



TESIS

# EVALUASI KEPUASAN PELANGGAN HOTEL BERDASARKAN ANALISA SENTIMENT PADA REVIEW PELANGGAN

REZA AMALIA PRIYANTINA  
09211750053018

Dosen Pembimbing:  
Prof. Drs.Ec. Ir. Riyanto Sarno, M.Sc.,Ph.D  
19590803 198601 1 001

Departemen Manajemen Teknologi  
Fakultas Bisnis Dan Manajemen Teknologi  
Institut Teknologi Sepuluh Nopember  
2019



## LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar

**Magister Manajemen Teknologi (M.MT)**

di

**Institut Teknologi Sepuluh Nopember**

Oleh:

**Reza Amalia Priyantina**

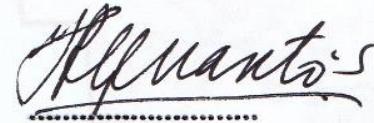
**NRP: 09211750053018**

**Tanggal Ujian: 15 April 2019**

**Periode Wisuda: September 2019**

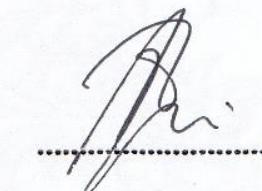
Disetujui oleh:

Pembimbing:

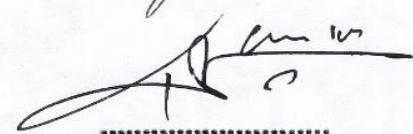


1. Prof. Drs. Ec. Ir. Riyanto Sarno, M.Sc., Ph.D.

Penguji:



1. Erma Suryani, S.T., M.T., PhD.



2. Faizal Mahamamto, S.Kom., M.Eng., Ph.D.



Kepala Departemen Manajemen Teknologi

Fakultas Bisnis dan Manajemen Teknologi

**Prof. Ir. I Nyoman Pujawan, M.Eng, Ph.D, CSCP**

**NIP: 196912311994121076**

*[Halaman ini sengaja dikosongkan]*

# **EVALUASI KEPUASAN PELANGGAN HOTEL BERDASARKAN ANALISA SENTIMENT PADA REVIEW PELANGGAN**

Nama : Reza Amalia P  
NRP : 09211750053018  
Pembimbing : Prof. Drs.Ec. Ir. Rianarto Sarno, M.Sc.,Ph.D.

## **ABSTRAK**

*Customer relationship management* (CRM) memiliki pengaruh yang sangat besar bagi kinerja perusahaan. Hubungan pelanggan dengan perusahaan saat ini sangat mudah untuk dilakukan, salah satunya melalui website pada review *online*. Review *online* akan sangat membantu perusahaan untuk mengetahui hal apa dari bisnis tersebut yang disenangi pelanggan maupun yang tidak. Untuk mempermudah perusahaan dalam mengetahui kepuasan pelanggan, diusulkan penelitian untuk mencari *sentiment* kepuasan dari setiap review sesuai dengan kategori aspect hotel kemudian melakukan evaluasi kepuasan. Aspect yang dimaksud terdiri dari: *location, meal, service, comfort* serta *cleanliness* hotel.

Penelitian ini mengambil teks review dalam bahasa Inggris. Kategorisasi aspect akan dilakukan dengan beberapa tahapan, pertama menggunakan *Latent Dirichlet Allocation* (LDA) sebagai metode untuk menemukan *hidden topic* dari review. *Latent Dirichlet Allocation* (LDA) memiliki kekurangan untuk mengklasifikasikan dokumen ke dalam salah satu aspect secara langsung. Sehingga pada tahap kedua diusulkan metode *Semantic Similarity* untuk mengkategorikan setiap *hidden topic* review yang dihasilkan oleh *Latent Dirichlet Allocation* (LDA) pada 5 aspect hotel. Kemudian dalam menghitung *Semantic Similarity*, *term list* akan diperluas dengan menggunakan metode *Term Frequency-Inverse Cluster Frequency* (TF-ICF). Akhirnya, dilakukan proses klasifikasi terhadap sentimen pelanggan (puas atau tidak puas) menggunakan *Word Embedding* untuk mengekstraksi setiap kata dan dokumen menjadi *vector* kata yang kemudian akan digunakan sebagai input untuk proses klasifikasi menggunakan metode *Long Short Term Memory* (LSTM). setelah ditemukan sentimen pada setiap aspect, selanjutnya akan dilakukan evaluasi hasil.

Performa dari setiap metode dievaluasi menggunakan *precision*, *recall* dan *F1-Measure*. Hasil dari uji coba menunjukkan bahwa performa kategorisasi aspect tertinggi dilakukan dengan melakukan penggabungan metode *Latent Dirichlet Allocation* (LDA) untuk mencari *hidden topic*, digabungkan dengan *Term Frequency-Inverse Cluster Frequency* (TF-ICF) 100% untuk peluasan *term* dan *Semantic Similarity* untuk kategorisasi aspect yang mendapatkan hasil performa hingga mencapai 85% dan performa *Word Embedding* untuk representasi angka *vector* dengan *Long Short Term Memory* (LSTM) untuk klasifikasi sentiment sangat tinggi yang mendapatkan performa mencapai 94%. Sehingga, peneliti melakukan penggabungan metode LDA+TF-ICF 100%+*Semantic Similarity* untuk melakukan kategorisasi aspect lalu menggunakan *Word Embedding*+LSTM untuk melakukan klasifikasi sentiment pada setiap review. Kemudian, pada evaluasi akhir yang dilakukan, peneliti mendapatkan bahwa aspect *comfort hotel* memiliki review dengan *sentiment negative* sangat tinggi yang mencapai 11,369% dibanding dengan *sentiment* review pada *aspect* lainnya (*location*: 0.464, *meal*: 0.696, *service*: 3.016, dan *cleanliness*: 1.160) sehingga pihak manajemen hotel perlu melakukan perbaikan-perbaikan untuk lebih memperhatikan kenyamanan pelanggan dengan tujuan untuk mengurangi jumlah review *negative* pada aspect *comfort* tersebut. Hasil juga menunjukkan bahwa perubahan *sentiment* (pada *positive* atau *negative sentiment*) dipengaruhi oleh *aspect* yang dimiliki oleh setiap review.

**Kata kunci:** *Customer relationship*, Analisa Review, Kategorisasi Aspect, Klasifikasi Sentiment, *topic modelling*, LDA, LDA-Similarity, TF-ICF, *Word Embedding*, LSTM.

# **EVALUATION OF HOTEL CUSTOMER SATISFACTION BASED ON SENTIMENT ANALYSIS ON CUSTOMER REVIEW**

Student's Name : Reza Amalia Priyantina

Student ID : 09211750053018

Supervisor : Prof. Drs.Ec. Ir. Rianarto Sarno, M.Sc.,Ph.D.

## **ABSTRACT**

Customer relationship management (CRM) has a huge influence on company performance. Nowadays, customers can contact companies in easy ways, one of them is through the website on an online review. Online reviews will greatly help the company to find out any of the business that makes customers like it or not. To help companies determine customer satisfaction, the proposed research to find satisfaction sentiment of each review in accordance with aspects of the category of the hotel then do an evaluation of satisfaction. Aspect is composed of location, meal, service, comfort, and cleanliness of the hotel.

This research will take a review text in English. These aspects were classified in several stages, first using the Latent Dirichlet Allocation (LDA) was used as a method to find the hidden topic of a document. Latent Dirichlet Allocation (LDA) has the disadvantage to classify documents into one aspect directly. So that in the second stage the Semantic Similarity method was proposed to categorize each hidden topic review produced by Latent Dirichlet Allocation (LDA) on 5 aspects of the hotel. Then in calculating the Semantic Similarity, term list will be expanded by using Cluster Term Frequency-Inverse Frequency (TF-ICF). Finally, the classification of customer sentiment (satisfied or dissatisfied) is done using Word Embedding to extract each word and document into a word vector which will then be used as input for the classification process using the LSTM method. After finding sentiment on each aspect, then the results evaluation will be carried out.

The performance of each method is evaluated using precision, recall and F1-Measure. The results of the trials show that the highest performance of aspect categorization is done by combining the Latent Dirichlet Allocation (LDA) method

to search hidden topics, combined with 100% Term Frequency-Inverse Cluster Frequency (TF-ICF) for expansion term and Semantic Similarity for categorization that get performance results up to 85% and Word Embedding for word vector representation combined with Long Short Term Memmory (LSTM) is getting very high sentiment classifications that get a performance of 94%. So, the researcher merged the LDA + TF-ICF 100% + Semantic Similarity method to categorize aspects and then used Word Embedding + LSTM to classify sentiments in each review. Then, at the final evaluation, the researcher found that the comfort aspect of the hotel had a review with very high negative sentiment which reached 11,369% compared to other aspects of the review sentiment (*location*: 0.464, *meal*: 0.696, *service*: 3.016, dan *cleanliness*: 1.160) so the hotel management needs to make improvements to pay more attention to customer convenience in order to reduce the number of negative reviews on the comfort aspect. The results also show that changes in sentiment (in positive or negative sentiments) are influenced by the aspects of each review.

**Keyword:** Customer relationship, Review Analysis, Aspect Categorization, Sentiment Classification, topic modelling, LDA, LDA-Similarity, TF-ICF, Word Embedding, LSTM.

## KATA PENGANTAR

Penulis mengucapkan rasa syukur yang tak berhingga kepada Allah SWT atas segala rahmat, berkah, hidayah, kesehatan dan petunjuk-Nya, sehingga penulis dapat menyelesaikan tesis yang merupakan salah satu syarat dalam menyelesaikan Program Studi Magister di Institut Teknologi Sepuluh Nopember Surabaya.

Terselesaikannya tesis beserta laporannya ini tentunya tak luput dari peran serta berbagai pihak yang telah memberikan bantuan dan dorongan semangat, baik secara langsung maupun tak langsung. Untuk itu, atas segala bantuan yang telah diberikan, penulis mengucapkan terima kasih serta penghargaan yang sebesar-besarnya antara lain kepada:

1. Bapak Dr. Tech. Ir. R. V. Hari Ginardi, M. Sc. selaku dosen wali yang senantiasa memberikan bimbingan, saran, dan motivasi selama perkuliahan S2 kepada penulis.
2. Bapak Prof. Drs.Ec. Ir. Ryanarto Sarno, M.Sc., Ph.D selaku dosen pembimbing yang telah banyak meluangkan waktu, tenaga dan pikiran dalam membimbing penulis sehingga tesis ini dapat terselesaikan dengan baik.
3. Ibu Erma Suryani, S.T., M.T., PhD. dan Bapak Faizal Mahamamto, S.Kom., M.Eng., Ph.D. selaku dosen penguji yang telah banyak membantu penulis untuk bisa menjadi lebih baik.
4. Seluruh dosen S2 Manajemen Teknologi MMT ITS yang telah memberikan ilmu dan pengetahuan kepada penulis selama menempuh studi.
5. Kedua Orang Tua yang senantiasa memberikan motivasi, semangat, dan harapan serta mendoakan penulis demi keberhasilan penulis dalam menyelesaikan studi.
6. Terimakasih disampaikan kepadateeman-teman yang telah disatukan dalam ikatan takdir untuk menyelesaikan thesis bersama dengan pembimbing Bapak Prof. Drs.Ec. Ir. Ryanarto Sarno, M.Sc., Ph.D yang senantiasa memberikan motivasi, semangat, nasehat dan perhatian kepada penulis dalam menyelesaikan studi dan tesisnya.
7. Terimakasih secara khusus disampaikan penulis kepada semua rekan mahasiswa S2 Manajemen Teknologi Informasi angkatan 2017 selaku rekan

seperjuangan yang telah memberikan bantuannya baik secara langsung maupun tidak langsung.

Semoga kebaikan dan bantuan yang telah diberikan kepada penulis dibalas dengan kebaikan yang lebih oleh Allah SWT. Aamin.

Penulis menyadari bahwa dalam laporan tesis ini masih banyak kekurangan. Karena itu, masukan ataupun saran demi perbaikan dan penerapan tesis ini di masa mendatang tetap penulis harapkan.

Surabaya,      Juni 2019

Penulis

**Reza Amalia Priyantina**

## DAFTAR ISI

ABSTRAK .....	v
ABSTRACT .....	vii
KATA PENGANTAR .....	ix
DAFTAR ISI.....	xi
DAFTAR TABEL.....	xv
DAFTAR GAMBAR .....	xvii
1. BAB 1 PENDAHULUAN .....	19
1.1. Latar Belakang .....	19
1.2. Perumusan Masalah.....	25
1.3. Tujuan.....	25
1.4. Manfaat.....	26
1.5. Kontribusi Penelitian.....	26
1.6. Batasan Masalah.....	28
1.7. Sistematika Penulisan.....	28
2. BAB 2 KAJIAN PUSTAKA .....	31
2.1. Customer Relationship Management (CRM).....	31
2.2. Pengumpulan Data .....	31
2.3. Keyword Term List untuk Aspect Hotel .....	32
2.4. Pembangunan Dataset Training dan Testing.....	33
2.5. Pengolahan Bahasa Manusia .....	34
2.5.1 <i>Pre Processing</i> .....	34
2.5.2 <i>Latent Dirichlet Allocation</i> (LDA).....	35
2.5.3 <i>Semantic Similarity</i> .....	36
2.5.4 <i>Term Frequency-Inverse Cluster Frequency</i> (TF-ICF) .....	37

2.5.5 Word Embedding .....	37
2.5.6 <i>Long Short Term Memory</i> (LSTM) .....	40
2.5.7 Evaluasi .....	43
2.6. TRAVELOKA .....	43
2.7. Penelitian Sebelumnya.....	45
3. BAB 3 METODOLOGI PENELITIAN .....	49
3.1. Metodologi Penelitian.....	50
3.2. Pembangunan Model Penelitian .....	53
3.2.1 Data Text Review Hotel .....	56
3.2.2 Pre Processing .....	56
3.2.3 Modul Perluasan <i>Term List</i> ( <i>Expanding Term List</i> ).....	60
3.2.4 Proses Kategorisasi Aspect .....	64
3.2.5 Pre-Proses Untuk Klasifikasi Sentiment Berdasarkan Aspect .....	69
3.2.6 Proses Klasifikasi Sentimen .....	71
3.2.7 Evaluasi .....	76
4. BAB 4 HASIL DAN PEMBAHASAN .....	79
4.1. Implementasi Sistem.....	79
4.1.1.Data Text Review Hotel .....	79
4.1.2.Pre-Processing Data .....	80
4.1.3.Expanding Term List.....	81
4.1.4.Proses Kategorisasi Aspect .....	88
4.1.5.Pre-Proses Untuk Klasifikasi Sentiment Berdasarkan Aspect .....	102
4.1.6.Proses Klasifikasi Sentiment .....	103
4.2. Hasil Pengujian dan Evaluasi.....	109
4.2.1.Pendekatan Evaluasi untuk Kategorisasi Aspect.....	110
4.2.2.Pendekatan Evaluasi untuk Klasifikasi Sentiment .....	119

4.2.3. Kesimpulan Metode yang akan Digunakan .....	128
4.2.4. Hasil Evaluasi Sentimen pada Aspect Analysis Hotel.....	133
4.2.5. Pengaruh aspect terhadap sentiment .....	138
5. BAB 5 KESIMPULAN DAN SARAN .....	141
5.1    Kesimpulan.....	141
5.2    Saran.....	143
DAFTAR PUSTAKA .....	145
LAMPIRAN I .....	153
LAMPIRAN II .....	157
LAMPIRAN III.....	159
LAMPIRAN IV .....	161
BIOGRAFI PENULIS .....	163

*[Halaman ini sengaja dikosongkan]*

## DAFTAR TABEL

<b>Tabel 2.1:</b> <i>Keyword Term List</i> Terkait Aspect yang Diperoleh .....	33
<b>Tabel 2.2:</b> Pre-Processing Data .....	34
<b>Tabel 2.3:</b> Detail dari <i>embedding</i> yang tersedia secara luas .....	38
<b>Tabel 3.1</b> Representasi Dokumen Review .....	56
<b>Tabel 3.2</b> Contoh Hasil <i>Pre-processing</i> untuk Masukan Proses Kategorisasi.....	59
<b>Tabel 3.3</b> Tabel <i>Keyword Term List</i> + Hasil TF-ICF terkait Aspect.....	62
<b>Tabel 3.4</b> Tabel Contoh <i>Input</i> dan <i>Output</i> proses LDA .....	66
<b>Tabel 3.5</b> Tabel Contoh Perbandingan <i>Hidden Topic</i> dan <i>Term List</i> Setiap Aspect .....	68
<b>Tabel 3.6</b> Tabel Contoh Hasil Perhitungan <i>Similarity</i> untuk Setiap Aspect .....	68
<b>Tabel 3.7</b> Contoh Ilustrasi Hasil <i>Aspect Categorization</i> .....	70
<b>Tabel 3.8</b> Contoh Data <i>Aspect-Based Sentiment</i> ( <i>Aspect Comfort</i> ).....	70
<b>Tabel 3.9</b> Contoh Data <i>Aspect-Based Sentiment</i> ( <i>Aspect Meal</i> ) .....	70
<b>Tabel 3.10</b> Contoh Hasil Klasifikasi Sentiment menggunakan <i>Word Embedding</i> + <i>Long Short Term Memory</i> (LSTM).....	75
<b>Tabel 4.1</b> Hasil <i>Pre-processing</i> untuk Masukan Proses Klasifikasi .....	81
<b>Tabel 4.2</b> Contoh Hasil Perhitungan <i>Term Frequency</i> .....	83
<b>Tabel 4.3</b> Contoh Hasil Perhitungan <i>Inverse Cluster Frequency</i> (ICF).....	85
<b>Tabel 4.4</b> Hasil Perhitungan TF-ICF .....	87
<b>Tabel 4.5</b> Tabel Hasil <i>Hidden Topic</i> LDA .....	90
<b>Tabel 4.6</b> Tabel Hasil Perhitungan LDA + Semantic Similarity AC1 .....	93
<b>Tabel 4.7</b> Tabel Hasil Perhitungan LDA + Semantic Similarity AC2 .....	97
<b>Tabel 4.8</b> Tabel Hasil Perhitungan LDA + Semantic Similarity AC3 .....	101
<b>Tabel 4.9</b> Data Hasil <i>Aspect Categorization</i> (AC3) .....	102
<b>Tabel 4.10</b> Data <i>Aspect-Based Sentiment</i> ( <i>Aspect Comfort</i> ).....	103
<b>Tabel 4.11</b> Data <i>Aspect-Based Sentiment</i> ( <i>Aspect Meal</i> ).....	103
<b>Tabel 4.12</b> Data <i>Aspect-Based Sentiment</i> ( <i>Aspect Service</i> ).....	103

<b>Tabel 4.13</b> Tabel Hasil Klasifikasi Sentimen Menggunakan <i>Word Embedding + Long short Term Memmory (LSTM)</i> .....	106
<b>Tabel 4.14</b> Tabel Hasil Klasifikasi Sentimen Menggunakan <i>Dictionary SentiWordnet</i> .....	107
<b>Tabel 4.15</b> Tabel Hasil Klasifikasi Sentimen Menggunakan LSTM .....	109
<b>Tabel 4.16</b> Tabel Pendekatan Pengujian untuk Kategorisasi Aspect.....	110
<b>Tabel 4.17</b> Data Review yang telah dilabeli oleh Annotator .....	111
<b>Tabel 4.18</b> Data Hasil Percobaan Kategorisasi Aspect (AC) 1 .....	112
<b>Tabel 4.19</b> Data Perbandingan antara Hasil Sistem dengan <i>Ground Truth</i> .....	113
<b>Tabel 4.20</b> Pengujian Performa Kategorisasi Aspect .....	117
<b>Tabel 4.21</b> Tabel Pendekatan Pengujian untuk Klasifikasi Sentiment .....	120
<b>Tabel 4.22</b> Data Kategorisasi Aspect (AC3) yang telah dilabeli oleh Annotator .....	121
<b>Tabel 4.23</b> Data Hasil Percobaan Klasifikasi Sentiment (SC) 1 .....	123
<b>Tabel 4.24</b> Data Perbandingan antara Hasil Sistem dengan <i>Ground Truth Sentiment</i> .....	124
<b>Tabel 4.25</b> Pengujian Performa Analisa Sentiment .....	127
<b>Tabel 4.26</b> Evaluasi Sentiment pada Aspect Analysis.....	129
<b>Tabel 4.27</b> Hasil Kategorisasi Aspect (AC3).....	130
<b>Tabel 4.28</b> Hasil Klasifikasi Sentiment (SC1).....	132
<b>Tabel 4.29</b> Hasil Evaluasi Sentimen pada Aspect Analysis Hotel.....	136
<b>Tabel 4.30</b> Contoh Kesalahan Hasil Klasifikasi Aspect dan Sentiment .....	138

## DAFTAR GAMBAR

<b>Gambar 1.1</b> Contoh Review Hotel pada Traveloka.....	21
<b>Gambar 2.1</b> Proses <i>Crawling</i> dengan Software WebHarvy .....	32
<b>Gambar 2.2</b> Ilustrasi <i>Latent Dirichlet Allocation</i> (LDA).....	35
<b>Gambar 2.3</b> Contoh <i>Word Embedding</i> .....	38
<b>Gambar 2.4</b> Contoh Word Embedding.....	39
<b>Gambar 2.5</b> Arsitektur LSTM .....	41
<b>Gambar 2.6</b> Ilustrasi metode LSTM .....	42
<b>Gambar 2.7</b> Tujuan Traveloka.....	44
<b>Gambar 2.8</b> Website yang Pernah dikunjungi dan Tingkat Konversinya .....	44
<b>Gambar 3.1</b> Diagram Alur Penelitian.....	49
<b>Gambar 3.2</b> Alur Model Penelitian .....	53
<b>Gambar 3.3</b> Proses Expanding Term List.....	60
<b>Gambar 3.4</b> Proses Kategorisasi Aspect.....	64
<b>Gambar 3.5</b> Pre-Proses Klasifikasi Sentiment berdasarkan Aspect .....	69
<b>Gambar 3.6</b> Proses Klasifikasi Sentimen .....	71
<b>Gambar 3.7</b> Contoh data Klasifikasi Sentiment dengan Aspect “ <i>Location</i> ” Menggunakan “SC1” .....	73
<b>Gambar 4.1</b> Contoh data hasil <i>crawling</i> .....	79
<b>Gambar 4.2</b> Data <i>Text Review</i> Hotel .....	80
<b>Gambar 4.3</b> Contoh Perhitungan Manual TF-IDF.....	86
<b>Gambar 4.4</b> Ilustrasi Pembagian data <i>Training</i> dan <i>Testing</i> untuk Klasifikasi Sentiment .....	104
<b>Gambar 4.5</b> Ilustrasi Penerapan Model ke Setiap Kata Untuk Memperoleh <i>Corresponding Vector</i> .....	106
<b>Gambar 4.6</b> Grafik Pengujian Performa Kategorisasi Aspect.....	119
<b>Gambar 4.7</b> Grafik Pengujian Performa Klasifikasi Sentiment .....	128
<b>Gambar 4.8</b> Uji Chi-Square korelasi hubungan Aspect terhadap Sentiment ....	137
<b>Gambar 4.9</b> Grafik Hasil Evaluasi Sentimen pada Aspect Analisis Hotel.....	138

*[Halaman ini sengaja dikosongkan]*

# BAB 1

## PENDAHULUAN

Pada bab ini akan dijelaskan beberapa hal dasar dalam pembuatan penelitian Thesis ini yang meliputi: latar belakang, perumusan masalah, tujuan, manfaat, kontribusi penelitian, dan batasan masalah.

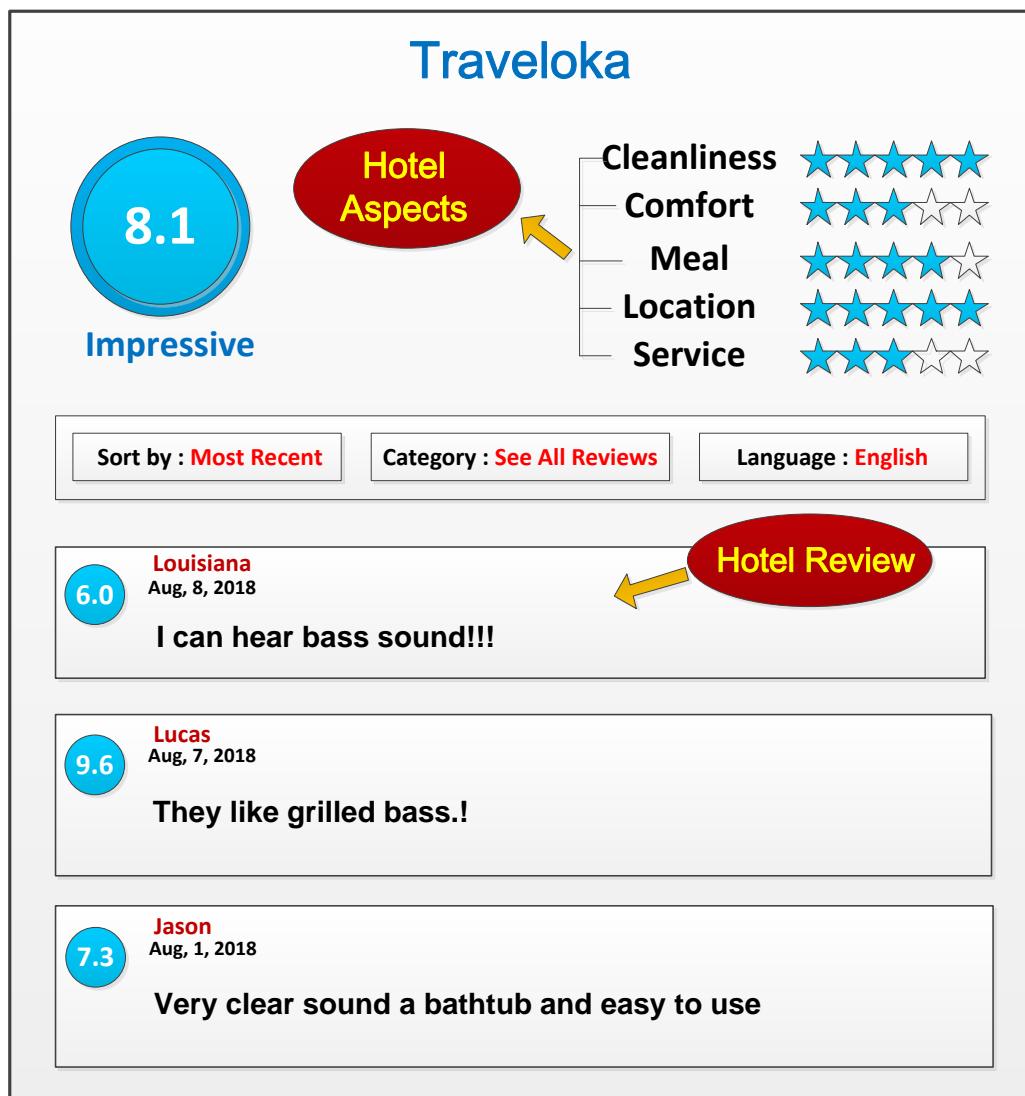
### 1.1. Latar Belakang

Semakin meningkatnya persaingan dalam dunia bisnis serta semakin luasnya jangkauan penjualan dalam sebuah perusahaan menjadikan sebuah kebutuhan penting bagi setiap perusahaan untuk memeriksa kembali, menyusun, menata dan memperbaiki semua aspect yang berkaitan dengan bisnis mereka sebagai upaya untuk mempertahankan atau meningkatkan kemampuan finansial perusahaan di pasar yang bergejolak. *Customer relationship management* (CRM) memiliki pengaruh yang sangat besar bagi kinerja perusahaan dan *Customer relationship management* (CRM) mampu meningkatkan kepuasan pelanggan (Haislip & Richardson, 2017). Kemampuan untuk meningkatkan pendapatan melalui hubungan pelanggan (*customer relationship*) yang dikelola secara efektif sangat penting untuk dimiliki oleh perusahaan agar perusahaan mampu mencapai tujuan yang telah ditentukan (Ghazian, Hossaini, & Farsijani, 2016).

Pada era ini, hubungan komunikasi antara pelanggan dengan perusahaan sangat mudah dilakukan, salah satunya adalah melalui *website* pada kolom komentar *review* pelanggan. Munculnya teknologi baru membawa cara baru untuk berbagi pengetahuan pribadi, opini dan pengalaman melalui media *online* (Hu & Chen, 2016). Komunikasi informal yang dilakukan oleh konsumen melalui teknologi berbasis internet yang terkait dengan penggunaan dan karakteristik produk atau layanan tertentu diakui sebagai saluran komunikasi paling berpengaruh antara penyedia layanan dan konsumen serta antar sesama konsumen itu sendiri ((Cantaloops & Salvi, 2014), (Schuckert, Law, & Xianwei, 2015), (Xiang, Uysal, & Schwartz, 2017) dan (Park, Choi, Kang, & Han, 2018)). Penelitian yang dilakukan oleh (Hu & Chen, 2016) dan (Ali & O' Brien, 2014) menemukan bahwa sekitar

89% dari *global travelers* dan 64% dari hoteliers global percaya bahwa ulasan hotel online berpengaruh terhadap pemesanan hotel. Survei yang dilakukan oleh (Ady & Felitti, 2015) mengungkapkan bahwa hampir 95% wisatawan membaca ulasan hotel *online* sebelum membuat keputusan pemesanan mereka, dan lebih dari sepertiga wisatawan percaya bahwa ulasan *online* adalah salah satu faktor paling penting untuk keputusan mereka tentang pemilihan hotel. Penelitian sebelumnya telah menunjukkan bahwa industri pariwisata sangat dipengaruhi oleh media sosial *online* ataupun *website* (Yacouel & Fleischer, 2012). Sedangkan *rating/peringkat online* dan umpan balik pelanggan dapat digunakan untuk membantu proses pengambilan keputusan pelanggan tetapi review memberikan wawasan yang lebih baik tentang hotel (Akhtar, Zubair, Kumar, & Ahmad, 2017). Sehingga, dapat disimpulkan bahwa meskipun rating atau peringkat online membantu, namun, review lebih membantu dalam pengambilan keputusan pelanggan serta dapat sangat membantu pihak manajemen hotel dalam mengambil langkah perbaikan.

Review pelanggan terhadap layanan dan produk hotel dapat menjadi salah satu faktor bagi manajemen hotel untuk melakukan evaluasi dan perbaikan serta merupakan faktor pemicu untuk memperbaiki kesalahan dan kekurangan terhadap produk ataupun pelayanan terhadap hotel (Geetha, Singha, & Sinha, 2017). Review Pelanggan yang ditulis dalam website akan menjadi data dengan jumlah yang besar dan tidak terstruktur, sehingga dapat dianalisis dengan teknik yang sesuai (Gandomi & Haider, 2015). Pengalaman pengguna dalam menilai hotel perlu untuk dianalisa lebih lanjut, sehingga informasi yang diberikan oleh pengguna dalam bentuk review produk dapat diolah untuk dijadikan masukan oleh manager bisnis (Liu, Jin, Ji, Harding, & Fung, 2013). Review dari *website* Traveloka dipilih sebagai aplikasi penyedia sumber data yang akan dianalisa. Website Traveloka dipilih karena merupakan salah satu situs web yang paling popular pada Negara ini dan berisi data utama tentang sebagian besar hotel. Gambar 1.1 berikut menunjukkan contoh review hotel yang akan dianalisa untuk melakukan evaluasi kepuasan pelanggan dari websites traveloka. Review yang akan diambil merupakan *review* dengan teks bahasa inggris.



**Gambar 1.1** Contoh Review Hotel pada Traveloka

Sehingga, Berdasarkan latar belakang yang telah dipaparkan pada paragraf diatas peneliti menyimpulkan bahwa website yang memiliki kolom komentar atau review akan sangat membantu perusahaan untuk mengetahui apa saja dari bisnis tersebut yang disenangi ataupun tidak disenangi oleh pelanggan mereka. Dari kolom komentar atau review tersebut, perusahaan dapat memperoleh informasi untuk melakukan rencana perubahan, menata kembali bisnisnya dan mungkin memperbaiki kesalahan mereka sebagai upaya mempertahankan hubungan dengan pelanggannya. Agar perusahaan mendapatkan informasi dengan jelas mengenai hal ini, penulis menyarankan pencarian *sentiment* kepuasan pelanggan sesuai dengan

kategori aspect hotel kemudian melakukan evaluasi. *Aspect* yang dimaksud terdiri dari: *location, meal, service, comfort* serta *cleanliness* hotel. *Aspect* hotel ini diambil dari websites Traveloka pada 5 macam data rating dan review yang biasanya dikeluhkan ataupun disenangi oleh pelanggan hotel.

Dalam tesis ini, tahap pertama yang dilakukan adalah menentukan aspect yang akan direview. Akan ada 5 macam aspect yang direview, yakni: *location, meal, service, comfort* serta *cleanliness* hotel. Penelitian ini akan mengambil teks review dalam bahasa Inggris. Kemudian, Penulis melakukan percobaan untuk mencari performa terbaik dalam pengkategorian *aspect* dengan menggunakan beberapa cara yakni: menggabungkan *Latent Dirichelet Allocation* (LDA) dengan *Semantic Similarity* menggunakan data *term list* yang telah ditentukan pada tabel *keyword term* yang terdiri dari campuran *term* yang ditemukan dari beberapa penelitian; menggabungkan *Latent Dirichelet Allocation* (LDA) dengan *semantic similarity* dengan menggunakan data term list “Tabel 2.1” ditambah dengan *Term Frequency-Inverse Cluster Frequency* (TF-ICF) 20%; dan menggabungkan *Latent Dirichelet Allocation* (LDA) dengan *semantic similarity* dengan menggunakan data term list “Tabel 2.1” ditambah dengan *Term Frequency-Inverse Cluster Frequency* (TF-ICF) 100% atau yang telah dituliskan pada “Tabel 3.3 Tabel Keyword Term List + Hasil TF-ICF terkait Aspect”.

*Latent Dirichelet Allocation* (LDA) merupakan salah satu metode topic modelling yang mampu memetakan hidden topic dari suatu dokumen. *Hidden topic* ini merupakan kata-kata penting atau kata-kata yang sering muncul dalam korpus yang dihitung berdasarkan probabilitas kedekatan *topic-dokumen* dan *word-topic* (Fu, et al., 2015), (Heng, Gao, Jiang, & Chen, 2018) dan (Chen, Yao, & Yang, 2017). Metode *Latent Dirichlet Allocation* (LDA) pada penelitian ini digunakan untuk menemukan *hidden topic* sesuai fungsi dari LDA sendiri untuk kemudian dari *hidden topic* tersebut dilakukan klasifikasi terhadap 5 *aspect* hotel yang telah ditentukan. Pencarian *hidden topic* ini dilakukan agar penelitian dapat lebih efektif dalam melakukan analisa kata. *Latent Dirichlet Allocation* (LDA) memiliki kekurangan untuk mengklasifikasikan dokumen ke dalam salah satu kategori secara langsung (Miller, Savova, & Dligach, 2016). Tidak hanya itu, *Latent Dirichlet Allocation* (LDA) tidak memanfaatkan informasi mengenai distribusi dari kata

yang ada (Zhai, Liu, Xu, & Jia, 2011 ). Sedangkan, dalam beberapa kondisi, hasil dari *Latent Dirichlet Allocation* (LDA) perlu untuk digeneralisasi menjadi aspect tertentu yang telah didefinisikan sebelumnya. Oleh karena itu, dalam pengembangannya, *Latent Dirichlet Allocation* (LDA) perlu menambahkan informasi mengenai domain tertentu untuk meningkatkan perfomanya (Priyantina & Sarno, 2019) dan (Wu & Chien, 2010). Sehingga penelitian ini mengusulkan metode yang menggabungkan *Latent Dirichlet Allocation* (LDA) (untuk menemukan hidden topic) dengan *Semantic Similarity* untuk meng-mengkategorikan dokumen kedalam 5 *aspect* hotel yang telah ditentukan sebelumnya kemudian didapatkanlah label dari setiap *review* berdasarkan *aspect*. Metode *Semantic Similarity* merupakan metode pengukuran yang mendefinisikan setiap dokumen atau *term* yang memiliki jarak diantaranya berdasarkan atas makna atau arti secara *semantic* (Soler, Tence, Gaubert, & Buche, 2013) dan (Tsai, Lin, Hu, & Yao, 2019). Adapun perluasan *term list* pada saat pengukuran *similarity* menggunakan metode *Term Frequency-Inverse Cluster Frequency* (TF-ICF). TF-ICF ini digunakan untuk memunculkan term-term yang berpengaruh pada setiap klaster *aspect*.

Setelah diketahui *aspect* dari setiap review, kemudian penulis melakukan percobaan untuk mencari performa terbaik pada klasifikasi sentiment dalam penelitian ini dilakukan dengan: melakukan klasifikasi sentiment dengan menggunakan *Word Embedding + Long Short Term Memmory* (LSTM); klasifikasi sentiment dengan menggunakan Sentiwordnet; dan klasifikasi sentiment dengan menggunakan *Long Short Term Memmory* (LSTM). *Word Embedding* digunakan untuk mengekstrak dokumen dan label menjadi *word vector* yang kemudian akan digunakan sebagai input untuk proses klasifikasi terhadap *sentiment* pelanggan (puas atau tidak puas) menggunakan metode *Long Short Term Memmory* (LSTM). *Long Short Term Memmory* (LSTM) merupakan metode yang popular untuk klasifikasi sentiment karena *Long Short Term Memmory* (LSTM), berdasarkan namanya, mampu menyimpan term dengan jangka yang panjang pada memory-nya sehingga *Long Short Term Memmory* (LSTM) dapat digunakan untuk memodelkan keterhubungan antara term bahkan yang memiliki interval yang jauh. *Long Short Term Memmory* (LSTM) mampu mengontrol beberapa operasi seperti baca, tulis

dan *reset* dari *input* yang diberikan maupun *output* dari keadaan sebelumnya. *Long Short Term Memmory* (LSTM) memiliki sebuah “*Forget Gate*” yang berfungsi untuk memutuskan informasi mana yang akan disimpan maupun yang akan dibuang untuk kemudian memperbaharui sel memory-nya. (Rao, Huang, Feng, & Cong, 2018) dan (Do, Prasad, Maag, & Alsadoon, 2019). Penggabungan *Word Embedding* + *Long Short Term Memmory* (LSTM) ini mampu mendorong penelitian ini agar mampu mengklasifikasi *review* sesuai dengan kategori-kategori analisa.

Penulis kemudian akan menerapkan metode yang memiliki performa terbaik dari kategorisasi aspect dan klasifikasi sentiment. Sehingga, tujuan dari penelitian ini adalah mencari performa terbaik pada setiap metode analisis untuk diterapkan, serta melakukan analisa dan evaluasi terhadap review pelanggan untuk mengetahui hal apa dari bisnis hotel tersebut yang membuat pelanggan puas maupun tidak puas yang didasarkan kepada 5 aspect hotel. Hal ini diharapkan akan membantu perusahaan agar mampu menyusun rencana perubahan, menata kembali bisnisnya dan mungkin memperbaiki kesalahan mereka.

Hasil dari penelitian ini adalah untuk mengetahui performa metode terbaik yang dapat digunakan untuk melakukan kategorisasi aspect maupun klasifikasi sentiment. Kemudian melakukan analisa kepuasan terhadap 5 aspect hotel yang direview. Performa hasil akan dievaluasi dengan menggunakan *precision*, *recall* dan *F1-Measure*. Dari hasil uji coba didapatkan performa metode kategorisasi aspect sangat tinggi dengan melakukan penggabungan *Latent Dirichlet Allocation* (LDA), *Term Frequency-Inverse Cluster Frequency* (TF-ICF), dan *Semantic Similarity* yakni mencapai 85%, performa klasifikasi *sentiment* tertinggi dengan menggunakan *Word Embedding* + *Long Short Term Memmory* (LSTM) mencapai 94%. Kemudian peneliti juga mendapatkan bahwa pada *aspect comfort* memiliki sentimen yang tinggi pada sisi negatif yakni mencapai 11,369% dibanding dengan *sentiment* pada *aspect* lainnya sehingga perlu dilakukan perbaikan-perbaikan untuk meningkatkan hal tersebut. Hasil juga menunjukkan bahwa sentimen dipengaruhi oleh suatu aspect.

## **1.2. Perumusan Masalah**

Berdasarkan latar belakang yang telah dipaparkan pada paragraf sebelumnya maka penulis merumuskan masalah dalam penelitian ini yaitu sebagai berikut :

1. Bagaimana mencari performa terbaik dalam mengkategorikan setiap data review pada 5 *aspect* hotel (*location, meal, service, comfort* serta *cleanliness*) kemudian melakukan klasifikasi sentiment?
2. Bagaimana mencari performa terbaik dari klasifikasi sentiment?
3. Bagaimana melakukan evaluasi review mengenai kepuasan pelanggan terhadap 5 aspect hotel pada review pelanggan?

## **1.3. Tujuan**

Tujuan dari penelitian ini adalah sebagai berikut:

1. Mencari performa terbaik untuk kategorisasi aspect yang dilakukan dengan beberapa percobaan yakni menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk pencarian hidden topic, *Term Frequency-Inverse Cluster Frequency* (TF-ICF) untuk perluasan *term list* dan *Semantic Similarity* untuk mengkategorikan setiap review pada 5 *aspect* hotel (*location, meal, service, comfort* serta *cleanliness*).
2. Mencari performa terbaik untuk klasifikasi sentiment yang dilakukan dengan beberapa percobaan yakni menggunakan *Word Embedding* untuk representasi vector kata dan *Long Short Term Memory* (LSTM) sebagai metode klasifikasi, serta dilakukan percobaan dengan menggunakan metode SentiWordNet. Klasifikasi sentiment dilakukan dengan menggunakan hasil dari kategorisasi aspect. Hasil dari klasifikasi sentiment adalah *sentiment positive* atau *negative* pada setiap review.
3. Melakukan evaluasi terhadap setiap *review* untuk melihat hal apa dari bisnis yang membuat pelanggan puas maupun tidak puas yang didasarkan kepada 5 *aspect* hotel agar perusahaan mampu menyusun rencana perubahan, menata kembali bisnisnya dan mungkin memperbaiki kesalahan mereka.

## **1.4. Manfaat**

Penelitian ini diharapkan dapat menghasilkan system untuk menganalisa kepuasan dan ketidakpuasan pelanggan terhadap 5 aspect (*location, meal, service, comfort* serta *cleanliness*) hotel.

## **1.5. Kontribusi Penelitian**

Kontribusi yang diharapkan dari penelitian ini adalah pencarian performa terbaik untuk melakukan kategorisasi aspect dan klasifikasi sentiment. Analisa *sentiment* dari review pelanggan terhadap *aspect* hotel dilakukan untuk membantu manajer bisnis melakukan perbaikan layanan dalam tujuan untuk meningkatkan kepuasan pelanggan. Sebelum mengkategorisasikan setiap review terhadap 5 *aspect* hotel, peneliti melakukan *crawling* data review pelanggan pada website. Kemudian peneliti melakukan *preprosesing* agar data lebih mudah untuk diolah menggunakan tokenization, stemming, stopwords removal, convert into lowercase, remove punctuation dan spelling correction.

Penelitian ini dilakukan untuk mencari performa kategorisasi aspect terbaik dengan menggabungkan metode *Latent Dirichlet Allocation* (LDA) dengan *semantic similarity* menggunakan data term list yang telah terlebih dahulu diidentifikasi dan dituliskan pada “Tabel 2.1”; menggabungkan *Latent Dirichlet Allocation* (LDA) dengan *semantic similarity* dengan menggunakan data *term list* “Tabel 2.1” ditambah dengan data *term list* yang ditemukan dengan menggunakan *Term Frequency-Inverse Cluster Frequency* (TF-ICF) 20%; dan menggabungkan *Latent Dirichlet Allocation* (LDA) dengan semantic similarity dengan menggunakan data term list “Tabel 2.1” ditambah dengan data *term list* yang ditemukan dengan menggunakan *Term Frequency-Inverse Cluster Frequency* (TF-ICF) 100% atau yang telah dituliskan pada “Tabel 3.3”. *Latent Dirichlet Allocation* (LDA) dipilih karena merupakan salah satu metode *topic modelling* yang mampu memetakan hidden topik dari suatu dokumen. Namun, *Latent Dirichlet Allocation* (LDA) memiliki kekurangan dalam mengkategorikan dokumen ke dalam salah satu tipe dari kategori klasifikasi secara langsung. Sehingga penelitian ini mengusulkan metode yang menggabungkan *Latent Dirichlet Allocation* (LDA) (untuk menemukan *hidden topic*) dengan *semantic similarity* untuk meng-kategorisasikan

dokumen kedalam 5 *aspect* hotel (*location, meal, service, comfort* serta *cleanliness*). *Term list* untuk melakukan *similarity* ditentukan terlebih dahulu pada “Tabel 2.1 *Keyword Term List* Terkait Aspect yang Diperoleh”. Kemudian, dilakukan perluasan *term list* pada saat pengukuran *similarity* dilakukan dengan menggunakan metode *Term Frequency-Inverse Cluster Frequency* (TF-ICF). *Term Frequency-Inverse Cluster Frequency* (TF-ICF) yang diterapkan ini bertujuan untuk mencari term-term penting yang dihitung berdasarkan frekuensi kemunculannya pada setiap cluster yang diperiksa (atau dalam hal ini berarti setiap aspect yang diteliti) sehingga diharapkan dengan penerapan TF-ICF ini didapatkan *term list* penting pada setiap aspect. Hasil dari performa setiap uji coba akan dianalisa dan dipilih yang terbaik untuk diaplikasikan.

Kemudian, digunakan metode *Word Embedding* untuk mengekstrak dokumen dan label menjadi word vector yang kemudian akan digunakan sebagai input untuk proses klasifikasi terhadap *sentiment* pelanggan (puas atau tidak puas) menggunakan metode *Long Short Term Memmory* (LSTM). *Long Short Term Memmory* (LSTM) merupakan metode yang popular untuk klasifikasi sentiment karena *Long Short Term Memmory* (LSTM), berdasarkan namanya, mampu menyimpan term dengan jangka yang panjang pada memory-nya sehingga *Long Short Term Memmory* (LSTM) dapat digunakan untuk memodelkan keterhubungan antara term bahkan yang memiliki interval yang jauh. Hal ini membuat metode ini sukses diterapkan pada berbagai sektor, diantaranya pemodelan bahasa, pengenalan suara, dan pemahaman bahasa yang diucapkan. Analisa *sentiment* dalam penelitian ini akan membandingkan antara klasifikasi sentiment dengan menggunakan *Word Embedding + Long Short Term Memmory* (LSTM); klasifikasi sentiment dengan menggunakan Sentiwordnet; dan klasifikasi sentiment dengan menggunakan *Long Short Term Memmory* (LSTM). Performa uji coba terbaik untuk analisa *sentiment* akan diaplikasikan.

*Output* dari kedua proses ini (Kategorisasi Aspect dan Klasifikasi Sentiment) akan menghasilkan evaluasi untuk mengetahui kepuasan dan ketidakpuasan pelanggan terhadap aspect *location, meal, service, comfort* serta *cleanliness* pada review hotel. Dalam hasil ditemukan juga bahwa sentimen dipengaruhi oleh suatu aspect.

## **1.6. Batasan Masalah**

Untuk memfokuskan permasalahan penelitian ini, batasan masalah yang ditentukan adalah sebagai berikut:

1. Review diambil dengan cara crawling pada ulasan pada hotel Manhattan, New York.
2. Dataset review yang dianalisa menggunakan bahasa Inggris.
3. Klasifikasi sentiment ditinjau dari 5 kategori aspect (location, meal, service, comfort serta cleanliness) hotel.
4. Preprosesing dilakukan dengan menggunakan tokenization, stemming, stopwords removal, convert into lowercase, remove punctuation dan spelling correction.
5. Peneliti menggunakan metode LDA dengan semantic similarity dan TF-IDF untuk melakukan Kategorisasi Aspect dokumen.
6. Peneliti menggunakan Word Embedding + LSTM untuk melakukan Klasifikasi Sentiment terhadap kepuasan pelanggan.
7. Hasil dari penelitian ini adalah untuk menemukan performa metode terbaik untuk Kategorisasi Aspect dan Klasifikasi Sentiment kemudian melakukan evaluasi terhadap kepuasan dan ketidakpuasan pelanggan terhadap aspect location, meal, service, comfort serta cleanliness hotel.
8. Data yang diambil adalah data review hotel pada tahun 2015-2018.
9. WordNet yang digunakan adalah Synonim Set WordNet.

## **1.7. Sistematika Penulisan**

Berikut ini adalah sistematika penulisan yang akan diterapkan pada proses penelitian ini :

### **Bab I Pendahuluan**

Bab ini menyajikan tentang latar belakang, rumusan masalah, tujuan, manfaat, batasan masalah, kontribusi penelitian, dan sistematika penulisan.

### **Bab II Kajian Pustaka**

Dalam bab ini terdapat sub bab dan landasan teori dari penelitian terdahulu yang memaparkan teori-teori yang berhubungan dengan masalah yang

diteliti serta beberapa penelitian yang telah dilakukan pada penelitian-penelitian sebelumnya.

### **Bab III Metode Penelitian**

Bab ini menguraikan deskripsi tentang bagaimana penelitian nantinya akan dilakukan dan menjelaskan variabel penelitian, definisi operasional, penentuan jenis sampel, jenis dan sumber data, jalannya penelitian dan alur penelitian.

### **Bab IV Hasil Penelitian dan Pembahasan**

Bab ini menjelaskan tentang pengumpulan data dan pengolahan data serta menguraikan tentang deskripsi objek penelitian melalui gambaran umum dan proses pengintegrasian data yang diperoleh untuk mencari makna dari hasil analisa.

### **Bab V Kesimpulan dan Saran**

Bab ini menyajikan kesimpulan dan saran yang didapatkan dari pembahasan pada hasil penelitian.

*[Halaman ini sengaja dikosongkan]*

## **BAB 2**

### **KAJIAN PUSTAKA**

Pada bab ini akan dijelaskan tentang pustaka yang terkait dengan landasan penelitian.

#### **2.1. Customer Relationship Management (CRM)**

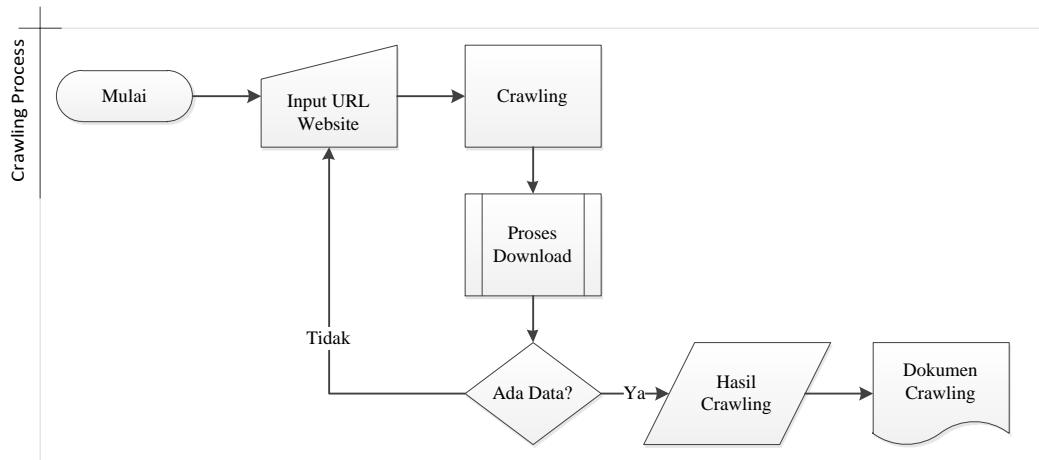
Dalam beberapa tahun terakhir, CRM telah tumbuh dalam relevansi baik dalam operasional dan sudut pandang strategis. Dua alasan utama untuk ini adalah peningkatan daya saing pasar dan biaya yang lebih rendah untuk mempertahankan klien daripada perekrutan klien baru (Petrick, 2004) dan (Yoo & Bai, 2013). Oleh karena itu, CRM telah menjadi strategi utama untuk mempersonalisasikan pengalaman klien dan untuk meningkatkan kepuasan mereka.

Sistem CRM adalah "alat perusahaan yang berbasis teknologi untuk mengembangkan dan memanfaatkan pengetahuan konsumen untuk memelihara, memelihara, dan memperkuat hubungan menguntungkan dengan konsumen" (Elfving & Lemoine, 2012). Soltani dan Navimipour (Soltani & Navimipour, 2016) menyatakan bahwa sistem CRM menyediakan infrastruktur yang memfasilitasi pembangunan hubungan jangka panjang dengan pelanggan. Beberapa contoh fungsionalitas sistem CRM adalah otomatisasi tenaga penjualan, pergudangan data, penambangan data, dukungan keputusan, dan alat pelaporan (Ballesteros, Serrano, Ruiz, Romero, & Rojo-Álvarez, 2018).

#### **2.2. Pengumpulan Data**

Data ulasan pelanggan *online*, diambil dengan metode *crawling* menggunakan *software* WebHarvy. *Software* WebHarvy, mengumpulkan data dari situs pemesanan hotel Traveloka. Website Traveloka, adalah media *online* yang digunakan oleh pelanggan untuk mencari hotel berdasarkan harga, popularitas, *review*, dan kelas hotel (Gössling & Lane, 2015). Alasan memilih website Traveloka sebagai sumber data yang ideal, karena website traveloka merupakan salah satu situs web yang paling popular pada Negara ini dan berisi data utama

tentang sebagian besar hotel. Proses *crawling* yang menggunakan *software* WebHarvy akan dijelaskan pada gambar 2.1.



**Gambar 2.1** Proses *Crawling* dengan Software WebHarvy

Hasil dari *crawling* data akan diolah menggunakan proses *preprocessing* yang akan dibahas pada 2.5 Pengolahan Bahasa Manusia.

### 2.3. Keyword Term List untuk Aspect Hotel

Pada penelitian ini, akan ada 5 macam aspect yang direview yakni: *location*, *meal*, *service*, *comfort* serta *cleanliness* hotel, dimana aspect ini diambil dari kelima data *rating review* pada aplikasi traveloka. Selain kelima aspect tersebut, peneliti juga mereview mengenai kepuasan maupun ketidak-puasan pelanggan.

Setelah melakukan penentuan aspect yang akan direview, langkah selanjutnya adalah mengklasifikasikan *review* pelanggan ke dalam beberapa aspect yang telah ditentukan. Beberapa kata kunci yang sering muncul dalam *text review* hotel pada setiap aspect di definisikan oleh (Akhtar, Zubair, Kumar, & Ahmad, 2017) digabungkan dengan data dari (Chen & Chen, 2015) sebagai berikut:

**Tabel 2.1:** *Keyword Term List* Terkait Aspect yang Diperoleh

<b>Aspect</b>	<b>Term terkait Aspect yang Diperoleh</b>
<b>Cleanliness</b>	ventilation, cleanliness, smell, cobweb, smoke, carpet, laundry, furniture, wall, housekeeping, toilet, air conditioner, elevator, hall, air, stair, noise, neighbor, complaint, heat
<b>Comfort</b>	connection, meeting, charge, activity, sleep, bed, bedroom, pillow, sofa, suite, living room, towel, unit, chair, lobby, experience, space, comfort, feel.
<b>Service</b>	facility, wifi, pool, gym, business, internet, desk, reliable, fast, convenient, check-in, check-out, good, staff, polite, helpful, friendly, reliable, quick, parking, conference room, fee
<b>Food</b>	cafe, drink, breakfast, spicy, meal, bagel, tea, buffet, bar, waffle, restaurant, dinner, lunch, brunch, delicious, food, dish, wine, salad, coffee, pastry, menu, item, cup
<b>Location</b>	railway, view, station, airport, distance, far, close, train, metro, location, place, distance, station, shopping, bus, ride, mall, bus stop, downtown, park, theater, district, museum, transportation, heart, middle

#### 2.4. Pembangunan Dataset Training dan Testing

Memisahkan data kedalam dataset pelatihan dan pengujian merupakan bagian yang penting dari evaluasi model data mining. Biasanya, untuk memisahkan satu set data ke dalam set pelatihan dan set pengujian, sebagian besar data akan digunakan untuk pelatihan, dan sebagian kecil dari data digunakan untuk pengujian (Duncan, Hu, Guyer, & Rabeler, 2018). Dengan menggunakan data yang serupa untuk pelatihan dan pengujian, dapat diminimalkan efek ketidaksesuaian data dan lebih memahami karakteristik model. Setelah model diproses dengan menggunakan set pelatihan, kemudian menguji model dengan membuat prediksi terhadap set tes. Karena data dalam set pengujian sudah berisi nilai yang diketahui untuk atribut yang ingin diprediksi, mudah untuk menentukan apakah tebakan model itu benar.

Secara default, Data Mining akan membagi data menjadi dua set: satu dataset dengan 70 persen dari sumber data, untuk model pelatihan, dan satu dengan 30 persen dari sumber data, untuk model pengujian. Default ini dipilih karena rasio 70-30 sering digunakan dalam data mining, tetapi dengan Layanan Analisis Anda dapat mengubah rasio ini sesuai dengan kebutuhan Anda (Duncan, Hu, Guyer, & Rabeler, 2018). Menurut (Allison, 2013), pembagian data terbaik adalah 80/20 dimana 80% dari data training dan 20% dari data testing.

## 2.5. Pengolahan Bahasa Manusia

Pemrosesan bahasa alami merupakan teknik untuk mengajarkan komputer dalam memahami maksud dari kata-kata yang digunakan oleh manusia. Metode ini lah yang kemudian diadaptasi oleh bidang Rekaya Perangkat Lunak salah satu nya dalam memproses kategori perubahan dari suatu produk perangkat lunak.

### 2.5.1 *Pre Processing*

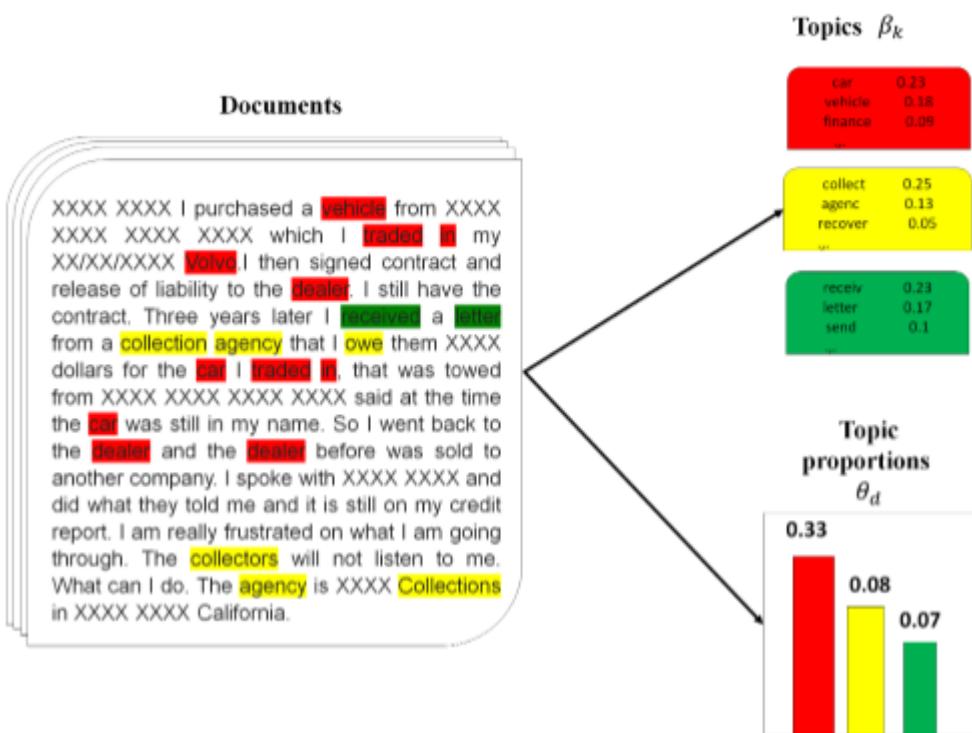
Salah satu teknik pemrosesan bahasa alami yang kerap digunakan pada pra proses adalah teknik-teknik berikut, yaitu:

**Tabel 2.2:** Pre-Processing Data

Nama Proses	Keterangan
Convert into lowercase	Merubah semua huruf menjadi huruf kecil
Spelling Correction	Proses ini memiliki fungsi untuk menyempurnakan kalimat yang memiliki kesalahan dalam penulisan.
Remove Punctuation	Menghilangkan tanda baca pada kalimat
Stopwords Removal	Stopwords Removal memiliki peran untuk menghapus kata henti dalam bahasa inggris.
Tokenisasi	Pada tahap ini, input teks dokumen dipecah menjadi unit atomis terkecil. Biasanya unit tersebut berupa kata-kata atau kalimat atau paragraf.
Stemming	Stemming memiliki peran untuk menjadikan teks menjadi kata dasar.

### 2.5.2 Latent Dirichlet Allocation (LDA)

LDA merupakan *Unsupervised Generative Model* yang mengkategorikan kata-kata yang muncul dalam dokumen ke dalam kelompok yang biasanya disebut sebagai topic (Fu, et al., 2015). Ide dasar dari *Latent Dirichlet Allocation* (LDA) yaitu bahwa dokumen terdiri dari beberapa *latent topic* dimana setiap topic terdiri dari distribusi kata-kata. Kepentingan relatif dari topik ditangkap dalam bentuk bobot yang berbeda dan bervariasi dari satu dokumen ke dokumen lainnya. Ilustrasi dari *Latent Dirichlet Allocation* (LDA) dapat dilihat pada gambar 2.2 berikut.



**Gambar 2.2** Ilustrasi *Latent Dirichlet Allocation* (LDA)

Sumber gambar: (Bastani, Namavari, & Shaffer, 2019)

*Latent Dirichlet Allocation* (LDA) ( (Baskara, Sarno, & Solichah, 2016) dan (Hagen, 2018)) merupakan model yang mampu memetakan *hidden topic* dari kata yang muncul pada korpus dari setiap dokumen. *Hidden topic* ini merupakan kata-kata penting atau kata-kata yang sering muncul dalam korpus yang dihitung berdasarkan probabilitas kedekatan *topic-dokumen* dan *word-topic*.

Menurut ( (Blei , Ng , & Jordan , 2003) dan (Fu, et al., 2015)), LDA didefinisikan sebagai berikut:

$$p(w, z / \alpha, \beta) = p(w / z, \beta) p(z / \alpha). \quad (2.1)$$

Parameter  $\alpha$  dan  $\beta$  merupakan model dari parameter, w adalah kata, dan z adalah topik,  $p(z / \alpha)$  adalah probabilitas dari topik z yang terdapat di dokumen d, dan  $p(w / z, \beta)$  adalah probabilitas huruf w ada di topik z. Namun komputasi dengan menggunakan persamaan 2.1 cukup sulit untuk dikendalikan. Sehingga Griffiths menggunakan perkiraan persamaan sebagai berikut:

$$p(z_i = k / z_{-i}, w) \propto \frac{n_{-i,k}^{w_i} + \beta}{n_{-i,k} + W\beta} \cdot \frac{n_{-i,k}^{d_i} + \alpha}{n_{-i}^{d_i} + T\alpha} \quad (2.2)$$

Pada persamaan 2.2,  $n_{-i}^{(.)}$  merupakan jumlah dari topik  $z_i$ ,  $n_{-i,k}^{w_i} + \beta$  adalah jumlah topik z yang berhubungan dengan huruf  $w_i$ ,  $n_{-i,k}^{d_i} + \alpha$  adalah jumlah topik z yang berhubungan dengan dokumen  $d_i$ , W adalah jumlah huruf berbeda yang dilakukan pre proses, dan T adalah jumlah topik.

### 2.5.3 Semantic Similarity

*Semantic similarity* merupakan metode pengukuran yang mendefinisikan setiap dokumen atau term yang memiliki jarak diantaranya berdasarkan atas makna atau arti secara *semantic* (Soler, Tence, Gaubert, & Buche, 2013) dan (Tsai, Lin, Hu, & Yao, 2019). Terdapat dua jenis perhitungan similaritas, yaitu berdasarkan sumber daya yang telah ada, seperti thesaurus dan berdasarkan pada penyebaran kata pada suatu corpus (Iosif & Potamianos, 2013).

$$\text{Similarity}(w_i, w_j) = \frac{\sum_{m=1}^K w_i^m w_j^m}{\sqrt{\sum_{m=1}^K (w_i^m)^2} \sqrt{\sum_{m=1}^K (w_j^m)^2}} \quad (2.3)$$

Dimana *similarity distance* mengukur jarak kedekatan antara word1 ( $w_i$ ) dan word2 ( $w_j$ ).  $\sum_{m=1}^K$  = jumlah iterasi m hingga K word. Nilai maksimal dari jarak similariti adalah 1 yang berarti benar-benar sama, dan nilai minimal adalah -1 yang berarti benar-benar berbeda. Nilai dari similarity akan berada dalam range 0 dan 1

karena term frequency (pembobotan tf-idf) tidak memungkinkan menghasilkan nilai -1. Kakas bantu yang digunakan untuk melakukan *expand term* dan mengkategorisasikan setiap dokumen adalah WordNet *similarity*

#### 2.5.4 Term Frequency-Inverse Cluster Frequency (TF-ICF)

*Term Frequency-Inverse Cluster Frequency* (TF-ICF) (Suadaa & Purwarianti, 2016) merupakan salah satu pembobotan term berdasarkan informasi dari dokumen-dokumen pada suatu klaster. Hal tersebut membuat metode ini mampu mengetahui informasi mengenai nilai dari suatu term. Secara umum *Term Frequency-Inverse Cluster Frequency* (TF-ICF) melihat frekuensi term terhadap klaster dengan menggunakan persamaan 2.4 dimana nilai ICF pada *term i* dipengaruhi oleh jumlah *cluster* yang ada dan jumlah *cluster* yang mengandung *term i* (cfi).

$$ICF_i = 1 + \log \frac{c}{cf_i} \quad (2.4)$$

Sedangkan setiap *term i* pada setiap klaster akan dihitung nilai bobot *Term Frequency-Inverse Cluster Frequency* (TF-ICF) nya dengan menggunakan persamaan 2.5, dimana  $tf_{ji}$  adalah frekuensi atau total term i pada cluster j dan  $ICF_i$  adalah nilai icf term tersebut.

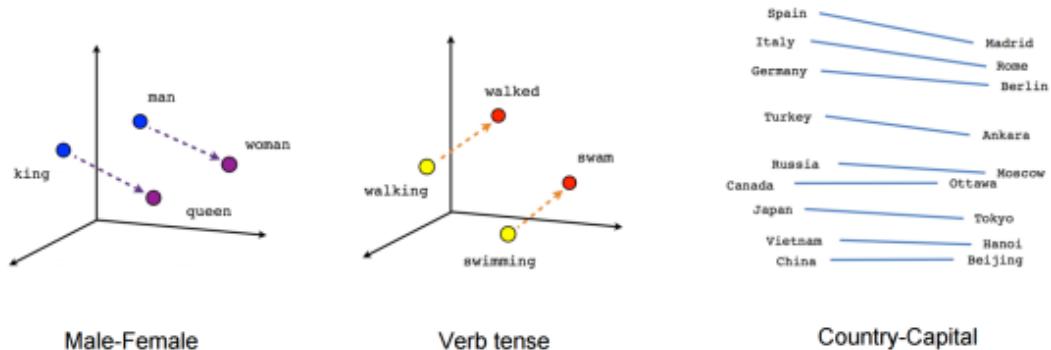
$$TF - ICF_j = tf_{ji} \times ICF_i \quad (2.5)$$

#### 2.5.5 Word Embedding

*Word embedding* merupakan kumpulan nama dari pemodelan bahasa dan teknik ekstraksi fitur pada *Natural Language Processing* (NLP) dimana setiap kata atau phrasa dari suatu kosakata akan dipetakan menjadi vektor yang berupa bilangan *real*. Vector ini menetapkan kemungkinan bahwa sebuah kata akan muncul dalam matriks kata tertentu dengan kata-kata yang terkait. Sehingga, dapat disimpulkan bahwa model ini mencari kata yang mungkin berkaitan dengan kata sebelumnya kemudian memasukkan informasi ke dalam jaringan untuk memprediksi kata selanjutnya (Do, Prasad, Maag, & Alsadoon, 2019).

*Word embedding* kerap digunakan dalam *neural networks*, reduksi dimensi pada matriks kemunculan kata, model probabilistik, dll. Metode *word embedding*

ini juga digunakan sebagai input untuk meningkatkan performa pada pengolahan bahasa manusia seperti parsing sintaktik dan analisa sentimen.



**Gambar 2.3** Contoh *Word Embedding*

(Mikolov, Chen, Sutskever, & Corrado, 2013) mengusulkan dua model *log-linear* untuk menghitung *word embeddings* dari suatu dataset secara efisien, yaitu *bag-of-words* dan *skip gram*. *Continous bag-of-words* (CBOW) model memprediksi kata saat ini berdasarkan konteks kata. Sedangkan *skip-gram* memprediksi kata-kata yang berada disekitar kata yang diberikan sesuai dengan kedekatan antara masing-masing vektor kata, seperti yang terlihat pada Gambar 2.2. Saat ini, terdapat banyak ringkasan dari *word embedding* yang dapat digunakan secara publik, beberapa diantaranya dijelaskan pada tabel 2.3

**Tabel 2.3:** Detail dari *embedding* yang tersedia secara luas

Embeddings	Senna	GloVe	Word2Vec
Training Corpus	Wikipedia	Wikipedia/Gigaword	Google News
Dimensionality	50	50	300
Size of Vocab.	130.000	400.000	3.000.000

Senna (*Semantic/Syntactic extraction using a neural network architecture*) merupakan pengembangan Collobert. *Word embedding* ini telah dilatih melalui Wikipedia selama dua bulan. Senna juga dapat digunakan sebagai bagian dari *part-of-speech* (POS) *tags*, *name entity recognition* (NER), *semantic role labelling* (SLR), dan *syntactic parsing* (PSG).

GloVe (*Global Vector*) dikembangkan oleh Pennington. *Word embedding* ini mengusulkan algoritma berbasis *unsupervised* untuk memperoleh representasi dari *word vector*. GloVe pada dasarnya merupakan metode *log-bilinear* dengan membobotan *least-squares* yang telah dilatih melalui enam miliar token *corpus* yang dikonstruksikan menggunakan Wikipedia2014 dan Gigaword5, dengan kosakata sebanyak 400.000 kata yang sering muncul.

Word2Vec merupakan perangkat yang menyediakan implementasi efisien dalam *continuous bag-of-words*. *Word embeddings* ini merupakan bagian dari *Google News dataset* yang mengandung 300 dimensi vektor untuk tiga juta kata dan frasa.

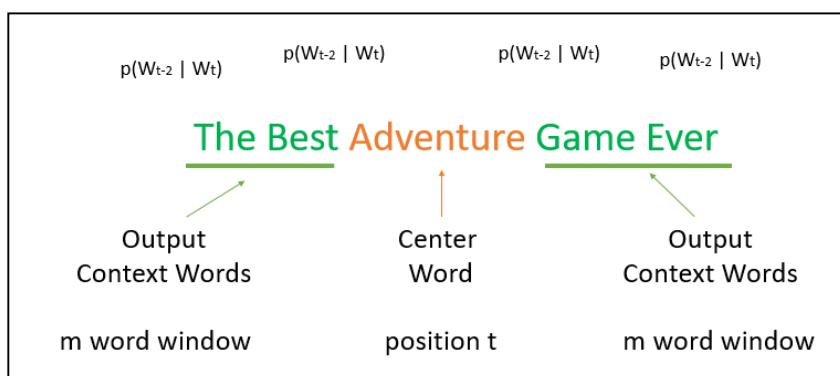
Proses penemuan nilai untuk masing-masing vektor diperoleh dari pembandingan antara suatu kata terhadap seluruh kata dengan menggunakan persamaan (2.6)

$$P(\text{context} / w_t) \quad (2.6)$$

Dengan nilai loss function pada persamaan (2.7)

$$J = 1 - p(w_{-t} / w_t) \quad (2.7)$$

Salah satu contoh penggunaannya ditunjukan pada Gambar



**Gambar 2.4** Contoh Word Embedding

Nilai dari  $p(w_{t+j} / w_t)$  didefinisikan dengan persamaan (2.8)

$$P(o | c) = \frac{\exp(u_o^T v_c)}{\sum_{w=1}^v \exp(u_w^T v_c)} \quad (2.1)$$

Dimana o adalah output dari indeks kata, c adalah pusat dari indeks kata,  $v_c$  dan  $u_o$  adalah nilai vektor “tengah” dan “luar” dari kata c dan o. Nilai *softmax* dengan menggunakan c untuk memperoleh nilai probability dari o. Nilai yang sama cenderung memiliki nilai vektor yang sama. Hasil yang muncul merupakan suatu kumpulan vektor-vektor untuk setiap jenis tipe kata. Hal ini membuat lebih mudah untuk memprediksi kata yang muncul sebagai *context words*.

Dalam penelitian ini, *Word Embeddings* yang akan digunakan adalah GloVe. Glove digunakan sebagai algoritma untuk mendapatkan konteks global. Jadi, GloVe memiliki akurasi yang baik untuk diterapkan, karena GloVe dapat memperkirakan dengan representasi kata dengan baik karena GloVe menerapkan fungsi perhitungan statistic pada representasi katanya (Rezaeinia, Rahmani, Ghodsi, & Veisi, 2019).

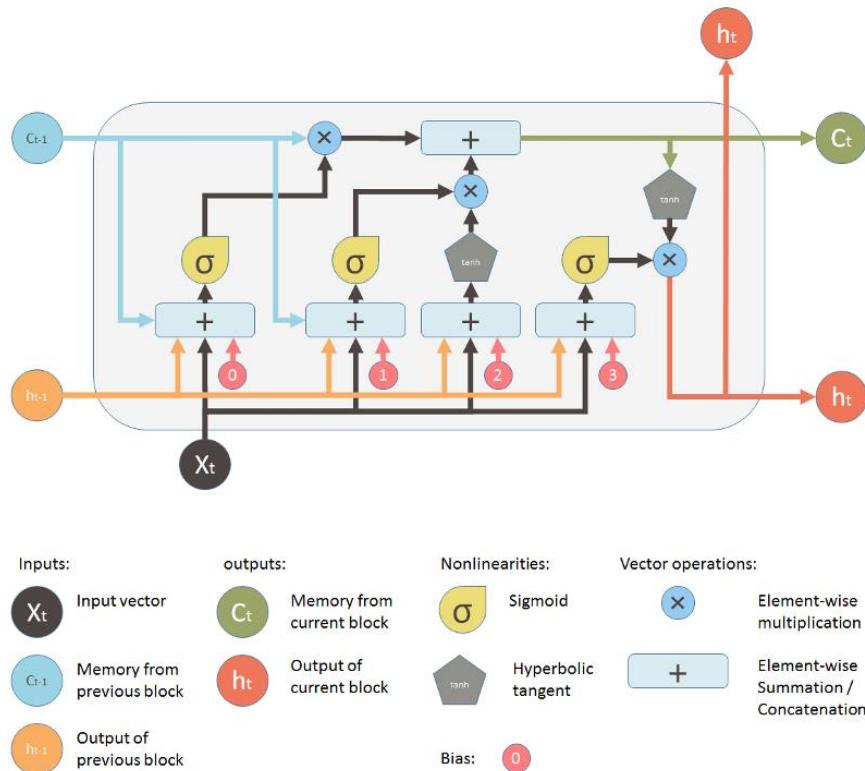
#### **2.5.6 Long Short Term Memory (LSTM)**

LSTM (Heikal, Torki, & El-Makky, 2018) adalah arsitektur *recurrent neural network* (RNN) yang didesain untuk memodelkan keterhubungan antara *term* yang memiliki interval yang jauh. *Long Short Term Memory* (LSTM) merupakan metode yang popular untuk klasifikasi sentiment karena LSTM, berdasarkan namanya, mampu menyimpan term dengan jangka yang panjang pada memory-nya sehingga LSTM dapat digunakan untuk memodelkan keterhubungan antara *term* bahkan yang memiliki interval yang jauh (Huang, Rao , Feng, & Cong, 2018). *Output* klasifikasi LSTM akan bergantung pada data *training* yang diberikan. LSTM memperluas memori dan mengambil kata-kata penting yang bahkan yang memiliki jeda waktu yang sangat lama (Jauh) di antaranya karena LSTM mengingat setiap input dalam jangka waktu yang lama.

Memori ini dapat dilihat sebagai sel yang terjaga keamanannya, di mana yang terjaga keamanannya berarti bahwa sel memutuskan apakah akan menyimpan atau menghapus informasi (mis. Apakah itu membuka gerbang atau tidak), berdasarkan

kepentingan yang diberikannya kepada informasi tersebut. Penentuan kepentingan terjadi melalui bobot, yang juga dipelajari oleh algoritma. Ini berarti bahwa LSTM belajar dari waktu ke waktu informasi mana yang penting dan mana yang tidak (Wang, Peng, & Zhang, 2018).

LSTM telah digunakan secara luas dalam pengolahan bahasa manusia seperti pada analisa sentimen, parsing sintaksis, kategorisasi dokumen yang memiliki ukuran yang panjang, dll (Huang, Rao , Feng, & Cong, 2018). Secara umum, arsitektur dari LSTM digambarkan pada Gambar 2.4



Gambar 2.5 Arsitektur LSTM

LSTM terdiri dari empat elemen yaitu *memory cell c*, *input gate i* untuk mengontrol arus *input* yang masuk ke dalam *neuron*, *output gate o* untuk mengontrol efek dari *aktivasi neuron* pada *neuron* lainnya, dan *forget gate f* yang membuat *neuron* berada dalam status *reset* dari statusnya saat ini. Secara umum, LSTM terdiri dari beberapa fungsi berikut:

$$i_t = \sigma(W^{(i)}x_t + U^{(i)}h_{t-1} + b^{(i)}) \quad (2.9)$$

$$o_t = \sigma(W^{(o)}x_t + U^{(o)}h_{t-1} + b^{(o)}) \quad (2.10)$$

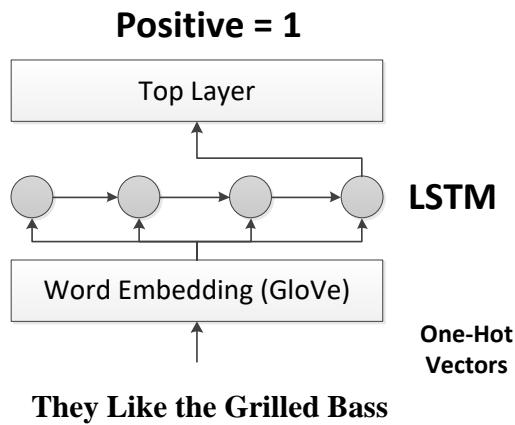
$$f_t = \sigma(W^{(f)}x_t + U^{(f)}h_{t-1} + b^{(f)}) \quad (2.11)$$

$$u_t = \tanh(W^{(u)}x_t + U^{(u)}h_{t-1} + b^{(u)}) \quad (2.12)$$

$$c_t = i_t \odot u_t + f_t \odot c_{t-1} \quad (2.13)$$

$$h_t = o_t \odot \tanh(c_t) \quad (2.14)$$

Dimana  $W_k$ ,  $U_k$  adalah bobot matrik antara dua *hidden layer* yang berurutan, antara *input* dan *hidden layer*, dan antara dua *cell activation* yang berurutan, masing-masing, terhubung dengan *gate k* (contoh: *input*, *output*, *forget*, dan *cell*), dan  $b_k$  adalah nilai vektor bias terkait. Simbol  $\odot$  menyatakan nilai produk untuk masing-masing elemen dari dua vektor. Nilai fungsi *gate*  $\sigma$  merupakan aktivasi *sigmoid*, dan  $b$  dan  $h$  adalah aktivasi dari *cell input* dan *cell output*, biasanya bernilai tanh.



**Gambar 2.6** Ilustrasi metode LSTM

Gambar 2.5 menjelaskan ilustrasi alur dari metode LSTM yang dipecah menjadi 4 komponen dengan klasifikasi sentimen (Do, Prasad, Maag, & Alsadoon, 2019). Komponen pada LSTM digunakan sebagai penyematan kata-kata dengan *classifier softmax biner* yang memberikan nilai vektor untuk *sentiment*. Nilai vektor pada langkah *classifier softmax biner* akan dikalikan dengan matriks bobot lain sehingga menghasilkan nilai 0 dan 1 (Chaudhuri & Ghosh, 2016). Secara efektif,

dapat memberikan parameter nilai pada *sentiment positive* dengan angka 1 dan angka 0 untuk *negative*.

### 2.5.7 Evaluasi

Terdapat banyak macam-macam metode evaluasi yang dapat digunakan untuk mengukur kehandalan dari metode yang diusulkan. Thesis ini mengusulkan metode pengukuran dengan menggunakan *Precision*, *Recall*, dan *F-1 measure*. Dimana metode pengukuran ini dianggap yang paling andal dalam mengukur performa metode yang diusulkan (Jiao & Du, 2016) dan (Do, Prasad, Maag, & Alsadoon, 2019). Adapun proses perhitungan dari *Precision* dan *recall* ditentukan dari prediksi informasi terhadap nilai sebenarnya yang direpresentasikan dengan *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*.

- *Precision* adalah tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh *system*.

$$Precision = \frac{TP}{TP+FP} \quad (2.15)$$

- *Recall* adalah tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi.

$$Recall = \frac{TP}{TP+FN} \quad (2.16)$$

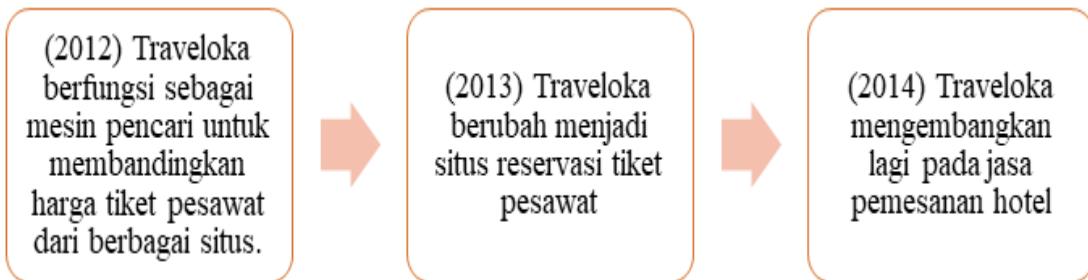
- *F1 measure* adalah perhitungan evaluasi dalam temu kembali informasi yang mengkombinasikan *recall* dan *precision*.

$$F1\ measure = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.17)$$

## 2.6. TRAVELOKA

Traveloka merupakan perusahaan travel terkemuka di Asia Tenggara yang menyediakan berbagai kebutuhan perjalanan dalam satu platform. Bersama Tokopedia dan Gojek, nama Traveloka dimasukkan dalam kategori **TRIO UNICORN** Indonesia. Unicorn adalah sebutan bagi start up yang valuasinya sudah tembus diatas USD 1 Milyar (atau setara Rp 13 triliun).

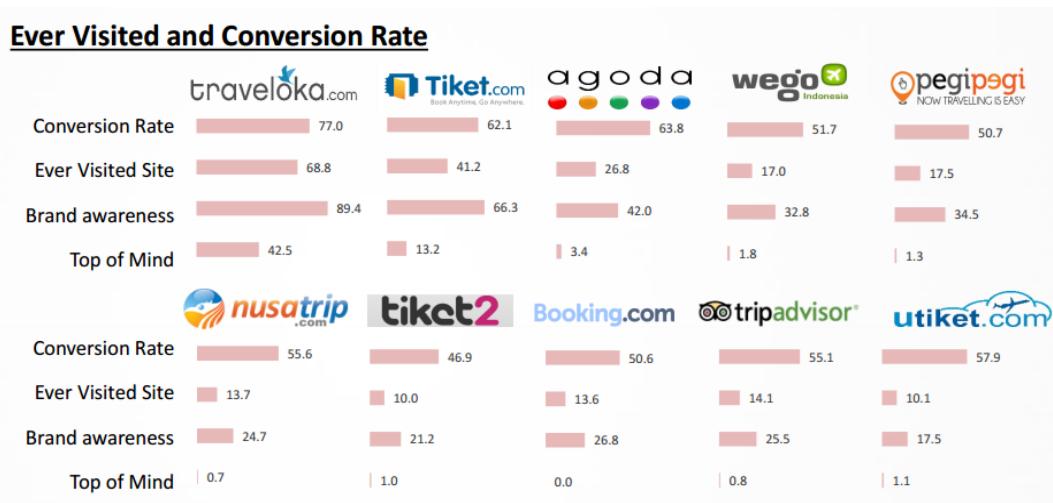
Tujuan awal Traveloka dijabarkan sebagai berikut:



**Gambar 2.7 Tujuan Traveloka**

Sehingga diharapakan dengan teknologi Traveloka, Pelanggan dapat menemukan rute penerbangan dan hotel terbaik dengan cepat, aman, harga termurah tanpa tambahan biaya apapun hanya dalam hitungan menit.

Traveloka saat ini menjadi aplikasi platrom utama yang menyediakan berbagai layanan yang memudahkan pelanggannya. Sehingga tidak heran bahwa Traveloka menjadi platform utama yang paling banyak digunakan di Indonesia. Hal ini sesuai dengan data yang diperoleh dari (Karimuddin, 2019) ditampilkan pada gambar 2.6 berikut:



**Gambar 2.8 Website yang Pernah dikunjungi dan Tingkat Konversinya**

Survei yang dilakukan tersebut, menyebutkan bahwa dari semua sisi penilaian, Traveloka menjadi situs yang paling populer di segmen ini di Indonesia.

Tiket.com dan Agoda mengikuti di posisi kedua dan ketiga. Sehingga review dari website Traveloka dipilih sebagai aplikasi penyedia sumber data yang akan dianalisa. Website Traveloka dipilih karena merupakan salah satu situs web yang paling popular pada Negara ini dan berisi data utama tentang sebagian besar hotel.

## **2.7. Penelitian Sebelumnya**

Penelitian sebelumnya (Xu, Wang, Li, & Haghghi, 2017), peneliti menganalisis ulasan pelanggan berdasarkan layanan hotel dari tujuan perjalanan, jenis hotel, dan rekomendasi editor dengan menggunakan metode *Latent Semantic Analysis* (LSA). Kekurangan dari penelitian sebelumnya adalah tidak fokus terhadap faktor-faktor dari aspect yang membentuk opini pelanggan. *Latent Semantic Analysis* (LSA) juga menganggap bahwa kata-kata yang memiliki pelafalannya yang sama namun memiliki makna yang berbeda merupakan satu kata yang sama.

Kemudian (Khotimah & Sarno, 2018) meneliti mengenai analisa sentiment dengan menggunakan metode *Probabilistic Latent Semantic Analysis* (PLSA). *Probabilistic Latent Semantic Analysis* (PLSA) ini merupakan pengembangan dari metode *Latent Semantic Analysis* (LSA) perbedaannya adalah bahwa *Probabilistic Latent Semantic Analysis* (PLSA) mempertimbangkan kata tidak berdasarkan pelafalan yang sama, namun makna yang sama. *Probabilistic Latent Semantic Analysis* (PLSA) memperlakukan *topic* sebagai distribusi kata dan menggunakan metode *probabilistic* dalam penerapannya, sehingga setiap kata dalam setiap kalimat akan dijadikan sebagai *term*. Sehingga dapat disimpulkan bahwa term yang akan dimiliki oleh penerapan metode ini akan sangat banyak dan dapat memakan *memory*. *Probabilistic Latent Semantic Analysis* (PLSA) yang diterapkan pada paper ini digabungkan dengan sentiwordnet untuk mendapatkan jumlah skor setiap kata atau term. Kekurangan lain dari metode ini adalah tidak dapat mendeteksi *sentiment* untuk teks pendek (*short term*).

(Akhtar, Zubair, Kumar, & Ahmad, 2017), penelitian ini menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk mengidentifikasi *hidden topic* (kata-kata yang penting atau kata-kata yang banyak muncul dalam suatu korpus). Kelebihan metode *Latent Dirichlet Allocation* (LDA) untuk mencari *hidden topic*

dibandingkan dengan metode lainnya adalah *Latent Dirichlet Allocation* (LDA) memiliki fungsi *dirichlet*, sehingga dapat mencegah *over fitting* dan memberikan analisa kata lebih baik. Penelitian ini membuat daftar *hidden topic* kemudian membuat file kosong dengan nama aspect yang akan dijadikan topic kasifikasi, kemudian membandingkan kata dengan setiap kata kunci dari daftar aspect, hitung skor rata-rata dari semua kata kunci aspect, kemudian cari tau aspect mana yang memiliki kemiripan maksimum dengan kalimat. Kekurangan dari penelitian ini, peneliti hanya menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk melakukan pencarian *hidden topic* dan melakukan klasifikasi aspect yang berarti bahwa paper tidak dapat mengkategorikan dokumen kedalam salah satu aspect secara langsung dan penelitian ini tidak menggunakan bantuan *expanding term list* untuk membuat daftar term sehingga pada saat proses “membandingkan kata dengan setiap kata kunci dari daftar aspect” tersebut, data masih membutuhkan pelabelan data dengan bantuan manusia sehingga akan risikan dengan *Human Error* serta memungkinkan adanya *term list* penting yang tidak terdefinisikan.

(Puspaningrum, Siahaan, & Faticahah, 2018) melakukan penelitian dengan melakukan penerapan metode *Latent Dirichlet Allocation* (LDA) yang digabungkan dengan *Wu Palmer similarity* untuk mengklasifikasikan dokumen dalam satu *topic*. Selain itu, penelitian ini juga menggunakan *Term Frequency-Inverse Cluster Frequency* (TF-ICF) sebagai salah satu metode untuk melakukan perluasan *term list*. Penelitian ini mendapatkan kesimpulan bahwa dengan melakukan penerapan kedua metode tersebut bersama-sama, akan di dapatkan performa yang sangat tinggi yakni mencapai 75%.

(Liu, Joty, & Meng, 2015) melakukan penelitian tentang penerapan pengembangan model *Recurrent Neural Network* (RNN) dan *word embedding* yang sukses diterapkan untuk mengklasifikasi review. Adapun model yang dibandingkan adalah *Elman-type RNN*, *Jordan-type RNN*, *Long Short Term Memory* (LSTM), *Bidirectionally*. *Fine-tuning of Embedding*. Adapun *word embedding* yang digunakan diantaranya adalah *SENNNA Embeddings*, *Google Embeddings*, *Amazon Embeddings*. Hasil menunjukan bahwa ekstraksi review dengan menggunakan *word embeddings* dapat meningkatkan performa. LSTM RNN mampu menunjukan performa terbaik pada kumpulan dataset dan berada di posisi kedua pada dataset

laptop dibandingkan dengan metode lainnya dan metode conditional random fields (CRF).

(Huang, Rao , Feng, & Cong, 2018) melakukan penelitian tentang penerapan jaringan syaraf menggunakan (SR-LSTM) metode ini sedikit mirip dengan *Word Embedding + Long Short Term Memory* (LSTM) karena metode ini memiliki 2 lapisan. Lapisan pertama adalah untuk mempelajari *vector* kalimat untuk mewakili nilai *semantic* dan lapisan kedua adalah mengkodekan hubungan kalimat dalam representasi dokumen. Penelitian ini mempelajari mengenai efek dari *word embedding*. *Word embedding* dalam penelitian ini menggunakan CBOW dan *Skip-gram* yang merupakan dua model yang terdapat pada Word2vec dan GloVe yang merupakan algoritma untuk mendapatkan konteks global. Hasil dari pembelajaran mengenai pentingnya *word embeddings* ini didapatkan bahwa GloVe memiliki akurasi yang baik untuk diterapkan, karena GloVe mampu memperkirakan representasi kata dengan baik.

(Wang, Peng, & Zhang, 2018) Melakukan penelitian tentang sentimen analisis menggunakan *Long Short Term Memory* (LSTM). *Long Short Term Memory* (LSTM) dianggap lebih baik dalam menangkap keterhubungan kata daripada sentimen yang berbasis polaritas. Dengan ditambahkan teknik *word embedding*, metode *Long Short Term Memory* (LSTM) lebih unggul dari metode yang berbasis leksikon dan regresi yang ada untuk memprediksi intensitas sentimen.

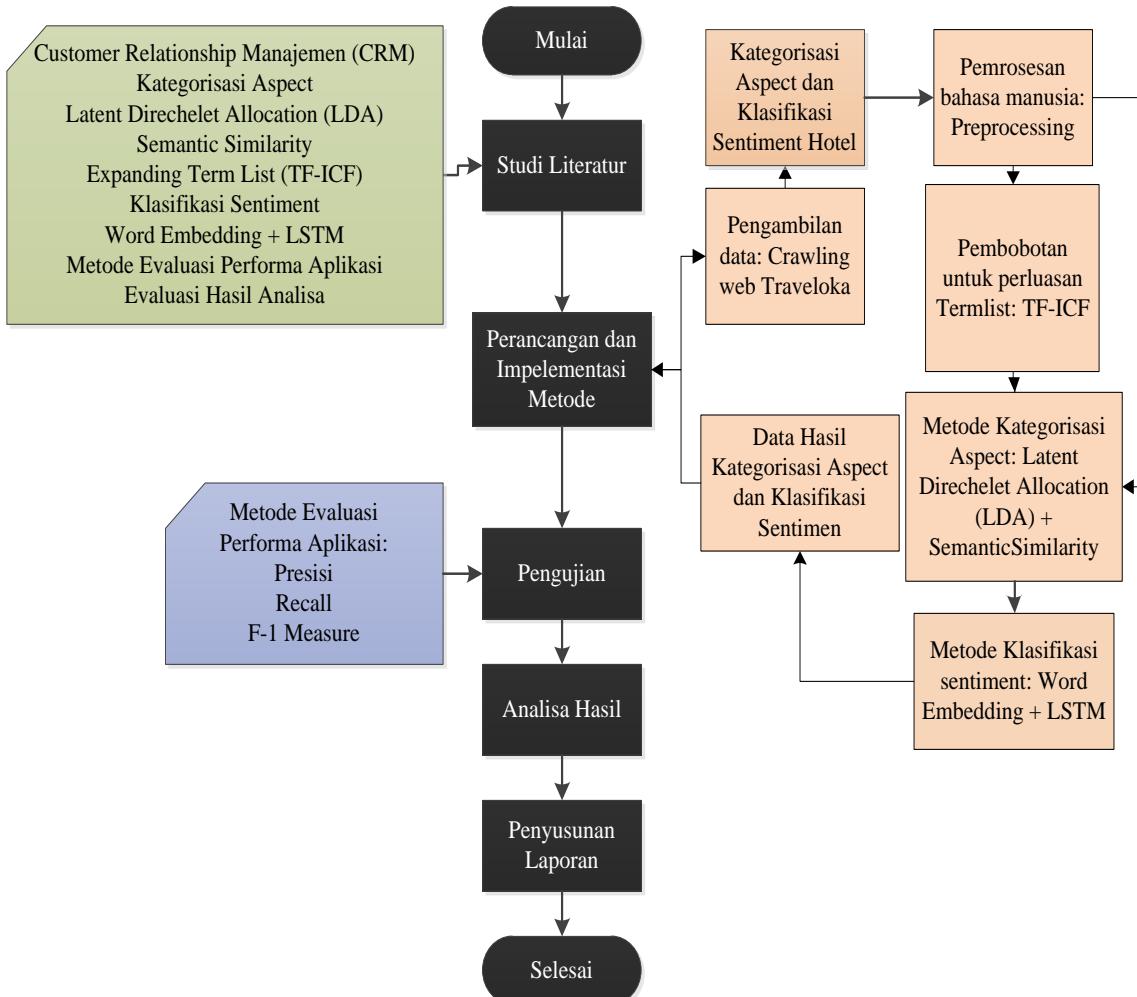
(Priyantina & Sarno, 2019) Priyantina, R.A. Selaku penulis Thesis ini melakukan penelitian yang mendasari pembuatan thesis, penelitian yang dilakukan menerapkan *Latent Dirichlet Allocation* (LDA) sebagai metode untuk melakukan pencaarian *hidden topic* kemudian di kombinasikan dengan *Semantic Similarity* untuk melakukan kategorisasi terhadap 5 aspect hotel yang telah ditentukan sebelumnya, dimana dalam melakukan proses kategorisasi, data *hidden topic* dibandingkan dengan term list yang telah terlebih dahulu diperluas menggunakan *Term Frequency-Inverse Cluster Frequency* (TF-ICF) agar proses perhitungan semantic lebih akurat. Kemudian setelah mendapatkan aspect pada setiap review, penulis melakukan klasifikasi sentimen pada *sentiment positive* dan *negative* dengan menggunakan *Long Short Term Memory* (LSTM) dimana dalam melakukan

proses klasifikasi setiap review terlebih dahulu akan diproses dengan menggunakan *Word embedding* untuk menjadikan setiap kata menjadi bilangan angka *vector*. *Word embedding* yang digunakan merupakan GloVe. Hasil dari penelitian ini menunjukkan bahwa kategorisasi aspect dengan menggunakan *Latent Dirichlet Allocation* (LDA) +TF-ICF + *Semantic Similarity* memiliki performa hingga 85% serta klasifikasi sentiment dengan menggunakan perpaduan *Word embedding* (GloVe) + *Long Short Term Memory* (LSTM) memiliki performa hingga 93%.

## BAB 3

### METODOLOGI PENELITIAN

Penelitian ini dimulai dengan melakukan studi literatur untuk mengetahui serta memahami lingkup penelitian yang akan dilakukan. Kemudian melakukan perancangan dan implemenasi metode dimana hal ini dilakukan dengan pengambilan data terlebih dahulu dengan *crawling* pada *website* traveloka, kemudian diproses menggunakan *preprosesing*, kemudian mengkategorikan setiap *review* berdasarkan *aspect* yang akan diteliti dan melakukan klasifikasi terhadap *sentiment* kepuasan pelanggan. Performa metode akan diuji dengan 3 metode pengujian yakni *precision*, *recall* dan *F-1 measure*. Keseluruhan alur penelitian dapat dilihat pada Gambar 3.1.



**Gambar 3.1** Diagram Alur Penelitian

Penjelasan tahapan metode penelitian pada Gambar 3.1 akan diterangkan secara terperinci pada sub bab berikut

### **3.1. Metodologi Penelitian**

Penelitian diawali dengan proses pengkajian yang berkaitan dengan topik penelitian yang diambil. Pada penelitian ini, referensi yang digunakan diperoleh dari jurnal, paper dan juga buku yang memiliki hubungan dengan klasifikasi *teks*, penggalian opini, metode *Latent Dirichlet Allocation* (LDA), *Semantic Similarity*, pembobotan *term* serta *Word Embedding* dan *Long Short Term Memory* (LSTM). Dari studi literatur yang telah dilakukan, diperoleh informasi yang berhubungan dengan penelitian, diantaranya sebagai berikut:

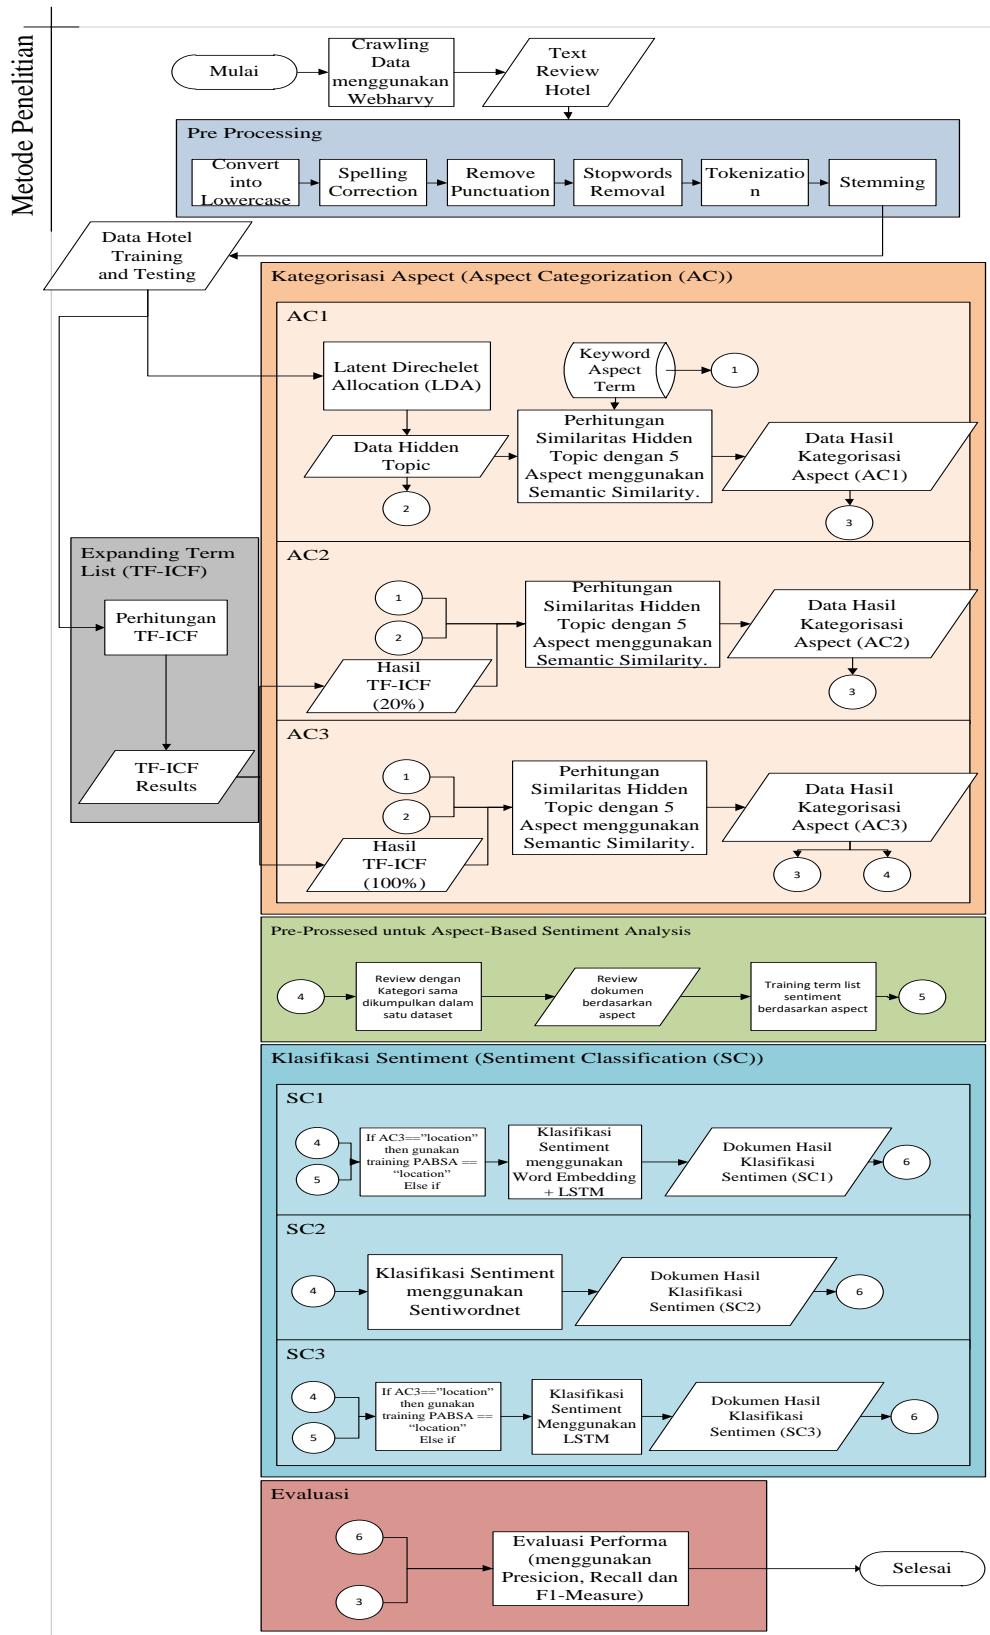
1. Banyaknya review atau opini yang terdapat pada review hotel di website Traveloka mengandung banyak informasi yang berhubungan dengan kepuasan maupun komplain pelanggan.
2. Proses penggalian opini membutuhkan metode klasifikasi yang baik agar pengembang dapat memperoleh banyak masukan untuk membantu manajer hotel dalam meningkatkan kualitas pelayanan hotel.
3. *Latent Dirichlet Allocation* (LDA) adalah model probabilistik yang mengelompokan bagian dari suatu data yang memiliki kemiripan berdasarkan makna atau arti secara *semantic*. *Latent Dirichlet Allocation* (LDA) mampu memetakan *hidden topic* dari suatu dokumen. *Hidden topic* ini merupakan kata-kata penting atau kata-kata yang sering muncul dalam korpus yang dihitung berdasarkan probabilitas.
4. Klasifikasi menggunakan metode *Semantic Similarity* berbasis nilai kemiripan antar kata (*word similarity*) dapat diperoleh melalui banyak cara, salah satunya adalah dengan menggunakan Wordnet *Similarity*. WordNet *Similarity* akan menjadi kakas bantu untuk melakukan *expand term* dan mengkategorisasikan setiap dokumen.
5. *Term Frequency – Inverse Cluster Frequency* (TF-ICF) merupakan metode pembobotan kata untuk mengetahui bobot suatu kata pada suatu klaster berdasarkan kemunculan *term* pada klaster tersebut. Hasil dari modul

*Expanding Term List* ini akan digunakan dalam proses perhitungan *Semantic Similarity*.

6. Ekstraksi fitur dengan menggunakan metode *Word Embedding*. Setiap kata dan topik akan dicari nilai fitur nya menggunakan rerata nilai representasi setiap kata dalam bentuk vektor (*Mean Representation Vector*). *Word Embeddings* yang digunakan dalam penelitian ini adalah GloVe. GloVe juga akan digunakan untuk menjadi kakas bantu dalam melakukan *expand term list* saat *training* data.
7. *Long Short Term Memory* (LSTM) merupakan metode yang popular untuk klasifikasi sentiment karena *Long Short Term Memory* (LSTM) mampu menyimpan term dengan jangka yang panjang pada memory-nya sehingga *Long Short Term Memory* (LSTM) dapat digunakan untuk memodelkan keterhubungan antara term bahkan yang memiliki interval yang jauh.
8. Evaluasi pelabelan menggunakan formula *Precision*, *Recall*, dan *F1-Measure* untuk melakukan pengukuran performa metode yang diusulkan.
9. Terdapat suatu karakteristik dari review aplikasi yang umum ditemukan pada kasus penggalian opini, diantaranya adalah:
  - a. Tidak menggunakan struktur tata bahasa yang baku  
*Teks* pada *dataset* penggalian opini tidak dapat dipastikan memiliki struktur bahasa yang baik, seperti tidak mengandung subjek atau predikat secara eksplisit.
  - b. Memungkinkan terdapat kata-kata yang jarang ditemukan secara umum  
Tidak adanya tuntutan menggunakan bahasa formal membuat pengguna bebas menuliskan opini nya, salah satunya adalah menggunakan kata-kata baru (*slang words*) yang mampu memicu *Out of Vocabulary* (OOV).
10. Metode lain yang dapat digunakan untuk menganalisa data opini adalah dengan memanfaatkan aturan bahasa atau dengan memanfaatkan relasi antar kata dalam kalimat. Dari studi literatur, dapat disimpulkan juga mengenai kondisi saat ini bahwa:
  - a. Sebagai salah satu sumber masukan bagi manajer bisnis hotel, penggalian opini dapat digunakan untuk menggali apakah pelanggan sebenarnya puas atau tidak puas terhadap 5 topik pelayanan hotel yang telah disediakan.

- b. Dalam melakukan proses penemuan aspect atau topik serta sentimen dari suatu review, dibutuhkan suatu proses yang dapat menganalisa jika terdapat review yang mengandung lebih dari satu aspect atau sentimen.

### 3.2. Pembangunan Model Penelitian



Gambar 3.2 Alur Model Penelitian

Model penelitian yang akan digunakan memiliki beberapa proses yang akan dijelaskan sebagaimana berikut:

1. Data *text review* hotel pertama-tama akan dicrawling dengan menggunakan WebHarvy. Data yang telah di *crawling* kemudian akan dipisahkan berdasarkan titik (*split data*). Hal tersebut berdasarkan pertimbangan bahwa suatu review mengandung lebih dari satu aspect. Data ini kemudian akan disimpan dalam text review hotel DB agar nantinya dapat diproses pada langkah selanjutnya.
2. Data yang diperoleh ini kemudian akan diolah dengan menggunakan tahapan *pre-processing*. Modul *preprocessing* ini bertugas untuk membersihkan *review* yang akan digunakan pada modul selanjutnya baik dari *noise* ataupun struktur *teks* yang kurang relevan untuk diproses. Dengan demikian, diharapkan modul yang dihasilkan pada tahap selanjutnya mampu bekerja dengan baik. Hasil dari tahapan *pre-processing* akan mengolah setiap *review* menjadi *term list*. Setelah itu, ditetapkan data *training* dan data *testing* yang akan digunakan. Data *training* berjumlah 80% dari data keseluruhan, sedangkan sisanya, 20% akan masuk pada data *testing*.
3. Sebagai upaya perluasan *term list* serta peningkatan performa saat perhitungan *similaritas*, data *training* (80% data hotel) akan diproses dengan menggunakan metode *Term Frequency – Inverse Cluster Frequency* (TF-ICF). Metode ini dilakukan untuk mendapatkan term-term penting pada setiap kelas atau setiap aspect yang akan dianalisa. Dengan demikian, diharapkan modul ini dapat mengoptimalkan proses pada modul “Kategorisasi Aspect” terutama pada saat perhitungan *hidden topic* yang dimatchingkan dengan aspect pada *Semantic Similarity*.
4. Data term list hasil pre-processing kemudian diproses dengan menggunakan *Latent Dirichlet Allocation* (LDA) untuk menemukan *hidden topic*. *Hidden topic* akan diproses oleh *Semantic Similarity* untuk melakukan proses kategorisasi aspect. Pada modul ini, data akan dikategorikan kedalam 5

- aspect yakni *location*, *meal*, *service*, *comfort* serta *cleanliness* hotel. Selanjutnya, akan didapatkan kategori aspect per data review hotel.
5. Setelah di dapatkan data kategorisasi aspect per hotel review, data kemudian diproses untuk dilakukan analisa *sentiment*. Sebelum itu, data hasil kategorisasi aspect akan diproses pada *Pre-prossesed for Aspect Based Sentiment Analysis*. Proses ini mengumpulkan hasil kategorisasi aspect berdasarkan kategori yang sama. Data yang memiliki aspect sama ini kemudian akan ditraining untuk mendapatkan *term list sentiment* per kategori aspect. Data hasil kategorisasi aspect dan data *term list* hasil *training* sentiment per aspect kemudian diproses untuk mencari klasifikasi sentiment kepuasan pelanggan berdasarkan aspect.
  6. Klasifikasi sentiment kemudian dilakukan dengan menggunakan metode *Long Short Term Memory* (LSTM) yang digabungkan dengan *Word Embedding* untuk menemukan nilai *vector* setiap kata, penggabungan ini didasarkan pada literature yang menyebutkan bahwa proses tersebut (*Word Embedding + LSTM*) akan menghasilkan performa yang lebih baik. *Word embedding* yang digunakan adalah Glove dengan pertimbangan bahwa Glove mampu menghasilkan performa yang lebih baik daripada *word embedding* yang lain (Huang, Rao , Feng, & Cong, 2018). Kemudian dari proses ini akan didapatkan data hasil klasifikasi sentiment per review hotel.
  7. Kategorisasi aspect dan klasifikasi sentiment akan melalui beberapa percobaan untuk mencari performa dari metode yang akan diterapkan, performa terbaik akan dievaluasi dengan menggunakan *precision*, *recall* dan *F1-Measure* (AC1, AC2, AC3 untuk percobaan kategorisasi aspect dan SC1, SC2 dan SC3 untuk klasifikasi sentiment).
  8. Dengan menggunakan performa metode terbaik, diharapkan hasil akhir dari tujuan “evaluasi terhadap setiap review untuk mengetahui hal apa dari bisnis yang membuat pelanggan puas maupun tidak puas yang didasarkan kepada 5 aspect hotel“ ini mampu direpresentasikan dengan baik.

### 3.2.1 Data Text Review Hotel

Data pertama-tama akan dicrawling dengan menggunakan WebHarvy. Data yang telah di *crawling* kemudian akan dipisahkan berdasarkan titik (*split* data). Hal tersebut berdasarkan pertimbangan bahwa suatu review mengandung lebih dari satu aspect. *Split* data akan dilakukan dengan bantuan `substring_index(review, '.', n)`. Data ini kemudian akan disimpan dalam *text review hotel* DB agar nantinya dapat diproses pada langkah selanjutnya. Data *text review hotel* yang akan diproses dan dianalisa selanjutnya disebut sebagai dokumen review. Setiap dokumen review akan disimpan ke dalam *database* dengan identifier IDReview (yang akan merepresentasikan ID dari data dan bersifat unik) dan IDKalimat (yang akan menunjukkan apakah review tersebut berasal dari data sama yang di *split* atau data review yang berbeda) yang merupakan representasi dari nama *dataset* yang sedang dianalisa. Berikut contoh dokumen review:

“Spacious guest room with comfortable light and ambiance.  
Excellent variety of breakfast buffet.”

**Tabel 3.1** Representasi Dokumen Review

IDReview	IDKalimat	Review text
1	1	Spacious guest room with comfortable light and ambiance
2	1	Excellent of breakfast buffet variety

Dari contoh data yang diberikan, dapat dilihat bahwa data merupakan satu kalimat review, namun penulis melakukan *split* pada data tersebut menjadi 2 ID, hal tersebut dikarenakan penulis memisahkan setiap review berdasarkan titik. IDReview pada tabel adalah ID dari review yang diambil sedangkan IDKalimat merupakan id dari kalimat yang telah dilakukan split data oleh penulis.

### 3.2.2 Pre Processing

Pada modul ini akan dilakukan proses untuk mempersiapkan dan memastikan dokumen yang diproses telah siap untuk digunakan pada modul

selanjutnya. Arsitektur yang dipilih merupakan arsitektur pre processing umum untuk mengekstrak suatu informasi. Pada model ini, dilakukan beberapa tahap yang akan terdiri dari:

*Pseudocode Pre-Processing Data*

```
Start
    1. Ambil dokumen review.
    2. Lakukan preprocessing dengan menggunakan Python Natural Language Toolkit (NLTK)
    3. Lakukan preprocessing pada “Tabel 2.2. Pre-Processing Data” dengan urutan: Convert into Lowercase → Spelling Correction → Remove Punctuation → Stopwords Removal → Tokenization → Stemming.
    4. Simpan hasil pre-processing.
End.
```

Adapun penjelasan dari setiap proses *preprocessing* di jabarkan sebagai berikut (data contoh diambil dari dokumen review pada “Tabel 3.1 Representasi dokumen review”):

1. *Convert into Lowercase*

Proses ini memiliki fungsi untuk mengubah huruf pada teks review ke dalam bentuk huruf kecil. Pada teks review

'Spacious guest room with comfortable light and ambiance.'

Akan berubah menjadi

'spacious guest room with comfortable light and ambiance.'

2. *Remove Punctuation*

Proses ini memiliki fungsi untuk menghapus tanda baca pada teks review. Pada *teks review*

'spacious guest room with comfortable light and ambiance.'

Akan berubah menjadi

'spacious guest room with comfortable light and  
ambiance'

### 3. *Spelling Correction*

Proses ini memiliki fungsi untuk menyempurnakan kalimat yang memiliki kesalahan dalam penulisan. Pada *teks review*

'spacious guest room with comfortable light and  
ambiance'

Akan berubah menjadi

'spacious guest room with comfortable light and  
ambiance'

### 4. *Tokenisasi*

*Tokenisasi* memiliki peran untuk memecah *teks* menjadi unit terkecil dalam proses bahasa atau dikenal dengan token atau potongan kata. Pada tahap *tokenisasi*, *review*

'spacious guest room with comfortable light and  
ambiance'

Akan dipecah menjadi

{spacious, guest, room, with, comfortable, light,  
and, ambiance}

### 5. *Stemming*

*Stemming* memiliki peran untuk menjadikan teks menjadi kata dasar. Pada tahap tokenisasi, *review*

'spacious guest room with comfortable light and  
ambiance'

Akan berubah menjadi

{spacious, guest, room, with, comfort, light, and,  
ambiance}

### 6. *Stopwords Removal*

*Stopwords Removal* memiliki peran untuk menghapus kata henti dalam bahasa Inggris. Pada *teks review*

'spacious guest room with comfortable light and  
ambiance'

Akan berubah menjadi

{spacious, guest, room, with, comfort, light,  
ambiance}

Begitu juga untuk kalimat hasil dari pra-preprocessing satunya, akan menjadi:

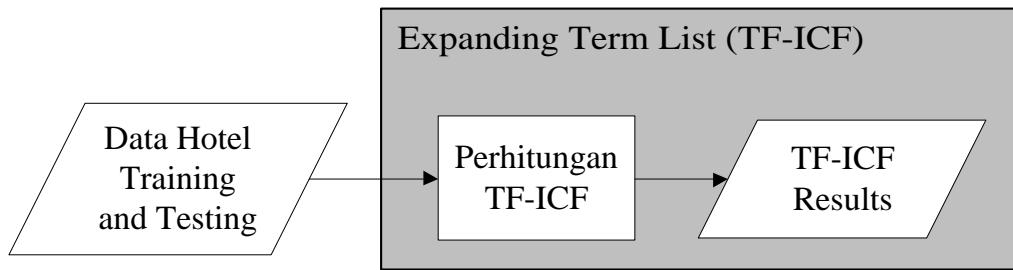
{excellent, breakfast, buffet, variety}

Selanjutnya hasil *preprocessing* ini akan digunakan sebagai *input* dari proses klasifikasi. Gambar 3.2 pada metode penelitian menunjukkan bahwa *pre-processing* akan menjadi *input* pada proses *expanding term list* dan proses kategorisasi aspect. Contoh *input* yang akan digunakan untuk melakukan proses kategorisasi ditunjukkan pada table 3.2.

**Tabel 3.2** Contoh Hasil *Pre-processing* untuk Masukan Proses Kategorisasi

Input data saat awal Preprocessing	Spacious guest room with comfortable light and ambiance
	Excellent of breakfast buffet variety
Output Preprocessing/ Input Proses Klasifikasi	spacious, guest, room, with, comfort, light, ambiance
	excellent, breakfast, buffet, variety

### 3.2.3 Modul Perluasan Term List (*Expanding Term List*)



Gambar 3.3 Proses Expanding Term List

Akan ada 5 aspect klasifikasi data yang akan digunakan dalam penelitian ini, ke-lima aspect tersebut adalah *location*, *meal*, *service*, *comfort* serta *cleanliness* hotel. Kelima aspect ini akan didefinisikan sebagai berikut:

1. Aspect *location* (lokasi) akan diberikan pada review yang membahas mengenai lokasi, tempat-tempat bagus dan unik di sekitar lokasi serta kemudahan akses transportasi karena lokasi yang baik. Data mengenai aspect lokasi diungkapkan sebagai berikut:

*"The location is the best thing with this hotel if you looking for stay nearby Times Square"*
2. Aspect *meal* (makanan) akan diberikan pada review yang membahas mengenai makanan dan kesukaan pelanggan terhadap masakan yang disajikan. Sebagai contoh, data mengenai aspect makanan adalah sebagai berikut:

*"The breakfast was great"*
3. Aspect *service* (pelayanan) akan diberikan pada setiap review yang membahas mengenai bagaimana cara petugas dan staff hotel dalam melakukan pelayanan serta fasilitas umum yang diberikan oleh hotel seperti (gym, kolam renang, dst.) sebagai bentuk lain dari pelayanan mereka. Data pelayanan biasanya dituliskan sebagai berikut:

*"Very awesome and polite made sure we had everything we needed and even got us an early check-in."*
4. Aspect *comfort* (kenyamanan) diberikan pada review yang membahas tentang aspect kenyamanan pada hotel tersebut. Kenyamanan ini dapat

berupa kenyamanan yang dihasilkan karena fasilitas tambahan hotel seperti (internet, wifi, dst. (yang tidak tampak secara fisik)) maupun karena perasaan nyaman pelanggan ketika tinggal dan menggunakan barang-barang yang ada di hotel tersebut. Data kenyamanan biasanya dituliskan sebagai berikut:

*"The rooms and bed was very comfortable."*

5. Aspect *cleanliness* (kebersihan) diberikan pada review yang membahas tentang aspect kebersihan pada hotel tersebut. Data kebersihan biasanya dituliskan sebagai berikut:

*"The carpetting on the floor may need a bit more cleaning but rest is just fine."*

Modul *Term Frequency-Inverse Document Frequency* (TF-IDF) ini merupakan modul yang ditujukan untuk mengatasi permasalahan *Out-of-Vocabulary* yang mungkin timbul pada saat pendeklarasian term list. *Out-of-Vocabulary* yaitu kondisi dimana pendeklarasian *term list* pada setiap aspect terbatas sehingga memungkinkan adanya term yang tidak dideskripsikan. Penelitian ini memperluas term list dengan menggunakan *Term Frequency-Inverse Document Frequency* (TF-IDF). Metode ini digunakan untuk mengambil term-term penting setiap kelas. Adapun formula dari TF-IDF dijelaskan pada formula 3.1 dan 3.2.

$$TF - ICF = TF_{t,i} \times ICF_t \quad (3.1)$$

$$TF - ICF = TF_{t,i} \times \log\left(\frac{N}{CF_t}\right) \quad (3.2)$$

$TF_{t,i}$  = jumlah term pada kelas i

N = jumlah kelas

$CF_t$  = jumlah kelas yang mengandung term t

Terdapat langkah-langkah dari *Term Frequency-Inverse Document Frequency* (TF-IDF) dalam menemukan *term list* tambahan. Hal tersebut dijelaskan pada *pseudocode* berikut:

*Pseudocode* proses *Term Frequency-Inverse Document Frequency* (TF-ICF).

<p>Start</p> <ol style="list-style-type: none"><li>1. Ambil 80% data Pre-processing untuk Masukan Proses Kategorisasi.</li><li>2. Data yang diambil untuk proses TF-ICF berupa Review dan Label (<i>Ground Truth</i> dari Anotator) dengan identifier IDReview.</li><li>3. Berdasarkan kelasnya masing-masing, hitung nilai dari <i>Term Frequency</i> (TF) pada setiap aspect.</li><li>4. Hitung <i>Inverse Cluster Frequency</i> (ICF) dengan menggunakan <i>Equation 2.4</i></li><li>5. Hitung nilai TF-ICF menggunakan <i>Equation 3.2</i></li><li>6. Untuk masing-masing kelas, analisa term-term penting sesuai nilai TF-ICF.</li></ol> <p>End</p>
----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Aturan tersebut berdasarkan pada analisa bahwa ekspresi setiap kelas akan berbeda-beda. Meskipun begitu, setiap kelas memiliki kecenderungan yang sama untuk mengekspresikan permasalahan, kebutuhan, atau kesan dari aplikasi yang dikembangkan. Oleh karena itu penggunaan penambahan term list berdasarkan kelas yang telah ditandai sebelumnya diharapkan mampu meningkatkan performa. Hasil dari modul *Expanding Term List* ini akan digunakan dalam proses perhitungan *Semantic Similarity*.

Hasil dari perluasan term list menggunakan *Term Frequency-Inverse Document Frequency* (TF-ICF), akan ditambahkan pada “Tabel 2.1 *Keyword Term List* Terkait Aspect yang Diperoleh” sehingga dapat direpresentasikan pada tabel berikut:

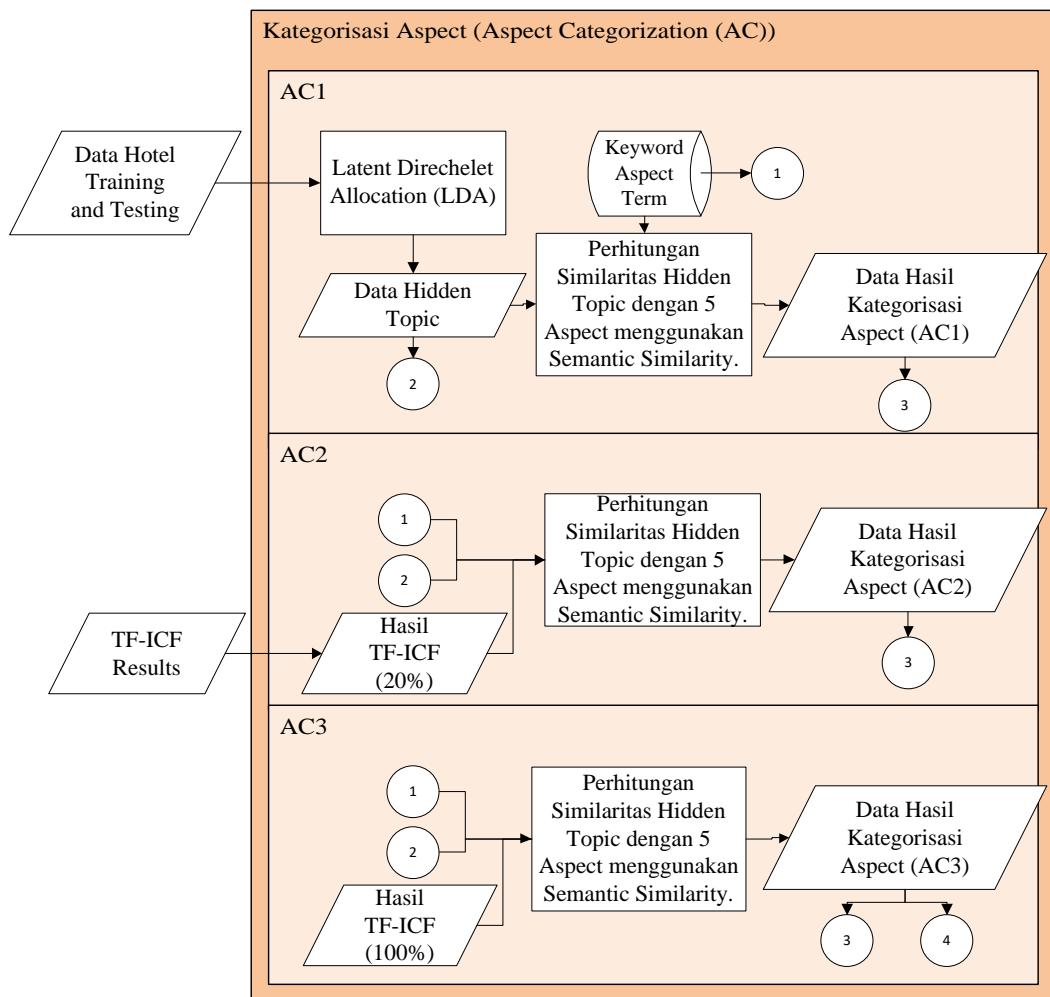
**Table 3.3** Tabel *Keyword Term List* + Hasil TF-ICF terkait Aspect

Aspect	Expanded Term terkait Aspect yang Diperoleh
<b>Cleanliness</b>	ventilation, cleanliness, smell, cobweb, smoke, carpet, laundry, furniture, wall, housekeeping, air conditioner, elevator, hall, air,

	stair, noise, neighbor, complaint, heat, <b>bathroom, clean, mold, dirty, stain, rug, fan, ceiling, floor</b>
<b>Comfort</b>	connection, meeting, charge, activity, sleep, bed, bedroom, pillow, sofa, suite, living room, towel, unit, chair, lobby, experience, space, comfort, feel, <b>sound, furniture, room, lamp, paintwork, charged, resort, heater, temperature, satisfy, scary</b>
<b>Service</b>	facility, wifi, pool, gym, business, internet, desk, reliable, fast, convenient, check-in, check-out, good, staff, polite, helpful, friendly, reliable, quick, parking, conference room, fee, <b>great, desk, front, request, hospitality, reception, manner, towel, staff, service, luggage, barista, kind</b>
<b>Food</b>	cafe, drink, breakfast, spicy, meal, bagel, tea, buffet, bar, waffle, restaurant, dinner, lunch, brunch, delicious, food, dish, wine, salad, coffee, pastry, menu, item, cup, <b>eat, starbucks, outlet, croissant, variety, shop, court, selection, snack, fruit, cereal, egg, juice, cheese</b>
<b>Location</b>	railway, view, station, airport, distance, far, close, train, metro, location, place, distance, station, shopping, bus, ride, mall, bus stop, downtown, park, theater, district, museum, transportation, heart, middle, <b>locate, convenient, access, subway, walking, building, garden, taxi, attraction, metro, block</b>

\*Bold merupakan term tambahan dari hasil dari penerapan metode *Term Frequency-Inverse Document Frequency* (TF-IDF)

### 3.2.4 Proses Kategorisasi Aspect



**Gambar 3.4** Proses Kategorisasi Aspect

Setelah melakukan tahap *pre-processing* dan perluasan *term list*, proses selanjutnya adalah melakukan kategorisasi aspect pada setiap dokumen review. Tujuan utama dari proses ini adalah mendapatkan hasil yaitu: kategori setiap dokumen review kedalam 5 aspect yang dianalisa (*location, meal, service, comfort* serta *cleanliness hotel*). Dalam melakukan percobaan untuk mencari performa categorization aspect terbaik. Setiap percobaan yang dilakukan, selanjutnya akan disebut *Aspect Categorization (AC)*. AC1 akan menggunakan metode *Latent Dirichlet Allocation (LDA)* untuk menghasilkan data *hidden topic*. Data *hidden topic* akan dikalkulasi menggunakan metode *Semantic Similarity* untuk di kategorisasikan kedalam 5 Aspect hotel yang *term listnya* telah ditentukan dengan

menggunakan “Tabel 2.1”;  $AC2 = AC1 + TF-ICF \times 20\%$  dan  $AC3 = AC1 + TF-ICF \times 100\%$ . Hal ini seperti yang telah digambarkan pada Gambar 3.4 mengenai proses kategorisasi aspect.

Penjabaran tentang percobaan *Aspect Categorization* dapat dilihat sebagai berikut:

#### **3.2.4.1. Aspect Categorization (AC) 1**

Kategorisasi aspect dilakukan dengan menggunakan data “Pre-processing untuk Masukan Proses Kategorisasi” seperti pada contoh “Tabel 3.2”. Percobaan ini dilakukan dengan menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk mencari *hidden topic* kamudian dilakukan *Semantic Similarity* dengan menggunakan data pada “Tabel 2.1” untuk mengkategorisasikan setiap review. Kakas bantu yang digunakan untuk melakukan expand term dan mengkategorisasikan setiap dokumen adalah WordNet *similarity* pada *synset* (synonym set). Penjabaran dari AC1 dapat dilihat:

##### **A. Latent Dirichelet Allocation (LDA)**

Metode pertama yang digunakan pada penelitian ini adalah *Latent Dirichlet Allocation* (LDA). Hasil yang diperoleh dari proses ini adalah *hidden topic* dan nilai probabilitasnya dari dokumen yang diinputkan. *Latent Dirichlet Allocation* (LDA) ini dipilih juga karena apabila ada review yang sangat panjang, sehingga akan menjadi tidak efektif apabila dicari berdasarkan similaritas setiap kata. Sehingga, diterapkannya *Latent Dirichlet Allocation* (LDA) agar dapat menangkap kata-kata penting saja atau selanjutnya disebut sebagai *hidden topic*.

*Hidden topic* yang diperoleh merupakan hasil identifikasi topik dari kata, dokumen, maupun keseluruhan *corpus*. Jumlah dari *hidden topic* yang dikeluarkan tidak ditentukan sebelumnya. Hal tersebut disebabkan karena panjang dokumen yang cenderung berbeda-beda.

Pada implementasinya, *Latent Dirichlet Allocation* (LDA) menggunakan *term* frekuensi untuk membangun vektor dari setiap token kata dengan menggunakan modul *CountVectorizer* dan selanjutnya dianalisa dengan menggunakan *Latent Dirichlet Allocation* (LDA) model yang dikonstruksi dengan

menggunakan Librari Gensim. *Input* dari proses ini adalah hasil dari *preprocessing*. Sedangkan *output* dari sub modul ini adalah dokumen dan *hidden topic* untuk masing-masing sub dokumen. Adapun setiap proses *Latent Dirichlet Allocation* (LDA) akan dilakukan:

*Pseudocode* proses Pencarian Hidden Topic LDA.

Start
<ol style="list-style-type: none"> <li>1. Ambil review pada “Tabel 3.2 Contoh Hasil <i>Pre-processing</i> untuk Masukan Proses Kategorisasi”.</li> <li>2. Dengan menggunakan <i>Library Python</i> Gensim hitung probabilitas kemunculan setiap kata pada dokumen dan corpus dan juga probabilitas kedekatan <i>topic-document</i> dan <i>word-topic</i> (dengan menggunakan <i>Equation 2.2</i> model LDA).</li> <li>3. Tampilkan data <i>hidden topic</i> (kata-kata penting atau kata-kata yang banyak muncul dalam suatu corpus) per dokumen review.</li> </ol>
End

Adapun contoh *input* dan *output* dari *hidden topic* yang telah dihitung menggunakan *Latent Dirichlet Allocation* (LDA) direpresentasikan pada tabel 3.4.

**Tabel 3.4** Tabel Contoh *Input* dan *Output* proses LDA

<b>Input LDA</b>	<b>Output LDA</b>
<b>Spacious guest room with comfortable light and ambiance</b>	$(0.040 * \text{``spacious''} + 0.059 * \text{``room''} + 0.070 * \text{``comfort''})$

## B. Kategorisasi Aspect Menggunakan Semantic Similarity

*Semantic Similarity* berfungsi untuk mengkategorikan setiap dokumen ke dalam lima aspect hotel yang akan diteliti, yaitu *location*, *meal*, *service*, *comfort* dan *cleanliness*. Metode yang digunakan untuk mengkategorikan setiap dokumen akan dibantu oleh WordNet *similarity*. WordNet ini merupakan basis data leksikal bahasa Inggris yang besar. Kata benda, kata kerja, kata sifat dan kata keterangan

dikelompokkan ke dalam set sinonim (synsets). Wordnet mencari kemiripan kata relasi *semantic* dan hubungan kedekatan atau kemiripan antar kata.

Proses *hidden topic similarity* ini merupakan tahapan terakhir pada proses pelabelan. *Input* dari proses ini adalah *hidden topic* yang telah dicari dengan menggunakan metode *Latent Dirichlet Allocation* (LDA) dan akan dilakukan perhitungan *similarity* dengan *expanded term list* (data dari “Tabel 2.1 Keyword Term List Terkait Aspect yang Diperoleh”) untuk melakukan kategorisasi review terhadap 5 aspect hotel yang telah ditentukan

Nilai *similaritas* tertinggi akan dijadikan label kelas dari dokumen tersebut. Adapun skala nilai yang dihasilkan adalah 1 dan 0. Dimana semakin mendekati nilai 1, maka *hidden topic* tersebut benar-benar mirip dan kemungkinan besar mampu merepresentasikan *cluster* tersebut. Sedangkan sebaliknya, nilai 0 merepresentasikan bahwa *hidden topic* sangat tidak mirip dan tidak dapat merepresentasikan *cluster*. Secara umum terdapat beberapa langkah untuk mengelompokan suatu dokumen terhadap salah satu dari kelas yang ada, proses terdiri dari empat langkah, yaitu:

*Pseudocode* proses Kategorisasi Menggunakan *Semantic Similarity*.

Start

1. Untuk setiap dokumen review, nilai *similarity* dihitung dengan menggunakan rumus *similarity* (Equation 2.3).
2. Nilai *similarity* yang diperoleh kemudian dicari reratanya sesuai dengan *aspect* klaster masing-masing.
3. Modul yang digunakan untuk mengkategorikan setiap dokumen akan dibantu oleh *Library WordNet similarity*.
4. Hasil rerata setiap klaster selanjutnya diranking. Klaster yang memiliki nilai *similarity* tertinggi selanjutnya akan menjadi label untuk dokumen tersebut.

End

**Tabel 3.5** Tabel Contoh Perbandingan *Hidden Topic* dan *Term List* Setiap Aspect

Aspect	Term terkait Aspect yang Diperoleh
Spacious	(Cleanliness) ventilation, cleanliness, smell, cobweb, smoke, carpet, laundry, furniture, wall, housekeeping, toilet, air conditioner, elevator, hall, air, stair, noise, neighbor, complaint, heat
	(Comfort) connection, meeting, charge, activity, sleep, bed, bedroom, pillow, sofa, suite, living room, towel, unit, chair, lobby, experience, space, comfort, feel.
	(Service) facility, wifi, pool, gym, business, internet, desk, reliable, fast, convenient, check-in, check-out, good, staff, polite, helpful, friendly, reliable, quick, parking, conference room, fee
Room	(Food) cafe, drink, breakfast, spicy, meal, bagel, tea, buffet, bar, waffle, restaurant, dinner, lunch, brunch, delicious, food, dish, wine, salad, coffee, pastry, menu, item, cup
Comfort	(Location) railway, view, station, airport, distance, far, close, train, metro, location, place, distance, station, shuttle, cab, taxi, subway, attraction, shopping, block, bus, ride, metro, mall, bus stop, downtown, park, theater, strip, district, museum, transportation, quarter, tourist interest, heart, trolley, middle

**Tabel 3.6** Tabel Contoh Hasil Perhitungan *Similarity* untuk Setiap Aspect

Term	Cleanliness	Comfort	Service	Food	Location
Spacious	0.576	0.423	0.504	0.370	0.625
Room	0.400	0.845	0.760	0.300	0.534
Comfort	0.311	0.612	0.423	0.676	0.620
Rerata	0.429	<b>0.627</b>	0.562	0.447	0.593

Hasil rerata tertinggi adalah pada topic kenyamanan (*comfort*), sehingga dapat disimpulkan bahwa contoh ini merupakan review yang membahas mengenai kenyamanan (*comfort*).

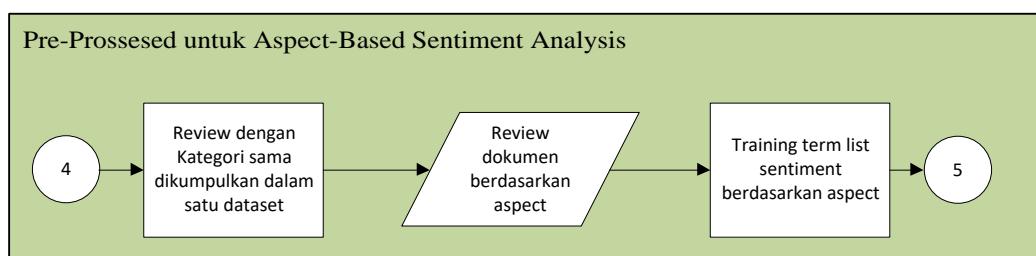
### 3.2.4.2. Aspect Categorization (AC) 2

Aspect Categorization (AC) 2 memiliki metode dan proses yang sama dengan AC1. Namun, term list yang digunakan untuk melakukan *Semantic Similarity* pada proses AC2 tidak hanya menggunakan *term list* pada “Tabel 2.1” tetapi ditambahkan data dari *Expanded Term list* TF-ICF 20%.

### 3.2.4.3. Aspect Categorization (AC) 3

Penambahan *Expanded Term List* dengan menggunakan *Term Frequency-Inverse Document Frequency* (TF-ICF) 20% pada AC2 ditemukan memiliki hasil yang lebih baik dibandingkan dengan hanya menggunakan *term list* yang terdapat pada “Tabel 2.1” pada AC1. Sehingga pada *Aspect Categorization* (AC) 3 dilakukan dengan menghitung nilai *similaritas* antara hidden topic dengan data pada “Tabel 3.3 Tabel Keyword Term List + Hasil TF-ICF terkait Aspect” (penambahan *Expanded Term List* menggunakan TF-ICF yang mencapai 100%).

## 3.2.5 Pre-Proses Untuk Klasifikasi Sentiment Berdasarkan Aspect



Gambar 3.5 Pre-Proses Klasifikasi Sentiment berdasarkan Aspect

Pada tahap ini, data hasil *Aspect Categorization* (ilustrasi pada Tabel 3.7) akan dikumpulkan berdasarkan kategori aspect yang sama (ilustrasi pada Tabel 3.8 dan Tabel 3.9). Setelah itu, dilakukan *training* untuk mendapatkan *term list sentiment* dari setiap aspect. *Training* data dilakukan dengan melabeli setiap data

dengan *sentiment* yang diinginkan untuk data tersebut. *Training* data dilakukan untuk melatih data review pada setiap aspect pada *positive* atau *negative sentiment*. Pelabelan *sentiment* untuk *training* dilakukan oleh annotator.

**Tabel 3.7** Contoh Ilustrasi Hasil Aspect Categorization

No.	Review	Aspect
1.	“Spacious”, “Room”, “Comfort”	Comfort
2.	“Excellent”, “Breakfast”, “Buffet”, “Variety”	Meal

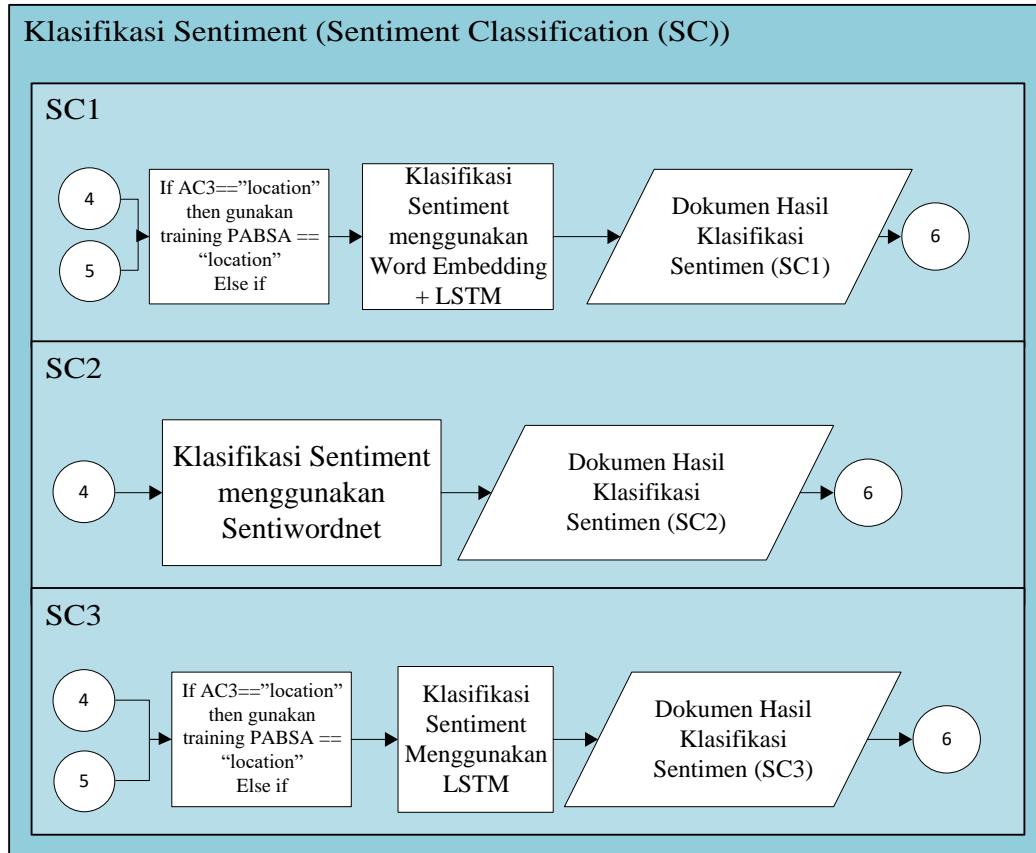
**Tabel 3.8** Contoh Data Aspect-Based Sentiment (Aspect *Comfort*)

No.	Review	Aspect	Sentiment
1.	“Spacious”, “Room”, “Comfort”	Comfort	Positive

**Tabel 3.9** Contoh Data Aspect-Based Sentiment (Aspect *Meal*)

No.	Review	Aspect	Sentiment
1.	“Excellent”, “Breakfast”, “Buffet”, “Variety”	Meal	Positive

### 3.2.6 Proses Klasifikasi Sentimen



**Gambar 3.6** Proses Klasifikasi Sentimen

Klasifikasi Sentimen dilakukan setelah didapatkan hasil dari kategorisasi aspect yang kemudian diolah dalam proses “3.2.5. Pre-Proses Untuk Klasifikasi Sentiment Berdasarkan Aspect”. Hal ini dilakukan untuk mendapatkan *training term list positive* dan *negative sentiment* pada masing-masing aspect. Sehingga pada proses ini, data *testing* akan diklasifikasikan dengan mengacu pada *training term list aspect* yang dibawanya. Misalkan data *training* yang akan diklasifikasikan memiliki aspect *location*, maka proses klasifikasi akan mengacu pada *training term list positive* dan *negative* pada aspect *location* juga.

Percobaan untuk mencari performa *Sentiment Classification* (SC) terbaik, dilakukan dengan: SC1 yang akan menggunakan *Word Embedding* untuk memperoleh nilai *vector* setiap kata. Hasil *word embedding* kemudian diproses dengan menggunakan *Long Short Term Memory* (LSTM) untuk mengklasifikasikan setiap kalimat pada sentiment; SC2 = SC1 namun proses

klasifikasi akan menggunakan Sentiwordnet; dan SC3 = SC1 klasifikasi akan menggunakan *Long Short Term Memory* (LSTM).

Hal ini seperti yang telah digambarkan pada Gambar 3.6 mengenai proses Klasifikasi Sentiment. Penjabaran tentang metode yang digunakan untuk analisa sentimen dapat dilihat sebagai berikut:

### 3.2.5.1.Sentiment Classification (SC) 1

Untuk setiap proses analisa sentiment dilakukan dengan:

*Pseudocode Sentimen Classification (SC) 1*

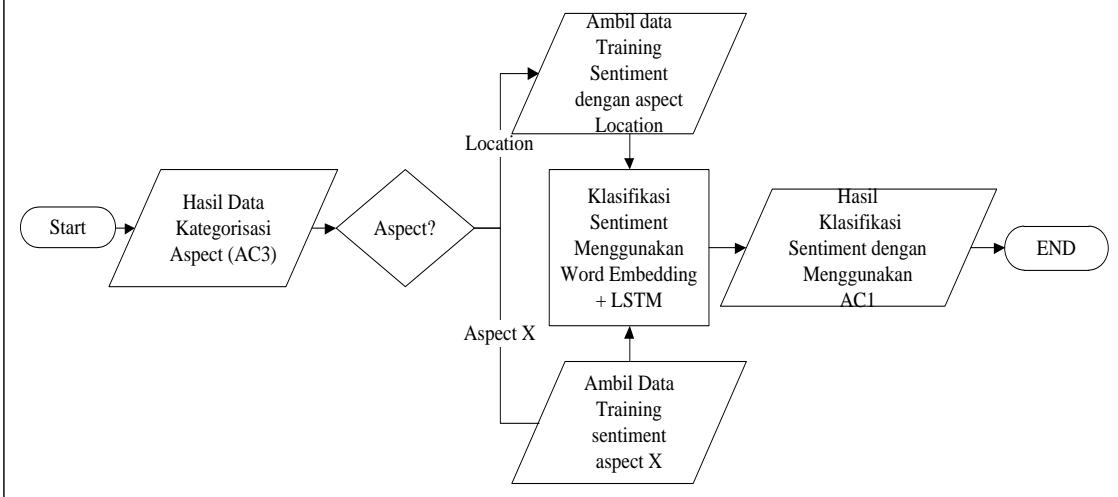
Start

1. Ambil data hasil kategorisasi aspect hotel yang telah dicari sebelumnya.
2. Kumpulkan review dengan kategori aspect yang sama.
3. Lakukan klasifikasi sentiment berdasarkan data training sentiment yang memiliki aspect yang sama.
4. Peneliti melakukan *Word Embedding* untuk mengekstraksi setiap kata menjadi vektor kata dan melakukan *expand term list*.
5. Lakukan klasifikasi sentimen menggunakan persamaan 2.9 hingga 2.14 *Long Short Term Memory* (LSTM).
6. Tampilkan hasil analisa *sentiment Positive* atau *Negative* dari setiap review yang dianalisa.

End.

Dalam melakukan Klasifikasi Sentiment, peneliti melakukan detail proses sebagai berikut:

Contoh untuk Klasifikasi Sentiment pada Review dengan Aspect “Lokasi” menggunakan SC1



**Gambar 3.7** Contoh data Klasifikasi Sentiment dengan Aspect “*Location*” Menggunakan “SC1”

Untuk melakukan klasifikasi sentiment pada SC1, peneliti melakukan tahapan sebagai berikut:

#### A. Word Embedding (Word + Topic Vector Learning)

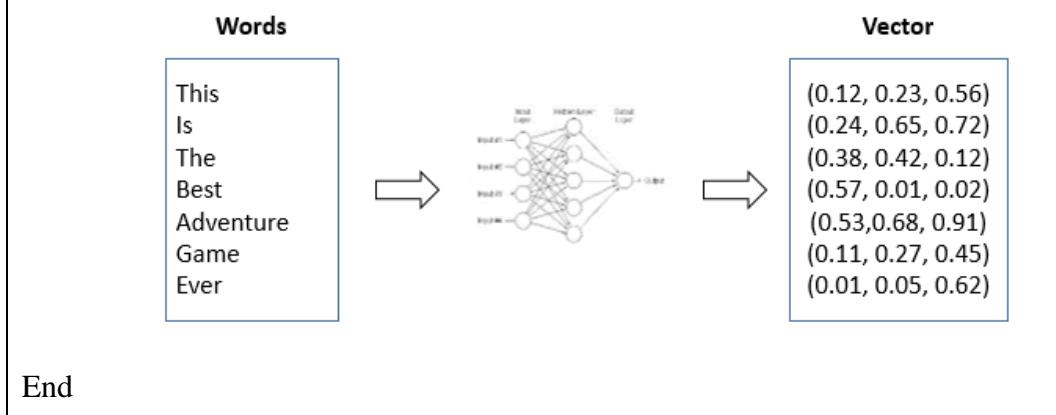
Sub modul ini berfungsi untuk menghasilkan nilai fitur yang digunakan pada proses klasifikasi. Pada modul ini setiap dokumen akan diproses menjadi *word vector*. *Input* dari proses ini adalah hasil dari proses kategorisasi aspect. Adapun *word embedding* yang digunakan adalah GloVe. Tensorflow digunakan untuk mengimplementasikan model *Neural Network* yang digunakan. Secara umum terdapat beberapa langkah untuk memperoleh *word vector*, proses terdiri dari dua langkah, yaitu:

#### Pseudocode Ilustrasi Word Embedding

Start

1. Untuk setiap dokumen review akan dilatih dengan menggunakan model *neural network* untuk memaksimalkan kemungkinan kondisional dari konteks kata yang diberikan.

2. Terapkan model ke setiap kata untuk memperoleh *corresponding vector*



Pada proses implementasi, GloVe dijalankan dengan menggunakan bantuan *library tensorflow* yang merupakan *library open source* untuk menyelesaikan permasalahan di sektor kecerdasan buatan dan Keras yang merupakan *library model* dari *neural network*.

### B. Long short Term Memmory (LSTM)

Sebelum memasukkan data ke model *Long Short Term Memmory* (LSTM), data perlu dikonversi dari kata menjadi angka agar dapat dipahami oleh *Long Short Term Memmory* (LSTM). Hal itu yang menyebabkan penulis menggunakan *word embedding* untuk menemukan *vector* angka serta untuk menjadi kakas bantu dalam melakukan *expand term list* saat *training* data dan saat klasifikasi. Setelah memperoleh nilai vektor yang digunakan sebagai fitur pada proses klasifikasi, selanjutnya *Long Short Term Memmory* (LSTM) digunakan sebagai metode klasifikasi. Pada penelitian ini, dokumen diklasifikasi apakah termasuk klaster tertentu atau tidak. Hal ini dikenal dengan nama *binary classification*.

*Output* dari proses ini adalah klasifikasi dengan menggunakan teknik *binary classification* dengan data yang telah diproses dengan menggunakan *word embedding*. Contoh hasil dari klasifikasi Sentiment menggunakan *Word Embedding + Long Short Term Memmory* (LSTM) dapat dilihat pada tabel 3.10 berikut:

**Tabel 3.10** Contoh Hasil Klasifikasi Sentiment menggunakan *Word Embedding + Long Short Term Memmory (LSTM)*

No.	AC3 Data	Aspect	Score Sentiment	
			Positive	Negative
1	<b>Review x</b>	Comfort	0.875	0.223
2	<b>Review y</b>	Meal	0.984	0.023

Hasil dari klasifikasi sentiment menggunakan *Word Embedding + LSTM* adalah *score sentiment* dengan angka *positive* atau *negative* seperti pada Tabel 3.10. Skor *sentiment* tertinggi akan menjadi *sentiment* dari review yang dianalisa tersebut.

### 3.2.5.2.Sentiment Classification (SC) 2

Dalam penelitian ini, penulis mencoba membandingkan dua metode umum yang biasanya digunakan untuk evaluasi sentiment. Salah satunya adalah dengan menggunakan *Long Short Term Memmory (LSTM)* dan dengan menggunakan Sentiwordnet. Dimana sentiwordnet merupakan *lexical resource* untuk penggalian opini, di dalam Sentiwordnet terdapat 3 pembobotan untuk setiap kata yang bersifat *subjective*, 3 pembobotan tersebut adalah *positive*, *negative* dan *objective* (Kim, 2018) dan (Suhariyanto, Sarno, & Firmanto, 2018). Dalam penelitian ini, Sentiwordnet yang digunakan adalah Sentiwordnet versi 3.0 dimana ini adalah versi yang disempurnakan dan ditingkatkan lebih dari 19% dari versi lamanya (AL-Sharuee, Liu, & Pratama, 2018). Metode sentiwordnet ini juga merupakan metode yang baik untuk melakukan analisa sentiment.

Sentiwordnet memiliki polaritas yang mencegah “*over-fitting*”, istilah ini dapat terjadi ketika harus dilakukan pembobotan kata-kata dalam satu set dokumen tertentu dan kemudian mengarah pada kinerja yang buruk pada uji dataset. *Polaritas synset* dapat dihitung sebagai berikut:

$$Pt,swn = SS_{pos} - SS_{neg} \quad (3.3)$$

SS = Skor dari synet yang didefinisikan dalam Sentiwordnet

Hasil dari SC2 juga akan berupa score positive atau negative seperti pada “Tabel 3.10”. Proses dalam SentiWordNet akan melakukan beberapa hal berikut:

#### *Pseudocode* Proses SentiWordNet

Start

1. Get\_Score (“SentiWordNet\_3.0.0\_20130122.txt”)
2. Ambil data PosScore (Positive Score)
3. Ambil data NegScore (Negative Score)
4. Dari data review yang dianalisa jumlahkan Total Positive Score
5. Dari data review yang dianalisa jumlahkan Total Negative Score
6. Lakukan rumus 3.3 pada Sentiment Classification SC2
7. if totalpositive > totalnegative; print ("Positive"); print ("Positive value : ",totalpositive)
8. else; print ("Negative"); print ("Negative value : ",totalnegative)

End

#### **3.2.5.3.Sentiment Classification (SC) 3**

Proses SC3 akan sama dengan SC1. Namun proses klasifikasi Sentiment akan menggunakan *Long Short Term Memmory* (LSTM). Pada proses implementasinya, *Long Short Term Memmory* (LSTM) akan dibantu oleh Word2Vec untuk merepresentasikan kata menjadi angka *vector*. Word2Vec akan dijalankan dengan menggunakan bantuan *library tensorflow* yang merupakan *library open source* untuk menyelesaikan permasalahan di sektor kecerdasan buatan dan Keras yang merupakan *library model* dari *neural network*.

#### **3.2.7 Evaluasi**

Evaluasi dilakukan dengan membandingkan beberapa performa untuk *Aspect Categorization* Perfoma kategorisasi aspect dengan:

**Aspect Categorization 1 (AC1):** menggabungkan *Latent Dirichlet Allocation* (LDA) dengan *Semantic Similarity* yang dimana *term* untuk *similarity* telah ditentukan pada “Tabel 2.1 *Keyword Topic Term* Terkait Aspect yang Diperoleh”;

**Aspect Categorization 2 (AC2):** menggabungkan *Latent Dirichlet Allocation* (LDA) + *Semantic Similarity* menggunakan *term list* pada “Tabel 2.1” ditambahkan data dari Expanded Term list *Term Frequency-Inverse Document Frequency* (TF-ICF) 20%;

**Aspect Categorization 3 (AC3):** menggabungkan *Latent Dirichlet Allocation* (LDA) + *Semantic Similarity* menggunakan *term list* pada “Tabel 2.1” + data dari Expanded Term list *Term Frequency-Inverse Document Frequency* (TF-ICF) 100% atau data term list yang terdapat pada “Tabel 3.3 Tabel Keyword Term List + Hasil TF-ICF terkait Aspect”.

Kemudian *Sentiment Classification* dengan:

**Sentiment Classification 1 (SC1):** melakukan klasifikasi sentiment dengan menggunakan *Word Embedding* + *Long Short Term Memory* (LSTM);

**Sentiment Classification 2 (SC2):** klasifikasi sentiment dengan menggunakan Sentiwordnet (SC2); dan

**Sentiment Classification 3 (SC3):** klasifikasi sentiment dengan menggunakan *Long Short Term Memory* (LSTM).

Masing-masing performa akan dievaluasi dengan menggunakan: *Precision*, *Recall* dan *F1 Measure*. Dimana, rumus dari setiap metode dapat dilihat pada formulasi 2.15, 2.16 dan 2.17 pada evaluasi.

*[Halaman ini sengaja dikosongkan]*

## **BAB 4**

### **HASIL DAN PEMBAHASAN**

Pada bab ini, akan diberikan pemaparan mengenai hasil implementasi system serta pengujian dari metode yang digunakan dengan menggunakan pembahasan yang telah dituliskan pada Bab 3. Proses implementasi akan dilakukan berdasarkan tahapan yang telah diberikan sebelumnya. Selanjutnya pengujian performa metode akan dilakukan dengan beberapa kondisi yang telah disebutkan pada setiap evaluasi. Dari pengujian performa yang didapatkan, selanjutnya akan diambil performa terbaik untuk melakukan tahap akhir yakni mendapatkan kesimpulan yang telah disampaikan pada tujuan.

#### **4.1. Implementasi Sistem**

##### **4.1.1. Data Text Review Hotel**

Data *text review* hotel yang akan digunakan untuk dianalisa telah ditentukan oleh penulis sebelumnya adalah data hotel mahattan. Data review yang dianalisa akan berjumlah 529 data. Data text review hotel ini kemudian akan dicrawling menggunakan WebHarvy. Data hasil *crawling* yang akan dilakukan analisa oleh penulis dapat dilihat pada gambar 4.1 berikut:

Reviewer Name	Review
Malouh K	I can hear bass sound ?
Lisa A	They like grilled bass
Sara B	Very clear sound a bathtub and easy to use ??
Cast López	A little fresh air might clear some of the cobwebs.
HLH	It was clear that he do not understand what i am said but also what i wished to very poor service!!! disappointing
italgall510	Very awesome and polite made sure we had everything we needed and even got us an early check-in. They gave us ideas on tourist activities we could partake in for our stay we even got gift bags over all i loved it will visits again
travellerhappy087	Excellent service! Got our room early! Very friendly and gave us great advice about the city as hotel! Room is beautiful! Would definitely recommend this hotel and Allison and Alam were very nice and informative
Phil L	awful. we were ignored by the reception staff, the rooms were little more basic than we expected and the price we paid did not even include breakfast the next day.? Could not wait to leave the next day!
janinedouglas26	made sure we was in our room before the 4 PM check-in which was Awesome!! . the location of this hotel is right of this hotel is right where u want to be!!

**Gambar 4.1** Contoh data hasil *crawling*

Pada implementasinya, hasil *crawling* setiap review akan dipecah per kalimat berdasarkan titik. Hal tersebut berdasarkan pertimbangan bahwa suatu review mungkin mengandung lebih dari satu aspect. Data ini kemudian akan disimpan dalam *text review* hotel DB agar nantinya dapat diproses pada langkah selanjutnya. Pemecahan setiap kalimat telah dijelaskan sebelumnya pada BAB 3 point “3.2.1 Data Text Review Hotel”. Setiap dokumen *text review* akan disimpan ke dalam *database* dengan identifier IDReview dan IDKalimat.

Hasil dari pemecahan setiap kalimat akan digambarkan pada 4.2 Data *Text Review* Hotel.

IDReview	IDKalimat	Review
1	1	I can hear bass sound ?
2	2	They like grilled bass
3	3	Very clear sound a bathtub and easy to use ??
4	4	A little fresh air might clear some of the cobwebs.
5	5	It was clear that he do not understand what i am said but also what i wished to very poor service!!! disappointing
6	6	Very awesome and polite made sure we had everything we needed and even got us an early check-in.
7	6	They gave us ideas on tourist activities we could partake in for our stay we even got gift bags over all i loved it will visits again
8	7	Excellent service! Got our room early! Very friendly and gave us great advice about the city as hotel! Room is beautiful! Would definitely recommend this hotel and Allison and Alam were very nice and informative
9	8	To summarise this stay during our visit to New York in September, it was truly overly expensive
10	8	the service at reception was awful, we were ignored by the reception staff, the rooms were little more basic than we expected and the price we paid did not even include breakfast the next day.?
11	8	Could not wait to leave the next day!
12	9	First let me say this hotel smelled sooo good when you walk in!
13	9	Second the service was AMAZING!! Especially Alam and Allison,they made sure we was in our room before the 4 PM check-in which was Awesome!! And
14	9	the location of this hotel is right of this hotel is right where u want to be!!
15	9	Definitely will stay here again! Thanks again Alam and Allison!

**Gambar 4.2** Data *Text Review* Hotel

Data *text review* hotel ini akan juga akan di proses untuk pelabelan yang akan dilakukan oleh anotator. *Dataset* pada proses pelabelan ini bertugas untuk membuat *ground truth* setiap dokumen.

#### 4.1.2. Pre-Processing Data

*Preprocessing* data akan mengambil data yang direpresentasikan pada Gambar 4.2 Data *Text Review* Hotel. Data tersebut kemudian diproses dengan

menggunakan *pseudocode preprocessing* data yang terdapat pada BAB 3 point “3.2.2 Pre-Processing”. Proses ini diharapkan dapat menghilangkan *noise* pada dokumen *review* saat proses klasifikasi.

Hasil akhir dari tahap *preprocessing* dengan menggunakan data penelitian (Gambar 4.2 Data *Text Review Hotel*) akan mendapatkan hasil sebagai berikut:

**Tabel 4.1** Hasil *Pre-processing* untuk Masukan Proses Klasifikasi

Review	Hasil Pre-processing	Label Anotator
Review 1	'bass', 'hear', 'sound'	<i>Comfort</i>
Review 2	'bass', 'like', 'grill'	<i>Meal</i>
Review 3	'sound', 'bathtub', 'clear', 'easy', 'use', 'very'	<i>Comfort</i>
Review 4	'clear', 'air', 'fresh', 'little', 'might', 'some'	<i>Comfort</i>
Review 5	'clear', 'very', 'but', 'disappoint', 'do', 'poor', 'say', 'service', 'understand', 'wish'	<i>Service</i>
Review 6	'very', 'awesome', 'polite', 'make', 'sure', 'we', 'have', 'everything', 'need', 'get', 'us', 'early'	<i>Service</i>

Hasil dari *preprocessing* ini kemudian akan menjadi masukan untuk proses kategorisasi. Label annotator diberikan secara manual oleh annotator dan akan dijadikan *ground truth* pada saat evaluasi akhir. Annotator yang terdaftar dalam pembuatan *ground truth* terdiri dari 3 orang. Sehingga *ground truth* yang diberikan berdasarkan hasil pemikiran, diskusi dan kesimpulan dari ketiganya. Label annotator yang diberikan berupa label aspect maupun label sentiment pada setiap review.

#### 4.1.3. Expanding Term List

Modul ini digunakan untuk mengatasi keterbatasan dari *term* yang telah didefinisikan sebelumnya (Tabel 2.1 *Keyword Term List* Terkait Aspect yang Diperoleh). Proses ini bertugas untuk menemukan term-term yang merepresentasikan setiap aspect dokumen. Data yang akan digunakan untuk

melakukan proses ini adalah 80% dari data hasil *preprocessing* “Tabel 4.1 Hasil *Pre-processing* untuk Masukan Proses Klasifikasi”. Hasil dari modul *Expanding Term List* ini akan digunakan dalam proses perhitungan *Semantic Similarity*.

Proses *expanding term list* dengan menggunakan *Term Frequency-Inverse Document Frequency* (TF-IDF) akan dilakukan mengikuti *pseudocode* proses *Term Frequency-Inverse Document Frequency* (TF-IDF) yang telah dijelaskan pada BAB 3 point “3.2.3. Modul Perluasan *Term List* (*Expanding Term List*)”. Penjabarannya, akan dijelaskan sebagai berikut:

### Perhitungan *Term Frequency* (TF)

Proses yang pertama kali dijalankan dalam proses ini adalah membentuk kamus kata yang berisi kata-kata unik pada *corpus* dokumen. Proses pembentukan kamus ini, tidak memperhatikan kata henti. Kata-kata unik ini selanjutnya dihitung kemunculannya tiap dokumen pada klaster yang sama. Oleh karena itu, masing-masing kelas memungkinkan memiliki nilai *term* frekuensi yang berbeda. Adapun contoh hasil dari tahap ini dicontohkan pada tabel 4.2.

Dalam menghitung nilai TF, dilakukan:

```
def computeTF(wordDict, bow, cluster):  
    tfDict = {}  
    #bowCount = len(bow)  
    for word, count in wordDict.items():  
        #tfDict[word] = count / float(bowCount)  
        tfDict[word] = count  
  
        if cluster == 1:  
            sqlUpdate = "update tf_icf SET tf1 =" + str(count) + "  
WHERE term = '" + str(word) + "'"  
        elif cluster == 2:  
            sqlUpdate = "update tf_icf SET tf2 =" + str(count) + "  
WHERE term = '" + str(word) + "'"  
        elif cluster == 3:  
            sqlUpdate = "update tf_icf SET tf3 =" + str(count) + "  
WHERE term = '" + str(word) + "'"
```

```

        elif cluster == 4:
            sqlUpdate = "update tf_icf SET tf4 =" + str(count) +
WHERE term = ' "+str(word)+" '"
        elif cluster == 5:
            sqlUpdate = "update tf_icf SET tf5 =" + str(count) +
WHERE term = ' "+str(word)+" '"

        cursor.execute(sqlUpdate)
        db.commit()

    return tfDict

```

**Tabel 4.2** Contoh Hasil Perhitungan *Term Frequency*

idterm	term	TF1	TF2	TF3	TF4	TF5
1	excellent	1	0	3	0	0
2	the	6	1	14	12	4
3	hotel	2	0	3	2	0
4	well	1	0	0	0	0
5	locate	3	0	0	0	0
6	look	2	0	2	2	0
7	nice	1	0	0	0	1

Tabel 4.2 TF1 menunjukkan jumlah kemunculan *term* pada *cluster* 1, TF2 pada *cluster* 2 begitu seterusnya hingga TF5 yang menunjukkan jumlah kemunculan term pada *cluster* 5. Sehingga, dari hasil dapat disimpulkan bahwa pada idterm 1 untuk term “*excellent*” muncul satu kali pada TF1 (*Aspect Location*) dan muncul nol kali pada aspect lainnya. Dari tabel hasil pula dapat disimpulkan bahwa pada idterm 2 untuk term “*the*” muncul enam kali pada TF1 (*Aspect Location*), satu kali pada TF2 (*Aspect Meal*), empat-belas kali pada TF3 (*Aspect Service*), dua-belas kali pada TF4 (*Aspect Comfort*), dan empat kali pada TF5 (*Aspect Cleanliness*),

## Perhitungan *Inverse Cluster Frequency* (ICF)

Proses ini akan menghitung nilai dari *Inverse Cluster Frequency* (ICF) yang mempertimbangkan kemunculan dari setiap term pada cluster berdasarkan fungsi logaritmik. Adapun contoh dari perhitungan *Inverse Cluster Frequency* (ICF) dijelaskan pada tabel 4.3.

Dalam menghitung nilai ICF dilakukan:

```
def computeICF():
    import math
    cursor.execute("select term, tf1, tf2, tf3, tf4, tf5 from
tf_icf")
    documents = cursor.fetchall()

    terms = []
    tf1, tf2, tf3, tf4, tf5 = [], [], [], [], []
    for i in documents:
        terms.append(i[0])
        tf1.append(i[1])
        tf2.append(i[2])
        tf3.append(i[3])
        tf4.append(i[4])
        tf5.append(i[5])

    number = len (terms)

    for i in range (0, number):
        val = 0
        print ("*****")
        print (terms[i])
        if tf1[i] != 0:
            val = val + 1
        else:
            val = val + 0

        if tf2[i] != 0:
            val = val + 1
```

```

else:
    val = val + 0

if tf3[i] != 0:
    val = val + 1
else:
    val = val + 0

if tf4[i] != 0:
    val = val + 1
else:
    val = val + 0

if tf5[i] != 0:
    val = val + 1
else:
    val = val + 0

print (val)
icf = math.log(5 / float(val))
print (icf)
sqlUpdate = "update tf_icf SET icf =" + str(icf) + " WHERE
term = '" + str(terms[i]) + "'"
cursor.execute(sqlUpdate)
db.commit()

```

**Tabel 4.3** Contoh Hasil Perhitungan *Inverse Cluster Frequency* (ICF)

id	term	TF1	TF2	TF3	TF4	TF5	ICF
1	excellent	1	0	3	0	0	0.9162
2	the	6	1	14	12	4	0
3	hotel	2	0	3	2	0	0.5108
4	well	1	0	0	0	0	1.6094
5	locate	3	0	0	0	0	1.6094
6	look	2	0	2	2	0	0.5108

7	nice	1	0	0	0	1	0.9162
---	------	---	---	---	---	---	--------

Tabel 4.3 menunjukkan bahwa ada data yang memiliki nilai *Inverse Cluster Frequency* (ICF) 0. Apabila nilai ICF adalah 0, hal tersebut berarti term tersebut terus muncul di semua klaster. Sehingga ketika fungsi logaritmik menghitung hasil pembagian jumlah klaster dengan klaster kemunculan term, maka akan menghasilkan nilai log (1), yaitu nol. *Inverse Cluster Frequency* (ICF) menunjukkan bahwa semakin sedikit klaster dimana term muncul, maka nilai *Inverse Cluster Frequency* (ICF) akan cenderung besar, seperti pada id 4 dan 5.

### Penentuan Term Penting Tiap Klaster (TF-ICF)

Proses pada tahap ini dimulai dengan menghitung nilai *Term Frequency-Inverse Document Frequency* (TF-ICF) untuk setiap klaster. Selanjutnya proses penentuan term-term penting dipengaruhi oleh nilai *Term Frequency-Inverse Document Frequency* (TF-ICF) yang dihasilkan. Perhitungan dari *Term Frequency-Inverse Document Frequency* (TF-ICF) akan dijelaskan pada Gambar 4.3.

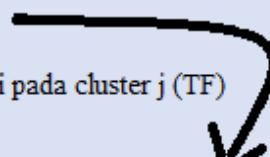
### Contoh Perhitungan TF-ICF

Untuk melakukan perhitungan *Term Frequency-Inverse Document Frequency* (TF-ICF) penulis akan menggunakan rumus yang telah dijelaskan pada BAB 2 pada rumus 2.5.

Rumus:

$$TF - ICF_j = tf_{ji} \times ICF_i$$

$tf_{ji}$  adalah frekuensi atau total term i pada cluster j (TF)  
 $ICF_i$  adalah nilai icf term tersebut



id	term	TF1	TF2	TF3	TF4	TF5	ICF	TF-ICF1	TF-ICF2	TF-ICF3	TF-ICF4	TF-ICF5
1	excellent	1	0	3	0	0	0.9162	0.9162	0	2.7488	0	0

Gambar 4.3 Contoh Perhitungan Manual TF-ICF

Adapun hasil dari perhitungan *Term Frequency-Inverse Document Frequency* (TF-ICF) dijelaskan pada tabel 4.4.

**Tabel 4.4** Hasil Perhitungan TF-ICF

id	term	TF1	TF2	TF3	TF4	TF5	ICF	TF-ICF1	TF-ICF2	TF-ICF3	TF-ICF4	TF-ICF5
1	excellent	1	0	3	0	0	0.9162	0.9162	0	2.7488	0	0
2	the	6	1	14	12	4	0	0	0	0	0	0
3	hotel	2	0	3	2	0	0.5108	1.0216	0	1.5324	1.0216	0
4	well	1	0	0	0	0	1.6094	1.6094	0	0	0	0
5	locate	3	0	0	0	0	1.6094	4.8283	0	0	0	0
6	look	2	0	2	2	0	0.5108	1.0216	0	1.0216	1.0216	0
7	nice	1	0	0	0	1	0.9162	0.9162	0	0	0	0.9162

Keterangan:

TF-ICF1 = *Location* (Lokasi)

TF-ICF2 = *Meal* (Makanan)

TF-ICF3 = *Service* (Pelayanan)

TF-ICF4 = *Comfort* (Kenyamanan)

TF-ICF5 = *Cleanliness* (Kebersihan)

Berdasarkan Tabel 4.4 *Term Frequency-Inverse Document Frequency* (TF-ICF)1 menunjukkan nilai suatu term pada cluster 1, TF-ICF2 menunjukkan nilai suatu term pada cluster 2, dan seterusnya hingga TF-ICF5 menunjukkan nilai suatu term pada cluster 5. Tabel tersebut menunjukkan bahwa nilai frekuensi suatu term di tiap klaster mampu mempengaruhi nilai ICF dalam menghasilkan nilai akhir TF-ICF. Sehingga semakin tinggi nilai frekuensi suatu term, selama nilai ICF nya tidak nol, maka nilai TF-ICF yang dihasilkan semakin besar (Seperti pada id 5). Hal tersebut senada dengan hipotesa peneliti untuk mengambil term-term setiap klaster dengan menggunakan TF-ICF karena semakin term muncul di klaster yang terbatas, maka semakin besar kemungkinan term tersebut mampu merepresentasikan klaster. Sehingga, nilai TF-ICF tertinggi selanjutnya dijadikan sebagai penambahan *term* pada *expanded term* yang akan digunakan untuk melakukan *Semantic Similarity*.

Namun, pada penelitian ini, peneliti melakukan beberapa *justifikasi* terhadap hasil yang diperoleh untuk menentukan *term cluster*, yaitu:

1. *Term* tidak akan digunakan meskipun nilai *Term Frequency-Inverse Document Frequency* (TF-IDF) tinggi jika memiliki nilai yang hampir serupa dengan TF-IDF pada klaster lainnya.  
Hal tersebut berdasarkan pertimbangan bahwa, nilai *Term Frequency-Inverse Document Frequency* (TF-IDF) yang hampir sama antar setiap klaster menunjukkan term tersebut tidak terlalu dapat merepresentasikan klaster nya. Sehingga, hal tersebut memungkinkan bahwa term tersebut muncul di klaster yang berbeda pada saat proses testing
2. *Term* tidak akan digunakan jika mengandung nama produk dari suatu barang atau hotel.  
Hal tersebut berdasarkan pertimbangan bahwa, penggunaan term yang merupakan nama produk akan menyulitkan pada proses hidden topic similarity dan menambah waktu komputasi.

Setiap term penting pada setiap kelas yang ditemukan akan ditambahkan pada “Tabel 2.1 *Keyword Term List* Terkait Aspect yang Diperoleh” sehingga, dihasilkanlah data pada “Table 3.3 Tabel *Keyword Term List* + Hasil TF-IDF terkait Aspect”. Dimana “Tabel 3.3” ini merupakan “Tabel 2.1” yang telah ditambahkan dengan hasil *Term Frequency-Inverse Document Frequency* (TF-IDF) 100%.

#### 4.1.4. Proses Kategorisasi Aspect

Data *review* yang akan diproses merupakan data *review* yang telah melalui proses *preprocessing* “Tabel 4.1 Hasil *Pre-processing* untuk Masukan Proses Klasifikasi”. Proses kategorisasi aspect akan dilakukan sesuai dengan penjelasan pada BAB 3 point “3.2.4 Proses Kategorisasi Aspect”. Proses ini akan membandingkan beberapa metode untuk melakukan kategorisasi aspect. Performa terbaik yang didapatkan dari kategorisasi aspect akan diterapkan. Beberapa metode performa untuk kategorisasi aspect yang dibandingkan adalah sebagai berikut: AC1

akan menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk menghasilkan data *hidden topic*. Data *hidden topic* akan dikalkulasi menggunakan metode *Semantic Similarity* untuk di kategorisasikan kedalam 5 Aspect hotel yang term listnya telah ditentukan dengan menggunakan “Tabel 2.1”;  $AC2 = AC1 + TF-ICF \times 20\%$  dan  $AC3 = AC1 + “Tabel 3.3”$  (atau data dari “Tabel 2.1” +  $TF-ICF \times 100\%$ ). Penjabaran mengenai perbandingan metode kategorisasi aspect akan dijabarkan pada point 4.1.4.1. *Aspect Categorization* (AC) 1 hingga 4.1.4.3. *Aspect Categorization* (AC) 3 dibawah ini.

#### **4.1.4.1. *Aspect Categorization* (AC) 1**

Percobaan pertama AC1 ini dilakukan dengan menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk mencari *hidden topic* kemudian dilakukan *Semantic Similarity* dengan menggunakan data pada “Tabel 2.1” untuk mengkategorisasikan setiap *review*. Kakas bantu yang digunakan untuk melakukan *expand term* dan mengkategorisasikan setiap dokumen adalah WordNet *similarity*. Penjabaran dari AC1 akan dijelaskan pada point “A. *Latent Dirichlet Allocation* (LDA)” dan point “B. Kategorisasi Aspect Menggunakan *Semantic Similarity*”.

##### **A. *Latent Dirichlet Allocation* (LDA)**

Proses untuk mencari *hidden topic* menggunakan metode *Latent Dirichlet Allocation* (LDA) akan dijelaskan pada “*Pseudocode* proses Pencarian *Hidden Topic LDA*” yang terdapat pada BAB 3 Sub bab 3.2.4.1. *Aspect Categorization* (AC) 1 pada point “A. *Latent Dirichelet Allocation* (LDA)”. Pada implementasinya, *Latent Dirichlet Allocation* (LDA) menggunakan *term* frekuensi untuk membangun vektor dari setiap token kata dengan menggunakan modul *CountVectorizer* dan selanjutnya dianalisa dengan menggunakan *Latent Dirichlet Allocation* (LDA) model yang dikonstruksi dengan menggunakan Librari Gensim. Hasil dari *hidden topic* yang telah dihitung menggunakan *Latent Dirichlet Allocation* (LDA) dari masing-masing dokumen review pada data yang menjadi percobaan penelitian akan direpresentasikan pada tabel 4.5:

**Tabel 4.5** Tabel Hasil *Hidden Topic* LDA

Review	Hidden Topic
Review 1	('0.200 * "sound" + 0.200 * "hear" + '0.200 * "bass")
Review 2	('0.200 * "like" + 0.200 * "bass")
Review 3	("0.300 * "sound" + 0.600 * "bathtub" + 0.500 * "clear" + 0.100 * "easy" + 0.100 * "use" + 0.200 * "very")
Review 4	('0.100 * "clear" + 0.200 * "air" + 0.200 * "fresh" + 0.200 * "little" + 0.400 * "might")
Review 5	('0.500 * "clear" + 0.400 * "disappoint" + 0.300 * "poor" + 0.200 * "say" + 0.600 * "service" + 0.300 * "understand" + 0.400 * "wish")

Pada tabel 4.5, angka sebelum kata ('0.200 \* "sound" ) merupakan angka probabilitas kemunculan kata tersebut dalam korpus. Setelah diperoleh *hidden topic* untuk masing-masing dokumen, selanjutnya, hasil *hidden topic* beserta data *term list* dari “Tabel 2.1 *Keyword Term List* Terkait Aspect yang Diperoleh” akan diproses untuk melakukan perhitungan similaritas menggunakan *Semantic Similarity*. Perhitungan ini dilakukan untuk mengkategorikan setiap review pada 5 aspect yang telah ditentukan sebelumnya.

## B. Kategorisasi Aspect Menggunakan Semantic Similarity

Proses similarity merupakan proses terakhir dalam pengklasifikasian aspect. Input dari proses ini adalah data hidden topic yang telah dicari dengan menggunakan metode *Latent Dirichlet Allocation* (LDA). Dimana hasil *hidden topic* ini dapat dilihat pada “Tabel 4.5 Tabel Hasil *Hidden Topic* LDA”. Data tersebut kemudian dihitung menggunakan *Semantic Similarity* dimana data untuk melakukan similaritas didasarkan pada data *term list* yang telah didapatkan “Tabel 2.1 *Keyword Term List* Terkait Aspect yang Diperoleh) untuk mengkategorikan setiap review kepada 5 aspect.

Proses ini akan mengikuti alur pada *pseudocode* proses Kategorisasi Menggunakan *Semantic Similarity* yang telah dijabarkan pada BAB 3 Sub bab 3.2.4.1. *Aspect Categorization* (AC) 1 pada point “B. Kategorisasi Aspect Menggunakan *Semantic Similarity*”. Hasil dari perhitungan kategorisasi aspect AC1 dengan menggunakan *Latent Dirichlet Allocation* (LDA) + *Similarity* pada penelitian adalah sebagai berikut:

Hasil Kategorisasi Aspect yang didapatkan oleh *system* untuk percobaan AC1

```
=====
['bass', 'hear', 'sound']

Final score Aspect LOCATION = 0.069275
Final score Aspect FOOD = 0.09930
Final score Aspect SERVICE = 0.07603
Final score Aspect COMFORT = 0.07907
Final score Aspect CLEANESS = 0.07959

In update lda_category SET location_sim =0.06927540703116151, food_sim
=0.09929927882245172, service_sim =0.07603271384033687, comfort_sim
=0.07906901371575285, cleanliness_sim =0.07959098464272756,
label = 2 WHERE id = '1'

--- DONE ---

=====
['bass', 'like']

Final score Aspect LOCATION = 0.068334
Final score Aspect FOOD = 0.10206
Final score Aspect SERVICE = 0.07486
Final score Aspect COMFORT = 0.07513
Final score Aspect CLEANESS = 0.07830

In update lda_category SET location_sim =0.06833408137755968, food_sim
=0.10206451797360892, service_sim =0.07485579313310407, comfort_sim
=0.0751273183338401, cleanliness_sim =0.07830233491998195,
label = 2 WHERE id = '2'
```

--- DONE ---

---

['sound', 'bathtub', 'clear', 'easy', 'use', 'very']

Final score Aspect LOCATION = 0.055688

Final score Aspect FOOD = 0.06056

Final score Aspect SERVICE = 0.06282

Final score Aspect COMFORT = 0.06447

Final score Aspect CLEANESS = 0.06318

In update lda\_category SET location\_sim =0.05568753619138233, food\_sim  
=0.060557236605959096, service\_sim =0.06281923399470415, comfort\_sim  
=0.06447342921141408, cleanliness\_sim =0.0631791798728288,  
label = 4 WHERE id = '3'

--- DONE ---

---

['clear', 'air', 'fresh', 'little', 'might', 'some']

Final score Aspect LOCATION = 0.020610

Final score Aspect FOOD = 0.02525

Final score Aspect SERVICE = 0.02174

Final score Aspect COMFORT = 0.02369

Final score Aspect CLEANESS = 0.02166

In update lda\_category SET location\_sim =0.02061017057620319, food\_sim  
=0.025249286581357295, service\_sim =0.02173754690761494, comfort\_sim  
=0.023689644862652116, cleanliness\_sim =0.021664603392317627,  
label = 2 WHERE id = '4'

--- DONE ---

---

['clear', 'very', 'but', 'disappoint', 'do', 'poor', 'say', 'service', 'understand', 'wish']

Final score Aspect LOCATION = 0.026282

Final score Aspect FOOD = 0.02491

Final score Aspect SERVICE = 0.03026

Final score Aspect COMFORT = 0.03110

Final score Aspect CLEANESS = 0.02306  
 In update lda\_category SET location\_sim =0.026282157639992754, food\_sim =0.024910695905453837, service\_sim =0.030262191680344653, comfort\_sim =0.031098131208836356, cleanliness\_sim =0.02306414226745692,  
 label = 4 WHERE id = '5'  
 --- DONE ---  
 ======  
 Etc.

Keterangan:

TF-ICF1 = *Location* (Lokasi)  
 TF-ICF2 = *Meal* (Makanan)  
 TF-ICF3 = *Service* (Pelayanan)  
 TF-ICF4 = *Comfort* (Kenyamanan)  
 TF-ICF5 = *Cleanliness* (Kebersihan)

Agar lebih mudah dibaca, penulis merepresentasikan hasil pada tabel 4.6 berikut:

**Tabel 4.6** Tabel Hasil Perhitungan LDA + Semantic Similarity AC1

Review	Aspect 1	Aspect 2	Aspect 3	Aspect 4	Aspect 5	Label	Label Annotator
	Location	Food	Service	Comfort	Cleaness		
["Sound", "Hear", "Bass"]	0.069	<b>0.099</b>	0.076	0.079	0.079	Meal	Comfort
["Like", "Bass"].	0.068	<b>0.102</b>	0.074	0.075	0.078	Meal	Meal
["Sound", "Bathtub", "Clear", "Easy", "Use"]	0.055	0.060	0.062	<b>0.064</b>	0.063	Comfort	Comfort
["clear", "air", "fresh", "little", "might"]	0.020	<b>0.025</b>	0.021	0.23	0.021	Meal	Comfort
['clear', 'very', 'but', 'disappoint', 'do', 'poor', 'say', 'service', 'understand', 'wish']	0.26	0.024	0.030	<b>0.031</b>	0.023	Comfort	Service

\*Warna merah adalah kesalahan sistem dalam melakukan kategorisasi

Dari tabel 4.6 dapat dilihat bahwa, untuk review 1, angka paling mendekati nilai “1” berada pada aspect 2 (angka bold) yakni “meal”, sedangkan data pada

review 1 pada “Tabel 4.1” kolom data annotator seharusnya masuk kedalam aspect “*comfort*”, sehingga dapat disimpulkan bahwa kategori yang diberikan pada data review 1 adalah kesalahan kategorisasi. Kemudian pada review 2 didapatkan angka terbesar pada aspect 2 atau meal, annotator pada “Tabel 4.1” juga memberikan review 2 aspect “*meal*”, sehingga kategorisasi pada review 2 adalah benar. Serta pada review 3 yang mendapatkan aspect “*comfort*”, label yang sama dengan yang diberikan oleh annotator pada review 3. Review 4 memiliki kesalahan kategorisasi lagi, karena pada hasil review 4 menunjukkan bahwa review tersebut masuk kedalam aspect “*meal*”, sedangkan seharusnya pada aspect “*comfort*”. Review 5 memiliki hasil yang sesuai dengan annotator yakni kategori “*service*”. Kesalahan dalam kategorisasi aspect ini dikarenakan model yang digunakan hanya memperhatikan aspect similaritas terhadap term yang telah didefinisikan sebelumnya, maka review tersebut diprediksi menjadi aspect yang salah.

Setelah proses ini, setiap review akan memiliki label dari proses kategorisasi yang telah dilakukan dengan menggunakan metode AC1. Dengan demikian, berarti setiap review akan memiliki salah satu aspect dari 5 aspect hotel yakni *Location* atau *meal* atau *service* atau *comfort* atau *cleanliness*. Hasil setelah tahap ini akan dievaluasi untuk dihitung berapa besar persentase performa yang dihasilkan. Evaluasi dilakukan dengan membandingkan data kategorisasi aspect yang dihasilkan oleh system dengan ground truth yang diberikan oleh annotator pada setiap dokumen review. Evaluasi akan dilakukan dengan mencari *Precision*, *Recall* dan *F1 measure* yang rumusnya dapat dilihat pada 2.15, 2.16 dan 2.17.

Kesimpulan dari AC1 adalah: kategorisasi aspect dengan cara ini tidaklah mendapatkan hasil yang baik. Hasil evaluasi dengan menggunakan metode ini hanya mencapai 0.608 atau 61% (hasil akan dijabarkan lebih lanjut pada point “4.2 Hasil Pengujian Dan Evaluasi”). Sehingga diusulkan pendekatan metode dengan cara lain, dimana akan dijelaskan pada Aspect Categorization (AC) 2 dan Aspect Categorization (AC) 3.

#### **4.1.4.2.Aspect Categorization (AC) 2**

Proses kategorisasi pada percobaan kedua, AC2 ini dilakukan dengan menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk mencari *hidden*

*topic* kemudian dilakukan *Semantic Similarity* dengan menggunakan data pada “Tabel 2.1” ditambah dengan *term* yang telah didapatkan menggunakan *Term Frequency-Inverse Document Frequency* (TF-IDF) 20% “Tabel 4.4 Hasil Perhitungan TF-IDF” untuk mengkategorisasikan setiap review.

Penambahan Expanding Term List *Term Frequency-Inverse Document Frequency* (TF-IDF) ini merupakan perbedaan dari AC2 dengan AC1, dengan penambahan diharapkan dapat meningkatkan performa dalam pengukuran similarity. *Expanding term list* yang akan digunakan adalah 20% dari total *synonym*. Kakas bantu yang digunakan untuk melakukan *expand term* dan mengkategorisasikan setiap dokumen adalah WordNet *similarity*. Penjabaran dari AC2 akan mirip seperti pada AC1 yang dijelaskan pada point “A. Latent Dirichlet Allocation (LDA)” dan point “B. Kategorisasi Aspect Menggunakan Semantic Similarity”. Namun pada point B. Kategorisasi Aspect Menggunakan Semantic Similarity AC2 akan menambahkan data dari *Expanding Term List* (TF-IDF) 20%. Hasil dari perhitungan kategorisasi aspect AC2 dengan menggunakan *Latent Dirichlet Allocation* (LDA) + *Similarity* pada penelitian adalah sebagai berikut:

Hasil Kategorisasi Aspect yang didapatkan oleh system untuk percobaan AC2

```
[bass', 'hear', 'sound']

Final score Aspect LOCATION = 0.067928
Final score Aspect FOOD = 0.078522
Final score Aspect SERVICE = 0.07377
Final score Aspect COMFORT = 0.09643
Final score Aspect CLEANESS = 0.07286

In update lda_category SET location_sim =0.06792820149221535, food_sim
=0.07852235900073268, service_sim =0.07376927983879854, comfort_sim
=0.0964279701779702, cleanliness_sim =0.07285893522276966,           label
= 4 WHERE id = '1'

--- DONE ---

=====
[bass', 'like']
```

```
Final score Aspect LOCATION = 0.067012
Final score Aspect FOOD = 0.09920
Final score Aspect SERVICE = 0.07263
Final score Aspect COMFORT = 0.07479
Final score Aspect CLEANESS = 0.07170
In update lda_category SET location_sim =0.06701196407078765, food_sim
=0.09920267640855876, service_sim =0.07262970095857799, comfort_sim
=0.07478993228993232, cleanliness_sim =0.07169755625637977,           label
= 2 WHERE id = '2'
--- DONE ---

=====
['sound', 'bathtub', 'clear', 'easy', 'use', 'very']

Final score Aspect LOCATION = 0.055487
Final score Aspect FOOD = 0.05857
Final score Aspect SERVICE = 0.06124
Final score Aspect COMFORT = 0.06429
Final score Aspect CLEANESS = 0.05793
In update lda_category SET location_sim =0.055486705829299265, food_sim
=0.05856863105709701, service_sim =0.06123517588323735, comfort_sim
=0.06428763171741113, cleanliness_sim =0.05793487072941833,           label
= 4 WHERE id = '3'
--- DONE ---

=====
['clear', 'air', 'fresh', 'little', 'might', 'some']

Final score Aspect LOCATION = 0.020890
Final score Aspect FOOD = 0.02472
Final score Aspect SERVICE = 0.02069
Final score Aspect COMFORT = 0.02392
Final score Aspect CLEANESS = 0.01989
In update lda_category SET location_sim =0.02088956681481192, food_sim
=0.024722256002893267, service_sim =0.020688285479952148, comfort_sim
```

```

=0.02391801870968538, cleanliness_sim =0.019887573837510292,           label
= 2 WHERE id = '4'

--- DONE ---

=====
['clear', 'very', 'but', 'disappoint', 'do', 'poor', 'say', 'service', 'understand', 'wish']

Final score Aspect LOCATION = 0.026506
Final score Aspect FOOD = 0.02514
Final score Aspect SERVICE = 0.03131
Final score Aspect COMFORT = 0.02988
Final score Aspect CLEANNESS = 0.02564

In update lda_category SET location_sim =0.026505800530584572, food_sim
=0.02513613586424125, service_sim =0.03131093959021765, comfort_sim
=0.02988081460167593, cleanliness_sim =0.02564252097713814,           label
= 3 WHERE id = '5'

--- DONE ---

=====
Etc.

```

Keterangan:

- TF-ICF1 = *Location* (Lokasi)
- TF-ICF2 = *Meal* (Makanan)
- TF-ICF3 = *Service* (Pelayanan)
- TF-ICF4 = *Comfort* (Kenyamanan)
- TF-ICF5 = *Cleanliness* (Kebersihan)

Agar lebih mudah dibaca, penulis merepresentasikan hasil pada tabel 4.7 berikut:

**Tabel 4.7** Tabel Hasil Perhitungan LDA + Semantic Similarity AC2

Review	Aspect 1	Aspect 2	Aspect 3	Aspect 4	Aspect 5	Label	Label Anotator
	Location	Food	Service	Comfort	Cleaness		
["Sound", "Hear", "Bass"]	0.067	0.078	0.073	0. 096	0.072	Comfort	Comfort
["Like", "Bass"].	0.067	<b>0.99</b>	0.072	0.074	0.071	Meal	Meal

["Sound", "Bathtub", "Clear", "Easy", "Use"]	0.055	0.058	0.061	<b>0.064</b>	0.067	Comfort	Comfort
["clear", "air", "fresh", "little", "might"]	0.020	<b>0.024</b>	0.020	0.23	0.019	Meal	Comfort
['clear', 'very', 'but', 'disappoint', 'do', 'poor', 'say', 'service', 'understand', 'wish']	0.26	0.025	<b>0.031</b>	0.029	0.025	Service	Service

\* Warna merah adalah kesalahan sistem dalam melakukan kategorisasi

Kesalahan dalam proses kategorisasi terdapat pada review ke-4, dimana aspect seharusnya adalah “comfort”, namun dengan menggunakan metode pada tahap ini, review-4 terdeteksi sebagai aspect “meal”. Kesalahan dalam kategorisasi aspect ini dikarenakan model yang digunakan hanya memperhatikan aspect similaritas terhadap term yang telah didefinisikan sebelumnya, maka review tersebut diprediksi menjadi aspect yang salah. Setelah melakukan kategorisasi dengan menggunakan tahapan pada AC2, hasil kemudian akan dievaluasi untuk diketahui performanya. Setelah dihitung menggunakan tahap evaluasi dengan menggunakan rumus 2.15, 2.16 dan 2.17, performa yang dimiliki sedikit mengalami peningkatan dibandingkan dengan Aspect Categorization (AC) 1 yakni mencapai 0.656 atau 66%. Dimana hasil ini meningkat 5% dibandingkan metode sebelumnya. Sehingga peneliti memutuskan untuk memaksimalkan penggunaan expanding term list (TF-ICF) menjadi 100% dari total *synonym*.

#### 4.1.4.3. Aspect Categorization (AC) 3

Proses kategorisasi pada percobaan ketiga, AC3 ini dilakukan dengan menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk mencari *hidden topic* kemudian dilakukan *Semantic Similarity* dengan menggunakan data pada “Tabel 3.3” (atau “Tabel 2.1” yang telah ditambahkan term dari TF-ICF 100%) untuk mengkategorisasikan setiap review. *Expanding term list* yang akan digunakan adalah 100% atau keseluruhan dari total *synonym*. Penjabaran dari AC3 akan mirip seperti pada AC2. Hasil dari perhitungan kategorisasi aspect AC3

dengan menggunakan *Latent Dirichlet Allocation* (LDA) + *Similarity* pada penelitian adalah sebagai berikut:

Hasil Kategorisasi Aspect yang didapatkan oleh system untuk percobaan AC3

```
[bass', 'hear', 'sound']

Final score Aspect LOCATION = 0.071190
Final score Aspect FOOD = 0.09705
Final score Aspect SERVICE = 0.07743
Final score Aspect COMFORT = 0.09838
Final score Aspect CLEANESS = 0.07955

In update lda_category SET location_sim =0.07119046491945652, food_sim
=0.09705303244927427, service_sim =0.07742834286951933, comfort_sim
=0.0983829114784997, cleanliness_sim =0.07955493580493582,
label = 4 WHERE id = '1'

--- DONE ---

=====
[bass', 'like']

Final score Aspect LOCATION = 0.070228
Final score Aspect FOOD = 0.09951
Final score Aspect SERVICE = 0.07623
Final score Aspect COMFORT = 0.08933
Final score Aspect CLEANESS = 0.07826

In update lda_category SET location_sim =0.07022782772782774, food_sim
=0.09951152242818911, service_sim =0.07622978725919902, comfort_sim
=0.08933244043538163, cleanliness_sim =0.07826467011249619,
label = 2 WHERE id = '2'

--- DONE ---

=====

['sound', 'bathtub', 'clear', 'easy', 'use', 'very']

Final score Aspect LOCATION = 0.058058
Final score Aspect FOOD = 0.06029
```

```
Final score Aspect SERVICE = 0.06673
Final score Aspect COMFORT = 0.07853
Final score Aspect CLEANESS = 0.06377
In update lda_category SET location_sim =0.058058082081099166, food_sim
=0.06029019328277222, service_sim =0.06673150798763541, comfort_sim
=0.07852774973035208, cleanliness_sim =0.06376624333862575,
label = 4 WHERE id = '3'
--- DONE ---

=====
['clear', 'air', 'fresh', 'little', 'might', 'some']

Final score Aspect LOCATION = 0.021574
Final score Aspect FOOD = 0.02544
Final score Aspect SERVICE = 0.02169
Final score Aspect COMFORT = 0.02360
Final score Aspect CLEANESS = 0.02189
In update lda_category SET location_sim =0.021573616528973674, food_sim
=0.025440509207870332, service_sim =0.021687789396122734, comfort_sim
=0.02360458395997612, cleanliness_sim =0.02188933884506135,
label = 2 WHERE id = '4'
--- DONE ---

=====
['clear', 'very', 'but', 'disappoint', 'do', 'poor', 'say', 'service', 'understand', 'wish']

Final score Aspect LOCATION = 0.025258
Final score Aspect FOOD = 0.02475
Final score Aspect SERVICE = 0.02887
Final score Aspect COMFORT = 0.02556
Final score Aspect CLEANESS = 0.02317
In update lda_category SET location_sim =0.02525753676393878, food_sim
=0.02474625754502375, service_sim =0.028871705283469974, comfort_sim
=0.025555523997843554, cleanliness_sim =0.023174011456209113,
label = 3 WHERE id = '5'
```

--- DONE ---

Etc.

Keterangan:

TF-ICF1 = *Location* (Lokasi)

TF-ICF2 = *Meal* (Makanan)

TF-ICF3 = *Service* (Pelayanan)

TF-ICF4 = *Comfort* (Kenyamanan)

TF-ICF5 = *Cleanliness* (Kebersihan)

Agar lebih mudah dibaca, penulis merepresentasikan hasil pada tabel 4.8 berikut:

**Tabel 4.8** Tabel Hasil Perhitungan LDA + Semantic Similarity AC3

Review	Aspect 1	Aspect 2	Aspect 3	Aspect 4	Aspect 5	Label	Label Annotator
	Location	Food	Service	Comfort	Cleaness		
["Sound", "Hear", "Bass"]	0.071	0.097	0.077	<b>0.098</b>	0.079	Comfort	Comfort
["Like", "Bass"].	0.070	<b>0.099</b>	0.076	0.089	0.078	Meal	Meal
["Sound", "Bathtub", "Clear", "Easy", "Use"]	0.058	0.06	0.067	<b>0.078</b>	0.064	Comfort	Comfort
["clear", "air", "fresh", "little", "might"]	<b>0.021</b>	<b>0.025</b>	<b>0.021</b>	<b>0.023</b>	<b>0.021</b>	Meal	Comfort
['clear', 'very', 'but', 'disappoint', 'do', 'poor', 'say', 'service', 'understand', 'wish']	0.025	0.024	<b>0.028</b>	0.025	0.023	Service	Service

\* Warna merah adalah kesalahan sistem dalam melakukan kategorisasi

Pada AC3, masih didapati kesalahan dalam kategorisasi yakni pada review ke-4 dimana seharusnya review tersebut masuk kedalam aspect “*comfort*” namun system mendeteksi sebagai aspect “*meal*”. Kesalahan dalam kategorisasi aspect ini dikarenakan model yang digunakan hanya memperhatikan aspect similaritas terhadap *term* yang telah didefinisikan sebelumnya, maka review tersebut diprediksi menjadi aspect yang salah. Setelah melakukan kategorisasi dengan menggunakan tahapan pada AC3, hasil kemudian evaluasi dengan menggunakan

rumus 2.15, 2.16 dan 2.17 untuk diketahui performanya. *Aspect Categorization* (AC) 3 ini memiliki hasil yang lebih maksimal yakni 0.854 atau 85% dari metode kategorisasi sebelumnya. Dimana dalam hal ini, dengan melakukan penerapan metode pada AC3 performa dari kategorisasi meningkat hingga 19% dari metode sebelumnya (AC2). Hasil evaluasi akan dibahas lebih lanjut pada point “4.2 Hasil Pengujian dan Evaluasi”.

#### **4.1.5. Pre-Proses Untuk Klasifikasi Sentiment Berdasarkan Aspect**

Sebelum masuk pada tahap klasifikasi sentiment, hasil yang didapatkan dari tahap *Aspect Categorization* (AC) 3 pada “Tabel 4.8” dikumpulkan terlebih dahulu berdasarkan aspect kategori yang sama. Setiap data yang memiliki kesalahan dalam proses kategorisasi akan dibuang. Hal ini dikarenakan data tersebut sudah tidak akan efektif lagi untuk diproses lebih lanjut. Sehingga, dari 529 data review yang dianalisa yang terdapat pada “Tabel 4.1 Hasil Pre-processing untuk Masukan Proses Klasifikasi” akan menjadi 449 data saja. 449 data ini kemudian akan dibagi menjadi 80% untuk *training* dan 20% *testing*. Sehingga didapatkan 359 data untuk *training* dan 90 data untuk *testing*. Data yang akan diproses adalah sebagai berikut:

**Tabel 4.9** Data Hasil *Aspect Categorization* (AC3)

No.	Review	Aspect Hasil AC3
1.	“Sound”, “Hear”, “Bass”	<i>Comfort</i>
2.	“Like”, “bass”	<i>Meal</i>
3.	“Sound”, “Bathtub”, “Clear”, “Easy”, “Use”	<i>Comfort</i>
4.	“Clear”, “Disappoint”, “Poor”, “Say”, “Service”, “Understand”, “Wish”	<i>Service</i>

Pre-Proses untuk Klasifikasi Sentiment berdasarkan Aspect ini bertujuan untuk melatih data *training* setiap kategori aspect pada *sentiment positive* dan *negative*. Sehingga, setelah proses ini diharapkan term list *sentiment* dari setiap aspect akan dihasilkan. Proses pelabelan pada training data untuk klasifikasi sentiment dilakukan oleh annotator. Data pada tabel 4.9 akan dibagi dan diberikan

label *sentiment* seperti pada tabel 4.10-4.12 untuk pre-proses untuk klasifikasi sentiment berdasarkan aspect:

**Tabel 4.10 Data Aspect-Based Sentiment (Aspect Comfort)**

No.	Review	Aspect	Sentiment
1.	“Sound”, “Hear”, “Bass”	Comfort	Negative
2.	“Sound”, “Bathtub”, “Clear”, “Easy”, “Use”	Comfort	Positive

**Tabel 4.11 Data Aspect-Based Sentiment (Aspect Meal)**

No.	Review	Aspect	Sentiment
1.	“Like”, “bass”	Meal	Positive

**Tabel 4.12 Data Aspect-Based Sentiment (Aspect Service)**

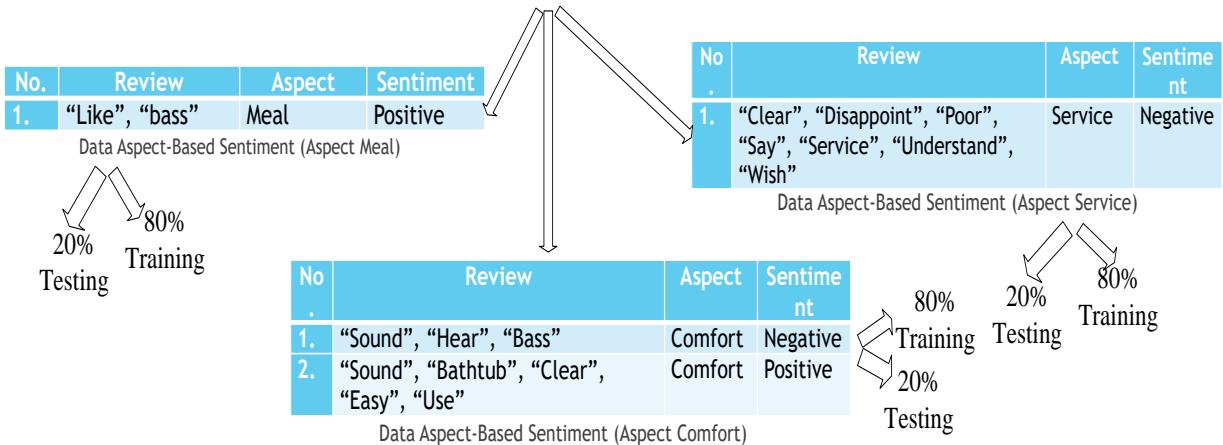
No.	Review	Aspect	Sentiment
1.	“Clear”, “Disappoint”, “Poor”, “Say”, “Service”, “Understand”, “Wish”	Service	Negative

#### 4.1.6. Proses Klasifikasi Sentiment

Klasifikasi sentiment dilakukan untuk mengklasifikasikan setiap review pada sentiment kepuasan atau ketidakpuasan pelanggan terhadap produk dan layanan hotel. Data yang digunakan untuk melakukan klasifikasi sentiment adalah data dari “Tabel 4.9” yang dimana aspectnya telah dicari dengan menggunakan kategorisasi aspect terbaik (AC3). Setelah data pada “Tabel 4.9” melalui tahap pre-proses untuk klasifikasi sentiment berdasarkan aspect yang dapat dilihat pada *point* “4.1.5 Pre-Proses Untuk Klasifikasi Sentiment Berdasarkan Aspect”. Contoh data hasil dapat dilihat pada Tabel 4.10, 4.11 dan 4.12 diatas. Data pada tabel 4.10, 4.11 dan 4.12 tersebut akan dipisahkan 80% untuk proses *training* dan 20% untuk proses *testing* dari total keseluruhan data setiap aspect. Ilustrasi penggunaan data dapat dilihat sebagai berikut:

No .	Review	Aspect
1.	"Sound", "Hear", "Bass"	Comfort
2.	"Like", "bass"	Meal
3.	"Sound", "Bathtub", "Clear", "Easy", "Use"	Comfort
4.	"Clear", "Disappoint", "Poor", "Say", "Service", "Understand", "Wish"	Service

Hasil Aspect Categorization (AC) 3



**Gambar 4.4** Ilustrasi Pembagian data *Training* dan *Testing* untuk Klasifikasi Sentiment

\*Data yang digunakan sebagai contoh, akan diletakkan pada data *testing* juga. Hal ini bertujuan agar data yang ditampilkan konsisten hingga akhir.

Proses klasifikasi sentiment akan dilakukan sesuai dengan penjelasan pada point “3.2.6 Proses Klasifikasi Sentiment”. Proses ini akan membandingkan beberapa metode untuk melakukan klasifikasi sentiment dengan: SC1 yang akan menggunakan *Word Embedding + Long short Term Memmory* (LSTM) untuk mengklasifikasikan setiap kalimat pada sentiment; SC2 = SC1 namun proses klasifikasi akan menggunakan Sentiwordnet; dan SC3 = SC1 klasifikasi akan menggunakan *Long short Term Memmory* (LSTM).

Penjabaran mengenai perbandingan metode klasifikasi sentiment akan dijabarkan pada point 4.1.6.1. *Sentiment Classification* (SC) 1 hingga 4.1.6.3. *Sentiment Classification* (SC) 3 dibawah ini.

#### **4.1.6.1. *Sentiment Classification* (SC) 1**

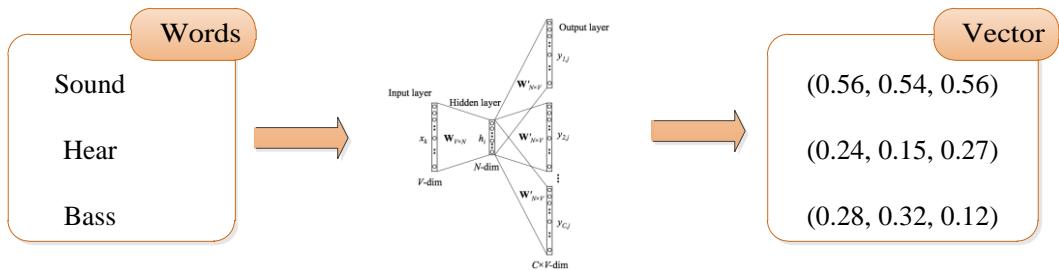
Tahap ini dilakukan dengan mengikuti alur *pseudocode* *Sentiment Classification* (SC) 1 pada BAB 3 point “3.2.5.1. *Sentiment Classification* (SC) 1” dan juga detail pada “Gambar 3.7 Contoh data Klasifikasi Sentiment dengan Aspect “*Location*” Menggunakan “SC1””. Data yang akan diproses untuk klasifikasi sentiment telah direpresentasikan pada “Tabel 4.9” dan akan dipisahkan 80% untuk *training* dan 20% *testing*.

Pada *Sentiment Classification* (SC) 1 ini, data diproses dengan menggunakan *word embedding* untuk memperoleh representasi *vector* dari kata-kata pada setiap dokumen. Karena *Long short Term Memory* (LSTM) hanya akan memproses atau memahami data yang berupa angka. Penelitian ini menggunakan GloVe sebagai *word embedding*. GloVe sendiri dipilih karena merupakan model *word embedding* yang telah terlatih. GloVe dalam penelitian ini digunakan untuk menjadi kakas bantu dalam melakukan *expand term list* saat *training* data dan saat klasifikasi.

Setelah memperoleh vektor yang digunakan sebagai fitur pada proses klasifikasi, selanjutnya *Long short Term Memory* (LSTM) digunakan sebagai metode klasifikasi. Pada penelitian ini, setiap dokumen akan diklasifikasikan apakah termasuk dalam klaster puas atau berarti *positive* apakah dalam klaster tidak puas atau berarti *negative*. Proses klasifikasi dengan menggunakan data yang didapatkan dari *word embedding* ini di kenal juga sebagai *binary classification*.

#### **A. Word Embedding**

Metode *Word embedding* yang akan digunakan adalah GloVe. Ilustrasi model *word embedding* ini dapat dilihat pada *Pseudocode* Ilustrasi *Word Embedding* yang berada pada BAB 3 point “3.2.5.1. *Sentiment Classification* (SC) 1” point “A. *Word Embedding* (*Word + Topic Vector Learning*)”. Ilustrasi hasil akan digambarkan pada “Gambar 4.4”. GloVe dalam penelitian ini digunakan untuk menjadi kakas bantu dalam melakukan *expand term list* saat *training* data dan saat klasifikasi.



**Gambar 4.5** Ilustrasi Penerapan Model ke Setiap Kata Untuk Memperoleh *Corresponding Vector*

Dalam melakukan pencarian *vector* kata, *Word embedding* menggunakan GloVe yang dijalankan dengan menggunakan bantuan *library* tensorflow yang merupakan *library open source* untuk menyelesaikan permasalahan di sektor kecerdasan buatan dan Keras yang merupakan *library* model dari *neural network*.

Hasil *Word Embedding* yang berupa *Sentence Vector* akan menjadi masukan untuk proses klasifikasi menggunakan *Long short Term Memmory* (LSTM).

## B. Long Short Term Memory (LSTM)

Klasifikasi menggunakan *Long short Term Memmory* (LSTM) telah dijabarkan pada BAB 3 point “3.2.5.1. *Sentiment Classification (SC) 1*” point “B. *Long short Term Memmory (LSTM)*”. Hasil yang didapatkan dari proses klasifikasi ini dapat dilihat pada tabel 4.13 berikut.

**Tabel 4.13** Tabel Hasil Klasifikasi Sentimen Menggunakan *Word Embedding + Long short Term Memmory (LSTM)*

No.	Data Review (direpresentasikan dalam bentuk angka vector)	Aspect (Hasil AC3)	Hasil Analisa Sentiment	
			Positive	Negative
1	“Sound”, “Hear”, “Bass”	Comfort	0.345	0.757
2	“Sound”, “Bathtub”, “Clear”, “Easy”, “Use”	Comfort	0.875	0.223

3	“Clear”, “Disappoint”, “Poor”, “Say”, “Service”, “Understand”, “Wish”	Service	0.023	0. 984
4	“Like”, “bass”	Meal	0.875	0.223

Proses klasifikasi yang terlihat pada tabel 4.13 dilakukan dengan menggunakan bantuan library tensorflow dan keras. Hasil analisa sentence *vector* akan diklasifikasikan dengan metode *Long short Term Memmory* (LSTM) pada sentiment *positive* atau *negative*.

#### 4.1.6.2.Sentiment Classification (SC) 2

Pada proses *Sentiment Classification* (SC) 2 dilakukan perhitungan dengan mengambil nilai *posititive* dan *negative* pada kata yang dianalisa. Dimana skor nilai akan didapatkan dari *dictionary* SentiWordNet untuk mencari *sentiment* per review yang dianalisa. Proses klasifikasi dengan menggunakan SentiWordNet ini akan dijabarkan pada BAB 3 point “3.2.5.2. *Sentiment Classification* (SC) 2” pada “*pseudocode* Proses SentiWordNet”. Hasil dari proses klasifikasi menggunakan SentiWordnet akan ditampilkan pada tabel 4.14 berikut:

**Tabel 4.14** Tabel Hasil Klasifikasi Sentimen Menggunakan *Dictionary* SentiWordnet

No.	Data Review hasil Aspect Categorization	Word	PosScore	NegScore	Label Sentiment	Label Sebenarnya
1	“Sound”, “Hear”, “Bass”	Sound	0	0.125	Negative	Negative
		Hear	0	0		
	Aspect : Comfort	Bass	0	0		
	Total		0	0.042		
2	“Sound”, “Bathtub”, “Clear”, “Easy”, “Use”	Sound	0	0.125	Negative	Positive
		Bathtub	0	0		
		Clear	0.125	0.625		
		Aspect : Comfort	Easy	0.125		
		Use	0	0.125		
	Total		0.05	0.175		
	“Clear”, “Disappoint”, “Poor”, “Say”, “Service”, “Understand”, “Wish”	Clear	0.125	0.625		
3	“Clear”, “Disappoint”, “Poor”, “Say”, “Service”, “Understand”, “Wish”	Disappoint	0	0.375	Negative	Negative
		Poor	0	0.375		
		Aspect : Service	Say	0.125		

		Service	0	0		
	<b>Total</b>		0.036	0.232		
<b>4</b>	“Like”, “bass”	Like	0.375	0.25	<b>Positive</b>	<b>Positive</b>
	Aspect : Meal	Bass	0	0		
		<b>Total</b>	0.1875	0.125		

Dapat dilihat pada tabel 4.14 dimana pada review nomer 2, “*very clear sound a bathtub and easy to use*” seharusnya memiliki label sentiment *positive*, namun dengan penggunaan metode SentiWordNet, review ini diklasifikasikan pada label yang salah yakni *Negative*. Data pada review ini adalah contoh kesalahan dari proses klasifikasi yang dilakukan. Hal ini dimungkinkan karena SentiWordNet hanya menganalisa kata sifat dan telah memiliki 3 penilaian yang telah ditentukan berupa *positive*, *negative* dan *objective*. Sedangkan *Word Embedding + Long short Term Memmory* (LSTM) mampu menganalisa sentiment tidak hanya dengan kata sifat, namun setiap kata akan diukur kedekatannya pada kata yang berlabel positive atau negative yang telah melalui proses training. Sehingga, kemungkinan metode *word embedding + Long short Term Memmory* (LSTM) untuk klasifikasi sentiment akan memiliki performa yang tinggi dibandingkan sentiwordnet.

#### 4.1.6.3.Sentiment Classification (SC) 3

Pada proses *Sentiment Classification* (SC) 3, implementasi dilakukan dengan menjalankan word2vec menggunakan bantuan *library tensorflow* yang merupakan *library open source* untuk menyelesaikan permasalahan di sektor kecerdasan buatan dan Keras yang merupakan *library model* dari *neural network*. Kemudian data akan diklasifikasikan menggunakan *Long short Term Memmory* (LSTM). Hasil dari Klasifikasi Sentiment pada SC 3 ini akan mirip dengan hasil klasifikasi pada SC1. Bedanya, SC3 tidak menggunakan GloVe dalam melakukan representasi kata dalam bentuk angka *vector*, namun menggunakan bantuan dari Word2Vec. Hasil dari proses klasifikasi menggunakan *Long short Term Memmory* (LSTM) akan mirip dengan hasil dari *Word Embedding + Long short Term Memmory* (LSTM). Hasil akan ditampilkan pada tabel 4.15 berikut:

**Tabel 4.15** Tabel Hasil Klasifikasi Sentimen Menggunakan LSTM

No.	Data Review hasil Aspect Categorization (direpresentasikan dalam bentuk angka vector)	Aspect	Hasil Analisa Sentiment	
			Positive	Negative
1	“Sound”, “Hear”, “Bass”	Comfort	0.393	0.443
2	“Sound”, “Bathtub”, “Clear”, “Easy”, “Use”	Comfort	0.985	0.023
3	“Clear”, “Disappoint”, “Poor”, “Say”, “Service”, “Understand”, “Wish”	Service	0.204	0.749
4	“Like”, “bass”	Meal	0.493	0.362

Dari tabel 4.15 dapat dilihat bahwa review pertama memiliki aspect *comfort* dengan *sentiment negative* (karena hasil skor terbesar berada pada *sentiment negative*). Review kedua memiliki aspect *comfort* dengan *sentiment positive*. Review 3 memiliki aspect *comfort* dengan *sentiment negative* dan review 4 memiliki aspect *meal* dengan review *positive*.

#### 4.2. Hasil Pengujian dan Evaluasi

Penulis telah menyebutkan pada BAB 3 mengenai evaluasi yang akan dilakukan untuk melakukan evaluasi hasil pada point “3.2.7 Evaluasi”. Evaluasi ini akan dilakukan untuk mencari performa terbaik dari *Aspect Categorization* (AC) dan *Sentiment Classification* (SC) dengan metode yang digunakan. Masing-masing performa akan terdiri dari beberapa pendekatan dan akan dievaluasi dengan menggunakan: *Precision*, *Recall* dan *F1 Measure*. Setiap hasil terbaik dari metode kategorisasi aspect maupun klasifikasi sentimen akan digunakan untuk mencari hasil akhir yang telah disebutkan dalam tujuan yaitu “evaluasi terhadap setiap review untuk mengetahui hal apa dari bisnis yang membuat pelanggan puas maupun tidak puas yang didasarkan kepada 5 aspect hotel agar perusahaan mampu menyusun rencana perubahan, menata kembali bisnisnya dan mungkin memperbaiki kesalahan mereka”.

#### 4.2.1.Pendekatan Evaluasi untuk Kategorisasi Aspect

Berdasarkan 529 data *review* pelanggan yang dicrawl dan diproses melalui *preprocessing*, dilakukan percobaan mencari performa terbaik untuk melakukan kategorisasi aspect dari metode yang digunakan. Metode untuk kategorisasi aspect terdiri dari metode untuk mencari *hidden topic*, perluasan *term list* serta kategorisasi menggunakan metode *similarity* akan dihitung performa setiap uji cobanya menggunakan *precision*, *recall* dan *F1 Measure*. Kemudian, performa terbaik akan disimpulkan. Untuk menghitung performa metode dilakukan dengan menggunakan 3 pendekatan pengujian untuk klasifikasi aspect yang akan dijabarkan pada tabel 4.16 berikut:

**Tabel 4.16** Tabel Pendekatan Pengujian untuk Kategorisasi Aspect

No. Approach	Keterangan
AC1	Melakukan evaluasi dengan menggunakan data crawling yang sudah melalui tahap preprocessing “Tabel 4.1 Hasil <i>Pre-processing</i> untuk Masukan Proses Klasifikasi” data tersebut kemudian diolah menggunakan metode <i>Latent Dirichlet Allocation</i> (LDA) untuk mencari <i>hidden topic</i> . <i>Semantic Similarity</i> akan menghitung kemiripan hasil <i>hidden topic</i> “Tabel 4.5 Tabel Hasil Hidden Topic LDA” terhadap aspect data yang dituliskan pada “Tabel 2.1 <i>Keyword Term List</i> Terkait Aspect yang Diperoleh” untuk mengkategorisasikan setiap review pada 5 aspect hotel yang telah ditentukan. Proses kategorisasi dapat dilihat pada Tahap “B. Kategorisasi Aspect Menggunakan <i>Semantic Similarity</i> ”.
AC2	AC1 + <i>Expanding term list</i> yang dihasilkan dari perhitungan modul perluasan term list <i>Term Frequency - Inverse Cluster Frequency</i> (TF-ICF) yang dituliskan pada “Tabel 4.4 Hasil Perhitungan TF-ICF” sebanyak 20% dari total <i>synonym</i> . Penambahan dilakukan pada saat proses

	perhitungan <i>Semantic Similarity</i> untuk mengkategorisasikan setiap review pada 5 aspect hotel yang telah ditentukan. Data TF-ICF 20% ini akan ditambahkan pada data aspect pada “Tabel 2.1”.
AC 3.	AC1, namun menggunakan “Tabel 3.3” (atau data “Tabel 2.1” + TF-ICF 100% dari total <i>synonym</i> ) untuk perhitungan <i>Semantic Similarity</i> .

Setiap pendekatan pengkategorian akan dievaluasi dengan menggunakan *precision*, *recall* dan *F1-Measure* yang masing-masing rumus dapat dilihat pada *Equation 2.15*, *2.16* dan *2.17*. Evaluasi dilakukan dengan cara melakukan perbandingan data kategorisasi aspect hasil akhir yang diperoleh oleh masing-masing metode pendekatan dengan data label kategori aspect yang diberikan oleh annotator. Penulis memiliki 3 (tiga) orang annotator untuk melakukan pelabelan kategori pada setiap data review yang digunakan.

Setiap evaluasi perhitungan performa yang dilakukan, penulis melakukan tahap sebagai berikut:

Start			
<b>id</b>	<b>id_preprocess</b>	<b>Review</b>	<b>Label Annotator</b>
1	1	I can hear bass sound	<i>comfort</i>
2	2	They like grilled bass	<i>meal</i>
3	3	Very clear sound a bathtub and easy to use	<i>comfort</i>
4	4	A little fresh air might clear some of the cobwebs.	<i>comfort</i>
5	5	It was clear that he do not understand what i am said but also what i wished to, very poor service. disappointing	<i>service</i>

	6	6	Very awesome and polite made sure we had everything we needed and even got us an early check-in.	<i>service</i>	
	7	6	They gave us ideas on tourist activities we could partake in for our stay we even got gift bags over all i loved it will visits again	<i>service</i>	
	8	7	Excellent service! Got our room early! Very friendly and gave us great advice about the city as hotel! Room is beautiful! Would definitely recommend this hotel and Allison and Alam were very nice and informative	<i>service</i>	
	9	8	To summarise this stay during our visit to New York in September, it was truly overly expensive	<i>service</i>	
	10	8	The service at reception was awful, we were ignored by the reception staff, the rooms were little more basic than we expected and the price we paid did not even include breakfast the next day.	<i>service</i>	

2. Ambil data dari hasil system.

(sebagai contoh: data hasil dari percobaan AC1)

**Tabel 4.18** Data Hasil Percobaan Kategorisasi Aspect (AC) 1

<b>id</b>	<b>id_preprocess</b>	<b>Review</b>	<b>Hasil AC1</b>
1	1	I can hear bass sound	<i>meal</i>
2	2	They like grilled bass	<i>meal</i>
3	3	Very clear sound a bathtub and easy to use	<i>comfort</i>
4	4	A little fresh air might clear some of the cobwebs.	<i>meal</i>
5	5	It was clear that he do not understand what i am said but also what i wished to, very poor service. disappointing	<i>comfort</i>

	6	6	Very awesome and polite made sure we had everything we needed and even got us an early check-in.	<i>service</i>	
	7	6	They gave us ideas on tourist activities we could partake in for our stay we even got gift bags over all i loved it will visits again	<i>service</i>	
	8	7	Excellent service! Got our room early! Very friendly and gave us great advice about the city as hotel! Room is beautiful! Would definitely recommend this hotel and Allison and Alam were very nice and informative	<i>service</i>	
	9	8	To summarise this stay during our visit to New York in September, it was truly overly expensive	<i>service</i>	
	10	8	the service at reception was awful, we were ignored by the reception staff, the rooms were little more basic than we expected and the price we paid did not even include breakfast the next day.	<i>service</i>	

3. Lakukan perbandingan untuk mencari kesalahan *system*. Proses ini dilakukan dengan membandingkan hasil yang diberikan oleh sistem dengan *ground truth* yang berasal dari data annotator. Sehingga, apabila hasil yang diberikan oleh *system* berbeda dengan *ground truth* yang diberikan Annotator, data tersebut dikategorikan dalam kesalahan pelabelan.

**Tabel 4.19** Data Perbandingan antara Hasil Sistem dengan *Ground Truth*

<b>id</b>	<b>id_preprocess</b>	<b>Review</b>	<b>Label Annotator</b>	<b>Hasil AC1</b>
1	1	I can hear bass sound	comfort	meal
2	2	They like grilled bass	meal	meal
3	3	Very clear sound a bathtub and easy to use	comfort	comfort
4	4	A little fresh air might clear some of the cobwebs.	comfort	meal

	5	5	It was clear that he do not understand what i am said but also what i wished to, very poor service. disappointing	service	<i>comfort</i>
	6	6	Very awesome and polite made sure we had everything we needed and even got us an early check-in.	service	<i>service</i>
	7	6	They gave us ideas on tourist activities we could partake in for our stay we even got gift bags over all i loved it will visits again	service	<i>service</i>
	8	7	Excellent service! Got our room early! Very friendly and gave us great advice about the city as hotel! Room is beautiful! Would definitely recommend this hotel and Allison and Alam were very nice and informative	service	<i>service</i>
	9	8	To summarise this stay during our visit to New York in September, it was truly overly expensive	service	<i>service</i>
	10	8	the service at reception was awful, we were ignored by the reception staff, the rooms were little more basic than we expected and the price we paid did not even include breakfast the next day.	service	<i>service</i>

- *Ps: warna merah merupakan kesalahan yang dilakukan oleh system.*

4. Buat *Confusion Matrix* agar lebih memudahkan dalam melakukan pengukuran kinerja pada proses evaluasi performa.

		Confusion Matrix Kategorisasi Aspect (AC1)				
		Actual Value				
Predicted Value	Location	Location	Meal	Service	Comfort	Cleanliness
	Location	62	0	1	3	1
	Meal	0	14	13	2	0
	Service	15	0	173	33	2
	Comfort	22	0	64	97	20
	Cleanliness	0	0	0	1	6

Warna dengan warna hijau merepresentasikan data yang tidak memiliki kesalahan pelabelan oleh system, hal ini berarti data tersebut termasuk dalam *True Positive*. Setiap data yang berjalan secara vertical pada setiap kolomnya merupakan data dari *False Positive* karena merupakan data aspect lain, namun terdeteksi sebagai aspect *location*. Sedangkan data yang berjalan secara horizontal, pada setiap barisnya merupakan *False Negative* karena merupakan data yang seharusnya milik aspect lain namun terdeteksi sebagai aspect *location*.

5. Lakukan evaluasi dengan menggunakan *precision*, *recall* dan *F1 Measure*.

$$\text{Presisi} = \frac{TP}{TP+FP}$$

Dimana:

*TP* = True Positive (Hasil di mana model dengan benar memprediksi kelas)

*FP* = False Positive (Hasil di mana model salah memprediksi kelas lain sebagai kelas yang sedang diperiksa)

Dalam contoh yang diberikan oleh “Tabel 4.19 Data Perbandingan antara Hasil Sistem dengan *Ground Truth*” data benar adalah pada data dengan Id: 2,3,6,7,8,9 dan 10. Serta dalam contoh yang diberikan oleh “Tabel 4.19 Data Perbandingan antara Hasil Sistem dengan *Ground Truth*” data salah adalah pada data dengan Id : 1,4 dan 5.

Dalam evaluasi yang dilakukan, dari total 529 data, didapatkan jumlah keseluruhan *True Positive* untuk data AC1 yakni 321 data, sedangkan

untuk *False Positive* yakni 208 data. Sehingga perhitungan Presisinya adalah sebagai berikut:

$$Precision = 0.647$$

$$Recall = \frac{TP}{TP+FN}$$

Dimana:

*TP* = True Positive (Hasil di mana model dengan benar memprediksi kelas)

*FN* = False Negative (Hasil di mana model salah memprediksi kelas yang sedang diperiksa sebagai kelas lain)

Dalam contoh yang diberikan oleh “Tabel 4.19 Data Perbandingan antara Hasil Sistem dengan *Ground Truth*” data benar adalah pada data dengan Id: 2,3,6,7,8,9 dan 10. Serta dalam contoh yang diberikan oleh “Tabel 4.19 Data Perbandingan antara Hasil Sistem dengan *Ground Truth*” data salah adalah pada data dengan Id : 1,4 dan 5.

Dalam evaluasi yang dilakukan, dari total 529 data, didapatkan jumlah keseluruhan *True Positive* untuk data AC1 yakni 321 data, sedangkan untuk *False Negative* yakni 208 data. Sehingga perhitungan *Recall*-nya adalah sebagai berikut:

$$Recall = 0.704$$

$$F1\text{-}Measure = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

*F1 Measure* merupakan perhitungan evaluasi dalam temu kembali informasi yang mengkombinasikan *recall* dan *precision*. Sehingga, *F1 Measure* adalah sebagai berikut:

$$F1\text{-}Measure = 0.607$$

- Ps: *Confusion Matrix* untuk Kategorisasi Aspect (AC) dapat dilihat pada **Lampiran I.**

6. Ambil angka setiap hasil akhir evaluasi.

(Hasil akhir evaluasi merupakan hasil dari *F1 Measure* yakni 0.607 atau 61%). Dimana hal ini berarti untuk kategorisasi aspect pada AC1 memiliki performa aplikasi sebesar 61%.

**End**

- Ps: contoh pada proses ini adalah data dari AC1. Proses ini juga akan dilakukan untuk melakukan perhitungan evaluasi performa pada Kategorisasi Aspect (AC)2 dan (AC)3.

Dari perhitungan yang telah dilakukan, didapatkan hasil evaluasi terhadap kategorisasi aspect menggunakan *Latent Dirichlet Allocation* (LDA), *Term Frequency - Inverse Cluster Frequency* (TF-ICF) dan *Semantic Similarity* seperti pada tabel 4.20:

**Tabel 4.20** Pengujian Performa Kategorisasi Aspect

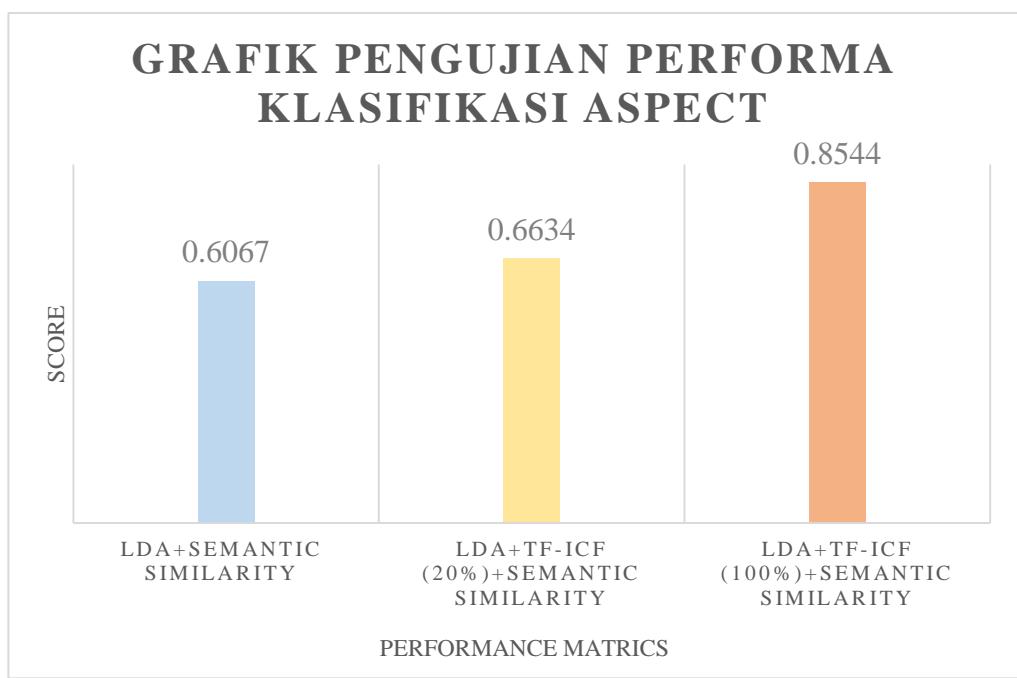
ASPECT ANALYSIS PERFORMANCE		
No. Approach	Performance Metrics	F1-Measure
AC 1	<i>Latent Dirichlet Allocation</i> (LDA) + <i>Semantic Similarity</i> data pada “Tabel 2.1 <i>Keyword Term List</i> Terkait Aspect yang Diperoleh”	0.607
AC 2	<i>Latent Dirichlet Allocation</i> (LDA) + <i>Term Frequency - Inverse Cluster Frequency</i> (TF-ICF) 20% + <i>Semantic Similarity</i>	0.663
AC 3	<i>Latent Dirichlet Allocation</i> (LDA) + <i>Term Frequency - Inverse Cluster Frequency</i> (TF-ICF) 100% + <i>Semantic Similarity</i>	0.854

Dari tabel 4.20 dapat diketahui bahwa, performa aplikasi pada AC1 melakukan evaluasi hasil kategorisasi aspect dengan *Latent Dirichlet Allocation* (LDA) + *Similarity* data pada “Tabel 2.1 *Keyword Term List* Terkait Aspect yang Diperoleh” hanya mendapatkan hasil performa F1-Measure yaitu sebesar 0.607 atau 61%. Kemudian AC2 yang melakukan evaluasi dengan *Latent Dirichlet Allocation* (LDA) + *Term Frequency - Inverse Cluster Frequency* (TF-ICF) (20%) + *Semantic Similarity* mendapatkan hasil performa sebesar 0.663 atau 66%.

Peningkatan performa inilah yang kemudian menjadi pertimbangan bagi penulis untuk memasukkan data *Term Frequency - Inverse Cluster Frequency* (TF-ICF) lebih banyak, yakni mencapai 100%.

Setelah diterapkan pemasukan data TF-ICF 100%, didapatkan bahwa pengujian performa klasifikasi aspect pada AC3: melakukan evaluasi dengan menggunakan *Latent Dirichlet Allocation* (LDA) untuk melakukan pencarian *hidden topic*. Kemudian *Semantic Similarity* akan menghitung kemiripan hasil *hidden topic* dengan *keyword term* pada “Tabel 2.1 *Keyword Term List* Terkait Aspect yang Diperoleh” + dengan term dari perhitungan *Term Frequency - Inverse Cluster Frequency* (TF-ICF) 100% atau yang telah dituliskan pada “Tabel 3.3” untuk melakukan pengkategorian aspect pada setiap review merupakan pendekatan terbaik. AC3 ini mampu menghasilkan performa aplikasi hingga mencapai 0.854 atau 85% dibandingkan dengan metode yang lain. Hasil evaluasi ini menunjukkan bahwa penambahan term list berdasarkan kelas yang telah ditandai sebelumnya atau penambahan *Term Frequency - Inverse Cluster Frequency* (TF-ICF) yang bertugas untuk menemukan term-term yang merepresentasikan setiap aspect dokumen menjadikan proses *semantic similarity* lebih baik. Sehingga pada penerapannya, penambahan ini mampu menunjukkan hasil yang terbaik.

Untuk lebih jelas mengenai perbandingan pengujian performa klasifikasi aspect, penulis juga menggambarkan hasil pegujian menggunakan grafik seperti pada gambar 4.6 berikut.



**Gambar 4.6** Grafik Pengujian Performa Kategorisasi Aspect

Grafik pada gambar 4.6 (Grafik pengujian performa kategorisasi aspect) ini merupakan grafik yang menunjukkan perbandingan evaluasi performa dengan menggunakan gambar dimana data yang digunakan untuk grafik merupakan data dari “tabel 4.20 Pengujian Performa Kategorisasi Aspect”. Data angka yang terdapat pada grafik tersebut berasal dari angka kesimpulan evaluasi pada F1 *Measure* pada masing-masing percobaan. Perlu diingat kembali bahwa aspect yang digunakan terdiri dari 5 aspect yakni: *Location, meal, service, comfort* dan *cleanliness*.

#### 4.2.2.Pendekatan Evaluasi untuk Klasifikasi Sentiment

Setelah dilakukan kategorisasi aspect dengan menggunakan metode pengkategorian terbaik, kini dapat dilakukan percobaan untuk menghitung performance dari klasifikasi sentiment. Data dari kategorisasi aspect yang masih memiliki kesalahan pelabelan akan dibuang, hal tersebut berdasarkan pertimbangan bahwa data sudah tidak efektif lagi untuk diklasifikasikan lebih lanjut. Performa setiap uji coba akan dihitung menggunakan *precision*, *recall* dan F1 *Measure*. Kemudian, performa terbaik akan disimpulkan. Untuk menghitung performa dari

*sentiment analysis* dilakukan dengan menggunakan 3 pendekatan pengujian. Ketiga pengujian ini akan dilakukan dengan menggunakan data yang dihasilkan dari proses kategorisasi dengan metode terbaik, dan melalui tahap “4.1.5. Pre-Proses Untuk Klasifikasi Sentiment Berdasarkan Aspect”.

Pendekatan pengujian *Sentiment Classification* (SC) akan dijabarkan pada tabel 4.21 berikut:

**Tabel 4.21** Tabel Pendekatan Pengujian untuk Klasifikasi Sentiment

No. Approach	Keterangan
SC1	Menggunakan data hasil kategorisasi aspect AC3. Kemudian melalui tahap “4.1.5. Pre-Proses Untuk Klasifikasi Sentiment Berdasarkan Aspect”. Setelah itu peneliti melakukan <i>trining</i> dan <i>testing</i> review berdasarkan aspect. <i>Training</i> ini bertujuan untuk melatih data klasifikasi sentiment terhadap aspect. Data akan diklasifikasi menggunakan <i>Word Embedding + Long short Term Memmory (LSTM)</i> . Hasil dari pendekatan Klasifikasi Sentiment (SC1) ini dapat dilihat pada “Tabel 4.13 Tabel Hasil Klasifikasi Sentimen Menggunakan Word Embedding + Long short Term Memmory (LSTM)”. Hasil klasifikasi adalah sentiment hotel berdasarkan aspect.
SC2	SC1 namun proses klasifikasi sentiment akan menggunakan SentiWordNet. Hasil dari pendekatan ini dapat dilihat pada “Tabel 4.14 Tabel Hasil Klasifikasi Sentimen Menggunakan Dictionary SentiWordnet”. Hasil klasifikasi adalah sentiment hotel berdasarkan aspect.

SC3	SC1 namun proses klasifikasi sentiment akan menggunakan <i>Long short Term Memory</i> (LSTM). Kekas bantu untuk merepresentasikan kata dalam bentuk angka <i>vector</i> menggunakan Word2Vec. Hasil dari pendekatan ini ditampilkan pada “Tabel 4.15 Tabel Hasil Klasifikasi Sentimen Menggunakan LSTM”. Hasil klasifikasi adalah sentiment hotel berdasarkan aspect.
-----	-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

*Performance* dari setiap klasifikasi sentiment yang dilakukan akan dihitung dengan menggunakan metode evaluasi yang sama dengan metode evaluasi yang digunakan untuk evaluasi aspect yakni menggunakan *precision*, *recall* dan *F1-Measure* yang masing-masing rumusnya dapat dilihat pada Equation 2.15, 2.16 dan 2.17. Evaluasi dilakukan dengan cara melakukan perbandingan data klasifikasi sentiment yang diperoleh oleh setiap metode klasifikasi dengan data klasifikasi aspect yang dilebeli oleh annotator. Penulis memiliki 3 (tiga) orang annotator untuk melakukan pelabelan klasifikasi sentiment pada setiap data review yang digunakan.

Setiap evaluasi perhitungan performa yang dilakukan, penulis melakukan tahap sebagai berikut:

Start																				
<ol style="list-style-type: none"> <li>Ambil data hasil dari Kategorisasi Aspect (AC3) dengan data review yang telah dilabeli sentiment oleh annotator.</li> </ol> <p><b>Tabel 4.22</b> Data Kategorisasi Aspect (AC3) yang telah dilabeli oleh Annotator</p> <table border="1"> <thead> <tr> <th><b>id</b></th> <th><b>id_preprocess</b></th> <th><b>review</b></th> <th><b>label Aspect</b></th> <th><b>Label Annotator</b></th> </tr> </thead> <tbody> <tr> <td>1</td> <td>1</td> <td>I can hear bass sound</td> <td><i>comfort</i></td> <td><i>negative</i></td> </tr> <tr> <td>2</td> <td>2</td> <td>They like grilled bass</td> <td><i>meal</i></td> <td><i>positive</i></td> </tr> <tr> <td>3</td> <td>3</td> <td>Very clear sound a bathtub and easy to use</td> <td><i>comfort</i></td> <td><i>positive</i></td> </tr> </tbody> </table>	<b>id</b>	<b>id_preprocess</b>	<b>review</b>	<b>label Aspect</b>	<b>Label Annotator</b>	1	1	I can hear bass sound	<i>comfort</i>	<i>negative</i>	2	2	They like grilled bass	<i>meal</i>	<i>positive</i>	3	3	Very clear sound a bathtub and easy to use	<i>comfort</i>	<i>positive</i>
<b>id</b>	<b>id_preprocess</b>	<b>review</b>	<b>label Aspect</b>	<b>Label Annotator</b>																
1	1	I can hear bass sound	<i>comfort</i>	<i>negative</i>																
2	2	They like grilled bass	<i>meal</i>	<i>positive</i>																
3	3	Very clear sound a bathtub and easy to use	<i>comfort</i>	<i>positive</i>																

	5	5	It was clear that he do not understand what i am said but also what i wished to, very poor service. disappointing	<i>service</i>	<i>negative</i>
	6	6	Very awesome and polite made sure we had everything we needed and even got us an early check-in.	<i>service</i>	<i>positive</i>
	7	6	They gave us ideas on tourist activities we could partake in for our stay we even got gift bags over all i loved it will visits again	<i>service</i>	<i>positive</i>
	8	7	Excellent service! Got our room early! Very friendly and gave us great advice about the city as hotel! Room is beautiful! Would definitely recommend this hotel and Allison and Alam were very nice and informative	<i>service</i>	<i>positive</i>
	9	8	To summarise this stay during our visit to New York in September, it was truly overly expensive	<i>service</i>	<i>negative</i>
	10	8	the service at reception was awful, we were ignored by the reception staff, the rooms were little more basic than we expected and the price we paid did not even include breakfast the next day.	<i>service</i>	<i>negative</i>

\*ps: apabila diperhatikan, data dengan id=4 tidak ada dalam proses evaluasi ini, hal ini berarti data dengan id=4 masih memiliki kesalahan dalam pelabelan. Hasil dari Kategorisasi Aspect (AC3) dapat dilihat pada “Tabel 4.8 Tabel Hasil Perhitungan LDA + Semantic Similarity AC3”.

2. Ambil data dari hasil system.  
(sebagai contoh: data hasil dari percobaan SC1)

**Tabel 4.23** Data Hasil Percobaan Klasifikasi Sentiment (SC) 1

<b>id</b>	<b>id_preprocess</b>	<b>review</b>	<b>Hasil SC1</b>
1	1	I can hear bass sound	negative
2	2	They like grilled bass	positive
3	3	Very clear sound a bathtub and easy to use	positive
5	5	It was clear that he do not understand what i am said but also what i wished to, very poor service. disappointing	negative
6	6	Very awesome and polite made sure we had everything we needed and even got us an early check-in.	positive
7	6	They gave us ideas on tourist activities we could partake in for our stay we even got gift bags over all i loved it will visits again	positive
8	7	Excellent service! Got our room early! Very friendly and gave us great advice about the city as hotel! Room is beautiful! Would definitely recommend this hotel and Allison and Alam were very nice and informative	positive
9	8	To summarise this stay during our visit to New York in September, it was truly overly expensive	negative
10	8	the service at reception was awful, we were ignored by the reception staff, the rooms were little more basic than we expected and the price we paid did not even include breakfast the next day.	negative

3. Lakukan perbandingan untuk mencari kesalahan system. Proses ini dilakukan dengan membandingkan hasil yang diberikan oleh sistem dengan ground truth yang berasal dari data annotator. Sehingga, apabila hasil yang diberikan oleh system berbeda dengan ground truth yang diberikan Annotator, data tersebut dikategorikan dalam kesalahan pelabelan.

**Tabel 4.24** Data Perbandingan antara Hasil Sistem dengan *Ground Truth Sentiment*

<b>id</b>	<b>id_preprocess</b>	<b>review</b>	<b>label Aspect</b>	<b>Label Annotator</b>	<b>Hasil SC1</b>
1	1	I can hear bass sound	comfort	negative	negative
2	2	They like grilled bass	meal	positive	positive
3	3	Very clear sound a bathtub and easy to use	comfort	positive	positive
5	5	It was clear that he do not understand what i am said but also what i wished to, very poor service. disappointing	service	negative	negative
6	6	Very awesome and polite made sure we had everything we needed and even got us an early check-in.	service	positive	positive
7	6	They gave us ideas on tourist activities we could partake in for our stay we even got gift bags over all i loved it will visits again	service	positive	positive
8	7	Excellent service! Got our room early! Very friendly and gave us great advice about the city as hotel! Room is beautiful! Would definitely recommend this hotel and Allison and Alam were very nice and informative	service	positive	positive
9	8	To summarise this stay during our visit to New York in September, it was truly overly expensive	service	negative	negative
10	8	the service at reception was awful, we were ignored by the reception staff, the rooms were little more basic than we expected and the price we paid did not even include breakfast the next day.	service	negative	negative

4. Buat *Confusion Matrix* agar lebih memudahkan dalam melakukan pengukuran kinerja pada proses evaluasi performa.

Confusion Matrix SC1

Predicted Value	Actual Value	
	Positive	Negative
	TP	FN
Positive	80	4
Negative	6	0
	FP	TN
	Positive	Negative

Dari total data 529 yang dianalisa, masih terdapat kesalahan dalam proses pelabelan untuk Aspect sebesar 80 data. Sehingga, pada saat klasifikasi sentiment data yang digunakan hanyalah sebesar 449 data. 449 data tersebut kemudian dibagi 80% untuk *training* dan 20% untuk *testing*. Sehingga data yang akan dievaluasi performanya yakni 90 data.

5. Lakukan evaluasi dengan menggunakan *precision*, *recall* dan *F1 Measure*.

$$Precision = \frac{TP}{TP+FP}$$

Dimana:

*TP* = True Positive (Hasil di mana model dengan benar memprediksi kelas)

*FP* = False Positive (False positive ini merupakan data yang seharusnya bernilai negative, namun ia terdeteksi sebagai positive)

Dalam contoh yang diberikan oleh “Tabel 4.24 Data Perbandingan antara Hasil Sistem dengan Ground Truth Sentiment” data benar adalah pada data dengan Id: 1,2,3,5,6,7,8,9, dan 10. Serta dalam contoh yang diberikan oleh “Tabel 4.24 Data Perbandingan antara Hasil Sistem dengan *Ground Truth Sentiment*” tidak memiliki data yang salah.

Setelah dilakukan evaluasi untuk kategorisasi aspect (AC) 3, dari total 529 data pada proses AC3 masih dimiliki kesalahan pelabelan yakni 80 data. Sehingga, data yang dianalisa untuk klasifikasi adalah sebesar 449

data. 449 data tersebut kemudian dibagi 80% untuk Training dan 20% untuk testing. Data yang akan dievaluasi adalah data yang berasal dari data testing, yakni sebesar: **90 data**.

Sehingga perhitungan precision untuk SC1 adalah sebagai berikut:

$$Precision = \frac{80}{80+6} = 0.930$$

$$Recall = \frac{TP}{TP+FN}$$

Dimana:

*TP* = True Positive (Hasil di mana model dengan benar memprediksi kelas)

*FN* = False Negative (False negative ini merupakan data yang seharusnya bernilai positive, namun ia terdeteksi sebagai negative)

Dalam contoh yang diberikan oleh “Tabel 4.24 Data Perbandingan antara Hasil Sistem dengan *Ground Truth Sentiment*” data benar adalah pada data dengan Id: 1,2,3,5,6,7,8,9, dan 10. Serta dalam contoh yang diberikan oleh “Tabel 4.24 Data Perbandingan antara Hasil Sistem dengan *Ground Truth Sentiment*” tidak memiliki data yang salah.

Dalam evaluasi yang dilakukan, dari total 90 data *testing*, didapatkan jumlah keseluruhan *True Positive* untuk data SC1 yakni 80 data, sedangkan untuk *False Negative* yakni 3 data. Sehingga perhitungan *Recall*-nya adalah sebagai berikut:

$$Recall = \frac{80}{80+4} = 0.952$$

$$F1\text{-}Measure = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

*F1 Measure* merupakan perhitungan evaluasi dalam temu kembali informasi yang mengkombinasikan *recall* dan *precision*. Sehingga, *F1 Measure* adalah sebagai berikut:

$$F1\text{-}Measure = 2 \times \frac{0.930 \times 0.952}{0.930 + 0.952} = 0.941$$

- Ps: *Confusion Matrix* untuk Klasifikasi Sentiment (SC) dapat dilihat pada **Lampiran II**.

6. Ambil angka setiap hasil akhir evaluasi.

(Hasil akhir evaluasi merupakan hasil dari F1 *Measure* yakni 0.941 atau 94%). Dimana hal ini berarti untuk klasifikasi sentiment pada SC1 memiliki performa aplikasi sebesar 94%.

**End**

- Ps: contoh pada proses ini adalah data dari SC1. Proses ini juga akan dilakukan untuk melakukan perhitungan evaluasi performa pada Klasifikasi Sentiment (SC)2 dan (SC)3.

Dari pengujian yang dilakukan, didapatkan hasil evaluasi terhadap Klasifikasi Sentimen seperti pada tabel 4.25 atau juga dapat dilihat pada gambar 4.7:

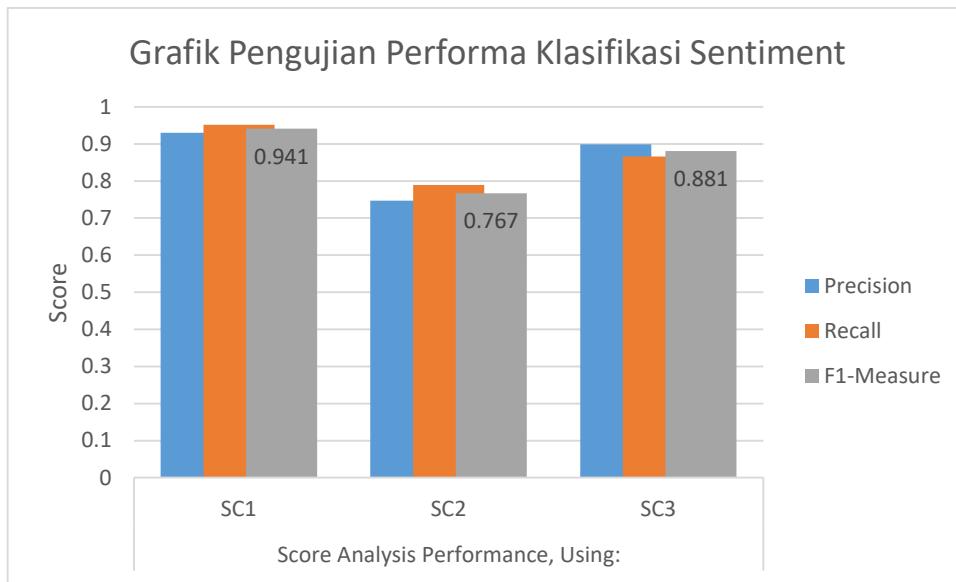
**Tabel 4.25** Pengujian Performa Analisa Sentiment

Sentiment Analysis Performance			
Performance Metrics	Score Analysis Performance, Using:		
	SC1	SC2	SC3
Precision	0.930	0.747	0.899
Recall	0.952	0.789	0.866
F1-Measure	0.941	0.767	0.881

Dari tabel 4.25 dapat diketahui bahwa pada SC1: Klasifikasi Sentiment menggunakan data hasil AC3 dengan metode *Word Embedding + Long short Term Memmory* (LSTM) memiliki performa hasil F1-*Measure* sebesar 0.941 atau 94%, hasil performa tersebut jauh lebih tinggi apabila dibandingkan dengan SC2 yang menggunakan sentiwordnet dengan hanya mendapatkan performa sebesar 0.767 atau 77% serta SC3 yang menggunakan *Long short Term Memmory* (LSTM) dengan performa sebesar 0.881 atau 88%.

Jadi dapat disimpulkan bahwa, performa terbaik didapatkan dengan menggunakan metode klasifikasi sentiment menggunakan *Word Embedding + Long short Term Memmory* (LSTM) pada SC1 yang menghasilkan performa 0.941 atau 94%.

Untuk lebih jelas mengenai perbandingan pengujian performa klasifikasi aspect, penulis juga menggambarkan hasil pegujian menggunakan grafik seperti pada gambar 4.7 berikut.



**Gambar 4.7** Grafik Pengujian Performa Klasifikasi Sentiment

Grafik pada gambar 4.7 (Grafik pengujian performa klasifikasi sentiment) ini merupakan grafik yang menunjukkan perbandingan evaluasi performa dengan menggunakan gambar dimana data yang digunakan untuk grafik merupakan data dari “Tabel 4.25 Pengujian Performa Analisa Sentiment”. Angka yang tertera pada grafik merupakan data dari angka F1 measure yang digunakan sebagai kesimpulan evaluasi yang telah mengkombinasikan recall dan precision. Sedangkan SC1, SC2 dan SC3 merupakan nama dari masing-masing percobaan untuk klasifikasi sentiment.

#### 4.2.3.Kesimpulan Metode yang akan Digunakan

Setelah melakukan pengujian dan evaluasi dengan “Pendekatan Evaluasi untuk Kategorisasi Aspect” dan “Pendekatan Evaluasi untuk Klasifikasi Sentiment” penulis kemudian mengetahui performa terbaik dari masing-masing pendekatan metode. Setiap metode terbaik pada masing-masing pendekatan evaluasi akan digunakan untuk melakukan *sentiment analysis* berdasarkan Aspect pada review

hotel. Dengan ini maka penulis menggunakan “Pendekatan untuk Kategorisasi Aspect” pada AC3 untuk menemukan Kategori Aspect pada setiap review dan “Pendekatan untuk Klasifikasi Sentiment” pada SC2 untuk melakukan klasifikasi sentiment.

Tabel 4.26 akan menunjukkan metode yang akan digunakan untuk melakukan kategorisasi aspect dan klasifikasi sentiment yang dilakukan oleh penulis.

**Tabel 4.26** Evaluasi Sentiment pada Aspect Analysis

Aspect Based Sentiment Analysis	
“Pendekatan untuk Kategorisasi Aspect” (AC3)	“Pendekatan untuk Klasifikasi Sentiment” (SC1)
LDA menghasilkan term list. Term list diklasifikasikan kedalam 5 aspect hotel menggunakan semantic similarity. Semantik similarity akan menghitung similarity antara term list dengan aspect yang telah ditulis dalam “Tabel 2.1” + Expanding Term List dari proses TF-ICF. TF-ICF yang diambil adalah 100% dari total sinonim. Data “Tabel 2.1” + Expanding Term List dari proses TF-ICF 100% ini telah dituliskan pada “Tabel 3.3”	Menggunakan AC3 data aspect Kategorisasi. Peneliti melakukan pelatihan dan pengujian data untuk klasifikasi sentiment dari setiap review berdasarkan aspect. Pelatihan ini bertujuan untuk melatih data klasifikasi sentimen pada aspect. Kemudian, data akan diklasifikasikan menggunakan Word Embedding + LSTM. Hasil klasifikasi adalah Aspect Based Sentiment Analysis Hotel.

Pendekatan evaluasi ini merupakan pendekatan terbaik yang telah dilakukan oleh penulis. Sehingga metode ini merupakan metode yang digunakan oleh penulis dalam melakukan kategorisasi aspect dan klasifikasi sentiment dimana penjabaran hasil telah dijelaskan pada point 4.1. Implementasi Sistem pada BAB 4. Atau hasil

Kategorisasi Aspect dan Klasifikasi Sentiment dapat dilihat pada Tabel 4.27 dan 4.28 berikut:

**Tabel 4.27** Hasil Kategorisasi Aspect (AC3)

```
=====
['bass', 'hear', 'sound']
Final score Aspect LOCATION = 0.071190
Final score Aspect FOOD = 0.09705
Final score Aspect SERVICE = 0.07743
Final score Aspect COMFORT = 0.09838
Final score Aspect CLEANESS = 0.07955
In update lda_category SET location_sim =0.07119046491945652, food_sim
=0.09705303244927427, service_sim =0.07742834286951933, comfort_sim
=0.0983829114784997, cleanliness_sim =0.07955493580493582,
label = 4 WHERE id = '1'
--- DONE ---
=====
['bass', 'like']
Final score Aspect LOCATION = 0.070228
Final score Aspect FOOD = 0.09951
Final score Aspect SERVICE = 0.07623
Final score Aspect COMFORT = 0.08933
Final score Aspect CLEANESS = 0.07826
In update lda_category SET location_sim =0.07022782772782774, food_sim
=0.09951152242818911, service_sim =0.07622978725919902, comfort_sim
=0.08933244043538163, cleanliness_sim =0.07826467011249619,
label = 2 WHERE id = '2'
--- DONE ---
=====
['sound', 'bathtub', 'clear', 'easy', 'use', 'very']
Final score Aspect LOCATION = 0.058058
```

```
Final score Aspect FOOD = 0.06029
Final score Aspect SERVICE = 0.06673
Final score Aspect COMFORT = 0.07853
Final score Aspect CLEANESS = 0.06377
In update lda_category SET location_sim =0.058058082081099166, food_sim
=0.06029019328277222, service_sim =0.06673150798763541, comfort_sim
=0.07852774973035208, cleanliness_sim =0.06376624333862575,
label = 4 WHERE id = '3'
--- DONE ---
=====
['clear', 'air', 'fresh', 'little', 'might', 'some']
Final score Aspect LOCATION = 0.021574
Final score Aspect FOOD = 0.02544
Final score Aspect SERVICE = 0.02169
Final score Aspect COMFORT = 0.02360
Final score Aspect CLEANESS = 0.02189
In update lda_category SET location_sim =0.021573616528973674, food_sim
=0.025440509207870332, service_sim =0.021687789396122734, comfort_sim
=0.02360458395997612, cleanliness_sim =0.02188933884506135,
label = 2 WHERE id = '4'
--- DONE ---
=====
['clear', 'very', 'but', 'disappoint', 'do', 'poor', 'say', 'service', 'understand', 'wish']
Final score Aspect LOCATION = 0.025258
Final score Aspect FOOD = 0.02475
Final score Aspect SERVICE = 0.02887
Final score Aspect COMFORT = 0.02556
Final score Aspect CLEANESS = 0.02317
In update lda_category SET location_sim =0.02525753676393878, food_sim
=0.02474625754502375, service_sim =0.028871705283469974, comfort_sim
```

```

=0.025555523997843554, cleanliness_sim =0.023174011456209113,
label = 3 WHERE id = '5'
--- DONE ---
=====
Etc.

```

<b>Label</b>	<b>Keterangan Label (Aspect)</b>
Label = 1	Location
Label = 2	Meal
Label = 3	Service
Label = 4	Comfort
Label = 5	Cleanliness

**Tabel 4.28** Hasil Klasifikasi Sentiment (SC1)

<b>id</b>	<b>Data Review</b> (direpresentasikan dalam bentuk angka vector)	<b>Aspect</b> <b>(Hasil</b> <b>AC3)</b>	<b>Hasil Analisa</b> <b>Sentiment</b>		<b>Label</b> <b>Sentime</b> <b>nt</b>
			<b>Positive</b>	<b>Negative</b>	
<b>1</b>	“Sound”, “Hear”, “Bass”	<b>Comfort</b>	0.345	0.757	<b>Negative</b>
<b>2</b>	“Sound”, “Bathtub”, “Clear”, “Easy”, “Use”	<b>Comfort</b>	0.875	0.223	<b>Positive</b>
<b>3</b>	“Clear”, “Disappoint”, “Poor”, “Say”, “Service”, “Understand”, “Wish”	<b>Service</b>	0.023	0.984	<b>Negative</b>
<b>4</b>	“Like”, “bass”	<b>Meal</b>	0.875	0.223	<b>Positive</b>

Data pada “Tabel 4.28 Hasil Klasifikasi Sentiment (SC1)” merupakan data akhir. Data dalam format inilah yang nantinya akan diproses untuk mendapatkan evaluasi akhir sebagai pemenuhan tujuan “3. Melakukan evaluasi terhadap setiap review untuk mengetahui hal apa dari bisnis yang membuat pelanggan puas maupun tidak puas yang didasarkan kepada 5 aspect hotel agar perusahaan mampu menyusun rencana perubahan, menata kembali bisnisnya dan mungkin

memperbaiki kesalahan mereka”. Cara membaca data dari tabel 4.28 adalah seperti “data pada id=1 memiliki aspect *comfort* dengan *sentiment negative*”.

#### 4.2.4. Hasil Evaluasi Sentimen pada Aspect Analysis Hotel

Setelah mencapai kesimpulan dari metode yang akan digunakan, penulis kemudian menerapkan metode tersebut untuk mendapatkan hasil akhir dari “Evaluasi Kepuasan Pelanggan Hotel Berdasarkan Analisa Sentiment Pada Review Pelanggan”. Hasil akhir dari metode yang digunakan untuk Kategorisasi Aspect dan Klasifikasi Sentiment telah ditampilkan pada “Tabel 4.27 Hasil Kategorisasi Aspect (AC3)” dan “Tabel 4.28 Hasil Klasifikasi Sentiment (SC1)”. Data dari hasil akhir ini akan dievaluasi untuk mendapatkan kepuasan pelanggan berdasarkan aspect.

Sebagai contoh proses evaluasi untuk mendapatkan hasil akhir dari “Evaluasi Kepuasan Pelanggan Hotel Berdasarkan Analisa Sentiment Pada Review Pelanggan”. Adalah sebagai berikut:

##### Start

1. Ambil data hasil akhir evaluasi “Tabel 4.28 Hasil Klasifikasi Sentiment (SC1)”.

id	Data Review (direpresentasikan dalam bentuk angka vector)	Aspect (Hasil AC3)	Hasil Analisa Sentiment		Label Sentiment
			Positive	Negative	
1	“Sound”, “Hear”, “Bass”	Comfort	0.345	0.757	Negative
2	“Sound”, “Bathtub”, “Clear”, “Easy”, “Use”	Comfort	0.875	0.223	Positive
3	“Clear”, “Disappoint”, “Poor”, “Say”, “Service”, “Understand”, “Wish”	Service	0.023	0.984	Negative

<b>4</b>	“Like”, “bass”	Meal	0.875	0.223	<b>Positive</b>
----------	----------------	------	-------	-------	-----------------

2. Pisahkan data berdasarkan aspect yang terdapat pada setiap review.

<b>id</b>	<b>Data Review</b> (direpresentasikan dalam bentuk angka vector)	<b>Aspect</b> (Hasil AC3)	<b>Label Sentiment</b>
<b>1</b>	“Sound”, “Hear”, “Bass”	<b>Comfort</b>	<b>Negative</b>
<b>2</b>	“Sound”, “Bathtub”, “Clear”, “Easy”, “Use”	<b>Comfort</b>	<b>Positive</b>

<b>id</b>	<b>Data Review</b> (direpresentasikan dalam bentuk angka vector)	<b>Aspect</b> (Hasil AC3)	<b>Label Sentiment</b>
<b>3</b>	“Clear”, “Disappoint”, “Poor”, “Say”, “Service”, “Understand”, “Wish”	<b>Service</b>	<b>Negative</b>

<b>id</b>	<b>Data Review</b> (direpresentasikan dalam bentuk angka vector)	<b>Aspect</b> (Hasil AC3)	<b>Label Sentiment</b>
<b>4</b>	“Like”, “bass”	<b>Meal</b>	<b>Positive</b>

3. Hitung total jumlah review dengan *sentiment negative* dan *positive* pada setiap aspect.

<b>Aspect</b>	<b>Sentiment</b>	<b>Total Jumlah Review</b>
Location	Positive	0
	Negative	0
Meal	Positive	1
	Negative	0
Service	Positive	0
	Negative	1

Comfort	Positive	1
	Negative	1
Cleanliness	Positive	0
	Negative	0

4. Total jumlah keseluruhan data.

Aspect	Sentiment	Total Jumlah Review
Location	Positive	0
	Negative	0
Meal	Positive	1
	Negative	0
Service	Positive	0
	Negative	1
Comfort	Positive	1
	Negative	1
Cleanliness	Positive	0
	Negative	0
Total		4

5. Lakukan ((data jumlah *positive* atau *negative* pada setiap kolom / total jumlah keseluruhan data) \*100) untuk melakukan normalisasi agar penjumlahan persentase mendapatkan hasil 100%.

Aspect	Sentiment	Total Jumlah Review	Hasil Evaluasi (Persentase)
Location	Positive	0	= (0/4)*100
	Negative	0	
Meal	Positive	1	
	Negative	0	
Service	Positive	0	
	Negative	1	
Comfort	Positive	1	
	Negative	1	
Cleanliness	Positive	0	
	Negative	0	
Total		4	

\*ps: angka dengan warna sama menunjukkan darimana data angka tersebut diambil. Misalnya, “=  $(0/4)*100$ ” angka 0 memiliki kesamaan warna dengan angka 0 pada total jumlah review, sehingga data angka 0 tersebut merupakan data milik total jumlah review.

**End**

\*ps: perhitungan diatas dilakukan pada data yang diambil sebagai contoh dan merupakan contoh perhitungan berdasarkan cara asli.

Berikut adalah hasil akhir dari evaluasi sentiment berdasarkan dari aspect hotel untuk optimasi Manajemen Hotel berdasarkan review online pelanggan menggunakan metode *Latent Dirichlet Allocation* (LDA) + *Term Frequency - Inverse Cluster Frequency* (TF-ICF) + Similarity dan *Word Embedding* + *Long Short Term Memory* (LSTM).

**Tabel 4.29** Hasil Evaluasi Sentimen pada Aspect Analysis Hotel

Sentiment Evaluation Results on Aspect		
Aspect	Sentiment	Evaluation Results (in Percent)
Location	Positive	21.11
	Negative	0.46
Meal	Positive	2.78
	Negative	0.69
Service	Positive	45.94
	Negative	3.02
Comfort	Positive	10.91
	Negative	11.37
Cleanliness	Positive	2.55
	Negative	1.16
Total Percentage		100

Dari tabel 4.29 dapat disimpulkan bahwa pelanggan hotel lebih sering memberikan review mengenai *service* atau pelayanan hotel, dimana hasil analisa pelayanan hotel memiliki 45,940 review *positif* dan 3,016 review *negative* dimana hal ini berarti pelayanan hotel sudah sangat memuaskan atau perlu diperbaiki sedikit lagi untuk menghilangkan 3,016 review *negative* terhadap pelayanan hotel. Review *positif* juga terdapat banyak pada topik *location* dengan 21,114 dan review *negative* hanya 0,464. Sedikit berbeda, dengan topik *service* maupun *location*, topik *cleanliness* dan *meal* memiliki perbedaan review *positif* dan *negative* hanya sedikit saja dimana, review *positif cleanliness* 2,552 dan memiliki review *negative* 1,160 begitu pula dengan topik *meal* yang memiliki review *positif* 2,784 dan review *negative* 0,696. Topik *comfort* memiliki perbedaan dari keseluruhan review yang telah dianalisa, dimana pada topik ini, jumlah review *negative* lebih besar daripada review *positif*, dimana review *positif comfort* 10,905 dan memiliki review *negative* 11,369.

Setelah evaluasi ini, penulis ingin mengetahui korelasi hubungan antara aspect dengan sentiment. Apakah benar aspect mempengaruhi sentiment yang akan didapatkan. Sehingga, dilakukanlah uji Chi-Square terhadap data hasil. Data hasil uji Chi-Square yang dilakukan dapat dilihat pada gambar 4.8 dibawah ini.

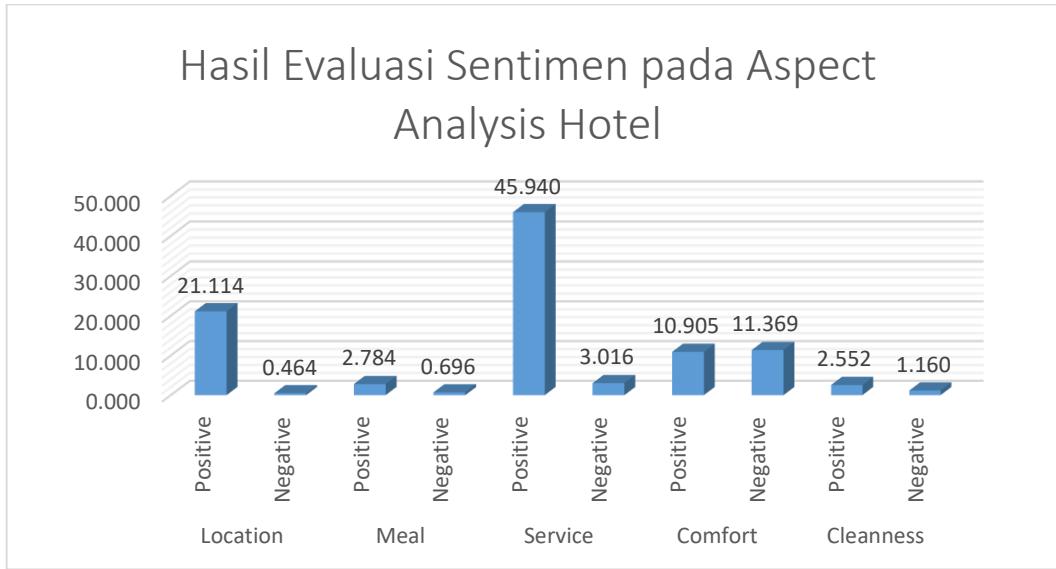
Chi-Square Tests			
	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	114.908 <sup>a</sup>	4	.000
Likelihood Ratio	104.034	4	.000
N of Valid Cases	431		

a. 2 cells (20.0%) have expected count less than 5. The minimum expected count is 2.51.

**Gambar 4.8** Uji Chi-Square korelasi hubungan Aspect terhadap Sentiment

Setelah dilakukan uji Chi-square terhadap korelasi hubungan aspect dengan *sentiment* didapatkan bahwa aspect dipengaruhi oleh *sentiment* secara signifikan dengan nilai signifikan yakni  $p < 0,001$ .

Hasil evaluasi Sentimen pada Aspect Analysis Hotel juga digambarkan dalam bentuk grafik seperti pada gambar 4.9 berikut.



**Gambar 4.9** Grafik Hasil Evaluasi Sentimen pada Aspect Analisis Hotel

#### 4.2.5.Pengaruh aspect terhadap sentiment

*Aspect based sentiment analysis* yang dilakukan oleh peneliti telah disimpulkan pada “Tabel 4.29”. Dari hasil pendekatan yang dilakukan, ditemukan bahwa “klasifikasi topic kedalam aspect hotel memiliki pengaruh terhadap hasil sentiment”. Peneliti menemukan bahwa adanya pengaruh aspect terhadap Klasifikasi Sentiment yang diberikan. Pengaruh yang dimaksud dapat dilihat pada contoh hasil sebagai berikut:

**Tabel 4.30** Contoh Kesalahan Hasil Klasifikasi Aspect dan Sentiment

Contoh review	Aspect	Sentiment
I Can Hear the Bass Sound	Comfort	Negative
They Like Grilled Bass	Meal	Positive

Dari tabel 4.30 pada contoh *review* dapat dilihat bahwa kata “*Bass*” memiliki 2 makna yang berbeda. *Bass* pada review pertama berarti alat *music bass* dan *bass* yang kedua berarti *bass* makanan atau ikan *bass*. Kedua “*bass*” tersebut kemudian memiliki aspect yang berbeda. *Bass* pertama pada aspect *comfort* karena merupakan alat *music* sehingga mengacu pada kenyamanan pelanggan sedangkan “*Bass*” yang kedua mengacu pada makanan berdasarkan sentence yang diberikan.

Walau memiliki kata yang sama “*Bass*”, sentiment yang dimiliki oleh setiap review dapat berbeda tergantung pada aspect dan sentence yang diberikan. Pada aspect pertama “*bass*” diklasifikasikan sebagai *comfort* sehingga dianggap sebagai gangguan karena “pelanggan dapat mendengar suara *bass*” yang bisa jadi pelanggan tersebut tidak nyaman dengan hal itu karena di hotel biasanya pelanggan akan membutuhkan kenyamanan dan ketenangan bukan suara *music* yang keras hingga terdengar oleh pelanggan lain dan merasa terganggu sehingga review ini memiliki aspect *negative*. Sedangkan “*Bass*” kedua dalam aspect makanan, ketika pelanggan mengatakan menyukai *bass* tersebut hal itu berarti pujian untuk makanan yang diberikan oleh hotel yang berarti memiliki sentiment *positive*.

*[Halaman ini sengaja dikosongkan]*

## **BAB 5**

### **KESIMPULAN DAN SARAN**

Pada bab terakhir ini, ditarik beberapa kesimpulan yang didapat dari hasil penelitian dan saran-saran yang dapat digunakan sebagai bahan pertimbangan untuk pengembangan atau riset selanjutnya

#### **5.1 Kesimpulan**

Berdasarkan metode yang telah diimplementasikan dan hasil uji coba yang diperoleh, maka dapat ditarik bebersapa kesimpulan:

1. Proses untuk melakukan Kategorisasi Aspect dapat dengan baik dilakukan dengan menggunakan metode *Latent Dirichlet Allocation* (LDA) Similarity dengan menggunakan penambahan perluasan *Term List* berbasis *Term Frequency - Inverse Cluster Frequency* (TF-ICF). Sedangkan untuk Klasifikasi Sentiment dapat dengan baik dilakukan dengan menggunakan metode *Word Embedding* serta metode *Long Short Term Memory* (LSTM) untuk melakukan proses klasifikasi.
2. Metode terbaik untuk melakukan proses Kategorisasi Aspect dilakukan dengan menggunakan *Latent Dirichlet Allocation* (LDA) sebagai metode untuk melakukan pencarian hidden topic dikombinasikan dengan *Term Frequency - Inverse Cluster Frequency* (TF-ICF) 100% (seluruh data term yang dihasilkan dari perhitungan TF-ICF) sebagai metode untuk melakukan perluasan term list pada saat perhitungan similarity serta *Semantic Similarity* untuk melakukan perhitungan similaritas setiap review terhadap 5 Aspect hotel (*location, meal, service, comfort* dan *cleaness*) dengan total nilai performa 85%. Dimana performa ini jauh diatas metode kategorisasi aspect lainnya dengan gap 19%.
3. Setelah dilakukan uji *Chi-square* terhadap korelasi hubungan aspect dengan sentiment didapatkan bahwa aspect dipengaruhi oleh sentiment secara signifikan dengan nilai signifikansi yakni  $p < 0,001$ .
4. Penambahan *Term Frequency - Inverse Cluster Frequency* (TF-ICF) yang bertugas untuk menemukan term-term yang merepresentasikan setiap aspect

dokumen menjadikan proses *Semantic Similarity* lebih baik. Penambahan *Term Frequency - Inverse Cluster Frequency* (TF-ICF) terdapat pada percobaan AC2 dan AC3 pada kategorisasi Aspect. Percobaan AC2 menerapkan 20% dari total TF-ICF yang ditemukan dan AC3 menerapkan 100% dari total TF-ICF yang ditemukan. Pada evaluasi performa, didapatkan pada percobaan AC2 lebih baik daripada percobaan AC1 (tidak menggunakan TF-ICF) dengan performa aplikasi 65% untuk AC2 dan 61% untuk AC1. Serta pada AC3 dengan menerapkan TF-ICF secara keseluruhan didapatkan hasil yang jauh lebih baik yakni 85%. Sehingga, dapat disimpulkan bahwa dengan melakukan penerapan penambahan *Term Frequency - Inverse Cluster Frequency* (TF-ICF) mampu menunjukkan hasil yang terbaik karena mampu meningkatkan performa hingga 24% dibandingkan dengan yang tidak menggunakan TF-ICF sama sekali.

5. Performa terbaik untuk melakukan Klasifikasi Sentiment dilakukan menggunakan *Long Short Term Memory* (LSTM) dengan *Pre Trained GloVe*. Dengan menggunakan cara ini, performa metode untuk analisa sentiment meningkat hingga 94%.
6. Kesimpulan akhir dari hasil evaluasi sentimen pada aspect analysis hotel menunjukkan bahwa:
  - 5.1. *Aspect service* memiliki jumlah review terbanyak dibandingkan dengan aspect lainnya. Pada *aspect service*, hotel memiliki banyak sentiment positive yakni 45,940 dengan sentiment negative hanya 3.016 hal ini berarti pelanggan sangat puas dengan pelayanan yang diberikan oleh pihak hotel.
  - 5.2. *Sentiment negative* terrendah adalah pada aspect *location* dengan 0.464 dimana hal ini berarti hotel telah berada pada lokasi yang tepat.
  - 5.3. Hal yang perlu diperhatikan adalah bahwa hotel memiliki *sentiment negative* yang lebih tinggi daripada *sentiment positive* pada aspect *comfort* 11,369, dimana hal ini berarti pihak manajemen hotel harus lebih memperhatikan kenyamanan yang diberikan kepada pelanggan.
7. Dari hasil yang didapatkan, diketahui pada aspect *service* memiliki tingkat sentiment *positive* yang tinggi, dibandingkan dengan aspect lainnya. Namun rating bintang yang terdapat di website (Gambar 1.1), menunjukkan bahwa

aspect *service* memiliki jumlah bintang yang sangat kurang sehingga dapat memunculkan persepsi bahwa *service* dari hotel tersebut buruk. Namun pada kenyatannya, setelah melakukan analisa secara mendalam dengan metode-metode yang digunakan, aspect *service* memiliki data kebalikannya. Sehingga dari sinilah disimpulkan bahwa tidak adanya hubungan antara rating bintang dengan review yang diberikan atau rating bintang tidak merepresentasikan kepuasan pelanggan dengan baik.

8. Hasil juga menunjukkan bahwa sentiment dipengaruhi oleh suatu aspect.

## 5.2 Saran

Beberapa saran atas penggerjaan tesis ini guna pengembangangan lebih lanjut diantaranya adalah:

1. Aspect yang memiliki *sentiment negative* tertinggi pada hotel “Manhattan, New York” yakni aspect *comfort*. Sehingga, disarankan untuk memperbaiki setiap aspect yang berhubungan dengan kenyamanan pelanggan. Diantaranya, pihak manajemen hotel dapat melakukan perbaikan terhadap fasilitas hotel sebagai layanan terhadap pelanggan. Fasilitas yang dimaksud dapat berupa memberbaiki kamar hotel agar pelanggan dapat lebih nyaman ketika berada di kamar, memperbaiki perabotan yang rusak dan terus mengutamakan kebersihan ruangan. Serta memperbaiki ataupun melatih para staff dengan tujuan agar staff mengetahui cara yang baik dan benar untuk membuat pelanggan nyaman salah satunya adalah dengan mengajarkan sikap ramah.
2. Penggunaan *semantic similarity* dapat dikuatkan dengan mempertimbangkan posisi kata serta hubungan kata pada kalimat dengan menggunakan beberapa metode seperti *word embedding*, posisi kata pada *linguistic rule*, serta pembobotan kata (*term weighting*).
3. Pada penelitian selanjutnya yang mungkin lebih terfokus pada *aspect-based sentiment analysis*, dapat menggunakan metode *Long Short Term Memory* (LSTM) dengan mempertimbangkan penggunaan layer untuk memeriksa data *aspect* terlebih dahulu kemudian review yang akan dilakukan analisa sentiment.

*[Halaman ini sengaja dikosongkan]*

## DAFTAR PUSTAKA

- Ady, M., & Felitti, D. Q. (2015). *Consumer Research Identifies Which Attributes Are Most Important to Travelers When Booking A Hotel*. London: Trust You.
- Akhtar, N., Zubair, N., Kumar, A., & Ahmad, T. (2017). Aspect based Sentiment Oriented Summarization of Hotel Reviews. *ScienceDirect: Computer Science*, 563–571. Doi: 10.1016/j.procs.2017.09.115.
- Ali, R., & O' Brien, J. (2014). *Skift report: state of travel 2014*. America: SkiftX, SkiftStats.
- Allison, B. (2013, 02 08). Stack Overflow. Retrieved from stackoverflow.com: <https://stackoverflow.com>
- AL-Sharuee, M. T., Liu, F., & Pratama, M. (2018). Sentiment analysis: An automatic contextual analysis and ensemble clustering approach and comparison. *ScienceDirect: Data & Knowledge Engineering*, 194-213. Doi: 10.1016/j.datak.2018.04.001.
- Ballesteros, P. T., Serrano, L. G., Ruiz, C. S., Romero, S. M., & Rojo-Álvarez, J. L. (2018). Using big data from Customer Relationship Management information systems to determine the client profile in the hotel sector. *ScienceDirect: Tourism Management*, 187–197. Doi: 10.1016/j.tourman.2018.03.017.
- Baskara, A. R., Sarno, R., & Solichah, A. (2016). Discovering traceability between business process and software component using Latent Dirichlet Allocation. *IEEE Xplore: 2016 International Conference on Informatics and Computing (ICIC)*, 251-256. Doi: 10.1109/IAC.2016.7905724.
- Bastani, K., Namavari, H., & Shaffer, J. (2019). Latent Dirichlet allocation (LDA) for topic modeling of the CFPB consumer complaints. *ScienceDirect: Expert Systems with Applications*, 256-271. Doi: 10.1016/j.eswa.2019.03.001.

- Blei , D. M., Ng , A. Y., & Jordan , M. I. (2003). Latent Dirichlet Allocation. *Journal of Machine Learning Research* 3 , 993-1022 . Doi: 10.1162/jmlr.2003.3.4-5.993.
- Cantaloops, A. S., & Salvi, F. (2014). New consumer behavior: a review of research on eWOM and hotels. . *International Journal of Hospitality Management*, 41–51. Doi: 10.1016/j.ijhm.2013.08.007.
- Chaudhuri, T. D., & Ghosh, I. (2016). Forecasting Volatility in Indian Stock Market using Artificial Neural Network with Multiple Inputs and Outputs. *Neural and Evolutionary Computing*, 7-15. Doi: 10.5120/21245-4034.
- Chen, G., & Chen, L. (2015). Augmenting service recommender systems by incorporating contextual opinions from user reviews. *User Modeling and User-Adapted Interaction*, 1-38. Doi: 10.1007/s11257-015-9157-3.
- Chen, Q., Yao, L., & Yang, J. (2017). Short text classification based on LDA topic model. *IEEE Xplore: 2016 International Conference on Audio, Language and Image Processing (ICALIP)*, 749-753. Doi: 10.1109/ICALIP.2016.7846525.
- Do, H. H., Prasad, P., Maag, A., & Alsadoon, A. (2019). Deep Learning for Aspect-Based Sentiment Analysis: A Comparative Review. *ScienceDirect: Expert Systems with Applications*, 272-299. Doi: 10.1016/j.eswa.2018.10.003.
- Duncan, O., Hu, J., Guyer, C., & Rabeler, C. (2018, 08 05). Training and Testing Data Sets. *Microsoft SQL Server Analysis Services*, pp. <https://docs.microsoft.com/en-us/sql/analysis-services/data-mining/training-and-testing-data-sets?view=sql-server-2017>.
- Elfving, J., & Lemoine, K. (2012). Exploring the concept of customer relationship management: Emphasizing socialPhd Master thesis. Supervisor: Karin Brunsson. Department of Business Studies, . *Uppsala University* , 05-25.
- Fu, Y., Yan, M., Zhang, X., Xu, L., Yang, D., & Kymer, J. D. (2015). Automated classification of software change messages by semi-supervised Latent Dirichlet Allocation. *ScienceDirect: Information and Software Technology*, 369-377. Doi: 10.1016/j.infsof.2014.05.017.

- Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *ScienceDirect: International Journal of Information Management*, 137-144. Doi: 10.1016/j.ijinfomgt.2014.10.007.
- Geetha, M., Singha, P., & Sinha, S. (2017). Relationship between customer sentiment and online customer ratings for hotels - An empirical analysis. *ScienceDirect: Tourism Management*, 43-54. Doi: 10.1016/j.tourman.2016.12.022.
- Ghazian, A., Hossaini, M. H., & Farsijani, H. (2016). The effect of customer relationship management and its significant relationship by customers' reactions in LG Company. *ScienceDirect: Economics and Finance*, 42 – 50. Doi: 10.1016/S2212-5671(16)30014-4.
- Gössling, S., & Lane, J. B. (2015). Rural tourism and the development of Internet-based accommodation booking platforms: a study in the advantages, dangers and implications of innovation. *J Sustain Tour*, 1386-1403. Doi: 10.1080/09669582.2014.909448.
- Hagen, L. (2018). Content analysis of e-petitions with topic modeling: How to train and evaluate LDA models? *ScienceDirect: Information Processing & Management*, 1292-1307. Doi: 10.1016/j.ipm.2018.05.006.
- Haislip, J. Z., & Richardson, V. J. (2017). The effect of Customer Relationship Management systems on firm performance. *ScienceDirect: International Journal of Accounting Information Systems*, 16-29. Doi: 10.1016/j.accinf.2017.09.003.
- Heikal, M., Torki, M., & El-Makky, N. (2018). Sentiment Analysis of Arabic Tweets using Deep Learning. *ScienceDirect: Procedia Computer Science*, 114-122. Doi: 10.1016/j.procs.2018.10.466.
- Heng, Y., Gao, Z., Jiang, Y., & Chen, X. (2018). Exploring hidden factors behind online food shopping from Amazon reviews: A topic mining approach. *ScienceDirect: Journal of Retailing and Consumer Services*, 161-168. Doi: 10.1016/j.jretconser.2018.02.006.
- Hu, Y.-H., & Chen, K. (2016). Predicting hotel review helpfulness: The impact of review visibility, and interaction between hotel stars and review ratings.

- International Journal of Information Management*, 929–944. Doi: 10.1016/j.ijinfomgt.2016.06.003.
- Huang, W., Rao , G., Feng, Z., & Cong, Q. (2018). LSTM with sentence representations for Document-level Sentiment Classification. *ScienceDirect: Neurocomputing*, 49-57. Doi: 10.1016/j.neucom.2018.04.045.
- Iosif, E., & Potamianos, A. (2013). Similarity computation using semantic networks created from web-harvested data. *Journal on Cambridge University Press 2013* , 49-79. Doi: 10.1017/S1351324913000144.
- Jiao, Y., & Du, P. (2016). Performance measures in evaluating machine learning based bioinformatics predictors for classifications. *Higher Education Press and Springer-Verlag Berlin Heidelberg*, 320-330. Doi: 10.1007/s4048
- Karimuddin, A. (2019, January 15). *DailySocial*. Retrieved from Traveloka Jadi Situs Pemesanan Kamar Hotel dan Tiket Pesawat Terpopuler Menurut Survei Nusaresearch: <https://dailysocial.id>
- Khotimah, D. A., & Sarno, R. (2018). Sentiment Detection of Comment Titles in Booking.com Using Probabilistic Latent Semantic Analysis. *ICCoICT 2018*. Doi: 10.1109/ICCoICT.2018.8528784
- Kim, K. (2018). An improved semi-supervised dimensionality reduction using feature weighting: Application to sentiment analysis. *ScienceDirect: Expert Systems with Applications*, 49-65. Doi: 10.1016/j.eswa.2018.05.023.
- Liu, P., Joty, S., & Meng, H. (2015). Fine-grained Opinion Mining with Recurrent Neural Networks and Word Embeddings. In *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, 1433-1443. Doi: 0.18653/v1/D15-1168.
- Liu, Y., Jin, J., Ji, P., Harding, J. A., & Fung, R. Y. (2013). Identifying helpful online reviews: A product designer's perspective. *Sciedirect: Computer-Aided Design*, 180-194. Doi: 10.1016/j.cad.2012.07.008.
- Mikolov, T., Chen, K., Sutskever, I., & Corrado, G. (2013). Distributed Representations of Words and Phrases and their Compositionality. *Advances in neural information processing systems*, 1-9.

- Miller, T., Savova, G., & Dligach, D. (2016). Unsupervised Document Classification with Informed Topic Models. *Conference: Proceedings of the 15th Workshop on Biomedical Natural Language Processing*, 83-91. Doi: 10.18653/v1/W16-2911.
- Park, E., Choi, D., Kang, J., & Han, J. (2018). Understanding customers' hotel revisiting behaviour: a sentiment analysis of online feedback reviews. *Current Issues in Tourism*, 1-7. Doi: 10.1080/13683500.2018.1549025.
- Petrick, J. F. (2004). Are loyal visitors desired visitors? *ScienceDirect: Tourism Management*, 463-470. Doi: 10.1016/S0261-5177(03)00116-X.
- Priyantina, R.A., & Sarno, R. (2019). Sentiment Analysis of Hotel Reviews Using Latent Dirichlet Allocation, Semantic Similarity and LSTM. *International Journal of Intelligent Engineering and Systems (IJIES)*, 142-155. Doi: 10.22266/ijies2019.0831.14.
- Puspaningrum, A., Siahaan, D., & Faticahah, C. (2018). Mobile App Review Labeling Using LDA Similarity and Term Frequency-Inverse Cluster Frequency (TF-ICF). *ResearchGate: Conference: 2018 10th International Conference on Information Technology and Electrical Engineering (ICITEE)*, 365-370. Doi: 10.1109/ICITEED.2018.8534785.
- Rao, G., Huang, W., Feng, Z., & Cong, Q. (2018). LSTM with sentence representations for document-level sentiment classification. *ScienceDirect: Neurocomputing*, 49-57. Doi: 10.1016/j.neucom.2018.04.045.
- Rezaeinia, S. M., Rahmani, R., Ghodsi, A., & Veisi, H. (2019). Sentiment analysis based on improved pre-trained word embeddings. *Expert Systems with Applications*, 139-147. Doi: 10.1016/j.eswa.2018.08.044
- Schuckert, M., Law, R., & Xianwei, L. (2015). Hospitality and Tourism Online Reviews: Recent Trends and Future Directions. *Research Gate: Journal of Travel & Tourism Marketing*, 608-621. Doi: 10.1080/10548408.2014.933154.
- Soler, J., Tence, F., Gaubert, L., & Buche, C. (2013). Data Clustering and Similarity. *Proceedings of the Twenty-Sixth International Florida Artificial Intelligence Research Society Conference*, 492-495.

- Soltani, Z., & Navimipour, N. J. (2016). Customer relationship management mechanisms: A systematic review of the state of the art literature and recommendations for future research. *ScienceDirect: Computers in Human Behavior*, 667-688. Doi: 10.1016/j.chb.2016.03.008.
- Suadaa, L. H., & Purwarianti, A. (2016). Combination of Latent Dirichlet Allocation (LDA) and Term Frequency-Inverse Cluster Frequency (TFxICF) in Indonesian text clustering with labeling. *ResearchGate: Conference on Information and Communication Technology (ICoICT)*, 1-6. Doi: 10.1109/ICoICT.2016.7571885.
- Suhariyanto, Sarno, R., & Firmanto, A. (2018). Prediction of Movie Sentiment Based on Reviews and Score on Rotten Tomatoes Using SentiWordnet. *IEEE Xplore: Conference Paper 2018 International Seminar on Application for Technology of Information and Communication (iSemantic)*, 202-206. Doi: 10.1109/ISEMANTIC.2018.8549704.
- Tsai, C.-F., Lin, W.-C., Hu, Y.-H., & Yao, G.-T. (2019). Under-sampling class imbalanced datasets by combining clustering analysis and instance selection. *ScienceDirect: Information Sciences*, 47-54. Doi: 10.1016/j.ins.2018.10.029.
- Wang, J., Peng, B., & Zhang, X. (2018). Using a Stacked Residual LSTM Model for Sentiment Intensity Prediction. *ScienceDirect: Neurocomputing*, 93-101. Doi: 10.1016/j.neucom.2018.09.049.
- Wu, M.-S., & Chien, J.-T. (2010). A new topic-bridged model for transfer learning. *IEEE Xplore: 2010 IEEE International Conference on Acoustics, Speech and Signal Processing*, 5349-5349. Doi: 10.1109/ICASSP.2010.5494947.
- Xiang, Z., Uysal, M., & Schwartz, Z. (2017). Market Intelligence: Social Media Analytics and Hotel Online Reviews. *Analytics in Smart Tourism Design: Concepts and Methods*, 281-295. Doi: 10.1007/978-3-319-44263-1\_16.
- Xu, X., Wang, X., Li, Y., & Haghghi, M. (2017). Business intelligence in online customer textual reviews: Understanding consumer perceptions and influential factors. *Sciencedirect: International Journal of Information Management*, 673-683. Doi: 10.1016/j.ijinfomgt.2017.06.004.

- Yacouel, N., & Fleischer, A. (2012). The role of cybermediaries in reputation building and price premiums in the online hotel market. *Journal of Travel Research*, 219–226. Doi: 10.1177/0047287511400611.
- Yoo, M., & Bai, B. (2013). Customer loyalty marketing research: A comparative approach between hospitality and business journals. *ScienceDirect: International Journal of Hospitality Management*, 166-177. Doi: 10.1016/j.ijhm.2012.07.009.
- Zhai, Z., Liu, B., Xu, H., & Jia, P. (2011 ). Clustering product features for opinion mining. *Web search and data mining*, 347-354. Doi: 10.1145/1935826.1935884.

*[Halaman ini sengaja dikosongkan]*

## LAMPIRAN I

Berikut penulis lampirkan penjabaran *Confusion Matrix* beserta hasil perhitungan *Precision*, *Recall* dan *F1 Measure* yang digunakan pada saat evaluasi performa.

### 1. Perhitungan Performa untuk Kategorisasi Aspect (AC1)

Confusion Matrix Kategorisasi Aspect (AC1)						
Predicted Value	Actual Value					
	Location	Meal	Service	Comfort	Cleanliness	
	Location	62	0	1	3	1
	Meal	0	14	13	2	0
	Service	15	0	173	33	2
	Comfort	22	0	64	97	20
	Cleanliness	0	0	0	1	6

Aspect	Total Nilai
Location	Precision
	Recall
	F1 Measure
Meal	Precision
	Recall
	F1 Measure
Service	Precision
	Recall
	F1 Measure
Comfort	Precision
	Recall
	F1 Measure
Cleanliness	Precision
	Recall
	F1 Measure

Rata-rata	Precision	0.647
	Recall	0.704
	F1 Measure	0.607

## 2. Perhitungan Performa untuk Kategorisasi Aspect (AC2)

Confusion Matrix Kategorisasi Aspect (AC2)					
Predicted Value	Actual Value				
	Location	Meal	Service	Comfort	Cleanliness
	Location	66	0	1	2
	Meal	2	14	13	3
	Service	9	0	197	29
	Comfort	13	0	48	101
	Cleanliness	0	0	0	9

Aspect	Total Nilai
Location	Precision
	Recall
	F1 Measure
Meal	Precision
	Recall
	F1 Measure
Service	Precision
	Recall
	F1 Measure
Comfort	Precision
	Recall
	F1 Measure
Cleanliness	Precision
	Recall
	F1 Measure

Rata-rata	Precision	0.706
	Recall	0.754
	F1 Measure	0.663

### 3. Perhitungan Performa untuk Kategorisasi Aspect (AC3)

Confusion Matrix Kategorisasi Aspect (AC3)					
Predicted Value	Actual Value				
	Location	Meal	Service	Comfort	Cleanliness
Location	85	0	0	1	0
Meal	0	14	3	3	0
Service	2	0	268	6	1
Comfort	6	0	19	107	3
Cleanliness	0	2	0	0	9

Aspect	Total Nilai
Location	Precision
	Recall
	F1 Measure
Meal	Precision
	Recall
	F1 Measure
Service	Precision
	Recall
	F1 Measure
Comfort	Precision
	Recall
	F1 Measure
Cleanliness	Precision
	Recall
	F1 Measure

Rata-rata	Precision	0.864
	Recall	0.853
	F1 Measure	0.854

## LAMPIRAN II

### 1. Perhitungan Performa untuk Klasifikasi Sentiment (SC1)

Confusion Matrix SC1

Predicted Value	Actual Value	
	Positive	Negative
TP	FN	
Positive	80	4
Negative	6	-
FP	TN	
Positive		Negative

		Total Nilai
Klasifikasi Sentiment (SC1)	Precision	0.914
	Recall	0.988
	F1 Measure	0.950

### 2. Perhitungan Performa untuk Klasifikasi Sentiment (SC2)

Confusion Matrix SC2

Predicted Value	Actual Value	
	Positive	Positive
TP	TP	
Positive	56	15
Negative	19	-
FP	TN	
Positive		Negative

		Total Nilai
Klasifikasi Sentiment (SC1)	Precision	0.747
	Recall	0.789
	F1 Measure	0.767

### 3. Perhitungan Performa untuk Klasifikasi Sentiment (SC3)

Confusion Matrix SC3

Predicted Value	Actual Value	
	Positive	Positive
Positive	TP	TP
71	11	
Negative	8	-
	FP	TN
	Positive	Negative

		Total Nilai
Klasifikasi Sentiment (SC1)	Precision	0.899
	Recall	0.866
	F1 Measure	0.882

## **LAMPIRAN III**

### **Daftar Singkatan:**

*Customer relationship management* (CRM)

*Latent Dirichlet Allocation* (LDA)

*Term Frequency - Inverse Cluster Frequency* (TF-ICF)

*Recurrent Neural Network* (RNN)

*Long Short Term Memory* (LSTM)

*Global Vector* (GloVe)

*Natural Language Processing* (NLP)

*Continous bag-of words* (CBOW)

*Semantic/Syntactic extraction using a neural network architecture* (SENNNA)

*Part-Of-Speech* (POS)

*Name Entity Recognition* (NER)

*Semantic Role Labelling* (SLR)

*Syntactic Parsing* (PSG)

*True Positive* (TP)

*True Negative* (TN)

*False Positive* (FP)

*False Negative* (FN)

*Latent Semantic Analysis* (LSA)

*Probabilistic Latent Semantic Analysis* (PLSA)

*State Refinegement- Long Short Term Memory* (SR-LSTM)

*Aspect Categorization* (AC)

*Sentiment Classification* (SC)

*[Halaman ini sengaja dikosongkan]*

## **LAMPIRAN IV**

Bismillah,

Kesempurnaan hanyalah milik Allah SWT.

Bagaimanapun penulis mencoba menuliskan thesis ini dengan sempurna, masih ada kekurangan di dalamnya. Oleh karena itu, penulis selalu mengingatkan diri dan berusaha untuk menjadi lebih baik lagi.

Beberapa kata-kata yang menyemangati penulis yakni:

“Orang yang luar biasa itu sederhana dalam ucapan, tetapi hebat dalam tindakan”  
“Teruslah berlari mengejar impianmu, hingga suara cemoohan itu berubah menjadi tepuk tangan”

*[Halaman ini sengaja dikosongkan]*

## BIOGRAFI PENULIS



Reza Amalia Priyantina, lahir di Pasuruan 23 September 1992. Penulis menempuh pendidikan dasar pada tahun 1999 di SDN Tropodo IV, pendidikan sekolah menengah di SMP PGRI 7 Sedati, selanjutnya di SMK Senopati Sedati, Sidoarjo. Penulis kemudian menempuh pendidikan sarjana pada tahun 2010 di Institut Bisnis dan Informatika STIKOM Surabaya di jurusan Sistem Informasi fakultas Teknologi dan Informatika. Pada saat menyelesaikan pendidikan S1 penulis mengambil konsentrasi bidang rancang bangun system informasi dan aplikasi. Kemudian penulis menempuh pendidikan S2 di Manajemen Teknologi Informasi (MTI)-Institut Teknologi Sepuluh Nopember (ITS). Pada saat menyelesaikan pendidikan S2, penulis mengambil konsentrasi bidang pada: *sentiment analysis*, *data categorization*, dan *topic modelling*. Penulis pernah juga melakukan riset mengenai *business process* yang mengacu pada COBIT. Penulis dapat dihubungi di email [rezaradcliffe@gmail.com](mailto:rezaradcliffe@gmail.com) ataupun telepon 082257600912.

### Riwayat Penelitian Penulis:

- Rancang Bangun Website Toko *Online* dengan Penerapan *Product Knowledge* dan *Strategi Up Selling* pada Mc Store Surabaya.
- *Measuring Maturity Index of Risk Management for IT-Governance Using Fuzzy Ahp and Fuzzy Topsis - Conference: 2018 International Seminar on*

*Application for Technology of Information and Communication* (iSemantic)

- DOI: 10.1109/ISEMANTIC.2018.8549732.

- *Sentiment Analysis of Hotel Reviews Using Latent Dirichlet Allocation, Semantic Similarity and LSTM - International Journal of Intelligent Engineering and Systems (IJIES) – 2019 - DOI: 10.22266/ijies2019.0831.14.*