BAB II

TINJAUAN PUSTAKA

2.1 Studi Sebelumnya

Bagian ini menyajikan beberapa penelitian terdahulu yang relevan sebagai landasan dalam penyusunan topik penelitian ini. Penelitian-penelitian tersebut memberikan gambaran mengenai pendekatan, metode, serta hasil yang dapat menjadi referensi untuk analisis yang lebih mendalam pada konteks yang sedang diteliti.

Penelitian yang dilakukan oleh Affandi dkk[5] menganalisis sentimen ulasan pengguna aplikasi Brompit di Google Play Store menggunakan algoritma *Naive Bayes* dan *Support Vector Machine* (SVM). Penelitian ini bertujuan untuk mengetahui kecenderungan sentimen pengguna serta membandingkan performa kedua algoritma dalam klasifikasi sentimen. Data penelitian diperoleh melalui proses *scraping* ulasan pengguna aplikasi, kemudian dilakukan tahapan *preprocessing* dan *feature extraction* menggunakan TF-IDF sebelum proses klasifikasi. Hasil penelitian menunjukkan bahwa algoritma SVM memiliki hasil akurasi yang lebih baik yaitu 81,90%–82,51% dibandingkan *Naive Bayes* dengan hasil 82,63%–83,05%. Penelitian ini menunjukkan bahwa algoritma SVM mampu digunakan untuk melakukan klasifikasi sentimen pada ulasan pengguna aplikasi Brompit, sehingga menjadi salah satu referensi dalam pemilihan metode analisis sentimen pada penelitian ini.

Penelitian oleh Maulana dkk[11] pada tahun 2024 melakukan penelitian untuk menganalisis sentimen terhadap ulasan pengguna aplikasi investasi digital menggunakan dua algoritma klasifikasi, yaitu *Naive Bayes* dan *Support Vector Machine* (SVM). Penelitian ini bertujuan untuk membandingkan kinerja klasifikasi antara algoritma *Naive Bayes* dan SVM. Hasil penelitian menunjukkan bahwa algoritma SVM memiliki kinerja yang lebih baik dibandingkan *Naive Bayes* dengan nilai akurasi sebesar 99,50%, *precision* 99,67%, *recall* 99,33%, dan F1-score 99,50%. Hasil tersebut memperkuat bahwa algoritma SVM memiliki performa yang baik dalam melakukan klasifikasi sentimen pada ulasan pengguna aplikasi sehingga layak digunakan sebagai metode analisis sentimen pada penelitian ini.

Penelitian Ernawati & Wati[12] yang mengevaluasi performa beberapa *kernel* pada algoritma SVM seperti Linear, Polynomial, Sigmoid, dan RBF menggunakan Hyperparameter dan VADER Lexicon dalam melakukan klasifikasi sentimen terhadap ulasan aplikasi. Penelitian ini bertujuan untuk membuktikan apakah *kernel* pada SVM dapat meningkatkan nilai akurasi. Hasil penelitian menunjukkan bahwa *kernel* RBF memberikan performa terbaik pada skenario 90:10 dengan nilai akurasi sebesar 92,72%, *precision* 92,44%, F1-score 96,10%, dan AUC sebesar 88%. Temuan tersebut menunjukkan bahwa pemilihan *kernel* berpengaruh terhadap performa algoritma SVM sehingga pada penelitian ini dilakukan evaluasi terhadap beberapa *kernel* SVM untuk memperoleh model klasifikasi dengan performa terbaik.

Penelitian oleh Apriyanto dkk[10]. menganalisis sentimen berbasis aspek terhadap komentar pengguna film Jumbo di YouTube menggunakan pendekatan *Aspect-Based Sentiment Analysis* (ABSA). Penelitian tersebut bertujuan mengidentifikasi aspek yang dibahas pengguna serta membandingkan performa algoritma *Decision Tree*, *Random Forest*, dan *Support Vector Machine* (SVM). Hasil penelitian menunjukkan bahwa *Decision Tree* memberikan performa terbaik, sementara analisis berbasis aspek mampu memberikan informasi yang lebih rinci mengenai aspek-aspek yang menjadi perhatian pengguna dibandingkan analisis sentimen pada tingkat dokumen. Temuan tersebut memperkuat pentingnya identifikasi aspek untuk melengkapi hasil analisis sentimen sehingga menjadi salah satu landasan konseptual dalam penelitian ini.

Penelitian oleh Kustyaningsih dkk[13]. membahas analisis sentimen berbasis aspek terhadap ulasan pengguna aplikasi EdLink di Google Play Store. Penelitian ini bertujuan menentukan aspek ulasan menggunakan pemodelan topik *Latent Dirichlet Allocation* (LDA) serta menganalisis sentimen menggunakan *Support Vector Machine* (SVM). Hasil penelitian menunjukkan bahwa LDA menghasilkan tiga aspek utama, yaitu *Application Usability*, *Application Reliability*, dan *Application Performance Efficiency*, sedangkan hasil analisis sentimen menunjukkan bahwa ulasan negatif lebih dominan dibandingkan ulasan positif. Penelitian ini menunjukkan bahwa LDA mampu mengidentifikasi aspek-aspek utama yang muncul dalam kumpulan ulasan sehingga menjadi referensi dalam proses eksplorasi topik sebagai dasar pembentukan subkategori pada penelitian ini.

Penelitian yang dilakukan oleh Junarta dkk[14]. menerapkan *Qualitative Content Analysis* (QCA) induktif untuk mengidentifikasi faktor-faktor yang memengaruhi *revisit intention* wisatawan Muslim pada destinasi wisata halal di Lombok. Hasil penelitian menunjukkan bahwa faktor-faktor yang teridentifikasi berhasil dikelompokkan ke dalam dua tema utama, yaitu *pull factors* (faktor penarik) dan *push factors* (faktor pendorong), dengan *Islamic Attributes of Destination* (IAD) sebagai faktor yang paling dominan. Penelitian tersebut menunjukkan bahwa pendekatan QCA mampu mengidentifikasi kategori dan tema yang muncul secara sistematis dari data sehingga menjadi salah satu referensi dalam penerapan QCA pada penelitian ini.

Penelitian yang dilakukan oleh Ashari dkk[15]. menganalisis representasi kampanye inklusivitas LGBT dalam film *Strange World* (2022) menggunakan metode *Qualitative Content Analysis* (QCA) berdasarkan pendekatan Kuckartz dan Rädiker (2023). Penelitian tersebut menerapkan tahapan QCA secara sistematis mulai dari pengumpulan data, kategorisasi, kodifikasi, analisis, hingga penarikan kesimpulan. Hasil penelitian menunjukkan bahwa QCA mampu mengidentifikasi berbagai bentuk representasi yang muncul dalam film. Penelitian ini menunjukkan bahwa pendekatan QCA menurut Kuckartz dan Rädiker dapat diterapkan secara sistematis pada berbagai jenis data kualitatif sehingga menjadi referensi dalam penyusunan tahapan QCA pada penelitian ini.

Berdasarkan penelitian-penelitian terdahulu, analisis sentimen terhadap ulasan pengguna aplikasi umumnya berfokus pada klasifikasi sentimen serta evaluasi performa algoritma klasifikasi, khususnya menggunakan *Support Vector Machine* (SVM). Di sisi lain, penelitian lain menunjukkan bahwa *Latent Dirichlet Allocation* (LDA) dapat digunakan untuk mengidentifikasi topik-topik yang muncul dalam kumpulan ulasan, sedangkan *Qualitative Content Analysis* (QCA) mampu mengidentifikasi kategori maupun subkategori secara sistematis berdasarkan interpretasi terhadap data kualitatif. Meskipun demikian, belum ditemukan penelitian yang mengombinasikan analisis sentimen, eksplorasi topik, dan analisis konten untuk memperoleh pemahaman yang lebih komprehensif mengenai aspek-aspek yang mendasari sentimen pengguna aplikasi Brompit. Oleh karena itu, penelitian ini mengombinasikan analisis sentimen menggunakan *Support Vector Machine* (SVM), *Topic Modeling* menggunakan LDA sebagai referensi eksplorasi awal terhadap topik ulasan, serta *Qualitative Content*

Analysis (QCA) untuk mengidentifikasi aspek-aspek yang muncul dalam ulasan positif dan negatif pengguna aplikasi Brompit.

Tabel 2. 1 Perbandingan Studi Sebelumnya

No	Peneliti	Tahun	Tujuan	Metode	Hasil
1.	Affandi, dkk.	2026	Menganalisis sentimen ulasan pengguna aplikasi Brompit pada Google Play Store serta membandingkan performa algoritma *Naive Bayes* dan *Support Vector Machine* (SVM) dalam proses klasifikasi sentimen.	*Naive Bayes* dan SVM	SVM memiliki performa klasifikasi yang lebih baik dengan nilai akurasi sebesar 81,90%–82,51% dibandingkan *Naive Bayes* dengan nilai akurasi sebesar 82,63%–83,05%.
2.	Maulana, dkk.	2024	Membandingkan kinerja algoritma *Naive Bayes* dan *Support Vector Machine* (SVM).	*Naive Bayes* dan SVM	SVM memiliki kinerja yang lebih baik dibandingkan *Naive Bayes* dengan nilai akurasi sebesar 99,50%, *precision* 99,67%, *recall* 99,33%, dan F1-score 99,50%.
3.	Ernawati & Wati	2024	Mengevaluasi performa *kernel* SVM (Linear, Polynomial, Sigmoid, dan RBF) dan pengaruh penggunaan berbagai *kernel* terhadap performa klasifikasi sentimen ulasan aplikasi.	SVM	*Kernel* RBF memberikan performa terbaik pada skenario 90:10 dengan nilai akurasi sebesar 92,72%, *precision* 92,44%, F1-score 96,10%, dan AUC sebesar 88%.

No	Peneliti	Tahun	Tujuan	Metode	Hasil
4.	Apriyanto, dkk	2026	Mengidentifikasi aspek yang dibahas pengguna serta membandingkan performa algoritma klasifikasi dalam analisis sentimen berbasis aspek.	ABSA dan klasifikasi menggunakan *Decision Tree*, *Random Forest*, dan SVM.	*Decision Tree* memperoleh performa terbaik dengan akurasi rata-rata 91,0%. Analisis berbasis aspek mampu memberikan informasi yang lebih spesifik mengenai aspek-aspek yang menjadi perhatian pengguna dibandingkan analisis sentimen pada tingkat dokumen.
5	Kustyaningsih, dkk	2024	Menentukan aspek utama pada ulasan pengguna aplikasi EdLink serta menganalisis sentimen pada setiap aspek.	LDA dan SVM.	LDA menghasilkan tiga aspek utama, yaitu Application Usability, Application Reliability, dan Application Performance Efficiency. Hasil analisis menunjukkan sentimen negatif lebih dominan dibandingkan sentimen positif.
6.	Junarta, dkk	2022	Mengidentifikasi faktor-faktor yang memengaruhi *revisit intention* wisatawan Muslim pada destinasi wisata halal di Lombok.	*Qualitative Content Analysis* (QCA).	Ditemukan 39 kode, 12 kategori, dan 2 tema utama, yaitu *pull factors* dan *push factors*. Faktor yang paling dominan memengaruhi *revisit intention* adalah Islamic Attributes of Destination (IAD) sebagai bagian dari *pull factors*.
7.	Ashari,dkk.	2024	Menganalisis representasi kampanye inklusivitas LGBT dalam	*Qualitative Content Analysis* (QCA).	Kampanye inklusivitas LGBT direpresentasikan secara manifes maupun laten melalui kategori

No	Peneliti	Tahun	Tujuan	Metode	Hasil
			film *Strange World* (2022) produksi Disney.		seperti bentuk interaksi homoseksual, karakter LGBT, dukungan *peer group*, dan situasi sosial politik yang diidentifikasi dari dialog, gestur, dan elemen sinematik film.

2.2 Dasar Teori

2.2.1 Analisis Sentimen

Analisis sentimen merupakan teknik untuk mengidentifikasi dan menganalisis opini atau emosi dalam data teks dengan memanfaatkan pengolahan bahasa alami (*Natural Language Processing*) untuk berinteraksi dengan komputer. Teknik ini bertujuan untuk mengetahui kecenderungan sentimen dari suatu teks, apakah termasuk ke dalam kategori positif, negatif, atau netral[16]. Dalam konteks aplikasi digital, analisis sentimen membantu memahami persepsi dan respons pengguna terhadap suatu layanan atau produk. Hasil analisis sentimen dapat digunakan untuk mengetahui tingkat kepuasan pengguna serta menjadi bahan evaluasi dalam pengambilan keputusan, seperti perbaikan fitur dan pengembangan layanan atau produk.

2.2.2 *Preprocessing*

Data *preprocessing* merupakan tahap awal dalam analisis data yang bertujuan menyiapkan data mentah agar lebih terstruktur dan siap digunakan dalam proses pemodelan[16]. Dalam *text mining*, *preprocessing* dilakukan untuk menyesuaikan bentuk teks dengan mengurangi noise seperti variasi penelitian, simbol, dan kata yang tidak relevan. Proses ini menghasilkan data yang lebih konsisten sehingga meningkatkan efektivitas analisis[17]. Tahapan umum dalam *preprocessing* teks meliputi:

a. *Cleaning*

   Cleaning merupakan tahap prapemrosesan yang bertujuan untuk memastikan kualitas data sebelum dilakukan analisis. Pada tahap ini dilakukan pengecekan dan penanganan data yang kosong *(missing/empty data)* maupun data duplikat, serta penghapusan tanda baca, simbol, emotikon, url, serta elemen lain yang tidak memiliki kontribusi terhadap analisis. Tahap ini bertujuan untuk mengurangi *noise* sehingga data menjadi lebih bersih dan fokus pada informasi utama.

b. *Case folding*

   Case folding merupakan proses mengubah seluruh huruf dalam teks menjadi huruf kecil (*lowercase*). Langkah ini dilakukan untuk menyamakan bentuk

kata agar tidak terjadi perbedaan makna akibat variasi penggunaan huruf besar dan kecil.

c. *Normalization*

Normalization merupakan tahap penyesuaian kata ke bentuk yang lebih baku sesuai dengan standar bahasa yang digunakan. Proses ini biasanya mencakup pengubahan kata tidak formal, singkatan, atau slang menjadi kata yang sesuai dengan kaidah bahasa agar makna teks menjadi lebih jelas dan seragam.

d. *Tokenizing*

Tokenizing adalah proses memecah teks menjadi unit-unit kecil berupa kata atau token. Pemisahan ini umumnya dilakukan berdasarkan spasi, sehingga setiap kata dapat dianalisis secara individu dalam tahap selanjutnya.

e. *Stopword* Removal

Stopword removal merupakan tahap penyaringan kata-kata yang dianggap tidak memiliki makna penting dalam analisis, seperti kata penghubung atau kata umum. Dengan menghilangkan kata-kata tersebut, proses analisis menjadi lebih fokus pada kata yang memiliki nilai informasi.

f. *Stemming*

Stemming adalah proses mengubah kata yang memiliki imbuhan menjadi bentuk dasarnya. Tujuan dari tahap ini adalah untuk menyederhanakan variasi kata sehingga kata-kata dengan makna yang sama dapat direpresentasikan dalam satu bentuk yang konsisten

2.2.3 *Term Frequency – Inverse Document Frequency* (TF-IDF)

Term Frequency–Inverse Document Frequency (TF-IDF) merupakan metode pembobotan kata yang digunakan untuk mengukur tingkat kepentingan suatu kata dalam sebuah dokumen terhadap keseluruhan dokumen. TF-IDF menggabungkan dua konsep *Term Frequency* (TF) untuk mengukur frekuensi kemunculan suatu kata pada sebuah dokumen, dan *Inverse Document Frequency* untuk mengukur tingkat keumuman kata tersebut dalam keseluruhan dokumen. Suatu kata akan memiliki bobot yang tinggi apabila kata tersebut sering muncul pada suatu dokumen, tetapi jarang muncul pada dokumen lainnya. Melalui metode TF-IDF, setiap dokumen

direpresentasikan ke dalam bentuk vektor numerik yang digunakan sebagai masukan pada proses klasifikasi sentimen untuk membantu model dalam mengenali pola sentimen[18].

2.2.4 Model Klasifikasi

Penelitian ini menggunakan *Support Vector Machine* (SVM) sebagai model utama dalam analisis sentimen. Selain itu, beberapa algoritma klasifikasi lain, yaitu *Naive Bayes*, *Random Forest*, dan *Decision Tree*, digunakan sebagai model pembanding untuk mengevaluasi performa klasifikasi pada dataset penelitian. Oleh karena itu, bagian ini menguraikan konsep dasar masing-masing algoritma sebagai landasan teoritis penelitian.

2.2.4.1. *Support Vector Machine*

Support Vector Machine (SVM) merupakan salah satu algoritma *machine learning* bertipe supervised learning yang banyak digunakan dalam proses klasifikasi data[19]. SVM bekerja dengan cara memisahkan data ke dalam dua kelas menggunakan suatu garis pemisah yang disebut *hyperplane*[20], yang berfungsi sebagai batas keputusan (*decision boundary*) antar kelas berdasarkan fitur data. Tujuan utama dari SVM adalah menemukan *hyperplane* terbaik yang mampu memisahkan data secara optimal dengan tingkat kesalahan minimum. Dalam prosesnya, SVM berupaya memaksimalkan margin, yaitu jarak antara *hyperplane* dengan titik data terdekat dari masing-masing kelas[21]. Titik-titik data terdekat tersebut disebut sebagai support vector dan memiliki peran penting dalam menentukan posisi *hyperplane*. Semakin besar margin yang dihasilkan, maka kemampuan generalisasi model terhadap data baru akan semakin baik, sehingga pendekatan ini dikenal sebagai prinsip *Structural Risk Minimization* (SRM) yang bertujuan meminimalkan risiko kesalahan prediksi.

Pada kondisi tertentu, data tidak dapat dipisahkan secara linear pada ruang asli, sehingga SVM menggunakan teknik *kernel trick* untuk mengatasi permasalahan tersebut[19]. *Kernel* merupakan fungsi matematis yang digunakan untuk memetakan data dari ruang berdimensi rendah ke ruang berdimensi lebih tinggi agar data yang awalnya tidak dapat dipisahkan secara linear menjadi dapat dipisahkan secara linear pada ruang fitur baru[20]. Dengan demikian, *kernel*

memungkinkan SVM untuk menangani pola data yang kompleks tanpa harus melakukan transformasi secara eksplisit. Secara umum, penggunaan *kernel* dalam SVM sangat berpengaruh terhadap keberhasilan proses klasifikasi karena *kernel* menentukan bagaimana data diproyeksikan dan dipisahkan dalam ruang fitur[21].

Dalam *Support Vector Machine*, *kernel* merupakan komponen penting untuk mengukur kemiripan antar data serta membantu membentuk batas keputusan sesuai karakteristik data. Pemilihan *kernel* sangat memengaruhi performa model karena setiap *kernel* memiliki cara berbeda dalam memetakan data ke ruang fitur. Secara umum, *kernel* dibagi menjadi *kernel* linear dan non-linear.

1. *Kernel* Linear

   Kernel linear digunakan ketika data dapat dipisahkan langsung dengan *hyperplane* tanpa transformasi ke dimensi lebih tinggi. Fungsi *kernel* dinyatakan sebagai K(x, xi) = x * xi. *Kernel* ini efisien secara komputasi dan cocok untuk data berdimensi tinggi seperti teks.

2. *Kernel* Non Linear

   Kernel non-linear digunakan ketika data tidak dapat dipisahkan secara linear, sehingga diperlukan pemetaan ke ruang berdimensi lebih tinggi agar dapat dipisahkan secara optimal. Beberapa jenis *kernel* non-linear meliputi:

   a. *Kernel* polynomial: memetakan data ke dimensi lebih tinggi untuk menangkap hubungan non-linear antar fitur. Tingkat kompleksitas model dipengaruhi oleh derajat (degree) yang digunakan.

   b. *Kernel* RBF: mengukur kemiripan antar data menggunakan fungsi eksponensial

      $K(x,x') = \exp(-\gamma \|x - x'\|2)$

      Parameter γ mengatur tingkat pengaruh antar data, di mana nilai kecil menghasilkan model lebih halus dan nilai besar

menghasilkan model lebih kompleks. *Kernel* ini efektif untuk data non-linear.

c. *Kernel* sigmoid: terinspirasi dari jaringan saraf tiruan dan digunakan untuk memodelkan hubungan non-linear. Namun, penggunaannya terbatas karena sensitif terhadap parameter.

2.2.4.2. *Naive Bayes*

Naive Bayes merupakan metode klasifikasi sederhana yang menggunakan pendekatan probabilistik dalam proses pengelompokan data. Metode ini menghitung kemungkinan suatu data masuk ke dalam kelas tertentu berdasarkan kombinasi dan distribusi nilai dari dataset. *Naive Bayes* memiliki asumsi bahwa setiap variabel atau fitur bersifat independen satu sama lain. Algoritma ini sering digunakan pada analisis sentimen untuk melakukan klasifikasi teks dengan menghitung probabilitas kemunculan kata pada setiap kelas sentimen hingga menghasilkan klasifikasi positif maupun negatif[22].

2.2.4.3. *Random Forest*

Random Forest merupakan salah satu metode klasifikasi yang bekerja dengan membangun dan mengombinasikan banyak pohon keputusan (*Decision Tree*) untuk menghasilkan prediksi yang lebih stabil. Setiap pohon keputusan pada algoritma ini dibentuk menggunakan sampel data tertentu dan memiliki node yang berfungsi sebagai proses pemisahan keputusan. Dalam analisis sentimen, *Random Forest* menentukan hasil klasifikasi berdasarkan gabungan prediksi dari seluruh pohon keputusan yang telah dibentuk[23].

2.2.4.4. *Decision Tree*

Decision Tree merupakan salah satu metode yang digunakan dalam proses klasifikasi dengan memanfaatkan struktur pohon untuk membantu pengambilan keputusan hingga menghasilkan keputusan akhir. Pada *Decision Tree*, setiap node merepresentasikan atribut atau fitur, sedangkan cabang pohon menunjukkan hasil dari proses pengambilan keputusan. Metode ini membangun struktur pohon berdasarkan atribut data yang digunakan dalam proses

klasifikasi. Algoritma ini banyak digunakan pada analisis sentimen karena mudah dipahami dan mampu menangani data dengan berbagai jenis atribut[24].

2.2.5 *Confusion Matrix*

Confusion matrix merupakan metode evaluasi yang digunakan untuk mengukur performa model klasifikasi dalam *machine learning*. Metode ini menyajikan hasil prediksi model dalam bentuk tabel yang membandingkan antara kelas sebenarnya dengan kelas hasil prediksi. *Confusion matrix* terdiri dari empat komponen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN)[25]. Adapun bentuk *Confusion matrix* ditunjukkan pada tabel berikut.

Tabel 2. 2 *Prediction dan Actual Class*

	Prediction Class Positive	*Prediction Class Negative*
Actual Class Positive	TP	FN
Actual Class Negative	FP	TN

Keterangan:

- *True Positive* (TP) adalah jumlah data dari kelas positif yang berhasil diklasifikasikan dengan benar sebagai kelas positif.
- *True Negative* (TN) adalah jumlah data dari kelas negatif yang berhasil diklasifikasikan dengan benar sebagai kelas negatif.
- *False Positive* (FP) adalah jumlah data dari kelas negatif yang salah diklasifikasikan sebagai kelas positif.
- *False Negative* (FN) adalah jumlah data dari kelas positif yang salah diklasifikasikan sebagai kelas negatif.

2.2.6 *Topic Modeling* dengan *Latent Dirichlet Allocation* (LDA)

Topic Modeling merupakan teknik *text mining* berbasis *unsupervised machine learning* yang digunakan untuk mengidentifikasi topik-topik tersembunyi (*latent topics*) dari sekumpulan dokumen teks dengan mengelompokkan kata-kata yang sering muncul secara bersamaan. Setiap dokumen direpresentasikan sebagai kombinasi beberapa topik, sedangkan setiap topik direpresentasikan sebagai distribusi probabilitas kata-kata penyusunnya. Teknik ini banyak digunakan untuk

mengidentifikasi tema utama dan pola informasi pada kumpulan data teks dalam jumlah besar[26].

Salah satu metode *Topic Modeling* yang banyak digunakan adalah *Latent Dirichlet Allocation* (LDA), yaitu model probabilistik yang mengidentifikasi topik-topik laten dalam sekumpulan dokumen. Dalam penerapannya, jumlah topik (*number of topics*) ditentukan sebelum proses pemodelan, sedangkan jumlah topik yang optimal dapat ditentukan menggunakan *coherence score*. Semakin tinggi nilai *coherence score*, semakin baik kualitas topik yang dihasilkan sehingga lebih mudah untuk diinterpretasikan[27].

2.2.7 *Qualitative Content Analysis* (QCA)

Analisis konten merupakan metode penelitian yang digunakan untuk mendeskripsikan dan memahami suatu fenomena secara sistematis dan objektif. Metode ini memungkinkan sejumlah besar data disederhanakan ke dalam kategori-kategori yang berkaitan dengan isi, dengan asumsi bahwa kata, frasa, atau pernyataan yang dikelompokkan ke dalam kategori yang sama memiliki makna yang serupa. Analisis konten bertujuan untuk menghasilkan deskripsi yang padat namun menyeluruh mengenai fenomena yang diteliti, di mana hasil akhir analisis berupa konsep atau kategori yang mampu menggambarkan fenomena tersebut. Oleh karena itu, analisis konten tidak hanya berfungsi untuk mengorganisasikan data secara sistematis, tetapi juga untuk meningkatkan pemahaman serta menghasilkan pengetahuan mengenai suatu fenomena melalui identifikasi makna yang terkandung dalam data[28].