAGA) dan Perlindungan Anak Terpadu Berbasis Masyarakat (PATBM) di tingkat desa hingga kabupaten/kota. Namun, penanganan akan lebih optimal jika mempertimbangkan karakteristik tiap kasus, khususnya dalam mengidentifikasi hubungan pelaku dan korban yang penting dalam memahami pola kekerasan dan langkah pencegahan yang tepat. Penelitian Humaira B et al (2015) menunjukkan bahwa mayoritas kekerasan seksual pada anak dilakukan oleh pelaku yang dikenal korban, seperti

teman, guru, hingga anggota keluarga dengan modus bujukan atau ancaman. Temuan ini menegaskan perlunya penanganan yang lebih spesifik berdasarkan relasi pelaku dan korban agar pencegahan dan penanganan dapat lebih tepat sasaran.

Media *online* menjadi sarana utama dalam menyebarkan informasi terkini dan aktual kepada masyarakat luas, tak terkecuali penyebaran berita terkait kekerasan pada anak. Beberapa portal berita seperti Detik, TribunNews, CNN, Kompas, dan Republika menyediakan akses cepat dan mudah bagi masyarakat dalam mendapatkan informasi terkini. Selain itu, berita *online* juga berperan dalam membentuk kesadaran publik, membangun empati, serta menarik perhatian terhadap isu-isu sosial, termasuk kekerasan anak (Arpandi, 2023).

Pengklasifikasian berita kekerasan anak berdasarkan pelaku merupakan langkah strategis dalam upaya mengidentifikasi hubungan antara korban dan pelaku tindak kekerasan anak, sehingga memberikan pemahaman yang lebih jelas mengenai pola kekerasan yang terjadi. Namun, proses klasifikasi yang dilakukan secara manual akan memakan waktu lama, rentan terhadap kesalahan, dan kurang efisien mengingat terus bertambahnya jumlah berita. Oleh karena itu, diperlukan sistem klasifikasi yang mampu mengidentifikasi pelaku dengan cepat dan akurat.

Text classification menggunakan metode *neural network* merupakan salah satu pendekatan yang dapat dilakukan untuk mengklasifikasikan pelaku kekerasan berdasarkan berita *online*. Metode ini memungkinkan analisis terhadap kumpulan berita guna mengekstrak informasi yang relevan secara cepat dan akurat. Penelitian sebelumnya oleh Zaghloul et al (2009) menunjukkan bahwa *neural network* mampu memberikan performa yang setara dengan *Support Vector Machines* (SVM),

bahkan lebih efisien dalam menangani dokumen pendek seperti abstrak. Sementara itu, Tripathi et al (2019) mengonfirmasi efektivitas *neural network* melalui kombinasi antara *n-fold cross-validation* dan metode *training-validation-test*, dengan *Bag of Words* (BoW) dapat meningkatkan akurasi klasifikasi. Hasil penelitian tersebut menunjukkan bahwa *neural network* mampu menangkap pola tersembunyi dalam data teks dan menghasilkan klasifikasi lebih baik. Dengan demikian, sistem klasifikasi pelaku kekerasan anak menggunakan *neural network* dari berita *online* dapat menjadi alat bantu yang efektif untuk membantu pemerintah dalam pencegahan dan penanganan kekerasan anak secara lebih efektif.

Konsep klasifikasi ini sejalan dengan firman Allah SWT yang menekankan pentingnya keberagaman untuk saling mengenal dalam QS. Al-Hujurat ayat 13 yang berbunyi:

يَا أَيُّهَا النَّاسُ إِنَّا خَلَقْنَاكُمْ مِنْ ذَكَرٍ وَأُنْثَىٰ وَجَعَلْنَاكُمْ شُعُوبًا وَقَبَائِلَ لِتَعَارَفُوا إِنَّ أَكْرَمَكُمْ عِنْدَ اللَّهِ أَتْقَاهُمْ إِنَّ اللَّهَ عَلِيمٌ
 خَبِيرٌ ﴿١٣﴾

"Wahai manusia! Sungguh, Kami telah menciptakan kamu dari seorang laki-laki dan seorang Perempuan, kemudian Kami jadikan kamu berbangsa-bangsa dan bersuku-suku agar kamu saling mengenal. Sungguh yang paling mulia di antara kamu di sisi Allah ialah orang yang paling bertakwa. Sungguh Allah Maha Mengetahui, Mahateliti" (Q.S Al-Hujurat: 13) (Baihaqi et al., 2015).

Ibnu Katsir menjelaskan bahwa Allah memberitahukan telah menciptakan manusia dari satu jiwa dan menjadikan pasangannya Adam dan Hawa. Dari keduanya lahirlah manusia-manusia yang kemudian berkembang menjadi berbangsa-bangsa dan bersuku-suku yang kedudukannya bertingkat-tingkat sesuai dengan ketinggian ketakwaan kepada Allah (Al-Syeikh, 2004c). Tafsir Al-Misbah

menegaskan bahwa kualitas ketakwaan dan keimanan seseorang hanya dapat diketahui oleh Allah dan tidak dapat dilihat oleh manusia (Shihab, 2002b). Adapun dalam Tafsir Kementerian Agama RI dijelaskan bahwa keberagaman bangsa dan suku bertujuan agar manusia saling mengenal, bekerja sama, bukan saling merendahkan atau bermusuhan. Nilai kemuliaan bukan diukur dari garis keturunan, kekayaan, atau status sosial, melainkan dari ketakwaan sejati (Kemenag, 2022).

Konsep keberagaman yang dijelaskan dalam ayat tersebut sejalan dengan prinsip klasifikasi, yaitu proses pengelompokan berdasarkan karakteristik yang membedakan setiap kategori. Klasifikasi pelaku kekerasan anak melalui berita *online* bertujuan untuk mengidentifikasi perbedaan relasi antara pelaku dan korban. Sebagaimana manusia diciptakan beragam agar saling mengenal, maka melalui klasifikasi sistem dapat mengenali pola-pola hubungan yang berbeda dalam teks berita. Dengan memahami pola-pola ini, sistem klasifikasi berbasis *neural network* dapat membantu mengungkap hubungan yang tersembunyi dalam teks berita, memberikan wawasan yang lebih dalam terhadap pola kekerasan anak, dan mendukung upaya pencegahan secara lebih tepat sasaran.

1.2 Pernyataan Masalah

Seberapa baik performa metode *neural network* dalam mengidentifikasi relasi korban dengan pelaku tindak kekerasan anak berdasarkan berita *online*?

1.3 Tujuan Penelitian

Mengukur seberapa baik performa metode *neural network* dalam mengidentifikasi relasi korban dengan pelaku tindak kekerasan anak berdasarkan berita *online*.

1.4 Batasan Masalah

- a. Sumber data pada penelitian ini berasal dari berita *online* Indonesia, seperti Detik, CNN, TribunNews, Kompas, dan Republika yang hanya terkait dengan berita kekerasan anak dari Januari 2023 hingga September 2024.
- b. Penelitian ini terbatas hanya menggunakan bahasa Indonesia.

1.5 Manfaat Penelitian

- a. Bagi pemerintah dan penegak hukum, penelitian ini membantu mereka merumuskan kebijakan dan strategi yang lebih efektif dalam menangani kasus kekerasan anak serta memungkinkan penegak hukum fokus pada tindakan preventif yang lebih tepat sasaran.
- b. Bagi lembaga penanganan kasus kekerasan anak, membantu lembaga merencanakan penanganan yang lebih efektif dengan berfokus pada rehabilitasi anak-anak korban dan menyediakan bantuan psikologis serta sosial yang diperlukan.
- c. Bagi masyarakat, membantu meningkatkan kesadaran mereka tentang perlindungan anak dari kekerasan dan mendorong partisipasi aktif dalam menciptakan lingkungan yang aman dan nyaman bagi anak-anak.

BAB II

STUDI PUSTAKA

2.1 Kasus Kekerasan Pada Anak

Menurut Undang-Undang Nomor 35 Tahun 2014 kekerasan terhadap anak adalah setiap perbuatan terhadap anak yang berakibat timbulnya kesengsaraan, atau penderitaan secara fisik, psikis, seksual, dan penelantaran, termasuk ancaman untuk melakukan perbuatan, pemaksaan, atau perampasan kemerdekaan melawan hukum. Selain itu, anak yang dimaksud dijelaskan dalam Pasal 1 didefinisikan sebagai seseorang yang berusia di bawah 18 tahun termasuk yang masih dalam kandungan.

Pada tahun 2023, KPAI mencatat terdapat 1800 pengaduan kasus kekerasan anak di dua kategori, yaitu Pemenuhan Hak Anak (PHA) dan Perlindungan Khusus Anak (PKA). PHA memiliki jumlah laporan yang lebih tinggi sebesar 68,7% atau 1237 kasus, sedangkan PKA memiliki jumlah laporan yang lebih rendah sebesar 563 kasus dimana pulau Jawa menjadi pulau yang persebaran korbannya paling banyak (KPAI, 2023b). Selain itu, KPAI mencatat terdapat 110 pemberitaan di media cetak dan 802 berita di media *online* yang berkaitan dengan kasus kekerasan anak. Hal tersebut menunjukkan bahwa media *online* memegang peranan penting dalam penyebaran berita terkait kekerasan anak (KPAI, 2023a).

Gamayanti mengklasifikasikan bentuk kekerasan terhadap anak menjadi tiga kategori, yaitu berupa kekerasan fisik, emosi, dan seksual (Tasya, 2024). Kekerasan pada anak dapat terjadi di mana saja terutama di lingkungan sekitar bahkan paling mungkin dilakukan oleh orang tua mereka sendiri di lingkungan keluarga (Wahyudi & Kushartono, 2020). Kekerasan pada anak berdampak sangat

luas, mencakup aspek fisik, psikologis, sosial, dan perilaku. Secara fisik, anak-anak yang menjadi korban kekerasan berisiko mengalami cedera serius, gizi buruk, hingga gangguan kognitif. Sementara itu, dari segi psikologis, kekerasan dapat menyebabkan anak menjadi agresif, apatis dan sulit untuk bersosialisasi. Bahkan kekerasan yang cukup parah mengakibatkan traumatis hingga PTSD (*Post Traumatic Stress Disorder*) (Utama et al., 2020). Dampak kekerasan di atas tentunya mempengaruhi masa depan anak salah satunya anak sulit untuk mengeluarkan potensi yang mereka miliki.

2.2 Penerapan *Machine Learning* dalam Analisis Kekerasan Pada Anak

Seiring dengan meningkatnya kasus kekerasan terhadap anak, banyak peneliti yang menerapkan algoritma *machine learning* untuk mengidentifikasi, mengklasifikasikan, serta mendukung upaya pencegahan dan penanganan kasus kekerasan anak. Penerapan ini bertujuan untuk membantu dalam pengambilan keputusan, mempercepat proses deteksi kasus, serta memberikan wawasan lebih mendalam guna merancang strategi perlindungan yang lebih efektif bagi anak-anak.

Penggunaan algoritma *Artificial Neural Network* (ANN) pernah dilakukan untuk mengeksplorasi potensi ANN sebagai alat bantu penilaian risiko dalam kasus dugaan kekerasan anak berdasarkan data dari *The Third National Incidence Study of Child Abuse and Neglect (NIS-3)* dengan mengembangkan berbagai arsitektur jaringan saraf *multilayer* (MLNN). Model 31-25-1 MLNN adalah model terbaik yang mencapai akurasi hingga 90% dalam mengklasifikasi kasus kekerasan (Zandi, 2001). Penelitian lain juga dilakukan dengan menggunakan data dari pusat registrasi Angkatan Udara Amerika Serikat terkait laporan kekerasan fisik anak

selama tahun 1990–2000 sebanyak 5.612 kasus. Dengan menggunakan 13 variabel prediktor dan 5 variabel interaksi, penelitian ini membangun dan melatih model ANN untuk memprediksi kemungkinan kekerasan fisik anak terulang kembali (Flaherty & Patterson, 2003).

Penelitian kekerasan anak terbaru dengan algoritma lain juga dilakukan salah satunya oleh Subroto et al (2022) yang melakukan penelitian menggunakan algoritma *Multinomial Naïve Bayes* untuk mengklasifikasi jenis kekerasan pada perempuan dan anak. Terdapat empat belas kategori pengklasifikasian, yaitu KDRT, pelecehan seksual, anak, penelantaran, pemerkosaan, kekerasan, perselingkuhan perceraian, *trafficking*, TKI, orang hilang, penculikan, pembunuhan, dan lainnya. Data yang digunakan adalah laporan dari Dinas Pemberdayaan Perempuan dan Perlindungan Anak (DP3A). Klasifikasi dilihat dari kronologi kejadian pada laporan yang digunakan. Alur penelitian menggunakan metode *Knowledge Discovery in Database (KDD)* dengan *Term Frequency-Inverse Document* (TF-IDF) sebagai ekstraksi fitur dan algoritma *Random Oversampling* sebagai algoritma *oversampling* untuk menangani dataset yang tidak seimbang. Hasil evaluasi model terbaik diperoleh dengan nilai *accuracy* sebesar 47%, *precision* sebesar 45%, *recall* sebesar 42%, dan *f-measure* sebesar 41%.

Penelitian selanjutnya dilakukan oleh Fanani Rudi & Fikriah Katul (2023) yang juga melakukan klasifikasi kekerasan menggunakan algoritma C4.5. Algoritma C4.5 adalah teknik yang digunakan untuk membentuk *Decision Tree* atau pohon keputusan yang berguna untuk meningkatkan keakuratan prediksi pada target. Data penelitian ini diperoleh dari observasi, wawancara, dan survei di

wilayah Kecamatan Tulis tepatnya di Kabupaten Batang, Jawa Tengah mengenai kekerasan perempuan, anak, dan kelompok kebutuhan khusus. Untuk meningkatkan akurasi, *Particle Swarm Optimazion* (PMO) akan digunakan sebagai ekstraksi fitur. Penelitian menunjukkan bahwa menggunakan algoritma C4.5 dan PMO meningkatkan akurasi sebesar 1,67% menjadi 82,5%.

Penelitian oleh Annapragada et al (2021) menggunakan algoritma NLP dan *deep learning* untuk mengidentifikasi pelecehan anak melalui analisis Rekam Medis Elektronik (RME) pediatrik yang berjumlah 867 data. Penelitian ini menerapkan tiga teknik ekstraksi fitur NLP, yaitu *Bag of Words-Term Frequency Inverse Document Frequency* (BOW-TFIDF), *Word Embeddings* (WE), dan *Rules-Based (RB)* untuk melatih jaringan syaraf *Multi-Layer Perceptron* (MLP). Hasil terbaik ditunjukkan oleh ekstraksi fitur BOW-TFIDF dengan akurasi rata-rata sebesar 90% dan ROC-AUC rata-rata sebesar 93%. Temuan ini menunjukkan penggunaan NLP dalam mengidentifikasi pelecehan anak dapat membantu para dokter mengidentifikasi kasus-kasus yang mungkin terlewat dan mencegah kekerasan yang berlanjut.

Kemudian, Shahi et al (2021) mengembangkan model *deep learning* untuk mendeteksi kekerasan fisik pada anak menggunakan data *registry* pusat trauma anak. Peneliti membuat dua model, yaitu model 1 menggunakan data demografi dan klinis pasien sebagai *input* untuk algoritma *deep learning* ANN dari *library TensorFlow/Keras*, sementara model 2 menambahkan *input* berupa teks laporan radiologi, MRI otak, dan survei kerangka yang diproses menggunakan model NLP BERT dari Google. Hasilnya menunjukkan bahwa Model 2 yang menggabungkan

metode BERT memiliki akurasi lebih tinggi yaitu sebesar 93.4% dibandingkan Model 1 sebesar 86.3% dalam mendeteksi kekerasan fisik pada anak. Rangkuman penelitian-penelitian di atas ditunjukkan pada Tabel 2.1.

Tabel 2.1 Penerapan *Machine Learning* dalam Analisis Kekerasan Pada Anak

No	Peneliti	Metode	Tujuan Penelitian	Data	Hasil
1	Subroto et al. (2022)	<i>Multinomial Naïve Bayes</i> (MNB), TF-IDF, <i>Random Oversampling</i>	Klasifikasi jenis kekerasan pada perempuan dan anak	Laporan Dinas Pemberdayaan Perempuan dan Perlindungan Anak (DP3A)	Akurasi 47%, Precision 45%, Recall 42%, F1-Score 41%
2	Fanani Rudi & Fikriah Katul (2023)	<i>C4.5, Particle Swarm Optimization</i> (PSO)	Klasifikasi kekerasan perempuan, anak, dan kelompok kebutuhan khusus	Observasi, wawancara, dan survei di Kabupaten Batang, Jawa Tengah	Akurasi 82,5%
3	Annapragada et al. (2021)	<i>Deep Learning</i> (MLP), NLP (BOW-TFIDF, WE, RB)	Identifikasi pelecehan anak	Rekam Medis Elektronik (RME) pediatrik	Akurasi 90%, ROC-AUC 93% dengan metode BOW-TFIDF
4	Shahi et al. (2021)	<i>Deep Learning</i> (ANN), NLP (BERT)	Deteksi kekerasan fisik pada anak	Data demografi, klinis, laporan radiologi, MRI otak, dan survei kerangka	Model 2 (BERT + ANN) menghasilkan akurasi 93.4%,

Dari penelitian-penelitian di atas masih belum ada penelitian yang mengidentifikasi relasi hubungan antara pelaku dan korban kekerasan anak terutama yang bersumber dari berita *online*. Klasifikasi pelaku kekerasan anak melalui berita *online* menggunakan algoritma *neural network* menjadi semakin relevan karena meningkatnya jumlah berita terkait kekerasan anak sejalan dengan meningkatnya kasus kekerasan itu sendiri. Berita *online* sering kali memuat informasi tentang pelaku, korban, dan konteks kekerasan yang terjadi, sehingga dapat menjadi sumber data yang bermanfaat untuk proses klasifikasi. Berita *online*

memberikan akses yang cepat dan terkini yang mencerminkan realitas sosial di mana kasus kekerasan terjadi (Arpandi, 2023).

Identifikasi relasi pelaku dengan korban melalui klasifikasi pelaku kekerasan dari berita *online*, yang meliputi kategori keluarga, tenaga pendidik, teman, pengasuh, dan orang asing dapat memberikan gambaran yang lebih lengkap mengenai motif dan pola kekerasan. Kategori-kategori ini dipilih karena pelaku kekerasan seringkali berasal dari orang-orang terdekat korban, seperti keluarga, tenaga pendidik, teman, dan pengasuh yang memiliki hubungan langsung dan intensitas interaksi yang tinggi dengan korban (Mozin & Sunge, 2021). Sementara, orang asing menjadi kategori karena dalam banyak kasus, pelaku tidak dikenal oleh korban dan sering kali tidak disebutkan dalam berita. Data UNICEF turut memperkuat hal ini dengan menunjukkan bahwa kekerasan fisik dan emosional terhadap anak umumnya dilakukan oleh individu yang memiliki otoritas kuat terhadap anak, seperti orang tua dan pengasuh, serta oleh orang-orang yang sering berinteraksi dengan anak, seperti teman dan guru. Adapun kekerasan seksual dapat dilakukan baik oleh individu yang dikenal maupun tidak dikenal oleh korban.

2.3 Penggunaan *Neural Network* dalam Klasifikasi Teks

Penggunaan *text classification* sebagai bagian dari *Natural Language Processing* (NLP) dapat membantu dalam proses pengklasifikasian pelaku berdasarkan berita online. NLP adalah teknik pemrosesan komputasi bahasa natural seperti suara dan teks yang digunakan untuk klasifikasi teks, analisis sentimen, penerjemahan mesin, dan pengenalan ucapan (Geetha et al., 2023). Metode *neural*

network dipilih karena efektif dalam melakukan klasifikasi dan menangani data yang kompleks (Tripathi et al., 2019).

Terdapat beberapa penelitian yang menggunakan metode *neural network* terutama dalam bidang *text classification*. Salah satunya analisis sentimen mengenai kenaikan BBM yang dilakukan oleh Najiyah (2023) menggunakan metode *Artificial Neural Network* (ANN). Dataset diperoleh dari proses *crawling* data pada media sosial *twitter* dengan hashtag *#kenaikanbbm* yang berhasil mengumpulkan 1.210 data berisi tanggapan masyarakat tentang kebijakan tersebut. Data dikategorikan ke dalam sentimen positif, negatif, dan netral. Penelitian ini menghasilkan akurasi sebesar 83.4%, *precision* sebesar 86,2%, *recall* sebesar 83,5%, dan *f1-score* sebesar 84,8% yang menunjukkan bahwa metode ANN efektif dalam klasifikasi teks.

Penelitian lain terkait analisis sentimen menggunakan algoritma ANN dengan metode *backpropagation* juga pernah diteliti oleh Euis Saraswati et al (2021). Peneliti meneliti opini publik mengenai virus *Covid-19* yang dibagi menjadi sentimen positif dan negatif. Data berasal dari *twitter* yang kemudian dioleh menggunakan ekstraksi fitur TF-IDF. Dengan persentasi data latih dan tes sebesar 80:20, *hidden layer 1* berjumlah 10 node, dan *learning rate* sebesar 0,02 menghasilkan akurasi 88,62%, *precision* 91,5%, dan *recall* sebesar 95,73%.

BAB III

DESAIN DAN IMPLEMENTASI

3.1 Pengumpulan Data


Data penelitian ini berasal dari berita *online* Indonesia, yaitu Detik, TribunNews, CNN, Kompas, dan Republika terkait kekerasan anak. Berita dikumpulkan menggunakan teknik *web scraping* yang menghasilkan sebanyak 1013 data. Pelaku kekerasan anak diidentifikasi pada setiap berita berdasarkan informasi yang disampaikan secara eksplisit dan diklasifikasikan ke dalam lima kategori, yaitu “keluarga”, “pengasuh”, “tenaga pendidik”, “teman”, dan “orang asing”. Data disimpan dalam format *.csv* yang ditunjukkan pada Tabel 3.1.

Tabel 3.1 Dataset Berita Kekerasan Anak

No	Judul	Tanggal	Link	Berita	Label
1	Ayah di Pinrang Ditangkap Usai Sandera dan Ancam Bunuh Anak, Terancam Penjara 5 tahun	Senin, 5 Agu 2024 18:59	https://makassar.tribunnews.com/2024/08/05/ayah-di-pinrang-ditangkap-usai-sandera-dan-ancam-bunuh-anak-terancam-penjara-5-tahun	Ayah di Pinrang Ditangkap Usai Sandera dan Ancam Bunuh Anak, Terancam Penjara 5 tahun. Ayah di Kabupaten Pinrang...	Keluarga
2	Dugaan Anak Dibawa Orang Tak Dikenal, Attila Syach Jalani BAP di Polres Bogor	Sabtu, 16 Des 2023 15:36	https://hot.detik.com/celeb/d-7093370/dugaan-anak-dibawa-orang-tak-dikenal-attila-syach-jalani-bap-di-polres-bogor	Dugaan Anak Dibawa Orang Tak Dikenal, Attila Syach Jalani BAP di Polres Bogor. Attila Syach menyambangi Polres Bogor...	Orang Asing
3	Perkosa 27 Gadis Remaja, Guru Ngaji di Senegal Ditangkap	Selasa, 06 Jun 2023 09:21	https://www.cnnindonesia.com/internasional/20230606085913-127-958070/perkosa-27-gadis-remaja-guru-ngaji-di-senegal-ditangkap	Perkosa 27 Gadis Remaja, Guru Ngaji di Senegal Ditangkap. Seorang guru mengaji di Senegal ditangkap...	Tenaga Pendidik

3.2 Desain Sistem

Desain sistem memperlihatkan alur tahapan dari sistem klasifikasi pelaku kekerasan anak yang diilustrasikan pada Gambar 3.1.




Gambar 3.1 Desain Sistem

Pertama, memasukkan dataset berita kekerasan anak sebagai *input*. Kedua, proses *data cleaning* untuk memastikan bahwa data yang digunakan sudah terhindar dari *noise*. Ketiga, tahap *text preprocessing* agar dapat diolah oleh algoritma *machine learning*. Keempat, data akan diubah menjadi format numerik menggunakan ekstraksi fitur *Word2Vec*. Terakhir, data lalu diproses dengan algoritma *neural network* yang menghasilkan *output* berupa salah satu kelas pelaku kekerasan anak.


3.2.1 Data Cleaning

Data cleaning yaitu proses pembersihan data dengan tujuan untuk menghilangkan *noise* pada dataset (Putu et al., 2021). Proses *data cleaning* dilakukan dengan menghapus data yang duplikat, menghapus kolom yang bukan sebagai *feature*, dan *label encoding*. *Label encoding* yaitu proses mengubah data kategori menjadi bentuk numerik (Dachi & Sitompul, 2023). Terdapat lima kategori yang akan diubah menjadi numerik, yaitu keluarga, pengasuh, tenaga pendidik, teman, dan orang asing. Pemilihan *feature* hanya menggunakan kolom “berita” sebagai *input* dan kolom “label” sebagai target klasifikasi. Jumlah data setelah melalui tahapan *data cleaning* sebanyak 975 data. Distribusi data setiap kategori

dan alur dari tahap *data cleaning* ditunjukkan pada Gambar 3.2 dan Gambar 3.3. Kemudian, hasil dari tahap *data cleaning* yang telah dilakukan ditunjukkan oleh Tabel 3.2.



Gambar 3.2 Distribusi Data Setiap Kategori Pelaku Kekerasan Anak




Gambar 3.3 Flowchart Tahap *Data Cleaning*

Tabel 3.2 Hasil Proses *Data Cleaning*

No	Berita	Label	Category_id
1	Ayah di Pinrang Ditangkap Usai Sandera dan Ancam Bunuh Anak, Terancam Penjara 5 tahun. Ayah di Kabupaten Pinrang,...	keluarga	0
2	Dugaan Anak Dibawa Orang Tak Dikenal, Attila Syach Jalani BAP di Polres Bogor. Attila Syach menyambangi Polres Bogor...	orang asing	4
3	Perkosa 27 Gadis Remaja, Guru Ngaji di Senegal Ditangkap. Seorang guru mengaji di Senegal ditangkap....	tenaga pendidik	2

3.2.2 Text Preprocessing

Text preprocessing merupakan proses mengolah data yang berbentuk teks menjadi data yang terstruktur sesuai dengan kebutuhan. Tujuannya agar sistem dapat memperoleh wawasan, informasi, dan pengetahuan dari data yang digunakan sehingga dapat memaksimalkan akurasi klasifikasi (Ridwansyah, 2022). Dalam penelitian ini, langkah-langkah *text processing* dapat dilihat pada Gambar 3.4.

Gambar 3.4 Diagram Alur Tahap *Text Preprocessing*

3.2.2.1 Punctuation Removal


Tahap *punctuation removal* berfungsi untuk menghapus elemen-elemen yang tidak mempunyai makna khusus dalam teks, seperti tanda baca, simbol, angka, dan karakter-karakter lainnya. Tahap ini bertujuan agar sistem lebih mudah dalam melakukan klasifikasi karena teks hanya berfokus pada isi konten (Hasanah et al., 2018). Alur tahap *punctuation removal* ditunjukkan oleh Gambar 3.5.



Gambar 3.5 Flowchart Tahap *Punctuation Removal*

3.2.2.2 Case Folding

Case folding berfungsi untuk mengubah semua kata dalam teks menjadi huruf kecil. Tahapan ini dilakukan agar semua huruf dalam teks memiliki ukuran yang sama (Hasanah et al., 2018). Gambar 3.6 menunjukkan tahapan dari *case folding*.



Gambar 3.6 Flowchart Tahap *Case Folding*

3.2.2.3 Tokenization

Tokenisasi atau *tokenization* adalah memotong dokumen teks menjadi potongan-potongan kecil yang disebut token (Ferrario & Naegelin, 2020). Alur tahapan *tokenization* dapat dilihat pada Gambar 3.7.



Gambar 3.7 Flowchart Tahap Tokenization

3.2.2.4 Stopword Removal

Stopword merupakan kumpulan kata yang tidak memiliki makna khusus atau dalam arti lain tidak memberikan pengaruh yang signifikan dalam analisis teks. *Stopword* terdiri dari kata-kata yang umum digunakan seperti kata hubung atau kata keterangan. Contohnya adalah kata “di”, “yang”, “dari”, “oleh” dan kata-kata umum lainnya (Ferrario & Naegelin, 2020). *Stopword removal* adalah bagian dari tahap *text preprocessing* agar data dapat lebih fokus pada kata-kata yang unik dan bermakna. Alur dari *stopword removal* ditunjukkan pada Gambar 3.8.



Gambar 3.8 *Flowchart Tahap Stopword Removal*

3.2.2.5 Stemming

Stemming adalah proses mengembalikan setiap kata ke bentuk dasarnya. Caranya dengan menghilangkan awalan kata, akhiran kata, sisipan kata, dan *confixes* (kombinasi awalan dan akhiran kata (Ridwansyah, 2022)). *Stemming* berguna untuk meminimalkan variasi kata yang beragam tetapi memiliki makna yang sama. Gambar 3.9 memperlihatkan alur dari tahapan *stemming*.



Gambar 3.9 *Flowchart Tahap Stemming*

Tabel 3.3 adalah data yang telah melewati tahap *text preprocessing* yang meliputi *punctuation removal*, *case folding*, *tokenization*, *stopword removal*, hingga tahap terakhir yaitu *stemming*.

Tabel 3.3 Hasil Tahap *Text Preprocessing*

No	Langkah	Hasil
1	<i>Punctuation Removal</i>	Ayah di Pinrang Ditangkap Usai Sandera dan Ancam Bunuh Anak Terancam Penjara tahun Ayah di Kabupaten Pinrang ...
	<i>Case Folding</i>	ayah di pinrang ditangkap usai sandera dan ancam bunuh anak terancam penjara tahun ayah di kabupaten pinrang ...
	<i>Tokenization</i>	['ayah', 'di', 'pinrang', 'ditangkap', 'usai', 'sandra', 'dan', 'ancam', 'bunuh', 'anak', 'terancam', 'penjara', 'tahun', 'ayah', 'di', 'kabupaten', 'pinrang', '....', '....', '....']
	<i>Stopword Removal</i>	['ayah', 'pinrang', 'ditangkap', 'sandra', 'ancam', 'bunuh', 'anak', 'terancam', 'penjara', 'ayah', 'kabupaten', 'pinrang', '....', '....', '....']
	<i>Stemming</i>	['ayah', 'pinrang', 'tangkap', 'sandra', 'ancam', 'bunuh', 'anak', 'ancam', 'penjara', 'ayah', 'kabupaten', 'pinrang', '....', '....', '....']
2	<i>Punctuation Removal</i>	Dugaan Anak Dibawa Orang Tak Dikenal Attila Syach Jalani BAP di Polres Bogor Attila Syach menyambangi Polres Bogor...
	<i>Case Folding</i>	dugaan anak dibawa orang tak dikenal attila syach jalani bap di polres bogor ...
	<i>Tokenization</i>	['dugaan', 'anak', 'dibawa', 'orang', 'tak', 'dikenal', 'attila', 'syach', 'jalani', 'bap', 'di', 'polres', 'bogor', '....', '....', '....']
	<i>Stopword Removal</i>	['dugaan', 'anak', 'dibawa', 'orang', 'dikenal', 'attila', 'syach', 'jalani', 'bap', 'polres', 'bogor', '....', '....', '....']
	<i>Stemming</i>	['duga', 'anak', 'bawa', 'orang', 'kenal', 'attila', 'syach', 'jalan', 'bap', 'polres', 'bogor', 'attila', 'syach', 'sambang', 'polres', 'bogor', '....', '....', '....']
3	<i>Punctuation Removal</i>	Perkosa Gadis Remaja Guru Ngaji di Senegal Ditangkap Seorang guru mengaji di Senegal...
	<i>Case Folding</i>	perkosa gadis remaja guru ngaji di senegal ditangkap seorang guru mengaji di senegal...
	<i>Tokenization</i>	['perkosa', 'gadis', 'remaja', 'guru', 'ngaji', 'di', 'senegal', 'ditangkap', 'seorang', 'guru', 'mengaji', 'di', 'senegal', '....', '....', '....']
	<i>Stopword Removal</i>	['perkosa', 'gadis', 'remaja', 'guru', 'ngaji', 'senegal', 'ditangkap', 'guru', 'mengaji', 'senegal', '....', '....', '....']
	<i>Stemming</i>	['perkosa', 'gadis', 'remaja', 'guru', 'ngaji', 'senegal', 'tangkap', 'guru', 'aji', 'senegal', '....', '....', '....']


3.2.3 Ekstraksi Fitur *Word2Vec*

Ekstraksi fitur pada teks adalah metode untuk mengekstrak informasi yang relevan dari teks dan mengubahnya menjadi format numerik (Liang et al., 2017). Menurut Efrizoni et al (2022) cara kerja ekstraksi fitur yaitu dengan memetakan

setiap kata yang terkandung pada dokumen ke dalam *dense vector*. Setiap dimensi *vector* mewakili setiap proyeksi kata dalam dokumen.

Word2Vec adalah metode *word embedding* yang menggunakan model *neural network* untuk memetakan kata-kata ke dalam ruang vektor (Nurdin et al., 2020). Metode *word2Vec* mempelajari makna semantik setiap kata dengan melihat konteks kata atau kata-kata di sekitarnya. Kata yang memiliki vektor yang berdekatan berarti memiliki makna semantik yang mirip. *Word2Vec* memiliki dua varian, yaitu *Continuous Bag of Words* (CBOW) dan *skip-gram*. CBOW memprediksi kata target dari konteks sekitarnya, sementara *skip-gram* memprediksi kata konteks dari kata target. Penelitian ini menggunakan varian *skip-gram* karena lebih efektif dalam menangkap hubungan semantik antar kata terutama dalam korpus yang besar (Yilmaz & Toklu, 2020).

Model *skip-gram* bekerja dengan memprediksi kata konteks $C(w_t)$ yaitu kata yang terletak sebelum dan sesudah kata pusat w_t . Misalnya diberikan sebuah urutan kata $w_1, w_2, w_3, \dots, w_t$ maka model *skip-gram* akan menebak kata konteks $C(w_t)$ di sekitar kata pusat w_t (Mikolov et al., 2013). Contohnya bila terdapat kalimat “Polisi menangkap pria yang diduga mencabuli anaknya” dengan ukuran jendela konteksnya adalah 2 dan kata pusat w_t adalah “pria” maka $C(w_t) = \{\text{'polisi'}, \text{'menangkap'}, \text{'yang'}, \text{'diduga'}\}$. Arsitektur *word2Vec* pada *skip-gram* berdasarkan contoh dapat dilihat pada Gambar 3.10.




Gambar 3.10 Arsitektur *WordVec* Model *Skip-Gram*

Terdapat tiga tahapan yang dilalui pada model *skip-gram*, yaitu:

- 1) Membuat *vocabulary* atau korpus: mengumpulkan semua kata unik dari teks, membentuk daftar kata (*vocabulary*), dan memberikan indeks pada setiap kata.
- 2) Menentukan kata pusat w_t dan kata konteks $C(w_t)$: menentukan kata-kata yang menjadi konteks $C(w_t)$ di sekitar kata pusat w_t berdasarkan ukuran jendela c . Ukuran jendela konteks adalah ukuran jangkauan kata yang dipertimbangkan untuk menciptakan pasangan target dan konteks.
- 3) Jaringan syaraf (*neural network*): *word2Vec* menggunakan *neural network* untuk melakukan *training* yaitu mempelajari representasi vektor setiap kata.

Gambar 3.11 menunjukkan arsitektur *neural network word2Vec* pada model *skip-gram* yang digunakan dalam penelitian ini.



Gambar 3.11 Arsitektur *Neural Network Word2Vec Model Skip-Gram*

Model *neural network word2Vec* memiliki tiga lapisan, antara lain:

- Input layer* : jumlah *node* sebanyak jumlah kata dalam daftar kosakata (*vocabulary*). *Input layer* akan diubah menjadi bentuk *one hot encode* dimana angka 1 mewakili kata pusat w_t dan angka 0 mewakili kata yang lain.
- Hidden layer* : jumlah *node* sebanyak 100 sesuai dengan dimensi vektor kata (*embedding dim*) yang ditentukan.
- Output layer* : jumlah *node* sama seperti *input layer* yaitu sebanyak jumlah kata dalam daftar kosakata (*vocabulary*).

3.2.3.1 Alur *Neural Network Word2Vec*

Alur *neural network word2Vec* memiliki dua tahapan yaitu, *feedforward* dan *backpropagation*. Berikut adalah alur *neural network Word2Vec*:

1. Inisialisasi *window size* = 3, *learning rate* = 0.01, *epoch* = 70, dan dimensi vektor kata (N) atau *embedding dim* = 100.
2. Inisialisasi w_{ij} dan v_{jk} . w_{ij} adalah matriks *embedding* berukuran $V \times N$ dan v_{jk} matriks berukuran $N \times V$ dimana V adalah jumlah kata dalam korpus dan N adalah jumlah dimensi vektor kata (Kurniawan & Maharani, 2020).
3. Proses *Feedforward*

- a) Menghitung *hidden layer* yang dihitung berdasarkan pada Persamaan 3.1.

$$A_j = \sum_{i=1}^v X_i \cdot w_{ij} \quad (3.1)$$

Keterangan:

A_j = nilai *hidden layer* pada *node* ke- j

w_{ij} = bobot dari *input layer* ke *hidden layer*

X_i = nilai *input layer* dari *node* ke- i hingga *node* ke- v

- b) Menghitung *output layer* yang dihitung berdasarkan pada Persamaan 3.2.

$$B_k = \sum_{j=1}^n A_j \cdot v_{jk} \quad (3.2)$$

Keterangan:

B_k = nilai *output layer* pada *node* ke- k

v_{jk} = bobot dari *hidden layer* ke *output layer*

A_j = nilai *hidden layer* pada *node* ke- j hingga *node* ke- n

- c) Menghitung nilai *output* menggunakan fungsi *softmax* untuk menghitung probabilitas setiap kata dalam *vocabulary* merupakan kata konteks berdasarkan kata pusat w_t .

$$Z = \text{softmax}(B_k) \quad (3.3)$$

Keterangan:

Z = probabilitas kata konteks w_j berdasarkan pada kata pusat w_t ($p(w_j|w_t)$)

4. Proses *Backpropagation*

- a) Menghitung nilai error berdasarkan *cross-entropy loss*.

$$L = - \sum_{k=1}^{|V|} y \log (Z) \quad (3.4)$$

Keterangan:

L = nilai *cross-entropy loss*

y = nilai *ground truth* kata konteks w_j berdasarkan pada kata pusat w_t

- b) Menghitung *gradient loss* terhadap *output layer* (B_k) dan *gradient loss* terhadap bobot v_{jk} .

$$\frac{\partial L}{\partial B_k} = Z - y \quad (3.5)$$

$$\frac{\partial L}{\partial v_{jk}} = (A_j)^T \times \frac{\partial L}{\partial B_k} \quad (3.6)$$

Keterangan:

$\frac{\partial L}{\partial B_k}$ = *gradient loss* terhadap *output layer* (B_k)

$\frac{\partial L}{\partial v_{jk}}$ = *gradient loss* terhadap bobot v_{jk}

$(A_j)^T$ = nilai *transpose* dari *hidden layer* pada *node ke-j*

- c) Menghitung *gradient loss* terhadap *hidden layer* (A_j) dan *gradient loss* terhadap bobot w_{ij} .

$$\frac{\partial L}{\partial A_j} = \frac{\partial L}{\partial B_k} \times (v_{jk})^T \quad (3.7)$$

$$\frac{\partial L}{\partial w_{ij}} = X_i^T \times \frac{\partial L}{\partial A_j} \quad (3.8)$$

Keterangan:

$\frac{\partial L}{\partial A_{1i}}$ = *gradient loss* terhadap *hidden layer* (A_j)

$$\begin{aligned}\frac{\partial L}{\partial w_{1ji}} &= \text{gradient loss terhadap bobot } w_{ij} \\ (v_{jk})^T &= \text{nilai transpose dari bobot } v_{jk} \\ X_i^T &= \text{nilai transpose dari input layer pada node ke-}i\end{aligned}$$

d) *Update* bobot w_{ij} dan v_{jk}


$$w_{ij}^t = w_{ij}^{t-1} - \eta \frac{\partial L}{\partial w_{ij}} \quad (3.9)$$

$$v_{jk}^t = v_{jk}^{t-1} - \eta \frac{\partial L}{\partial v_{jk}} \quad (3.10)$$

Keterangan:


$$\begin{aligned}w_{ij}^t &= \text{nilai bobot baru input layer ke hidden layer setelah update} \\ v_{jk}^t &= \text{nilai bobot baru hidden layer ke output layer setelah update} \\ w_{ij}^{t-1} &= \text{nilai bobot lama input layer ke hidden layer sebelum update} \\ v_{jk}^{t-1} &= \text{nilai bobot lama hidden layer ke output layer sebelum update} \\ \eta &= \text{learning rate atau laju pembelajaran}\end{aligned}$$

Untuk dapat memahami alur kerja sistem *word2vec* model *skip-gram* maka dibuatkan *flowchart* yang menggambarkan langkah-langkah teknis. *Flowchart* dari proses *neural network* pada model *skip-gram* diilustrasikan pada Gambar 3.12.



Gambar 3.12 Flowchart Neural Network Pada Model Skip-Gram

Dari Gambar 3.12 sistem dimulai dengan memasukkan daftar pasangan kata pusat dan konteks, diikuti dengan inisialisasi parameter model. Selanjutnya, dilakukan iterasi pelatihan sebanyak jumlah *epoch* yang ditentukan. Dalam setiap iterasi, proses *feedforward* dan *backpropagation* dijalankan untuk menghitung *error* dan gradien, kemudian bobot w_{ij} dan v_{jk} diperbarui. Proses ini berulang hingga semua *epoch* selesai, setelah itu bobot w_{ij} yang telah terlatih disimpan dan proses iterasi berakhir. Proses *training* dari model word2vec *skipgram* ditunjukkan pada Gambar 3.13 sebagai berikut.



Gambar 3.13 Grafik *Loss* Proses *Training Word2vec Skip-Gram*

Dari Gambar 3.13 terlihat bahwa proses pelatihan sudah mencapai titik konvergensi, yaitu pada sekitar epoch ke-50 hingga ke-70 nilai *loss* cenderung stagnan. Pada awal pelatihan, nilai *loss* mengalami penurunan yang cukup tajam, yang menandakan model berhasil belajar pola dari data dengan baik. Namun, seiring bertambahnya jumlah *epoch*, penurunan *loss* menjadi lebih lambat dan grafik *loss* menjadi relatif datar yang menunjukkan bahwa model sudah tidak mengalami perubahan signifikan dalam belajar sehingga dapat dikatakan pelatihan telah mencapai hasil optimal dengan konfigurasi dan data yang digunakan. Setelah proses *training* selesai diperoleh matriks embedding w_{ij} , di mana setiap baris dari matriks tersebut mewakili vektor embedding 100 dimensi untuk satu kata. Hasil vektor embedding ditampilkan pada Tabel 3.4.

Tabel 3.4 Hasil Vektor Embedding

No	Kata	Vektor Embedding
1	ayah	[-0,0353170, 0,31167793, -0,24700886, 0,33387050, 0,09822940, -0,03070815, 0,29054421, ..., ...]
	pinrang	[-0,3564126, 0,64205563, -0,57720458, 0,23268346, 0,69875192, 0,07281012, 0,55919396, ..., ...]
	tangkap	[0,29735830, 0,70507490, -0,51841109, 0,31537845, 0,32617513, 0,11055850, 0,42765122, ..., ...]
	...	...
2	duga	[0,00887687, 0,15733344, 0,04441884, 0,03483704, 0,36321759, 0,14959663, 0,04010662, ..., ...]
	anak	[0,40457138, 0,13035048, 0,14324997, -0,01508956, 0,17933625, 0,07560060, 0,05238653, ..., ...]
	bawa	[0,37025660, 0,33079019, 0,16631344, 0,19284585, -0,00197417, -0,10074839, -0,05686160, ..., ...]
	...	...
3	perkosa	[0,72670447, 0,1131726, -0,05319953, -0,30828738, 0,71188873, 0,36329197, 0,50348621, ..., ...]
	gadis	[1,57031762, -0,53263610, 0,63893091, -0,18093493, -0,20745126, -0,02583436, -0,32572338, ..., ...]
	remaja	[0,34520599, 1,03257536, -0,05225384, -0,39595839, 0,79884183, 0,10881694, 0,13839498, ..., ...]
	...	...

3.2.3.2 Agregasi Vektor

Hasil dari matriks embedding w_{ij} akan diolah menggunakan metode agregasi rata-rata (*average pooling*) agar setiap vektor mewakili satu dokumen. Agregasi ini bertujuan untuk memperoleh vektor tunggal yang mewakili semantik setiap dokumen yang merupakan *input* di metode *machine learning* selanjutnya. Agregasi rata-rata dihitung menggunakan Persamaan 3.11.

$$V = \frac{1}{m} \sum_{i=1}^m w_{ij} \quad (3.11)$$

Keterangan:

- V = vektor rata-rata representasi dokumen
 w_{ij} = bobot dari *input layer* ke *hidden layer* (matriks embedding)
 m = jumlah total kata dalam dokumen
 $\sum_{i=1}^m w_{ij}$ = penjumlahan semua vektor kata dalam dokumen

Tabel 3.5 adalah hasil agregasi vektor dari matriks embedding w_{ij} yang mewakili satu dokumen dan akan digunakan sebagai *input* pada *neural network* untuk klasifikasi. Setiap vektor pada matriks tersebut merepresentasikan konteks semantik dari suatu kata dalam dimensi vektor tertentu.

Tabel 3.5 Hasil Agregasi Vektor

No	Berita	Vektor Dokumen
1	['ayah', 'pinrang', 'tangkap', 'sandra', 'ancam', 'bunuh', 'anak', 'ancam', 'penjara', 'ayah', 'kabupaten', 'pinrang', 'sulawesi', 'selatan', 'sulsel', 'nama', 'sandi', 'tangkap', 'polisi', 'sandra', 'anak', '....', '....', '....']	[0.17960928, 0.41701304, -0.04744936, 0.16406092, 0.33008304, 0.51112955, 0.27888852, ..., ...]
2	['duga', 'anak', 'bawa', 'orang', 'kenal', 'attila', 'syach', 'jalan', 'bap', 'polres', 'bogor', 'attila', 'syach', 'sambang', 'polres', 'bogor', 'jalan', 'lapor', 'kait', 'duga', 'anak', 'bawa', 'kabur', 'sekap', 'oknum', '....', '....', '....']	[0.10238317, 0.24704149, 0.27464881, 0.07162185, 0.27867609, 0.16106963, 0.21878425, ..., ...]
3	['perkosa', 'gadis', 'remaja', 'guru', 'ngaji', 'senegal', 'tangkap', 'guru', 'aji', 'senegal', 'tangkap', 'duga', 'perkosa', 'remaja', 'perempuan', 'kabur', 'minggu', 'tangkap', '....', '....', '....']	[0.27266201, 0.32876896, 0.10859704, 0.17696940, 0.35974007, 0.23283024, 0.39247292, ..., ...]

Gambar 3.14 menampilkan hasil t-SNE *plot* dari 100 kata yang paling sering muncul. t-SNE berguna sebagai visualisasi hubungan antar kata berdasarkan kemiripan makna dari hasil pelatihan *word2Vec* dimana vektor kata yang memiliki makna serupa akan cenderung berdekatan dan kata yang tidak saling berkaitan akan tersebar lebih jauh. Visualisasi ini memberikan gambaran menyeluruh mengenai struktur semantik dari kata-kata dalam korpus terutama pada 100 kata dengan frekuensi terbanyak.




Gambar 3.14 t-SNE Plot untuk 100 Kata dengan Frekuensi Tertinggi

3.2.4 Neural Network

Neural network adalah model yang dirancang menyerupai cara otak manusia dalam melakukan tugas atau fungsi tertentu (Haykin, 1999). Otak manusia terdiri dari miliaran *neuron* yang saling terhubung dan berkomunikasi satu sama lain untuk memproses suatu informasi. Demikian pula *neural network* terdiri dari banyak *neuron* atau *node* yang diatur dalam lapisan-lapisan *layer* dimana setiap *neuron* terhubung satu sama lain. Model ini belajar dengan menyesuaikan bobot

dan bias antar *neuron* agar dapat memproses informasi dengan akurat. Arsitektur *neural network* pada penelitian ini ditunjukkan pada Gambar 3.15.



Gambar 3.15 Arsitektur *Neural Network*

Seperti pada Gambar 3.15 arsitektur *neural network* pada penelitian ini memiliki tiga lapisan, yaitu *input layer*, *hidden layer*, dan *output layer*. *Input layer* berfungsi untuk menerima input data dari luar. *Node* pada lapisan input tidak melakukan apapun pada data hanya meneruskan ke lapisan berikutnya. *Hidden layer* adalah lapisan yang berada di tengah antara *input layer* dan *output layer* yang bertugas untuk mengolah informasi dan menemukan pola tersembunyi dalam data (Pradana et al., 2022). Jumlah *node* pada *hidden layer* berpengaruh pada akurasi model, terlalu sedikit jumlah *node* pada *hidden layer* dapat menyebabkan *underfitting* karena model sulit menangkap pola yang kompleks, sebaliknya terlalu banyak *node* menyebabkan *overfitting* yaitu ketika model terlalu fokus pada *training data* (Deng, 2023). Menurut Heaton (2008) jumlah *node* yang ideal berada di antara ukuran *input* dan *output layer*, dan dapat dihitung menggunakan rumus

heuristik yaitu dua pertiga dari jumlah *input* ditambah jumlah *output*. Terakhir, *output layer* berupa hasil dari informasi yang telah diproses sebelumnya (Pradana et al., 2022).

Otak manusia memiliki sinapsis untuk menghubungkan *neuron* satu dengan *neuron* lain. Model *neural network* juga terdapat bobot yang menghubungkan *node* antar lapisan. Bobot menunjukkan seberapa besar pengaruh satu *neuron* terhadap *neuron* lainnya. Pada tiap *node* kecuali *node* pada *input layer*, terdapat juga bisa bias yang berfungsi sebagai penyeimbang yang menggeser fungsi aktivasi ke sisi positif atau negatif. Fungsi aktivasi juga digunakan untuk menentukan apakah sebuah neuron perlu diaktifkan atau tidak serta membatasi nilai *output* dalam jangkauan tertentu (Mousavirad et al., 2020). Pada penelitian ini, jumlah *layer*, jumlah *node*, dan fungsi aktivasi yang digunakan disajikan dalam Tabel 3.6 sebagai berikut.

Tabel 3.6 Jumlah *Layer*, *Node*, dan Fungsi Aktivasi Model *Neural Network*

No	Nama <i>Layer</i>	Jumlah <i>Node</i>	Fungsi Aktivasi	Keterangan
1	<i>Input layer</i>	100	-	Menerima input berupa vektor hasil ekstraksi fitur <i>Word2Vec</i>
2	<i>Hidden layer 1</i>	10 / 30 / 60	<i>ReLu</i>	Mengolah informasi dan mempelajari pola tersembunyi dalam data
3	<i>Hidden layer 2</i>	5	<i>Softmax</i>	Menghasilkan probabilitas dari masing – masing kelas
4	<i>Output layer</i>	1	-	Mengambil kelas prediksi berdasarkan nilai probabilitas tertinggi

Dalam *neural network* terdapat dua tahapan yaitu *feedforward* dan *backpropagation*. *Feedforward* adalah proses dimana data *input* diteruskan melalui lapisan-lapisan *neural network*, mulai dari *input layer* ke *hidden layer* hingga mencapai *output layer*. Pada tahap ini, setiap *node* pada *hidden layer* dan *output*

layer akan dihitung bersama dengan bobot dan bias yang diberikan. Proses perhitungan *feedforward* adalah sebagai berikut.

- 1) Menghitung *hidden layer 1* dengan bobot dan bias yang terhubung dari *input layer* menuju *hidden layer 1* menggunakan fungsi aktivasi RELU (*Rectified Linear Unit*).

$$P_j = \max \left(0, \sum_{i=1}^m X_i \cdot w_{ij} + b \right) \quad (3.12)$$

Keterangan:

P_j = nilai *hidden layer 1* pada node ke- j

w_{ij} = bobot dari *input layer* ke *hidden layer 1*

X_i = nilai *input layer* dari node ke- i hingga node ke- n

b = nilai bias pada *hidden layer 1*

$\sum_{i=1}^n X_i \cdot w_{ij}$ = total perkalian bobot pada *input layer* dan *hidden layer 1*

Pada Persamaan 3.10 jika A lebih besar dari 0 maka *output* tetap bernilai A , tetapi jika A kurang dari atau sama dengan 0 maka *output* menjadi 0.

- 2) Kemudian, menghitung *hidden layer 2* dengan nilai bobot dan bias yang terhubung dari *hidden layer 1* menuju *hidden layer 2*.

$$Q_k = \sum_{j=1}^n P_j \cdot v_{jk} + c \quad (3.13)$$

Keterangan:

Q_k = nilai *hidden layer 2* pada node ke- k

v_{jk} = bobot dari *hidden layer 1* ke *hidden layer 2*

c = nilai bias pada *hidden layer 2*

$\sum_{k=1}^o P_j \cdot v_{jk}$ = total perkalian bobot pada *hidden layer 1* dan *hidden layer 2*

- 3) Selanjutnya menghitung nilai *output* menggunakan fungsi aktivasi *softmax*. Fungsi *softmax* akan menghasilkan nilai *output* berupa prediksi dari kelas atau kategori.

$$Q_k = \text{softmax}\left(\sum_{j=1}^n P_j \cdot v_{jk} + c\right) \quad (3.14)$$

$$Z = Q_k \quad (3.15)$$

Keterangan:

Z = hasil output prediksi dari model

3.2.4.1 Proses *Training Neural Network*

Tahap selanjutnya adalah proses *training* model pada tahap *backpropagation*. *Backpropagation* yaitu proses untuk menghitung dan memperbarui bobot serta bias dalam *neural network* berdasarkan *error (loss)* antara output prediksi dengan output sebenarnya (*ground truth*). Proses *backpropagation* menggunakan *gradient descent* untuk meminimalkan *error* dengan merambatkan gradien dari *layer* output ke *layer-layer* sebelumnya. Proses perhitungan *backpropagation* adalah sebagai berikut.

- 1) Menghitung nilai error berdasarkan *cross-entropy loss* menggunakan Persamaan 3.16.

$$L = - \sum_{k=1}^5 y \log (Z) \quad (3.16)$$

Keterangan:

L = nilai *cross-entropy loss*

y = target output (*ground truth*)

Z = hasil output prediksi model

- 2) Menghitung *gradient loss* atau *error* terhadap *hidden layer 2* (Q_k), *gradient loss* terhadap bobot v_{jk} , dan *gradient loss* terhadap bias c .

$$\frac{\partial L}{\partial Q_k} = Z - y \quad (3.17)$$

$$\frac{\partial L}{\partial v_{jk}} = (P_j)^T \times \frac{\partial L}{\partial Q_k} \quad (3.18)$$

$$\frac{\partial L}{\partial c} = \frac{\partial L}{\partial Q_k} \quad (3.19)$$

Keterangan:

$\frac{\partial L}{\partial Q_k}$ = *gradient loss* terhadap *hidden layer 2* (Q_k)

$\frac{\partial L}{\partial v_{jk}}$ = *gradient loss* terhadap bobot v_{jk}

$\frac{\partial L}{\partial c}$ = *gradient loss* terhadap bias c

$(P_j)^T$ = nilai *transpose* dari *hidden layer 1* pada *node ke-j*

- 3) Menghitung *gradient loss* terhadap *hidden layer 1* (P_j), *gradient loss* terhadap bobot w_{ij} , dan *gradient loss* terhadap bobot b .

$$\frac{\partial L}{\partial P_j} = \frac{\partial L}{\partial Q_k} \times (v_{jk})^T \times f'(P_j) \quad (3.20)$$

$$\frac{\partial L}{\partial w_{ij}} = X_i^T \times \frac{\partial L}{\partial P_j} \quad (3.21)$$

$$\frac{\partial L}{\partial b} = \frac{\partial L}{\partial P_j} \quad (3.22)$$

Keterangan:

$\frac{\partial L}{\partial P_j}$ = *gradient loss* terhadap *hidden layer 1* (P_j)

$\frac{\partial L}{\partial w_{ij}}$ = *gradient loss* terhadap bobot w_{ij}

$\frac{\partial L}{\partial b}$ = *gradient loss* terhadap bias b

$f'(P_j)$ = turunan fungsi aktivasi RELU pada *hidden layer 1*

$(v_{jk})^T$ = nilai *transpose* dari bobot v_{jk}

X_i^T = nilai *transpose* dari *input layer* pada *node ke-i*

- 4) Terakhir adalah *update* patameter bobot dan bias

$$w_{ij}^t = w_{ij}^{t-1} - \eta \frac{\partial L}{\partial w_{ij}} \quad (3.23)$$

$$v_{jk}^t = v_{jk}^{t-1} - \eta \frac{\partial L}{\partial v_{jk}} \quad (3.24)$$


$$b^t = b^{t-1} - \eta \frac{\partial L}{\partial b} \quad (3.25)$$

$$c^t = c^{t-1} - \eta \frac{\partial L}{\partial c} \quad (3.26)$$

Keterangan:

- w_{ij}^t = nilai bobot baru *input layer* ke *hidden layer 1* setelah *update*
- v_{jk}^t = nilai bobot baru *hidden layer 1* ke *hidden layer 2* setelah *update*
- w_{ij}^{t-1} = nilai bobot lama *input layer* ke *hidden layer 1* sebelum *update*
- v_{jk}^{t-1} = nilai bobot lama *hidden layer 1* ke *hidden layer 2* sebelum *update*
- b^t = bias baru pada *hidden layer 1* setelah *update*
- c^t = bias baru pada *hidden layer 2* setelah *update*
- b^{t-1} = bias lama pada *hidden layer 1* sebelum *update*
- c^{t-1} = bias lama pada *hidden layer 2* sebelum *update*
- η = *learning rate* atau laju pembelajaran

Proses *training* model membutuhkan parameter berupa *epoch* dan *learning rate*. *Learning rate* menentukan seberapa besar perubahan yang diterapkan pada bobot dan bias dalam setiap iterasi selama proses pelatihan (*training*). Nilai *learning rate* dapat diinisialisasi secara bebas sesuai kebutuhan eksperimen seperti penelitian oleh Euis Saraswati et al (2021) yang melakukan uji coba *learning rate* sebesar 0,01 – 0,05. Sementara itu, *epoch* merujuk pada satu siklus penuh dimana model memproses seluruh dataset. *Flowchart* proses *neural network* ditunjukkan pada Gambar 3.16.



Gambar 3.16 Flowchart Proses Neural Network

Gambar 3.16 menggambarkan alur proses pelatihan *neural network* yang dimulai dengan inisialisasi parameter seperti *learning rate*, ukuran *hidden layer*, *cost tolerance*, bobot, dan bias. Selanjutnya, model menghitung fungsi *cost* berdasarkan *output* prediksi dan target, kemudian memeriksa apakah nilai *cost* sudah lebih kecil dari toleransi yang ditentukan. Jika belum, dilakukan proses *feedforward* dan *backpropagation* untuk memperbarui bobot dan bias model. Proses ini akan diulang terus menerus hingga nilai *cost* mencapai batas toleransi. Setelah kondisi tersebut terpenuhi, bobot dan bias disimpan sebagai hasil pelatihan dan proses dinyatakan selesai.

BAB IV

UJI COBA DAN PEMBAHASAN

4.1 Skenario Pengujian

Skenario pengujian dilakukan untuk mengevaluasi kinerja model klasifikasi pelaku kekerasan anak yang dibangun menggunakan *neural network*. Terdapat beberapa tahapan yang dilakukan dalam skenario pengujian ini.

1) Pembagian dataset menjadi data *training*, *validation*, dan *testing*

Dataset yang telah melalui tahap *data cleaning*, *text preprocessing*, ekstraksi fitur menggunakan *word2Vec* menjadi data *training*, *validation*, dan *testing*. Pada penelitian ini, data akan dibagi dengan rasio data *training*, *validation*, dan *testing* sebesar 80:10:10 secara *random* (acak) mengikuti penelitian yang dilakukan oleh Kim & MacKinnon (2018) menghasilkan akurasi sebesar 95,40%. Dari pembagian data diperoleh 780 data sebagai data *training*, 97 data sebagai data *validation*, dan 98 data sebagai data *testing*. Data *training* akan digunakan untuk melatih model agar dapat mengenali pola pada data, sedangkan data *validation* berfungsi untuk memantau kinerja model selama proses pelatihan serta mendeteksi kemungkinan terjadinya *overfitting* atau *underfitting*. Sementara itu, data *testing* digunakan untuk menguji performa akhir model terhadap data yang belum pernah dilihat sebelumnya.

2) Parameter yang diuji

Pada penelitian ini, parameter yang diuji adalah jumlah *node* pada *hidden layer* pertama dan *learning rate*. Pengujian ini bertujuan untuk menentukan pengaruh variasi jumlah *node* dan nilai *learning rate* terhadap performa model.

Keseluruhan skenario pengujian disajikan pada Tabel 4.1 yang penamannya sesuai dengan konfigurasi setiap model. Kode huruf menunjukkan variasi jumlah *node* pada *hidden layer* pertama, yaitu X untuk 10, Y untuk 30, dan Z untuk 60. Sementara itu, kode angka menunjukkan nilai *learning rate*, yaitu angka 1 untuk 0,001, angka 2 untuk 0,05, dan angka 3 untuk 0,01.

Tabel 4.1 Skenario Pengujian

Model	Jumlah node <i>hidden layer 1</i>	<i>Learning Rate</i>
X1	10	0.001
X2	10	0.005
X3	10	0.01
Y1	30	0.001
Y2	30	0.005
Y3	30	0.01
Z1	60	0.001
Z2	60	0.005
Z3	60	0.01

Jumlah *node* pada *hidden layer* pertama dipilih sebagai parameter yang diuji karena memengaruhi model dalam menangkap pola pada data. Jumlah *node* yang optimal dapat menangkap kompleksitas data tanpa menyebabkan *underfitting* atau *overfitting*. Penelitian ini menggunakan tiga konfigurasi jumlah *node* pada *hidden layer* pertama, yaitu 10, 30, dan 60 untuk mengevaluasi dampak kompleksitas jaringan pada performa model. Sementara itu, *learning rate* diuji untuk mengetahui pengaruh kecepatan model model. Selain itu, *learning rate* diuji untuk mengetahui pengaruh kecepatan pembelajaran model terhadap kestabilan dan performa. Dalam penelitian ini, digunakan tiga variasi nilai *learning rate*, yaitu 0,001, 0,005, dan 0,01. Nilai 0,001 dipilih sebagai nilai yang paling stabil, 0,005 sebagai nilai menengah, dan 0,01 untuk mengamati kestabilan model pada nilai *learning rate* yang relatif tinggi.

Pada setiap skenario pengujian, bobot dan bias akan diinisialisasi secara *random* untuk menghindari bias awal yang bisa mempengaruhi proses pelatihan dan hasil akhir. Dalam melakukan *training*, proses iterasi *neural network* akan berhenti apabila selisih antara nilai *cost* pada iterasi saat ini dan iterasi sebelumnya lebih kecil dari nilai *cost tolerance*. Proses pelatihan dihentikan karena model dianggap telah mencapai titik konvergensi, yaitu kondisi ketika model telah mencapai hasil yang stabil dan nilai *cost* stagnan atau tidak mengalami perubahan yang signifikan. *Cost tolerance* adalah batas toleransi perubahan *cost* antara dua iterasi berturut-turut pada proses *training* yang digunakan untuk menghentikan proses *training*. Uji coba menggunakan nilai *cost tolerance* sebesar 0,0000001 atau 10^{-6} .

3) Pengukuran performa sistem

Pengukuran performa sistem dilakukan menggunakan *confusion matrix* yaitu matriks dua dimensi yang berfungsi untuk menilai performa model klasifikasi berdasarkan *output* prediksi dari hasil pengujian model dan *output* sebenarnya (*ground truth*). *Confusion matrix* menghasilkan empat kategori, antara lain:

- 1) *True Positive* (TP): ketika model memprediksi data bernilai positif yang sebenarnya bernilai positif.
- 2) *True Negative* (TN): ketika model memprediksi data bernilai negatif yang sebenarnya bernilai negatif.
- 3) *False Positive* (FP): ketika model memprediksi data bernilai positif padahal seharusnya bernilai negatif.
- 4) *False Negative* (FN): ketika model memprediksi data bernilai negatif padahal seharusnya bernilai positif.

Confusion matrix pada penelitian ini dapat dilihat pada Tabel 4.2 dimana setiap kelas pelaku kekerasan direpresentasikan dengan huruf. A untuk kategori keluarga, B untuk kategori pengasuh, C untuk kategori tenaga pendidik, D untuk kategori teman, dan E untuk kategori orang asing.

Tabel 4.2 *Confusion Matrix*

Kelas Aktual	Kelas Prediksi				
	Keluarga (A)	Pengasuh (B)	Tenaga Pendidik (C)	Teman (D)	Orang Asing (E)
Keluarga (A)	AA	AB	AC	AD	AE
Pengasuh (B)	BA	BB	BC	BD	BE
Tenaga Pendidik (C)	CA	CB	CC	CD	CE
Teman (D)	DA	DB	DC	DD	DE
Orang Asing (E)	EA	EB	EC	ED	EE

Setiap kelas memiliki satu *confusion matrix* terdiri dari TP, TN, FP, dan FN yang dihitung berdasarkan Tabel 4.2 *Confusion matrix* untuk setiap kelas dapat dilihat pada lima tabel di bawah ini.

Tabel 4.3 *Confusion Matrix* Kelas Keluarga

Kelas Aktual	Kelas Prediksi	
	Keluarga (A)	Bukan Keluarga
Keluarga (A)	<i>True Positive</i> (TP) (AA)	<i>False Negative</i> (FN) (AB + AC + AD + AE)
Bukan Keluarga	<i>False Positive</i> (FP) (BA + CA + DA + EA)	<i>True Negative</i> (TN) (Prediksi yang tidak termasuk pada TP, FN, dan FP)

Tabel 4.4 *Confusion Matrix* Kelas Pengasuh

Kelas Aktual	Kelas Prediksi	
	Pengasuh (B)	Bukan Pengasuh
Pengasuh (B)	<i>True Positive</i> (TP) (BB)	<i>False Negative</i> (FN) (BA + BC + BD + BE)
Bukan Pengasuh	<i>False Positive</i> (FP) (AB + CB + DB + EB)	<i>True Negative</i> (TN) (Prediksi yang tidak termasuk pada TP, FN, dan FP)

Tabel 4.5 *Confusion Matrix* Kelas Tenaga Pendidik

Kelas Aktual	Kelas Prediksi	
	Tenaga Pendidik (C)	Bukan Tenaga Pendidik
Tenaga Pendidik (C)	<i>True Positive</i> (TP) (CC)	<i>False Negative</i> (FN) (CA + CB + CD + CE)
Bukan Tenaga Pendidik	<i>False Positive</i> (FP) (AC + BC + DC + EC)	<i>True Negative</i> (TN) (Prediksi yang tidak termasuk pada TP, FN, dan FP)

Tabel 4.6 *Confusion Matrix* Kelas Teman

Kelas Aktual	Kelas Prediksi	
	Teman (D)	Bukan Teman
Teman (D)	<i>True Positive</i> (TP) (DD)	<i>False Negative</i> (FN) (DA + DB + DC + DE)
Bukan Teman	<i>False Positive</i> (FP) (AD + BD + CD + ED)	<i>True Negative</i> (TN) (Prediksi yang tidak termasuk pada TP, FN, dan FP)

Tabel 4.7 *Confusion Matrix* Kelas Orang Asing

Kelas Aktual	Kelas Prediksi	
	Orang asing (E)	Bukan Orang asing
Orang asing (E)	<i>True Positive</i> (TP) (EE)	<i>False Negative</i> (FN) (EA + EB + EC + ED)
Bukan Orang asing	<i>False Positive</i> (FP) (AE + BE + CE + DE)	<i>True Negative</i> (TN) (Prediksi yang tidak termasuk pada TP, FN, dan FP)

Kemudian, menghitung *accuracy*, *precision*, *recall*, dan *F1-score* dari tabel *confusion matrix* di atas sebagai indikator pengukuran performa model *neural network* dalam mengklasifikasikan pelaku kekerasan dengan persamaan sebagai berikut.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

$$precision = \frac{TP}{TP + FP} \quad (4.2)$$

$$recall = \frac{TP}{TP + FN} \quad (4.3)$$

$$F1 - score = 2 \times \frac{precision \times recall}{precision + recall} \quad (4.4)$$

Accuracy berfungsi untuk mengukur keakuratan model dalam melakukan klasifikasi dengan menghitung jumlah prediksi benar dari seluruh data. *Precision* adalah proporsi data yang benar-benar positif dari seluruh data yang diprediksi positif. *Recall* mengukur sejauh mana model berhasil menemukan semua data positif sebenarnya. *F1-score* adalah rata-rata *precision* dan *recall* yang memberikan keseimbangan antara keduanya.


Penelitian ini juga menggunakan *k-fold cross validation* yaitu metode untuk menilai kinerja model *neural network* pada berbagai variasi data atau subset data. *K-fold cross validation* membagi data menjadi *k* bagian yang dikenal sebagai *fold*. Model akan dilatih sebanyak *k* kali dengan setiap *fold* secara bergantian digunakan sebagai data *testing* dan sisanya digunakan sebagai data *training*. Untuk memberikan gambaran umum mengenai kinerja model, hasil dari setiap iterasi akan dihitung dan dirata-ratakan. Nilai *k* yang digunakan untuk setiap model pada penelitian ini adalah $k = 10$.

4.2 Hasil Uji Coba

Penelitian ini melakukan 9 kali uji coba dengan jumlah *node* pada *hidden layer* pertama dan nilai *learning rate* yang bervariasi sesuai skenario pengujian pada Tabel 4.1. Tujuan dari pengujian ini adalah menentukan jumlah *node* pada *hidden layer* pertama dan nilai *learning rate* yang memberikan hasil paling optimal untuk model klasifikasi.


4.2.1 Model X1

Model X1 menguji arsitektur *neural network* dengan 10 *node* pada *hidden layer* pertama dan *learning rate* sebesar 0,001. Proses *training* model X1 berhenti di *epoch* ke-65408 dalam waktu 181,52 detik. Nilai *loss* dan *accuracy* proses *training* dan proses *validation* ditunjukkan pada Gambar 4.1.




Gambar 4.1 Grafik *Loss* dan *Accuracy* (*Training & Validation*) Model X1

Berdasarkan pengujian pada proses *testing*, model X1 menghasilkan *confusion matrix* yang ditunjukkan pada Gambar 4.4 dimana model dapat memprediksi 74 data dengan benar dan 24 data diprediksi secara keliru.




Gambar 4.2 *Confusion Matrix* Model X1

Selanjutnya, dari Gambar 4.2 dihitung metrik evaluasi untuk mengukur performa model, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* berdasarkan Persamaan 4.1, 4.2, 4.3, dan 4.4. Hasil perhitungan tersebut direpresentasikan pada Gambar 4.3.



Gambar 4.3 *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model X1


Untuk mengevaluasi kinerja model pada berbagai variasi data, model X1 diuji menggunakan *k-fold cross validation* ($k = 10$) yang ditampilkan pada Gambar 4.6. Berdasarkan Gambar 4.4 diperoleh nilai rata-rata akurasi sebesar 0,7733 serta standar deviasi sebesar 0,0461.



Gambar 4.4 *Accuracy* Setiap *Fold* Model X1


4.2.2 Model X2

Model X2 menguji arsitektur *neural network* dengan 10 *node* pada *hidden layer* pertama dan *learning rate* sebesar 0,005. Proses *training* model X1 berhenti di *epoch* ke-34509 dalam waktu 51,45 detik. Nilai *loss* dan *accuracy* proses *training* dan proses *validation* ditampilkan pada Gambar 4.5.




Gambar 4.5 Grafik *Loss* dan *Accuracy* (*Training & Validation*) Model X2

Berdasarkan proses *testing*, model X2 menghasilkan *confusion matrix* yang ditunjukkan pada Gambar 4.6 dimana model dapat memprediksi 75 data dengan benar dan 23 data diprediksi secara keliru.




Gambar 4.6 *Confusion Matrix* Model X2

Selanjutnya, dari Gambar 4.6 dihitung metrik evaluasi untuk mengukur performa model, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* berdasarkan Persamaan 4.1, 4.2, 4.3, dan 4.4. Hasil perhitungan tersebut direpresentasikan pada Gambar 4.7.



Gambar 4.7 *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model X2


Untuk mengevaluasi kinerja model pada berbagai variasi data, model X2 akan diuji menggunakan *k-fold cross validation* ($k = 10$) yang ditampilkan pada Gambar 4.8. Berdasarkan Gambar 4.8 diperoleh nilai rata-rata akurasi sebesar 0,8215 dan standar deviasi sebesar 0,0361.



Gambar 4.8 *Accuracy* Setiap *Fold* Model X2


4.2.3 Model X3

Model X3 menguji arsitektur *neural network* dengan 10 *node* pada *hidden layer* pertama dan *learning rate* sebesar 0,01. Proses *training* model X3 berhenti di *epoch* ke-27276 dalam waktu 42,64 detik. Nilai *loss* dan *accuracy* proses *training* dan proses *validation* ditampilkan pada Gambar 4.9.




Gambar 4.9 Grafik *Loss* dan *Accuracy* (*Training & Validation*) Model X3

Berdasarkan pengujian pada proses *testing*, model X3 menghasilkan *confusion matrix* yang ditunjukkan pada Gambar 4.10 dimana model dapat memprediksi 76 data dengan benar dan 22 data diprediksi secara keliru.




Gambar 4.10 *Confusion Matrix* Model X3

Selanjutnya, dari Gambar 4.10 dihitung metrik evaluasi untuk mengukur performa model, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* berdasarkan Persamaan 4.1, 4.2, 4.3, dan 4.4. Hasil perhitungan tersebut direpresentasikan pada Gambar 4.11.



Gambar 4.11 *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model X3


Untuk mengevaluasi kinerja model pada berbagai variasi data, model X3 akan diuji menggunakan *k-fold cross validation* ($k = 10$) yang ditampilkan pada Gambar 4.12. Berdasarkan Gambar 4.12 diperoleh nilai rata-rata akurasi sebesar 0,8164 dan standar deviasi sebesar 0,0376.



Gambar 4.12 *Accuracy* Setiap *Fold* Model X3

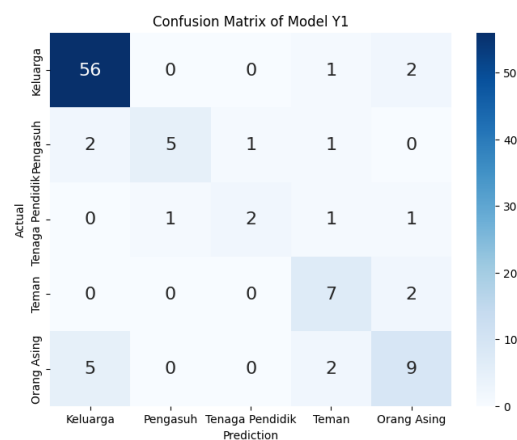
4.2.4 Model Y1

Model Y1 menguji arsitektur *neural network* dengan 30 *node* pada *hidden layer* pertama dan *learning rate* sebesar 0,001. Proses *training* model Y1 berhenti di *epoch* ke-67769 dalam waktu 144,78 detik. Nilai *loss* dan *accuracy* proses *training* dan proses *validation* ditampilkan pada Gambar 4.13.




Gambar 4.13 Grafik *Loss* dan *Accuracy* (*Training & Validation*) Model Y1

Berdasarkan pengujian pada proses *testing*, model Y1 menghasilkan *confusion matrix* yang ditunjukkan pada Gambar 4.14 dimana model dapat memprediksi 79 data dengan benar dan 19 data diprediksi secara keliru.




Gambar 4.14 *Confusion Matrix* Model Y1

Selanjutnya, dari Gambar 4.14 dihitung metrik evaluasi untuk mengukur performa model, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* berdasarkan Persamaan 4.1, 4.2, 4.3, dan 4.4. Hasil perhitungan tersebut direpresentasikan pada Gambar 4.15.



Gambar 4.15 *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model Y1


Untuk mengevaluasi kinerja model pada berbagai variasi data, model Y1 akan diuji menggunakan *k-fold cross validation* ($k = 10$) yang ditampilkan pada Gambar 4.16. Berdasarkan Gambar 4.16 diperoleh nilai rata-rata akurasi sebesar 0,7928 dan standar deviasi sebesar 0,0401.



Gambar 4.16 *Accuracy* Setiap *Fold* Model Y1

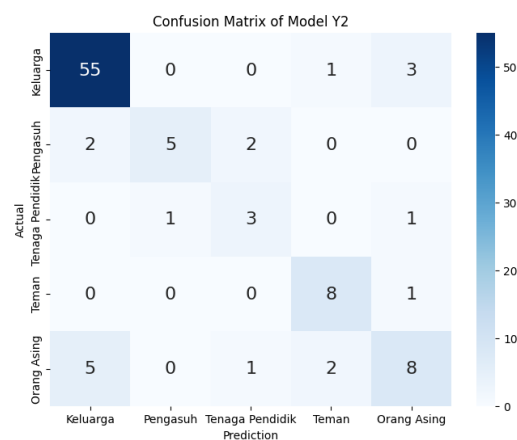
4.2.5 Model Y2

Model Y2 menguji arsitektur *neural network* dengan 30 *node* pada *hidden layer* pertama dan *learning rate* sebesar 0,005. Proses *training* model Y2 berhenti di *epoch* ke-31737 dalam waktu 73,18 detik. Nilai *loss* dan *accuracy* proses *training* dan proses *validation* ditampilkan pada Gambar 4.17.




Gambar 4.17 Grafik *Loss* dan *Accuracy* (*Training & Validation*) Model Y2

Berdasarkan pengujian pada proses *testing*, model Y2 menghasilkan *confusion matrix* yang ditunjukkan pada Gambar 4.18 dimana model dapat memprediksi 79 data dengan benar dan 19 data diprediksi secara keliru.




Gambar 4.18 *Confusion Matrix* Model Y2

Selanjutnya, dari Gambar 4.18 dihitung metrik evaluasi untuk mengukur performa model, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* berdasarkan Persamaan 4.1, 4.2, 4.3, dan 4.4. Hasil perhitungan tersebut direpresentasikan pada Gambar 4.19.



Gambar 4.19 *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model Y2


Untuk mengevaluasi kinerja model pada berbagai variasi data, model Y2 akan diuji menggunakan *k-fold cross validation* ($k = 10$) yang ditampilkan pada Gambar 4.22. Berdasarkan Gambar 4.20 diperoleh nilai rata-rata akurasi sebesar 0,8257 dan standar deviasi sebesar 0,0319.



Gambar 4.20 *Accuracy* Setiap *Fold* Model Y2


4.2.6 Model Y3

Model Y3 menguji arsitektur *neural network* dengan 30 *node* pada *hidden layer* pertama dan *learning rate* sebesar 0,01. Proses *training* model Y3 berhenti di *epoch* ke-26029 dalam waktu 105,09 detik. Nilai *loss* dan *accuracy* proses *training* dan proses *validation* ditampilkan pada Gambar 4.21.




Gambar 4.21 Grafik *Loss* dan *Accuracy* (*Training & Validation*) Model Y3

Berdasarkan pengujian pada proses *testing*, model Y3 menghasilkan *confusion matrix* yang ditunjukkan pada Gambar 4.22 dimana model dapat memprediksi 77 data dengan benar dan 21 data diprediksi secara keliru.




Gambar 4.22 *Confusion Matrix* Model Y3

Selanjutnya, dari Gambar 4.22 dihitung metrik evaluasi untuk mengukur performa model, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* berdasarkan Persamaan 4.1, 4.2, 4.3, dan 4.4. Hasil perhitungan tersebut direpresentasikan pada Gambar 4.23.



Gambar 4.23 *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model Y3

Untuk mengevaluasi kinerja model pada berbagai variasi data, model Y3 akan diuji menggunakan *k-fold cross validation* ($k = 10$) yang ditampilkan pada Gambar 4.26. Berdasarkan Gambar 4.24 diperoleh nilai rata-rata akurasi sebesar 0,8164 dan standar deviasi sebesar 0,0314.



Gambar 4.24 *Accuracy* Setiap *Fold* Model Y3


4.2.7 Model Z1

Model Z1 menguji arsitektur *neural network* dengan 60 *node* pada *hidden layer* pertama dan *learning rate* sebesar 0,001. Proses *training* model Y3 berhenti di *epoch* ke-64488 dalam waktu 284,53 detik. Nilai *loss* dan *accuracy* proses *training* dan proses *validation* ditampilkan pada Gambar 4.25.




Gambar 4.25 Grafik *Loss* dan *Accuracy* (*Training & Validation*) Model Z1

Berdasarkan pengujian pada proses *testing*, model Z1 menghasilkan *confusion matrix* yang ditunjukkan pada Gambar 4.26 dimana model dapat memprediksi 81 data dengan benar dan 17 data diprediksi secara keliru.




Gambar 4.26 *Confusion Matrix* Model Z1

Selanjutnya, dari Gambar 4.26 dihitung metrik evaluasi untuk mengukur performa model, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* berdasarkan Persamaan 4.1, 4.2, 4.3, dan 4.4. Hasil perhitungan tersebut direpresentasikan pada Gambar 4.27.



3" Gambar 4.27 *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model Z1


Untuk mengevaluasi kinerja model pada berbagai variasi data, model Z1 akan diuji menggunakan *k-fold cross validation* ($k = 10$) yang ditampilkan pada Gambar 4.28. Berdasarkan Gambar 4.28 diperoleh nilai rata-rata akurasi sebesar 0,7938 dan standar deviasi sebesar 0,0455.



Gambar 4.28 *Accuracy* Setiap *Fold* Model Z1


4.2.8 Model Z2

Model Z2 menguji arsitektur *neural network* dengan 60 node pada *hidden layer* pertama *learning rate* sebesar 0,005. Proses *training* model Z2 berhenti di *epoch* ke-31069 dalam waktu 160,51 detik. Nilai *loss* dan *accuracy* proses *training* dan proses *validation* ditampilkan pada Gambar 4.29.




Gambar 4.29 Grafik *Loss* dan *Accuracy* (*Training & Validation*) Model Z2

Berdasarkan pengujian pada proses *testing*, model Z2 menghasilkan *confusion matrix* yang ditunjukkan pada Gambar 4.30 dimana model dapat memprediksi 79 data dengan benar dan 19 data diprediksi secara keliru.




Gambar 4.30 *Confusion Matrix* Model Z2

Selanjutnya, dari Gambar 4.30 dihitung metrik evaluasi untuk mengukur performa model, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* berdasarkan Persamaan 4.1, 4.2, 4.3, dan 4.4. Hasil perhitungan tersebut direpresentasikan pada Gambar 4.31.



Gambar 4.31 *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model Z2


Untuk mengevaluasi kinerja model pada berbagai variasi data, model Z2 akan diuji menggunakan *k-fold cross validation* ($k = 10$) yang ditampilkan pada Gambar 4.32. Berdasarkan Gambar 4.32 diperoleh nilai rata-rata akurasi sebesar 0,8298 dan standar deviasi sebesar 0,0306.



Gambar 4.32 *Accuracy* Setiap *Fold* Model Z2


4.2.9 Model Z3

Model Z3 menguji arsitektur *neural network* dengan 60 *node* pada *hidden layer* pertama *learning rate* sebesar 0,01. Proses *training* model Z3 berhenti di *epoch* ke-26172 dalam waktu 139,76 detik. Nilai *loss* dan *accuracy* proses *training* dan proses *validation* ditampilkan pada Gambar 4.33.




Gambar 4.33 Grafik *Loss* dan *Accuracy* (*Training & Validation*) Model Z3

Berdasarkan pengujian pada proses *testing*, model Z3 menghasilkan *confusion matrix* yang ditunjukkan pada Gambar 4.34 dimana model dapat memprediksi 78 data dengan benar dan 20 data diprediksi secara keliru.




Gambar 4.34 *Confusion Matrix* Model Z3

Selanjutnya, dari Gambar 4.34 dihitung metrik evaluasi untuk mengukur performa model, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* berdasarkan Persamaan 4.1, 4.2, 4.3, dan 4.4. Hasil perhitungan tersebut direpresentasikan pada Gambar 4.35.



Gambar 4.35 *Accuracy*, *Precision*, *Recall*, dan *F1-Score* Model Z3

Untuk mengevaluasi kinerja model pada berbagai variasi data, model Z3 akan diuji menggunakan *k-fold cross validation* ($k = 10$) yang ditampilkan pada Gambar 4.36. Berdasarkan Gambar 4.36 diperoleh nilai rata-rata akurasi sebesar 0,8185 dan standar deviasi sebesar 0,0340.



Gambar 4.36 *Accuracy* Setiap *Fold* Model Z3

4.3 Pembahasan

Berdasarkan proses *training* yang telah dilakukan pada sembilan jenis model dengan kombinasi jumlah *node* pada *hidden layer* pertama dan nilai *learning rate* yang berbeda diperoleh hasil proses *training* yang tercantum pada Tabel 4.8.

Tabel 4.8 Hasil Proses *Training*

Model	Training		
	Cost	Epoch	Waktu (detik)
X1	0,109346	65408	181,52
X2	0,065319	34509	51,45
X3	0,051268	27276	42,64
Y1	0,103346	67769	144,78
Y2	0,064026	31737	73,18
Y3	0,049969	26029	105,09
Z1	0,102102	64488	284,53
Z2	0,062977	31069	160,51
Z3	0,048423	26172	139,76

Berdasarkan Tabel 4.8 terdapat 3 jenis variabel yang digunakan untuk membandingkan performa masing-masing model, yaitu *cost*, *epoch*, dan *waktu pelatihan*. Nilai *cost* digunakan untuk mengukur seberapa besar *error* yang dihasilkan model selama proses *training*. Semakin kecil nilai *cost*, semakin baik model dalam mempelajari pola dari data *training*. *Epoch* merepresentasikan jumlah iterasi yang dibutuhkan hingga model mencapai titik konvergen. Semakin sedikit jumlah *epoch* menunjukkan bahwa model lebih cepat mencapai kestabilan pembelajaran. Sementara itu, waktu pelatihan mencerminkan efisiensi komputasi yang dibutuhkan oleh masing-masing model.

Hasil proses pelatihan menunjukkan bahwa seluruh model menghasilkan nilai *cost* akhir yang relatif rendah, yakni berada pada kisaran antara 0,048 hingga 0,109. Hal ini mengindikasikan bahwa seluruh konfigurasi model mampu mempelajari pola data dengan cukup baik. Kemudian, peningkatan nilai *learning*

rate cenderung menghasilkan *cost* akhir yang lebih rendah serta jumlah *epoch* yang lebih sedikit. Hal ini terlihat dari perbandingan antara model dengan kode angka 1 hingga 3 dalam setiap kelompok variasi jumlah *node hidden layer* pertama (X1–X3, Y1–Y3, dan Z1–Z3). Misalnya pada kelompok X, peningkatan *learning rate* dari 0,001 (X1) menjadi 0,01 (X3) menurunkan nilai *cost* dari 0,109 menjadi 0,051 serta mengurangi jumlah *epoch* dari 65.408 menjadi 27.276. Pola penurunan serupa juga terjadi pada kelompok Y dan Z, yang memperlihatkan penurunan nilai *cost* dan jumlah *epoch* secara konsisten.

Selain itu, peningkatan jumlah *node* pada *hidden layer* pertama dari 10 (X) menjadi 30 (Y) hingga 60 (Z) juga memengaruhi durasi pelatihan. Model dengan jumlah *node hidden layer* pertama lebih banyak umumnya membutuhkan waktu pelatihan yang lebih lama. Hal ini terlihat pada model dengan *learning rate* 0,005 (X2, Y2, Z2) dan *learning rate* 0,01 (X3, Y3, Z3). Hal ini disebabkan oleh arsitektur model yang lebih kompleks sehingga memerlukan lebih banyak bobot dan parameter yang harus dihitung. Akibatnya, proses pelatihan membutuhkan waktu komputasi yang lebih besar.

Bobot dan bias yang didapatkan pada proses *training* akan digunakan untuk mengukur performa masing-masing model pada proses *testing* menggunakan metrik evaluasi yang meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik evaluasi ini digunakan untuk menilai sejauh mana model mampu melakukan klasifikasi secara akurat terhadap data baru. Evaluasi ini penting untuk memastikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data *testing*. Hasil proses testing dari setiap model ditunjukkan pada Tabel 4.9.

Tabel 4.9 Hasil Proses *Testing*

Model	Testing			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
X1	0,75510	0,67668	0,60366	0,62648
X2	0,76530	0,66351	0,66354	0,65025
X3	0,77551	0,67007	0,67604	0,66041
Y1	0,80612	0,72301	0,64899	0,67027
Y2	0,80612	0,71261	0,69532	0,69458
Y3	0,78571	0,68869	0,67943	0,67184
Z1	0,82653	0,77617	0,69238	0,72609
Z2	0,80612	0,70858	0,69532	0,68943
Z3	0,79591	0,69796	0,69193	0,68367

Berdasarkan Tabel 4.9 yaitu hasil evaluasi proses *testing* terhadap sembilan konfigurasi model menunjukkan bahwa nilai *accuracy* berkisar antara 0,755 hingga 0,826 yang menandakan bahwa model *neural network* cukup baik dalam mengklasifikasikan data baru. Model Z1 yang memiliki jumlah *node hidden layer* pertama sebanyak 60 dan *learning rate* sebesar 0,001 menghasilkan performa tertinggi dengan *accuracy* sebesar 0,82653, *precision* sebesar 0,77617, *recall* sebesar 0,69238, dan *F1-score* tertinggi sebesar 0,72609. Hal ini menunjukkan bahwa model Z1 mampu memberikan hasil klasifikasi yang paling seimbang antara *precision* dan *recall* serta memiliki kemampuan generalisasi yang baik terhadap data baru. Model dengan konfigurasi lebih sederhana seperti jumlah *node hidden layer* pertamanya berjumlah 10 (X1, X2, X3) cenderung memiliki performa yang lebih rendah dengan *accuracy* berkisar antara 0,755 hingga 0,775 dan *F1-score* terendah sebesar 0,626.

Secara umum peningkatan jumlah *node* pada *hidden layer* pertama berdampak positif terhadap performa model, meskipun tidak selalu linier. Misalnya pada kelompok *learning rate* 0,001, peningkatan jumlah *node hidden layer* pertama dari 10 (X1), 30 (Y1), dan 60 (Z1) meningkatkan *accuracy* dari 0,755 menjadi

0,826 serta *F1-score* dari 0,626 menjadi 0,726. Selain itu, *learning rate* juga berperan penting dalam performa model meskipun pengaruhnya tidak selalu konsisten di setiap kelompok jumlah *node*. Misalnya, pada kelompok X dengan jumlah *node hidden layer* pertama adalah 10, peningkatan *learning rate* dari 0,001 (X1) ke 0,01 (X3) justru meningkatkan *accuracy* dan *F1-score*. Hal ini menunjukkan bahwa untuk arsitektur yang lebih sederhana, *learning rate* yang lebih tinggi dapat membantu model belajar lebih efisien. Namun, pada kelompok dengan jumlah *node hidden layer* pertama adalah 60 (Z) *learning rate* yang terlalu tinggi yaitu Z3 justru menurunkan performa dibandingkan Z1. Hal ini menunjukkan bahwa pemilihan *learning rate* optimal sangat bergantung pada kompleksitas model yang digunakan. Oleh karena itu, diperlukan evaluasi tambahan untuk mengukur kestabilan model terhadap data yang bervariasi, salah satunya melalui *k-fold cross validation*.

Dalam penelitian ini, digunakan metode *k-fold cross validation* dengan $k = 10$ di mana dataset dibagi menjadi sepuluh bagian dan proses pelatihan serta pengujian dilakukan sebanyak sepuluh kali secara bergantian. Hasil dari *accuracy* setiap *fold* akan dihitung dan dirata-ratakan untuk memberikan gambaran kinerja model secara umum. Kemudian akan dihitung juga standar deviasi untuk mengukur seberapa konsisten atau stabil performa model pada variasi data setiap *fold*. Semakin kecil nilai standar deviasi maka semakin stabil model tersebut dalam menghasilkan akurasi yang tidak jauh berbeda di setiap *fold*. Tabel 4.10 menunjukkan hasil rata-rata *accuracy* dan standar deviasi dari pengujian *k-fold validation* setiap model.

Tabel 4.10 Hasil *K-Fold Cross Validation*

Model	Rata-rata <i>Accuracy</i>	Standar Deviasi
X1	0,7733	0,0461
X2	0,8215	0,0361
X3	0,8164	0,0376
Y1	0,7928	0,0401
Y2	0,8257	0,0319
Y3	0,8164	0,0314
Z1	0,7938	0,0455
Z2	0,8298	0,0306
Z3	0,8185	0,0340

Berdasarkan Tabel 4.10 menunjukkan bahwa semua model memiliki performa klasifikasi yang cukup baik dalam menyesuaikan diri pada berbagai variasi data, seperti yang ditunjukkan oleh rentang nilai rata-rata akurasi 0,773 – 0,8298 dan standar deviasi 0,0306 – 0,0461. Nilai standar deviasi yang relatif kecil menandakan bahwa model-model tersebut memiliki kestabilan yang baik dalam menghasilkan akurasi yang konsisten di setiap *fold*.

Model Z2 memperoleh rata-rata *accuracy* tertinggi sebesar 0,8298 dengan standar deviasi terkecil yaitu 0,0306. Hasil ini menunjukkan bahwa model Z2 tidak hanya akurat tetapi juga stabil saat diujikan pada berbagai variasi data. Kemudian, disusul oleh model Y2 dengan *accuracy* 0,8257 serta model X2 dengan *accuracy* 0,8215. Sementara itu, model Z1 yang memiliki performa *testing* terbaik berdasarkan Tabel 4.10, pada *k-fold cross validation* menunjukkan rata-rata *accuracy* sebesar 0,7938 dan standar deviasi sebesar 0,0455 yang sudah cukup baik. Hal ini mengindikasikan bahwa meskipun Z1 mampu memberikan hasil sangat baik pada data *testing*, performanya menurun ketika diuji pada berbagai subset data.

Konfigurasi model dengan *learning rate* 0,005 (X2, Y2, Z2) secara konsisten menghasilkan performa yang tinggi dan stabil di seluruh jumlah *node*

hidden layer. Di sisi lain, peningkatan jumlah *node hidden layer* dari 10 ke 60 juga memberikan peningkatan performa meskipun dalam jumlah kecil, terutama jika dikombinasikan dengan *learning rate* yang tepat. Model Z2 menjadi model paling unggul baik dari segi akurasi pada data *testing* sebesar 0,80612 dan *F1-score* sebesar 0,68943 serta memiliki stabilitas terbaik pada hasil *k-fold cross validation*.

Selanjutnya, analisis terhadap *learning curve* pada Gambar 4.1, 4.5, 4.9, 4.13, 4.17, 4.21, 4.25, 4.29, 4.33 memberikan pemahaman mengenai proses pembelajaran model terutama dalam mengidentifikasi adanya gejala *overfitting*, *underfitting*, atau sudah *good fit*. Berdasarkan *learning curve*, mayoritas model menunjukkan indikasi *overfitting* yang terlihat dari perbedaan signifikan antara *train accuracy* dan *validation accuracy*. Misalnya, model-model seperti X2, X3, Y2, Y3, Z2, dan Z3 memiliki *train accuracy* di atas 90%, sementara *validation accuracy* stagnan di kisaran 75 – 80%. Hal ini mengindikasikan bahwa model terlalu menyesuaikan diri terhadap data pelatihan sehingga kurang mampu melakukan generalisasi terhadap data validasi. Sementara itu, model X1, Y1, dan Z1 menunjukkan gejala *overfitting* ringan ditandai dengan selisih *train-validation accuracy* yang lebih kecil yaitu sekitar 5–8% serta grafik *validation accuracy* yang cenderung stabil tanpa penurunan tajam. Untuk mengatasi permasalahan *overfitting* tersebut dapat menerapkan penambahan *dropout*, mengurangi kompleksitas model, atau menambah jumlah data pelatihan untuk meningkatkan kemampuan generalisasi model.

Setelah model dikembangkan dan dievaluasi, dilakukan analisis terhadap data berita kasus kekerasan anak. Berdasarkan Gambar 3.2, terlihat bahwa kategori

pelaku kekerasan anak yang paling dominan berasal dari kalangan keluarga, dengan jumlah mencapai 498 berita. Temuan ini menunjukkan bahwa lingkungan terdekat yang seharusnya menjadi tempat perlindungan justru menjadi sumber utama terjadinya kekerasan terhadap anak. Kategori pelaku terbanyak berikutnya berasal dari orang asing sebanyak 168 berita, diikuti oleh teman, tenaga pendidik, dan terakhir pengasuh. Fakta ini mencerminkan bahwa anak-anak sangat rentan mengalami kekerasan, baik dari orang-orang yang memiliki kedekatan emosional dan tanggung jawab terhadap mereka.

Sebagai bagian dari eksplorasi data dilakukan visualisasi dalam bentuk *Wordcloud* untuk melihat kata-kata yang paling sering muncul dalam berita pada setiap kategori pelaku. Visualisasi ini memberikan gambaran mengenai konteks atau pola yang muncul di setiap jenis pelaku kekerasan anak. Kata-kata dominan pada kelas keluarga, pengasuh, teman, tenaga pendidik, dan orang asing ditunjukkan pada Gambar 4.37, 4.38, 4.39, 4.40, dan 4.41 berikut.



Gambar 4.37 *Wordcloud* Kelas Keluarga

Dalam kategori keluarga kata seperti “ayah”, “kandung”, dan “tiri” muncul cukup dominan menunjukkan keterlibatan orang tua dalam kekerasan anak. Kata-

kata seperti “perkosa”, “cabul”, “keras”, “aniaya”, dan “ancam” mengindikasikan bahwa bentuk kekerasan yang terjadi seringkali bersifat fisik dan seksual. Kata “rumah” berarti pelaku kekerasan seringkali melakukannya di rumah.



Gambar 4.38 Wordcloud Kelas Pengasuh

Kasus pada kategori pengasuh banyak berkaitan dengan *daycare* atau tempat penitipan anak. Kata “aniaya” dan “asuh” menunjukkan bahwa bentuk kekerasan cenderung berupa penganiayaan fisik akibat kelalaian atau perlakuan kasar.



Gambar 4.39 Wordcloud Kelas Tenaga Pendidik

Pada kategori tenaga pendidik, kata “guru”, “siswa”, dan “sekolah” menjadi ciri utama dengan tambahan kata seperti “cabul” dan “seksual” yang memperjelas

bentuk kekerasan cenderung pada pelecehan seksual oleh oknum guru atau pendidik terhadap murid di sekolah.



Gambar 4.40 *Wordcloud* Kelas Teman

Kategori teman didominasi oleh kata-kata yang berkaitan dengan lingkungan sekolah seperti “sekolah”, “siswa”, “runding”, dan “*bullying*” yang menandakan bahwa banyak kekerasan antar teman terjadi di area pendidikan, terutama dalam bentuk perundungan (*bullying*). Kata “video” juga cukup dominan, yang mengarah pada kejadian yang terekam dan viral di media sosial.



Gambar 4.41 *Wordcloud* Kelas Tenaga Orang Asing

Untuk kategori orang asing, kata-kata yang mencolok seperti “cabul” dan “pria” menunjukkan pola kekerasan seksual yang dilakukan oleh orang tak dikenal,

seringkali berupa pelecehan yang dilakukan oleh pria. Kata “video” juga menunjukkan bahwa beberapa kasus terekspose melalui rekaman.

Konsep klasifikasi untuk mengidentifikasi pelaku kekerasan dalam penelitian ini sejalan dengan firman Allah dalam menciptakan keragaman dan perbedaan diantara manusia yang terdapat dalam Q.S Ar-Rum ayat 22 sebagai berikut.

وَمِنْ آيَاتِهِ خَلْقُ السَّمُوتِ وَالْأَرْضِ وَالاخْتِلَافُ أَلْسِنَتِكُمْ وَالْوَانِكُمْ إِنَّ فِي ذَلِكَ لَآيَاتٍ لِّلْعَالَمِينَ ﴿٢٢﴾

"Dan diantara tanda-tanda (kebesaran)-Nya ialah penciptaan langit dan bumi, perbedaan bahasamu dan warna kulitmu. Sungguh pada yang demikian itu benar-benar terdapat tanda-tanda bagi orang-orang yang mengetahui" (Q.S Ar-Rum: 22) (Baihaqi et al., 2015).

Menurut tafsir Kementrian Agama RI, ayat ini menegaskan bahwa seluruh manusia berasal dari unsur yang sama, tetapi diciptakan dengan keragaman dan karakteristiknya masing-masing seperti perbedaan bahasa dan warna kulit sebagai bagian dari tanda-tanda kebesaran-Nya (Kemenag, 2022). Tafsir Al-Misbah menjelaskan bahwa bukti kekuasaan Allah dapat dilihat dari diri manusia, yaitu perbedaan lidah, bahasa, dialek, suara, intonasi, warna kulit, perbedaan malam dan siang serta perbedaan musim (Shihab, 2002a). Kemudian, menurut Ibnu Katsir Allah menciptakan seluruh penduduk bumi dari Adam hingga hari kiamat tanpa kesamaan hidung, alis, wajah dan anggota tubuh lainnya sebagai bukti keunikan ciptaan-Nya (Al-Syeikh, 2004b). Keragaman yang Allah tunjukkan selaras dengan konsep klasifikasi dalam penelitian ini, dimana setiap pelaku kekerasan memiliki

karakteristik tindakan dan pola yang berbeda meskipun mereka berasal dari satu wilayah atau budaya yang sama.

Selain itu, Q.S Al-Isra ayat 84 juga menjelaskan bahwa manusia memiliki watak dan perilaku yang khas. Ayat tersebut berbunyi:

قُلْ كُلٌّ يَعْمَلُ عَلَىٰ شَاكِلَتِهِ ۖ فَرُبُّكُمْ أَعْلَمُ بِمَنْ هُوَ أَهْدَىٰ سَبِيلًا ۝ (٨٤)

"Katakanlah (Muhammad), "Setiap orang berbuat sesuai dengan pembawaannya masing-masing." Maka, Tuhanmu lebih mengetahui siapa yang lebih benar jalannya." (Q.S Al-Isra: 84) (Baihaqi et al., 2015).

Tafsir Tahlili menjelaskan bahwa ayat ini berisi perintah Allah kepada Nabi Muhammad agar umatnya bekerja atau berbuat sesuai dengan potensi, tabiat, dan kecenderungan mereka masing-masing (Kemenag, 2022). Tafsir Al-Misbah menyatakan bahwa kecenderungan bawaan ini menjadi pendorong aktivitas manusia dan Allah mengetahui siapa yang berbuat baik dan siapa yang berbuat sesat (Shihab, 2002c). Dalam tafsir Ibnu Katsir makna "berbuat menurut keadaanya masing-masing" ada beberapa pendapat, seperti Ibnu Abbas memaknainya sebagai "dalam posisinya", Qatadah menyatakan "menurut niatnya", serta Ibnu Zaid menyatakan "menurut agamanya", dan Allah akan memberikan balasan sesuai apa yang diperbuat manusia (Al-Syeikh, 2004a). Hal ini menguatkan bahwa perilaku pelaku kekerasan tidak bersifat seragam, melainkan dipengaruhi oleh relasi, motif, dan kondisi personal yang khas.

Selanjutnya, Allah juga menerangkan tentang bagaimana karakteristik orang yang tidak berada dalam kerugian yaitu pada Q.S Al-'Ashr ayat 2-3.

إِنَّ الْإِنْسَانَ لَفِي خُسْرٍ ﴿٢﴾ إِلَّا الَّذِينَ آمَنُوا وَعَمِلُوا الصَّالِحَاتِ وَتَوَاصَوْا بِالْحَقِّ وَتَوَاصَوْا بِالصَّبْرِ ﴿٣﴾

"Sungguh manusia berada dalam kerugian. Kecuali orang-orang yang beriman dan mengerjakan kebajikan serta saling menasihati untuk kebenaran dan saling menasehati untuk kesabaran" (Q.S Al-‘Ashr: 2-3) (Baihaqi et al., 2015).

Menurut Ibnu Katsir, ciri-ciri orang tidak merugi adalah mereka yang beriman dengan hati mereka, mengerjakan amal saleh melalui anggota tubuhnya, saling menasihati dalam kebenaran, yakni menaati perintah Allah dan menjauhi larangan-Nya, serta saling menasihati dalam kesabaran, yaitu tetap tabah dalam menghadapi musibah dan ujian, serta menjauhi segala bentuk maksiat kepada-Nya (Al-Syeikh, 2004d). Kementerian Agama RI menyampaikan bahwa pada dasarnya seluruh manusia berada dalam kerugian, kecuali mereka yang benar-benar beriman, melakukan amal kebaikan dengan ikhlas sesuai syariat, serta saling menasihati dengan cara yang baik dan bijaksana agar tetap teguh dalam kebenaran ajaran agama, dan bersabar dalam menjalani kehidupan (Kemenag, 2022). Tafsir Al-Misbah menjelaskan bahwa manusia merugi kecuali yang melakukan empat kegiatan pokok, yaitu orang-orang yang beriman dan beramal sholeh yakni yang bermanfaat, serta saling berwasiat tentang kebenaran dan ketabahan. Berwasiat dalam kebenaran maksudnya bahwa seseorang belum terbebas dari beriman, beramal sholeh, dan mengetahui kebenaran itu untuk dirinya, tetapi ia berkewajiban untuk mengajarkannya kepada orang lain (Shihab, 2002d).

Sesuai dengan Q.S Al-‘Ashr ayat 2-3, hasil penelitian ini juga menunjukkan bahwa setiap pelaku kekerasan memiliki ciri khas dan karakteristik dalam melakukan kekerasan terhadap anak yang dapat dikenali melalui analisis *wordcloud* pada masing-masing kategori. Misalnya, kategori keluarga cenderung melibatkan

orang tua kandung atau tiri dan terjadi di rumah dengan bentuk kekerasan fisik maupun seksual. Kategori pengasuh menampilkan pola kekerasan akibat kelalaian atau kekerasan fisik di tempat penitipan anak. Sementara itu, kategori tenaga pendidik sering berkaitan dengan pelecehan seksual oleh oknum guru di lingkungan sekolah. Kategori teman didominasi oleh bentuk *bullying* di sekolah yang sering kali terekam dalam video dan tersebar di media sosial. Adapun kategori orang asing menunjukkan kecenderungan kekerasan seksual oleh pria yang tidak dikenal dan sering kali dapat dikenali melalui dokumentasi visual yang beredar.

Dengan mengetahui pola kekerasan yang khas pada setiap kategori pelaku, diharapkan penelitian ini dapat memberikan kontribusi dalam merancang strategi pencegahan dan perlindungan anak yang lebih tepat sasaran. Informasi ini memungkinkan lembaga perlindungan anak dan aparat penegak hukum untuk mengambil langkah-langkah yang lebih efektif sesuai dengan karakteristik masing-masing pelaku.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang dilakukan terhadap sembilan konfigurasi model *neural network*, metode ini menunjukkan performa yang baik dalam mengidentifikasi relasi korban dengan pelaku tindak kekerasan anak berdasarkan berita *online*. Seluruh model menghasilkan nilai akurasi yang cukup tinggi pada proses *testing*, yaitu berkisar antara 0,755 hingga 0,826, serta nilai *F1-score* antara 0,626 hingga 0,726 yang mencerminkan keseimbangan antara *precision* dan *recall*. Model Z2 yang memiliki jumlah *node hidden layer* pertama sebanyak 60 dan *learning rate* sebesar 0,005 dapat dikategorikan sebagai model terbaik. Model ini mencapai *accuracy* sebesar 0,80612 dan *F1-score* sebesar 0,68943 pada data *testing*, serta menunjukkan rata-rata *accuracy* tertinggi sebesar 0,8298 dan standar deviasi terkecil sebesar 0,0306 pada pengujian *k-fold cross validation*. Hasil tersebut menunjukkan bahwa model Z2 tidak hanya memiliki performa klasifikasi yang tinggi terhadap data baru, tetapi juga konsisten dan stabil pada variasi data yang berbeda. Dengan demikian, dapat disimpulkan bahwa metode *neural network* efektif dan andal dalam melakukan klasifikasi relasi korban dan pelaku kekerasan anak dari teks berita *online*.

5.2 Saran

Penelitian mengenai identifikasi relasi korban dengan pelaku tindak kekerasan anak berbasis *text classification* menggunakan *neural network* masih

memiliki potensi untuk penelitian lebih lanjut. Terdapat beberapa saran yang dapat dipertimbangkan untuk penelitian berikutnya, antara lain:

1. Mengumpulkan data berita yang lebih beragam dan dalam jumlah yang lebih besar sehingga membantu meningkatkan performa dan generalisasi model, khususnya dalam menangani variasi gaya bahasa dan istilah dalam berita.
2. Mempertimbangkan metode ekstraksi fitur lainnya, seperti *GloVe*, *FastText*, atau BERT untuk menangkap konteks semantik dari kalimat dengan lebih baik.
3. Menggunakan arsitektur *neural network* yang lebih lain, seperti LSTM, GRU, atau *Transformer* agar dapat menangkap konteks bahasa dan hubungan antar kata secara lebih mendalam serta meningkatkan performa model.

DAFTAR PUSTAKA

- Al-Syeikh, A. bin M. bin A. bin I. (2004a). *Tafsir Ibnu Katsir Jilid 5* (M. A. Ghoffar & A. I. Al-Atsari, Trans.). Pustaka Imam Asy-Syafi'i.
- Al-Syeikh, A. bin M. bin A. bin I. (2004b). *Tafsir Ibnu Katsir Jilid 6* (M. A. Ghoffar & A. I. Al-Atsari, Trans.). Pustaka Imam Asy-Syafi'i.
- Al-Syeikh, A. bin M. bin A. bin I. (2004c). *Tafsir Ibnu Katsir Jilid 7* (M. A. Ghoffar & A. I. Al-Atsari, Trans.). Pustaka Imam Asy-Syafi'i.
- Al-Syeikh, A. bin M. bin A. bin I. (2004d). *Tafsir Ibnu Katsir Jilid 8* (M. A. Ghoffar & A. I. Al-Atsari, Trans.). Pustaka Imam Asy-Syafi'i.
- Annapragada, A. V., Donaruma-Kwoh, M. M., Annapragada, A. V., & Starosolski, Z. A. (2021). A natural language processing and deep learning approach to identify child abuse from pediatric electronic medical records. *PLOS ONE*, 16(2), e0247404. <https://doi.org/10.1371/journal.pone.0247404>
- Arpandi, A. (2023). Media Online dalam Meningkatkan Partisipasi Politik Masyarakat pada Pemilihan Umum (Pemilu). *EDU SOCIETY: JURNAL PENDIDIKAN, ILMU SOSIAL DAN PENGABDIAN KEPADA MASYARAKAT*, 3(1), 843–855. <https://doi.org/10.56832/edu.v3i1.293>
- Baihaqi, A. F. Al, Ardiansah, D., Chafizh, A., Saefuddin, Rahman, F., Hikmatiar, N., & Firmansyah. (2015). *Al-Hilali: Mushaf Al-Qur'an & Terjemah Tanpa Takwil Asma Wa Sifat*. PT. Insan Media Pustaka.
- Dachi, J. M. A. S., & Sitompul, P. (2023). Analisis Perbandingan Algoritma XGBoost dan Algoritma Random Forest Ensemble Learning pada Klasifikasi Keputusan Kredit. *JURNAL RISET RUMPUN MATEMATIKA DAN ILMU PENGETAHUAN ALAM*, 2(2), 87–103. <https://doi.org/10.55606/jurrimipa.v2i2.1470>
- Deng, T. (2023). Effect of the Number of Hidden Layer Neurons on the Accuracy of the Back Propagation Neural Network. *Highlights in Science, Engineering and Technology*, 74, 462–468. <https://doi.org/10.54097/nbra6h45>
- Efrizoni, L., Defit, S., Tajuddin, M., & Anggrawan, A. (2022). Komparasi Ekstraksi Fitur dalam Klasifikasi Teks Multilabel Menggunakan Algoritma Machine Learning. *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 21(3), 653–666. <https://doi.org/10.30812/matrik.v21i3.1851>
- Euis Saraswati, Yuyun Umaidah, & Apriade Voutama. (2021). Penerapan Algoritma Artificial Neural Network untuk Klasifikasi Opini Publik Terhadap

- Covid-19. *Generation Journal*, 5(2), 109–118.
<https://doi.org/10.29407/gj.v5i2.16125>
- Fanani Rudi, M., & Fikriah Katul, F. (2023). Seleksi Fitur PSO untuk Klasifikasi Jenis Kekerasan dengan Algoritma C4.5. *Smart Comp: Jurnalnya Orang Pintar Komputer*, 12(1). <https://doi.org/10.30591/smartcomp.v12i1.4407>
- Ferrario, A., & Naegelin, M. (2020). The Art of Natural Language Processing: Classical, Modern and Contemporary Approaches to Text Document Classification. *SSRN Electronic Journal*.
<https://doi.org/10.2139/ssrn.3547887>
- Flaherty, C. W., & Patterson, D. A. (2003). Predicting Child Physical Abuse Recurrence: Comparison of a Neural Network to Logistic Regression. *Journal of Technology in Human Services*, 21(4), 93–111.
https://doi.org/10.1300/J017v21n04_06
- Geetha, Dr. V, Gomathy, D. C. K., Vallab Yaratha Yagn, Mr. D. S. D., & Praneesh, S. (2023). THE ROLE OF NATURAL LANGUAGE PROCESSING. *INTERANTIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*, 07(11), 1–11.
<https://doi.org/10.55041/IJSREM27094>
- Hasanah, U., Astuti, T., Wahyudi, R., Rifai, Z., & Pambudi, R. A. (2018). An Experimental Study of Text Preprocessing Techniques for Automatic Short Answer Grading in Indonesian. *2018 3rd International Conference on Information Technology, Information System and Electrical Engineering (ICITISEE)*, 230–234. <https://doi.org/10.1109/ICITISEE.2018.8720957>
- Haykin, S. S. (1999). *Neural Networks: A Comprehensive Foundation* (2nd ed.). Prentice Hall.
- Heaton, J. (2008). *Introduction to Neural Networks with Java*. Heaton Research, Inc.
- Humaira B, D., Rohmah, N., Rifanda, N., Novitasari, K., Diena H, U., & Nuqul, F. L. (2015). Kekerasan Seksual Padaanak: Telaah Relasi Pelaku Korban Dan Kerentanan Pada Anak. *Psikoislamika : Jurnal Psikologi Dan Psikologi Islam*, 12(2), 5. <https://doi.org/10.18860/psi.v12i2.6398>
- Kemenag. (2022). *Quran Kemenag*. <https://quran.kemenag.go.id/>
- Kim, D. H., & MacKinnon, T. (2018). Artificial intelligence in fracture detection: transfer learning from deep convolutional neural networks. *Clinical Radiology*, 73(5), 439–445. <https://doi.org/10.1016/j.crad.2017.11.015>

- KPAI. (2023a). *Data Kasus Perlindungan Anak dari Media Tahun 2023*. Bankdata.Kpai.Go.Id. <https://bankdata.kpai.go.id/tabulasi-data/data-kasus-perlindungan-anak-dari-media-tahun-2023>
- KPAI. (2023b). *Data Kasus Perlindungan Anak dari Pengaduan ke KPAI Tahun 2023*. Bankdata.Kpai.Go.Id. <https://bankdata.kpai.go.id/tabulasi-data/data-kasus-perlindungan-anak-dari-pengaduan-ke-kpai-tahun-2023>
- Kurniasari, A. (2019). DAMPAK KEKERASAN PADA KEPERIBADIAN ANAK. *Sosio Informa*, 5(1). <https://doi.org/10.33007/inf.v5i1.1594>
- Kurniawan, F. W., & Maharani, W. (2020). Analisis Sentimen Twitter Bahasa Indonesia dengan Word2Vec. *E-Proceeding of Engineering*, 7(2), 7821–7829.
- Liang, H., Sun, X., Sun, Y., & Gao, Y. (2017). Text feature extraction based on deep learning: a review. *EURASIP Journal on Wireless Communications and Networking*, 2017(1), 211. <https://doi.org/10.1186/s13638-017-0993-1>
- Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., & Dean, J. (2013). Distributed Representations of Words and Phrases and their Compositionality. *Neural Information Processing Systems*. <https://api.semanticscholar.org/CorpusID:16447573>
- Mousavirad, S. J., Schaefer, G., Jalali, S. M. J., & Korovin, I. (2020). A benchmark of recent population-based metaheuristic algorithms for multi-layer neural network training. *Proceedings of the 2020 Genetic and Evolutionary Computation Conference Companion*, 1402–1408. <https://doi.org/10.1145/3377929.3398144>
- Mozin, N., & Sunge, M. (2021). PEMBERIAN EDUKASI DAN BANTUAN HUKUM TERHADAP ANAK KORBAN KEKERASAN. *Jurnal Ius Constituendum*, 6(1), 166. <https://doi.org/10.26623/jic.v6i1.2485>
- Najiyah, I. (2023). ANALISIS SENTIMEN TANGGAPAN MASYARAKAT INDONESIA TENTANG KENAIKAN BBM MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORK. *Jurnal Responsif: Riset Sains Dan Informatika*, 5(1), 92–100. <https://doi.org/10.51977/jti.v5i1.1061>
- Nurdin, A., Anggo Seno Aji, B., Bustamin, A., & Abidin, Z. (2020). PERBANDINGAN KINERJA WORD EMBEDDING WORD2VEC, GLOVE, DAN FASTTEXT PADA KLASIFIKASI TEKS. *Jurnal Tekno Kompak*, 14(2), 74. <https://doi.org/10.33365/jtk.v14i2.732>
- Pradana, D., Luthfi Alghifari, M., Farhan Juna, M., & Palaguna, D. (2022). Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network. *Indonesian Journal of Data and Science*, 3(2), 55–60. <https://doi.org/10.56705/ijodas.v3i2.35>

- Putu, N. L. P. M., Ahmad Zuli Amrullah, & Ismarmiaty. (2021). Analisis Sentimen dan Pemodelan Topik Pariwisata Lombok Menggunakan Algoritma Naive Bayes dan Latent Dirichlet Allocation. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 123–131. <https://doi.org/10.29207/resti.v5i1.2587>
- Ridwansyah, T. (2022). Implementasi Text Mining Terhadap Analisis Sentimen Masyarakat Dunia Di Twitter Terhadap Kota Medan Menggunakan K-Fold Cross Validation Dan Naïve Bayes Classifier. *KLIK: Kajian Ilmiah Informatika Dan Komputer*, 2(5), 178–185. <https://doi.org/10.30865/klik.v2i5.362>
- Shahi, N., Shahi, A. K., Phillips, R., Shirek, G., Lindberg, D. M., & Moulton, S. L. (2021). Using deep learning and natural language processing models to detect child physical abuse. *Journal of Pediatric Surgery*, 56(12), 2326–2332. <https://doi.org/10.1016/j.jpedsurg.2021.03.007>
- Shihab, M. Q. (2002a). *Tafsir Al Mishbah: Pesan Kesan dan Keserasian Al-Qur'an* (Vol. 11). Lentera Hati.
- Shihab, M. Q. (2002b). *Tafsir Al Mishbah: Pesan Kesan dan Keserasian Al-Qur'an* (Vol. 13). Lentera Hati.
- Shihab, M. Q. (2002c). *Tafsir Al Mishbah: Pesan Kesan dan Keserasian Al-Qur'an* (Vol. 7). Lentera Hati.
- Shihab, M. Q. (2002d). *Tafsir Al Mishbah: Pesan Kesan dan Keserasian Al-Qur'an* (Vol. 15). Lentera Hati.
- SIMFONI-PPA. (2024). *Data Kasus Kekerasan di Indonesia*. SIMFONI-PPA. <https://kekerasan.kemenpppa.go.id/ringkasan>
- Subroto, G., Sulistiyowati, N., & Ridha, A. A. (2022). Klasifikasi Jenis Kekerasan Pada Perempuan Dan Anak Dengan Algoritma Multinomial Naïve Bayes. *INTECOMS: Journal of Information Technology and Computer Science*, 5(1), 104–113. <https://doi.org/10.31539/intecom.v5i1.3598>
- Tasya. (2024). *Psikolog UGM: Pelaku Kekerasan Anak Cenderung Punya Gangguan Kesehatan Mental*. Ugm.Ac.Id. <https://ugm.ac.id/id/berita/psikolog-ugm-pelaku-kekerasan-anak-cenderung-punya-gangguan-kesehatan-mental/>
- Tripathi, K., Vyas, R. G., & Gupta, A. K. (2019). Document Classification Using Artificial Neural Network. *Asian Journal of Computer Science and Technology*, 8(2), 55–58. <https://doi.org/10.51983/ajcst-2019.8.2.2140>
- UNICEF. (n.d.). *Violence against children*. UNICEF. Retrieved June 11, 2025, from <https://www.unicef.org/protection/violence-against-children>

- Utama, T. S. C., Pasaribu, J., & Anggraeni, L. D. (2020). PERSEPSI IBU TENTANG KEKERASAN PADA ANAK TODDLER DAN PRESCHOOL. *Jurnal Ilmu Keperawatan Komunitas*, 3(1), 28–34. <https://doi.org/https://doi.org/10.32584/jikk.v3i1.561>
- Wahyudi, T. S., & Kushartono, T. (2020). PERLINDUNGAN HUKUM TERHADAP HAK ANAK YANG MENJADI KORBAN PERLAKUAN TINDAK KEKERASAN DALAM RUMAH TANGGA DIHUBUNGKAN DENGAN UNDANG-UNDANG NOMOR 35 TAHUN 2014 TENTANG PERUBAHAN ATAS UNDANG-UNDANG NOMOR 23 TAHUN 2002 TENTANG PERLINDUNGAN ANAK. *Jurnal Dialektika Hukum*, 2(1), 57–82. <https://doi.org/10.36859/jdh.v2i1.510>
- Yilmaz, S., & Toklu, S. (2020). A deep learning analysis on question classification task using Word2vec representations. *Neural Computing and Applications*, 32(7), 2909–2928. <https://doi.org/10.1007/s00521-020-04725-w>
- Zaghloul, W., Lee, S. M., & Trimi, S. (2009). Text classification: neural networks vs support vector machines. *Industrial Management & Data Systems*, 109(5), 708–717. <https://doi.org/10.1108/02635570910957669>
- Zandi, I. (2001). Use of artificial neural network as a risk assessment tool in preventing child abuse. *IJCNN'01. International Joint Conference on Neural Networks. Proceedings (Cat. No.01CH37222)*, 1438–1442. <https://doi.org/10.1109/IJCNN.2001.939573>