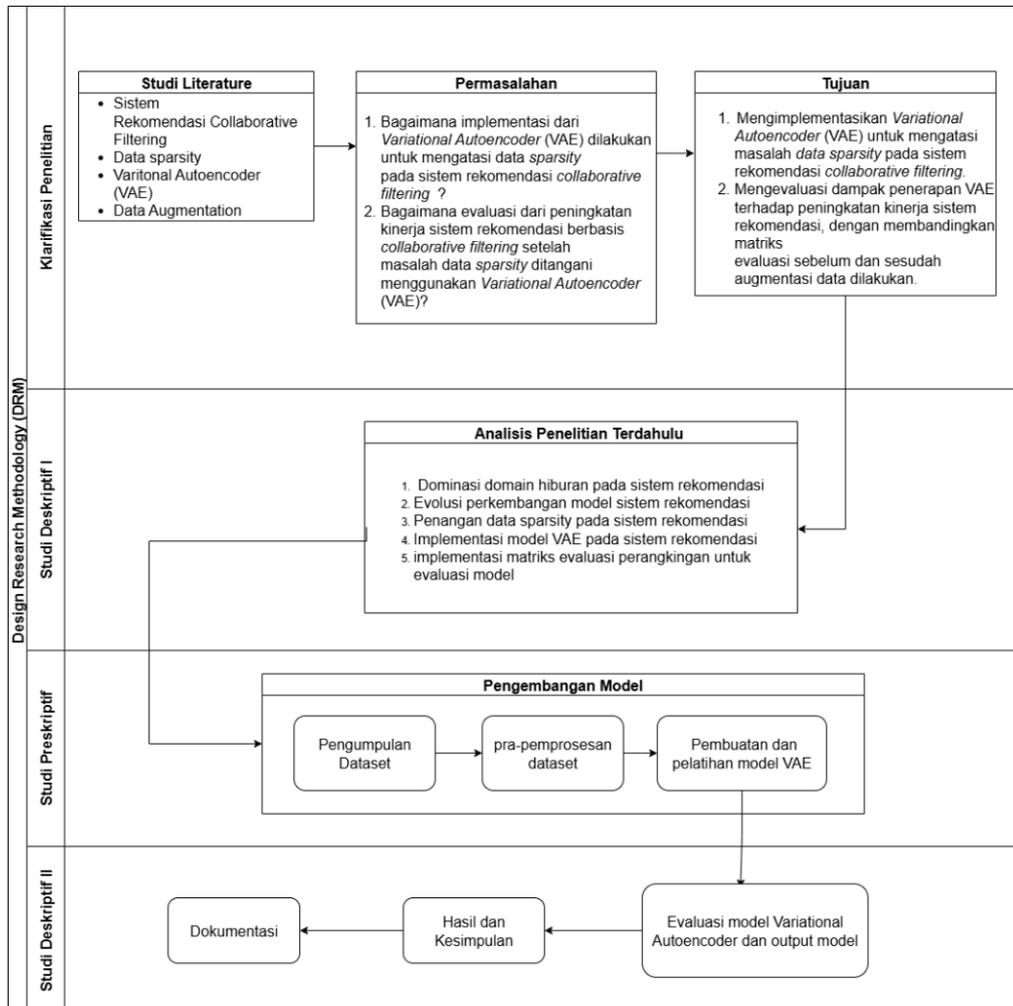


BAB III

METODE PENELITIAN

3.1. Metode Penelitian

Metodologi Penelitian *Design Research Methodology* (DRM) dipilih karena memberikan kerangka kerja yang sistematis untuk mengembangkan solusi teknis terhadap permasalahan yang ada. Pendekatan ini menekankan tahapan desain, implementasi, dan evaluasi secara terstruktur, sehingga peneliti dapat melakukan perbaikan berulang pada model desain berdasarkan hasil evaluasi yang diperoleh selama penelitian demi mencapai solusi yang optimal (Peffer dkk., 2007).



Gambar 3.1 *Design Research Methodology* (DRM)

3.2. Klarifikasi Penelitian

Tahap klarifikasi penelitian merupakan langkah awal dalam *Design Research Methodology* (DRM) yang bertujuan pada pengkajian literatur untuk memperoleh pemahaman mendalam mengenai topik penelitian. Pada tahap ini, peneliti melakukan studi literatur terkait sistem rekomendasi khususnya yang berbasis *collaborative filtering*. Selain itu, dilakukan studi literatur mengenai masalah pada sistem rekomendasi berbasis *collaborative filtering* seperti data sparsity. Dan tidak lupa juga melakukan studi literatur mengenai model *variational autoencoder* yang dapat mengatasi masalah data *sparsity* pada *Dataset* sistem rekomendasi *collaborative filtering* dan dapat melakukan augmentasi data sehingga menghasilkan data sintesis yang dapat digunakan untuk meningkatkan performa model sistem rekomendasi *collaborative filtering*.

3.3. Studi Deskriptif I

Studi Deskriptif I adalah tahap kedua dalam *Design Research Methodology* (DRM) yang berfokus pada analisis mendalam terhadap penelitian-penelitian terdahulu untuk memetakan kondisi *state-of-the-art* saat ini. Berdasarkan studi literatur, ditemukan bahwa riset sistem rekomendasi didominasi oleh domain hiburan seperti film dan musik, serta telah mengadopsi model *deep learning* canggih seperti VAE untuk mengatasi masalah *data sparsity*. Dari temuan ini, diidentifikasi celah penelitian yang signifikan, yaitu minimnya penerapan model tersebut pada domain pariwisata Indonesia yang memiliki karakteristik data unik dan tingkat *sparsity* data yang tinggi. Oleh karena itu, tahapan ini merumuskan kebaruan penelitian yang berfokus pada adaptasi model VAE untuk konteks pariwisata Indonesia. Tujuannya adalah untuk menghasilkan rekomendasi yang tidak hanya akurat, tetapi juga lebih personal dan beragam, yang kemudian akan dievaluasi menggunakan metrik evaluasi berbasis peringkat.

3.4. Studi Preskriptif

Studi preskriptif merupakan salah satu tahap krusial dalam *Design Research Methodology* (DRM) yang berfokus pada perumusan dan perancangan solusi berdasarkan analisis dan temuan yang diperoleh dari tahap-tahap sebelumnya. Pada

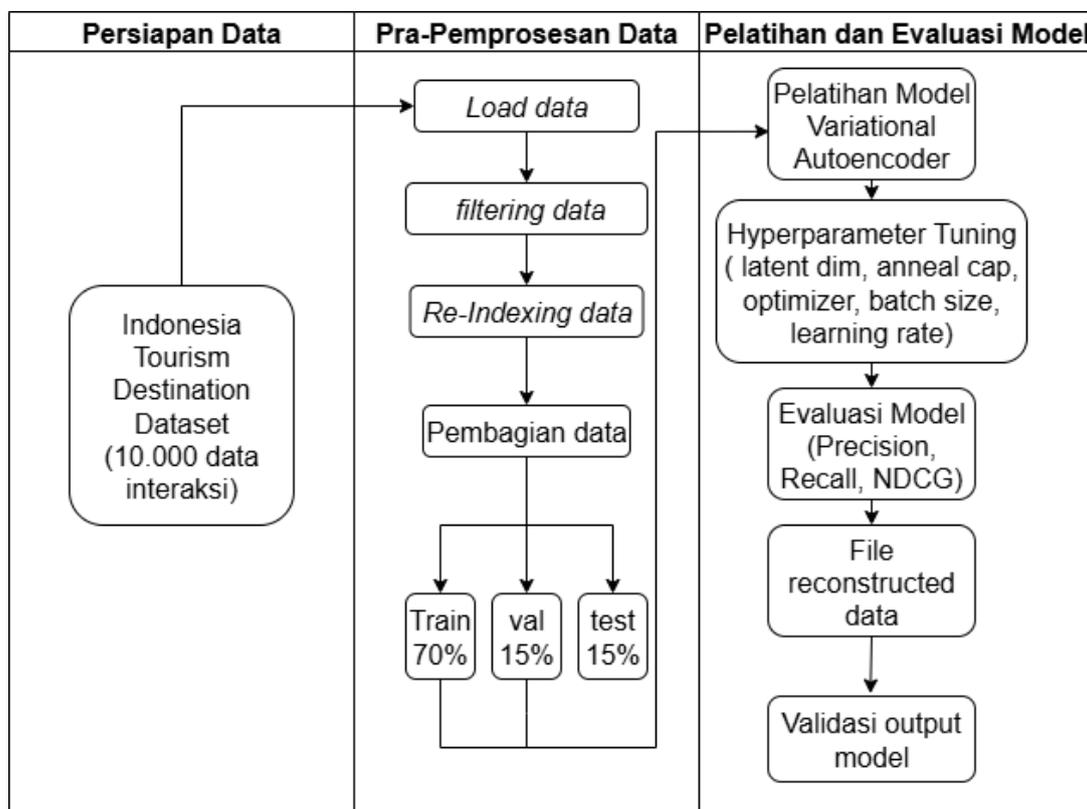
fase ini, peneliti tidak hanya mengidentifikasi gap pengetahuan, tetapi juga mengusulkan model atau strategi yang dapat mengatasi masalah yang telah diuraikan sebelumnya. Dalam konteks penelitian ini, implementasi studi preskriptif dilakukan dengan berfokus pada perancangan, implementasi, dan justifikasi solusi komputasional untuk mengatasi masalah tersebut. Sesuai dengan tujuan penelitian, solusi yang dikembangkan adalah model sistem rekomendasi berbasis *deep learning*, yaitu *Variational Autoencoder* (VAE).

Model VAE dipilih karena kemampuannya sebagai model generatif yang dapat mempelajari representasi data yang padat dan kaya makna (dikenal sebagai *latent space*) dari input yang sangat jarang (*sparse*). Dengan mempelajari representasi ini, VAE secara efektif mampu mengisi atau merekonstruksi matriks interaksi pengguna-item yang kosong, sehingga secara langsung mengatasi masalah *sparsity*. Tahap ini mencakup seluruh proses pengembangan model, mulai dari persiapan data, perancangan arsitektur VAE, pencarian *hyperparameter*, hingga pelatihan model final, sebagaimana diuraikan dalam diagram alur penelitian.

3.4.1. Pengembangan Model

Proses pengembangan model dalam penelitian ini mengikuti alur yang terstruktur untuk memastikan hasil yang valid dan dapat direproduksi. Model VAE yang dikembangkan bertujuan untuk memetakan riwayat interaksi setiap pengguna ke dalam sebuah representasi laten probabilistik, yang kemudian digunakan untuk merekonstruksi dan memprediksi kemungkinan interaksi pengguna terhadap seluruh item destinasi wisata.

Pengembangan model dibagi menjadi beberapa tahapan utama, tahapan pertama adalah pengumpulan data. Tahapan selanjutnya adalah tahap pra-pemrosesan Data. Setelah selesai dengan tahap pra-pemrosesan data, tahap selanjutnya adalah pembangunan arsitektur model VAE dan dilanjutkan ke tahap pelatihan model dan juga *hyperparameter tuning* menggunakan data yang sudah dilakukan proses pra-pemrosesan. Pada tahapan terakhir adalah tahapan evaluasi model untuk memastikan *output* yang dihasilkan model sudah sesuai. Berikut adalah ilustrasi alur dari proses pengembangan model.



Gambar 3.2 Alur Pengembangan Model

3.4.2. Pengumpulan Data

Langkah fundamental dalam pengembangan model adalah mempersiapkan *Dataset*. Tahap ini diawali dengan pengumpulan data menggunakan *Dataset* yang digunakan pada penelitian Nuril Adlan & Budi Setiawan (2025) dan dapat diakses secara publik dari *website kaggle*. *Dataset* tersebut berisi transaksi historis antara pengguna dan destinasi wisata di 5 kota besar di Indonesia yaitu kota Jakarta, Bandung, Semarang, Yogyakarta, dan Surabaya. *Dataset* ini dipilih karena kelengkapannya, yang mencakup data interaksi berupa *rating* yang esensial untuk membangun model *collaborative filtering*, serta data pendukung mengenai pengguna dan item (destinasi wisata).

3.4.3. Pra-pemrosesan Data (*Preprocessing*)

Setelah data terkumpul, dilakukan tahap pra-pemrosesan untuk menjamin kualitas dan konsistensi data. Data *rating* eksplisit diubah menjadi format umpan balik implisit (*implicit feedback*), dimana hanya fakta adanya interaksi yang

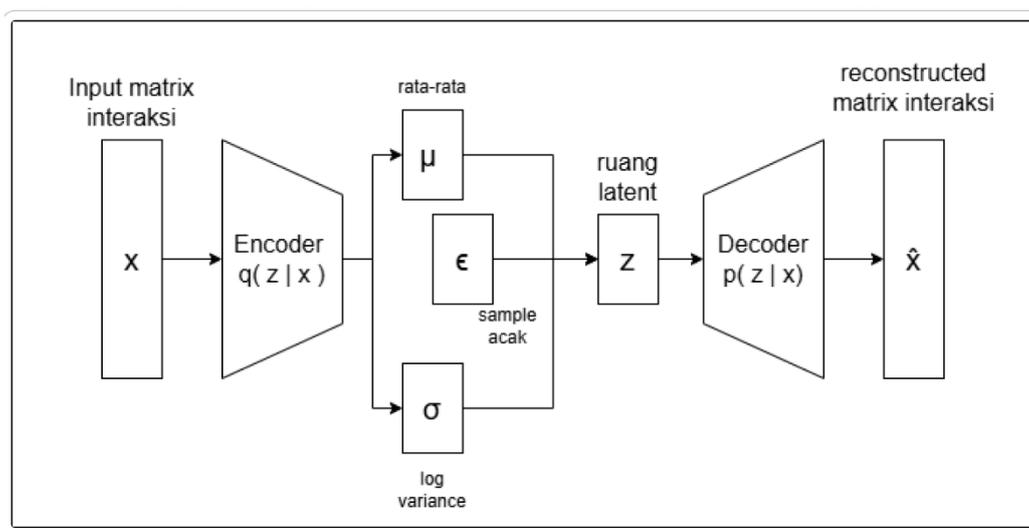
digunakan (nilai 1 untuk interaksi yang ada, dan 0 untuk yang tidak ada). Proses ini dilanjutkan dengan *filtering* data untuk hanya menyertakan pengguna yang memiliki 5 atau lebih interaksi guna memastikan model belajar dari data yang cukup representatif, prosedur *filtering* data tersebut sesuai dengan apa yang dijelaskan pada penelitian yang dilakukan oleh (Behera dkk., 2024). Setelah *filtering*, dilakukan analisis *sparsity* awal untuk menetapkan *baseline* permasalahan. Terakhir, *Dataset* yang telah bersih dibagi secara proporsional menjadi tiga set. Konfigurasi pembagian data yang digunakan adalah 70% data latih, 15% data validasi, dan 15% data uji. Konfigurasi pembagian data untuk data latih, uji dan validasi sesuai dengan penelitian Parwita (2019), agar dapat memberikan fondasi bagi VAE untuk mempelajari representasi laten preferensi pengguna, sementara alokasi 15% yang seimbang untuk validasi dan pengujian memungkinkan *hyperparameter tuning* yang efektif dan evaluasi akhir yang objektif dan stabil.

3.4.4. Arsitektur *Variational Autoencoder* (VAE)

Arsitektur model VAE yang dibangun dalam penelitian ini terdiri dari dua komponen utama yaitu *Encoder* dan *Decoder*. *Encoder* berfungsi sebagai kompresor informasi yang menerima input berupa vektor interaksi pengguna yang *sparse* dan memetakannya ke dalam sebuah distribusi probabilitas di ruang laten (*latent space*). Distribusi ini didefinisikan oleh dua vektor keluaran dari *Encoder*, yaitu *mean* (μ) dan *log-variance* ($\log(\sigma^2)$), yang secara bersama-sama merepresentasikan selera pengguna dalam bentuk yang padat dan informatif. Untuk memungkinkan proses optimisasi melalui *backpropagation*, diterapkan sebuah teknik bernama *Reparameterization Trick*, dimana representasi laten pengguna (z) diambil sampelnya dengan formula (6).

Selanjutnya, vektor *laten* z yang padat ini menjadi *input* bagi *Decoder*, yang berfungsi sebagai rekonstruktor. *Decoder* memproses z melalui serangkaian lapisan untuk menghasilkan sebuah vektor padat seukuran jumlah total item. Lapisan *output* dari *Decoder* menggunakan fungsi aktivasi *Sigmoid* untuk memastikan setiap elemen *output* merepresentasikan probabilitas (nilai antara 0 dan 1) bahwa

pengguna akan berinteraksi dengan item tersebut. Keunikan VAE terletak pada fungsi *loss* gabungan yang dioptimalkannya, yang terdiri dari *Reconstruction Loss* (menggunakan *Binary Crossentropy*) untuk mengukur akurasi rekonstruksi, dan *KL Divergence Loss* yang berfungsi sebagai regularizer untuk membuat ruang laten terstruktur dan mencegah *overfitting*.



Gambar 3.3 Arsitektur Model VAE

3.4.5. Hyperparameter tuning

Sebelum melatih model final, dilakukan tahap *hyperparameter tuning* untuk menemukan konfigurasi parameter terbaik yang dapat memaksimalkan performa model pada *Dataset* wisata. Penelitian ini menggunakan metode *Grid Search*, dimana berbagai kombinasi *hyperparameter* kunci diuji secara sistematis, metode *grid search* dipilih karena metode ini menguji setiap kombinasi *hyperparameter* sehingga konfigurasi *hyperparameter* yang dihasilkan merupakan *hyperparameter* terbaik dari semua konfigurasi *hyperparameter*, hal tersebut sesuai dengan yang dilakukan oleh Belete & Huchaiah, (2022). Parameter yang diuji meliputi ukuran dimensi laten (*latent dimension*), batas atas *annealing* (*anneal cap*), laju pembelajaran (*learning rate*), *Optimizer* dan juga *Batch Size* atau jumlah sampel data yang digunakan dalam satu kali iterasi. Setiap kombinasi dilatih dan dievaluasi pada set validasi, dengan performa diukur menggunakan matriks $NDCG@100$.

Proses ini dipantau oleh mekanisme *EarlyStopping* untuk menghentikan pelatihan jika performa tidak lagi meningkat. Kombinasi yang menghasilkan skor $val_ndcg@100$ tertinggi dipilih sebagai konfigurasi optimal untuk digunakan pada tahap selanjutnya.

3.4.6. Pelatihan dan Evaluasi Model

Tahap selanjutnya dalam studi perskriptif ini adalah pelatihan model final dan evaluasinya. Model dengan konfigurasi *hyperparameter* terbaik dari tahap *tuning* dilatih kembali dari awal. Untuk memaksimalkan data pembelajaran dan membangun model yang lebih general, pelatihan ini dilakukan pada gabungan data latih dan data validasi. Proses pelatihan berjalan selama jumlah *epoch* yang terbukti optimal selama tahap *tuning* sebelumnya. Setelah model final selesai dilatih, kinerjanya dievaluasi satu kali saja pada data uji yang belum pernah terlihat selama proses *training* maupun *tuning*. Hasil evaluasi ini, yang diukur dengan matriks $Precision@K$, $Recall@K$, dan $NDCG@K$, akan menjadi bukti utama dari kemampuan model dalam memberikan rekomendasi yang akurat dan relevan.

3.4.7. Validasi Matriks Augmentasi

Untuk memvalidasi efektivitas dan kualitas matriks interaksi yang telah diaugmentasi oleh VAE, dilakukan serangkaian pengujian empiris. Validasi ini bertujuan untuk membuktikan bahwa interaksi sintetis yang ditambahkan merupakan sinyal preferensi pengguna yang bermakna dan bukan sekadar *noise*. Hal tersebut sejalan dengan penelitian sebelumnya yang dilakukan oleh Choi dkk., (2023), untuk mengatasi *data sparsity* dengan cara menghasilkan matriks interaksi baru yang lebih padat (*dense*) dan lebih akurat, lalu menguji matriks interaksi yang lebih padat tersebut dengan menjadikan matriks tersebut sebagai *input* algoritma CF standar dan membandingkan hasilnya dengan matriks aslinya.

Pengujian dilakukan dengan menggunakan dua model *collaborative filtering* fundamental yang sering dijadikan *baseline* dalam penelitian sistem rekomendasi, yaitu *Singular Value Decomposition* (SVD) dan *Alternating Least Squares* (ALS). Kedua model ini dilatih dan dievaluasi pada setiap versi matriks augmentasi (dari $N=11000$ hingga $N=15000$). Kinerja masing-masing model diukur menggunakan

metrik evaluasi yang sama, yaitu $Precision@K$, $Recall@K$, dan $NDCG@K$, untuk memberikan tolak ukur yang objektif dan komprehensif terhadap dampak dari metode augmentasi data yang diusulkan.

3.5. Studi Deskriptif II

Studi Deskriptif II merupakan tahap lanjutan dalam *Design Research Methodology* (DRM) yang berfokus pada evaluasi mendalam terhadap hasil implementasi solusi yang telah dirancang pada tahap studi preskriptif. Pada fase ini, peneliti mengumpulkan data hasil eksperimen dan melakukan analisis untuk mengetahui dampak penerapan solusi terhadap permasalahan awal. Dalam penelitian ini, evaluasi dilakukan dengan mengukur kinerja model *Variational Autoencoder* (VAE). Untuk menilai efektivitas model VAE, peneliti menggunakan tiga matriks utama, yaitu $NDCG$, $Precision$, dan $Recall$.

Pengujian juga dilakukan pada *output* model VAE yang merupakan matriks interaksi hasil augmentasi. Pengujian tersebut dilakukan dengan menggunakan matriks interaksi hasil augmentasi tersebut pada model sistem rekomendasi *collaborative filtering* lain yang umum digunakan, yaitu *Singular Value Decomposition* (SVD) dan *Alternating Least Squares* (ALS), sesuai yang dilakukan pada penelitian (Choi dkk., 2023). Hasil evaluasi ini tidak hanya menyediakan umpan balik penting untuk penyempurnaan model, tetapi juga berperan sebagai dasar untuk pengembangan solusi yang lebih efektif di tahap penelitian selanjutnya.

3.6. Alat dan Bahan Penelitian

Dalam melakukan penelitian diperlukan beberapa alat dan bahan. Alat dan bahan tersebut dapat berupa perangkat keras (*Hardware*) dan juga perangkat lunak (*Software*). Penggunaan alat dan bahan tersebut dimaksudkan untuk membuat program, menjalankan program, dan juga melakukan pengujian program. Alat dan bahan yang digunakan akan di jelaskan pada tabel berikut.

Tabel 3.1 Spesifikasi Perangkat

Perangkat Keras / Lunak	Spesifikasi
-------------------------	-------------

<i>Processor</i>	10 th Gen Intel® Core™ i5-10310U
RAM	16 GB DDR4
<i>Storage</i>	SSD 512GB
GPU	Intel UHD Graphics
Sistem Operasi	Windows 10 Professional (64-bit)
Lingkup Pengembangan	Google Collaboratory, Visual Studio Code

3.7. Instrumen Penelitian

Instrumen penelitian merupakan faktor penting dalam suatu penelitian yang di dalamnya terletak kebenaran hasil penelitian yang menentukan kesimpulan. Instrumen penelitian digunakan untuk mengumpulkan data dan mengukur objek suatu variabel penelitian (Adisti Yuliastrin dkk., 2023). Instrumen yang digunakan pada penelitian ini adalah matriks evaluasi dengan rentang skala 0 sampai 1, yang menunjukkan semakin mendekati 1 maka performa model semakin bagus (Bahri, 2021). Berikut adalah matriks evaluasi yang digunakan :

1. *Normalized Discounted Cumulative Gain* (NDCG):

$$NDCG = \frac{DCG}{IDCG} \quad (8)$$

Keterangan:

DCG = Jumlah kumulatif gain (skor relevansi) yang terdiskon berdasarkan posisi item dalam urutan, sehingga item di peringkat atas mendapat bobot lebih tinggi

IDCG = Nilai maksimum (ideal), yaitu *DCG* yang diperoleh apabila semua item diurutkan dari relevansi tertinggi ke terendah

2. *Recall*

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

Keterangan:

TP = Jumlah kasus positif yang di prediksi benar secara positif.

FN = Jumlah kasus positif yang salah diprediksi sebagai negative (model gagal mendeteksi nya)

3. Precision

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

Keterangan :

TP = Jumlah item yang direkomendasikan dan benar-benar relevan (disukai/diklik oleh pengguna). Ini adalah rekomendasi yang sukses.

FP = Jumlah item yang direkomendasikan tetapi tidak relevan (tidak disukai/diabaikan oleh pengguna). Ini adalah rekomendasi yang gagal atau salah.

3.8. Analisis Data

Setelah proses pelatihan model VAE, analisis data dilakukan untuk mengevaluasi dan membandingkan kinerja model dalam konteks sistem rekomendasi berbasis *collaborative filtering*. Prosedur analisis data dimulai dengan pengumpulan hasil eksperimen berupa *output* prediksi model yang dihasilkan setelah pelatihan. Selanjutnya, kinerja model diukur dengan menggunakan tiga matriks utama, yaitu *NDCG*, *Precision* dan *Recall*. Matriks interaksi yang dihasilkan oleh model VAE juga ikut dianalisis dengan cara mengumpulkan data hasil pengujian model *Singular Value Decomposition* (SVD) dan *Alternating Least Squares* (ALS) yang dilatih menggunakan matriks interaksi yang dihasilkan oleh VAE. Selanjutnya model SVD dan ALS tersebut di evaluasi menggunakan matriks evaluasi *NDCG*, *Precision* dan *Recall*.