

# BAB 1

## PENDAHULUAN

### 1.1 Latar Belakang Masalah

Kecerdasan buatan (*Artificial Intelligence*) merupakan ilmu komputer yang mempelajari bagaimana cara membuat komputer dapat melakukan pekerjaan seperti yang dilakukan oleh manusia [1]. Ada beberapa contoh kecerdasan buatan, seperti *virtual assistant*, sistem navigasi, dan *chatbot*. *Chatbot* adalah sebuah program komputer yang dirancang untuk menstimulasikan percakapan yang interaktif dengan pengguna [2]. Salah satu contoh dari *chatbot* adalah ChatGPT.

ChatGPT (*Generative Pre-trained Transformer*) adalah sebuah *chatbot* yang dikembangkan oleh OpenAI dan dirilis pada 30 November 2022 [3]. ChatGPT menarik banyak perhatian karena memberikan jawaban yang detail dan mengartikulasikan jawaban di berbagai bidang pengetahuan [4]. Terdapat berbagai macam respon terhadap ChatGPT, baik respon positif maupun negatif. Salah satu respon positif adalah manfaat yang didapatkan dari ChatGPT, seperti meningkatkan pencarian, layanan referensi dan informasi, pembuatan katalog dan metadata, serta pembuatan konten [5]. Namun, ada juga respon lain yang mengatakan bahwa ChatGPT memberikan tantangan dalam mengembangkan kemampuan menulis kreatif siswa [6].

Analisis sentimen adalah proses mengumpulkan dan menganalisis pendapat seseorang tentang suatu topik tertentu [7]. Salah satu tujuan utama analisis sentimen adalah tentang studi dan analisis sensasi, emosi, sentimen, opini, penilaian, dan evaluasi yang terkandung dalam rekaman digital [8]. Analisis sentimen dapat menghasilkan *actionable knowledge* dari pendapat publik tentang suatu entitas [9]. Hasil analisis sentimen dapat bernilai positif, negatif, atau netral [10]. Data yang digunakan dalam penelitian ini diambil dari media sosial Twitter. Twitter adalah situs media sosial populer yang memungkinkan pengguna untuk mengirim pesan teks pendek yang panjangnya hingga 140 karakter [11]. Alasan menggunakan media sosial ini adalah karena pengguna Twitter bisa menyampaikan pendapat mereka tentang suatu topik tertentu, serta pengambilan data di Twitter bisa dilakukan dengan mudah. Salah satu metode yang digunakan untuk melakukan analisis sentimen adalah *Random Forest Classifier*. *Random Forest Classifier* merupakan *ensemble classifier* yang menghasilkan banyak *decision*

*tree* [12]. Kelebihan dari *Random Forest Classifier* adalah bisa mengidentifikasi data penting dengan cepat dari *dataset* besar, menangani *missing values*, dan mengurangi *overfitting* [13]. *Random Forest* mengurangi tingkat *overfitting* dengan menggabungkan beberapa evaluator *overfit (decision tree)* untuk membentuk algoritma *ensemble learning* [14].

Sebuah penelitian terdahulu menggunakan 150.000 data dari *review* pada aplikasi *Zomato* terhadap restoran di Bengaluru untuk mengukur nilai akurasi, presisi, dan *recall*. Pelabelan sentimen positif, negatif, dan netral dilakukan berdasarkan *rating*. *Rating* 1 dan 2 merupakan sentimen negatif, *rating* 3 merupakan sentimen netral, sedangkan *rating* 4 dan 5 merupakan sentimen positif. Tahapan yang dilakukan dalam penelitian ini adalah melakukan *lowercase*, *tokenization*, *remove numbers and punctuation*, *stopwords*, *pos tags*, dan *lemmatization*. Setelah itu, dilakukan pembobotan kata menggunakan *TF-IDF* dan juga *split data* menggunakan 80% *data training* dan 20% *data testing*. Nilai akurasi yang didapatkan adalah sebesar 92%, nilai presisi dari sentimen positif, negatif, dan netral secara berturut-turut adalah 92%, 93%, dan 96%, sedangkan nilai *recall* dari sentimen positif, negatif, dan netral secara berturut-turut adalah 99%, 89%, dan 73% [15]. Terdapat juga penelitian lain yang membandingkan tiga algoritma, yaitu *Naive Bayes*, *Random Forest*, dan *Support Vector Machine* menggunakan 1.629 data dari *review* pada *Google Play Store* terhadap aplikasi *Ruangguru*. Tahapan yang dilakukan adalah *tokenize*, *stemming*, *case folding*, dan *stopword removal*. Setelah itu, dilakukan pelabelan, lalu dilakukan penyeimbangan data menggunakan *SMOTE*. Berdasarkan penelitian tersebut, *Random Forest* mendapat hasil akurasi tertinggi dengan nilai 97,16% [16]. Berdasarkan latar belakang di atas, dilakukan sebuah penelitian untuk melihat performa *Random Forest Classifier* dalam melakukan analisis sentimen terhadap ChatGPT.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang yang sudah dijelaskan di atas, terdapat beberapa rumusan masalah sebagai berikut.

1. Bagaimana mengimplementasikan *Random Forest Classifier* untuk melakukan analisis sentimen terhadap ChatGPT?
2. Berapa nilai akurasi, presisi, *recall*, dan *f1-score* dari model *Random Forest Classifier*?

### 1.3 Batasan Permasalahan

Untuk mempertajam fokus penelitian, terdapat beberapa batasan masalah sebagai berikut.

1. Data yang digunakan diambil dari media sosial Twitter.
2. Data yang diambil adalah *tweet* Bahasa Indonesia yang mengandung kata kunci "chatgpt" (tidak *case sensitive*) sejak tanggal 30 November 2022 sampai 17 April 2023. Alasan menggunakan data sejak tanggal 30 November 2022 adalah karena ChatGPT dirilis pada tanggal tersebut, sedangkan tanggal 17 April 2023 merupakan tanggal pengambilan data.
3. Data sentimen terbagi menjadi positif, negatif, dan netral. Pelabelan dilakukan menggunakan Indonesia Sentiment Lexicon.

### 1.4 Tujuan Penelitian

Berdasarkan rumusan masalah yang sudah dibuat, tujuan penelitian ini adalah sebagai berikut.

1. Mengimplementasikan *Random Forest Classifier* untuk melakukan analisis sentimen terhadap ChatGPT.
2. Mengukur nilai akurasi, presisi, *recall*, dan *f1-score* dari model *Random Forest Classifier*.

### 1.5 Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut.

1. Membantu pemerintah dan masyarakat mendapatkan gambaran tentang respon pengguna ChatGPT di Indonesia. Setelah mendapatkan informasi tersebut, pemerintah juga bisa menentukan kebijakan terkait penggunaan ChatGPT.
2. Memudahkan *developer* dalam melakukan klasifikasi sentimen masyarakat secara otomatis.

## 1.6 Sistematika Penulisan

Sistematika penulisan laporan adalah sebagai berikut:

- Bab 1 PENDAHULUAN  
Pada Bab ini dilakukan penulisan tentang pendahuluan. Bagian yang perlu dituliskan pada bab ini adalah latar belakang, rumusan masalah, batasan permasalahan, tujuan penelitian, manfaat penelitian, dan sistematika penulisan.
- Bab 2 LANDASAN TEORI  
Pada Bab ini dilakukan penulisan tentang teori literatur yang digunakan dalam penelitian ini. Beberapa literatur yang dipelajari adalah *text mining*, analisis sentimen, *data scraping*, *remove duplicate*, *foreign word translation*, *text preprocessing*, *labeling*, *CountVectorizer*, *Term Frequency-Inverse Document Frequency (TF-IDF)*, *Synthetic Minority Oversampling Technique (SMOTE)*, *Random Forest Classifier*, *hyperparameter tuning*, dan *confusion matrix*.
- Bab 3 METODOLOGI PENELITIAN  
Pada Bab ini dilakukan penulisan tentang metodologi penelitian. Bagian yang perlu dituliskan pada bab ini adalah gambaran umum penelitian, studi literatur, pengumpulan data, pembuatan model, pengujian dan evaluasi, penulisan laporan, serta spesifikasi sistem.
- Bab 4 HASIL DAN DISKUSI  
Pada Bab ini dilakukan penulisan tentang hasil dan diskusi. Bagian yang perlu dituliskan pada bab ini adalah hasil implementasi, uji coba, hasil uji coba, dan diskusi.
- Bab 5 SIMPULAN DAN SARAN  
Pada Bab ini dilakukan penulisan tentang kesimpulan dari penelitian yang sudah dilakukan. Selain kesimpulan, dituliskan juga saran untuk pengembangan atau penelitian selanjutnya.