Implementasi IndoBERT untuk Klasifikasi Risiko Bunuh Diri sebagai Sistem Pendukung Keputusan Psikolog

1st Rafi Arifiansyah
Program Studi Teknologi Informasi
Universitas Telkom, Kampus Surabaya
Surabaya, Indonesia
rafiars@student.telkomuniversity.ac.id

2nd Farah Zakiyah Rahmanti
Program Studi Teknologi Informasi
Universitas Telkom, Kampus Surabaya
Surabaya, Indonesia
farahzakiyah@telkomuniversity.ac.id

3nd Yohanes Setiawan
Program Studi Teknologi Informasi
Universitas Telkom, Kampus Surabaya
Surabaya, Indonesia
yohanessetiawan@telkomuniversity.ac.id

***Abstrak* — Risiko bunuh diri merupakan permasalahan kesehatan mental yang memerlukan deteksi dini untuk mencegah dampak fatal. Pada layanan kesehatan Tingkat pertama seperti puskesmas, asesmen psikologis umumnya menggunakan *Beck Depression Inventory* (BDI) dan analisis keluhan pasien secara manual sehingga proses skrining memerlukan waktu dan berpotensi menimbulkan subjektivitas. Penelitian ini mengembangkan sistem pendukung keputusan berbasis website yang mengintegrasikan hasil asesmen BDI dan analisis teks keluhan pasien menggunakan model IndoBERT berbasis *Natural Language Processing* (NLP). Model digunakan untuk mengklasifikasikan teks keluhan berbahasa Indonesia ke dalam dua kategori, yaitu Low Risk dan *High Risk*. Tahapan penelitian meliputi *preprocessing*, augmentasi data, tokenisasi, *fine-tuning* model, evaluasi, dan implementasi pada website. Evaluasi dilakukan menggunakan *confusion matrix* dengan metrik *accuracy, precision, recall,* dan *F1-score*. Hasil eksperimen menunjukkan konfigurasi terbaik diperoleh pada *learning rate* 2×10^{-5}, *batch size* 16, dan 3 *epoch*, dengan *accuracy* 81,08%, *precision* 76,92%, *recall* 71,43%, dan *Macro F1-score* 79,59%. Hasil penelitian menunjukkan bahwa IndoBERT mampu mengklasifikasikan Risiko bunuh diri pada teks berbahasa Indonesia dengan baik serta berhasil diimplementasikan Risiko bunuh diri pada teks berbahasa Indonesia dengan baik serta berhasil diimplementasikan dalam sistem pendukung Keputusan berbasis website untuk mendukung skrining awal yang lebih cepat.*

***Kata kunci*— Beck Depression Inventory, IndoBERT, natural language processing, suicidal ideation, sistem pendukung keputusan**

I. PENDAHULUAN

Kesehatan mental merupakan salah satu aspek fundamental dalam menentukan kualitas hidup individu dan kesejahteraan masyarakat secara keseluruhan [1]. Gangguan kesehatan mental tidak hanya berdampak pada kondisi psikologis seseorang, tetapi juga berpengaruh terhadap fungsi sosial, produktivitas, serta risiko munculnya berbagai perilaku berbahaya [2]. Salah satu gangguan kesehatan mental yang paling umum dan memiliki dampak serius Adalah depresi. World Health Organization (WHO) menyatakan bahwa depresi merupakan gangguan mental yang ditandai dengan perasaan sedih berkepanjangan, kehilangan minat, serta penurunan energi yang signifikan, sehingga dapayt menganggu aktivitas sehari-hari individu. WHO juga mela;porkan salah satu gangguan kesehatan mental denganm prevelensi tertinggi secara global [3]. Kondisi ini menunjukkan bahwa depresi bukan merupakan permasalahan individual semata, melainkan ini kesehatan masyarakat yang memerlukan perhatian serius.

Depresi memiliki hubungan yang erat dengan munculnya pikiran menyakiti sendiri (*self-harm*) dan ide bunuh diri (*suicidal ideation*) [4]. Individu yang mengalami depresi, terutama pada tingkat berat, cenderung memiliki pola pikir negatif terhadap diri sendiri, masa depan, dan lingkungan sekitarnya. Pola pikir tersebut dapat berkembang menjadi perasaan putus asa, tidak memiliki harapan, serta keyakinan bahwa hidup tidak lagi bermakna [5]. Dalam banyak kasus, ide bunuh diri merupakan fase awal yang mendahului perilaku bunuh diri yang lebih serius apabila tidak mendapatkan perhatian, pemantauan, dan intervensi yang tepat dari tenaga kesehatan [6]. Bunuh diri merupakan masalah kesehatan mental global yang semakin mengkhawatirkan, dengan lebih 727.000 kasus kematian setiap tahunnya pada tahun 2021 [7]. Menurut data Kementerian Kesehatan RI dan Polri, di Indonesia, prevalensi kematian akibat bunuh diri juga semakin meningkat pada tahun 2023, yakni mencapai 1.350 kasus, dari 826 kasus pada tahun sebelumnya [8].

Puskesmas sebagai fasilitas pelayanan kesehatan tingkat pertama memiliki peran strategis dalam upaya promotive dan preventif kesehatan mental di masyarakat. Sebagai garda terdepan layanan keehatan, puskesmas menjadi tempat pertama bagi masyarakat untuk memperoleh layanan kesehatan jiwa dasar, termasuk skrining awal gangguan mental, emosional, depresi, serta risiko bunuh diri. Namun, besarnya peran tersebut belum sepenuhnya diimbangi dengan ketersediaan sumber daya dan dukungan sistem yang optimal. Kondisi tersebut juga tercermin pada layanan kesehatan jiwa di tingkat puskesmas secara lokal, termasuk di Kota Surabaya. Puskesmas Sidosermo sebagai salah satu fasilitas pelayanan Kesehatan di Kota Surabaya yang

memiliki peran penting dalam penyediaan layanan kesehatan jiwa bagi masyarakat di wilayah Sidosermo. Layanan psikologi / poli psikolog di Puskesmas Sidosermo menangani berbagai permasalahan kesehatan mental, seperti depresi, kecemasan, serta permasalahan psikologis lainnya yang dialami oleh kelompok usia anak maupun dewasa. Dalam praktik sehari-hari, psikolog di Puskesmas Sidosermo berperan sebagai tenaga profesional yang melakukan asesmen awal, observasi klinis, serta menentukan kebutuhan intervensi atau rujukan lanjutan bagi pasien. Namun, proses asesmen di Puskesmas Sidosermo masih bergantung pada metode manual menggunakan kuesioner kertas, dimana psikolog menghitung skor secara manual untuk mengkategorikan tingkat depresi.

Penelitian oleh [9] menunjukkan bahwa pemanfaatan kecerdasan buatan berbasis *Natural Language Processing* (NLP) mampu meningkatkan efektivitas klasifikasi data teks pada domain kesehatan. Model bahasa pra-latih seperti IndoBERT terbukti memiliki kemampuan yang baik dalam memahami konteks bahasa Indonesia, sehingga berpotensi digunakan untuk membantu analisis data psikologis berbasis teks sebagai sistem pendukung keputusan. Penelitian lain oleh [10] memperkenalkan IndoBERT sebagai model bahasa pra-latih yang dirancang khusus untuk bahasa Indonesia dan menunjukkan perfoma yang unggul dibandingkan metode pembelajaran mesin konvensional pada berbagai tugas klasifikasi teks. Kemampuan IndoBERT dalam menangkap konteks sementik secara dua arah menjadikannya relavan untuk diimplementasikan pada data hasil instrument psikologis, seperti *Beck Depression Inventory* (BDI), yang mengandung pernyataan subjektif mengenai kondisi emosional individu.

II. KAJIAN TEORI

A. Kesehatan Mental

Kesehatan mental merupakan komponen penting dari kesehatan secara keseluruhan yang mencakup kesejahteraan emosional, psikologis, dan sosial individu. Menurut Kementerian Kesehatan Republik Indonesia, kesehatan mental yang baik adalah kondisi ketika seseorang mampu menikmati kehidupan sehari-hari, memanfaatkan potemsi dirinya secara optimal. Sebaliknya, gangguan emosi dan penurunan kemampuan mengendalikan diri yang berdampak pada produktivitas serta kualitas hidup [11]. World Health Organization mendefinisikan kesehatan mental sebagai kondisi ketika individu mampu menyadari potensinya, mengatasi tekanan hidup, bekerja secara produktif, dan berkontribusi kepada masyarakat [12].

B. Depresi

Depresi merupakan salah satu gangguan kesehatan mental yang paling umum dan berdampak signifikan terhadap kualitas hidup individu. Kondisi ini ditandai oleh perasaan sedih yang berkepanjangan, hilangnya minat terhadap aktivitas, serta penurunan energi yang memengaruhi aspek emosional, kognitif perilaku, dan fisik. Menurut World Health Organization, depresi dapat memengaruhi cara seseorang berpikir, merasakan, dan bertindak sehingga menganggu fungsi sosial maupun produktivitas sehari-hari. Berdasarkan American Psychiatric Association [13], gejala utama depresi meliputi perasaan sedih yang mendalam kehilangan minat atau kesenangan, gangguan tidur, kesulitan berkonsentrasi, serta munculnya perasaan bersalah atau tidak berharga. Depresi juga berkaitan dengan perilaku *self-harm* dan *suicidal ideation.* Individu yang mengalami depresi sering kali merasakan tekanan emosional dan keputusasaan (hopelessness) yang meningkatkan risiko bunuh diri apabila tidak memperoleh penanganan yang tepat [14].

C. Risiko Bunuh Diri (*Suicidal Ideation*)

Bunuh diri merupakan fenomena kompleks yang dipengaruhi oleh faktor psikologis, emosional, sosial, dan lingkungan. Menurut American Psychological Association (APA), bunuh diri sering berkaitan dengan gangguan mental seperti depresi, kecemasan, dan gangguan suasana hati [15]. Kondisi tersebut dapat mendorong munculnya pikiran negatif yang terdistosi, perasaan tidak berdaya, dan keyakinan bahwa tidak ada solusi lain selain mengakhiri hidup. Proses munculnya ideasi hingga berkembang menjadi perilaku bunh diri dijelaskan melalui sejumlah teori psikologis. Model stress-diathesis menekankan bahwa individu dengan kerentanan bawaan, baik genetis, biologis, maupun psikologis seperti riwayat gangguan mental atau trauma, akan lebih mudah mengalami ideasi bunh diri ketika menghadapi peristiwa hidup yang penuh tekanan [16].

Suicidal ideation merupakan pikiran atau keinginan untuk mengakhiri hidup yang terbagi dua kategori [17], yaitu:

a. *Passive Suicidal Ideation,* yaitu keinginan untuk tidak hidup lagi tanpa disertai niat, rencana, atau persiapan melakukan bunuh diri. Meskipuj belum mengarah pada tindakan, kondisi ini menunjukkan adanya distress psikologis yang perlu mendapat perhatian.
b. *Active Suicidal Ideation*, yaitu pikiran bunuh diri yang telah disertai niat, rencana, atau persiapan untuk mengakhiri hidup. Kondisi ini memiliki tingkat risiko lebih tinggi karena lebih dekat dengan terjadinya percobaan bunuh diri.

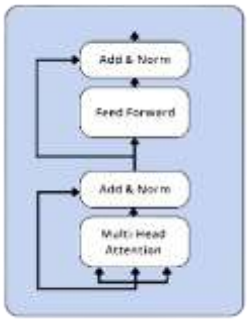
D. *Natural Language Processing* (NLP)

Natural Language Processing (NLP) merupakan cabang kecerdasan buatan yang memungkinkan komputer memahami, menganalisis, dan memproses bahasa alami manusia dalam bentuk yang dapat diproses secara komputasional [18]. NLP tidak hanya menekankan pada pemahaman struktur bahasa (*syntax*), tetapi juga mencakup analisis makna (*semantics*), emosi (*affect*), serta konteks penggunaan bahasa (*progmatics*) [19]. Pendekatan ini memungkinkan sistem untuk menangkap informasi yang lebih mendalam dari teks, termasuk ekspresi kondisi psikologis dan pola kognitif individu.

E. *Bidirectional Encoder Representaions from Transformers* (BERT)

Biderectional Encoder Encoder Representations from Transformers (BERT) merupakan pre-trained language model yang dikembangkan oleh Google AI untuk berbagai tugas Natural Language Processing (NLP) [20]. Berbeda dengan model sekuensial seperti LSTM, BERT menggunakan arsitektur Transformer Encoder dengan

mekanisme bidirectional, sehingga mampu memahami konteks kata berdasarkan informasi dari sisi kiri dan kanan kalimat secara bersamaan.



GAMBAR 1
(ARSITEKTUR BERT)

Berdasarkan Gambar 1, arsitekrut BERT terdiri atas beberapa lapisan Transformer Encoder yang mencakup *Multi-Head Self-Attention*, *Add & Layer Normalization*, dan *Feed Forward Network*. Komponen utama yang memungkinkan BERT memahami hubungan antar kata adalah mekanisme Self-Attention, yang dirumuskan sebagai berikut:

$$Attention(Q,K,V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1)$$

Dengan Q (*Query*), K (*Key*), dan V (*Value*) merupakan representasi setiap token, sedangkan d_k adalah dimensi vektor *key*. Mekanisme ini menghasilkan bobot perhatian (*attention weights*) yang menunjukkan tingkat keterkaitan antar token dalam suatu kalimat sehingga model mampu menghasilkan representasi teks yang kontekstual. BERT dilatih melalui dua tahap, yaitu pre-training mengunakan tugas Masked Language Modeling (MLM) dan Next Sentence Prediction (NSP), kemudian fine-tuning untuk tugas spesifik seperti klasifikasi teks.

F. IndoBERT

IndoBERT merupakan model bahasa berbasis arsitektur BERT yang dikembangkan khusus untuk bahasa Indonesia. Model ini dilatih menggunakan korpus besar IndoB4 sehingga mampu mempresentasikan struktur bahasa Indonesia secara lebih akurat dibandingkan model multibahasa. Sebagai model monolingual, IndoBERT sering digunakan sebagai dasar berbagai tugas pemrosesan bahasa alami. Secara arsitektur, IndoBERT menggunakna struktur Transformer encoder yang sama seperti BERT, memanfaatkan mekanisme self-attention untuk memahami hubungan antar kata dalam suatu kalimat. Mekanisme ini memungkinkan model untuk menangkap konteks kata baik dari sisi kiri maupun kanan secara bersamaan sehingga menghasilkan representasi teks yang lebih kontektual.

G. Confusion Matrix

Confusion Matrix merupakan metode evaluasi yang membandingkan hasil prediksi model dengan label aktual. Metode ini terdiri atas empat komponen, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN), yang digunakan untuk menghitung *accuracy*, *precision*, *recall*, dan *F1-score*..

TABEL 1
(CONFUSION MATRIX)

	Prediksi Positif	Prediksi Negatif
Aktual Positif	*True Positive* (TP)	*False Negative* (FN)
Aktual Negatif	*False Positive* (FP)	*True Negative* (TN)

Berdasarkan Confusion Matrix, perfoma model dievaluasi menggunakan metrik sebagai berikut:

1 *Accuracy* mengukur proporsi prediksi yang benar terhadap seluruh data uji.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

2 *Precision* mengukur ketepatan model dalam memberikan prediksi positif.

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

3 *Recall* mengukur kemampuan model dalam mengidentifikasi seluruh data positif.

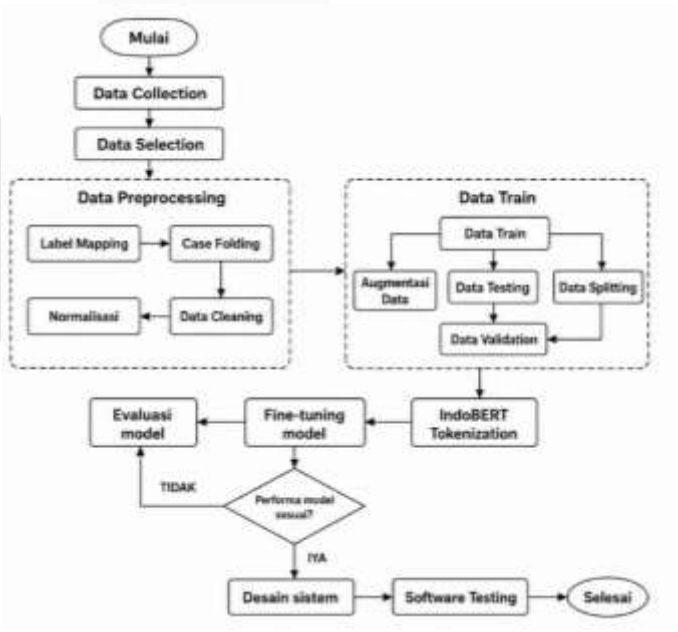
$$Recall = \frac{TP}{TP+FN} \quad (4)$$

4 *F1-Score* merupakan rata-rata harmonik antara *precision* dan *recall*, sehingga memberikan evaluasi yang lebih seimbang, terutama pada dataset yang tidak seimbang.

$$F1\text{-}score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

III. METODE

A. Sistematika Penyelesaian Masalah



GAMBAR 2
(DIAGRAM ALUR PENELITIAN)

Sistematika penelitian meliputi tahapan data collection, data selection, dan data preprocessing, yang mencakup *label mapping*, *case folding*, *data cleaning*, dan normalisasi untuk menyiapkan data sebelum proses pemodelan.

B. Pengumpulan Data / Data Collection

Tahap data collection dilakukan menggunakan dataset Kaggle yang berisi komentar teks media sosial dan label tingkat risiko. Kolom komentar digunakan sebagai data klasifikasi, sedangkan kolom risk sebagai label kelas. Contoh dataset ditunjukkan pada Tabel 2.

TABEL 2
(SAMPEL DATASET PADA KAGGLE)

Komentar	Platform	Emotion	Risk
Huh capek gw hidup kek gini mulu apa apa dimarahin mulu padahal ga ad salah 🥺	Youtube	Hopelessness	High Risk
gw terlalu takut buat bunuh diri gw takut	Twitter	Stress	Low risk
jangan ya, setelah matipun masih banyak hal yang harus kita hadapi 💪	Tiktok	Positive	No Risk

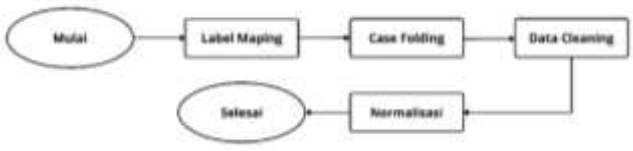
C. Data Selection

Tahap data selection dilakukan dengan memilih atribut Komentar dan Risk, serta menghapus data berlabel No Risk. Hasil seleksi menghasilkan 738 data dari total 1.041 data yang digunakan pada tahap pengolahan selanjutnya.

TABEL 3
(SAMPEL HASIL DATA SELECTION)

Komentar	Risk
Huh capek gw hidup kek gini mulu apa apa dimarahin mulu padahal ga ad salah 🥺	High Risk
gw terlalu takut buat bunuh diri gw takut	Low Risk

D. Data Preprocessing



GAMBAR 3
(ALUR PREPROCESSING)

Tahap *data preprocessing* dilakukan untuk meningkatkan kualitas data sebelum proses pelatihan model. Preprocessing meliputi empat tahapan, yaitu label mapping, case folding, data cleaning, dan text normalization. Pada tahap *label mapping*, variasi penulisan label pada kolom Risk diseragamkan menjadi dua kelas, yaitu Low Risk (0) dan High Risk (1). Selanjutnya, *case folding* mengubah seluruh teks menjadi huruf kecil untuk menyeragamkan penulisan. Tahap *data cleaning* menghapus karakter yang tidak relevan, seperti, tanda baca, simbol, emoji. Terakhir, *text normalization* mengubah kata tidak baku, singkatan, dan huruf berulang menjadi bentuk baku menggunakan kamus normalisasi. Contoh hasil setiap tahapan preprocessing ditunjukkan pada Tabel 4

TABEL 4
(HASIL PREPROCESSING)

Tahap	Hasil
Data Asli	Huh capek gw hidup kek gini mulu apa apa dimarahin mulu padahal ga ad salah 🥺
Label Mapping	High Risk = 1
Case Folding	huh capek gw hidup kek gini mulu apa apa dimarahin mulu padahal ga ada salah 🥺
Data Cleaning	huh capek gw hidup kek gini mulu apa apa dimarahin mulu padahal ga ada salah
Normalisasi	huh capek aku hidup kek gini mulu apa apa dimarahin mulu padahal tidak ada salah

E. Data Splitting

Setelah preprocessing, dataset dibagi menjadi training, validation, dan testing menggunakan stratified sampling dengan proporsi 80%, 10%, dan 10% untuk menjaga distribusi kelas pada setiap subset. Hasil pembagian dataset ditunjukkan pada Tabel 5.

TABEL 5
(TOTAL DATA SPLITTING)

Dataset	Low Risk	High Risk	Total
Training	365	225	590
Validation	46	28	74
Testing	46	28	74

F. Data Augmentasi

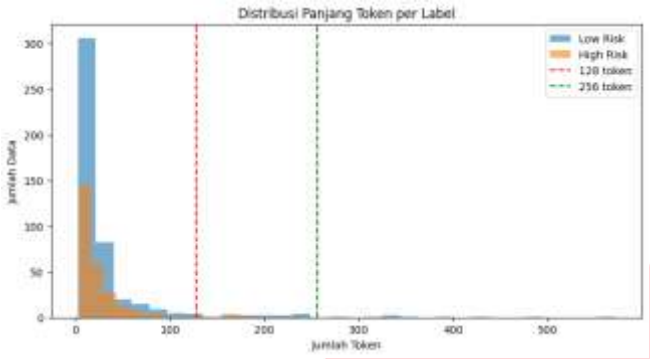
Tahap data augmentation dilakukan pada data training untuk meningkatkan variasi data dan mengurangi ketidakseimbangan kelas, khususnya pada High Risk. Augmentasi dilakukan menggunakan dua metode, yaitu penambahan data manual dan synonym replacement, sedangkan data validation dan testing tidak diaugmentasi untuk mencegah data leakage. Hasil augmentasi ditunjukkan pada Tabel 6.

TABEL 6
(JUMLAH DATA AUGMENTASI)

Tahap	Jumlah Data
Hasil Data Splitting	590
Setelah Penambahan Data Manual	625
Setelah Synonym Replacement	716

G. Tokenisasi IndoBERT

Data hasil augmentasi ditokenisasi menggunakan tokenizer IndoBERT (*indobenchmark/indobert-base-p1*) untuk mengubah teks menjadi input IDs dan attention masks yang dapat diproses oleh model. Selanjutnya, dilakukan analisis distribusi panjang token untuk menentukan nilai maximum sequence length.



GAMBAR 4
(DISTRIBUSI PANJANG TOKEN)

Berdasarkan Gambar 4, sebagian besar data memiliki panjang kurang dari 128 token, sedangkan hanya sebagian kecil data yang melebihi batas tersebut. Oleh karena itu, maximum sequence length ditetapkan sebesar 128 token untuk menyeimbangkan efisiensi komputasi dan mempertahankan informasi pada sebagian besar data. Teks yang lebih pendek dilakukan padding, sedangkan teks yang melebihi batas dipotong (truncation) sebelum proses fine-tuning.

H. Fine-tuning IndoBERT

Model dikembangkan melalui proses *fine-tuning* menggunakan IndoBERT Base P1 (*indobenchmark/indobert-base-p1*) untuk klasifikasi Low Risk dan High Risk. Enam skenario *fine-tuning* dengan variasi learning rate dan epoch diuji menggunakan data training dan validation, sedangkan batch size dipertahankan tetap (Tabel 7). Konfigurasi terbaik dipilih berdasarkan accuracy, precision, recall, dan Macro F1-score, kemudian dievaluasi pada data testing.

TABEL 7
(KONFIGURASI FINE-TUNING)

Skenario	Learning Rate	Batch Size	Epoch
S1	1×10^{-5}	16	3
S2	2×10^{-5}	16	3
S3	3×10^{-5}	16	3
S4	1×10^{-5}	16	4
S5	2×10^{-5}	16	4
S6	3×10^{-5}	16	4

IV. HASIL DAN PEMBAHASAN

A. Evaluasi Kinerja

Bagian ini menyajikan hasil evaluasi model klasifikasi risiko bunuh diri yang diusulkan. Sebagaimana dijelaskan pada bagian metodologi, enam skenario fine-tuning diuji dengan memvariasikan learning rate dan jumlah epoch, sedangkan hyperparameter lainnya dipertahankan tetap. Setiap skenario dievaluasi menggunakan data validation untuk menentukan konfigurasi pelatihan terbaik. Kinerja setiap skenario diukur menggunakan metrik accuracy, precision, recall, dan Macro F1-score. Konfigurasi dengan performa terbaik dipilih sebagai model akhir dan selanjutnya dievaluasi menggunakan data testing. Perbandingan hasil seluruh skenario *fine-tuning* ditunjukkan pada Tabel 8.

TABEL 8
(HASIL SKENARIO)

Skenario	Accuracy	Recall	Precision	Macro F1
S1	71,62%	62,07%	64,29%	70,04%
S2	81,08%	76,92%	71,43%	79,59%
S3	78,28%	87,50%	50,00%	74,13%
S4	72,97%	78,57%	39,29%	66,76%
S5	77,03%	70,37%	67,86%	75,41%
S6	79,73%	72,41%	75,00%	78,60%

Berdasarkan Tabel 8, enam skenario *fine-tuning* menghasilkan performa klasifikasi yang berbeda, menunjukkan bahwa variasi learning rate dan jumlah epoch memengaruhi kemampuan model dalam mengklasifikasikan risiko bunuh diri. Di antara seluruh skenario yang diuji, S2 memperoleh performa terbaik dengan accuracy sebesar 81,08% dan Macro F1-score sebesar 79,59%, sehingga dipilih sebagai konfigurasi *fine-tuning* terbaik.



GAMBAR 5
(TRAIN VS VALIDATION LOSS)

Gambar 5 menunjukkan perubahan training loss dan validation loss selama proses *fine-tuning*. Nilai *training loss* menurun secara konsisten dari 0,7224 pada epoch pertama menjadi 0,4355 pada epoch ketiga. Sementara itu, *validation loss* menurun dari 0,6441 menjadi 0,5833 pada epoch kedua dan relatif stabil pada 0,5820 di epoch ketiga. Hasil ini menunjukkan bahwa model mencapai konvergensi dengan baik tanpa indikasi *overfitting* yang signifikan.

TABEL 9
(HASIL PADA TRAINING, VALIDATION, TESTING)

Dataset	Accuracy	Precision	Reall	Macro F1
Training	81,98%	81,08%	80,36%	81,91%
Validation	71,62%	62,07%	64,29%	70,04%
Testing	81,08%	76,92%	71,43%	79,59%

Tabel 9 menunjukkan perbandingan kinerja model pada data training, validation, dan testing. Model memperoleh performa terbaik pada data training dengan accuracy sebesar 81,98% dan Macro F1-score sebesar 81,91%. Pada data validation, model mencapai accuracy sebesar 71,62% dan Macro F1-score sebesar 70,04%, sedangkan pada data testing diperoleh accuracy sebesar 81,08% dan Macro F1-score sebesar 79,59%. Hasil tersebut menunjukkan bahwa model memiliki kemampuan generalisasi yang baik pada data yang belum pernah dilihat sebelumnya, dengan perbedaan performa yang masih wajar sehingga tidak menunjukkan indikasi overfitting yang signifikan.

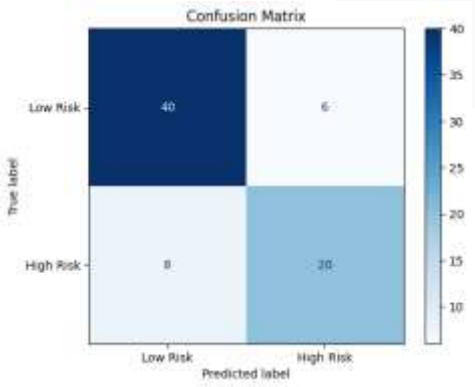
B. Evaluasi Hasil Klasifikasi

Konfigurasi fine-tuning terbaik (S2) selanjutnya dievaluasi menggunakan data testing untuk mengukur kemampuan model dalam mengklasifikasikan data yang belum pernah dilihat sebelumnya. Evaluasi dilakukan menggunakan classification report dan confusion matrix. Classification report pada Tabel 10 menyajikan metrik precision, recall, F1-score, accuracy, macro average, dan weighted average sebagai dasar evaluasi kinerja model.

TABEL 10
(CLASSIFICATION REPORT)

Kelas	Precision	Recall	F1-score	Support
Low Risk	0,83	0,87	0,85	46
High Risk	0,77	0,71	0,74	28
Accuracy			0,81	74
Macro Avg	0,80	0,79	0,80	74
Weighted Avg	0,81	0,81	0,81	74

Berdasarkan Tabel 10, model memperoleh accuracy sebesar 81,08% pada data testing. Model menghasilkan F1-score sebesar 0,85 untuk kelas Low Risk dan 0,74 untuk kelas High Risk, sedangkan Macro F1-score sebesar 0,80 menunjukkan bahwa model mampu mempertahankan performa yang seimbang pada kedua kelas meskipun terdapat ketidakseimbangan jumlah data. Secara keseluruhan, hasil ini menunjukkan bahwa model mampu mengklasifikasikan risiko bunuh diri dengan baik.



GAMBAR 7
(CONFUSION MATRIX)

Berdasarkan Gambar 6, model berhasil mengklasifikasikan 40 data Low Risk dan 20 data High Risk dengan benar. Sementara itu, terdapat 6 data Low Risk yang diprediksi sebagai High Risk dan 8 data High Risk yang diprediksi sebagai Low Risk. Kesalahan klasifikasi tersebut menunjukkan adanya kemiripan karakteristik semantik pada beberapa teks di kedua kategori. Meskipun demikian, confusion matrix menunjukkan bahwa model menghasilkan lebih banyak prediksi yang benar dibandingkan prediksi yang salah, sehingga memiliki performa klasifikasi yang baik dan berpotensi mendukung psikolog dalam proses klasifikasi risiko bunuh diri.

C. Implementasi Sistem

Model IndoBERT yang terpilih berhasil diimplementasikan ke dalam sistem pendukung keputusan berbasis web menggunakan Laravel, Flask, dan MySQL. Sistem memungkinkan psikolog mengelola data pasien, memasukkan teks keluhan, memperoleh hasil prediksi risiko bunuh diri, serta menyimpan riwayat asesmen dalam satu platform. Integrasi model ke dalam aplikasi mendukung proses asesmen yang lebih cepat, terstruktur, dan terdokumentasi dengan baik. Implementasi sistem ditunjukkan pada Gambar 7.



GAMBAR 6
(IMPLEMENTASI ANALISIS)

Gambar 7 menunjukkan antarmuka sistem pendukung keputusan berbasis web yang dikembangkan. Sistem memungkinkan psikolog memasukkan data pasien, teks keluhan, dan hasil asesmen depresi sebelum melakukan analisis risiko bunuh diri. Setelah proses analisis selesai, sistem menampilkan kategori risiko bunuh diri beserta confidence score dan menyimpan hasil asesmen sebagai riwayat. Implementasi ini menunjukkan bahwa sistem mampu mendukung proses skrining awal secara lebih cepat dan terstruktur, dengan tetap mempertahankan peran psikolog sebagai pengambil keputusan akhir.

D. KESIMPULAN

Penelitian ini mengusulkan sistem pendukung keputusan berbasis web untuk klasifikasi risiko bunuh diri menggunakan IndoBERT guna membantu psikolog dalam menganalisis teks keluhan pasien berbahasa Indonesia. Tahapan penelitian meliputi pengumpulan data, preprocessing, augmentasi data, tokenisasi, fine-tuning, evaluasi model, dan implementasi sistem. Enam skenario *fine-tuning* diuji untuk memperoleh konfigurasi terbaik. Hasil pengujian menunjukkan bahwa konfigurasi dengan learning rate 2×10^{-5}, batch size 16, dan 3 epoch memberikan performa terbaik dengan accuracy sebesar 81,08%, precision 76,92%, recall 71,43%, dan Macro F1-score 79,59% pada data testing. Hasil confusion matrix menunjukkan bahwa model mampu mengklasifikasikan sebagian besar teks keluhan dengan benar ke dalam kategori Low Risk dan High Risk. Model yang telah diimplementasikan ke dalam aplikasi

berbasis web menggunakan Laravel, Flask, dan MySQL mampu mendukung proses skrining awal risiko bunuh diri secara lebih cepat dan terstruktur, dengan tetap mempertahankan peran psikolog sebagai pengambil keputusan akhir. Secara keseluruhan, hasil penelitian menunjukkan bahwa IndoBERT merupakan pendekatan yang efektif untuk klasifikasi risiko bunuh diri berbahasa Indonesia dan berpotensi mendukung layanan kesehatan mental di fasilitas pelayanan kesehatan tingkat pertama.

Untuk penelitian selanjutnya, penggunaan dataset yang lebih besar dan beragam dapat meningkatkan kemampuan model dalam mengenali berbagai variasi ekspresi bahasa yang berkaitan dengan risiko bunuh diri. Selain itu, evaluasi terhadap model Transformer lainnya serta penerapan Explainable Artificial Intelligence (XAI) dapat dipertimbangkan untuk meningkatkan akurasi dan interpretabilitas sistem pendukung keputusan yang dikembangkan

REFERENSI

[1] World Health Organization, “Mental health.” [Online]. Available: https://www.who.int/health-topics/mental-health#tab=tab_2

[2] World Health Organization, “Mental disorders.” [Online]. Available: https://www.who.int/news-room/fact-sheets/detail/mental-disorders

[3] World Health Organization, “Depressive disorder (depression).” [Online]. Available: https://www.who.int/news-room/fact-sheets/detail/depression?utm_source=chatgpt.com

[4] D. Febrianti *et al.*, “Hubungan Tingkat Depresi dan Faktor Resiko Ide Bunuh Diri pada Remaja SMPN,” vol. 13, no. 1, pp. 85–94, 2021.

[5] M. M. Omnia *et al.*, “Depresi dan ide bunuh diri pada dewasa muda,” vol. 11, no. 1, pp. 103–110, 2023.

[6] F. S. Putri, Z. Nazihah, and D. P. Ariningrum, “Depresi Remaja di Indonesia : Penyebab dan Dampaknya Adolescent Depression in Indonesia : Causes and Effects,” vol. 10, no. 2, pp. 99–108, 2022.

[7] World Health Organization, “Suicide.” [Online]. Available: https://www.who.int/news-room/fact-sheets/detail/suicide

[8] Kementerian Kesehatan Republik Indonesia, “Cegah Bunuh Diri, Kemenkes Ajak Remaja Bicara Soal Kesehatan Mental,” Kementerian Kesehatan Republik Indonesia. [Online]. Available: https://kemkes.go.id/id/cegah-bunuh-diri-kemenkes-ajak-remaja-bicara-soal-kesehatan-mental?utm_source=chatgpt.com

[9] I. R. Hidayat and W. Maharani, “General Depression Detection Analysis Using IndoBERT Method,” *Int. J. Inf. Commun. Technol.*, vol. 8, no. 1, pp. 41–51, 2022, doi: 10.21108/ijoict.v8i1.634.

[10] F. Koto and T. Baldwin, “IndoLEM and IndoBERT : A Benchmark Dataset and Pre-trained Language Model for Indonesian NLP,” pp. 757–770, 2020.

[11] Kementerian Kesehatan Republik Indonesia, “Pengertian Kesehatan Mental.” [Online]. Available: https://ayosehat.kemkes.go.id/pengertian-kesehatan-mental

[12] World Health Organization, “Mnetal Health.” [Online]. Available: https://www.who.int/news-room/fact-sheets/detail/mental-health-strengthening-our-response?utm_source=chatgpt.com

[13] M. D. Chinenye Onyemaechi, “What Is Depression?,” AMERICAN PSYCHOLOGICAL ASSOCIATION. [Online]. Available: https://www.psychiatry.org/patients-families/depression/what-is-depression

[14] E. D. Klonsky and A. M. May, “The Three-Step Theory (3ST): A New Theory of Suicide Rooted in the ‘ Ideation-to-Action ’ Framework,” vol. 8, no. 2, pp. 114–129, 2015.

[15] AMERICAN PSYCHOLOGICAL ASSOCIATION, “Talking to teens: Suicide prevention,” AMERICAN PSYCHOLOGICAL ASSOCIATION. [Online]. Available: https://www.apa.org/topics/suicide/prevention-teens

[16] B. Harmer, S. Lee, A. Rizvi, and A. Saadabadi, “Suicide Ideation,” in *StatPearls*, StatPearls Publishing, 2024. [Online]. Available: https://www.ncbi.nlm.nih.gov/books/NBK565877/

[17] A. B. MPH, “Passive Suicidal Ideation vs Active Suicidal Ideation: What’s the Difference,” Charlie Health. [Online]. Available: https://www.charliehealth.com/post/passive-suicidal-ideation-vs-active

[18] F. Ratnawati, “Implementasi Algoritma Naive Bayes Terhadap Analisis Sentimen Opini Film Pada Twitter,” *INOVTEK Polbeng - Seri Inform.*, vol. 3, no. 1, p. 50, 2018, doi: 10.35314/isi.v3i1.335.

[19] E. Cambria and B. White, “Jumping NLP curves: A review of natural language processing research,” *IEEE Comput. Intell. Mag.*, vol. 9, no. 2, pp. 48–57, 2014, doi: 10.1109/MCI.2014.2307227.

[20] J. Devlin, M. W. Chang, K. Lee, and K. Toutanova, “BERT: Pre-training of deep bidirectional transformers for language understanding,” *NAACL HLT 2019 - 2019 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang. Technol. - Proc. Conf.*, vol. 1, pp. 4171–4186, 2019.