

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Melalui penelaahan berbagai penelitian sebelumnya yang berkaitan dengan analisis sentimen, khususnya pada domain e-commerce dan teks berbahasa Indonesia, peneliti dapat memahami perkembangan metode yang telah digunakan serta mengidentifikasi celah penelitian yang masih dapat dikembangkan. Kajian terhadap penelitian sebelumnya juga membantu dalam mengevaluasi pendekatan, teknik pemodelan, serta hasil yang telah dicapai oleh peneliti lain, sehingga penelitian ini memiliki posisi yang jelas dan kontribusi yang terarah dalam pengembangan model klasifikasi sentimen berbasis word embedding dan Long Short-Term Memory (LSTM). Rangkuman penelitian-penelitian terdahulu yang menjadi referensi dalam penelitian ini disajikan pada Tabel 2.1.

Tabel 2.1 Tabel Penelitian Terdahulu

Penelitian 1	
Judul	Analisis Sentimen Pengguna Shopee Menggunakan LSTM
Tahun	2025
Penulis	Pratiwi et al.
Tools / Method	LSTM + TF-IDF
Hasil	Model LSTM mencapai akurasi 86,48% untuk klasifikasi sentimen ulasan Shopee.
Gap Analysis	Menggunakan TF-IDF, belum menguji <i>word embedding</i> yang menangkap konteks semantik lebih baik untuk Bahasa Indonesia.

Penelitian 2	
Judul	Implementasi Long Short-Term Memory (LSTM) dan Word Embedding Model pada Analisis Sentimen Layanan Uang Elektronik Ovo dan Link Aja
Tahun	2023
Penulis	Iin Kurniasari, Achmad Arif Alfin ² , Eko Widodo
Tools / Method	LSTM + Word Embedding
Hasil	Mendapatkan akurasi ~79–83%; menunjukkan Word Embedding mampu meningkatkan representasi teks.
Gap Analysis	Fokus pada layanan uang elektronik, bukan ulasan produk e-commerce seperti kosmetik.
Penelitian 3	
Judul	<i>Performance Evaluation of Word Embedding Techniques in Twitter Sentiment Analysis Using LSTM</i>
Tahun	2025
Penulis	Ladayya et al.
Tools / Method	Word2Vec, GloVe, FastText + LSTM
Hasil	Word2Vec unggul dibandingkan embedding lain dalam sentiment classification Twitter Indonesia.
Gap Analysis	Konteks media sosial (Twitter), bukan ulasan produk e-commerce (Shopee).
Penelitian 4	

Judul	<i>URL-Based Sentiment Analysis of Product Reviews Using LSTM and GRU</i>
Tahun	2024
Penulis	Aakash, Shagun Gupta, Amandeep Noliya
Tools / Method	LSTM + GRU
Hasil	Model berhasil mengklasifikasi sentimen ulasan produk secara efisien dalam <i>e-commerce</i> .
Gap Analysis	Tidak fokus pada Bahasa Indonesia dan belum menerapkan embedding kontekstual spesifik Indonesia.
Penelitian 5	
Judul	<i>A Modernized Approach to Sentiment Analysis of Product Reviews using BiGRU & LSTM</i>
Tahun	2025
Penulis	Atlas et al.
Tools / Method	Hybrid BiGRU + LSTM
Hasil	Model hybrid menunjukkan akurasi lebih tinggi dalam klasifikasi ulasan produk secara umum.
Gap Analysis	Fokus pada model hybrid teknis, belum mengeksplorasi konteks lokal Indonesia atau domain produk tertentu.
Penelitian 6	
Judul	<i>Combining Bi-LSTM and Word2Vec Embedding for Sentiment Analysis Models</i>

Tahun	2024
Penulis	Lestari et al.
Tools / Method	Bi-LSTM + Word2Vec
Hasil	Kombinasi embedding Word2Vec dan Bi-LSTM mencapai akurasi ~87%, unggul dibanding LSTM saja.
Gap Analysis	Word2Vec dan Bi-LSTM mencapai akurasi ~87%, unggul dibanding LSTM saja. Berfokus pada ulasan aplikasi/perangkat lunak, bukan ulasan produk e-commerce kosmetik.
Penelitian 7	
Judul	<i>Transforming sentiment analysis for e-commerce product reviews: Hybrid deep learning</i>
Tahun	2024
Penulis	Punithavathi Rasappan, Manoharan Premkumar et al.
Tools / Method	<i>Modified LSTM + term weighting + optimizer</i>
Hasil	Model hybrid outperformed state-of-the-art, menunjukkan pentingnya fitur dan optimasi.
Gap Analysis	Model kompleks dengan optimasi tingkat lanjut; belum diuji khusus pada Bahasa Indonesia.
Penelitian 8	

Judul	<i>Comparison of RNN and LSTM Algorithms Based on FastText Embeddings in Sentiment Analysis on the Merdeka Mengajar Platform</i>
Tahun	2024
Penulis	Anjis Sapto Nugroho & Kristiawan Nugroho
Tools / Method	FastText + RNN/LSTM
Hasil	LSTM menunjukkan akurasi tinggi (~93%) dalam klasifikasi ulasan platform edukasi.
Gap Analysis	Fokus pada ulasan platform edukasi, bukan ulasan e-commerce; masih membuka peluang untuk studi lebih lanjut pada domain komersial & Bahasa Indonesia spesifik seperti review produk.
Penelitian 9	
Judul	<i>Food and Beverage Product Review Sentiment Analysis on E-Commerce with Word Embedding and LSTM</i>
Tahun	2025
Penulis	Herry Bowo et al.
Tools / Method	Word Embedding + LSTM
Hasil	Model mampu mengklasifikasikan ulasan produk makanan & minuman dengan tingkat akurasi cukup tinggi pada platform Tokopedia.

Gap Analysis	Penelitian dilakukan pada produk lain (F&B), belum secara spesifik pada ulasan produk kosmetik; peluang pengembangan pada domain kosmetik lokal masih terbuka.
Penelitian 10	
Judul	Sentiment Analysis of Indonesian <i>E-Commerce Reviews</i> Using IndoBERT and <i>Machine Learning Models</i>
Tahun	2025
Penulis	Wahyu Widyananda, Maskur, Ahmad Fauzi
Tools / Method	Text Embedding + Machine Learning Classifier
Hasil	Representasi teks berbasis embedding kontekstual menunjukkan peningkatan signifikan dalam menangkap makna semantik kalimat dibandingkan fitur tradisional, sehingga menghasilkan akurasi klasifikasi sentimen yang lebih tinggi pada data ulasan e-commerce berbahasa Indonesia.
Gap Analysis	Penelitian ini belum mengeksplorasi penggunaan Word Embedding statis yang dikombinasikan dengan arsitektur LSTM untuk menangkap dependensi sekuensial antar kata.
Penelitian 11	
Judul	<i>Sentiment Analysis Using Word2vec and Long Short-Term Memory (LSTM) for Indonesian Hotel Reviews</i>
Tahun	2021
Penulis	Muhammad, Kusumaningrum, Wibowo
Tools / Method	Word2Vec (Skip-gram) + LSTM

Hasil	Model mencapai akurasi terbaik 85,96% dalam klasifikasi sentimen ulasan hotel berbahasa Indonesia.
Gap Analysis	Berfokus pada domain ulasan hotel/OTA dengan ~2.500 data, belum membahas penanganan class imbalance; penelitian ini memperluas ke domain ulasan produk kosmetik lokal (Shopee) dengan 10.000 data serta menambahkan analisis class weight balancing.

Berdasarkan Tabel 2.1, dapat diketahui bahwa penelitian analisis sentimen telah banyak dilakukan dengan memanfaatkan berbagai metode deep learning, khususnya Long Short-Term Memory (LSTM) dan pengembangannya seperti Bidirectional LSTM (Bi-LSTM) serta Gated Recurrent Unit (GRU). Selain itu, berbagai penelitian juga mengkombinasikan model deep learning dengan teknik representasi teks seperti TF-IDF, Word2Vec, GloVe, FastText, maupun embedding kontekstual untuk meningkatkan kualitas pemrosesan teks.

Hasil penelitian terdahulu menunjukkan bahwa penggunaan Word Embedding mampu membantu model dalam memahami hubungan antar kata dan konteks kalimat dengan lebih baik dibandingkan metode representasi teks tradisional. Kombinasi Word Embedding dan LSTM juga telah diterapkan pada berbagai domain, seperti media sosial, layanan digital, platform pendidikan, serta ulasan produk e-commerce, dan menunjukkan performa yang baik dalam tugas klasifikasi sentimen. Selain itu, beberapa penelitian menunjukkan bahwa pengembangan arsitektur model, seperti penggunaan Bi-LSTM, GRU, maupun pendekatan hybrid, dapat meningkatkan kemampuan model dalam memahami konteks teks dan menghasilkan performa klasifikasi yang lebih baik.

Meskipun demikian, sebagian besar penelitian masih berfokus pada peningkatan performa model berdasarkan metrik evaluasi seperti accuracy, precision, recall, dan F1-score. Penelitian yang memanfaatkan hasil analisis sentimen untuk menggali persepsi konsumen dan menghasilkan insight yang dapat

digunakan sebagai dasar pengambilan keputusan bisnis masih relatif terbatas. Selain itu, penelitian pada domain kosmetik lokal Indonesia juga masih belum banyak dilakukan dibandingkan domain lainnya.

Berdasarkan hasil kajian penelitian terdahulu, dapat disimpulkan bahwa penggunaan Word Embedding dan Long Short-Term Memory (LSTM) telah banyak digunakan dalam penelitian analisis sentimen pada berbagai bidang, seperti media sosial, layanan digital, platform pendidikan, maupun ulasan produk *e-commerce*. Hasil penelitian tersebut menunjukkan bahwa metode tersebut mampu digunakan untuk mengklasifikasikan sentimen dengan cukup baik sehingga penggunaannya dalam analisis sentimen sudah cukup umum dilakukan.

Meskipun demikian, penelitian yang membahas analisis sentimen pada ulasan produk kosmetik lokal Indonesia masih relatif terbatas. Sebagian besar penelitian terdahulu lebih banyak berfokus pada pengukuran kinerja model menggunakan metrik evaluasi seperti accuracy, precision, recall, dan F1-score. Padahal, hasil analisis sentimen juga dapat dimanfaatkan untuk mengetahui persepsi konsumen terhadap suatu produk dan menjadi bahan pertimbangan dalam pengambilan keputusan bisnis.

Selain itu, ulasan produk kosmetik memiliki karakteristik yang berbeda dengan domain lainnya karena banyak dipengaruhi oleh pengalaman penggunaan masing-masing konsumen, seperti kecocokan dengan jenis kulit, kualitas produk, warna, aroma, maupun efek yang dirasakan setelah penggunaan. Oleh karena itu, penelitian ini dilakukan untuk menganalisis sentimen ulasan produk Wardah pada platform Shopee menggunakan metode Word2Vec dan Long Short-Term Memory (LSTM), serta mengidentifikasi persepsi konsumen yang terkandung dalam ulasan sehingga dapat memberikan informasi yang bermanfaat bagi evaluasi dan pengembangan produk.

2.2 Teori terkait Penelitian

Penelitian ini didasarkan pada beberapa teori utama dalam bidang *Natural Language Processing* dan *Deep Learning*, khususnya analisis sentimen,

representasi teks, serta pemodelan data sekuensial. Dari sisi analisis teks, teori analisis sentimen digunakan untuk mengidentifikasi dan mengklasifikasikan opini pengguna terhadap produk berdasarkan ulasan yang diberikan. Dari sisi representasi data, teknik word embedding digunakan untuk mengubah teks menjadi vektor numerik yang mampu merepresentasikan makna semantik kata. Sementara itu, dari sisi pemodelan data, metode Long Short-Term Memory (LSTM) digunakan untuk memproses data teks sebagai urutan (sequence) sehingga mampu menangkap hubungan kontekstual antar kata dalam kalimat. Integrasi ketiga pendekatan tersebut menghasilkan model yang mampu melakukan klasifikasi sentimen secara lebih akurat pada ulasan produk Wardah di platform Shopee, berikut penjelasan pada masing-masing teori yang digunakan:

2.2.1 E-Commerce

Electronic commerce (e-commerce) merupakan suatu sistem transaksi digital yang memungkinkan terjadinya pertukaran barang maupun jasa melalui jaringan internet, di mana platform online berperan sebagai perantara utama antara pihak penjual dan pembeli. Dalam implementasinya, aktivitas e-commerce tidak hanya terbatas pada proses jual beli, tetapi juga mencakup tahapan pencarian informasi produk, perbandingan alternatif, proses pemesanan, transaksi pembayaran, hingga distribusi barang kepada konsumen. Seluruh proses tersebut didukung oleh sistem informasi seperti manajemen katalog produk, pengelolaan pesanan, serta layanan pelanggan yang terintegrasi dalam website maupun aplikasi.

Keberadaan platform e-commerce berfungsi tidak hanya sebagai media promosi, tetapi juga sebagai infrastruktur transaksi yang memungkinkan proses perdagangan berlangsung lebih efisien, terdokumentasi dengan baik, serta memiliki jangkauan pasar yang lebih luas dibandingkan dengan metode konvensional. Selain itu, dalam ekosistem digital, e-commerce memberikan peluang besar bagi pelaku usaha mikro, kecil, dan menengah (UMKM) untuk memperluas pasar, membangun reputasi melalui ulasan pelanggan, serta meningkatkan efisiensi operasional berbasis data.

Klasifikasi model bisnis dalam e-commerce dapat dibedakan berdasarkan hubungan antar pelaku transaksi, antara lain *Business-to-Consumer* (B2C), *Business-to-Business* (B2B), *Consumer-to-Consumer* (C2C), dan *Consumer-to-Business* (C2B). Di antara berbagai model tersebut, B2C menjadi yang paling banyak digunakan pada *platform marketplace* karena menawarkan kemudahan dalam pencarian produk, promosi, serta sistem pembayaran dan pengiriman yang telah terintegrasi. Pertumbuhan ini juga didukung oleh meningkatnya penetrasi internet dan penggunaan perangkat mobile, adopsi sistem pembayaran digital seperti *electronic wallet* (*e-wallet*), serta kemajuan sektor logistik termasuk layanan *last-mile delivery* yang berperan dalam mempercepat proses distribusi dan meningkatkan kepuasan pelanggan.

2.2.2 *Sentiment Analysis*

Analisis sentimen (*sentiment analysis*) merupakan salah satu tugas utama dalam *Natural Language Processing* (NLP) yang berfokus pada identifikasi, ekstraksi, dan klasifikasi opini, emosi, atau sikap yang terkandung dalam teks terhadap suatu entitas tertentu seperti produk, layanan, atau isu tertentu. Proses ini bertujuan untuk menentukan polaritas sentimen yang umumnya dikategorikan ke dalam kelas positif, negatif, atau netral. Analisis sentimen banyak diterapkan data tidak terstruktur seperti ulasan produk, media sosial, dan forum online, yang mengandung opini pengguna dalam jumlah besar.

Secara umum, proses analisis sentimen melibatkan beberapa tahapan utama, yaitu *data collection*, *text preprocessing* (tokenisasi, normalisasi, *stopword removal*, *stemming*), *feature extraction*, serta *classification*. Tantangan utama dalam analisis sentimen terletak pada kompleksitas bahasa alami, seperti ambiguitas makna, penggunaan bahasa informal, ironi, serta konteks kalimat yang mempengaruhi interpretasi sentimen.

Perkembangan metode analisis sentimen telah mengalami pergeseran dari pendekatan berbasis leksikon dan *machine learning* tradisional menuju pendekatan berbasis *deep learning*. Model *deep learning* mampu secara otomatis mengekstraksi fitur dari data tanpa memerlukan *feature engineering*


secara manual. Penelitian menunjukkan bahwa pendekatan deep learning secara signifikan meningkatkan performa analisis sentimen karena mampu menangkap hubungan kompleks dalam teks. Selain itu, penggunaan model deep learning seperti LSTM dan CNN terbukti efektif dalam mengolah data teks yang bersifat sekuensial dan tidak terstruktur, sehingga menghasilkan akurasi klasifikasi yang lebih tinggi dibandingkan metode konvensional. Oleh karena itu, analisis sentimen berbasis deep learning menjadi pendekatan yang dominan dalam penelitian modern.

2.2.3 Word Embedding

Word embedding merupakan teknik representasi kata dalam bentuk vektor numerik berdimensi tinggi yang bertujuan untuk menangkap hubungan semantik dan sintaktik antar kata dalam suatu korpus teks. Berbeda dengan pendekatan tradisional seperti Bag-of-Words dan TF-IDF yang hanya mempertimbangkan frekuensi kemunculan kata, word embedding mampu merepresentasikan makna kata berdasarkan konteks penggunaannya dalam kalimat.

Metode *word embedding* yang populer meliputi Word2Vec, GloVe, dan FastText. Word2Vec, misalnya, menggunakan model neural network untuk mempelajari representasi kata berdasarkan konteks lokal (context window), sedangkan GloVe memanfaatkan statistik global dari korpus teks. FastText memperluas konsep ini dengan mempertimbangkan subword atau karakter n gram, sehingga lebih efektif dalam menangani kata yang jarang muncul (rare words).

UNIVERSITAS
MULTIMEDIA
NUSANTARA



Gambar 2.1 Arsitektur *Word Embedding*

Peran *word embedding* dalam analisis sentimen sangat penting karena menjadi tahap *feature extraction* yang menentukan kualitas representasi data sebelum diproses oleh model klasifikasi. Penelitian menunjukkan bahwa penggunaan word embedding secara signifikan meningkatkan performa model deep learning karena mampu menyediakan representasi semantik yang lebih kaya. Selain itu, berbagai penelitian menunjukkan bahwa kombinasi embedding dengan teknik pembobotan seperti TF-IDF dapat lebih meningkatkan akurasi model karena menggabungkan informasi semantik dan pentingnya kata dalam dokumen. Bahkan, pemilihan jenis embedding yang tepat dapat berdampak signifikan terhadap performa model, terutama pada bahasa dengan kompleksitas morfologi tinggi.


Pada penelitian ini, teknik *Word Embedding* yang digunakan adalah Word2Vec. Metode ini dipilih karena mampu merepresentasikan kata ke dalam bentuk vektor numerik berdasarkan konteks kemunculannya dalam korpus teks. Word2Vec yang digunakan dibangun menggunakan arsitektur Skip-Gram dengan ukuran vektor sebesar 100 dimensi, nilai window sebesar 5, nilai

min_count sebesar 2, dan jumlah pelatihan sebanyak 10 epoch. Hasil representasi vektor yang diperoleh kemudian digunakan untuk membentuk embedding matrix yang menjadi masukan pada model Long Short-Term Memory (LSTM) dalam proses klasifikasi sentimen ulasan produk Wardah.

2.3 Framework/Algoritma yang digunakan

2.3.1 *Cross-Industry Standard Process for Data Mining (CRISP-DM)*

Cross-Industry Standard Process for Data Mining atau CRISP-DM dikembangkan pada tahun 1996 oleh sekelompok perusahaan, merupakan suatu standar yang ditujukan untuk melakukan proses analisis strategi pemecahan masalah dari bisnis atau unit penelitian di suatu industri.



Gambar 2.2 *Framework* CRISP-DM

Sebagaimana ditunjukkan pada Gambar 2.2, CRISP-DM merupakan sebuah kerangka kerja data mining yang tersusun atas enam tahapan utama, yaitu Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, dan Deployment. Keenam tahapan tersebut membentuk suatu siklus yang saling berkaitan dan menyediakan alur kerja yang sistematis dalam pelaksanaan proyek data mining, dimulai dari identifikasi kebutuhan bisnis hingga penerapan model ke dalam lingkungan operasional.

Tahap *Business Understanding* berfokus pada perumusan permasalahan dan tujuan bisnis, yang kemudian diterjemahkan menjadi sasaran data mining yang terukur. Tahap *Data Understanding* mencakup proses pengumpulan data awal serta eksplorasi data untuk memperoleh pemahaman awal dan mendeteksi potensi permasalahan pada dataset. Selanjutnya, pada tahap *Data Preparation*, data melalui proses pembersihan, transformasi, dan integrasi agar siap digunakan dalam pembangunan model. Tahap *Modeling* melibatkan pemilihan metode dan teknik data mining yang sesuai serta proses pelatihan model berdasarkan data yang telah dipersiapkan. Kinerja model kemudian dievaluasi pada tahap *Evaluation* untuk memastikan kesesuaiannya dengan tujuan yang telah ditetapkan, sebelum akhirnya model diimplementasikan pada tahap *Deployment* untuk digunakan dalam konteks nyata.


CRISP-DM banyak digunakan karena memiliki struktur yang bersifat modular dan fleksibel, sehingga dapat diterapkan pada berbagai bidang, seperti industri manufaktur, sektor kesehatan, dan layanan keuangan. Meskipun demikian, beberapa studi mencatat adanya keterbatasan, antara lain minimnya panduan teknis yang rinci pada tahap *deployment* serta kebutuhan adaptasi tambahan ketika diterapkan pada data yang lebih kompleks, seperti data temporal atau data berskala besar. Dengan berbagai pengembangan dan penyesuaian, CRISP-DM tetap dipertahankan sebagai salah satu metodologi standar yang relevan dalam praktik analitik dan data mining hingga saat ini.

2.3.2 Long Short-Term Memory

Long Short-Term Memory (LSTM) merupakan salah satu arsitektur *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi permasalahan *vanishing gradient* yang sering terjadi pada RNN tradisional. LSTM memiliki kemampuan untuk menyimpan informasi dalam jangka panjang melalui mekanisme *memory cell* dan tiga jenis gerbang utama, yaitu *input gate*, *forget gate*, dan *output gate*.

Keunggulan utama LSTM terletak pada kemampuannya dalam menangani data sekuensial, seperti teks, di mana urutan kata memiliki pengaruh besar

terhadap makna keseluruhan kalimat. Dalam konteks analisis sentimen, LSTM mampu menangkap dependensi jangka panjang antar kata, sehingga dapat memahami konteks kalimat secara lebih mendalam dibandingkan model tradisional. Gambaran arsitektur dari model LSTM dapat dilihat pada Gambar 2.3.



Gambar 2.3 Arsitektur *Model Long Short-Term Memory*

Penelitian menunjukkan bahwa LSTM memiliki performa yang sangat baik dalam tugas klasifikasi sentimen, terutama ketika dikombinasikan dengan word embedding sebagai representasi input. Selain itu, pengembangan lebih lanjut seperti Bidirectional LSTM (Bi-LSTM) memungkinkan model untuk memproses informasi dari dua arah (*forward* dan *backward*), sehingga mampu memahami konteks secara lebih komprehensif. Hal ini terbukti meningkatkan akurasi dalam berbagai penelitian analisis sentimen. Lebih lanjut, kombinasi LSTM dengan model lain seperti CNN atau mekanisme *attention* juga menunjukkan peningkatan performa yang signifikan karena mampu menangkap fitur lokal sekaligus dependensi global dalam teks.

2.4 Tools Penelitian

2.4.1 *Google Collaboratory*

Google Colaboratory atau *Google Colab* merupakan platform berbasis cloud yang menyediakan lingkungan *notebook* Jupyter interaktif secara gratis. Platform ini memungkinkan pengguna menjalankan kode Python langsung melalui browser tanpa perlu melakukan konfigurasi perangkat keras lokal.

Google Colab populer di kalangan peneliti dan praktisi data science karena menyediakan akses mudah ke sumber daya komputasi seperti GPU dan TPU, yang secara signifikan mempercepat proses pelatihan model machine learning, terutama untuk model yang besar dan kompleks.

Selain itu, Google Colab mendukung kolaborasi dengan memungkinkan beberapa pengguna mengakses dan mengedit *notebook* yang sama secara real time. Integrasi dengan Google Drive memudahkan penyimpanan data dan hasil eksperimen. Fitur-fitur ini menjadikan Google Colab alat yang efisien untuk pengembangan, eksperimen, dan dokumentasi model *machine learning*, sekaligus memberikan solusi yang fleksibel dan hemat biaya bagi penelitian atau prototipe yang membutuhkan sumber daya komputasi tinggi tanpa harus memiliki perangkat keras khusus.

2.4.2 Python

Python adalah bahasa untuk pemrograman berorientasi objek. Contoh lain dari bahasa pemrograman tingkat tinggi adalah Python. Selain itu, sintaks bahasa pemrograman ini biasanya sangat mudah dan sederhana untuk dipahami. Selain itu, pustaka Python tersedia untuk umum dan tidak memerlukan biaya. Python seharusnya dapat meningkatkan produktivitas pengguna karena tidak perlu melakukan kompilasi dan memungkinkan proses edit, tes, dan debug yang sangat cepat. Selain itu, Python hanya akan mengeluarkan pengecualian dan bukannya kesalahan segmentasi ketika programmer memasukkan data yang salah.