

2. BAB II KAJIAN LITERATUR

2.1. Tinjauan Pustaka

2.1.1. *E-commerce*

E-commerce telah berkembang sejak awal abad ke-21. Semakin banyak barang yang dijual saat ini di *web* dan basis data pelanggan juga bertambah. Pengirim online meminta pelanggan mereka untuk memberikan umpan balik yang berharga ketika mereka membeli barang untuk meningkatkan loyalitas pelanggan dan latar belakang belanja. Dengan semakin banyak orang yang membeli barang melalui *e-commerce*, jumlah survei untuk setiap barang meningkat dengan cepat yang mengarah ke sejumlah besar data untuk diproses. Pembuat item dapat menghadapi kesulitan karena jumlah input yang masuk dari pelanggan. Selain itu, pelanggan terkadang mendapatkan umpan balik negatif hanya dengan melalui satu atau dua umpan balik (De, 2017).

Menurut Bossenbroek dan Gringhuis (2015) pada *white paper*-nya, menjelaskan bahwa adopsi besar-besaran *web* sebagai *platform e-commerce* telah menyebabkan perubahan mendasar dalam cara bisnis berinteraksi dengan pelanggan. Sementara akses potensial ke basis pelanggan yang lebih besar dan lebih beragam umumnya dipandang sebagai peluang, ini juga dapat mewakili peningkatan persaingan. Taruhannya tinggi dan bisnis harus mengembangkan strategi canggih untuk menarik dan mempertahankan pelanggan. Daripada berfokus pada "titik sentuh" selama proses pemasaran dan penjualan, bisnis menggunakan algoritma cerdas dan teknologi sosial untuk membentuk hubungan yang bermakna dan berkelanjutan dengan pelanggan. Hal ini dapat melibatkan interaksi online yang sering, sering menggunakan saluran sosial. Terlibat dengan pelanggan tidak lagi merupakan serangkaian pengalaman satu kali saja; ini adalah dialog yang berkelanjutan. Anehnya, dialog yang sedang berlangsung ini menyerupai dialog antara orang-orang: mereka biasanya mengekspresikan niat

dan mencapai tujuan mereka dengan membangun kepercayaan dan hubungan terbuka.

Menurut De (2017), dalam beberapa tahun terakhir, sistem rekomendasi telah berkembang menjadi alat bisnis utama yang mengubah dunia *e-commerce*. Pertumbuhan *World Wide Web* yang cepat, akses yang mudah di dalam kehidupan sehari-hari dan kemunculan *e-commerce* yang tak terhindarkan selanjutnya telah mengarah pada pengembangan sistem rekomendasi. Di tengah pasar elektronik yang terus berkembang, keberadaan dan stabilitas konstruktif perdagangan dan bisnis bergantung pada membangun dominasi kompetitif melalui strategi pemasaran yang efektif dan agresif. Dengan jumlah informasi yang terus-menerus tersedia melalui media elektronik, para pengguna *web* tidak dapat memanfaatkan sumber daya ini karena kurangnya alat yang tepat untuk digunakan. Karena ini, menjadi berat bagi pengguna *web* untuk mengakses informasi yang relevan secara produktif. Selain itu, peningkatan signifikan dalam jumlah situs web mengedepankan tugas yang menantang untuk mengatur konten situs web untuk memenuhi kebutuhan pengguna.

Solusi yang efektif dan digunakan secara luas untuk ini adalah metode 'Penyaringan Informasi' yang diterapkan untuk mengelola arus informasi yang melimpah. Tujuan mendasar dari penyaringan informasi adalah untuk mengenalkan pengguna pada informasi yang berkaitan dengan mereka. Sistem yang memfasilitasi ini disebut Sistem Rekomendasi. Sistem ini digunakan secara produktif dalam pasar elektronik dengan menekankan pada perilaku pelanggan, menghasilkan komunitas yang menarik dan membangun kepercayaan di antara pengguna (De 2017).

Menurut Bossenbroek dan Gringhuis (2015) pada *white paper*-nya, penggunaan sistem rekomendasi dalam lingkungan *e-commerce* dapat memengaruhi kinerja keuangan serta intensitas dialog dengan pelanggan. Lebih khusus lagi, sistem pemberi rekomendasi dapat meningkatkan dialog *e-commerce* dengan tiga cara, yaitu:

1. "Konversi": Mengubah *Browser* menjadi Pembeli

Meningkatkan proporsi pengunjung ke situs web yang melakukan pembelian. Sistem rekomendasi membantu konsumen menemukan barang yang paling sesuai dengan minat; termasuk pembelian yang tidak direncanakan yang didorong oleh kebetulan dari rekomendasi yang dibuat.

2. Dengan meningkatkan *Cross-sell*

Sistem rekomendasi meningkatkan penjualan silang dengan menyarankan produk atau layanan tambahan kepada pelanggan. Jika rekomendasinya bagus, rata-rata pesanan akan meningkat. Misalnya, sebuah situs merekomendasikan produk tambahan dalam proses *checkout*, berdasarkan produk-produk yang sudah ada di keranjang belanja.

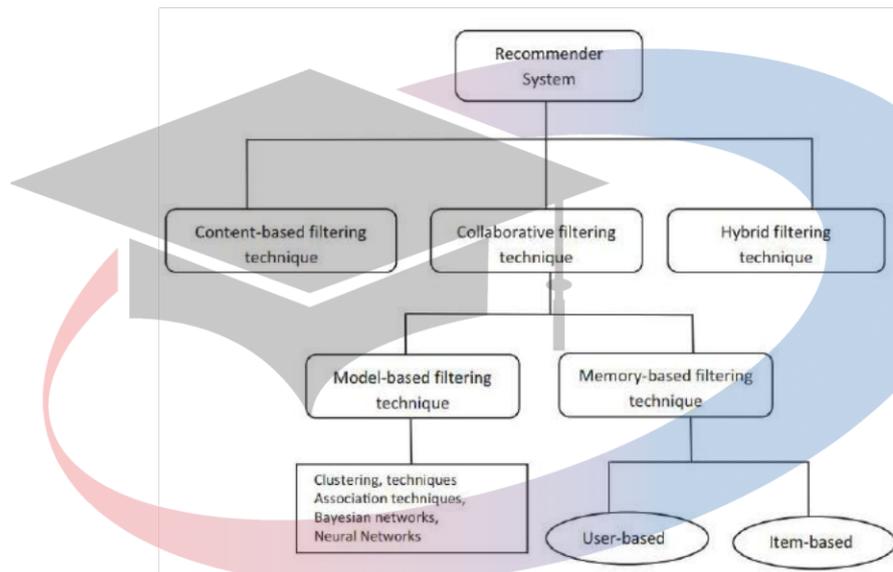
3. Dengan membangun loyalitas

Di dunia dimana pesaing hanya berjarak satu klik, membangun loyalitas pelanggan menjadi aspek penting dari strategi bisnis. Sistem rekomendasi dapat meningkatkan loyalitas dengan menciptakan hubungan nilai tambah antara situs dan pelanggan. Setiap kali pelanggan mengunjungi situs web, sistem "belajar" lebih banyak tentang preferensi dan minat pelanggan dan semakin meningkatkan pengoperasian informasi contohnya mempersonalisasi apa yang ditawarkan. Dengan memberikan setiap pelanggan pengalaman yang relevan, maka akan meningkatkan kemungkinan pelanggan kembali ke situs tercapai. Pada akhirnya, kedalaman wawasan yang diperoleh dalam preferensi dan minat pelanggan bisa sangat besar sehingga bahkan jika pesaing meluncurkan sistem yang identik, atau bahkan superior, pelanggan perlu menghabiskan waktu dan energi yang sangat banyak untuk mengajari pesaing untuk menawarkan pengalaman yang sama menariknya

2.1.2. *Rekomendasi*

Menurut Driskill (1999), rekomendasi produk sudah ada sejak lama, setidaknya sejak akhir 90-an. Namun, karena data yang terus meningkat untuk setiap hari, penting untuk menyelidiki apakah algoritma rekomendasi produk yang telah digunakan sebelumnya cocok untuk data yang banyak. Penting juga untuk menyelidiki metode untuk memproses dan membuat perhitungan pada data

peristiwa pengguna untuk melihat seberapa baik metode dan kerangka kerja ini cocok untuk kumpulan data yang lebih besar. Menurut Hua, et al (2017) dan Isinkaye et al (2015), algoritma atau sistem rekomendasi dapat dikategorikan ke dalam 3 kelas yaitu *content-based recommendation*, *collaborative-filtering recommendation* dan *hybrid recommendation* yang diilustrasikan pada gambar berikut



Gambar 2.1. Teknik Rekomendasi (Isinkaye et al, 2015)

1. Content Based Recommendation

Pengguna mendapatkan produk yang direkomendasikan berdasarkan penilaian item sebelumnya. Dengan menggunakan penilaian dari pengguna untuk produk tertentu, pengguna dapat direkomendasikan produk yang memiliki karakteristik yang mirip dengan produk yang telah diberi nilai tinggi oleh pengguna. Dengan demikian, algoritma ini menggunakan data historis dari penilaian produk pengguna, membuat profil pengguna (Hua et al, 2017).

Hasil dari menggunakan algoritma rekomendasi berbasis konten adalah bahwa algoritma ini hanya dapat merekomendasikan produk yang memiliki penilaian dan bukan barang baru, juga tidak dapat merekomendasikan produk yang disukai pengguna yang serupa. Konsekuensi lain adalah bahwa tidak mungkin untuk menggunakan algoritma ini dalam situasi awal, di mana tidak ada informasi yang dikumpulkan tentang pengguna, misalnya ketika pengguna baru

saja menginstal aplikasi dan belum melakukan pembelian. (Hua et al, 2017) (Desrosiers & Karypis, 2011)

2. Collaborative Filtering Recommendation

Algoritma collaborative filtering (CF) fokus pada pengguna yang memiliki minat yang sama. Berdasarkan minat yang sama, produk direkomendasikan kepada pengguna dalam kelompok pengguna yang serupa. Itu bergantung pada peringkat oleh pengguna target serta peringkat pengguna umum. (Hua et al, 2017) (Desrosiers & Karypis, 2011)

Seperti yang ditunjukkan pada Gambar 2.1, algoritma rekomendasi dapat dibagi lagi menjadi dua kelas yaitu berbasis memori dan berbasis model. Algoritma berbasis memori mencoba mencari tetangga yang menyetujui produk serupa. Teknik berbasis memori dibagi lagi menjadi berbasis item dan berbasis pengguna. Pemfilteran berbasis pengguna menghitung kesamaan pengguna tergantung pada peringkat mereka pada produk. Semua peringkat yang tidak diketahui oleh pengguna tertentu diatur dengan membuat prediksi. Peringkat yang diprediksi untuk pengguna saat ini pada suatu item dihitung sebagai rata-rata tertimbang dari rating pada item tersebut oleh semua pengguna yang serupa. Dalam pemfilteran berbasis item, kesamaan dihitung antara item dan bukan pengguna. (Isinkaye et al, 2015)

Dalam algoritma berbasis model, peringkat yang diketahui digunakan untuk membangun model. Untuk membangun model untuk membuat rekomendasi, metode pembelajaran mesin dapat digunakan. Menggunakan pembelajaran mesin, sebuah model dapat dikomputasi sehingga rekomendasi dapat disampaikan dengan cepat. (Isinkaye et al, 2015)

Seperti rekomendasi CB, batasan untuk rekomendasi CF bersifat cold-start (ketika ada pengguna baru yang belum memberi peringkat item apa pun). Masalah lain adalah bahwa rekomendasi didasarkan pada peringkat pengguna lain. Konsekuensi dari ini adalah bahwa pengguna tidak dapat menerima rekomendasi untuk produk baru jika tidak ada pengguna lain yang memberi peringkat produk baru. Masalah lain adalah bahwa metode CF biasa dikatakan tidak dapat diskalakan untuk dataset besar (Isinkaye et al, 2015).

3. *Hybrid Recommendation*

Algoritma rekomendasi jenis lain termasuk dalam kelas *hybrid*. Algoritma ini menggabungkan berbagai jenis teknik rekomendasi untuk dapat menghindari masalah dengan berbagai teknik dalam penyaringan kolaboratif dan berbasis konten. Jenis algoritma rekomendasi ini melibatkan *weighted hybridization* dan *switching hybridization* di antara teknik-teknik lain yang disebutkan dalam (Isinkaye et al, 2015).

Dalam *weighted hybridization*, rumus linier digunakan di mana hasil dari beberapa teknik terintegrasi. Ini berarti bahwa penyaringan kolaboratif dan berbasis konten dapat digunakan, dan skor mereka dikumpulkan dan dimasukkan ke dalam rumus linear untuk mendapatkan rekomendasi akhir. Dalam *switching hybridization*, mesin rekomendasi dapat beralih di antara teknik yang berbeda jika perlu (Isinkaye et al, 2015).

2.1.3. *Opinion Mining*

Penambangan opini melibatkan analisis opini, sentimen atau mentalitas penulis dari teks tertulis. Pendapat online memiliki pengaruh tidak langsung pada bisnis situs *e-commerce*. Situs-situs tersebut memasarkan produk mereka dan para pengguna *web* membaca ulasan produk sebelum membeli produk. Banyak organisasi menggunakan sistem penambangan opini untuk melacak ulasan pelanggan tentang produk yang dijual online (De, 2017).

Penambangan opini adalah sebuah cara untuk mempertahankan fokus pada beberapa tren bisnis terkait dengan administrasi transaksi, manajemen status dan juga iklan. Prediksi pola juga dilakukan dengan menggunakan pendapat pelanggan. Berbagai istilah yang digunakan dalam penambangan opini diberikan di bawah ini (De, 2017):

1. Fakta: Kepastian adalah apa yang telah benar-benar terjadi atau memang demikian.
2. Opini: Perasaan adalah perspektif atau penilaian yang dibingkai tentang sesuatu, tidak begitu banyak dalam terang kebenaran atau informasi.

3. Kalimat Subyektif: Sebuah kalimat atau konten bersifat subjektif atau keras kepala jika itu benar-benar menunjukkan emosi seseorang.
4. Kalimat Target: Kalimat target menunjukkan beberapa aktualitas dan data yang diketahui tentang dunia.
5. Hal: satu artikel atau unit, terutama yang merupakan bagian dari jadwal, pengumpulan, atau set.
6. Survei: Audit adalah konten yang mengandung susunan kata yang memiliki sentimen klien untuk hal tertentu. Sebuah survei mungkin subjektif atau objektif atau keduanya.
7. Aspek yang Diketahui: Sudut yang dikenal adalah sudut pandang standar yang diberikan oleh situs tertentu tempat klien memberikan penilaian secara independen.

2.1.4. *Text Mining*

Menurut Feldman & Sanger (2007), *text mining* merupakan salah satu bagian dari *data mining* yang menerapkan konsep dan teknik *data mining* ke dalam teks. *Text mining* dapat didefinisikan sebagai suatu proses menggali informasi dimana seorang *user* berinteraksi dengan sekumpulan dokumen menggunakan alat-alat analisis yang merupakan komponen-komponen dalam *data mining*. Pada *data mining*, data yang digunakan adalah data terstruktur, sedangkan dalam *text mining* data yang digunakan adalah data tidak terstruktur berupa teks. *Text mining* atau *text analytics* adalah istilah yang mendeskripsikan sebuah teknologi yang mampu menganalisis data teks semi-terstruktur maupun tidak terstruktur, hal inilah yang membedakannya dengan *data mining* dimana *data mining* mengolah data yang sifatnya terstruktur.

Menurut Feldman & Sanger (2007), perbedaan antara *text mining* dengan *data mining* terletak pada sumber data yang digunakan. Dalam *text mining* pola-pola yang diekstrak dari data tekstual yang tidak terstruktur bukan berasal dari suatu *database*. Beberapa kesamaannya adalah data yang digunakan merupakan data besar dan data berdimensi tinggi dengan struktur yang terus berubah. Dalam *data mining*, data yang diolah adalah data yang terstruktur dari proses

warehousing sehingga lebih mudah diproses oleh mesin/komputer. Analisis teks lebih sulit karena teks digunakan sebagai komunikasi manusia secara langsung bukan untuk mesin/komputer. Ditambah struktur teks yang kompleks, struktur yang tidak lengkap, bahasa yang berbeda, dan arti yang tidak standar. Oleh sebab itu pada umumnya digunakan *Natural Language Processing* untuk analisis teks yang tidak terstruktur.

2.1.4.1. Pendekatan *Lexicon*

Dalam pendekatan ini, kamus yang berisi daftar kata dan idiom yang dipakai untuk analisis dikenal dengan *opinion lexicons*. Kamus ini akan mengklasifikasi kata ke dalam kelas positif, negatif dan netral setelah melalui proses analisis. Berdasarkan pendekatan ini, kata yang termasuk sentimen adalah kata sifat sedangkan fiturnya kata benda. Berdasarkan cara pembobotan untuk *opinion lexicon*, terdapat dua pendekatan sebagai berikut (Addepalli *et al.*, 2016):

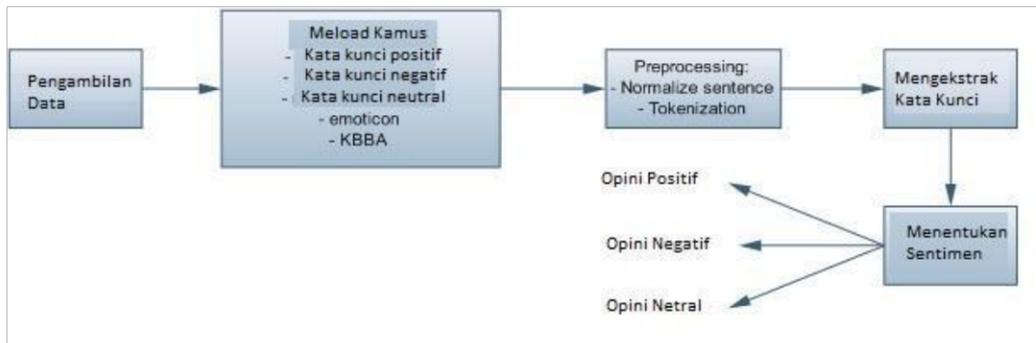
1. Pendekatan berbasis kamus kata

Dalam pendekatan ini daftar kata-kata sebelumnya digunakan untuk memetakan dengan sentimen yang diekstraksi. Daftar terus bertambah dengan mencari sinonim dari kata-kata. Kerugiannya adalah kamus mungkin tidak spesifik konteks atau terkait dengan domain maka kata opini yang diekstraksi mungkin tidak terlalu akurat.

2. Pendekatan berbasis semantik

Skor sentimen diprediksi secara langsung dengan menggunakan kesamaan antara kata-kata yang dihitung oleh algoritma yang berbeda. Kesamaan antara kata-kata dihitung oleh keterkaitan semantiknya, yang memberikan mereka skor yang sama. Misalnya, jika kata sifat memiliki skor dua, menurut leksikon sebagaimana disebutkan di atas kata benda juga mendapat skor.

Dalam analisis sentimen dikenal adanya metode berbasis *machine learning*, berbasis kamus (*lexicon-based*), atau gabungan keduanya. Secara umum alur proses analisis sentimen menggunakan *lexicon based* ditunjukkan oleh gambar 2.2 berikut.



Gambar 2.2. Alur proses analisis sentimen dengan lexicon based (Nurfalah & Suryani, 2016)

2.1.4.2. Pengambilan Data

Pada proses ini dilakukan pengambilan data teks dari media sosial. Hasil dari proses ini adalah daftar opini *user* dan jika perlu metadata-nya seperti: nama *user*, lokasi, dan waktu untuk kepentingan pengelompokkan berdasarkan temporal dan spasial.

2.1.4.3. Memuat Kamus

Kamus adalah komponen penting dalam sistem yang menggunakan pendekatan *lexicon*. Kamus digunakan dalam proses normalisasi kalimat dan ekstraksi kata kunci. Berikut adalah contoh kamus dan isinya:

1. Positif *keywords*: baik, banyak, bangkit
2. Negatif *keywords*: bangkrut, banjir, bantah
3. *Negation keywords*: belum, bukan, tidak
4. *Emoticon*: :) (nilainya: 1), :((nilainya: -1)
5. Kamus konversi bahasa gaul (KBBA): bgmn = bagaimana, bgs = bagus, beud = banget

2.1.4.4. Text Preprocessing

Dalam melakukan *text mining*, teks dokumen yang digunakan harus dipersiapkan terlebih dahulu, setelah itu baru dapat digunakan untuk proses utama. Proses mempersiapkan teks dokumen atau dataset mentah disebut juga dengan proses *text preprocessing*. *Text preprocessing* berfungsi untuk mengubah data teks yang tidak terstruktur menjadi data yang terstruktur. Secara umum proses yang dilakukan dalam tahapan *preprocessing* adalah sebagai berikut (Informatikalogi, 2017):

1. Remove Punctuation

Tahap penghapusan tanda baca yang tidak dibutuhkan dalam proses ekstraksi opini. Contoh tanda baca yang dihapus [`”#$%&’()*+,-./:;<=>?@[\\]^_`{|}~`]:

2. Case Folding

Case folding adalah proses penyamaan *case* dalam sebuah dokumen. Hal ini dilakukan untuk mempermudah pencarian. Tidak semua dokumen teks konsisten dalam penggunaan huruf kapital. Oleh karena itu peran *case folding* dibutuhkan dalam mengkonversi keseluruhan teks dalam dokumen menjadi suatu bentuk standar (dalam hal ini huruf kecil atau *lowercase*).

3. Spelling Normalization

Spelling Normalization merupakan proses perbaikan atau substitusi kata-kata yang salah eja atau disingkat dalam bentuk tertentu. Substitusi kata dilakukan untuk menghindari jumlah perhitungan dimensi kata yang melebar. Perhitungan dimensi kata akan melebar jika kata yang salah eja atau disingkat tidak diubah karena kata tersebut sebenarnya mempunyai maksud dan arti yang sama tetapi akan dianggap sebagai entitas yang berbeda pada saat proses penyusunan matriks.

4. Tokenizing

Tokenizing adalah proses memecah kalimat menjadi kata-kata yang dilakukan untuk menjadikan sebuah kalimat menjadi lebih bermakna. Tahap pertama yang dilakukan adalah normalisasi kata dengan mengubah semua karakter huruf menjadi huruf kecil atau *toLowerCase*. Proses tokenisasi diawali dengan menghilangkan delimiter-delimiter yaitu simbol dan tanda baca yang ada pada teks tersebut seperti @, \$, &, koma (,) tanda tanya (?). Tahap tokenisasi selanjutnya yaitu proses penguraian teks yang semula berupa kalimat-kalimat yang berisi kata-kata. Proses pemotongan string berdasarkan tiap kata yang menyusunnya, umumnya setiap kata akan terpisahkan dengan karakter spasi, proses tokenisasi mengandalkan karakter spasi pada dokumen teks untuk melakukan pemisahan. Hasil dari proses ini adalah kumpulan kata saja.

5. Stopword Removal

Tahap mengambil kata-kata penting dari hasil token. Algoritma stoplist

(membuang kata yang kurang penting) atau wordlist (menyimpan kata yang penting) dapat digunakan pada tahap ini. Stopword adalah kata-kata yang tidak deskriptif dan bukan merupakan kata penting dari suatu dokumen sehingga dapat dibuang. Contoh *stopword* adalah “yang”, “dan”, “di”, “dari” dan seterusnya. Dalam filtrasi ini menggunakan *stoplist/stopword* agar kata-kata yang kurang penting dan sering muncul dalam suatu dokumen dibuang sehingga hanya menyisakan kata-kata yang penting dan mempunyai arti yang diproses ke tahap selanjutnya.

6. Feature Selection

Tahap ini merupakan tahap lanjutan dari pengurangan dimensi. Walaupun ditahap sebelumnya sudah melakukan penghapusan kata-kata yang tidak deskriptif (*stopwords*), tidak semua kata-kata di dalam dokumen memiliki arti penting. Sehingga untuk mengurangi dimensi, pemilihan hanya dilakukan pada kata-kata yang relevan dan yang benar-benar mempresentasikan isi dari suatu dokumen. Kata-kata yang dinilai penting dilihat dari intensitas kemunculan dan yang paling informatif dari keseluruhan.

7. Stemming

Stemming (Informatikalogi, 2017) merupakan salah satu tahapan dalam proses *text preprocessing*. *Stemming* bertujuan untuk mentransformasikan kata menjadi kata dasarnya (*root*) dengan menghilangkan semua imbuhan kata (*affixes*) meliputi awalan kata (*prefixes*), sisipin kata (*infixes*), akhiran kata (*suffixes*) dan atau menghilangkan awalan dan akhiran kata (*confixes*) pada kata turunan.

Adapun tahapan algoritma *stemming* sebagai berikut :

1. Langkah pertama adalah memeriksa apakah kata tersebut merupakan akar kata (*root*) terdapat dalam daftar akar kata (*root*). Jika kata tersebut merupakan akar kata, maka proses dihentikan pada tahap pertama ini.
2. Menghilangkan *Inflection Suffixes* (“-lah”, “-kah”, “-ku”, “-mu”, atau “-nya”). Jika kata berupa particles (“-lah”, “-kah”, “-tah” atau “-pun”) maka langkah ini diulangi lagi untuk menghapus Possesive Pronouns (“-ku”, “-mu”, atau “-nya”).

3. Menghilangkan *derivational suffix* (imbuhan turunan). Hilangkan imbuhan -i, -kan, -an.
4. Menghilangkan *derivational prefix* (awalan turunan). Hilangkan awalan be-, di-, ke-, me-, pe-, se- dan te-.
5. Bila dari langkah iv di atas belum ketemu juga. Maka lakukan analisis apakah kata tersebut masuk dalam tabel diambiguitas kolom terakhir atau tidak.
6. Bila dari langkah iv di atas belum ketemu juga. Maka lakukan analisis apakah kata tersebut masuk dalam tabel diambiguitas kolom terakhir atau tidak.
7. Bila semua proses di atas gagal, maka algoritma mengembalikan kata aslinya.

2.1.5. **Klasifikasi**

Bagian sangat penting dalam *data mining* adalah teknik klasifikasi, yaitu bagaimana mempelajari sekumpulan data sehingga dihasilkan aturan yang bisa mengklasifikasi atau mengenali data-data baru yang belum pernah dipelajari. Klasifikasi dapat didefinisikan sebagai proses untuk menyatakan suatu objek data sebagai salah satu kategori (kelas) yang telah didefinisikan sebelumnya. Klasifikasi banyak digunakan dalam berbagai aplikasi, di antaranya adalah deteksi kecurangan (*fraud detection*), pengelolaan pelanggan, diagnosis medis, prediksi penjualan, dan sebagainya (Suyanto, 2019).

Model klasifikasi dapat dibangun berdasarkan pengetahuan seorang pakar (ahli). Namun, mengingat himpunan data yang sangat besar, model klasifikasi lebih sering dibangun menggunakan teknik pembelajaran dalam bidang *machine learning*. Proses pembelajaran secara otomatis terhadap suatu himpunan data mampu menghasilkan model klasifikasi (fungsi target) yang memetakan objek data x (*input*) ke salah satu kelas y yang telah didefinisikan sebelumnya. Jadi, proses pembelajaran memerlukan masukan (*input*) berupa himpunan data latihan (*training set*) yang berlabel (memiliki atribut kelas) dan mengeluarkan *output* yang berupa sebuah model klasifikasi (Suyanto, 2019).

Penentuan pengklasifikasian bertujuan untuk menentukan sentimen suatu kalimat opini. Terdapat 3 cara dalam menentukan kelas yaitu:

1. Menurut Nurfalah & Suryani (2016), penentuan sentimen dilakukan dengan menghitung probabilitas kemunculan kata kunci positif dan kata kunci negatif. Setelah diketahui semua kata kunci dan *emoticon* yang mempunyai nilai sentimen, selanjutnya dihitung probabilitas kemunculan sentimen positif dan negatif mana yang lebih dominan. Jika nilai sentimen positif lebih dominan maka nilai sentimen untuk kalimat tersebut adalah positif, namun jika nilai sentimen negatif lebih dominan maka nilai sentimen untuk kalimat tersebut adalah negatif, namun jika nilainya sama antara sentimen negatif dan sentimen positif maka nilai sentimen untuk kalimat tersebut adalah netral. Gambar 2.2 merupakan formula dalam penentuan sentimen:

$$sentiment\ value = \begin{cases} 1, & \sum sentiments + emoticons > 0 \\ 0, & \sum sentiments + emoticons = 0 \\ -1, & \sum sentiments + emoticons < 0 \end{cases}$$

Gambar 2.3. Formula dalam Penentuan Sentimen (Nurfalah & Suryani, 2016)

2. Menurut Pamungkas dan Putri (2017), penentuan sentimen dilakukan dengan menghitung jumlah bobot kata kunci positif ($S_{positive}$) dan jumlah bobot kata kunci negatif ($S_{negative}$) yang ditemukan pada opini. Rumus untuk mendapatkan $S_{positive}$ dengan $S_{negative}$ dapat dilihat pada formula 2.1 dan 2.2 dibawah ini.

$$S_{positive} = \sum_{i \in T} positive\ score_i \quad (2.1)$$

$$S_{negative} = \sum_{i \in F} |negative\ score_i| \quad (2.2)$$

Setelah jumlah sentimen diperoleh, dilakukan perbandingan $S_{positive}$ dengan $S_{negative}$. Jika nilai positif lebih besar dari nilai negatif maka kalimat termasuk opini positif. Jika nilai negatif lebih besar dari nilai positif maka kalimat termasuk opini negatif. Jika nilai positif dan nilai negatif sama

maka kalimat termasuk opini netral. Gambar 2.4 menunjukkan rumus pengklasifikasiannya.

$$Sentence_{sentiment} \begin{cases} \text{positive if } S_{positive} > S_{negative} \\ \text{neutral if } S_{positive} = S_{negative} \\ \text{negative if } S_{positive} < S_{negative} \end{cases}$$

Gambar 2.4. Rumus dalam Penentuan Sentimen (Pamungkas & Putri, 2017)

- Menurut Thelwal (2012), penentuan sentimen dilakukan dengan menghitung maksimum bobot opini positif ($S_{positive}$) dan maksimum bobot opini negatif ($S_{negative}$) yang ditemukan pada opini. Jika $Max(S_{positive})$ lebih besar dari $Max(S_{negative})$ maka termasuk kelas positif. Jika $Max(S_{positive})$ lebih kecil dari $Max(S_{negative})$ maka termasuk kelas negatif. Jika $Max(S_{positive})$ dan $Max(S_{negative})$ bernilai sama maka termasuk kelas netral. Gambar 2.5 menunjukkan rumus klasifikasinya.

$$Sentence_{sentiment} = \begin{cases} \text{positive if } Max(S_{positive}) > Max(|S_{negative}|) \\ \text{neutral if } Max(S_{positive}) = Max(|S_{negative}|) \\ \text{negative if } Max(S_{positive}) < Max(|S_{negative}|) \end{cases}$$

Gambar 2.5. Rumus dalam Penentuan Sentimen (Thelwal, 2012)

Selain klasifikasi untuk menentukan kelas opini, klasifikasi untuk *rating* juga diperlukan agar dapat dibandingkan dengan opini. Aturan pengklasifikasian *rating* menurut Xia dan Jiang (2018) dapat dilihat pada tabel 2.1 di bawah ini.

Tabel 2.1. Aturan Klasifikasi *Rating* (Xia dan Jiang, 2018)

Rating	Kelas
1-2	Negatif
3	Netral
4-5	Positif

Kata-kata opini positif digunakan untuk mengekspresikan keadaan yang diinginkan sementara kata-kata opini negatif digunakan untuk mengekspresikan keadaan yang tidak diinginkan. Contoh kata-kata opini positif adalah: cantik, indah, baik, dan menakjubkan. Contoh kata-kata opini negatif adalah buruk, miskin, dan mengerikan. Terlepas dari kata-kata individual, ada juga opini frasa

dan idiom. Secara kolektif, itu disebut *lexicon* opini dan merupakan instrumen untuk analisis sentimen.

2.1.6. *Sentistrength*

SentiStrength (Thelwal, 2012) adalah pengklasifikasian berbasis leksikon yang mengeksploitasi leksikon sentimen yang dibangun serta menggabungkan entri dari sumber daya linguistik yang berbeda. Algoritma SentiStrength digunakan untuk mengidentifikasi polaritas sentimen dalam teks dan mendeteksi kekuatan sentimen yang diekspresikan. SentiStrength menampilkan skor sentimen positif dan negatif, yaitu -1 (tidak negatif) hingga -5 (sangat negatif), 1 (tidak positif) hingga 5 (sangat positif) untuk setiap teks input yang ditulis dalam bahasa Inggris. Berdasarkan penelitian dari psikologi, mengungkapkan bahwa proses sentimen positif dan negatif berjalan secara paralel (campuran emosi). Berdasarkan jumlah aljabar mereka, SentiStrength juga dapat melaporkan skor trinary keseluruhan, yaitu keseluruhan positif (skor = 1), negatif (skor = -1) dan netral (skor = 0).

Algoritma SentiStrength bergantung pada informasi yang digunakan dalam algoritma dan dapat disesuaikan. Informasi yang dimaksud sebagai berikut (Thelwal, 2012):

1. Kamus Sentimen (*EmotionLookUpTable*)

Kamus sentimen berisi kumpulan kata yang telah diberi bobot dengan kekuatan sentimen 1 (tidak memiliki sentimen positif) s.d. 5 (memiliki sentimen positif yang sangat kuat), dan -1 (tidak memiliki sentimen negatif) s.d. -5 (memiliki sentimen negatif yang sangat kuat). Kamus sentimen didapatkan dari hasil translasi kamus sentimen berbahasa Inggris yang telah mengalami penambahan dan pengurangan kata berdasarkan dari hasil pengamatan dalam proses pengembangan sistem ini.

2. Kamus *Emoticon* (*EmoticonLookUpTable*)

Emoticon adalah simbol atau kombinasi dari simbol-simbol yang biasanya digunakan untuk menggambarkan ekspresi wajah manusia yang mengandung emosi atau perasaan dalam bentuk pesan atau tulisan. Misalnya, simbol “:D” menunjukkan ungkapan emosi tertawa. Data ini dihasilkan secara manual

berdasarkan pengamatan dalam proses pengembangan sistem ini. Kamus emosikon ini juga diberi bobot yang akan menentukan perubahan bobot sentimen pada sebuah kalimat.

3. Kamus Bahasa Indonesia (*EnglishWordList*)

Kamus yang berisi 31.128 kata umum bahasa Indonesia yang dibutuhkan untuk melakukan penyaringan *term* berbahasa Indonesia pada tahap *preprocessing*.

4. Kamus Idiom (*IdiomLookupTable*)

Kamus Idiom adalah kata ungkapan yang memiliki makna berbeda dengan kata aslinya. Misalnya, kata “banting tulang” bukan berarti tulang yang dibanting melainkan ungkapan pengganti bekerja keras. Kamus Idiom ini juga diberi bobot yang akan menentukan perubahan bobot sentimen pada sebuah kalimat. Data ini dihasilkan secara manual berdasarkan pengamatan dalam proses pengembangan sistem ini.

5. Slangwords dan Konversinya (*SlangLookupTable*)

Slangwords adalah kata-kata tidak baku yang sering digunakan seperti penggunaan kata yang disingkat, bahasa pergaulan yang biasa digunakan sehari-hari serta kata yang memiliki kesalahan penulisan.

6. *BoosterWordList*

BoosterWordList adalah kata yang dapat meningkatkan atau mengurangi intensitas sentimen kata disebelahnya. Misal, kata “sangat bahagia” lebih positif daripada kata “bahagia”, kata “kurang bahagia” tidak lebih positif daripada kata “bahagia”. Kata ini diberi bobot 1-2 untuk menambah atau mengurangi skor kata disampingnya. Data ini dihasilkan secara manual berdasarkan pengamatan dalam proses pengembangan sistem ini.

7. Kata Negasi (*NegatingWordList*)

Kata negasi merupakan kata yang terdapat dalam suatu kalimat yang dapat mengubah orientasi dari suatu opini. Misalnya, kata “nakal” merupakan kata yang bermakna negatif, akan tetapi jika kata “nakal” didahului kata negasi “tidak” maka susunan kata menjadi “tidak nakal” yang bermakna positif. Kata ini disimpan dalam bentuk file .txt, tidak disimpan dalam database. Data ini

dihasilkan secara manual berdasarkan pengamatan dalam proses pengembangan sistem ini.

8. Kata Tanya (*QuestionWords*)

Kata tanya merupakan kata yang terdapat dalam suatu kalimat yang dapat mengubah orientasi dari suatu opini. Misalnya, “apakah kamu marah?”, walaupun terdapat kata “marah”, kalimat ini tidak memiliki orientasi positif maupun negatif, sehingga diklasifikasikan sebagai kalimat netral. Kata ini disimpan dalam bentuk file .txt, tidak disimpan dalam database. Data ini dihasilkan secara manual berdasarkan pengamatan dalam proses pengembangan sistem ini.

Untuk menyesuaikan SentiStrength untuk bahasa Indonesia, pertama-tama, harus mengganti daftar istilah bahasa Inggris *EmotionLookupTable.txt* dengan bahasa Indonesia. Daftar kata dikompilasi dengan menerjemahkan daftar kata dalam bahasa Inggris dan menambahkan kata-kata yang mengandung sentimen paling umum dari opini yang dianalisis. Setiap kata di *EmotionLookupTable.txt* harus ditandai dengan skor sentimen yang menunjukkan polaritas khas dan kekuatan sentimen yang diekspresikan menggunakan skema berikut:

[-5] Sentimen negatif yang sangat kuat

[-4] Sentimen negatif yang kuat

[-3] Sentimen negatif sedang

[-2] Sentimen negatif ringan

[2] Sentimen positif ringan

[3] Tingkatkan sentimen positif

[4] Sentimen positif yang kuat

[5] Sentimen positif yang sangat kuat

2.1.7. *Ukuran Evaluasi Model Klasifikasi*

Evaluasi terhadap suatu klasifikasi umumnya dilakukan menggunakan sebuah himpunan data uji, yang tidak digunakan dalam pelatihan klasifikasi tersebut, dengan suatu ukuran tertentu. Terdapat sejumlah ukuran yang dapat digunakan untuk menilai atau mengevaluasi model klasifikasi, diantaranya adalah: *accuracy* atau tingkat pengenalan, *error rate* atau tingkat kesalahan atau

kekeliruan klasifikasi, *recall* atau *sensitivity* atau *true positive*, *specificity* atau *true negative* dan *precision*. Model klasifikasi yang dibuat adalah pemetaan dari suatu baris data dengan keluaran sebuah hasil prediksi kelas/target dari data tersebut. Klasifikasi yang memiliki dua kelas sebagai keluarannya disebut dengan klasifikasi biner. Kedua kelas tersebut biasa direpresentasikan dalam $\{0,1\}$, $\{+1,-1\}$ atau $\{positive; negative\}$. (Suyanto, 2019)

Empat istilah penting untuk memahami semua ukuran evaluasi adalah sebagai berikut :

1. TP atau *True Positive* adalah jumlah tuple positif yang dilabeli dengan benar oleh *classifier*. Yang dimaksud tuple positif adalah tuple aktual yang berlabel positif, seperti tuple dengan label Bonus='Ya'.
2. TN atau *True Negatives* adalah jumlah tuple negatif yang dilabeli dengan benar oleh *classifier*. Yang dimaksud tuple negatif adalah tuple aktual yang berlabel negatif, seperti tuple dengan label Bonus='Tidak'.
3. FP atau *False Positive* adalah jumlah tuple negatif yang salah dilabeli oleh *classifier*. Misalnya, sebuah tuple pelanggan yang berlabel Bonus='Tidak' tetapi oleh *classifier* dilabeli Bonus='Ya'.
4. FN atau *False Negatives* adalah jumlah tuple positif yang salah dilabeli oleh *classifier*. Misalnya sebuah tuple pelanggan yang berlabel Bonus='Ya', tetapi oleh *classifier* dilabeli Bonus='Tidak'.

Keempat istilah di atas dapat direpresentasikan sebagai matriks 2 x 2 yang disebut *confusion matrix* yang ditunjukkan oleh gambar 2.6.

		Aktual	
		<i>Class</i>	<i>Positive</i>
Prediksi	<i>Positive</i>	<i>True Positive (TP)</i>	<i>False Negative (FN)</i>
	<i>Negative</i>	<i>False Positive (FP)</i>	<i>True Negative (TN)</i>

Gambar 2.6. Confusion Matrix

Confusion matrix berguna untuk menganalisis kualitas *classifier* dalam mengenali tuple-tuple dari kelas yang ada. TP dan TN menyatakan bahwa *classifier* mengenali tuple dengan benar, artinya tuple positif dikenali sebagai positif dan tuple negatif dikenali sebagai negative. Sebaliknya, FP dan FN

menyatakan bahwa *classifier* salah dalam mengenali tuple, tuple positif dikenali sebagai negatif dan tuple negatif dikenali sebagai positif. Terdapat beberapa rumus umum yang dapat digunakan untuk menghitung performa klasifikasi. Hasil dari nilai akurasi, presisi, dan *recall* biasa ditampilkan dalam persentase.

1. *Accuracy*

Akurasi adalah jumlah proporsi prediksi yang benar. Adapun rumus penghitungan akurasi.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.3)$$

2. *Precision*

Precision adalah proporsi jumlah dokumen teks yang relevan terkenali diantara semua dokumen teks yang terpilih oleh sistem. Rumus *precision*.

$$Precision = \frac{TP}{TP+FP} \quad (2.4)$$

3. *Recall*

Recall adalah proporsi jumlah dokumen teks yang relevan terkenali diantara semua dokumen teks relevan yang ada pada koleksi. Rumus *recall*.

$$Recall = \frac{TP}{TP+FN} \quad (2.5)$$

2.1.8. *Penelitian Terkait*

Islam (2014) mempelajari perilaku *user* dalam penggunaan aplikasi pada Android IOS. Pemilihan aplikasi yang digunakan bergantung pada rata-rata *rating* yang diberikan *user* lain. Permasalahan yang timbul dengan hanya berfokus pada *rating* yaitu ketidaksesuaian antara *rating* dengan opini serta bias pada kesimpulan *rating user*. Opini diekstrak dengan menggunakan *sentiment-lexicons* dan pendekatan ini mampu mengatasi permasalahan data yang berasal dari berbagai kategori. Keluaran dari penelitian ini adalah berupa kajian teoritis dan belum ada pengukuran untuk menghitung efisiensi dari teori yang dihasilkan.

Pamungkas dan Putri (2016) melakukan studi analisis penggunaan teknik *lexicon* pada data berbahasa Indonesia. Pendekatan yang dilakukan pada penelitian ini adalah konversi bahasa Indonesia menjadi bahasa Inggris, kemudian menerapkan teknik *lexicon* pada kamus data bahasa Inggris untuk mendapatkan nilai sentimen. Data opini *user* diperoleh dari *google playstore* dan *appstore*.

Proses konversi menggunakan Bing *translator*. Peneliti berasumsi hasil *translate* telah cukup baik dan tidak dilakukan proses koreksi secara manual. Hasil penelitian ini menunjukkan rata-rata nilai akurasi 0,68 untuk klasifikasi opini dari tiga jenis sentimen yaitu positif, negatif dan netral. Beberapa isu yang dibahas pada penelitian ini adalah masalah normalisasi data, struktur bahasa yang tidak standar, dan kata-kata yang ambigu.

Dhaoui, dkk (2017) telah melakukan perbandingan teknik *lexicon* dengan *machine learning* untuk sentimen analisis di sosial media. Data yang digunakan berupa *big data* yang berasal dari 83 *brand* di facebook dengan 850 sampel data komentar yang bersumber dari pengguna. Data tersebut digunakan untuk menentukan sentimen positif atau negatif dari konsumen. Hasil penelitian tersebut menunjukkan kedua pendekatan memiliki tingkat akurasi yang mirip. Selain itu, kedua teknik mampu memberikan akurasi yang lebih tinggi untuk mendeteksi sentimen positif daripada sentimen negatif.

Nurfalah dan Suryani (2017) melakukan ekstraksi opini pelayanan pasti pas pertamina dengan jumlah opini sebanyak 150 data dengan menggunakan pendekatan *lexicon*. Kamus kata yang digunakan dalam pendekatan ini antara lain kata positif, kata negatif, kata negasi, emotikon dan kamus bahasa Indonesia. Pada kamus kata positif dan negatif tidak terdapat bobot, hanya kamus emotikon yang memiliki bobot positif (1) atau negatif (-1). Penentuan klasifikasi opini dilakukan dengan menghitung probabilitas kemunculan kata positif dan negatif yang lebih dominan. Pada penelitian ini, *preprocessing* yang diterapkan hanyalah *normalisasi* dan *tokenization*. Dalam membandingkan hasil ekstraksi dengan opini, peneliti melakukan proses pelabelan secara manual ke dalam kelas positif, negatif atau netral yang selanjutnya dibandingkan dengan hasil klasifikasi opini. Hasil penelitian ini menghasilkan akurasi sebesar 0,66.

Berdasarkan uraian penelitian di atas, pemilihan *rating* mengacu pada penelitian Islam yang menemukan bahwa adanya ketidaksesuaian antara *rating* dengan opini. Sehingga ekstraksi opini dengan menggunakan *lexicon* dapat menjadi pertimbangan untuk memperoleh penilaian yang lebih akurat dari produk

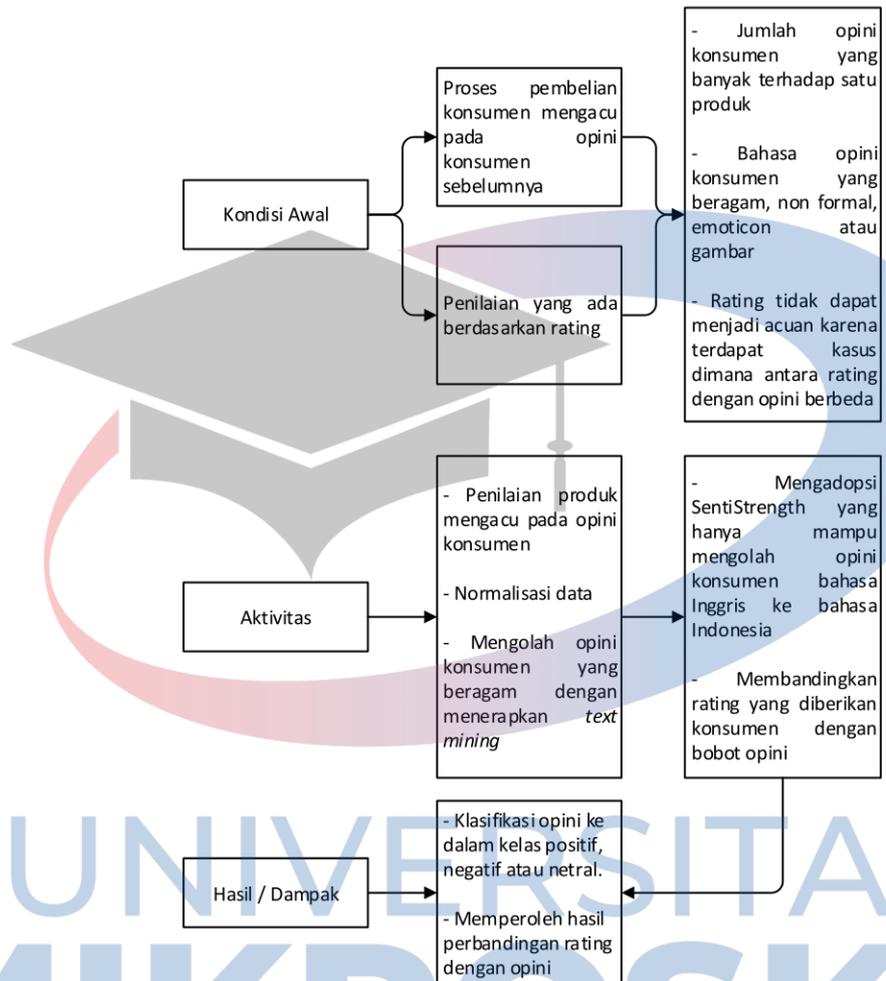
atau layanan. Hal ini didukung oleh penelitian Dhaoui, dkk yang membandingkan hasil akurasi *lexicon* dengan *machine learning*. Kedua metode sama-sama menghasilkan akurasi tinggi untuk mendeteksi sentimen positif daripada sentimen negatif. Penelitian Putri dan Pamungkas juga menggunakan *lexicon* untuk mengolah opini dengan rata-rata akurasi 0,68. Hasil akurasi diperoleh tanpa menerapkan normalisasi data, pengecekan struktur bahasa yang tidak standar dan kata-kata yang ambigu. Sehingga pada penelitian ini akan dibahas isu yang belum terselesaikan. Penelitian ini juga memperbaharui penelitian Nurfalah dan Suryani, yaitu kamus yang digunakan menggunakan kamus pada penelitian Putri dan Pamungkas yang berbahasa Inggris diterjemahkan ke bahasa Indonesia, kemudian menambahkan tahapan *preprocessing* yaitu *stemming* dan *stopword removal*.

2.2. Kerangka Konsep

Kerangka pikir pemecahan masalah menggambarkan bagaimana masalah penelitian dapat diselesaikan melalui solusi-solusi yang diusulkan serta dari solusi tersebut diharapkan memiliki dampak yang dapat menyelesaikan permasalahan penelitian. Gambar 2.7 akan menjelaskan kerangka konsep pemecahan masalah dari penelitian yang akan dilakukan.

Platform e-commerce telah berkembang secara cepat dengan beragam produk dan pengalaman membeli dengan penawaran yang menarik. Namun berefek pada ketidakamanan konsumen dalam mengenali produk yang akan dibeli meskipun sudah terdapat solusi yang diberikan yaitu *meta-data*. Konsumen masih merasa kesulitan dalam memutuskan membeli hanya dengan mengetahui fitur-fitur produk. Sehingga *e-commerce* menyediakan fitur forum agar konsumen memperoleh gambaran produk berdasarkan pengalaman konsumen sebelumnya serta mampu memberikan opini terhadap produk. Akan tetapi dengan banyaknya opini yang tersedia pada produk, menyebabkan konsumen kesulitan untuk membaca semua opini dan membuat keputusan dalam membeli produk. Jika konsumen hanya membaca beberapa opini, maka pandangan bias tentang produk dapat dihasilkan (Rajganes, Nandhini & Sumitha, 2016). Untuk memudahkan menerjemahkan opini konsumen, *e-commerce* memanfaatkan *rating*. *Rating* yang

digunakan adalah bintang dari skala 1 sampai 5. Namun, menggunakan *rating* saja tidak cukup untuk menjadi referensi untuk menentukan sentimen, karena terdapat perbedaan antara *rating* dengan opini yang diberikan (Islam, 2014).



Gambar 2.7. Kerangka konsep penelitian

Tindakan yang dapat diterapkan adalah menerapkan *text mining* untuk mengolah semua opini dengan memperhatikan format opini (AL-Rubaiee *et al.*, 2018). Terdapat program untuk mengolah opini konsumen dalam bahasa Inggris dengan nama SentiStrength (Thelwal, 2012). Program ini akan diadopsi untuk mampu mengolah opini dalam bahasa Indonesia. Cara kerja program ini menggunakan pendekatan *lexicon* yang membutuhkan kamus kata dalam menentukan kata-kata yang termasuk opini dan diberi bobot. Berdasarkan bobot yang diperoleh pada opini akan dibandingkan bobot maksimum antara opini positif dengan opini negatif untuk dikategorikan ke dalam kelas positif, negatif

atau netral. Dengan klasifikasi yang dihasilkan untuk setiap opini dan dikelompokkan per item dapat memberi nilai manfaat baik konsumen maupun penjual. Konsumen terbantu dalam proses pembelian berdasarkan pengalaman konsumen sebelumnya. Sedangkan bagi penjual, dapat mengelola kepuasan, kepercayaan serta loyalitas konsumen demi perkembangan jangka panjang *e-commerce*.

Kelas opini yang diperoleh akan dibandingkan dengan kelas *rating* untuk mengetahui kesesuaian nilai *rating* dengan bobot. Pada penelitian ini, *rating* diasumsikan sebagai data aktual dengan pertimbangan *rating* merupakan nilai yang diberikan langsung oleh konsumen. Pengklasifikasian *rating* mengacu pada aturan yang dikemukakan oleh Xia dan Jiang (2018) yaitu *rating* 1-2 termasuk kelas negatif, *rating* 3 termasuk kelas netral dan *rating* 4-5 termasuk kelas positif. Setelah kelas *rating* dan kelas opini tersedia, maka perbandingan akan ditampilkan dalam bentuk grafik dan *confusion matrix*. Dari *confusion matrix* selanjutnya akan dihitung akurasi, presisi dan *recall*.

UNIVERSITAS MIKROSKIL