

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Tabel 2.1 Penelitian Terdahulu

No	Penulis	Studi Fokus	Metodologi	Temuan Utama	Akurasi
1	Zhang et al. (2020)	Evaluasi kualitas UI berbasis feedback pengguna	<i>Deep Learning (CNN-LSTM)</i>	Mengidentifikasi pola dari feedback untuk mengklasifikasi kualitas antarmuka	84%
2	Xie et al. (2021)	Evaluasi UI menggunakan data log interaksi pengguna	<i>Log-based Analysis + SVM</i>	Log aktivitas dapat digunakan untuk menilai efektivitas UI	80%
3	Wang & Fang (2022)	Prediksi usability menggunakan machine learning	<i>Random Forest & Gradient Boosting</i>	Data uji sistem dapat digunakan sebagai prediktor usability score	87%
4	Nguyen et al. (2021)	Evaluasi otomatis UI berbasis visual dan teks	<i>CNN + NLP</i>	Menggabungkan fitur visual dan teks meningkatkan hasil evaluasi	89%

N o	Penulis	Studi Fokus	Metodologi	Temuan Utama	Akuras i
5	Dostie, Kromann, & Sørensen (2025)	Analisis peran tingkat pendidikan tenaga kerja dalam membantu perusahaan mengatasi hambatan inovasi dan meningkatkan keberhasilan inovasi.	<i>Endogenous Switching Regression Model</i> menggunakan data survei inovasi (<i>Community Innovation Survey</i>) dan data registrasi perusahaan di Denmark periode 2006–2018.	Perusahaan yang menghadapi hambatan inovasi memiliki probabilitas keberhasilan inovasi yang lebih tinggi ketika memiliki tingkat skill tenaga kerja yang lebih tinggi. Skill intensity terbukti signifikan hanya pada kondisi perusahaan yang menghadapi hambatan, sementara pada perusahaan tanpa hambatan pengaruhnya tidak signifikan.	-

No	Penulis	Studi Fokus	Metodologi	Temuan Utama	Akurasi
6	Natalia et al. (2019)	Visualisasi pola data menggunakan dashboard interaktif.	<i>K-Medoids</i> , <i>DBSCAN</i> , <i>X-Means</i> + <i>Power BI Dashboard</i>	Menghasilkan dashboard interaktif untuk memvisualisasikan pola banjir berdasarkan klasterisasi data sehingga dapat digunakan untuk pengambilan keputusan oleh pengguna non-teknis.	-

Penelitian-penelitian terdahulu pada Tabel 1 menunjukkan bahwa evaluasi kualitas antarmuka pengguna (UI) telah banyak dikaji melalui pendekatan berbasis data, baik dari sisi teks, log aktivitas, maupun visualisasi. Zhang et al. [1] dan Nguyen et al. [5] sama-sama menekankan pentingnya **analisis feedback pengguna**, di mana komentar teks dapat digunakan untuk mengidentifikasi kualitas UI melalui model deep learning. Sementara Xie et al. [3] serta Wang dan Fang [4] menyoroti keterkaitan antara **log interaksi pengguna**, seperti waktu penggunaan, jumlah klik/error, dan aktivitas system dengan efektivitas UI. Temuan-temuan ini saling melengkapi, menunjukkan bahwa evaluasi UI yang komprehensif memerlukan kombinasi informasi subjektif (feedback) dan objektif (interaction logs). Pendekatan berbasis Transformer yang diperkenalkan oleh Liu et al. [13] memberikan peningkatan akurasi signifikan dalam pemahaman teks, sehingga menjadi dasar kuat untuk mengolah feedback pengguna dengan model modern seperti BERT. Sementara itu, Natalia et al. [17] memberikan kontribusi penting pada aspek visualisasi, yaitu bagaimana hasil analisis dapat disajikan dalam bentuk dashboard interaktif untuk mendukung pengambilan keputusan.

Dari keterhubungan tersebut terlihat bahwa penelitian sebelumnya telah membangun fondasi kuat dalam pemanfaatan data teks, log interaksi, dan visualisasi untuk keperluan evaluasi UI. Namun, belum ada penelitian yang secara langsung mengintegrasikan seluruh jenis data tersebut dalam satu kerangka kerja prediktif menggunakan model *Transformer* dan menggabungkannya dengan visualisasi dashboard untuk interpretasi hasil. Oleh karena itu, penelitian ini mengadopsi elemen-elemen penting dari studi terdahulu, yakni pemrosesan feedback teks, pemanfaatan log interaksi, dan teknik visualisasi dashboard untuk membangun pendekatan hybrid yang mampu memprediksi kualitas UI secara objektif dan menyajikannya dalam bentuk visual yang mudah dipahami.

Berdasarkan kajian terhadap penelitian terdahulu, dapat disimpulkan bahwa pendekatan machine learning telah banyak diterapkan dalam evaluasi kualitas antarmuka pengguna (UI). Berbagai algoritma seperti *Convolutional Neural Network* (CNN), *Long Short-Term Memory* (LSTM), dan *Support Vector Machine* (SVM) dimanfaatkan untuk menganalisis data log interaksi, umpan balik pengguna, serta fitur visual antarmuka guna mengukur tingkat kualitas dan usability sistem. Hasil penelitian-penelitian tersebut menunjukkan bahwa pemanfaatan data historis pengujian sistem dapat memberikan dasar evaluasi UI yang lebih objektif dibandingkan metode manual.

Selain itu, penelitian yang mengintegrasikan lebih dari satu jenis data, khususnya data teks dan visual, cenderung menghasilkan akurasi prediksi yang lebih tinggi dibandingkan pendekatan berbasis satu modalitas. Penggabungan informasi visual antarmuka dengan feedback pengguna memungkinkan model untuk menangkap aspek fungsional dan perseptual secara bersamaan, sehingga evaluasi kualitas UI menjadi lebih komprehensif.

Lebih lanjut, perkembangan model berbasis *Transformer*, khususnya BERT, menawarkan kemampuan representasi teks yang lebih unggul dibandingkan pendekatan NLP tradisional. Dengan mekanisme attention dan pemahaman konteks dua arah, BERT mampu menangkap makna dan nuansa bahasa dalam *feedback*

pengguna secara lebih mendalam. Keunggulan ini menjadikan model *Transformer* sebagai pendekatan yang relevan dan potensial untuk digunakan dalam evaluasi kualitas UI berbasis data teks, terutama ketika dikombinasikan dengan data interaksi sistem dan visualisasi hasil analisis.

2.2 Teori tentang Topik Skripsi

2.2.1 Antarmuka Pengguna (*User Interface/UI*)

Antarmuka Pengguna (UI) adalah media interaksi antara sistem komputer dan pengguna. UI mencakup elemen visual seperti tombol, ikon, menu, warna, tipografi, serta struktur tata letak antarmuka yang memungkinkan pengguna untuk mengakses dan mengendalikan sistem [11]. UI yang dirancang dengan baik dapat mempengaruhi kepuasan pengguna, meningkatkan efisiensi tugas, serta mengurangi tingkat kesalahan interaksi.

Tujuan utama dari perancangan UI adalah untuk menciptakan sistem yang **intuitif**, **mudah dipelajari**, dan **nyaman digunakan**. Faktor-faktor penting dalam kualitas UI meliputi konsistensi desain, kejelasan navigasi, waktu respons sistem, serta kemudahan akses informasi [12].

2.2.2 Evaluasi Kualitas UI

Evaluasi UI merupakan proses penilaian terhadap seberapa baik antarmuka pengguna mendukung penggunaan sistem. Kualitas UI dapat diukur melalui pendekatan **kuantitatif** maupun **kualitatif**, termasuk pengukuran usability, analisis task completion, feedback pengguna, hingga pengamatan terhadap interaksi pengguna [13].

Menurut standar ISO 9241-11, usability didefinisikan sebagai tingkat efektivitas, efisiensi, dan kepuasan yang dicapai oleh pengguna dalam konteks penggunaan tertentu. Evaluasi manual seperti heuristic evaluation dan usability testing masih lazim digunakan, namun metode ini cenderung subjektif dan memerlukan sumber daya manusia yang banyak [14].

2.2.3 *Machine Learning* dalam Evaluasi UI

Dalam beberapa tahun terakhir, pendekatan berbasis machine learning mulai digunakan untuk mengevaluasi UI secara otomatis. Model ini dapat belajar dari data historis seperti log aktivitas pengguna, feedback teks, serta metadata antarmuka untuk memprediksi kualitas atau mendeteksi masalah desain. Teknik yang umum digunakan meliputi klasifikasi, clustering, dan regression analysis terhadap berbagai fitur UI [15].

Pendekatan ini memberikan keunggulan dalam hal **skalabilitas, kecepatan evaluasi, serta reduksi bias subjektif** yang umum dijumpai dalam metode manual.

2.2.4 **Model Transformer dan BERT**

Model Transformer adalah arsitektur deep learning berbasis attention mechanism yang pertama kali diperkenalkan oleh Vaswani et al. (2017). Tidak seperti model berbasis RNN, Transformer memungkinkan pemrosesan paralel terhadap data sekuensial, sehingga lebih efisien dan akurat dalam memahami konteks panjang dalam data teks [16].

BERT (Bidirectional Encoder Representations from Transformers) adalah varian Transformer yang dilatih secara dua arah (bidirectional) untuk memahami konteks kata dalam kalimat secara lebih utuh. BERT telah digunakan secara luas dalam klasifikasi teks, ekstraksi entitas, sentiment analysis, hingga sistem tanya jawab [17].

Dalam konteks skripsi ini, BERT digunakan untuk merepresentasikan data teks seperti feedback pengguna dan deskripsi error yang muncul selama proses pengujian sistem. Kemampuannya untuk memahami konteks memungkinkan BERT memberikan hasil prediksi yang lebih akurat dibanding model tradisional.

2.3 Teori tentang Framework/Algoritma yang digunakan

Dalam penelitian ini, pendekatan utama yang digunakan adalah model **Transformer**, khususnya **BERT (Bidirectional Encoder Representations from Transformers)**, yang dibandingkan dengan beberapa algoritma machine learning lain yang juga populer digunakan dalam prediksi dan evaluasi kualitas UI.

Tabel 2.2 menyajikan perbandingan beberapa algoritma/framework berdasarkan deskripsi umum, kelebihan, kekurangan, dan kinerja yang diharapkan.

Tabel 2.2 Perbandingan Framework

<i>Model</i>	<i>Deskripsi</i>	<i>Kelebihan</i>	<i>Kekurangan</i>	<i>Kinerja yang diharapkan</i>	<i>Ref</i>
<i>CNN-LSTM</i>	Kombinasi Convolutional Neural Network (untuk visual) dan Long Short-Term Memory (untuk sekuensial data)	Baik dalam menangkap fitur spasial dan temporal secara bersamaan	Waktu pelatihan lebih lama, rawan overfitting	Akurasi tinggi untuk kombinasi teks dan gambar, tapi butuh tuning intensif	[6]
<i>Random Forest</i>	Ensemble learning berbasis pohon keputusan untuk klasifikasi atau regresi	Cepat dalam pelatihan, mudah diinterpretasi	Tidak efektif menangani data teks panjang atau konteks kompleks	Cocok untuk dataset tabular sederhana	[8]

<i>Model</i>	<i>Deskripsi</i>	<i>Kelebihan</i>	<i>Kekurangan</i>	<i>Kinerja yang diharapkan</i>	<i>Ref</i>
<i>CNN + NLP</i>	Kombinasi model visual (CNN) dengan NLP tradisional untuk analisis multimodal UI	Mampu menggabungkan informasi visual dan teks dasar	NLP tradisional tidak memahami konteks sedalam Transformer	Akurasi sedang, tergantung preprocessing teks	[9]
<i>BERT (Transformer)</i>	Model deep learning berbasis attention mechanism yang mempelajari representasi kontekstual dari teks secara dua arah	Unggul dalam pemahaman konteks, pre-trained, dan bisa disesuaikan dengan task spesifik	Membutuhkan sumber daya komputasi besar, interpretasi kompleks	Akurasi tinggi, performa stabil dalam klasifikasi dan prediksi teks	[17]

Model **BERT** dipilih dalam penelitian ini karena kemampuannya dalam memahami konteks kalimat yang kompleks dan performanya yang sangat baik dalam tugas klasifikasi berbasis teks. Dalam konteks evaluasi UI, BERT mampu memahami makna feedback pengguna, deskripsi bug, dan teks dalam laporan SIT secara lebih mendalam dibanding model lain. Hal ini diharapkan dapat menghasilkan prediksi yang lebih akurat dan relevan dengan kondisi UI aktual.

2.4 Teori tentang tools/software yang digunakan

Tabel 2.3 Perbandingan Software

<i>Perangkat Lunak</i>	<i>Kategori</i>	<i>Fitur</i>	<i>Pro</i>	<i>Kontra</i>	<i>Kasus Pengguna an Terbaik</i>	<i>Ref</i>
<i>Python (Jupyter)</i>	<i>Pemrograman & Analitik</i>	Library lengkap (pandas, sklearn, transformers, matplotlib, seaborn)	Open-source, fleksibel, komunitas luas	Perlu instalasi library secara manual, performa lambat jika tidak dioptimalkan	Data preprocessing, training model, evaluasi performa ML	[12], [15]
<i>Transformers (HuggingFace)</i>	<i>Framework NLP</i>	Pre-trained model (BERT, RoBERTa, DistilBERT), tokenizer, fine-tuning tools	Mendukung berbagai model, dokumentasi lengkap	Membutuhkan GPU untuk proses training lebih cepat	Fine-tuning model teks seperti BERT untuk klasifikasi UI	[17]
<i>Excel</i>	<i>Spreadsheet & Data Mart</i>	Manipulasi data sederhana, kompilasi manual, pivot table	Mudah digunakan, cepat untuk tabulasi awal	Tidak cocok untuk pemrosesan data besar atau otomatisasi - Generalisasi terbatas.	Pembuatan data mart awal dari dokumen pengujian sistem	[8]
<i>Tableau / Power BI</i>	<i>Visualisasi Data</i>	Dashboard interaktif, integrasi ke Excel dan Python	Antarmuka user-friendly, drag & drop	Kustomisasi terbatas untuk analitik lanjutan	Visualisasi skor UI, distribusi kategori, insight desain ulang	[14]

Dalam penelitian ini, pemilihan alat difokuskan pada kemudahan integrasi antara data teks, visual, dan output model. Python digunakan sebagai inti

pemrosesan karena mendukung berbagai library NLP dan visualisasi, serta integrasi dengan model Transformer. Excel digunakan untuk membangun data mart awal karena fleksibel dan familiar di lingkungan kerja. Untuk visualisasi, digunakan Tableau/Power BI karena mampu menyajikan hasil prediksi secara interaktif dan informatif.

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

CRISP-DM merupakan kerangka kerja standar yang banyak digunakan dalam proyek data mining dan machine learning. Model ini masih menjadi pendekatan yang paling luas diadopsi karena fleksibilitas, skalabilitas, serta struktur proses yang sistematis. CRISP-DM terdiri dari enam fase utama yang membentuk siklus analitik secara menyeluruh, yaitu Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, dan Deployment.

1) Business Understanding

Fase ini bertujuan memahami tujuan bisnis dan mendefinisikan permasalahan yang akan diselesaikan melalui pendekatan data. Hasil fase ini berupa rumusan masalah analitik dan tujuan model.

2) Data Understanding

Pada tahap ini, mengumpulkan, memeriksa, dan memahami karakteristik data awal. Proses eksplorasi dilakukan untuk mengidentifikasi kualitas data, nilai hilang, keberagaman fitur, serta potensi masalah data.

3) Data Preparation

Tahap ini mencakup pembersihan, transformasi, dan penyusunan data agar siap digunakan dalam pemodelan. Kegiatan dapat berupa normalisasi, encoding, integrasi data, dan pembentukan dataset final.

4) Modeling

Pada fase ini dilakukan pemilihan algoritma, pelatihan model, penyesuaian parameter, serta evaluasi awal terhadap performa model.

5) **Evaluation**

Model yang telah dibangun dievaluasi menggunakan metrik tertentu untuk memastikan kualitas prediksi dan kesesuaian dengan tujuan awal. Bias, error, dan validitas hasil dievaluasi sebelum model digunakan lebih lanjut.

6) **Deployment**

Tahap akhir berupa penerapan hasil analisis ke dalam bentuk implementasi, seperti laporan, dashboard, automasi, atau sistem pendukung keputusan.

CRISP-DM digunakan sebagai dasar metodologi dalam penelitian ini karena kerangka tersebut mendukung proses analitik yang terstruktur dari tahap pemahaman masalah hingga penyajian hasil. Selain itu, CRISP-DM cocok diterapkan pada penelitian yang memerlukan integrasi antara data numerik dan teks, serta proses pemodelan prediktif seperti pada analisis kualitas antarmuka pengguna (UI). Dengan menggunakan CRISP-DM sebagai landasan metodologis, penelitian ini memiliki kerangka alur penelitian yang jelas dan dapat direplikasi.

