

BAB I


PENDAHULUAN

1.1 Latar Belakang

Deteksi emosi adalah suatu proses untuk mengidentifikasi dan mengekstraksi kondisi emosional seseorang, seperti rasa bahagia, sedih, maupun marah, yang terkandung dalam bahasa yang digunakan manusia secara alami. Dalam konteks media sosial, kemampuan mendeteksi emosi dari teks yang diunggah atau disebarluaskan oleh pengguna memiliki nilai informasi yang tinggi, karena dapat dimanfaatkan untuk memahami pola reaksi emosional masyarakat terhadap berbagai situasi dan peristiwa yang terjadi di sekitar mereka. Lebih dari itu, deteksi emosi juga berpotensi memberikan kontribusi nyata dalam mendukung pengambilan keputusan di berbagai bidang, interaksi pengguna, keuangan, politik, kesehatan dan juga pendidikan [1].

Menurut laporan Digital 2024 dari *We Are Social*, jumlah orang yang menggunakan media sosial secara aktif di Indonesia mencapai lebih dari 167 juta orang, atau sekitar 60,4% dari semua total populasi. Sekarang media sosial tidak hanya digunakan berinteraksi, juga dipakai pada berbagai tujuan lain, contohnya berbagi dan bertukar informasi dalam komunitas interaksi virtual. Fenomena ini tidak terlepas dari meningkatnya jumlah pengguna internet yang terus bertambah, serta didukung adanya infrastruktur yang semakin memadai. Salah satu media sosial yang digunakan banyak orang adalah Twitter. Selain itu, pendapat di Twitter mudah menarik perhatian orang banyak. Berdasarkan ulasan pengguna, pendapat di Twitter sering kali sangat beragam dan memiliki berbagai tanggapan, sehingga bisa menjadi viral. Sementara itu, di media sosial Twitter, selain menyampaikan opini dan informasi, pengguna juga bisa mengekspresikan perasaan mereka [7].

Penggunaan media sosial di Indonesia kembali melonjak tahun ini. Jumlah identitas pengguna media sosial tumbuh 26% secara tahunan, mencapai 180 juta - setara dengan 62,9% dari total populasi[2]. Pada tahun 2026, 81,82% masyarakat Indonesia diperkirakan memiliki media sosialnya sendiri. Angka ini meningkat 2 kali lipat dari tahun 2017, sebesar 47,03%. Yang dapat kita lihat pada gambar 1.1.



Gambar 1. 1 pengguna sosial media Indonesia


pengguna sosial media Indonesia Berdasarkan pada gambar 1.1, 78,5% pengguna internet diperkirakan menggunakan paling tidak 1 buah atau akun media sosial. Nilai ini digadang-gadang akan terus bertambah di tahun-tahun yang akan datang. Melansir Statista, di tahun 2017, pengguna media sosial di Indonesia hanya 47,03% dari seluruh populasi. Angka ini diperkirakan naik 2 kali lipat di tahun 2026 dengan total pengguna 81,82%. Youtube menjadi media sosial yang paling banyak digunakan di Indonesia, dengan total pengguna sebesar 139 juta di awal tahun 2023. Facebook duduk di posisi kedua dengan 119,9 juta pengguna. Meski begitu, nilai ini mengalami penurunan 10 juta pengguna dari tahun 2022, atau sebesar 7,7%[2] .

Pada sumber lain data dari Hootsuiit menyatakan bahwa di tahun 2020 pada salah satu platform yang sering digunakan oleh masyarakat Indonesia adalah twitter. Terdapat 56% pengguna aktif media sosial di indonesia yang menggunakan twitter [4] pengguna aktif media sosial di Indonesia yang menggunakan Twitter. Melihat jumlah pengguna aktif Twitter di Indonesia, masyarakat dengan bebas

mengekspresikan perasaan emosi mereka yang dituangkan dalam bentuk teks dalam tweet[3].

Di sisi lain, semua pengguna sosial media di Indonesia terus berkembang dan bertambah dengan cepat. Hal tersebut dapat mendorong para peneliti menganalisis sentimen citra dan deteksi emosi dengan data teks. Bahasa Indonesia adalah bahasa yang masih kurang mendapatkan sumber daya yang cukup untuk diolah dengan bahasa alami. Oleh karena itu, perlu dilakukan penelitian agar sumber tersebut dapat dikembangkan [3].

Pasar keuangan Indonesia sedang berada di krisis kepercayaan yang mengkhawatirkan. Pada Januari 2026, Morgan Stanley Capital International (MSCI) sebagai lembaga penyedia indeks pasar saham mengguncang lantai bursa dengan membekukan sementara penyesuaian bobot (rebalancing) indeks saham Indonesia. Merespon pengumuman tersebut, Goldman Sachs selaku bank investasi dan lembaga jasa keuangan multinasional memangkas rekomendasi ekuitas Indonesia. Seminggu berselang, Moody's sebagai satu dari tiga lembaga pemeringkat kredit internasional terbesar menurunkan outlook peringkat utang Indonesia dari stabil menjadi negative dapat dilihat pada gambar 1.2.



Gambar 1. 2 Perubahan IHSG 2026

Berdasarkan pada gambar 1.2 diketahui bahwa rentetan peristiwa tersebut membuat koreksi tajam Indeks Harga Saham Gabungan (IHSG) yang sempat berujung trading halt. Penurunan tajam dalam satu hari hingga 8% serta penurunan total 18,49% selama kuartal I tahun 2026 ke level 7.048 seolah membangkitkan kembali bayang-bayang krisis ekonomi. Jika dilihat secara historis, penurunan tajam IHSG pada Januari 2026 ini memiliki pola statistik yang hampir sama dengan beberapa peristiwa di masa lalu, seperti saat krisis moneter 1998 (-11,88%), krisis keuangan global pada 2008 (-10,38%), serta pandemi Covid-19 pada tahun 2020 yang sempat mengalami rangkaian trading halt karena penurunan lebih dari 5%. Meskipun sama secara pola statistik, pemicu hal tersebut cukup berbeda. Jika apa yang terjadi pada 1998, 2008, dan 2020 didorong oleh faktor eksternal seperti krisis global atau pandemi, kejatuhan 2026 terasa lebih menyakitkan karena justru bersumber dari faktor internal Indonesia sendiri.

Pada *Deep learning* merupakan salah satu pendekatan yang biasa digunakan untuk mengelompokkan teks. Penelitian ini menggunakan pendekatan eksperimental untuk memodelkan deteksi emosi berdasarkan teks dengan memanfaatkan teknologi BERT yang merupakan singkatan dari BiDirectional Encoder Representations from Transformers[3]. BERT adalah salah satu model yang telah dilatih dengan dasar model bahasa bertopeng dan prediksi kalimat berikutnya, yang digunakan untuk merepresentasikan kata secara dua arah secara mendalam dari teks yang tidak berlabel. Model ini mempertimbangkan konteks kata di sebelah kiri dan kanan pada semua lapisannya [4]. Arsitektur dua arah pada BERT memberi kemampuan kepada BERT untuk memprediksi konteks sebelum dan sesudah sebuah kata secara bersamaan. Hal ini membuat model BERT mampu memahami konteks secara dalam sebuah kalimat, belajar hubungan makna antar kata dengan baik, sehingga bisa menemukan pola yang rumit dalam kalimat dan digunakan sesuai dengan tugas yang diberikan. Proses pelatihan awal BERT membuat pengaturan ulang model saat *fine-tuning* menjadi lebih efisien, baik dalam hal kebutuhan data pelatihan untuk tugas tertentu maupun dalam hal komputasi dikarenakan proses ini dilakukan dengan penambahan satu *output layer* tanpa melakukan modifikasi pada arsitektur dasar sehingga dapat menghasilkan model dengan komputasi dan resource yang rendah namun tetap

memiliki performa yang baik terutama dalam implementasi dan integrasi pada aplikasi third party lainnya [7], [4].

Sumber artikel yang berjudul "*Fine-tune BERT berdasarkan Model Machine Learning untuk Analisis Sentimen*" [4] menerapkan model bahasa BERT untuk melakukan ekstraksi *embedding* kata berupa token. Hasil diperoleh dari model yang diajukan, yaitu BERT-GSVM, mencapai akurasi tertinggi sebesar 0.91 [4]. Namun, model tersebut membutuhkan waktu eksekusi yang lebih lama dibandingkan Word2vec-GSVM, yaitu 2 jam 38 menit [4]. Penelitian lain yang berjudul "Emotion Detection Via Bert-Based Deep Learning Approaches In Natural Language Processing" [5] membuat model deteksi emosi menggunakan model BERT dengan akurasi 0.87 untuk empat emosi dasar, yaitu marah, takut, senang, dan sedih. Model deteksi emosi ini bekerja dengan baik. Performa pada kelas label sedih tergolong rendah karena terjadi prediksi salah pada kelas label senang. Keterbatasan dalam penelitian ini adalah model BERT membutuhkan daya komputasi yang besar serta data yang banyak, sehingga prosesnya memakan waktu yang cukup lama. Selain itu, ada beberapa penelitian lain yang membahas deteksi emosi dengan menggunakan deep learning, yang menyatakan bahwa performa yang buruk terjadi karena jumlah dan kualitas *dataset* yang digunakan. Oleh karena itu, diperlukan model ekstraksi fitur yang berbeda serta eksperimen pada hyperparameter agar performa model dapat ditingkatkan [5], [6].

BERT adalah arsitektur model *pre-trained* yang dilatih menggunakan data berbahasa Inggris [23]. Arsitektur BERT terdiri dari beberapa lapisan transformer encoder yang memiliki sejumlah attention head. Setiap head menghitung vektor query, key, dan value untuk setiap token dalam urutan masukan guna menghasilkan representasi berbobot melalui mekanisme *self-attention*. Keluaran dari seluruh head pada lapisan yang sama kemudian digabungkan dan diproses menggunakan fully connected layer. Setiap lapisan dilengkapi dengan skip connection dan diikuti oleh proses layer normalization. Selain itu, Convolutional Neural Network (CNN) juga banyak digunakan dalam tugas klasifikasi teks [24].

Dalam proses deteksi emosi pada teks, setiap kata yang terdapat dalam *dataset* perlu direpresentasikan dalam bentuk vektor numerik atau yang dikenal

sebagai vektor kata. Merujuk pada beberapa penelitian sebelumnya, di antaranya penelitian berjudul "*Emotion Detection in Twitter Social Media Using Long Short-Term Memory (LSTM) and FastText*" [6] serta penelitian berjudul "*A Comparison of Word-Embeddings in Emotion Detection from Text using BiLSTM, CNN and Self-Attention*" [7] yang keduanya mengkaji perbandingan berbagai metode *word embedding* dalam menghasilkan representasi vektor dari teks, diperoleh kesimpulan bahwa FastText secara konsisten menunjukkan tingkat akurasi tertinggi dibandingkan metode *word embedding* lainnya dalam proses vektorisasi kata. Hal ini dikarenakan FastText menggunakan teknik skip-gram yang menghasilkan representasi *n*-banyak *output* kata dari satu kata yang ada, sehingga mampu mengatasi permasalahan Out of Vocabulary (OOV). OOV adalah keadaan dimana tidak ditemukannya suatu kata atau istilah selama proses *training* sehingga dapat mengurangi akurasi model. Vektor yang dihasilkan kemudian akan dijadikan sebagai *inputan* dalam pemodelan yang akan dibangun menggunakan Bi-LSTM dan *Self-Attention* [7].

Penelitian komparatif ini melibatkan BiLSTM bersama model deep learning lain untuk mendeteksi depresi dari teks media sosial. Hasilnya menunjukkan bahwa model yang menggunakan bidirectional mampu menangkap konteks linguistik yang lebih kaya dibandingkan varian searah [8]. Didapatkan hasil bahwa BiLSTM menjadi model dengan performa terbaik, dengan akurasi 98,45% dan F1-score 96,37%, karena kemampuannya memahami konteks dua arah dalam teks. CNN memiliki precision tinggi tetapi recall rendah, sementara RNN dan GRU kurang efektif dalam menangkap pola kompleks. Penelitian ini menyimpulkan bahwa BiLSTM efektif untuk pemantauan kesehatan mental, dan penelitian selanjutnya disarankan menggunakan model berbasis transformer seperti BERT untuk meningkatkan performa [8].

Model deteksi emosi yang diterapkan dalam penelitian ini didasarkan pada sinergi antara dua pendekatan klasifikasi, yaitu jaringan long-short-term memory (LSTM) [27] dalam variasi dua arahnya dan jaringan saraf konvolusional [27] (CNN) yang dimediasi oleh pendekatan max pooling. Selain itu, kami memutuskan untuk menyertakan, setelah Bi-LSTM, lapisan *self-attention* untuk memungkinkan

sistem menangkap hubungan jarak jauh antar kata dengan bobot yang berbeda tergantung pada kontribusinya terhadap klasifikasi.

Penelitian ini mengevaluasi efektivitas dua algoritma pembelajaran mendalam tingkat lanjut. Bidirectional Long Short-Term Memory (BiLSTM) dan Bidirectional Encoder Representations from Transformers (BERT) memberikan wawasan tentang kekuatan komparatif mereka dan manfaat mengintegrasikannya melalui metode ensemble [6]. BiLSTM dipilih karena kemampuannya dalam memproses urutan dari arah maju dan mundur. Tidak seperti model yang lebih tradisional, BiLSTM memanfaatkan data sekuensial secara efektif, sehingga sangat cocok untuk tugas-tugas di mana konteks lengkap dari urutan *input* sangat penting untuk prediksi yang akurat. Sedangkan BERT telah dipilih karena kinerjanya yang kuat dalam berbagai tugas NLP dan penggunaannya yang lazim dalam penelitian pengenalan emosi [7,8] [6]. Kemampuannya untuk memahami konteks secara mendalam melalui model Pre-train sebelumnya membuatnya sangat efektif untuk pemrosesan bahasa yang bernuansa yang dibutuhkan dalam pengenalan emosi [6]. Oleh sebab itu, pada penelitian ini mengambil judul “Perbandingan Algoritma BERT dan Bidirectional LSTM dalam Deteksi Emosi Pada Teks”.

1.2 Perumusan Masalah

Berdasarkan pemaparan latar belakang diatas, didapatkanlah rumusan masalah sebagai berikut:

1. Bagaimana Menerapkan Algoritma BERT & BiLSTM pada pengenalan emosi teks?
2. Bagaimana kinerja Algoritma BERT dan BiLSTM pada pengenalan emosi teks?

1.3 Batasan Masalah

Supaya penelitian ini menjadi lebih terarah, sehingga perlu diadakannya batasan masalah. Pada penelitian ini batasan masalah yang dibahas terdiri dari:

1. Algoritma yang diuji hanya algoritma BERT dan BiLSTM
2. Penelitian ini akan fokus pada enam emosi dasar yang terdapat dalam dataset: joy, sadness, anger, fear, love, atau surprise. Emosi kompleks atau campuran tidak termasuk dalam lingkup penelitian ini
3. Program hanya bisa mendeteksi hanya satu emosi pada satu kalimat dan kata

1.4 Tujuan Penelitian


Rumusan masalah yang dipaparkan didapatkanlah tujuan yang ingin dicapai dalam penelitian ini sebagai berikut:

1. Menerapkan Algoritma BERT dan BiLSTM pada pengenalan emosi teks
2. Mengetahui perbandingan kinerja tingkat akurasi algoritma BERT dan BiLSTM pada pengenalan emosi teks

1.5 Kerangka Pemikiran Penelitian

Terdapat alur kerangka pemikiran yang akan digunakan dalam penelitian ini digambarkan pada Gambar 1.3. Kebingungan yang sering muncul karena banyaknya pilihan algoritma pengenalan emosi adalah masalah yang diangkat. Untuk mengatasi hal ini, cara yang disarankan adalah dengan membandingkan algoritma-algoritma tersebut. Selanjutnya, Penelitian ini berfokus pada permasalahan pengenalan emosi pada teks dengan memanfaatkan algoritma pembelajaran mendalam. Untuk menjawab permasalahan tersebut, digunakan dua pendekatan deep learning dalam pemrosesan bahasa alami, yaitu BERT dan BiLSTM. Penerapan kedua algoritma ini diharapkan mampu menangkap konteks dan pola bahasa secara lebih akurat dalam proses klasifikasi emosi.





Gambar 1.3 kerangka pemikiran

Gambar 1.3 kerangka pemikiran dalam penelitian ini disusun untuk menggambarkan alur berpikir peneliti, mulai dari latar belakang permasalahan hingga hasil yang diharapkan, sebagaimana ditunjukkan pada Gambar 3.1. Kerangka ini terdiri dari delapan komponen, yaitu *Fact*, *Theory*, *Problem*,

Opportunity, Approach, Software Development, Software Implementation, dan Result.

Penelitian ini diawali dari komponen *Fact* yang menguraikan kondisi nyata yang melatarbelakangi penelitian. Peningkatan jumlah data teks di media sosial menghasilkan beragam ekspresi emosi yang perlu dianalisis secara otomatis. Berbagai penelitian sebelumnya telah memanfaatkan Bidirectional Encoder Representations from Transformers (BERT) dan Bidirectional Long Short-Term Memory (BiLSTM) untuk klasifikasi emosi pada teks. Namun, performa kedua model tersebut masih bervariasi pada *dataset* yang berbeda, sehingga belum diketahui model mana yang secara konsisten paling optimal. Kondisi ini didukung oleh komponen *Theory*, yaitu bahwa Natural Language Processing (NLP) memungkinkan komputer memahami bahasa manusia, dan BiLSTM serta BERT merupakan metode deep learning yang banyak digunakan dalam klasifikasi emosi karena mampu memahami konteks dan makna teks.

Berdasarkan fakta dan teori, dirumuskan komponen *Problem*, yaitu bagaimana perbandingan performa algoritma BERT dan BiLSTM dalam mengenali emosi pada teks, serta algoritma mana yang menghasilkan kinerja paling optimal dalam klasifikasi emosi berbasis konteks. Rumusan masalah ini menjadi inti yang menghubungkan seluruh tahapan penelitian. Di sisi lain, komponen *Opportunity* menunjukkan bahwa ketersediaan algoritma canggih seperti BERT dan BiLSTM untuk pemrosesan teks membuka potensi penerapan pengenalan emosi di berbagai bidang, seperti analisis media sosial, layanan pelanggan, dan riset pasar, sehingga penelitian ini relevan dan berpotensi memberikan manfaat praktis.

Untuk menjawab permasalahan tersebut, komponen *Approach* menetapkan penggunaan dan perbandingan dua pendekatan deep learning, yaitu BERT dan BiLSTM, guna mengkaji efektivitas dan efisiensi keduanya dalam pengenalan emosi pada teks. Pada tahap *Software Development*, pengembangan algoritma dilakukan menggunakan metode *Knowledge Discovery in Database (KDD)* yang menyediakan tahapan sistematis mulai dari pemilihan data, *preprocessing*, transformasi, penambahan data, hingga evaluasi hasil. Tahapan tersebut kemudian

diwujudkan pada komponen *Software Implementation* dengan menggunakan bahasa pemrograman Python, baik untuk *preprocessing* data teks maupun pemodelan dengan algoritma BERT dan BiLSTM.

Tahap akhir adalah komponen *Result*, yaitu berupa analisis perbandingan yang menampilkan hasil performa dari kedua algoritma sehingga dapat ditentukan algoritma yang paling optimal untuk klasifikasi emosi pada teks. Garis putus-putus dari *Result* menuju *Problem* menunjukkan bahwa hasil penelitian dievaluasi kembali terhadap rumusan masalah, untuk memastikan bahwa permasalahan yang diajukan telah terjawab.

1.6 Metodologi Penelitian

Penelitian menggunakan *dataset* EDFN (Emotion Dataset for NLP), yang terdiri dari kalimat-kalimat atau teks dengan berbagai ekspresi emosi, termasuk bahagia, sedih, marah, takut, terkejut, dan netral. *Dataset* ini diunduh dari repository resmi dan telah digunakan secara luas dalam penelitian terkait pengenalan emosi. Setelah data diperoleh, dilakukan *preprocessing* yang mencakup konversi teks ke format huruf kecil dan konversi kontraksi, kemudian menghapus noise atau tidak relevan seperti email, tag html, karakter spesial dan karakter berakksen. Setiap teks dan label dirubah ke kategori yang akan dilakukan encode data. Selanjutnya, data dibagi menjadi dua subset utama, yaitu data latih dan data uji, dengan proporsi 70% untuk pelatihan dan 30% untuk pengujian, lalu 60% untuk pelatihan dan 40% untuk pengujian, dan 80% untuk pelatihan dan 20% untuk pengujian, lalu 90% untuk pelatihan dan 10% untuk pengujian.

Tahap selanjutnya adalah transformasi data, di mana fitur diekstraksi dari teks melalui dua pendekatan utama. Pada pendekatan bidirectional long short term memory (BiLSTM), fitur diekstraksi melalui tahap *preprocessing*, dan hasil dari *preprocessing* digunakan sebagai representasi fitur untuk klasifikasi. Fitur yang diekstraksi ini kemudian dibandingkan dengan fitur yang dihasilkan dari arsitektur BERT untuk metode mana yang memberikan hasil lebih baik.

Dalam tahap modeling, dua model utama dikembangkan dan diuji. Pertama, model BiLSTM dengan arsitektur RNN diinisialisasi dan dilatih menggunakan data

latih yang sudah diproses, dengan pengaturan hyperparameter seperti jumlah epoch sebanyak 50 dan learning rate sebesar 0,001. Model ini digunakan sebagai baseline untuk perbandingan. Kedua, model BERT dengan transformer, di mana fitur yang diekstraksi dari *preprocessing* digunakan sebagai *input* untuk BERT, yang juga dilatih dengan pengaturan yang sama yaitu 50 epoch dan learning rate 0,001.

Hasil dari klasifikasi ini kemudian dievaluasi menggunakan metrik presisi, recall, F1-score, dan akurasi. Metrik-metrik ini digunakan untuk menilai kinerja masing-masing model, dan hasilnya dibandingkan untuk menentukan metode mana yang lebih efektif dalam pengenalan emosi dari teks. Berdasarkan hasil evaluasi, analisis kinerja dilakukan dengan mempertimbangkan faktor-faktor seperti ukuran *dataset*, teknik *stopwords*, *tokenize*, dan konfigurasi model.

1.7 Sistematika Penulisan

Penelitian ini disusun ke dalam lima bab dengan rincian sebagai berikut:

BAB I: PENDAHULUAN

Bab pertama menguraikan dasar-dasar penelitian yang mencakup latar belakang yang melatarbelakangi penelitian ini, rumusan masalah yang ingin dijawab, tujuan yang ingin dicapai, batasan masalah yang ditetapkan, kerangka berpikir yang digunakan, serta sistematika penulisan laporan penelitian ini secara keseluruhan.

BAB II: KAJIAN LITERATUR

Bab kedua menyajikan tinjauan teoritis yang menjadi fondasi penelitian, meliputi landasan teori yang relevan serta berbagai penelitian terdahulu yang dijadikan rujukan dan acuan dalam pelaksanaan penelitian ini.

BAB III: METODE PENELITIAN

Bab ketiga menjelaskan secara rinci pendekatan dan metode yang diterapkan dalam penelitian ini, mencakup metode analisis sumber data yang digunakan serta metode pengembangan sistem yang diterapkan selama proses penelitian berlangsung.

BAB IV: HASIL DAN PEMBAHASAN

Bab keempat menyajikan hasil yang diperoleh dari penelitian yang telah dilaksanakan, disertai pembahasan mendalam mengenai proses evaluasi model yang dihasilkan beserta interpretasi dari setiap temuan yang didapatkan.

BAB V: KESIMPULAN DAN SARAN

Bab kelima merangkum seluruh kesimpulan yang diperoleh berdasarkan hasil penelitian yang telah dilakukan, sekaligus memberikan saran dan rekomendasi yang dapat dijadikan pertimbangan bagi peneliti selanjutnya yang ingin mengembangkan penelitian serupa.

