



TESIS - BM185407

**ANALISIS SENTIMEN BERDASARKAN ASPEK PADA  
REVIEW HOTEL MENGGUNAKAN PROBABILISTIC  
LATENT SEMANTIC ANALYSIS, WORD  
EMBEDDING, DAN LSTM**

**DEWI AYU KHUSNUL KHOTIMAH  
09211750053002**

**Dosen Pembimbing:  
Prof. Drs.Ec. Ir. Riyanarto Sarno, M.Sc., Ph.D**

**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:

**DEWI AYU KHUSNUL KHOTIMAH**

**NRP: 09211750053002**

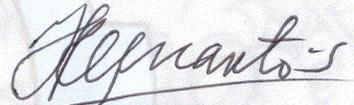
Tanggal Ujian: 15 April 2019

Periode Wisuda: September 2019

Disetujui oleh:

**Pembimbing:**

1. **Prof. Drs.Ec. Ir. Riyanarto Sarno, M.Sc., Ph.D.**  
**NIP: 19590803 198601 1 001**



.....

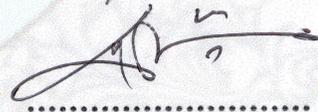
**Penguji:**

1. **Erma Suryani, ST, MT, Ph.D.**  
**NIP: 19700427 200501 2 001**



.....

2. **Faizal Mahananto, S.Kom., M.Eng., Ph.D**  
**NIP: 19851031 201903 1 009**



.....

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]*

# ANALISIS SENTIMEN BERDASARKAN ASPEK pada REVIEW HOTEL Menggunakan PROBABILISTIC LATENT SEMANTIC ANALYSIS, WORD EMBEDDING, dan LSTM

Nama Mahasiswa : Dewi Ayu Khusnul Khotimah  
NRP : 09211750053002  
Pembimbing : Prof. Drs.Ec. Ir. Riyanarto Sarno, M.Sc.,Ph.D.

## ABSTRAK

Di era industri 5.0, ulasan produk sangat penting untuk keberlanjutan perusahaan. Ulasan produk adalah fitur *User Generated Content* (UGC) yang menggambarkan kepuasan pelanggan secara keseluruhan. Kepuasan pelanggan dapat diukur berdasarkan aspek yang mempengaruhinya. Penelitian ini menggunakan 3 pendekatan untuk kategorisasi aspek (AC) dan klasifikasi sentimen (SC) berdasarkan lima aspek hotel. Kelima aspek hotel diambil dari website Traveloka meliputi *Location*, *Meal*, *Service*, *Comfort*, dan *Cleanliness*. Penelitian ini hanya mengambil ulasan produk yang menggunakan bahasa inggris. Setiap ulasan produk, akan di *preprocessing* menjadi dokumen *term list*. Dokumen *term list*, digunakan sebagai *input* data awal untuk keseluruhan proses penelitian yang menggunakan bahasa pemrograman Python.

Tiga pendekatan dalam kategorisasi aspek (AC) dan klasifikasi sentimen (SC) digunakan untuk menguji performa terbaik dari beberapa metode yang diusulkan. Penelitian ini mengusulkan metode *Probabilistic Latent Semantic Analysis* (PLSA) yang digunakan untuk menghasilkan *hidden topic*. Metode *Semantic Similarity* digunakan untuk klasifikasi *topic* ke dalam lima aspek hotel. Adapun perluasan *term list* pada saat pengukuran *similarity* menggunakan metode *Term Frequency-Inverse Cluster Frequency* (TF-ICF). Penelitian ini juga mengusulkan metode *Word embedding* untuk mendapatkan nilai *vector* pada metode *deep learning* dari *Long Short-Term Memory* (LSTM) untuk klasifikasi sentimen.

Hasil penelitian menunjukkan bahwa pendekatan AC3 (metode PLSA + TF ICF 100% + *Semantic Similarity*) memiliki nilai yang lebih unggul yaitu 0,839 dalam kategorisasi aspek; Pendekatan SC1 (metode *Word Embedding* + LSTM) mengungguli dalam klasifikasi sentimen dengan nilai 0,940; aspek *service* memiliki nilai sentimen *positive* yang lebih tinggi yaitu 45,545 dibandingkan aspek yang lain; aspek *comfort* memiliki nilai sentimen *negative* yang lebih tinggi yaitu 12,871 dibandingkan aspek yang lain. Hasil penelitian dapat disimpulkan bahwa *service* hotel yang baik tidak menjamin kenyamanan pelanggan. Aspek hotel yang sama dapat memiliki nilai sentimen yang berbeda, hal ini dibuktikan dengan analisis sentimen yang dapat dipengaruhi oleh aspek.

**Kata kunci** : Ulasan Produk, Kepuasan Pelanggan, Aspek Hotel, Dokumen *term list*, *hidden topic*, *Semantic Similarity*, *Aspect categorization*, *Word Embedding*, *Deep Learning*, Klasifikasi Sentimen.

*[Halaman ini sengaja dikosongkan]*

# **SENTIMENT ANALYSIS BASED ON HOTEL REVIEW ASPECTS USING PROBABILISTIC LATENT SEMANTIC ANALYSIS, WORD EMBEDDING, AND LSTM**

By : Dewi Ayu Khusnul Khotimah  
Student Identity Number : 09211750053002  
Supervisor : Prof. Drs.Ec. Ir. Riyanarto Sarno, M.Sc.,Ph.D.

## **ABSTRACT**

In the industrial era 5.0, product review is necessary for corporate sustainability. Product review is a User Generated Content (UGC) feature that describes overall customer satisfaction. Customer satisfaction can be measured based on a number of aspects. This study uses 3 approaches for aspect categorization (AC) and sentiment classification (SC) based on five hotel aspects of the hotel. Those five hotel aspects were obtained from the Traveloka website including Location, Meal, Service, Comfort, and Cleanliness. This study only took product reviews in English. Each product review underwent preprocessing to be a term list document. The term list document was used as the initial data input for the entire research process using the Python programming language.

Three approaches of aspect categorization (AC) and sentiment classification (SC) were used to test the best performance of the proposed methods. This study proposed the Probabilistic Latent Semantic Analysis (PLSA) method to produce hidden topics. The Semantic Similarity method was used to classify the topic into five hotel aspects. The expansion of the term list during similarity measurement used the Term Frequency-Inverse Cluster Frequency (TF-ICF) method. This study also proposed the Word embedding method to obtain vector values in deep learning method of Long Short-Term Memory (LSTM) for sentiment classification.

The result showed that the AC3 approach (ICF 100% + Semantic Similarity PLSA + TF) had a superior value of 0,839 in aspect categorization; The SC1 approach (Word Embedding + LSTM method) outperformed the sentiment classification with a value of 0,940; aspect service obtained higher positive sentiment value of 45.545 compared to the other aspects; the comfort aspect obtained a higher negative sentiment value of 12.871 compared to the other aspects. It can be concluded that good hotel service did not guarantee customer satisfaction. The same hotel aspect could obtain different sentiment values, evidenced by the sentiment analysis which could be affected by the aspects.

**Keywords:** Product Review, Customer Satisfaction, Hotel Aspect, Term list document, hidden topic, Semantic Similarity, Aspect categorization, Word Embedding, Deep Learning, Sentiment Classification.

*[Halaman ini sengaja dikosongkan]*

## 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. Riyanarto 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, ST, MT, Ph.D, M.Sc. dan Bapak Faizal Mahananto, 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, motivasi dan pengetahuan kepada penulis selama menempuh studi.
5. Ayah yang senantiasa memberikan bantuan secara materil dan Almh. Ibu sebagai pembuktian janji penulis dalam menyelesaikan studi tepat waktu, serta Kakak yang membantu dalam hal transportasi selama studi.
6. Regy, Ansya, Reni Malisa dan Erlin Eka yang senantiasa memberikan motivasi, semangat, dan perhatian kepada penulis dalam menyelesaikan studi dan tesisnya.
7. Teman-teman dari bimbingan Prof. Drs.Ec. Ir. Riyanarto Sarno di MMT jurusan Manajemen Teknologi Informasi angkatan 2017 yang senantiasa

memberikan bantuan dan semangat dalam suka dan duka kepada penulis selama menyelesaikan studi.

8. Barista-barista Starbucks graha pena, Surabaya yang senantiasa menghibur penulis selama menyelesaikan tesis.
9. 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. 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.

*"Allah, i do thank You for (a child who has but one parent living), my failed plan, postponed journey because it brings me to people, something, somewhere, and chance better, bigger, and brighter"*

Surabaya, 29 Juli 2019

Penulis

**Dewi Ayu Khusnul Khotimah**

## DAFTAR ISI

LEMBAR PENGESAHAN .....	iii
ABSTRAK .....	v
ABSTRACT .....	vii
KATA PENGANTAR .....	ix
DAFTAR ISI .....	xi
DAFTAR GAMBAR .....	xv
DAFTAR TABEL .....	xvii
BAB 1 PENDAHULUAN .....	1
1.1. Latar Belakang .....	1
1.2. Perumusan Masalah .....	7
1.3. Tujuan .....	7
1.4. Manfaat .....	7
1.5. Kontribusi Penelitian .....	7
1.6. Batasan Masalah .....	9
1.7. Sistematika Penulisan .....	10
BAB 2 KAJIAN PUSTAKA .....	11
2.1 Industry 5.0 ( <i>Society 5.0</i> ) .....	11
2.2 Kepuasan Pelanggan .....	13
2.3 E-Commerce .....	14
2.4 Pengumpulan Data .....	16
2.5 <i>Keyword Term List</i> untuk Aspek Hotel .....	16
2.6 Pengolahan Bahasa Manusia .....	17
2.6.1 <i>Pre Processing</i> .....	17
2.6.2 <i>Expanded Term List (TF-ICF)</i> .....	19

2.6.3	<i>Probabilistic Latent Semantic Analysis (PLSA)</i> .....	19
2.6.4	<i>Semantic Similarity</i> .....	22
2.6.5	<i>Word Embedding</i> .....	23
2.6.6	<i>Long-Short Term Memory (LSTM)</i> .....	25
2.6.7	Evaluasi .....	29
2.7	Website Traveloka .....	30
2.8	Penelitian Sebelumnya.....	34
BAB 3 METODOLOGI PENELITIAN .....		39
3.1	Metodologi Penelitian.....	40
3.2	Pembangunan Model Penelitian .....	42
3.2.1	Data Ulasan Produk Hotel .....	44
3.2.2	Preprocessing.....	46
3.2.3	Modul Perluasan <i>Term List (Expanding Term List)</i> .....	47
3.2.4	Aspect Categorization .....	50
3.2.5	<i>Pre-process Aspect Based Sentiment Classification</i> .....	55
3.2.6	<i>Sentiment Classification (SC)</i> .....	56
3.2.7	Evaluasi .....	60
BAB 4 HASIL PENELITIAN DAN PEMBAHASAN.....		63
4.1	Implementasi Sistem.....	63
4.1.1	Data Ulasan Produk Hotel .....	63
4.1.2	Preprocessing Data .....	63
4.1.3	Expanding Term List.....	64
4.1.4	Proses Kategorisasi Aspek (AC) .....	69
4.1.5	<i>Pre-Process Aspect based Sentiment Classification</i> .....	74
4.1.6	Proses <i>Sentiment Classification (SC)</i> .....	75
4.2	Hasil Pengujian dan Evaluasi.....	80

4.2.1. Pendekatan Evaluasi untuk Kategorisasi Aspek (AC).....	80
4.2.2. Pendekatan Evaluasi untuk Klasifikasi Sentimen (SC).....	86
4.3 Kesimpulan Metode yang akan di Gunakan .....	90
4.4 Evaluasi Analisis Sentimen berdasarkan Aspek Hotel .....	91
4.4.1 Hubungan Kategorisasi Aspek Hotel dengan Analisis Sentimen.....	92
4.5 Pengaruh Sentimen terhadap Aspek Hotel.....	94
BAB 5 KESIMPULAN DAN SARAN .....	97
5.1 Kesimpulan.....	97
5.2 Saran.....	99
DAFTAR PUSTAKA .....	101
BIODATA PENULIS .....	107
LAMPIRAN 1 .....	109
LAMPIRAN 2.....	111

*[Halaman ini sengaja dikosongkan]*

## DAFTAR GAMBAR

<b>Gambar 1.1</b> Tampilan Website Traveloka.....	2
<b>Gambar 2.1</b> Interaksi dan kolaborasi antara manusia dan mesin pada Industri 5.0 .....	11
<b>Gambar 2.2</b> Memasuki Masyarakat 5.0.....	12
<b>Gambar 2.3</b> Ilustrasi kepuasan pelanggan dalam bentuk rating bintang.....	14
<b>Gambar 2.4</b> Data Pertumbuhan Pengguna Internet tahun 2017 APJI.....	15
<b>Gambar 2.5</b> Ulasan Pelanggan pada hotel Times Square, Manhattan, New York, 2018.....	16
<b>Gambar 2.6</b> Proses dari <i>Crawling</i> data menggunakan WebHarvy.....	16
<b>Gambar 2.7</b> Enam tahap dalam Preprocessing.....	18
<b>Gambar 2.8</b> Proses Keseluruhan Ekstraksi Topic metode PLSA.....	20
<b>Gambar 2.9</b> Contoh dari <i>Word Embedding</i> .....	23
<b>Gambar 2.10</b> Contoh Penggunaan <i>Word Embedding</i> .....	25
<b>Gambar 2.11</b> Standard metode LSTM.....	26
<b>Gambar 2.12</b> Ilustrasi metode LSTM.....	27
<b>Gambar 2.13</b> Tingkat Konversi dari Kunjungan Website Tahun 2016.....	31
<b>Gambar 2.14</b> Peringkat & Kunjungan Website di Indonesia Tahun 2016 versi Alexa.....	32
<b>Gambar 2.15</b> Alexa Traffic Ranks Tahun 2019.....	33
<b>Gambar 2.16</b> Similiarweb Traffic Ranks Tahun 2019.....	33
<b>Gambar 3.1</b> Diagram Alur Penelitian.....	39
<b>Gambar 3.2</b> Diagram Alur Model Penelitian.....	42
<b>Gambar 3.3</b> Proses dari <i>Aspect Categorization</i> .....	50
<b>Gambar 3.4</b> Proses dari <i>Pre-process Aspect based Sentiment Classification</i> .....	55
<b>Gambar 3.5</b> Proses dari <i>Sentiment Classification (SC)</i> .....	56
<b>Gambar 3.6</b> Ilustrasi <i>sentiment classification</i> pada aspek hotel.....	57
<b>Gambar 3.7</b> Contoh data Klasifikasi <i>Sentiment</i> dengan <i>Aspect</i> “Location” Menggunakan “SC1”.....	58
<b>Gambar 3.8</b> Proses dari <i>Word Embedding</i> .....	58

<b>Gambar 4.1</b> Ilustrasi Perhitungan <i>Term Frequency</i> (TF).....	65
<b>Gambar 4.2</b> Ilustrasi perhitungan <i>Inverse Cluster Frequency</i> (ICF) .....	66
<b>Gambar 4.3</b> Ilustrasi perhitungan <i>term</i> . .....	67
<b>Gambar 4.4</b> Ilustrasi Penerapan Model ke Setiap Kata dalam <i>Corresponding Vector</i> .....	76
<b>Gambar 4.5</b> Performa metode dari <i>Aspect Categorization</i> (AC).....	85
<b>Gambar 4.6</b> Performa metode dari <i>Sentiment Classification</i> (SC) .....	89
<b>Gambar 4.7</b> Grafik Hasil Klasifikasi Sentimen berdasarkan Kategorisasi Aspek .....	91
<b>Gambar 4.8</b> Chi Square Tabel.....	94

## DAFTAR TABEL

<b>Tabel 2.1</b> <i>Keyword Term List</i> Aspek Hotel yang diperoleh .....	17
<b>Tabel 2.2</b> Tiga metode dari <i>Word Embedding</i> yang tersedia secara umum .....	24
<b>Tabel 3.1</b> Hasil data <i>crawling</i> menggunakan WebHarvy.....	45
<b>Tabel 3.2</b> Hasil <i>Crawling</i> dengan pelabelan dokumen .....	45
<b>Tabel 3.3</b> Ilustrasi dari Data <i>Preprocessing</i> .....	46
<b>Tabel 3.4</b> Hasil dari Data <i>Preprocessing</i> untuk Masukan Proses Klasifikasi .....	47
<b>Tabel 3.5</b> <i>Keyword Term List</i> + Hasil TF-ICF terkait 5 Aspek.....	49
<b>Tabel 3.6</b> Tabel Contoh <i>Input</i> dan <i>Output</i> proses PLSA.....	52
<b>Tabel 3.7</b> Contoh Perbandingan <i>Hidden Topic</i> dan <i>Term List</i> Setiap Aspek.....	53
<b>Tabel 3.8</b> Contoh Hasil Perhitungan <i>Semantic Similarity</i> untuk Setiap Aspek ...	54
<b>Tabel 3.9</b> Contoh Hasil Klasifikasi Sentimen menggunakan <i>Word Embedding</i> + LSTM.....	59
<b>Tabel 4.1</b> Hasil <i>Pre-processing</i> untuk Masukan Proses Klasifikasi .....	64
<b>Tabel 4.2</b> Contoh Hasil Perhitungan <i>Term Frequency</i> .....	66
<b>Tabel 4.3</b> Contoh Hasil Perhitungan <i>Inverse Cluster Frequency</i> .....	67
<b>Tabel 4.4</b> Contoh Hasil Perhitungan TF-ICF .....	68
<b>Tabel 4.5</b> Hasil <i>Hidden Topic</i> dari metode PLSA.....	70
<b>Tabel 4.6</b> Hasil Perhitungan metode PLSA + <i>Semantic Similarity</i> .....	71
<b>Tabel 4.7</b> Hasil Perhitungan PLSA + <i>Semantic Similarity</i> + TF ICF 20% .....	73
<b>Tabel 4.8</b> Hasil Perhitungan PLSA + <i>Semantic Similarity</i> + TF ICF 100% .....	74
<b>Tabel 4.9</b> Data Hasil <i>Aspect Categorization (AC3)</i> .....	74
<b>Tabel 4.10</b> Data <i>Aspect-Based Sentiment (Aspect Cleanliness)</i> .....	75
<b>Tabel 4.11</b> Data <i>Aspect-Based Sentiment (Aspect Service)</i> .....	75
<b>Tabel 4.12</b> Hasil Klasifikasi Sentimen Menggunakan <i>Word Embedding</i> + LSTM .....	77
<b>Tabel 4.13</b> Tabel Hasil Klasifikasi Sentimen Menggunakan SentiWordNet.....	78
<b>Tabel 4.14</b> Hasil Klasifikasi Sentimen Menggunakan metode LSTM.....	79
<b>Tabel 4.15</b> Pendekatan untuk Kategorisasi Aspek .....	80
<b>Tabel 4.16</b> <i>Confusion Matrix</i> Kategorisasi Aspek 1 (AC1) .....	82

<b>Tabel 4.17</b> Evaluasi Kelima Aspek Hotel pada AC1 .....	82
<b>Tabel 4.18</b> <i>Confusion Matrix</i> Kategorisasi Aspek 2 (AC2).....	83
<b>Tabel 4.19</b> Evaluasi Kelima Aspek Hotel pada AC2.....	83
<b>Tabel 4.20</b> <i>Confusion Matrix</i> Kategorisasi Aspek 3 (AC3).....	84
<b>Tabel 4.21</b> Evaluasi Kelima Aspek Hotel pada AC3.....	84
<b>Tabel 4.22</b> Evaluasi Kinerja <i>Aspect Categorization Performance Evaluation</i> .....	85
<b>Tabel 4.23</b> Pendekatan untuk Klasifikasi Sentimen .....	86
<b>Tabel 4.24</b> <i>Confusion Matrix</i> SC1 .....	87
<b>Tabel 4.25</b> <i>Confusion Matrix</i> SC2 .....	88
<b>Tabel 4.26</b> <i>Confusion Matrix</i> SC3 .....	88
<b>Tabel 4.27</b> Performa dari <i>Sentiment Classification</i> (SC).....	89
<b>Tabel 4.28</b> Evaluasi dari Klasifikasi Sentimen Berbasis Kategorisasi Aspek .....	90
<b>Tabel 4.29</b> Hasil Klasifikasi Sentimen berdasarkan Kategorisasi Aspek.....	91
<b>Tabel 4.30</b> Hasil Uji Korelasi Antar Variabel dengan <i>Chi-Square</i> .....	93
<b>Tabel 4.31</b> Taraf Signifikasi Korelasi .....	94
<b>Tabel 4.32</b> Efek dari pentingnya Aspek terhadap Sentimen.....	95

# **BAB 1**

## **PENDAHULUAN**

Pada bab ini akan dijelaskan beberapa hal dasar dalam pembuatan penelitian tesis yang meliputi: Latar Belakang, Perumusan Masalah, Tujuan, Manfaat, Kontribusi Penelitian, dan Batasan Masalah.

### **1.1. Latar Belakang**

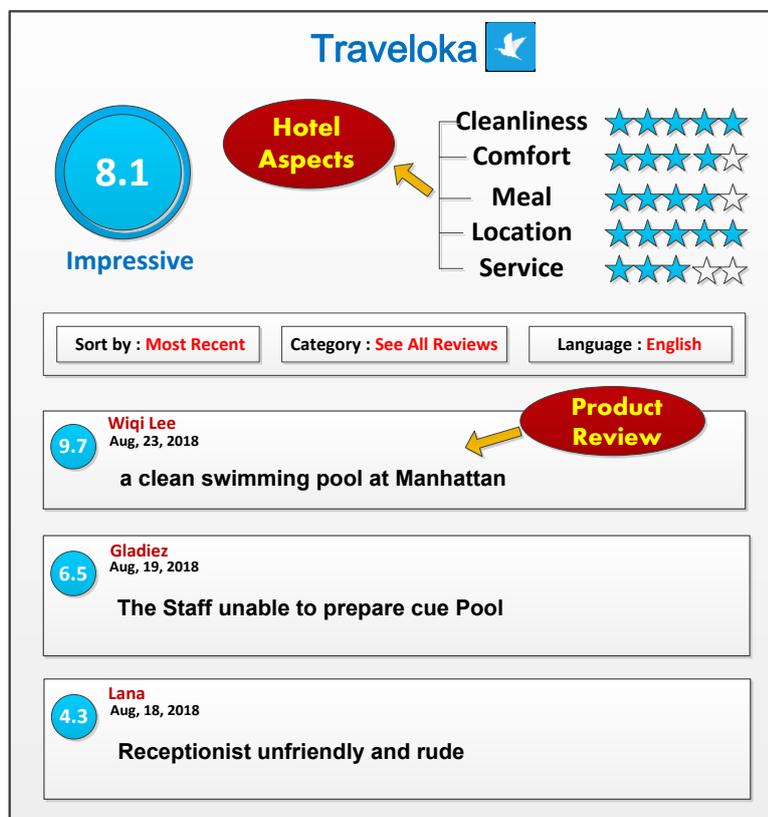
Di era industri 5.0, ulasan produk sangat penting untuk keberlanjutan perusahaan. Ulasan produk adalah *User Generated Content* (UGC) yang dapat menggambarkan kepuasan pelanggan secara keseluruhan. Dampak dari industri 5.0, dapat menghasilkan *big data* pada media sosial yang menjadi poin utama dari bisnis (Ladhari dan Michaud, 2015). Media sosial, menjadi pusat penilaian dari kebiasaan manusia yang dapat mempengaruhi proses pengambilan keputusan (Berezina et al, 2016). Berbagai jenis perkembangan media sosial dapat berkontribusi pada pembentukan *big data* tentang berbagai opini publik (Aziz, Firmanto, Fajrin, dan Ginardi, 2018). Ulasan produk yang ditulis pelanggan dalam sebuah media sosial, akan menjadi data dengan jumlah yang besar dan tidak terstruktur. Data yang besar dan tidak terstruktur, harus di analisis menggunakan teknik yang sesuai (Gandomi dan Haider, 2015). Menurut Xun Xu (Xun Xu et al, 2017), ulasan produk dapat di analisis menggunakan teknik analisis sentimen. Penelitian lain (Suhariyanto, Firmanto, dan Sarno, 2018), telah melakukan analisis sentimen untuk mengulas opini pelanggan dari *movie*, menggunakan SentiWordnet. Bagus et al (Bagus, Sarno, dan Fatichah, 2018), juga meneliti tentang opini pelanggan dari website Amazon dengan menangani konteks lokal dan global.

Sebelumnya, Dewi Ayu (Khotimah dan Sarno, 2018) telah melakukan penelitian untuk mengukur kepuasan pelanggan terhadap hotel, berdasarkan analisis sentimen menggunakan metode *Probability Latent Semantic Analysis* (PLSA). Kepuasan pelanggan dinilai sangat penting untuk suatu keputusan terkait pembelian produk (Xun Xu et al, 2017). Keputusan pelanggan, sering bergantung pada opini dan citra merek suatu produk (Schumaker, Jarmoszko, dan Labeledz,

2016). Kami menggunakan ulasan produk pada hotel, untuk mengukur kepuasan pelanggan berdasarkan aspek.

Citra merek pada hotel, dapat mempengaruhi opini pelanggan yang diukur dari ulasan dengan aspek yang mempengaruhinya. Aspek yang dapat mempengaruhi citra merek hotel, disebut aspek hotel (Hnin, Naw, dan Win, 2018). Tujuan dari aspek hotel, untuk memprediksi opini dari setiap ulasan produk (Barnaghi, Ghaffari, dan Breslin, 2016). Peneliti memilih website Traveloka sebagai sumber data yang paling ideal, karena mampu menggambarkan secara eksplisit dari opini pelanggan secara global (Xiang et al, 2015).

*Aspect Categorization* (AC) dan *Sentiment Classification* (SC) merupakan teknik yang digunakan dalam penelitian ini, berdasarkan pada ulasan produk yang menggunakan lima aspek hotel dan diolah dengan bahasa pemrograman Python. Kelima aspek hotel, diambil dari website Traveloka meliputi *Location*, *Meal*, *Service*, *Comfort*, dan *Cleanliness*. Pernyataan tersebut selaras dengan infografis yang dideskripsikan tampilan website Traveloka pada Gambar 1.1



Gambar 1.1 Tampilan Website Traveloka

Gambar 1.1 menjelaskan bahwa potensi yang dimiliki oleh website Traveloka sangat luas, dengan lima aspek yang digunakan untuk menilai ulasan. Pengalaman pelanggan dalam menilai hotel perlu di analisis lebih lanjut (Hnin, Naw, dan Win, 2018). Pada literatur (Xun Xu et al, 2017), peneliti menganalisis ulasan pelanggan dari berbagai jenis hotel dengan menggunakan metode *Latent Semantic Analysis* (LSA). Kekurangan dari penelitian sebelumnya adalah tidak fokus terhadap aspek-aspek yang dapat mempengaruhi sentimen. Rating bintang pada kelima aspek dalam Gambar 1.1 dianggap tidak merepresentasikan dengan baik untuk kepuasan pelanggan (Xun Xu et al, 2017), (Y. Zhao, X. Xu, dan M. Wang, 2019). Oleh sebab itu, dengan penelitian ini sistem membuktikan bahwa rating bintang tidak merepresentasikan kepuasan pelanggan dengan baik, tanpa melihat 5 aspek hotel yang dapat mempengaruhinya.

Pentingnya mengetahui aspek adalah untuk memprediksi topik dari setiap ulasan produk. Contoh dari pentingnya aspek yaitu pada ulasan Gambar 1.1 “*Receptionist unfriendly and rude*”. *Term List* pada “*reception*” dan “*unfriendly*” tersirat dan menyiratkan topik yang masuk kedalam aspek “*Service*”. Jika aspek dalam ulasan tidak ditangkap dengan baik, maka persepsi pelanggan pada aspek “*Service*” tidak dapat diidentifikasi. Namun, jika aspek tersebut ditangkap dengan baik, dapat disimpulkan bahwa pelanggan sedang mengulas *service* hotel.

Data ulasan produk pada website Traveloka diambil dengan cara *crawling* menggunakan *software* WebHarvy (Kaspa et al, 2018). Data yang diambil, berasal dari ulasan-ulasan hotel Times Square, Manhattan, New York. Peneliti hanya mengambil ulasan produk yang menggunakan bahasa Inggris. Langkah selanjutnya adalah melakukan *Preprocessing* (Thomas dan Resmipriya, 2016). Setiap ulasan produk, akan di *Preprocessing* menjadi dokumen *term list*. Pada langkah *preprocessing*, akan dilakukan proses *Convert into Lowercase*, *Tokenization*, *Stemming*, *Stopwords Removal*, *Remove Punctuation*, dan *Spelling Corection* untuk menjadi *term list*. Dokumen *term list* akan digunakan sebagai *training* dan *testing*.

Dalam penelitian ini, digunakan metode *Probabilistic Latent Semantic Analysis* (PLSA) untuk menghasilkan *hidden topic* dari dokumen *term list*. Dengan dasar pertimbangan bahwa, metode PLSA menghasilkan performa

akurasi (*precision*, *recall* dan *F1-Measure*) lebih baik dibandingkan metode *Latent Semantic Analysis* (LSA) dalam melakukan pencarian *hidden topic*. Menurut Xun Xu (2017), LSA merupakan sebuah metode yang tradisional dan tidak dapat diterapkan pada *Natural Language Processing* (NLP) ataupun *Artificial Intelligence* (AI). Metode LSA memeriksa kata yang dianggap sama berdasarkan pelafalannya, namun memiliki makna yang berbeda. Sedangkan metode PLSA, mampu memeriksa kata berdasarkan pada pelafalan dan makna yang sama.

Peneliti lain (Puspaningrum, Siahaan, dan Fatichah, 2018) juga mengungkapkan bahwa metode *Latent Dirichlet Allocation* (LDA) mampu menghasilkan *hidden topic* dari ulasan pendek pelanggan. Metode LDA memiliki fungsi *dirichlet*, sehingga dapat mencegah *over fitting* dalam analisa kata. Namun penelitian sebelumnya (Khotimah dan Sarno, 2018), membuktikan bahwa metode PLSA sangat baik untuk menghasilkan *hidden topic* dengan mempertimbangkan probabilitas kemunculan kata dari ulasan yang panjang. Ulasan yang panjang, dapat dideteksi dengan mudah menggunakan algoritma *Expectation* (E-Step) dan *Maximization* (M-Step) pada *Natural Language Processing* (NLP) Python.

*Hidden topic* dihasilkan dari kata yang memiliki banyak arti dan dikelompokkan dengan kata yang sama (Revindasari, Sarno, dan Solichah, 2016). Algoritma yang digunakan metode PLSA untuk menghasilkan *hidden topic* adalah *Expectation* (E-Step) dan *Maximization* (M-Step) (Fernandez-Beltran dan Pla, 2015). E-step dan M-step mampu menangani kata-kata yang mengandung polisemi dan dilengkapi *corpus* pelatihan dokumen. Topik-topik yang ditemukan oleh metode PLSA, kami gunakan untuk kategorisasi pada kelima aspek hotel (*Location*, *Meal*, *Service*, *Comfort*, dan *Cleanliness*).

Penelitian ini menggunakan kategorisasi lima aspek hotel dalam tiga pendekatan, yaitu *Aspect Categorization 1* (AC1), *Aspect Categorization 2* (AC2), dan *Aspect Categorization 3* (AC3). Kategorisasi aspek, digunakan untuk mengkategorikan *hidden topic* kedalam lima aspek hotel. Kelima aspek hotel, dikategorisasi menggunakan metode *Semantic Similarity* yang diambil dari data *hidden topic* dan *Keyword Term List for Hotel Aspect*.

Metode *Term Frequency-Inverse Corpus Frequency* (TF-ICF) digunakan dalam penelitian ini sebagai pembobotan setiap *term list* (Puspaningrum, Siahaan, dan Faticah, 2018), yang diperluas dari masing-masing *cluster* pada dokumen (Suadaa dan Purwarianti, 2016). Selain itu, TF-ICF juga digunakan peneliti sebagai perluasan *term list*, pembandingan dan meningkatkan keakurasian data. TF-ICF digunakan pada kategorisasi aspek AC2 dan AC3 sebagai pembandingan dari AC1. *Aspect Categorization 2* (AC2) menggunakan 20% dan *Aspect categorization 3* (AC3) menggunakan 100% dari hasil TF-ICF.

Setelah kelima aspek dikategorisasikan, kami melakukan *Pre-process Aspect Based Sentiment Classification*. *Pre-process Aspect Based Sentiment Classification* adalah mengelompokkan setiap ulasan produk sesuai dengan aspeknya. Pengelompokan setiap aspek, bertujuan untuk memudahkan peneliti dalam melakukan klasifikasi sentimen berdasarkan aspek.

Hasil dari *Pre-process Aspect Based Sentiment Classification* adalah data *training* tiap aspek. Data *training* tiap aspek dan AC3, kami gunakan pada proses *Word embedding* untuk mendapatkan nilai *word* vektor. Nilai *word* vektor akan kami gunakan untuk klasifikasi sentimen menggunakan metode *Long Short-Term Memory* (LSTM) (Gao dan Ren, 2019), (Araque et al, 2017). Metode LSTM digunakan sebagai konsep dari *deep learning* yang dapat membantu meningkatkan kinerja pada klasifikasi sentimen (Reddy dan Delen, 2018), (Tai, Socher, dan Manning, 2015). Peneliti menggunakan model Global Vektor (GloVe) pada *Word embedding* untuk membantu LSTM dalam memodelkan dependensi *term list* yang sangat baik (Pennington, Socher, dan Manning, 2014), (Pham dan Le, 2018), (Wang et al, 2016).

Penelitian ini menggunakan dua parameter dalam klasifikasi sentimen, yaitu *positive* dan *negative*. Jika ada kata sifat (Adj) yang memiliki nilai sentimen "netral", maka anator mengklasifikasikan menjadi *positive* atau *negative*. Sentiment *positive* dan *negative*, ditentukan dari setiap kata dalam kalimat pada ulasan produk. Pelanggan merasa puas, jika memiliki nilai sentimen yang *positive*. Pelanggan merasa tidak puas, jika memiliki nilai sentimen yang *negative*. Nilai sentimen yang tegas menggambarkan *feelings*, *opinions*, *emotions* dari banyak pelanggan secara jelas, seperti puas atau tidak puas (Ekinici dan Omurca, 2018).

Ulasan produk pada “*Receptionist unfriendly and rude*” akan terdeteksi sebagai sentimen *negative* pada *term list* “*unfriendly*” dan “*rude*”. Kami melakukan klasifikasi sentimen dengan tiga proses yaitu *Sentiment Classification 1 (SC1)*, *Sentiment Classification 2 (SC2)*, dan *Sentiment Classification 3 (SC3)* sebagai perbandingan. Kami memilih kinerja terbaik dari evaluasi kategorisasi lima aspek, dan klasifikasi sentimen sebagai keunggulan dari metode yang kami usulkan. Sehingga, tujuan dari penelitian ini adalah mencari performa terbaik pada setiap metode analisis untuk diterapkan. Analisa dan evaluasi terhadap ulasan produk, digunakan untuk memahami kebutuhan dan kepuasan pelanggan berdasarkan 5 aspek hotel. Harapan kami, dengan penelitian ini akan membantu perusahaan dalam menyusun rencana perbaikan, meningkatkan kualitas produk dan jasa.

Keseluruhan hasil, akan di evaluasi menggunakan *Precision*, *Recall*, dan *F1-Measure*. Hasil menunjukkan bahwa kombinasi metode PLSA + TF ICF 100% + *Semantic Similarity* lebih unggul yaitu 0.840 dalam kategorisasi kelima aspek hotel. Metode *Word embedding* + LSTM mengungguli dalam klasifikasi sentimen sebesar 0.946. Hasil dari penelitian ini, menunjukkan bahwa aspek *Service* memiliki nilai sentimen *positive* yang lebih tinggi sebesar 45.545, dibandingkan aspek yang lain; aspek *Comfort* memiliki nilai sentimen *negative* yang lebih tinggi sebesar 12.871, dibandingkan aspek yang lain. Hasil penelitian juga menunjukkan bahwa sentimen dapat dipengaruhi oleh sebuah aspek yang diukur berdasarkan korelasinya. Dalam penelitian ini, metode yang digunakan untuk mengukur korelasi hubungan antara aspek dengan sentimen menggunakan *Chi-Square* pada perangkat lunak SPSS 23.

Penggunaan literatur *Business Intelligence* dan *Analytics*, sedikit mengungguli untuk menunjang pentingnya sentimen terhadap aspek. Harapan kami dengan penelitian ini, perusahaan dapat mengidentifikasi persepsi pelanggan secara global dan menghargai ketepatan waktu dalam pelayanan, serta jasa untuk meningkatkan net profit margin di era industri 5.0.

## **1.2. Perumusan Masalah**

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

1. Apakah ulasan produk berpengaruh terhadap kualitas hotel?
2. Apakah 3 pendekatan dapat menghasilkan performa terbaik dalam Kategorisasi Aspek (AC) dan Klasifikasi Sentimen (SC) pada 5 aspek hotel (*Location, Meal, Service, Comfort dan Cleanliness*)?
3. Apakah sentimen pelanggan dapat dipengaruhi oleh 5 aspek hotel?

## **1.3. Tujuan**

Berdasarkan perumusan masalah diatas, maka tujuan dari penelitian ini adalah :

1. Menguji pengaruh ulasan produk terhadap kualitas hotel.
2. Menguji 3 pendekatan untuk menghasilkan performa terbaik dalam Kategorisasi Aspek (AC) dan Klasifikasi Sentimen (SC) pada 5 aspek hotel (*Location, Meal, Service, Comfort dan Cleanliness*).
3. Menguji sentimen pelanggan yang dapat dipengaruhi oleh 5 aspek hotel.

## **1.4. Manfaat**

Penelitian ini diharapkan, penulis dapat menghasilkan system untuk menganalisa kepuasan pelanggan terhadap 5 aspek hotel (*Location, Meal, Service, Comfort dan Cleanliness*) dengan 3 pendekatan yang berbeda. Tiga pendekatan yang berbeda, diharapkan dapat menghasilkan performa terbaik untuk mengukur sentimen pelanggan yang dapat dipengaruhi oleh aspek. Sehingga, perusahaan dapat mengidentifikasi persepsi pelanggan secara global dan menghargai ketepatan waktu dalam pelayanan, serta jasa untuk meningkatkan net profit margin di era industri 5.0

## **1.5. Kontribusi Penelitian**

Kontribusi yang diharapkan dari penelitian ini adalah pencarian performa terbaik untuk melakukan kategorisasi *aspect* dan klasifikasi *sentiment*. Analisa *sentiment* dari ulasan produk terhadap *aspect* dapat memberikan kontribusi

terhadap praktisi bisnis dalam meningkatkan kualitas dan layanan hotel. Praktisi bisnis, dapat dengan mudah memahami kebutuhan pelanggan, menghargai ketepatan waktu dalam pelayanan dan keberlanjutan perusahaan di era industri 5.0.

Sebelum mengkategorikan setiap ulasan terhadap 5 aspek hotel, peneliti melakukan *crawling* data ulasan produk pada website Traveloka. Data yang diambil, berasal dari ulasan-ulasan hotel Times Square, Manhattan, New York. Peneliti hanya mengambil ulasan produk yang menggunakan bahasa Inggris. Langkah selanjutnya adalah melakukan *Preprocessing*. Setiap ulasan produk, akan di *preprocessing* menjadi dokumen *term list*. Pada langkah *preprocessing*, akan dilakukan proses *Convert into Lowercase*, *Tokenization*, *Stemming*, *Stopwords Removal*, *Remove Punctuation*, dan *Spelling Corection* untuk menjadi *term list*. Dokumen *term list* akan digunakan sebagai *training* dan *testing*.

Penelitian ini dilakukan untuk mencari performa kategorisasi *aspect* terbaik dengan menggabungkan metode *Probablistic Latent Semantic Analysis* (PLSA) dengan *semantic similarity* menggunakan data *term list* Tabel 2.1; menggabungkan metode PLSA dengan *semantic similarity* dan menggunakan data *term list* Tabel 2.1 ditambah dengan TF-ICF 20%; dan menggabungkan metode PLSA dengan *semantic similarity* dan menggunakan data *term list* Tabel 2.1 ditambah dengan TF-ICF 100%. *Probablistic Latent Semantic Analysis* (PLSA) dipilih karena merupakan salah satu metode *topic modelling* yang mampu memetakan *hidden topik* dari suatu dokumen. Algoritma yang digunakan metode PLSA untuk menghasilkan *hidden topic* adalah *Expectation* (E-Step) dan *Maximization* (M-Step). E-step dan M-step mampu menangani kata-kata yang mengandung polisemi dan dilengkapi *corpus* pelatihan dokumen. Namun, PLSA memiliki kekurangan dalam mengkategorikan dokumen ke dalam salah satu tipe dari kategori klasifikasi secara langsung. Sehingga, penelitian ini mengusulkan metode yang menggabungkan PLSA (untuk menemukan *hidden topic*) dengan *Semantic Similarity* untuk mengklasifikasikan dokumen dalam 5 *aspect* hotel (*Location*, *Meal*, *Service*, *Comfort* dan *Cleanliness*). *Term list* untuk melakukan *similarity* ditentukan terlebih dahulu pada “Tabel 2.1: *Keyword Term List* Aspek Hotel”. Kemudian, dilakukan perluasan *term list* pada saat pengukuran *similarity*

dilakukan dengan menggunakan metode TF-ICF. Hasil dari performa setiap uji coba akan dianalisa dan dipilih yang terbaik untuk diaplikasikan.

Penelitian ini juga menggunakan metode *Word Embedding* untuk mengekstrak dokumen dan label menjadi *word vector*. Hasil dari *word vector* akan digunakan sebagai input untuk proses klasifikasi sentimen terhadap kepuasan pelanggan menggunakan metode *Long-Short Term Memory* (LSTM). Metode LSTM merupakan metode yang populer untuk klasifikasi *sentiment*, karena mampu menyimpan *term* dengan jangka yang panjang pada memory-nya. Metode LSTM, dapat digunakan untuk memodelkan keterhubungan antar *term* bahkan yang memiliki interval yang jauh. Hal ini yang membuat metode LSTM sukses diterapkan pada berbagai sektor, diantaranya pemodelan bahasa, pengenalan suara, dan pemahaman bahasa yang diucapkan. Analisa sentimen dalam penelitian ini, membandingkan antara klasifikasi *sentiment* dengan menggunakan *Word Embedding* + LSTM; klasifikasi *sentiment* dengan menggunakan SentiWordNet; dan klasifikasi *sentiment* menggunakan LSTM. Performa uji coba terbaik untuk analisa *sentiment* akan di aplikasikan.

*Output* dari kedua proses ini (Kategorisasi *Aspect* dan Klasifikasi *Sentiment*) akan menghasilkan evaluasi untuk mengetahui kepuasan pelanggan terhadap 5 aspek hotel meliputi: *Location*, *Meal*, *Service*, *Comfort* dan *Cleanliness*. Dalam hasil penelitian, ditemukan bahwa sentimen dapat dipengaruhi oleh suatu aspek.

## **1.6. Batasan Masalah**

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

1. Ulasan produk diambil dengan cara *crawling* pada ulasan hotel Times Square, Manhattan, New York.
2. Dataset ulasan produk yang akan diproses hanya menggunakan bahasa inggris.
3. Data ulasan produk yang di ambil 3 tahun terakhir yaitu 2015-2018.

4. Klasifikasi sentimen ditinjau dari lima aspek hotel pada website Traveloka meliputi *Location, Meal, Service, Comfort* dan *Cleanliness*.
5. *Preprocessing* menggunakan 6 tahap meliputi *Convert into Lowercase, Tokenization, Stemming, Stopwords Removal, Remove Punctuation,* dan *Spelling Corection*.
6. 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, jenis dan sumber data, jalannya penelitian dan alur penelitian.

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

Bab ini menjelaskan tentang pengumpulan 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.

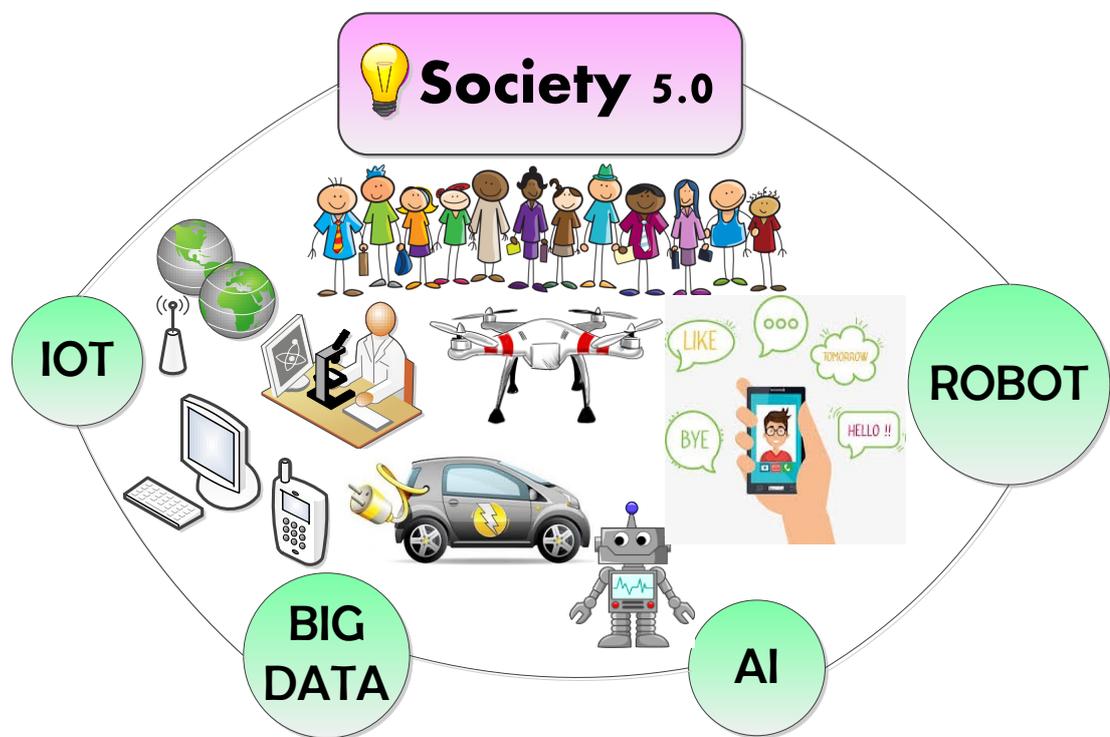
## BAB 2

### KAJIAN PUSTAKA

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

#### 2.1 Industry 5.0 (*Society 5.0*)

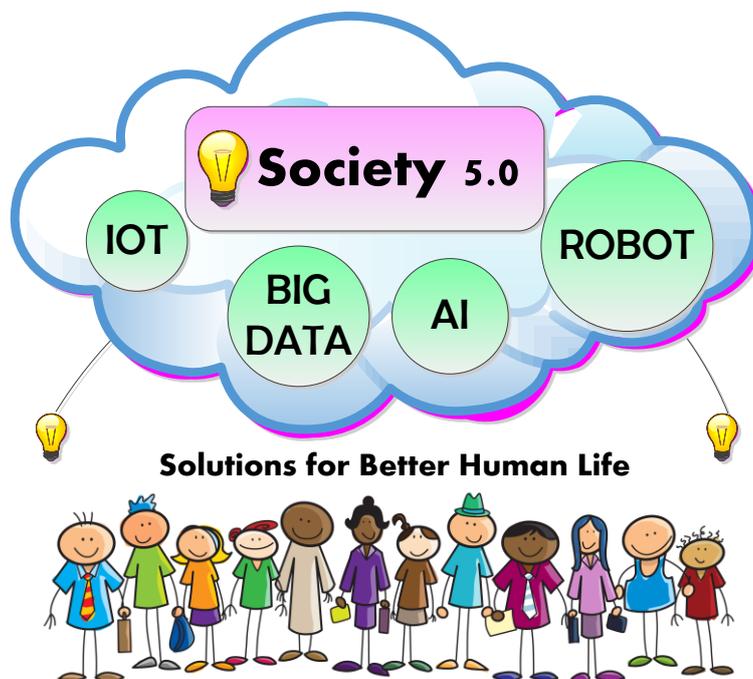
Istilah Industri 5.0 adalah singkatan dari revolusi industri kelima yang didefinisikan sebagai kontrol dari aspek masyarakat, tidak hanya dalam bidang produksi dan industri (Vural, dan Nezh, 2018). Tujuan utama Industri 5.0 adalah menciptakan masyarakat yang dapat bekerja sama dengan inovasi industri 4.0 (misalkan IoT, *big data*, kecerdasan buatan (AI), robot, dan berbagi ilmu ekonomi) ke dalam setiap industri dan kehidupan sosial. Masyarakat 5.0 (*Society 5.0*), merupakan masyarakat yang dibentuk menjadi super pintar. Negara Jepang akan memimpin untuk mewujudkan industri 5.0 terlebih dahulu dari negara-negara lain di dunia.



**Gambar 2.1** Interaksi dan kolaborasi antara manusia dan mesin pada Industri 5.0

Gambar 2.1 merupakan interaksi dan kolaborasi antara manusia dan mesin pada Industri 5.0. Disebut revolusi masyarakat, karena banyak kreativitas dan inovasi dari pikiran manusia membuat proses industri menjadi lebih maju, modern dan digital. Situasi pasar saat ini, akan menyatukan pikiran manusia dan tingkat tertinggi dari proses digital akan mewakili revolusi industri generasi kelima. Industri generasi kelima, akan membawa tingkat personalisasi yang lebih tinggi untuk kepuasan pelanggan. Kepuasan pelanggan, sebagai salah satu faktor utama oleh pengembang industri yang dapat menjamin penempatan produk dan membuka peluang pasar baru.

Pemerintah Indonesia, menggalakkan gerakan literasi *society* sebagai penguat bahkan menggeser gerakan literasi lama. Gerakan literasi baru yang dimaksudkan terfokus pada tiga literasi utama yaitu, 1) literasi digital, 2) literasi teknologi, dan 3) literasi manusia. Tiga keterampilan ini, diprediksi menjadi keterampilan yang sangat dibutuhkan di masa era industri 5.0. Literasi *society* diarahkan pada tujuan peningkatan kemampuan membaca, menganalisis dan menggunakan informasi di dunia digital (*Big Data*) untuk menjadi masyarakat yang super pintar.



**Gambar 2.2** Memasuki Masyarakat 5.0

Gambar 2.2 merupakan tahapan awal masyarakat yang memasuki era revolusi industri 5.0. Dalam dunia digital, *big data* yang dikumpulkan oleh IoT akan menjangkau setiap sudut masyarakat. Ketika pindah ke Society 5.0, semua kehidupan masyarakat akan lebih nyaman dan berkelanjutan karena orang hanya diberi produk dan layanan dalam jumlah dan waktu yang diperlukan.

Fase industri merupakan *real change* dari perubahan yang ada. Industri 1.0 ditandai dengan mekanisasi produksi untuk menunjang efektifitas dan efisiensi aktivitas manusia, industri 2.0 dicirikan oleh produksi massal dan standarisasi mutu, industri 3.0 ditandai dengan penyesuaian massal dan fleksibilitas manufaktur berbasis otomasi dan robot. Industri 4.0 selanjutnya hadir menggantikan industri 3.0 yang ditandai dengan *cyber* fisik dan kolaborasi manufaktur. Menurut definisi Witkowski (2017), industri 4.0 ditandai dengan peningkatan digitalisasi manufaktur yang didorong oleh empat faktor: 1) peningkatan volume data, kekuatan komputasi, dan konektivitas; 2) munculnya analisis, kemampuan, dan kecerdasan bisnis; 3) terjadinya bentuk interaksi baru antara manusia dengan mesin; dan 4) perbaikan instruksi transfer digital ke dunia fisik, seperti robotika dan 3D *printing*. Industri 5.0 (*Society 5.0*) hadir menggantikan industri 4.0 yang ditandai dengan perubahan masyarakat yang super pintar (Dalenogare et al., 2018).

## **2.2 Kepuasan Pelanggan**

Kepuasan pelanggan menurut Yabing (Y. Zhao, X. Xu, dan M. Wang, 2019), adalah tingkat perasaan pelanggan setelah membandingkan kinerja atau hasil yang dirasakan dengan harapannya. Tingkat kepuasan pelanggan merupakan fungsi dari perbedaan antara kinerja yang dirasakan dengan harapan. Apabila kinerja dibawah harapan, maka pelanggan akan kecewa. Bila kinerja sesuai dengan harapan, maka pelanggan akan puas. Kepuasan pelanggan menjadi sangat krusial menuju terwujudnya pelanggan yang loyal atau setia.



**Gambar 2.3** Ilustrasi kepuasan pelanggan dalam bentuk rating bintang

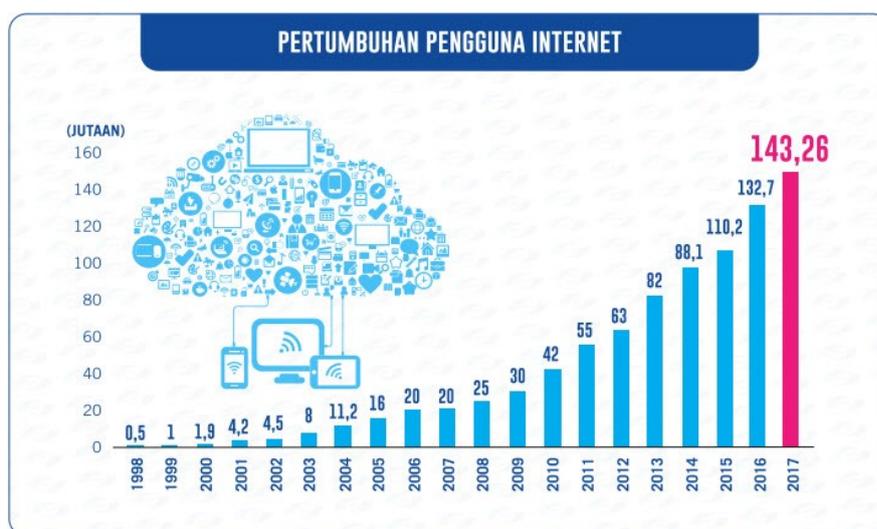
Banyak website yang diciptakan untuk memudahkan pelanggan dalam menyampaikan opini atau pengalaman melalui ulasan pada kolom komentar dan rating bintang. Ulasan-ulasan ini, biasanya disimpan dalam data warehouse dan data mining yang digunakan untuk mengekstrasi informasi berhubungan dengan perusahaan dari pelanggan yang bersangkutan.

Ulasan dalam kolom komentar biasanya berupa teks, sehingga lebih mudah di analisis. Sedangkan rating bintang, hanya merepresentasikan kepuasan pelanggan berdasarkan subjektivitas yang kurang dieksplorasi lebih detail (Y. Zhao, X. Xu, dan M. Wang, 2019). Kepuasan pelanggan sering diukur menggunakan teknik analisis sentimen (Xun Xu et al, 2017) untuk menggambarkan *feelings, opinions, emotions* dari banyak pelanggan (Ekinci dan Omurca, 2018). Sentimen *positive, neutral* dan *negative*, ditentukan dari setiap kata dalam kalimat pada ulasan produk. Pelanggan merasa puas, jika memiliki nilai sentimen yang *positive*. Pelanggan merasa tidak berpihak, jika memiliki nilai sentimen yang *neutral*. Pelanggan merasa tidak puas, jika memiliki nilai sentimen yang *negative*. Kepuasan pelanggan, menjadi tolak ukur keberhasilan perusahaan yang dapat mempengaruhi citra merek suatu produk (Schumaker, Jarmoszko, dan Labeledz, 2016).

### **2.3 E-Commerce**

*E-Commerce (electronic commers)* adalah pembelian, penjualan, pemasaran barang dan jasa melalui system elektronik seperti internet, televisi, *world wide web*, atau jaringan-jaringan computer lainnya. *E-Commerce* melibatkan

transfer dana elektronik, pertukaran data elektronik, sistem manajemen inventori otomatis, dan sistem pengumpulan data otomatis. Salah satu jaringan yang digunakan adalah internet. Sementara itu, Aryanto, et.all. (2013) mendefinisikan *E-Commerce* dari beberapa perspektif, antara lain sebagai berikut: a) Perspektif komunikasi, *E-Commerce* adalah pengiriman informasi, barang dan jasa, melalui jaringan telepon, atau jalur komunikasi lainnya. b) Perspektif proses bisnis, *E-Commerce* adalah aplikasi teknologi menuju otomatisasi transaksi bisnis. c) Perspektif pelayanan, *E-Commerce* adalah alat yang digunakan untuk mengurangi biaya dalam pemesanan dan pengiriman barang. d) Perspektif online, *E-Commerce* menyediakan kemampuan untuk menjual dan membeli barang melalui internet dan jaringan jasa online lainnya.



**Gambar 2.4** Data Pertumbuhan Pengguna Internet tahun 2017 APJI

Gambar 2.4 diambil dari data hasil survey APJI (Asosiasi Penyelenggara Jasa Internet Indonesia) yang menjelaskan bahwa dari tahun 1998-2017, pengguna internet semakin meningkat. Pengguna yang semakin meningkat, mengindikasikan betapa pentingnya internet dalam dunia pemasaran. System elektronik pada internet seperti website menjadi peluang besar bagi praktisi bisnis dalam memasarkan produk dan jasa.

## 2.4 Pengumpulan Data

Penelitian ini menggunakan data ulasan produk secara online, di situs website Traveloka sebagai sumber data yang mewakili *User Generated Content* (UGC). Peneliti melakukan teknik *crawling* data ulasan menggunakan *software* WebHarvy.



**Gambar 2.5** Ulasan Pelanggan pada hotel Times Square, Manhattan, New York, 2018.

Gambar 2.5 menjelaskan bahwa ulasan produk yang diambil oleh peneliti hanya ulasan yang berupa teks.



**Gambar 2.6** Proses dari *Crawling* data menggunakan WebHarvy.

Gambar 2.6 menjelaskan tentang proses *crawling* data menggunakan software WebHarvy (Kaspa et al, 2018). Proses yang pertama adalah memasukkan alamat URL ulasan hotel Times Square, Manhattan, New York dari website Traveloka menggunakan *tools* WebHarvy. Pada *tools* WebHarvy, kami mengambil ulasan produk dikolom komentar pelanggan yang berupa *text*.

Langkah terakhir adalah melakukan *export results*. Hasil *crawling* data dari *export results*, akan disimpan dalam format file excel (.csv) agar mudah digunakan untuk pengolahan data menggunakan bahasa pemrograman python. Hasil dari *crawling* akan digunakan untuk tahap selanjutnya yaitu *preprocessing* (Thomas dan Resmipriya, 2016), (Wang, Peng, dan Zhang, 2018).

## 2.5 *Keyword Term List* untuk Aspek Hotel

*Keyword term list* adalah kata kunci yang sering muncul dalam ulasan produk. Pada penelitian ini, peneliti menggunakan *keyword term list* untuk aspek

hotel yang diambil dari beberapa penelitian. Kami menemukan *term list* hotel dengan mengambil lima label dari beberapa penelitian sebelumnya (Khotimah dan Sarno, 2018), (Chen dan Chen, 2015), (Akhtar et al, 2017). Label aspek hotel yang kami ambil meliputi: 1) *Location*; 2) *Meal*; 3) *Service*; 4) *Comfort*; dan 5) *Cleanliness*. *Term list* aspek hotel yang diperoleh akan direpresentasikan pada Tabel 2.1.

**Tabel 2.1** *Keyword Term List* Aspek Hotel yang diperoleh

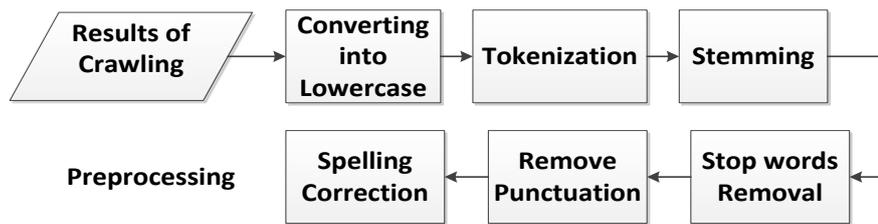
<b>Aspek Hotel</b>	<b><i>Term List</i> Aspek Hotel yang diperoleh</b>
<b>1 Location</b>	railway, view, station, airport, distance, far, close, convenient, train, metro, location, place, distance, station, shuttle, cab, taxi, uber, subway, attraction, shopping, block, bus, ride, metro, mall, bus stop, downtown, park, theater, strip, district, museum, transportation, quarter, tourist interest, heart, trolley, middle, square.
<b>2 Meal</b>	drink, breakfast, spicy, meal, tea, buffet, bar, restaurant, dinner, lunch, brunch, delicious, food, dish, wine, salad, pizza, buffet variety, court, shop, dinner, selection, snack, fruit, cereal, egg, cheese, juice, variety, coffee, bagel, pastry, waffle, cafe, menu, item, gift, cup.
<b>3 Service</b>	connection, meeting, charge, activity, sleep, bed, bedroom, pillow, sofa, suite, room, pool, towel, unit, chair, lobby, experience, space, comfort, feel.
<b>4 Comfort</b>	facility, Wifi, cue, gym, business, internet, spa, connection, meeting, activity, sofa, therapy, room, lobby, studio, sleep, broken, bed, space, elevator, lift, scary, comfort.
<b>5 Cleanliness</b>	cleanliness, cleaning, smell, smoke, carpet, smoking, furniture, wall, air, swimming, conditioner, elevator, hall, air conditioning, stair, noise, neighbor, toilet, complaint, fan, ceiling, heat.

## 2.6 Pengolahan Bahasa Manusia

Pemrosesan bahasa alami merupakan teknik untuk mengajarkan komputer dalam memahami maksud dari kata-kata yang digunakan oleh manusia. Metode ini yang kemudian diadaptasi untuk proses awal dalam penelitian ulasan produk.

### 2.6.1 *Pre Processing*

Salah satu teknik pemrosesan bahasa alami yang kerap digunakan pada saat pra-proses menggunakan enam teknik, akan dijelaskan dalam gambar dibawah ini;



**Gambar 2.7** Enam tahap dalam Preprocessing

Gambar 2.7 menjelaskan teknik dari *preprocessing*. Setiap ulasan produk, akan dipreprocessing menjadi dokumen *term list*. Teknik *preprocessing* dilakukan dengan 6 tahap, yaitu: *Converting into Lowercase*, *Tokenization*, *Stemming*, *Stop words Removal*, *Remove Punctuation* dan *Spelling Correction*.

Tahap pertama adalah *Convert into Lowercase* yang memiliki peran untuk merubah teks pada ulasan produk menjadi huruf kecil. Tahap kedua *Tokenisasi* yaitu memecah teks menjadi token atau potongan kata. Tahap ketiga adalah *Stemming* yang memiliki peran untuk merubah teks pada ulasan produk menjadi kata dasar. Tahap keempat adalah *Stop Words Removal* yang memiliki peran untuk kata umum yang biasanya muncul dalam jumlah besar dan dianggap tidak memiliki makna (Contoh: *for, a, of, the, and, to, in, as, are, is, at, on, be, i, you, they, we, she, he, it, if, up, also, your, their, its, her, his, that, this, those, these, there, here an, or, now, why, who, what, was, were, am, can, not, so, when, which, me*). Tahap kelima adalah *Remove Punctuation* untuk menghapus tanda baca pada teks ulasan pelanggan. Tahap terakhir yaitu *Spelling Correction* memiliki fungsi untuk menyempurnakan teks pada ulasan produk yang memiliki kesalahan dalam penulisan.

NLP (*Natural Language Processing*) digunakan dalam penelitian ini, untuk *part-of-speech tagging* (POS *Tagging*) dari setiap *term list*. Penggunaan POS *tagging* pada *preprocessing* dapat menghindari penggunaan kata yang tidak tepat (Puspaningrum, Siahaan, dan Fatichah, 2018). POS *tagging* dilakukan dengan memberi *part-of-speech* yang diambil dari *Library Natural Language Toolkit* (NLTK) (Stein, Jaques, dan Valiati, 2019). Penandaan yang diberikan oleh POS *Tagging* pada setiap *term list*, akan digabungkan dengan perhitungan kesamaan

pada *singular noun* dan *infinitive form* hingga menjadi sebuah kalimat (Akhtar et al, 2017).

### 2.6.2 Expanded Term List (TF-ICF)

Peneliti menggunakan metode *Term Frequency-Inverse Corpus Frequency* (TF-ICF) untuk mendapatkan istilah-istilah penting dari pembobotan setiap *term* menjadi *expanded term list* dari setiap *cluster* (Puspaningrum, Siahaan, dan Faticah, 2018). Secara umum TF-ICF melihat frekuensi *term* terhadap kluster menggunakan persamaan 2.1 dimana nilai ICF pada *term i* dipengaruhi oleh jumlah *cluster* yang ada dan jumlah *cluster* yang mengandung *term i* ( $cf_i$ ).

$$ICF_i = 1 + \log \frac{c}{cf_i} \quad (2.1)$$

Sedangkan setiap *term i* pada setiap kluster akan dihitung nilai bobot TF-ICF nya dengan menggunakan persamaan 2.5, dimana  $tf_{ji}$  adalah frekuensi atau total *term i* pada kluster  $j$  dan  $ICF_i$  adalah nilai icf term tersebut. Formula TF-ICF akan dijelaskan pada rumus (2.2).

$$TF - ICF_j = tf_{ji} \times ICF_i \quad (2.2)$$

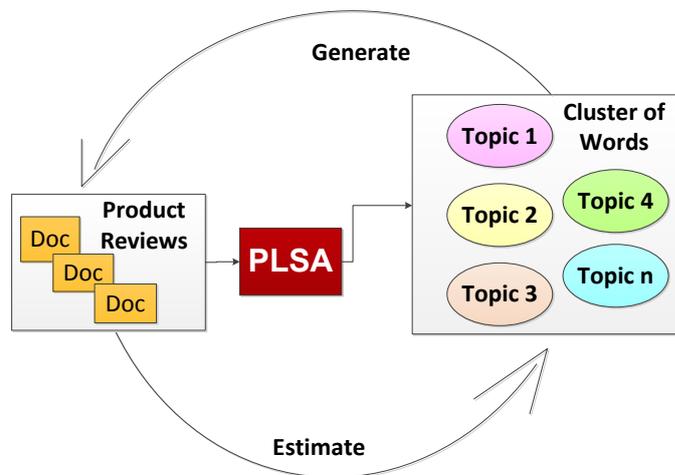
$tf_{ji}$  = frekuensi atau total term *term i* pada kluster  $j$

$ICF_t$  = Jumlah kelas yang mengandung *term t*

Peneliti melakukan beberapa tahap untuk perluasan *term list* menggunakan TF-ICF secara maksimal. Tahap pertama adalah menghitung frekuensi dari setiap *term list*. Tahap kedua adalah Menentukan *term-term* yang memiliki nilai skor tertinggi pada TF-ICF dari setiap *cluster*.

### 2.6.3 Probabilistic Latent Semantic Analysis (PLSA)

Setelah *preprocessing* selesai, proses selanjutnya adalah menemukan *hidden topic* dari setiap dokumen ulasan *term list*. *Hidden Topic* adalah kata-kata penting atau kata-kata yang sering muncul dalam korpus yang dihitung berdasarkan probabilitas kedekatan antar *topic*-dokumen dan *word-topic*.



**Gambar 2.8** Proses Keseluruhan Ekstraksi Topic metode PLSA.

Gambar 2.8 menjelaskan proses pencarian *hidden topic* dari dokumen *term list*. Proses pertama adalah mengumpulkan *term list* dari setiap dokumen ulasan produk. Setiap dokumen, berisi satu ulasan produk yang diberi label *Identity Document* (ID). Label ID di sesuaikan dengan urutan nomor pada ulasan produk.

Keseluruhan hasil akan di *expand* menggunakan WordNet untuk relasi semantik antar *synset* dalam bahasa Inggris. Fungsi dari WordNet adalah mendeteksi kata yang memiliki makna ganda. Hasil *expand* akan digunakan sebagai dataset (Wang et al, 2019). Annotator akan memberikan label pada data *training* dan disimpan dalam dataset sebagai *corpus*. Peneliti menggunakan dataset secara *real-life* yang diperoleh dari ulasan produk.

Proses terakhir adalah menggunakan *term list* hasil *expand* WordNet untuk dihitung dengan probabilitas semantik dari setiap kata menjadi beberapa topik (Wang et al, 2016), (Blokh dan Alexandrov, 2017). Algoritma *Expectation-Maximization* (E-Step dan M-Step) dalam PLSA, menghasilkan *hidden topic* dari keterkaitan kata dan kemiripan topik dalam suatu dokumen (Fernandez-Beltran dan Pla, 2015), (Kaspa et al, 2018).

Metode *Probabilistic Latent Semantic Analysis* (PLSA) dipilih peneliti, karena mampu menangani kata-kata yang mengandung polisemi dan dilengkapi *corpus* pelatihan dokumen dari algoritma E-Step dan M-step. PLSA mampu

menghasilkan *hidden topic* yang lebih baik dengan pendekatan *machine learning* pada *Natural Language Processing* (Revindasari, Sarno, dan Solichah, 2016).

Berikut ini adalah algoritma dari cara kerja PLSA; Peneliti menentukan jumlah topik ( $Z$ ) dan melakukan inialisasi parameter probabilitas dalam topik;  $P(Z)$  Probabilitas topik,  $P(d|Z)$  adalah dokumen probabilitas yang berisi topik,  $P(w|Z)$  adalah probabilitas kata-kata yang terkandung dalam topik secara acak. Perhitungan kata dalam dokumen yang akan dijelaskan pada rumus (2.3).

$$P(d_i, w_j) = \sum_{k=1}^K P(Z_k)P(Z_k)P(d_i|Z_k) P(w_j|Z_k) \quad (2.3)$$

Tahap selanjutnya adalah menghitung nilai probabilitas kata dalam setiap parameter menggunakan algoritma *Expectation step* dan *Maximization step*. *Expectation step* (E-step) menghitung probabilitas topik pada dokumen, yang akan dijelaskan pada rumus (2.4).

$$P(Z_k|d_i, w_j) = \frac{P(w_j|Z_k)P(Z_k|d_i)}{\sum_{k=1}^k P(w_j|Z_l)P(Z_l|d_i)} \quad (2.4)$$

Langkah terakhir adalah menghitung *Maximization step* (M-step). M-step digunakan peneliti untuk melakukan perhitungan terhadap pembaharuan nilai, dari parameter dokumen yang ditunjukkan pada rumus (2.5) dan (2.6).

$$P(w_j|Z_k) = \frac{\sum_{i=1}^N n(d_i|w_j)P(Z_k|d_i, w_j)}{\sum_{m=1}^M \sum_{i=1}^N n(d_i|w_m)P(Z_k|d_i, w_m)} \quad (2.5)$$

$$P(Z_k|d_i) = \frac{\sum_{j=1}^N n(d_i|w_j)P(Z_k|d_i, w_j)}{n(d_i)} \quad (2.6)$$

Hasil perhitungan pada rumus (2.5) dan (2.6) adalah probabilitas kata dalam dokumen yang menghasilkan *hidden topic* (Revindasari, Sarno, dan Solichah, 2016).

#### 2.6.4 *Semantic Similarity*

*Hidden topic* yang dihasilkan oleh metode PLSA, akan diklasifikasikan menggunakan *Semantic Similarity* untuk pelabelan dalam setiap dokumen (Kaspa et al, 2018), ke dalam lima aspek hotel. Kelima aspek hotel, diambil dari website Traveloka meliputi *Location, Meal, Service, Comfort, dan Cleanliness*. *Semantic Similarity* merupakan metode pengukuran yang mendefinisikan setiap dokumen atau *term* yang memiliki jarak diantaranya berdasarkan atas makna atau arti secara semantik. Terdapat dua jenis perhitungan similaritas, yaitu berdasarkan sumber daya yang telah ada, seperti Thesaurus, WordNet atau SentiWordNet dan berdasarkan pada penyebaran kata pada suatu *corpus*.

Peneliti menggunakan anator untuk memvalidasikan dokumen, berdasarkan lima aspek hotel pada data *training*. Kemiripan *hidden topic* pada lima aspek hotel ditentukan dengan nilai kesamaan semantik dari *term list*. Setiap dokumen *hidden topic*, akan dihitung menggunakan *Semantic similarity* untuk dilihat kemiripannya dengan *term list* pada Tabel 2.1 dan ditambahkan dengan *expanded term list* TF-ICF. Setiap dokumen, kami kumpulkan untuk membentuk *cluster* dengan aspek yang sama. Hal ini, bertujuan untuk megklasifikasikan *topic* pada setiap dokumen *term list* kedalam lima aspek hotel secara tepat.

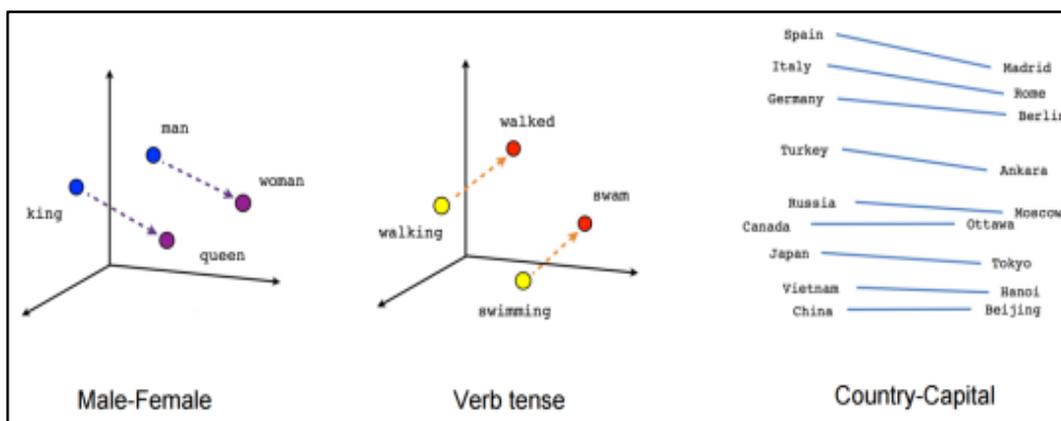
Metode *Semantic similarity* akan menghitung similaritas dari setiap *cluster* berdasarkan dari thesaurus penyebaran kata dalam suatu *corpus* (Puspaningrum, Siahaan, dan Faticah, 2018). Berikut ini adalah rumus *Semantic similarity* yang dijelaskan dalam rumus (2.7).

$$Semantic\ Similarity(w_i, w_j) = \frac{\sum_{m=1}^K w_i^m w_j^m}{\sqrt{\sum_{m=1}^K (w_i^m)^2} \sqrt{\sum_{m=1}^K (w_j^m)^2}} \quad (2.7)$$

Rumus (2.7) digunakan peneliti untuk mengukur jarak kesamaan antara word 1 ( $w_i$ ) dan word 2 ( $w_j$ ).  $\sum_{m=1}^K$  = adalah jumlah iterasi  $m$  hingga  $K$  word. Jarak similariti memiliki nilai 1 yang berarti sama dan -1 berarti berbeda. *Semantic Similarity* dianggap lebih baik dari pembobotan TF-IDF yang tidak dapat memberikan nilai -1 (Puspaningrum, Siahaan, dan Fatichah, 2018).

### 2.6.5 Word Embedding

Representasi vektor kata sangat berguna dalam menangkap makna dari semantik kata-kata (Naili et al, 2017). *Word embedding* merupakan kumpulan nama dari pemodelan bahasa dan teknik ekstraksi fitur pada *Natural Language Processing* (NLP). Setiap kata dari suatu kosakata akan dipetakan menjadi vektor yang berupa bilangan *real*. *Word embedding* sering digunakan dalam *neural networks*, reduksi dimensi pada matriks, kemunculan kata, model probabilistic, dll. Metode *word embedding* ini juga digunakan sebagai input untuk meningkatkan performa pada pengolahan bahasa manusia seperti parsing sintaktik dan analisa sentimen.



**Gambar 2.9** Contoh dari *Word Embedding*

Mikolov (Mikolov et al, 2013), mengusulkan 2 model log-linear untuk menghitung *Word Embeddings* dari suatu dataset secara efisien, yaitu *bag-of-words*. *Continuous bag-of words* (CBOW) model memprediksi kata saat ini berdasarkan konteks kata, seperti yang terlihat pada Gambar 2.9. Berikut ini adalah tiga metode dari *Word Embedding* yang dapat digunakan secara publik, beberapa diantaranya dijelaskan pada Tabel 2.2.

**Tabel 2.2** Tiga metode dari *Word Embedding* yang tersedia secara umum

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

Senna (*Syntactic extraction using a neural network architecture*) merupakan pengembangan Collobert. *Word embedding* 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 membobotkan *least-squares* yang telah dilatih melalui enam milyar 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 *continous bag-of-words*. *Word embeddings* ini merupakan bagian dari Google News dataset yang mengandung 300 dimensi vektor untuk tiga juta (3.000.000) kata dan frasa.

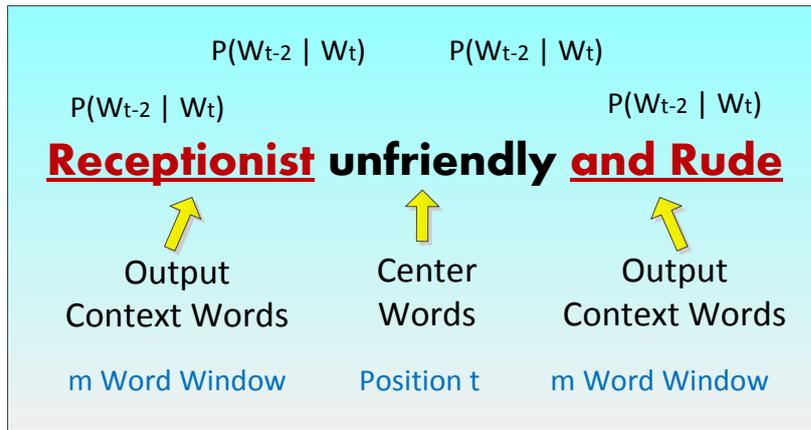
Kami menggunakan *Word embedding* pada GloVe untuk mendapatkan nilai vektor dari setiap *term list* dengan menggunakan rumus (2.8).

$$P(\text{context} | w_t) \quad (2.8)$$

Dengan nilai *loss function* pada rumus (2.9)

$$J = 1 - p(w_{-t} | w_t) \quad (2.9)$$

Salah satu contoh penggunaannya ditunjukkan pada Gambar 2.10



**Gambar 2.10** Contoh Penggunaan *Word Embedding*

$$P(o | c) = \frac{\exp(u_o^T v_c)}{\sum_{w=1}^v \exp(u_w^T v_c)} \quad (2.10)$$

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*.

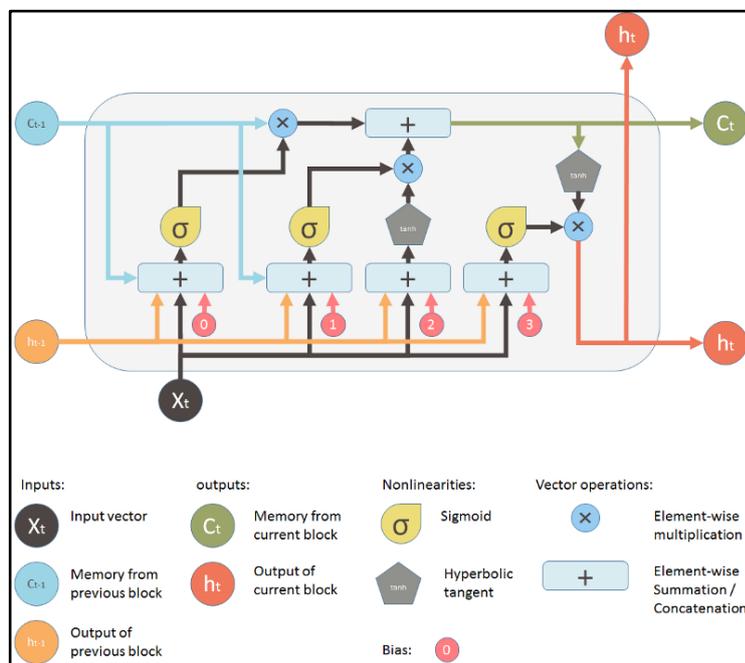
### 2.6.6 Long-Short Term Memory (LSTM)

Analisis sentimen dilakukan setelah tahap klasifikasi dari kelima aspek hotel ditemukan (Wang, Peng, dan Zhang, 2018). Data yang digunakan untuk melakukan klasifikasi sentimen adalah data hasil dari *Aspect Categorization Hotel Reviews Data*.

Kami menggunakan *Word embedding* pada GloVe untuk mendapatkan nilai vektor dari setiap *term list*. Nilai vektor akan kami gunakan untuk klasifikasi sentiment menggunakan metode *Long Short-Term Memory* (LSTM). Klasifikasi sentimen menggunakan teknik *machine learning* pada TensorFlow (Rezaeinia et al, 2019). TensorFlow merupakan perangkat lunak yang digunakan untuk pelatihan sentiment pada metode LSTM (Fernandez-Beltran dan Pla, 2016).

Pada modul ini, setiap label dari dokumen *term list* akan diproses menjadi nilai vektor sebagai nilai fitur (Puspaningrum, Siahaan, dan Fatichah, 2018). Nilai fitur, diambil dari rerata nilai vektor pada representasi *Word embedding* dalam setiap *term* (Kaspa et al, 2018). Representasi *Word embedding*, digunakan untuk inialisasi dari setiap *term* menggunakan Global Vectors (GloVe). Keunggulan dari GloVe, mampu memodelkan representasi vektor yang mewakili *term-term* dari statistik *corpus* secara global. Hal ini dikarenakan bahwa *Word embedding* harus didasarkan pada rasio probabilitas dari kemunculan setiap *term* (Rao et al, 2018).

Pada metode LSTM, terdapat pustaka thesaurus untuk mengimplementasikan model dari *Neural Networks* untuk *synonyms*, *antonyms*, *definitions*, *pronunciations* dalam bahasa Inggris. Penelitian ini menggunakan fungsional *Application Programming Interface* (API) pada Keras, untuk menentukan model yang lebih kompleks. Keras adalah *library* dalam *Neural Networks*, yang dapat berjalan pada TensorFlow dengan bahasa pemrograman Python.



**Gambar 2.11** Standard metode LSTM

Gambar 2.11 menjelaskan standarisasi metode LSTM yang kemudian dibagi menjadi empat komponen yaitu *Input-Gate* (i) untuk mengontrol arus input yang

masuk ke dalam neuron, *Forget-Gate* (f) yang membuat neuron berada dalam status reset dari statusnya saat ini, *Output-gate* (o) untuk mengontrol efek dari aktivasi neuron pada neuron lainnya, dan *memory cell* (c) (Fu et al, 2018). Berikut ini adalah fungsi dari LSTM yang dijelaskan pada rumus (2.11), (2.12), (2.13), (2.14), (2.15), dan (2.16):

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

$$o_t = \sigma(W^{(o)}x_t + U^{(o)}h_{t-1} + b^{(o)}) \quad (2.12)$$

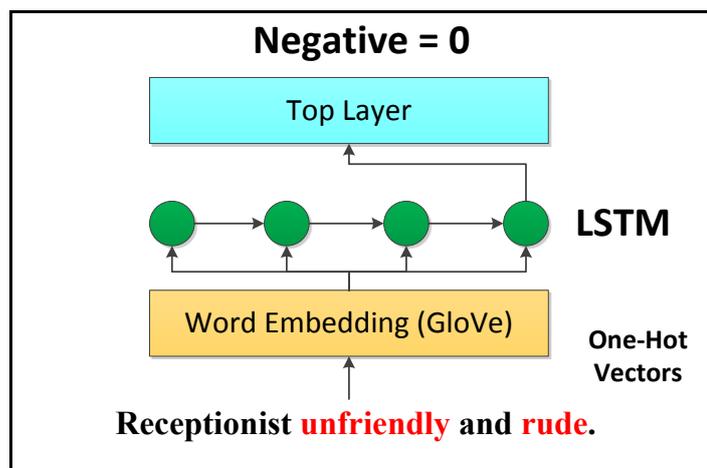
$$f_t = \sigma(W^{(f)}x_t + U^{(f)}h_{t-1} + b^{(f)}) \quad (2.13)$$

$$u_t = \tanh(W^{(u)}x_t + U^{(u)}h_{t-1} + b^{(u)}) \quad (2.14)$$

$$c_t = i_t \odot u_t + f_t \odot c_{t-1} \quad (2.15)$$

$$h_t = o_t \odot \tanh(c_t) \quad (2.16)$$

Bobot matrik antara dua *hidden layer* yang berurutan diberi simbol  $W_k$  dan  $U_k$ . Antara input, *hidden layer*, dan dua *cell activation* yang berurutan, masing-masing terhubung dengan gate k (contoh: input  $\rightarrow$  output  $\rightarrow$  forget  $\rightarrow$  cell). Nilai vektor bias disimbolkan dengan  $b_k$ . Nilai produk pada masing-masing elemen dari dua vektor diberi simbol  $\odot$ . Aktivasi sigmoid nilai merupakan fungsi gate yang diberi simbol  $\sigma$ . Simbol g dan h merupakan aktivasi dari *cell input* dan *cell output* yang bernilai tanh.



Gambar 2.12 Ilustrasi metode LSTM

Gambar 2.12 menjelaskan ilustrasi alur standar dari metode LSTM yang dipecah menjadi empat komponen dengan klasifikasi sentimen (Do et al, 2019). Komponen pada LSTM digunakan sebagai penyematan kata-kata dengan *classifier softmax biner* yang memberikan nilai vektor untuk sentimen. Nilai vektor pada langkah *classifier softmax biner* akan dikalikan dengan matriks bobot lain sehingga menghasilkan nilai 0 dan 1 (Chaudhuri dan Ghosh, 2016). Secara efektif, dapat memberikan parameter nilai pada sentimen *positive* dengan angka 1 dan angka 0 untuk *negative*.

Perhitungan pada klasifikasi sentimen, akan menghasilkan *Accuracy*. *Accuracy* dijadikan sebagai formula untuk mengevaluasi performa sentimen dari metode *deep learning* dengan menggunakan teknik *binary classification*.

Pada penelitian ini, kami ingin membuktikan bahwa *Word embedding* yang ditambahkan dengan metode LSTM mampu menganalisis dokumen *term list* dengan baik, tidak hanya kata sifat. Setiap *term* akan ditentukan dengan nilai vektor, berdasarkan kedekatan kata *positive* dan *negative* yang telah melalui proses *training*. Sehingga, kemungkinan metode *Word embedding* dan LSTM akan memiliki performa yang lebih tinggi dibandingkan teknik yang dilakukan pada SentiWordNet.

Pada penelitian sebelumnya (Suhariyanto, Firmanto, dan Sarno, 2018), analisis sentimen dilakukan dengan menggunakan SentiWordNet. Namun, akurasi data dari SentiWordNet cenderung memiliki nilai yang kecil dibandingkan dengan metode LSTM. Teknik yang dilakukan oleh SentiWordNet adalah menghitung setiap similaritas *term*, menggunakan skor yang dimiliki oleh *dictionary* SentiWordNet. *Dictionary* pada SentiWordNet meliputi *positive*, netral, dan *negative*. Kami menggunakan dua parameter dalam penelitian ini, yaitu *positive* dan *negative* pada SentiWordNet sebagai perbandingan dalam klasifikasi sentimen. Berikut ini adalah rumus SentiWordNet yang dijelaskan dalam rumus (2.17), (2.18) dan (2.19).

$$\text{positive\_score} = \sum_{i=t}^n \text{pos\_score\_SentiWordNet}(i) \quad (2.17)$$

$$\text{negative\_score} = \sum_{i=t}^n \text{neg\_score\_SentiWordNet}(i) \quad (2.18)$$

$$\text{total\_score} = \text{positive\_score} - \text{negative\_score} \quad (2.19)$$

### 2.6.7 Evaluasi

Evaluasi merupakan metode pengukuran yang dianggap paling baik dalam mengukur performa metode yang diusulkan menggunakan *confusion matrix* (Do et al, 2019). Adapun proses perhitungan dari *precision*, *recall* dan *F1-Measure* ditentukan dari prediksi informasi terhadap nilai sebenarnya yang direpresentasikan dengan *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

TP (*True positive*) adalah jumlah dokumen yang diidentifikasi dengan benar sebagai dokumen yang relevan. TN (*True Negative*) adalah jumlah dokumen yang diidentifikasi dengan benar sebagai dokumen yang tidak relevan. FP (*False Positif*) adalah jumlah dokumen yang diambil salah dan diklasifikasikan sebagai dokumen yang relevan. Sedangkan FN (*False Negative*) adalah jumlah dokumen yang diambil salah dan diakui sebagai dokumen yang tidak relevan. Berikut ini adalah formula dari TP, TN, FP dan FN yang akan dijelaskan pada rumus (2.20), (2.21), dan (2.22).

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

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2.20)$$

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

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.21)$$

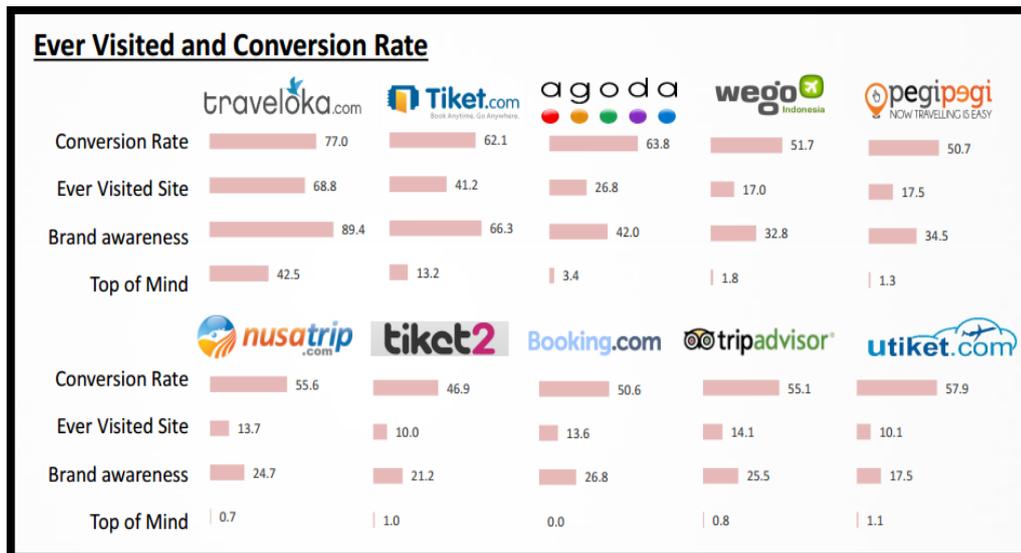
- **F1-Measure** merupakan bobot *harmonic mean* dari *recall* dan *precision*.

$$F1 - Measure = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.22)$$

## 2.7 Website Traveloka

Traveloka adalah perusahaan yang menyediakan layanan pemesanan tiket pesawat dan hotel secara daring dengan memfokuskan diri pada perjalanan domestik di Indonesia. Traveloka memiliki system reservasi tiket yang terintegrasi dengan booking system dari airline, melalui partner-partner yang sudah dipercaya. Traveloka memberikan keamanan transaksi tiket serta kemudahan pemesanan hotel melalui sistem otomatis, tanpa harus melalui pemesanan manual. Hal ini memungkinkan konsumen yang akan melakukan pemesanan tiket mendapatkan pilihan yang di inginkan, kenyamanan dan keamanan yang terjamin.

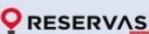
Traveloka adalah salah satu contoh sistem informasi di bidang Transportasi yang menyediakan layanan penjualan tiket pesawat dan hotel secara online. Pelanggan dapat memesan tiket melalui website atau *download* aplikasi melalui website, appstore dan playstore, sehingga tidak perlu lagi ke bandara atau ke hotel secara langsung. Nama Traveloka masuk dalam kategori Trio Unicorn Indonesia bersama dengan Tokopedia dan Gojek. Unicorn adalah sebutan bagi *start up* yang valuasinya sudah tembus diatas USD 1 Milyar (atau setara Rp 13 triliun). Hal ini selaras dengan data yang diperoleh dari (Karimuddin, 2019) yang ditampilkan pada Gambar 2.13 berikut ini:



**Gambar 2.13** Tingkat Konversi dari Kunjungan Website Tahun 2016.

Gambar 2.13 menjelaskan bahwa Traveloka menjadi situs website yang paling populer di negara Indonesia. Traveloka mampu mengekspand wisatawan hingga ke luar negeri. Pelanggan yang ada diluar negeri mampu mengakses Traveloka, termasuk negara maju seperti New York. Tiket.com dan Agoda mengikuti di posisi kedua dan ketiga. Sehingga, diharapkan dengan website Traveloka pelanggan dapat menemukan rute penerbangan dan hotel terbaik secara cepat, aman, dan harga yang lebih ekonomis dari dalam hingga ke luar negeri. Traveloka saat ini menjadi aplikasi platfom utama yang menyediakan berbagai layanan yang memudahkan pelanggannya. Traveloka memiliki tampilan website yang lebih *user friendly* dari para pesaingnya, sehingga pelanggan lebih familiar dan mudah saat menggunakan website Traveloka.

**Peringkat & Kunjungan**

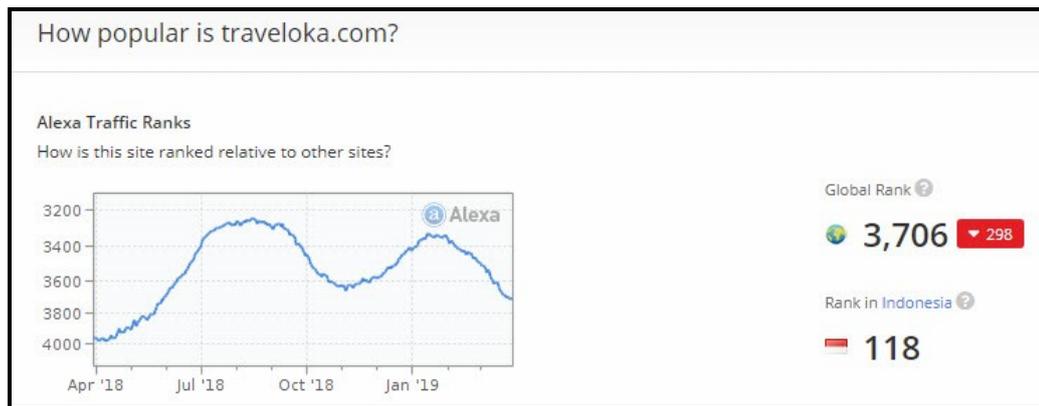
No	Nama	Alexa (ID)	Kunjungan (bulan)
1	 traveloka.com	103	7.375.350
2	 Tiket.com	152	4.213.500
3	 pegipegi	474	1.408.620
4	 nusatrip	1.277	628.290
5	 RESERVASI.com	1.981	310.680

Ket : : Data diambil setara.net pada 18 Desember 2016, pukul 01:20 WIB  
Sumber : Alexa & Statshow.com



**Gambar 2.14** Peringkat & Kunjungan Website di Indonesia Tahun 2016 versi Alexa.

Gambar 2.14 menjelaskan tren penggunaan website Traveloka di Indonesia pada tahun 2016 untuk pemesanan tiket hotel, berdasarkan rating dari Alexa. Alexa merupakan software yang membantu bisnis dalam mengungkap strategi pemasaran untuk ditindak lanjuti agar mendapatkan hasil pemasaran yang baik. Traveloka adalah perusahaan dengan startup yang berada diposisi urutan ke 103 untuk negara Indonesia. Tiket.com menduduki urutan ke 152, lalu ada pegipegi.com yang menduduki peringkat 474, sedangkan nusatrip.com jauh tertinggal, Traveloka berada di urutan 1.277 dan ada Reservasi.com yang masih sangat jauh tertinggal diperingkat 1981. Tak hanya dari alexa saja namun dalam segi jumlah kunjungan website, traveloka menduduki tempat paling atas dari keempat startup lainnya. Jumlah kunjungan website traveloka menurut statshow.com tiap bulannya ada di angka 7.375.350. Seperti peringkat alexa, Tiket.com selalu mengejar jejak Traveloka dengan menduduki angka kunjungan sebesar 4.213.500. Menyusul Pegipegi di 1.408.620 dan Nusatrip diangka 628.290. Reservasi menduduki peringkat terakhir dengan nilai 310.680 saja dalam sebulan.



**Gambar 2.15** Alexa Traffic Ranks Tahun 2019

Gambar 2.15 menjelaskan bahwa pada tahun 2019, Traveloka mengalami penurunan dalam rank dunia dengan nilai 3.706. Sedangkan rank di Indonesia, Traveloka berada dalam urutan 118.



**Gambar 2.16** Similiarweb Traffic Ranks Tahun 2019

Gambar 2.16 menjelaskan bahwa pada tahun 2019, ranking Traveloka dalam dunia berada dalam posisi 2.005. Sedangkan rank di Indonesia, Traveloka berada dalam urutan 59 dengan kategori rank travel pada urutan ke 7.

Beberapa situs memberikan angka survey yang berbeda-beda. Perbedaan rank yang signifikan ini, dapat dijadikan acuan bagi praktisi bisnis lainnya dalam mengelola manajemen hotel dari skala nasional dan internasional. Praktisi bisnis dapat belajar dari pengalaman, lingkungan, dan pesaing bisnis dalam meningkatkan kualitas layanan dan jasa berdasarkan kepuasan pelanggan dari ulasan-ulasan pelanggan secara online.

## 2.8 Penelitian Sebelumnya

Pada literatur Xun Xu (Xun Xu et al, 2017), peneliti menganalisa sentimen ulasan pelanggan dari berbagai jenis hotel dengan menggunakan metode *Latent Semantic Analysis* (LSA). Kekurangan dari penelitian adalah tidak fokus terhadap aspek-aspek yang dapat mempengaruhi sentimen pelanggan. Rating bintang dalam website Traveloka, dianggap tidak dapat merepresentasikan dengan baik untuk menilai kepuasan pelanggan. Kemudian, metode LSA merupakan sebuah metode yang tradisional dan tidak dapat diterapkan pada *Natural Language Processing* (NLP) ataupun *Artificial Intelligence* (AI). Kekurangan yang lainnya adalah metode LSA memeriksa kata yang dianggap sama berdasarkan pelafalan, namun memiliki makna yang berbeda.

Sama seperti Xun Xu (Xun Xu et al, 2017), Yabing (Y. Zhao, X. Xu, dan M. Wang, 2019) melakukan penelitian dengan mengukur kepuasan pelanggan dengan analisa sentimen dari website TripAdvisor berdasarkan rating yang diberikan oleh pelanggan dan rating keseluruhan pada hotel. Kekurangan dari penelitian adalah melihat dari polaritas sentimen berdasarkan rating bintang pada hotel dan rating bintang pada ulasan, tanpa mempertimbangkan aspek hotel yang lainnya. Pentingnya dari mempertimbangkan aspek hotel adalah aspek dapat mempengaruhi opini pelanggan (sentimen pelanggan).

Penelitian Dewi Ayu (Khotimah dan Sarno, 2018), mengembangkan dari penelitian Xun Xu (Xun Xu et al, 2017) dan membuktikan bahwa metode PLSA sangat baik untuk menghasilkan *hidden topic* dengan mempertimbangkan probabilitas kemunculan kata dari ulasan yang panjang. Ulasan yang panjang digunakan untuk mendeteksi sentimen pelanggan berdasarkan judul komentar. Analisa sentimen yang dihasilkan memiliki tingkat akurasi yang tinggi dengan tingkat kesalahan sistem yang cenderung kecil. Kekurangan dari penelitian adalah tidak mencari aspek-aspek yang dapat mempengaruhi sentimen pelanggan pada hotel. Hasil penelitian yang dilakukan Khotimah (Khotimah dan Sarno, 2018), menghasilkan beberapa *term list* hotel yang kemudian ditambahkan kedalam penelitian ini sebagai *keyword term list* hotel yang diperoleh.

Penelitian Chen (Chen dan Chen, 2015), mengukur aspek-aspek yang dapat mempengaruhi sentimen pelanggan berdasarkan ulasan online. Kekurangan dari penelitian adalah mencari aspek secara luas menggunakan algoritma regresi linear. Sehingga, aspek yang diperoleh terlalu luas dan beragam. Keberagaman aspek menjadi sulit untuk dianalisa karena aspek terlalu luas dan bersifat *optional* (tergantung dari jenis hotel). Hasil *term list* hotel dalam penelitian Chen, akan ditambahkan pada penelitian ini sebagai *keyword term list* hotel yang diperoleh.

Penelitian Akhtar (Akhtar et al, 2017), mengukur kepuasan pelanggan dengan analisa sentimen berdasarkan ulasan hotel pada website TripAdvisor. Kekurangan dari penelitian adalah mencari sentimen pelanggan berdasarkan keseluruhan aspek yang mempengaruhinya. Kekurangan selanjutnya adalah metode yang digunakan dalam analisa sentimen masih memiliki nilai akurasi yang kecil yaitu dibawah 70%. Aspek hotel terlalu luas, sehingga akan membuat opini pelanggan yang beragam. Hal ini akan menyulitkan pihak manajemen hotel atau praktisi bisnis dalam melakukan evaluasi kepuasan pelanggan. Evaluasi pelanggan harus fokus terhadap beberapa aspek untuk memudahkan praktisi bisnis dalam memperbaiki kualitas dan layanan hotel (misalnya kebersihan, makanan, *service*, lokasi dan kenyamanan). Hasil penelitian yang dilakukan oleh Akhtar, menghasilkan beberapa *term list* hotel yang kemudian ditambahkan kedalam penelitian ini sebagai *keyword term list* hotel yang diperoleh.

Sama seperti Akhtar (Akhtar et al, 2017), penelitian yang dilakukan oleh Cho (C. C. Hnin, N. Naw, dan A. Win, 2018) masih terlalu luas untuk menggali aspek yang dapat mempengaruhi sentimen pelanggan. Aspek hotel yang digali dari ulasan pelanggan terlalu global dan hanya berdasarkan pada 1 ulasan hotel saja. Sehingga, tidak dapat dijadikan pedoman untuk mengukur kepuasan pelanggan pada ulasan hotel lain. Aspek hotel yang diperoleh juga akan berbeda-beda tergantung dari jenis hotel dan wilayah dari suatu negara. Sedangkan dalam suatu negara memiliki banyak karakteristik seperti aturan, suku, agama dan perilaku manusia yang beragam.

Penelitian Revindasari (Revindasari, Sarno, dan Solichah, 2016) yang memperkuat opini peneliti dalam menggunakan metode PLSA untuk mencari *hidden topic* dengan mempertimbangkan probabilitas kemunculan kata berdasarkan dari dokumen. Kekurangan dari penelitian ini adalah mencari topik yang sama berdasarkan pada dokumen bisnis proses (BP) dan software komponen (SK) yang dimiliki oleh perusahaan, namun tidak secara global dan *up to date*. Topik yang global dan *up to date* dapat diperoleh dari ulasan pelanggan secara online. Sehingga, metode PLSA dapat diterapkan pada ulasan pelanggan secara online untuk mencari *hidden topic* secara akurat. *Hidden topic* sering digunakan oleh peneliti lain untuk membentuk suatu aspek yang dapat mempengaruhi kepuasan pelanggan.

Kemudian Puspaningrum (Puspaningrum, Siahaan, dan Fatichah, 2018), juga meneliti menggunakan metode *Latent Dirichlet Allocation* (LDA) untuk menghasilkan *hidden topic* dari ulasan pelanggan *mobile app review*. Metode *Term Frequency-Inverse Corpus Frequency* (TF-ICF) juga diterapkan sebagai pembobotan setiap *term list* yang diperluas dari masing-masing *cluster* pada setiap dokumen. Metode LDA memiliki fungsi *dirichlet*, sehingga dapat mencegah *over fitting* dalam analisa kata. Kekurangan dari penelitian adalah metode LDA tidak maksimal jika diterapkan pada ulasan yang panjang untuk menemukan topik. Ulasan yang panjang, dapat dideteksi dengan baik menggunakan metode PLSA seperti pada penelitian yang dilakukan oleh Khotimah (Khotimah dan Sarno, 2018).

Penelitian Suadaa (Suadaa dan Purwarianti, 2016) juga menggunakan TF-ICF sebagai pembobotan setiap *term list* yang diperluas dari masing-masing *cluster* pada setiap dokumen menggunakan bahasa indonesia. Kekurangan dari penelitian ini adalah minimnya *corpus* dalam bentuk bahasa indonesia sehingga tidak sesuai jika diterapkan pada penelitian yang menggunakan bahasa internasional seperti bahasa inggris.

Penelitian Wang (J. Wang, B. Peng, dan X. Zhang, 2018), menggunakan GloVe sebagai *Word embedding* untuk mendapatkan nilai vektor dari setiap *term*

*list*. Nilai vektor digunakan untuk memprediksi sentimen pelanggan menggunakan metode *Long Short-Term Memory* (LSTM). Kekurangan dari penelitian, hanya menganalisa sentimen tanpa memperhatikan aspek-aspek yang dapat mempengaruhinya. Namun, hasil akurasi sistem dalam menganalisa sentimen masih lebih baik dari penelitian Akhtar (Akhtar et al, 2017) dan Cho (C. C. Hnin, N. Naw, dan A. Win, 2018).

Penelitian Kaspas (Kaspas et al, 2018) dan Rao (Rao et al, 2018), juga menggunakan Global Vectors (GloVe) untuk menghasilkan nilai fitur yang diambil dari rerata nilai vektor pada representasi *Word embedding* dalam setiap *term*. Representasi *Word embedding*, digunakan untuk inisialisasi dari setiap *term* menggunakan GloVe. Keunggulan dari GloVe, mampu memodelkan representasi vektor yang mewakili *term-term* dari statistik *corpus* secara global. Hal ini dikarenakan bahwa *Word embedding* harus didasarkan pada rasio probabilitas dari kemunculan setiap *term*. Kekurangan dari penelitian hanya berfokus pada *Word embedding* dalam setiap *term* namun tidak diperluas dengan riset yang lain.

Penelitian Rezaeinia (Rezaeinia et al, 2019), menggunakan metode LSTM untuk klasifikasi sentimen dengan teknik *machine learning* pada TensorFlow. Akurasi sistem yang dihasilkan sangat baik, namun dalam penelitian Rezaeinia tidak meneliti aspek-aspek yang dapat mempengaruhi nilai sentimen pelanggan. Sehingga, kekurangan ini dapat dijadikan masukan oleh peneliti dimasa depan untuk mencari aspek yang dapat mempengaruhi opini pelanggan (sentimen pelanggan).

Oleh sebab itu, peneliti mengembangkan dan melakukan kolaborasi dari beberapa penelitian diatas. Hasil sistem membuktikan bahwa rating bintang tidak dapat merepresentasikan kepuasan pelanggan dengan baik, tanpa melihat aspek-aspek hotel yang mempengaruhinya. Terdapat 5 aspek hotel sebagai alat ukur dari kepuasan pelanggan pada website Traveloka yaitu kebersihan, makanan, *service*, lokasi dan kenyamanan. Dalam penelitian ini, digunakan metode *Probabilistic Latent Semantic Analysis* (PLSA) untuk menghasilkan *hidden topic* dari dokumen *term list* untuk menemukan aspek-aspek hotel yang ditambahkan dengan *term list*

dari penelitian Akhtar (Akhtar et al, 2017), Chen (Chen dan Chen, 2015) dan Khotimah (Khotimah dan Sarno, 2018). Dengan dasar pertimbangan bahwa, metode PLSA menghasilkan performa akurasi (*precision, recall* dan *F1-Measure*) lebih baik dibandingkan metode *Latent Semantic Analysis* (LSA) dalam melakukan pencarian *hidden topic*.

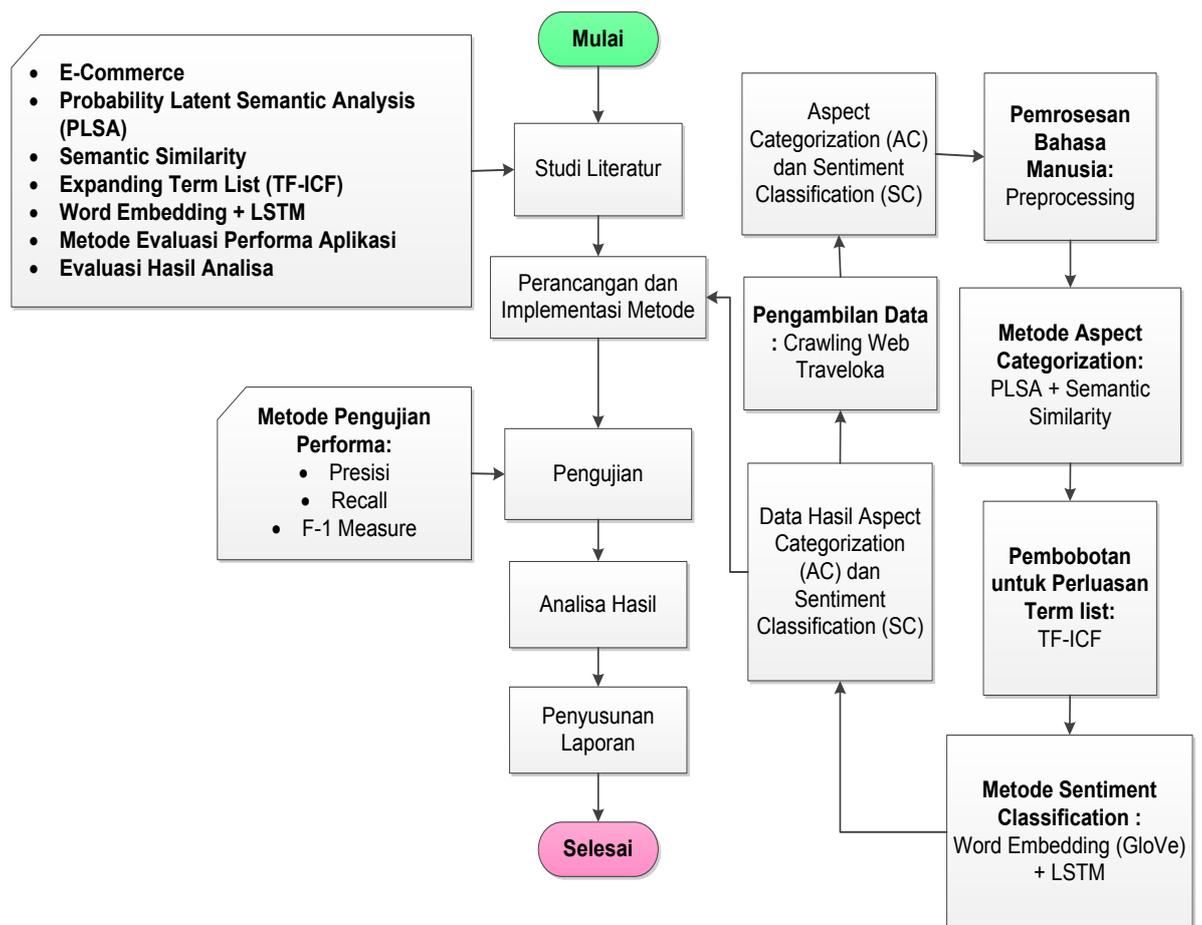
Kelebihan lainnya adalah metode PLSA, mampu memeriksa kata berdasarkan pada pelafalan dan makna kata yang sama (Lebih baik dari metode LSA). Metode PLSA lebih tepat digunakan pada ulasan produk yang panjang (Lebih baik daripada metode LDA). Ulasan yang panjang dapat dideteksi dengan mudah menggunakan algoritma *Expectation* (E-Step) dan *Maximization* (M-Step) pada *Natural Language Processing* (NLP) Python. Metode TF-ICF digunakan sebagai pembobotan dari *term list* yang diperluas dari masing-masing *cluster* pada setiap dokumen seperti pada penelitian Puspaningrum (Puspaningrum, Siahaan, dan Faticah, 2018) dan Suadaa (Suadaa dan Purwarianti, 2016). Tiga pendekatan digunakan untuk membuktikan keefektifan suatu metode untuk menganalisa aspek hotel. Hasil penelitian menunjukkan bahwa dengan menambahkan metode TF-ICF dapat meningkatkan keakurasian data pada 5 aspek hotel (kebersihan, makanan, *service*, lokasi dan kenyamanan).

Penelitian dari Kaspas (Kaspas et al, 2018) dan Rao (Rao et al, 2018) memperkuat opini peneliti dalam menggunakan Glove untuk menghasilkan nilai fitur yang diambil dari rerata nilai vektor pada representasi *Word embedding* dalam setiap *term*. Fungsi dari nilai vektor adalah menghasilkan angka 0 dan 1 yang akan dibaca oleh metode lain untuk klasifikasi sentimen. Klasifikasi sentimen pada ulasan pelanggan menggunakan teknik *machine learning* pada TensorFlow yaitu metode metode *Long Short-Term Memory* (LSTM) seperti pada penelitian Wang (J. Wang, B. Peng, dan X. Zhang, 2018). Pendekatan aspek terbaik akan digunakan untuk langkah selanjutnya yaitu analisa sentimen. Tiga pendekatan digunakan untuk membuktikan keefektifan suatu metode untuk analisa sentimen pelanggan terhadap hotel. Pendekatan dari analisa sentimen terbaik, akan digunakan sebagai saran kepada pembaca dan peneliti lain untuk terus mengembangkan penelitian ini.

## BAB 3

### METODOLOGI PENELITIAN

Penelitian ini dimulai dengan melakukan studi literatur untuk mengetahui ruang lingkup penelitian. Peneliti melakukan perancangan dan implementasi metode dengan pengambilan data terlebih dahulu (*crawling*) pada website Traveloka. Data hasil *crawling* akan diproses dengan cara *preprocessing*, kemudian mengkategorikan setiap ulasan berdasarkan kelima aspek hotel. Peneliti juga melakukan klasifikasi sentimen terhadap 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 dari tahapan metode penelitian Gambar 3.1 akan diterangkan secara terperinci pada sub bab berikut ini:

### 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 yang memiliki hubungan dengan klasifikasi teks, penggalan opini, metode PLSA, *Semantic Similarity*, perluasan *term list*, *Word Embedding* (GloVe) dan LSTM. Dari studi literatur yang telah dilakukan, diperoleh informasi yang berhubungan dengan penelitian, diantaranya sebagai berikut:

1. Ulasan produk merupakan *User Generated Content* (UGC) yang menggambarkan *feelings, opinions, emotions* dari banyak pelanggan secara jelas, sebagai tolak ukur dalam menilai kepuasan pelanggan.
2. Proses penggalan opini membutuhkan metode klasifikasi yang baik agar pengembang dapat memperoleh banyak masukan untuk membantu manajer hotel dalam meningkatkan kualitas jasa dan pelayanan hotel.
3. Metode PLSA (*Probabilistic Latent Semantic Analysis*) digunakan untuk menghitung probabilitas kata dan dokumen dari ulasan produk. PLSA mengidentifikasi kata-kata yang digunakan melalui algoritma EM (*Expectation-Maximization*). PLSA mampu menghasilkan *hidden topic* dari suatu dokumen. *Hidden topic* merupakan kata-kata penting atau kata-kata yang sering muncul dalam korpus yang dihitung berdasarkan nilai probabilitasnya.
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.
5. *Term Frequency-Inverse Cluster Frequency* (TF-ICF) merupakan metode perluasan *term list* untuk mengetahui bobot suatu kata pada suatu klaster berdasarkan kemunculan *term* pada cluster.
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*

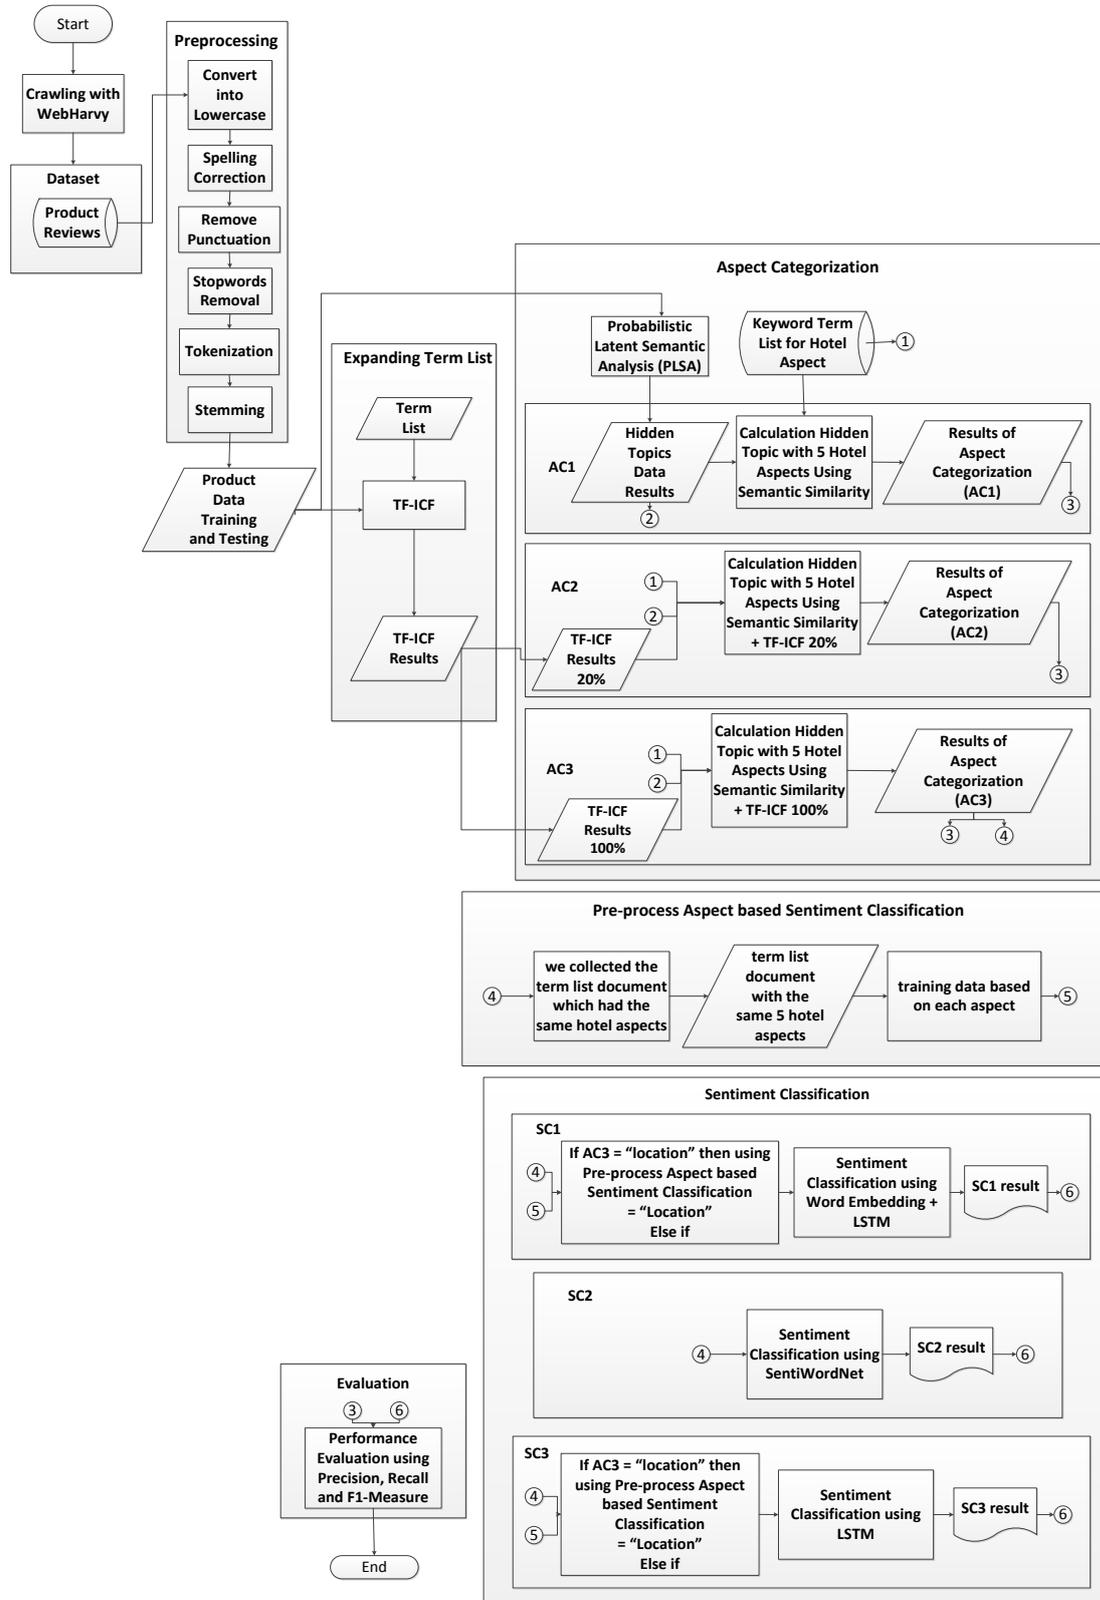
*Embeddings* yang digunakan dalam penelitian ini adalah GloVe. GloVe juga akan digunakan untuk menjadi kakas bantu dalam melakukan *expand term list* saat training data dan saat klasifikasi.

7. *Long Short Term Memory* (LSTM) merupakan metode yang populer untuk klasifikasi sentimen karena LSTM mampu menyimpan *term-term* dengan jangka yang panjang pada memory-nya sehingga LSTM dapat digunakan untuk memodelkan keterhubungan antara *term* bahkan yang memiliki interval yang jauh.
8. Evaluasi pelabelan menggunakan formula *Precision*, *Recall*, dan *F-Measure* untuk melakukan pengukuran performa metode yang diusulkan.
9. Terdapat suatu karakteristik dari ulasan 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 opininya, 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 relasi antar kata dalam kalimat. Dari studi literatur, dapat disimpulkan juga mengenai kondisi saat ini bahwa:
  - c. Sebagai salah satu sumber masukan bagi manajer bisnis hotel, penggalian opini dapat digunakan untuk menggali kepuasan pelanggan terhadap 5 aspek hotel.
  - d. Dalam melakukan proses penemuan aspek atau topik serta sentimen dari suatu ulasan produk, dibutuhkan suatu proses yang dapat menganalisa jika terdapat ulasan yang mengandung lebih dari satu aspek atau sentimen.

### 3.2 Pembangunan Model Penelitian



Gambar 3.2 Diagram Alur Model Penelitian.

Gambar 3.2 menjelaskan keseluruhan kinerja dari model penelitian. Model penelitian yang digunakan memiliki beberapa proses yang akan dijelaskan berikut ini:

1. Data *text* ulasan hotel akan di *crawling* dengan menggunakan software WebHarvy. Data yang telah di *crawling* akan dipisahkan berdasarkan tanda titik (*split data*). Hal tersebut berdasarkan pertimbangan bahwa suatu ulasan mengandung lebih dari satu *aspect* dan sentimen. Data ini kemudian disimpan dalam *text* ulasan hotel DB (Database) agar nantinya dapat diproses pada langkah selanjutnya.
2. Data yang diperoleh dari No.1, akan diolah dengan menggunakan tahapan *pre-processing*. Modul *pre processing* bertugas untuk membersihkan ulasan 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 ulasan 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*, data *training* (80% data hotel) akan diproses menggunakan metode TF-ICF untuk mendapatkan *term-term* penting pada setiap kelas atau setiap *aspect* yang akan dianalisa. Dengan demikian, diharapkan modul ini dapat mengoptimalkan proses pada modul “*Aspect Categorization*” terutama pada saat perhitungan *hidden topic* yang dimatching-kan dengan kelima aspek hotel (*Location, Meal, Service, Comfort* dan *Cleanliness*) menggunakan metode Semantic Similarity.
4. Data *term list* hasil *pre-processing* akan diproses menggunakan metode PLSA untuk menemukan *hidden topic*. *Hidden topic* akan diproses oleh metode Semantic Similarity untuk melakukan proses kategorisasi *aspect*. Pada modul ini, data akan dikategorikan kedalam 5 aspek hotel (*Location,*

- Meal, Service, Comfort dan Cleanliness*). Selanjutnya, akan didapatkan kategorisasi aspek dari setiap data ulasan.
5. Setelah di dapatkan data kategorisasi *aspect* dari setiap ulasan, data akan diproses untuk dilakukan analisa sentimen. Sebelum itu, data hasil kategorisasi *aspect* akan diproses pada *Pre-processed for Aspect Based Sentiment Analysis*. Proses ini mengumpulkan hasil kategorisasi *aspect* berdasarkan kategori yang sama. Data yang memiliki *aspect* sama akan di training untuk mendapatkan *term list* sentimen dari setiap kategori *aspect*. Data hasil kategorisasi *aspect* dan data *term list* hasil training sentimen dari setiap *aspect*, akan diproses untuk mencari klasifikasi sentimen kepuasan pelanggan berdasarkan *aspect*.
  6. Kalsifikasi sentimen kemudian dilakukan dengan menggunakan metode LSTM yang digabungkan dengan *Word Embedding* untuk menemukan nilai vector setiap kata, penggabungan ini didasarkan pada literatur yang menyebutkan bahwa proses tersebut (*Word Embedding + LSTM*) akan menghasilkan performa yang lebih baik. *Word embedding* yang digunakan oleh peneliti adalah GloVe. Kemudian, dari proses ini akan diperoleh data hasil klasifikasi sentimen dari setiap ulasan hotel.
  7. Kategorisasi *aspect* dan klasifikasi sentimen 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 sentimen).
  8. Dengan menggunakan performa metode terbaik, diharapkan hasil akhir dari tujuan “Analisis Sentimen berdasarkan Aspek pada *Review Hotel* menggunakan *Probabilistic Latent Semantic Analysis, Word Embedding, dan LSTM*” ini mampu direpresentasikan dengan baik.

### **3.2.1 Data Ulasan Produk Hotel**

Data diambil dengan cara *crawling* menggunakan software WebHarvy. Hasil dari data *crawling* akan disimpan dalam *product reviews* DB agar nantinya

dapat diproses pada langkah selanjutnya. Data ulasan hotel yang akan diproses dan dianalisa selanjutnya disebut sebagai dokumen ulasan produk.

**Tabel 3.1** Hasil data *crawling* menggunakan WebHarvy

<b>Reviewer Name</b>	<b>Product Reviews</b>
William	a clean swimming pool at Manhattan
Richard	The Staff unable to prepare cue Pool
Lana	Receptionist unfriendly and rude
Edward	Poor breakfast.
Maria	Crowded lobby and scary corridors.
Roy Leonard	Don't be deceived by the nice smell in the lobby.
Steve	The hotel has a fab location and should be attracting great reviews.
Fransiscus E.S	The breakfast is als0 great!!!
Kathleen K.	A nice hotell,small but GOOD 🍑🍑🍑.!!
Robert	the internet was VERY SLOWWW at night. make us not comfortable to stay at this hotel.

Tabel 3.1 menampilkan beberapa data dari hasil *crawling*. Peneliti memperoleh 529 data, dari hasil *crawling* ulasan produk pada hotel Times Square, Manhattan, New York yang diambil dalam 3 tahun terakhir (2015-2018). Ulasan produk yang diambil peneliti adalah ulasan yang menggunakan bahasa inggris.

**Tabel 3.2** Hasil *Crawling* dengan pelabelan dokumen

<b>id_rev</b>	<b>id_doc</b>	<b>Product Reviews</b>
1	1	a clean swimming pool at Manhattan
2	2	The Staff unable to prepare cue Pool
3	3	Receptionist unfriendly and rude
4	4	Poor breakfast.
5	5	Crowded lobby and scary corridors.
6	6	Don't be deceived by the nice smell in the lobby.
7	7	The hotel has a fab location and should be attracting great reviews.
8	8	The breakfast is als0 great!!!
9	9	A nice hotell,small but GOOD 🍑🍑🍑.!!
10	10	the internet was VERY SLOWWW at night.
11	10	make us not comfortable to stay at this hotel.

Tabel 3.2 menampilkan hasil data *crawling* dari Table 3.1 yang diberi label *Identity Document* (ID). Label ID di sesuaikan dengan urutan nomor pada ulasan produk. Urutan dari ulasan produk, diberi inisial “id\_rev” yang memiliki arti dokumen. Dokumen akan di *split* pada data tersebut menjadi dua ID dan diberikan ID pada masing-masing dokumen. ID pada masing-masing dokumen, akan diberi inisial “id\_doc” sebagai nomor unik yang mewakili bagian dari salah satu dokumen.

Tanda baca titik (.) pada setiap ulasan, akan dijadikan dokumen baru seperti pada ulasan “id\_rev 10”. Hal tersebut dikarenakan, peneliti ingin memisahkan setiap ulasan berdasarkan titik. Ulasan “id\_rev 10” akan direpresentasikan dalam dua id\_review dengan satu id\_doc. Sehingga, kalimat pada ulasan produk yang panjang dapat dideteksi dengan mudah sesuai dengan aspek dan sentimennya.

### 3.2.2 Preprocessing

Teknik *preprocessing* dilakukan dengan enam tahap yaitu *Convert into Lowercase*, *Tokenisasi*, *Stemming*, *Stopwords Removal*, *Remove Punctuation*, *Spelling Correction* yang di ilustrasikan pada Tabel 3.3.

**Tabel 3.3** Ilustrasi dari Data *Preprocessing*

Product Review	Preprocessing	Results
A nice hotell,small but GOOD 👍👍👍!!	<i>Converting into Lowercase</i>	a nice hotell,small but good 👍👍👍!!
	<i>Tokenization</i>	a, nice, hotell, small, but, good, 👍,👍,👍,..,!,!
	<i>Stemming</i>	nice, hotell, small, but, good, 👍,👍,👍,..,!,!
	<i>Stopwords Removal</i>	nice, hotell, small, good, 👍,👍,👍,!,!
	<i>Remove Punctuation</i>	nice, hotell, small, good
	<i>Spelling Correction</i>	nice, hotel, small, good

Proses preprocessing dilakukan dengan menggunakan *Natural Language Toolkit* (NLTK) pada Python. Dokumen dari hasil *preprocessing*, disebut dokumen *term list*. Selanjutnya, hasil *preprocessing* ini akan digunakan sebagai input dari proses klasifikasi. Gambar 3.2 pada diagram alur metode penelitian menunjukkan bahwa preprocessing akan menjadi input pada proses *expanding*

*term list* dan proses kategorisasi aspek. Contoh *input* yang akan digunakan untuk melakukan proses klasifikasi ditunjukkan pada Tabel 3.4.

Kami mengambil delapan contoh ulasan produk dari Tabel 3.3 untuk ditampilkan dalam Tabel 3.4.

**Tabel 3.4** Hasil dari Data *Preprocessing* untuk Masukan Proses Klasifikasi

id_rev	Data Preprocessing Result
1	'clean', 'swimming', 'pool', 'manhattan'
2	'staff', 'unable', 'prepare', 'cue', 'pool'
3	'receptionist', 'unfriendly', 'rude'
4	'poor', 'breakfast'
5	'crowd', 'lobby', 'scary', 'corridor'
6	'dont', 'deceive', 'nice', 'smell', 'lobby'
7	'hotel', 'fab', 'locate', 'attract', 'great', 'review'
8	'breakfast', 'great'

Beberapa contoh dalam hasil *preprocessing* pada Tabel 3.4 kami gunakan sebagai ilustrasi pada penelitian ini.

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

*Term Frequency* (TF) adalah metode paling sederhana untuk perluasan *term list* melalui pembobotan dari setiap *term*. Setiap *term*, diasumsikan memiliki kepentingan yang proporsional dengan jumlah kemunculan *term* dalam dokumen.

Kami menggunakan 5 aspek hotel yang diambil dari website Traveloka, meliputi: 1) *Location*; 2) *Meal*; 3) *Service*; 4) *Comfort*; dan 5) *Cleanliness* untuk klasifikasi data. Kelima *aspect* ini akan didefinisikan sebagai berikut:

1. Aspek *Location* berisi tentang ulasan-ulasan yang membahas lokasi, tempat-tempat bagus dan unik di sekitar lokasi serta kemudahan akses transportasi karena lokasi yang baik. Berikut ini adalah contoh ulasan produk mengenai aspek lokasi:

*“The location is the best thing with this hotel if you looking for stay nearby Times Square”*

2. Aspek *Meal* berisi tentang ulasan-ulasan yang membahas makanan dan kegemaran pelanggan terhadap masakan yang disajikan. Berikut ini adalah contoh ulasan produk mengenai aspek makanan:

*"The breakfast was great"*

3. Aspek *Service* berisi tentang ulasan-ulasan yang membahas bagaimana cara petugas atau staff hotel dalam memberikan pelayanan (jasa) serta fasilitas umum yang diberikan oleh hotel seperti (gym, kolam renang, dst.) sebagai bentuk lain dari pelayanan mereka. Berikut ini adalah contoh ulasan produk mengenai aspek pelayanan:

*"Very awesome and polite made sure we had everything we needed and even got us an early check-in."*

4. Aspek *Comfort* berisi tentang ulasan-ulasan yang membahas tentang aspek kenyamanan pada hotel. 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. Berikut ini adalah contoh ulasan produk mengenai aspek kenyamanan:

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

5. Aspek *Cleanliness* berisi tentang ulasan-ulasan yang membahas tentang aspek kebersihan pada hotel tersebut. Berikut ini adalah contoh ulasan produk mengenai aspek kebersihan:

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

Peneliti menggunakan *Term Frequency-Inverse Document Frequency* (TF-ICF) untuk memperluas *term list* menggunakan rumus (2.2). Metode TF-ICF digunakan untuk mengambil *term-term* penting dari setiap kelas. Penambahan *term list* berdasarkan kelas yang telah ditandai sebelumnya, diharapkan mampu meningkatkan performa hasil penelitian. Hasil dari modul *Expanding Term List* ini akan digunakan dalam proses perhitungan metode *Semantic Similarity*.

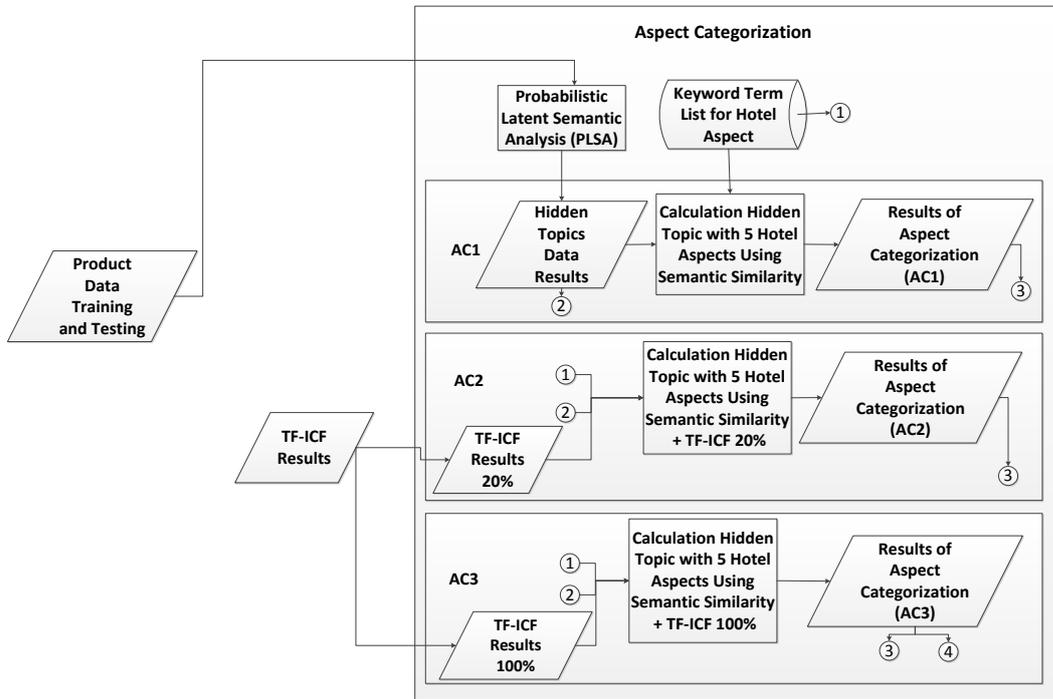
Hasil dari perluasan term list menggunakan TF-ICF, akan ditambahkan pada tabel “2.1 *Keyword Term List* Aspek Hotel” sehingga dapat di representasikan pada tabel berikut ini:

**Tabel 3.5** *Keyword Term List* + Hasil TF-ICF terkait 5 Aspek

<b>Aspek</b>	<b>Expanded Term terkait Aspek yang Diperoleh</b>
<b>Location</b>	railway, view, station, airport, distance, far, close, convenient, train, metro, location, place, distance, station, shuttle, cab, taxi, uber, subway, attraction, shopping, block, bus, ride, metro, mall, bus stop, downtown, park, theater, strip, district, museum, transportation, quarter, tourist interest, heart, trolley, middle, square, <b>locate, convenient, access, subway, walking, building, garden, taxi, attraction, metro, block.</b>
<b>Meal</b>	drink, breakfast, spicy, meal, tea, buffet, bar, restaurant, dinner, lunch, brunch, delicious, food, dish, wine, salad, pizza, buffet variety, court, shop, dinner, selection, snack, fruit, cereal, egg, cheese, juice, variety, coffee, bagel, pastry, waffle, cafe, menu, item, gift, cup, <b>eat, starbucks, outlet, croissant, variety, shop, court, selection, snack, fruit, cereal, egg, juice, cheese.</b>
<b>Service</b>	connection, meeting, charge, activity, sleep, bed, bedroom, pillow, sofa, suite, room, pool, towel, unit, chair, lobby, experience, space, comfort, feel, <b>great, desk, front, request, hospitality, reception, manner, towel, staff.</b>
<b>Comfort</b>	facility, WiFi, cue, gym, business, internet, spa, connection, meeting, activity, sofa, therapy, feel, room, lobby, studio, sleep, broken, bed, space, elevator, lift, scary, comfort, <b>sound, furniture, room, lamp, paintwork, charged, resort, heater, temperature.</b>
<b>Cleanliness</b>	cleanliness, cleaning, smell, smoke, carpet, smoking, furniture, wall, air, swimming, conditioner, elevator, hall, air conditioning, stair, noise, neighbor, toilet, complaint, fan, ceiling, heat, <b>bathroom, clean, mold, dirty, stain, rug, fan, ceiling, floor.</b>

\***Bold** merupakan *term-term* tambahan dari hasil TF-ICF

### 3.2.4 Aspect Categorization



**Gambar 3.3** Proses dari *Aspect Categorization*.

Gambar 3.3 menjelaskan keseluruhan proses pada *aspect categorization* dengan beberapa pendekatan meliputi AC1, AC2, dan AC3. Setelah melakukan tahap *preprocessing* dan *expanded term list*, proses selanjutnya adalah melakukan kategorisasi aspek pada setiap dokumen ulasan produk. Tujuan utama dari proses ini adalah mendapatkan hasil, yaitu: kategorisasi dari setiap dokumen ulasan kedalam 5 aspek hotel (*Location, Meal, Service, Comfort, dan Cleanliness*).

Peneliti melakukan percobaan untuk mencari performa terbaik dari kategorisasi aspek yang disebut dengan *Aspect Categorization* (AC). AC1 menggunakan metode *Probabilistic Latent Semantic Analysis* (PLSA) untuk menghasilkan data *hidden topic*. Data *hidden topic* akan dikalkulasi menggunakan metode *Semantic Similarity* untuk di kategorisasikan kedalam 5 aspek hotel yang term listnya telah ditentukan dengan menggunakan Tabel 2.1 (*Keyword Term List Aspek Hotel*);  $AC2 = AC1 + TF-ICF\ 20\%$  dan  $AC3 = AC1 + TF-ICF\ 100\%$ . Hal ini selaras pada Gambar 3.3 mengenai proses dari kategorisasi aspek.

Penjelasan tentang pendekatan-pendekatan yang dilakukan dalam *Aspect Categorization* (AC) dapat dilihat dalam penjelasan berikut ini:

#### **3.2.4.1 Aspect Categorization 1 (AC1)**

Kategorisasi aspek 1 (AC1) dilakukan dengan menggunakan data “Hasil Data *Preprocessing* untuk Masukan Proses Klasifikasi” seperti pada contoh Tabel 3.4. Percobaan ini dilakukan dengan menggunakan metode PLSA untuk mencari *hidden topic*, kemudian melakukan kategorisasi lima aspek menggunakan metode *Semantic Similarity* pada Tabel 2.1. Kata bantu yang digunakan untuk melakukan *expand term* dan mengkategorisasikan setiap dokumen adalah WordNet *similarity* pada synset (*synonym set*). Penjabaran dari AC1 dapat dilihat sebagai berikut:

##### **A. Probabilistic Latent Semantic Analysis (PLSA)**

Metode pertama yang digunakan pada penelitian ini adalah *Probabilistic Latent Semantic Analysis* (PLSA). Hasil yang diperoleh dari proses ini adalah *hidden topic* dan nilai probabilitas dari dokumen yang di inputkan. Metode PLSA dipilih, karena dapat menghasilkan similaritas kata dari ulasan yang sangat panjang. Sehingga, metode PLSA dapat menangkap kata-kata yang penting atau *hidden topic*.

*Hidden topic* yang diperoleh merupakan hasil dari 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.

Python memiliki *library* bernama Scikit Learn yang dapat digunakan dalam *Machine Learning*. Pada *library* ini, terdapat algoritma *CountVectorizer* yang dapat mengubah fitur teks menjadi sebuah representasi vector. Metode PLSA menggunakan *term* frekuensi untuk membangun vektor dari setiap token kata dengan menggunakan modul *CountVectorizer*. Metode PLSA akan mengidentifikasi kata-kata yang digunakan melalui algoritma EM (*Expectation-Maximization*) pada python. *Input* dari proses ini adalah hasil dari *preprocessing*. Sedangkan *output* dari sub modul ini adalah dokumen dan *hidden topic* untuk masing-masing sub dokumen.

Contoh *input* dari Tabel 3.4 (Hasil dari Data *Preprocessing* untuk Masukan Proses Klasifikasi) dan *output* dari *hidden topic* yang telah dihitung menggunakan PLSA direpresentasikan pada Tabel 3.6.

**Tabel 3.6** Tabel Contoh *Input* dan *Output* proses PLSA

<b>Input PLSA</b>	<b>Output PLSA</b>
'clean', 'swimming', 'pool', 'manhattan'	$(0.083 * \text{"clean"} + 0.200 * \text{"swimming"} + 0.286 * \text{"pool"})$
'staff', 'unable', 'prepare', 'cue', 'pool'	$(0.286 * \text{"staff"} + 0.277 * \text{"unable"} + 0.097 * \text{"prepare"} + 0.200 * \text{"cue"} + 0.286 * \text{"pool"})$

Data pada Tabel 3.6 telah kami *expand* menggunakan WordNet untuk relasi semantik antar *synset* (*synonym set*) dalam bahasa Inggris. Data hasil *expand* kami proses dengan metode PLSA menggunakan rumus (2.3), (2.4), (2.5), dan (2.6).

#### **B. Kategorisasi Aspek Hotel menggunakan *Semantic Similarity***

Data pada Tabel 3.6 kami proses dengan metode *Semantic Similarity* menggunakan rumus (2.7). *Semantic Similarity* digunakan untuk mengukur similaritas antara *hidden topic* (yang telah ditemukan menggunakan metode PLSA) dengan *term list* pada Tabel 2.1.

*Semantic Similarity* akan mengelompokkan setiap dokumen ke dalam lima aspek hotel yang akan diteliti, yaitu *Location*, *Meal*, *Service*, *Comfort*, dan *Cleanliness*. Metode yang digunakan untuk mengelompokkan setiap dokumen akan dibantu oleh WordNet similarity. Proses *hidden topic similarity* ini merupakan tahapan terakhir pada proses pelabelan. Input dari proses ini adalah *hidden topic* yang telah dicari dengan menggunakan metode PLSA dan akan dihitung similaritasnya dengan *expanded term list* (data dari "Tabel 2.1: *Keyword Term List* Aspek Hotel") untuk melakukan kategorisasi dokumen *term list* terhadap 5 aspek hotel yang telah ditentukan.

Nilai similaritas tertinggi akan dijadikan label kelas dari dokumen tersebut. Adapun skala nilai yang dihasilkan adalah 0 dan 1. Dimana semakin mendekati nilai 1, maka *hidden topic* tersebut benar-benar mirip dan kemungkinan besar

mampu merepresentasikan *cluster* tersebut. Sebaliknya, nilai 0 merepresentasikan bahwa *hidden topic* tidak mirip dan tidak dapat merepresentasikan *cluster*.

**Tabel 3.7** Contoh Perbandingan *Hidden Topic* dan *Term List* Setiap Aspek

Aspek	Term terkait Aspek yang Diperoleh
	<p><b>(Location)</b>  railway, view, station, airport, distance, far, close, convenient, train, metro, location, place, distance, station, shuttle, cab, taxi, uber, subway, attraction, shopping, block, bus, ride, metro, mall, bus stop, downtown, park, theater, strip, district, museum, transportation, quarter, tourist interest, heart, trolley, middle, square.</p>
	<p><b>(Meal)</b>  drink, breakfast, spicy, meal, tea, buffet, bar, restaurant, dinner, lunch, brunch, delicious, food, dish, wine, salad, pizza, buffet variety, court, shop, dinner, selection, snack, fruit, cereal, egg, cheese, juice, variety, coffee, bagel, pastry, waffle, cafe, menu, item, gift, cup.</p>
<b>Pool</b>	<p><b>(Service)</b>  connection, meeting, charge, activity, sleep, bed, bedroom, pillow, sofa, suite, room, pool, towel, unit, chair, lobby, experience, space, comfort, feel.</p>
	<p><b>(Comfort)</b>  facility, WiFi, cue, gym, business, internet, spa, connection, meeting, activity, sofa, therapy, feel, room, lobby, studio, sleep, broken, bed, space, elevator, lift, scary, comfort.</p>
<b>Clean Swimming</b>	<p><b>(Cleanliness)</b>  cleanliness, cleaning, smell, smoke, carpet, smoking, furniture, wall, air, swimming, conditioner, elevator, hall, air conditioning, stair, noise, neighbor, toilet, complaint, fan, ceiling, heat.</p>

Tabel 3.7 merepresentasikan contoh perbandingan *hidden topic* dan *term list* setiap aspek menggunakan salah satu contoh ulasan pada Tabel 3.6.

**Tabel 3.8** Contoh Hasil Perhitungan *Semantic Similarity* untuk Setiap Aspek

Document Term List	Hotel Aspects				
	1. Location	2. Meal	3. Service	4. Comfort	5. Cleanliness
'clean'	0.083	0.017	0.061	0.122	<b>0.337</b>
'swimming'	0.020	0.000	0.030	0.122	<b>0.200</b>
'pool'	0.070	0.000	<b>0.286</b>	0.122	0.100
<b>Rerata</b>	0.173	0.017	0.377	0.366	<b>0.637</b>

Tabel 3.8 menunjukkan *hidden topic* yang dihasilkan oleh metode PLSA dan diklasifikasikan pada kelima aspek hotel dengan *Semantic Similarity*. Hasil rerata tertinggi adalah pada aspek *Cleanliness*, sehingga dapat disimpulkan bahwa contoh ini merupakan ulasan yang membahas mengenai kebersihan (*Cleanliness*).

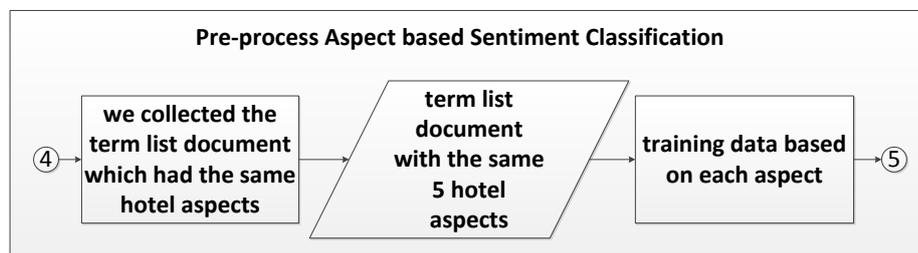
#### 3.2.4.2 Aspect Categorization 2 (AC2)

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

#### 3.2.4.3 Aspect Categorization 3 (AC3)

Penambahan *Expanded Term List* dengan menggunakan TF-ICF 20% pada pendekatan AC2 memiliki hasil yang lebih baik dibandingkan dengan hanya menggunakan Tabel 2.1 (*Keyword Term List* Aspek Hotel) pada AC1. Sehingga, pada *Aspect Categorization 3* (AC3) dilakukan dengan menghitung nilai similaritas antara *hidden topic* dengan data pada Tabel 3.5 “*Keyword Term List + Hasil TF-ICF terkait 5 Aspek*” (penambahan *Expanded Term List* menggunakan TF-ICF yang mencapai 100%). Data yang tidak terdeteksi dengan benar (*a mistake in identification*) pada AC3 akan dibuang. Sebaliknya, data yang terdeteksi benar pada AC3, akan digunakan sebagai *input* dalam proses selanjutnya, yaitu *Pre-process Aspect Based Sentiment Classification*.

### 3.2.5 Pre-process Aspect Based Sentiment Classification

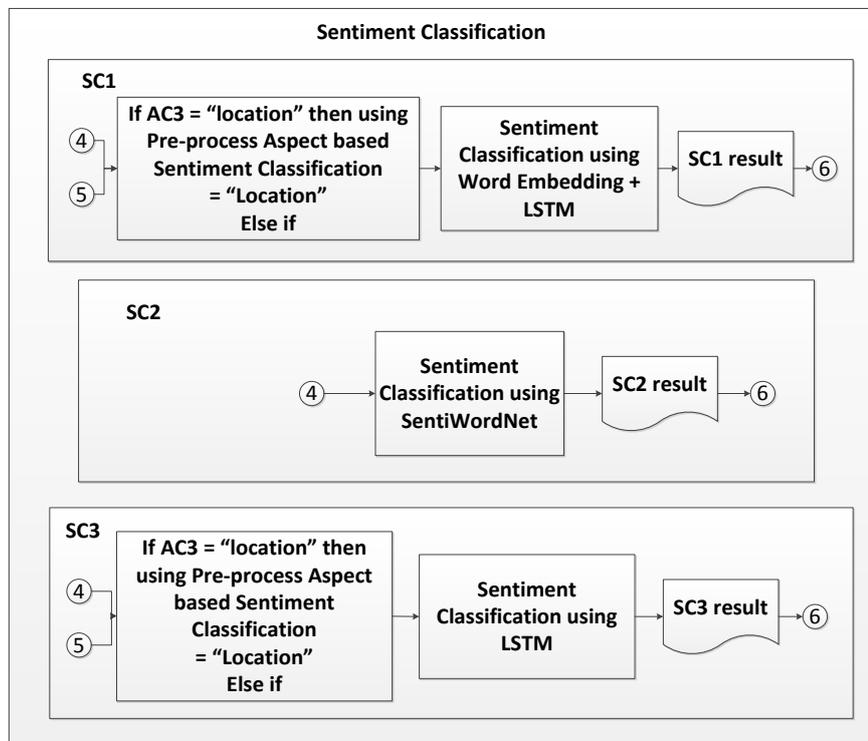


**Gambar 3.4** Proses dari *Pre-process Aspect based Sentiment Classification*.

Gambar 3.4 menjelaskan keseluruhan proses pada *pre-process aspect based sentiment classification*. Kami mengumpulkan dokumen *term list* yang memiliki aspek hotel yang sama, dari hasil AC3. Aspek hotel yang sama, akan dikelompokkan sesuai dengan kelima aspek hotel. Ilustrasinya adalah dokumen yang memiliki aspek "Location" akan dikumpulkan kedalam kumpulan aspek *location*. Dokumen *term list* yang memiliki aspek "Meal" akan dikumpulkan kedalam kumpulan aspek *meal*. Dokumen *term list* yang memiliki aspek "Service" akan dikumpulkan kedalam kumpulan aspek *service*. Dokumen *term list* yang memiliki aspek "Comfort" akan dikumpulkan kedalam kumpulan aspek *comfort*. Dokumen *term list* yang memiliki aspek "Cleanliness" akan dikumpulkan kedalam kumpulan aspek *cleanliness*.

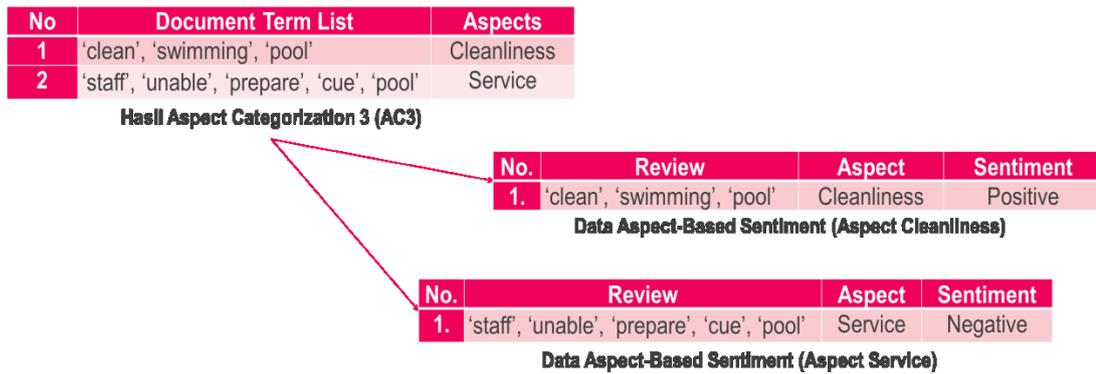
Hasil dari *pre-process aspect based sentiment classification* adalah data dokumen *term list* berdasarkan kelima aspek hotel. Kemudian, kami akan gunakan data tersebut untuk *training* dari setiap aspek hotel. Peneliti melakukan *training* untuk mendapatkan *term list* sentimen dari setiap *aspect*. *Training* data dilakukan dengan melabeli setiap data dengan *sentiment* yang diinginkan pada data tersebut. *Training* data dilakukan untuk melatih dokumen *term list*, pada setiap aspek dengan sentimen *positive* atau *negative*. Pelabelan *sentiment* untuk training dilakukan oleh *annotator*.

### 3.2.6 Sentiment Classification (SC)



**Gambar 3.5** Proses dari *Sentiment Classification* (SC).

Gambar 3.5 menjelaskan keseluruhan proses pada *Sentiment Classification* dengan tiga pendekatan meliputi SC1, SC2, dan SC3. Klasifikasi Sentimen dilakukan setelah didapatkan hasil dari kategorisasi aspek yang kemudian diolah dalam proses "3.2.5. *Pre-process aspect based sentiment classification*". Hal ini dilakukan untuk mendapatkan *training term list* pada sentimen *positive* atau *negative* dari masing-masing aspek. Sehingga, data *testing* akan diklasifikasikan dengan mengacu pada *training term list* dari aspek yang dibawanya. Apabila data *training* yang diklasifikasikan memiliki aspek *Location*, maka pada proses klasifikasi akan mengacu pada *training term list positive* atau *negative* pada aspek *Location* juga. Ilustrasi *sentiment classification* akan dijelaskan pada Gambar 3.6



**Gambar 3.6** Ilustrasi *sentiment classification* pada aspek hotel

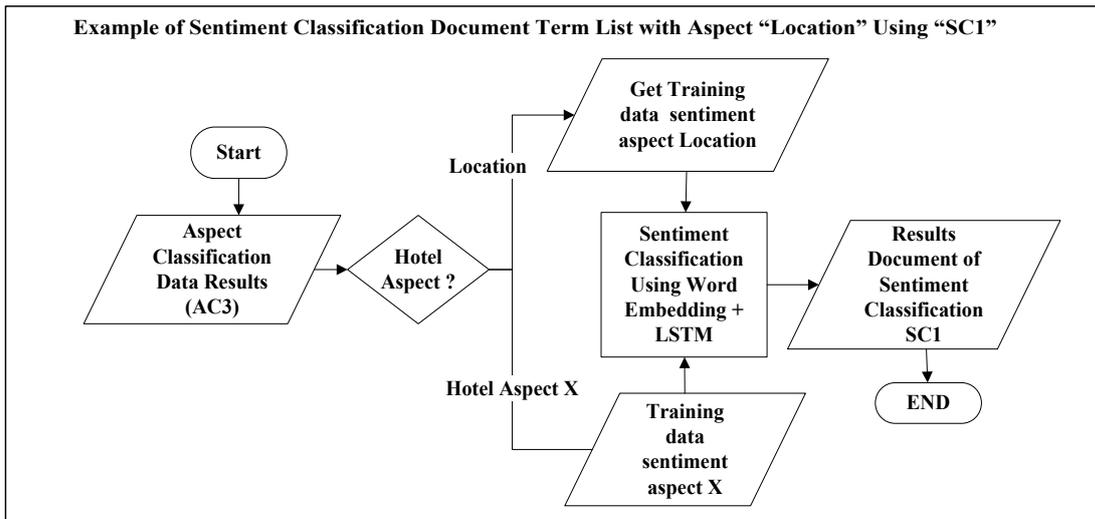
Gambar 3.6 menjelaskan secara ilustrasi, bagaimana metode bekerja dalam *sentiment classification* pada aspek hotel. Ilustrasi pada Gambar 3.6 juga menjelaskan bahwa hasil kedua ulasan tersebut masuk dalam kategori aspek “*Cleanliness*” dan “*Service*”. Kedua ulasan memiliki nilai sentimen yang berbeda. Ulasan pertama memiliki nilai sentimen *positive*, dalam aspek *cleanliness*. Ulasan kedua memiliki nilai sentimen *negative*, dalam aspek *service*.

Percobaan untuk mencari performa terbaik dari *Sentiment Classification* (SC), dilakukan dengan beberapa pendekatan yaitu SC1 yang menggunakan *Word Embedding* untuk memperoleh nilai *vector* dari setiap kata. Hasil *word embedding* pada GloVe kemudian diproses dengan menggunakan LSTM untuk mengklasifikasikan setiap dokumen *term list* pada sentimen; SC2 = SC1 namun proses klasifikasi akan menggunakan SentiWordNet; dan SC3 = SC1 hasil *word embedding* pada Word2Vec kemudian diproses dengan menggunakan LSTM untuk mengklasifikasikan setiap dokumen *term list* pada sentimen.

Hal ini seperti yang telah digambarkan pada Gambar 3.5 mengenai proses klasifikasi Sentimen. Penjabaran tentang metode yang digunakan untuk analisa sentimen dapat dijelaskan sebagai berikut:

### 3.2.6.1 *Sentiment Classification 1 (SC1)*

Untuk melakukan klasifikasi sentimen pada pendekatan SC1, peneliti melakukan detail proses sebagai berikut:

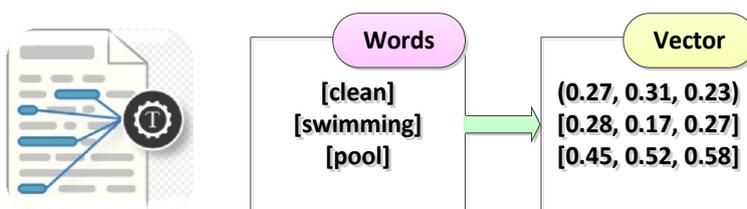


**Gambar 3.7** Contoh data Klasifikasi *Sentiment* dengan *Aspect* “Location” Menggunakan “SC1”

Untuk melakukan klasifikasi sentimen 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 aspek. Adapun *Word Embedding* yang digunakan adalah GloVe. Tensorflow digunakan untuk mengimplementasikan model *Neural Network* yang digunakan. Untuk setiap dokumen ulasan akan dilatih dengan menggunakan model *Neural Network* untuk memaksimalkan kemungkinan kondisional dari konteks kata yang diberikan. Kemudian terapkan model ke setiap kata untuk memperoleh *corresponding vector*, ilustrasinya adalah sebagai berikut:



**Gambar 3.8** Proses dari *Word Embedding*

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

### B. *Long-Short Term Memory (LSTM)*

Data yang digunakan, perlu dikonversi terlebih dahulu menjadi angka agar dapat digunakan dalam analisis sentimen. Peneliti menggunakan *word embedding* pada GloVe untuk menemukan *vector* angka dalam melakukan *expand term list* saat *training* data dan klasifikasi menggunakan rumus (2.8), (2.9) dan (2.10). Nilai vektor digunakan untuk klasifikasi sentimen dalam metode LSTM pada rumus (2.11), (2.12), (2.13), (2.14), (2.15), dan (2.16). Pada penelitian ini, dokumen diklasifikasikan dalam suatu *cluster* tertentu atau tidak. Hal ini, dikenal dengan nama *binary classification*.

*Output* dari proses ini adalah klasifikasi menggunakan teknik *binary classification* dengan data yang telah diproses menggunakan *word embedding*. Contoh hasil dari klasifikasi Sentimen menggunakan *word embedding* GloVe + LSTM dapat dilihat pada Tabel 3.9 berikut ini:

**Tabel 3.9** Contoh Hasil Klasifikasi Sentimen menggunakan *Word Embedding* + LSTM

No.	Data AC3	Aspek Hotel	Skor Sentimen	
			<i>Positive</i>	<i>Negative</i>
1	Review X	Comfort	<b>0.875</b>	0.223
2	Review Y	Meal	<b>0.984</b>	0.023

Hasil dari klasifikasi sentimen menggunakan *Word Embedding* + LSTM adalah *score* sentimen dengan angka *positive* atau *negative* seperti pada Tabel 3.9. Angka yang tertinggi akan menjadi kesimpulan dari sentimen ulasan yang dianalisa.

### 3.2.6.2 *Sentiment Classification 2 (SC2)*

Dalam penelitian ini, penulis mencoba membandingkan dua metode umum yang biasa digunakan dalam evaluasi sentimen. Salah satunya adalah dengan menggunakan metode LSTM dan menggunakan algoritma dari SentiWordNet. SentiWordNet merupakan *lexical resource* untuk menggali opini menggunakan 3 pembobotan untuk setiap kata yang bersifat *subjective* yaitu *positive*, *negative* dan *objective* (Kim, 2018) (Suhariyanto, Sarno, dan Firmanto, 2018). Peneliti menggunakan SentiWordNet pada versi 3.0 yang telah disempurnakan dan ditingkatkan lebih dari 19% dari versi lamanya (AL-Sharuee, Liu, dan Pratama, 2018). Klasifikasi sentimen dalam metode LSTM menggunakan rumus (2.11), (2.12), (2.13), (2.14), (2.15), dan (2.16), sedangkan polaritas synset dapat dihitung menggunakan rumus (2.17), (2.18) dan (2.19). Hasil dari SC2 juga akan berupa *score positive* atau *negative* seperti pada Tabel 3.9.

### 3.2.6.3 *Sentiment Classification 3 (SC3)*

*Sentiment Classification* pada SC3 sama dengan proses pada klasifikasi SC1 namun menggunakan *word embedding* pada Word2Vec untuk mendapatkan *vector* angka serta metode LSTM untuk klasifikasi sentimen. Metode pada SC3 digunakan untuk perbandingan performa dengan metode yang kami gunakan dari pendekatan SC1 dan SC2. Klasifikasi sentimen dalam metode LSTM menggunakan rumus (2.11), (2.12), (2.13), (2.14), (2.15), dan (2.16).

### 3.2.7 **Evaluasi**

Evaluasi dilakukan dengan membandingkan performa dari beberapa pendekatan yang dilakukan oleh peneliti menggunakan rumus (2.20), (2.21), dan (2.22). Berikut ini adalah langkah-langkah dalam melakukan evaluasi pada *Aspect Categorization (AC)* dan *Sentiment Classification (SC)* yaitu:

1. Pada *Aspect Categorization 1 (AC1)*, peneliti akan mengevaluasi performa dari kategorisasi aspek dengan cara menggabungkan metode PLSA menggunakan metode *Semantic Similarity* dimana *term* untuk *similarity* diambil dari Tabel 2.1 (*Keyword Term List* Aspek Hotel) Terkait Aspek yang Diperoleh.

2. Pada *Aspect Categorization 2* (AC2), menggabungkan metode PLSA + *Semantic Similarity* menggunakan *term list* pada Tabel 2.1 (*Keyword Term List* Aspek Hotel) ditambahkan dengan data dari *Expanded Term list* TF-ICF 20%.
3. Pada *Aspect Categorization 3* (AC3), menggabungkan metode PLSA + *Semantic Similarity* menggunakan *term list* pada Tabel 2.1 (*Keyword Term List* Aspek Hotel) + data dari *Expanded Term list* TF-ICF 100% (AC3).
4. Pada *Sentiment Classification 1* (SC1), peneliti akan mengevaluasi performa dari klasifikasi sentimen menggunakan *Word Embedding* pada GloVe + Metode LSTM.
5. Pada *Sentiment Classification 2* (SC2), peneliti melakukan klasifikasi sentimen menggunakan SentiWordNet.
6. Pada *Sentiment Classification 3* (SC3), peneliti melakukan klasifikasi sentimen menggunakan *Word Embedding* pada Word2Vec + metode LSTM.

Masing-masing performa akan dievaluasi menggunakan: *Precision*, *Recall* dan *F1-Measure*. Evaluasi performa menggunakan rumus (2.20), (2.21) dan (2.22).

*[Halaman ini sengaja dikosongkan]*

## **BAB 4**

### **HASIL PENELITIAN 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 implemementasi 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 setiap performa yang didapatkan, akan diambil performa terbaik untuk melanjutkan tahap akhir yaitu mendapatkan kesimpulan yang telah disampaikan dalam tujuan penelitian.

#### **4.1 Implementasi Sistem**

##### **4.1.1 Data Ulasan Produk Hotel**

Peneliti memperoleh 529 data, dari hasil *crawling* ulasan produk pada hotel Times Square, Manhattan, New York yang diambil dalam 3 tahun terakhir (2015-2018). Hal ini, dikarenakan peneliti ingin mengukur kepuasan pelanggan berdasarkan aspek ditahun 2015-2018. Data yang diambil akan digunakan sebagai data *training* dan *testing*. Peneliti menggunakan 80% data untuk *training* dan 20% untuk *testing*; yaitu 423 data *training* dan 106 data *testing*. Data ulasan hotel diambil dengan cara *crawling* menggunakan *software* WebHarvy. Data hasil *crawling* ada dalam BAB 3 pada Tabel 3.1 (hasil data *crawling* menggunakan WebHarvy) dan Tabel 3.2 (hasil *crawling* yang diberi label *Identity Document* (ID)). Data ulasan hotel akan di proses untuk pelabelan yang akan dilakukan oleh *annotator*. Dataset pada proses pelabelan ini bertugas untuk membuat *ground truth* dari setiap dokumen.

##### **4.1.2 Preprocessing Data**

Pada langkah Preprocessing, peneliti akan mengambil data yang telah di *crawling*, dalam BAB 3 pada Tabel 3.2. Teknik *preprocessing* dilakukan dengan enam tahap yaitu *Convert into Lowercase*, *Tokenisasi*, *Stemming*, *Stopwords*

*Removal*, *Remove Punctuation*, *Spelling Correction* yang di ilustrasikan dalam BAB 3 pada Tabel 3.3 menggunakan delapan contoh ulasan. Proses ini diharapkan dapat menghilangkan *noise* pada dokumen ulasan saat proses klasifikasi. Hasil preprocessing dalam BAB 3 pada Tabel 3.4 (Hasil dari Data *Preprocessing* untuk Masukan Proses Klasifikasi) akan diperjelas dengan menambahkan label *annotator*, agar lebih mudah dipahami oleh pembaca yaitu sebagai berikut:

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

<b>id_rev</b>	<b>Data <i>Preprocessing Result</i></b>	<b>Label Annotator</b>
1	'clean', 'swimming', 'pool', 'manhattan'	<i>Cleanliness</i>
2	'staff', 'unable', 'prepare', 'cue', 'pool'	<i>Service</i>
3	'receptionist', 'unfriendly', 'rude'	<i>Service</i>
4	'poor', 'breakfast'	<i>Meal</i>
5	'crowd', 'lobby', 'scary', 'corridor'	<i>Comfort</i>
6	'dont', 'deceive', 'nice', 'smell', 'lobby'	<i>Cleanliness</i>
7	'hotel', 'fab', 'locate', 'attract', 'great', 'review'	<i>Location</i>
8	'breakfast', 'great'	<i>Meal</i>

Hasil dari Tabel 4.1 ini, digunakan sebagai masukan untuk proses kategorisasi.

#### **4.1.3 Expanding Term List**

Modul ini digunakan untuk mengatasi keterbatasan dari *term* yang telah didefinisikan sebelumnya (Tabel 2.1: *Keyword Term List* Aspek Hotel). Proses ini bertugas untuk menemukan *term-term* yang merepresentasikan setiap aspek dalam dokumen. Data yang 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* menggunakan TF-ICF akan dilakukan mengikuti pseudocode dari proses TF-ICF yang telah dijelaskan dalam BAB 3 point 3.2.3 Modul Perluasan *Term List (Expanding Term List)*. Hal tersebut dijelaskan pada *pseudocode* berikut ini;

1. Ambil review produk yang telah di *preprocessing* pada modul sebelumnya.
2. Berdasarkan kelasnya masing-masing, hitung nilai dari Term Frequency (TF).
3. Hitung Inverse Cluster Frequency (ICF).
4. Hitung nilai TF-ICF menggunakan rumus (2.2). dimana  $(TF)_j$  adalah frekuensi atau total term  $i$  pada cluster  $j$  dan  $(ICF)_j$  adalah nilai icf term tersebut.
5. Untuk masing-masing kelas, analisa term-term penting sesuai nilai TF-ICF dan justifikasi yang telah didefinisikan sebelumnya.

#### 4.1.3.1 Perhitungan *Term Frequency (TF)*

*Term Frequency (TF)* merupakan frekuensi kemunculan *term (t)* pada dokumen *review* produk ( $d$ ). Proses yang pertama adalah membentuk kamus kata yang berisi kata-kata unik pada *corpus* dokumen. Proses pembentukan kamus ini, tidak memperhatikan kata henti. Kata-kata unik ini akan dihitung kemunculannya dari setiap dokumen dalam *cluster* yang sama. Oleh karena itu, masing-masing kelas memungkinkan untuk memiliki nilai term frekuensi yang berbeda. Hal ini selaras dengan ilustrasi pada Gambar 4.1 dan direpresentasikan dalam Tabel 4.2.

		TF1	TF2	TF3	TF4	TF5
idterm	tf(j,i)	location	Meal	Service	Comfort	Cleanliness
5	locate	3	0	0	0	0
Kemunculan term "locate" dalam kluster "Location" adalah 3 kali.						
Sedangkan dalam kluster lain, term tersebut tidak muncul.						

**Gambar 4.1** Ilustrasi Perhitungan *Term Frequency (TF)*

**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

Berdasarkan Tabel 4.2 TF1 menunjukkan jumlah kemunculan *term* pada *cluster* 1, TF2 menunjukkan jumlah kemunculan *term* pada *cluster* 2, TF3 menunjukkan jumlah kemunculan *term* pada *cluster* 3, TF4 menunjukkan jumlah kemunculan *term* pada *cluster* 4, dan TF5 menunjukkan jumlah kemunculan *term* pada *cluster* 5.

#### 4.1.3.2 Perhitungan *Inverse Cluster Frequency (ICF)*

Proses ini akan menghitung nilai dari ICF yang mempertimbangkan kemunculan dari setiap *term* pada *cluster* berdasarkan fungsi logaritmik (fungsi yang dikenal dalam analisis teknikal). Hal ini selaras dengan ilustrasi pada Gambar 4.2 dan contoh dari perhitungan ICF pada Tabel 4.3 menggunakan rumus (2.1).

<b>Rumus ICF:</b>							
$ICF_i = 1 + \log \frac{c}{cf_i}$		Nilai ICF pada <i>term</i> <i>i</i> dipengaruhi oleh jumlah <i>cluster</i> yang ada. dan jumlah <i>cluster</i> yang mengandung <i>term</i> <i>i</i> ( <i>cf<sub>i</sub></i> ).					
id	term	TF1	TF2	TF3	TF4	TF5	ICF
5	locate	3	0	0	0	0	16.094
term "Locate" hanya muncul dalam kluster "Location" (TF1) sebanyak 1 kali. Sehingga, memiliki nilai ICF yang cenderung tinggi dan term tersebut yang akan kita ambil.							

**Gambar 4.2** Ilustrasi perhitungan *Inverse Cluster Frequency (ICF)*

**Tabel 4.3** Contoh Hasil Perhitungan *Inverse Cluster Frequency*

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 ICF 0. Nilai ICF 0 memiliki arti bahwa *term* tersebut terus muncul di semua *cluster*. Sehingga, ketika fungsi logaritmik menghitung hasil pembagian jumlah *cluster* dengan *cluster* kemunculan *term*, maka akan menghasilkan nilai log (1), yaitu nol. ICF menunjukkan bahwa semakin sedikit *term* yang muncul di semua *cluster*, maka nilai ICF akan cenderung besar, seperti pada id 4 dan 5.

#### 4.1.3.3 Penentuan *Term Penting Tiap Cluster (TF-ICF)*

Proses pada tahap ini dimulai dengan menghitung nilai TF-ICF untuk setiap *cluster*. Selanjutnya, proses penentuan *term-term* penting dipengaruhi oleh nilai TF-ICF yang dihasilkan. Gambar 4.3 merupakan contoh perhitungan *term* penting tiap *Cluster (TF-ICF)* menggunakan rumus (2.2).

**Rumus TF-ICF:**  
 $TF - ICF_j = tf_{ji} \times ICF_i$

$tf_{ji}$  = frekuensi atau total term term i pada klust  
 $ICF_t$  = Jumlah kelas yang mengandung term t

id	term	TF1	TF2	TF3	TF4	TF5	ICF	TF-ICF1	TF-ICF2	TF-ICF3	TF-ICF4	TF-ICF5
5	locate	3	0	0	0	0	16.094	48.283	0	0	0	0

**Gambar 4.3** Ilustrasi perhitungan *term*.

Berikut ini adalah hasil perhitungan TF-ICF yang direpresentasikan dari Gambar 4.3 ke dalam Tabel 4.4 menggunakan rumus (2.2).

**Tabel 4.4** Contoh 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 = Aspek *Location*

TF-ICF2 = Aspek *Meal*

TF-ICF3 = Aspek *Service*

TF-ICF4 = Aspek *Comfort*

TF-ICF5 = Aspek *Cleanliness*

Berdasarkan Tabel 4.4 pada TF-ICF1 menunjukkan nilai suatu *term* pada *cluster* 1, TF-ICF2 menunjukkan nilai suatu *term* pada *cluster* 2, TF-ICF3 menunjukkan nilai suatu *term* pada *cluster* 3, TF-ICF4 menunjukkan nilai suatu *term* pada *cluster* 4 dan TF-ICF5 menunjukkan nilai suatu *term* pada *cluster* 5. Tabel 4.4 menjelaskan 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 (Contoh pada id 5). Semakin sering *term* muncul didalam *cluster* yang terbatas, maka semakin besar kemungkinan *term* tersebut mampu merepresentasikan *cluster*. Nilai TF-ICF tertinggi akan dijadikan sebagai penambahan *term* dalam *expanded term* yang akan digunakan pada *Semantic Similarity*.

Setiap *term* penting dalam setiap kelas yang ditemukan, akan ditambahkan pada “Tabel 2.1: *Keyword Term List* Aspek Hotel” sehingga, akan menghasilkan data pada “Tabel 3.5 *Keyword Term List* + Hasil TF-ICF terkait 5 Aspek”.

Dimana Tabel 3.5 ini merupakan Tabel 2.1 yang telah ditambahkan dengan hasil TF-ICF sebesar 100%.

#### **4.1.4 Proses Kategorisasi Aspek (AC)**

Data ulasan produk yang akan diproses merupakan data ulasan yang telah melalui tahap *preprocessing* (Tabel 4.1 Hasil *Pre-processing* untuk Masukan Proses Klasifikasi). Proses kategorisasi aspek dilakukan sesuai dengan penjelasan pada BAB 3 sub bab 3.2.4 *Aspect Categorization*. Peneliti akan membandingkan beberapa pendekatan untuk kategorisasi aspek. Hasil pendekatan yang memiliki performa terbaik, akan dipilih oleh peneliti. Berikut ini adalah beberapa pendekatan yang dilakukan oleh peneliti dalam mengukur performa dari metode yaitu: AC1 menggunakan metode *Probabilistic Latent Semantic Analysis* (PLSA) untuk menghasilkan data *hidden topic*. Data *hidden topic* akan dikalkulasi menggunakan metode *Semantic Similarity* untuk di kategorisasikan kedalam 5 aspek hotel yang term listnya telah ditentukan menggunakan Tabel 2.1 (*Keyword Term List Aspek Hotel*); AC2 = AC1 + TF-ICF 20% dan AC3 = AC1 + Tabel 3.5 (Tabel 2.1 + TF-ICF 100%). Representasi perbandingan metode dalam kategorisasi aspek akan dijelaskan pada sub bab 4.1.4.1 *Aspect Categorization 1* (AC1), 4.1.4.2 *Aspect Categorization 2* (AC2) , dan 4.1.4.2 *Aspect Categorization 3* (AC3) dibawah ini:

##### **4.1.4.1 Aspect Categorization 1 (AC1)**

Peneliti akan melakukan uji performa pada setiap pendekatan dari metode penelitian. Uji performa ini, dilakukan untuk mencari performa terbaik untuk kategorisasi lima aspek hotel. Percobaan pertama adalah AC1 yang dilakukan dengan menggunakan metode PLSA untuk mencari *hidden topic* kemudian dilakukan *Semantic Similarity* dengan menggunakan data pada Tabel 2.1 (*Keyword Term List Aspek Hotel*) untuk kategorisasi setiap dokumen. Peneliti melakukan *expand term* dan mengkategorisasikan setiap dokumen menggunakan WordNet *similarity*. Representasi dari AC1 akan dijelaskan pada poin A. *Probabilistic Latent Semantic Analysis* (PLSA) dan poin B. Kategorisasi Aspek Menggunakan *Semantic Similarity*.

### A. Probabilistic Latent Semantic Analysis (PLSA)

Proses untuk mencari *hidden topic* menggunakan metode PLSA akan dijelaskan pada BAB 3 Sub bab 3.2.4.1 *Aspect Categorization 1 (AC1)* pada poin A. *Probabilistic Latent Semantic Analysis (PLSA)*. Python memiliki *library* bernama *Scikit Learn* yang dapat digunakan dalam *Machine Learning*. Pada *library* ini, terdapat algoritma *CountVectorizer* yang dapat mengubah fitur teks menjadi sebuah representasi vektor. Metode PLSA menggunakan *term* frekuensi untuk membangun vektor dari setiap token kata dengan menggunakan modul *CountVectorizer*. Metode PLSA akan mengidentifikasi kata-kata yang digunakan melalui algoritma EM (*Expectation-Maximization*) pada python. Berikut ini adalah hasil dari *hidden topic* yang telah dihitung menggunakan PLSA pada setiap dokumen ulasan dan akan direpresentasikan dalam Tabel 4.5:

**Tabel 4.5** Hasil *Hidden Topic* dari metode PLSA

id_rev	Hidden Topic
1	(0.083 * "clean" + 0.200 * "swimming" + 0.286 * "pool")
2	(0.286 * "staff" + 0.277 * "unable" + 0.097 * "prepare" + 0.200 * "cue" + 0.286 * "pool")
3	(0.300 * "sound" + 0.600 * "bathtub" + 0.500 * "clear" + 0.100 * "easy" + 0.100 * "use" + 0.200 * "very")
4	(0.100 * "clear" + 0.200 * "air" + 0.200 * "fresh" + 0.200 * "little" + 0.400 * "might")
5	(0.500 * "clear" + 0.400 * "disappoint" + 0.300 * "poor" + 0.200 * "say" + 0.600 * "service" + 0.300 * "understand" + 0.400 * "wish")

Setelah diperoleh *hidden topic* untuk masing-masing dokumen, selanjutnya hasil dari *hidden topic* dan hasil *expanded term list* dari metode TF-ICF akan diproses untuk ke dalam perhitungan similaritas menggunakan *Semantic Similarity*. Perhitungan ini dilakukan untuk mengkategorisasikan setiap ulasan produk dalam 5 aspek (*Location, Meal, Service, Comfort, dan Cleanliness*).

## B. Kategorisasi Aspek menggunakan *Semantic Similarity*

Penggunaan *semantic similarity* merupakan proses akhir dalam kategorisasi aspek. Input dari proses ini adalah data *hidden topic* menggunakan metode PLSA. Hasil *hidden topic* dapat dilihat pada “Tabel 4.5 Hasil *Hidden Topic* dari PLSA”. Data tersebut akan dihitung menggunakan *Semantic Similarity*, dimana data untuk perhitungan similaritas didapatkan data dari Tabel 2.1 (*Keyword Term List* Aspek Hotel) untuk mengkategorikan setiap ulasan dalam 5 aspek (*Location, Meal, Service, Comfort*; dan *Cleanliness*).

Proses ini akan mengikuti alur pada proses Kategorisasi aspek Menggunakan *Semantic Similarity* yang telah dijelaskan dalam BAB 3 Sub bab 3.2.4.1. *Aspect Categorization 1 (AC1)*, poin B. Kategorisasi Aspek Menggunakan *Semantic Similarity*”. Hasil dari perhitungan kategorisasi aspek menggunakan PLSA + *Semantic Similarity* akan direpresentasikan pada Tabel 4.6 berikut:

**Tabel 4.6** Hasil Perhitungan metode PLSA + *Semantic Similarity*

Document Term List	Aspect 1	Aspect 2	Aspect 3	Aspect 4	Aspect 5	Label PLSA	Label Annotator
	Location	Meal	Service	Comfort	Cleanliness		
["Clean", "Swimming", "Pool"]	<b>0.087</b>	0.033	0.079	0.081	0.083	1	5
["Staff", "Unable", "Prepare", "Cue", "Pool"]	0.068	0.024	<b>0.089</b>	0.075	0.078	3	3
["Receptionist", "Unfriendly", "Rude"]	0.057	0.040	<b>0.084</b>	0.066	0.063	3	3
["Poor", "Breakfast"]	0.040	0.060	<b>0.067</b>	0.053	0.020	3	2

\*Warna **merah** adalah kesalahan sistem dalam melakukan kategorisasi aspek.

Pada Tabel 4.6 menunjukkan hasil perhitungan PLSA + *Semantic Similarity* dengan label *annotator* sebagai *keyword* dari jawaban yang benar. Kesalahan dalam deteksi aspek akan diberi *highlight* warna merah seperti pada ulasan “*a clean swimming pool at Manhattan*” yang terdeteksi pada aspek “*Location*” dan

ulasan “*Poor Breakfast*” yang terdeteksi pada aspek “*Service*”. Sedangkan *highlight* warna hijau adalah jawaban yang benar. Peneliti menggunakan *keyword* dari label *annotator* sebagai jawaban yang benar. Setiap ulasan akan memiliki label dari hasil kategorisasi aspek pada Tabel 4.6. Hasil dalam tahap ini akan dievaluasi untuk dihitung prosentase keberhasilan performa yang dihasilkan.

#### **4.1.4.2 Aspect Categorization 2 (AC2)**

Proses kategorisasi dalam pendekatan kedua adalah AC2. Pendekatan AC2 dilakukan menggunakan metode PLSA untuk mencari *hidden topic* kemudian dikategorisasikan menggunakan *Semantic Similarity* yang menggunakan data pada Tabel 2.1 (*Keyword Term List* Aspek Hotel) ditambah dengan *term* yang telah didapatkan menggunakan TF-ICF 20% (Tabel 4.4 Contoh Hasil Perhitungan TF-ICF) untuk mengkategorisasikan setiap ulasan.

Penambahan *Expanding Term List* (TF-ICF) adalah perbedaan dari pendekatan AC2 dan AC1, yang diharapkan dapat meningkatkan performa dalam pengukuran *similarity*. *Expanding term list* yang digunakan adalah 20% dari total *synonym*. Peneliti menggunakan WordNet *similarity* untuk melakukan *expand term* dan mengkategorisasikan setiap dokumen. Penjelasan dari AC2 akan mirip seperti dalam pendekatan AC1, yang telah dijelaskan dalam poin A. *Probabilistic Latent Semantic Analysis* (PLSA) dan poin B. Kategorisasi Aspek Menggunakan *Semantic Similarity*. Namun dalam poin B. Kategorisasi Aspek Menggunakan *Semantic Similarity*, AC2 akan ditambahkan data dari *Expanding Term List* (TF-ICF) sebesar 20%.

Hasil dari perhitungan kategorisasi aspek AC2 dengan menggunakan PLSA + *Semantic Similarity* + TF ICF 20% akan direpresentasikan pada Tabel 4.7 berikut ini:

**Tabel 4.7** Hasil Perhitungan PLSA + *Semantic Similarity* + TF ICF 20%

Document Term List	Aspect 1	Aspect 2	Aspect 3	Aspect 4	Aspect 5	Label PLSA	Label Annotator
	Location	Meal	Service	Comfort	Cleanliness		
["Clean", "Swimming", "Pool"]	0.072	0.031	0.075	<b>0.098</b>	0.096	4	5
["Staff", "Unable", "Prepare", "Cue", "Pool"]	0.065	0.020	<b>0.092</b>	0.073	0.071	3	3
["Receptionist", "Unfriendly", "Rude"]	0.053	0.020	<b>0.107</b>	0.081	0.057	3	3
["Poor", "Breakfast"]	0.030	0.062	<b>0.065</b>	0.043	0.018	3	2

\*Warna **merah** adalah kesalahan sistem dalam melakukan kategorisasi aspek.

Pada Tabel 4.7 menunjukkan bahwa penambahan TF-ICF sangat berpengaruh dalam hasil kategorisasi aspek yang dapat dilihat dari perubahan nilai dalam setiap aspek. Kesalahan dalam deteksi aspek akan diberi *highlight* warna merah seperti pada ulasan pada ulasan “*a clean swimming pool at Manhattan*” yang terdeteksi pada aspek “*Comfort*” dan ulasan “*Poor Breakfast*” yang terdeteksi pada aspek “*Service*”. Sedangkan *highlight* warna hijau adalah jawaban yang benar. Peneliti menggunakan *keyword* dari label *annotator* sebagai jawaban yang benar. Setelah melakukan kategorisasi dengan menggunakan tahapan pada AC2, hasil kemudian akan dievaluasi untuk diketahui prosentase keberhasilan performa yang dihasilkan.

#### 4.1.4.3 Aspect Categorization 3 (AC3)

Proses kategorisasi dalam pendekatan ketiga adalah AC3. Pendekatan AC3 dilakukan dengan menggunakan metode PLSA untuk mencari *hidden topic* kemudian dilakukan kategorisasi aspek menggunakan *Semantic Similarity* yang menggunakan data pada Tabel 2.1 (*Keyword Term List* Aspek Hotel) ditambah dengan *term* yang telah didapatkan dalam TF-ICF (Tabel 4.4 Contoh Hasil Perhitungan TF-ICF) 100%. Hasil dari perhitungan kategorisasi aspek AC3 menggunakan PLSA + *Semantic Similarity* pada data penelitian akan direpresentasikan pada Tabel 4.8 berikut ini:

**Tabel 4.8** Hasil Perhitungan PLSA + *Semantic Similarity* + TF ICF 100%

Document Term List	Aspect 1	Aspect 2	Aspect 3	Aspect 4	Aspect 5	Label PLSA	Label Annotator
	Location	Meal	Service	Comfort	Cleanliness		
["Clean", "Swimming", "Pool"]	0.173	0.027	0.377	0.366	<b>0.637</b>	5	5
["Staff", "Unable", "Prepare", "Cue", "Pool"]	0.082	0.025	<b>0.956</b>	0.342	0.117	3	3
["Receptionist", "Unfriendly", "Rude"]	0.126	0.014	<b>0.942</b>	0.252	0.014	3	3
["Poor", "Breakfast"]	0.009	0.372	<b>0.373</b>	0.142	0.020	3	2

\*Warna **merah** adalah kesalahan sistem dalam melakukan kategorisasi aspek.

#### 4.1.5 Pre-Process Aspect based Sentiment Classification

Sebelum masuk dalam tahap *Sentiment Classification* (SC), hasil yang didapatkan dari tahap *Aspect Categorization* 3 (AC3) pada Tabel 4.8 dikumpulkan terlebih dahulu berdasarkan kategori aspek yang sama. Setiap data yang memiliki kesalahan dalam proses kategorisasi lima aspek akan dibuang. Sehingga, dari data awal *review* produk sebesar 529 akan berubah menjadi 449 data. Hal ini, dikarenakan data tersebut sudah tidak akan efektif lagi untuk diproses lebih lanjut. Sehingga pada proses ini, data yang akan diproses adalah sebagai berikut:

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

id_rev	Document Term List	Aspects
1	'clean', 'swimming', 'pool'	Cleanliness
2	'staff', 'unable', 'prepare', 'cue', 'pool'	Service

Pre-Proses untuk klasifikasi sentimen berdasarkan aspek, bertujuan untuk melatih data *training* dari setiap kategorisasi aspek pada sentimen *positive* dan *negative*. Sehingga setelah proses ini, diharapkan *term list sentiment* dari setiap aspek akan dihasilkan. Proses pelabelan pada data *training* untuk klasifikasi sentimen dilakukan oleh *annotator*. Data pada Tabel 4.9 akan dibagi dan

diberikan label sentimen seperti pada Tabel 4.10 dan Tabel 4.11 untuk pre-proses dalam klasifikasi sentimen berdasarkan aspek:

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

id_rev	Document Term List	Aspects	Sentiment
1	'clean', 'swimming', 'pool'	Cleanliness	Positive

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

id_rev	Document Term List	Aspects	Sentiment
1	'staff', 'unable', 'prepare', 'cue', 'pool'	Service	Negative

#### 4.1.6 Proses *Sentiment Classification* (SC)

Klasifikasi sentimen dilakukan untuk mengklasifikasikan setiap ulasan pada sentimen kepuasan pelanggan terhadap layanan dan jasa yang diberikan oleh hotel. Data yang digunakan untuk melakukan klasifikasi sentimen adalah data dari tahap *Aspect Categorization* (AC) yang memiliki performa terbaik yaitu dokumen *term list* AC3. Data dari *Aspect Categorization* dengan performa terbaik (AC3) akan digunakan untuk tahap pre-proses klasifikasi sentimen berdasarkan aspek yang dapat dilihat pada poin 4.1.5 *Pre-Process Aspect based Sentiment Classification*. Contoh dari hasil data dapat dilihat dalam Tabel 4.8 dan 4.9. Data pada Tabel 4.8 dan Tabel 4.9 akan dipisahkan menjadi 80% untuk proses *Training* dan 20% untuk proses *Testing*.

Proses dalam klasifikasi sentimen akan dilakukan sesuai dengan penjelasan pada poin "3.2.6 *Sentiment Classification*". Proses ini akan membandingkan beberapa pendekatan metode dalam klasifikasi sentimen dengan: SC1 yang akan menggunakan *Word Embedding* pada GloVe + LSTM untuk mengklasifikasikan setiap dokumen *term list* pada sentimen; SC2 = SC1 namun proses klasifikasi akan menggunakan SentiWordNet; dan SC3 = SC1 klasifikasi yang akan menggunakan *Word Embedding* pada Word2Vec + LSTM untuk mengklasifikasikan setiap dokumen *term list* pada sentimen.

Penjelasan mengenai pendekatan dari beberapa metode klasifikasi sentimen akan dijelaskan pada sub bab 4.1.6.1 *Sentiment Classification 1 (SC1)*, 4.1.6.2 *Sentiment Classification 2 (SC2)*, dan 4.1.6.3 *Sentiment Classification 3 (SC3)*. *Sentiment Classification 3 (SC3)* dibawah ini:

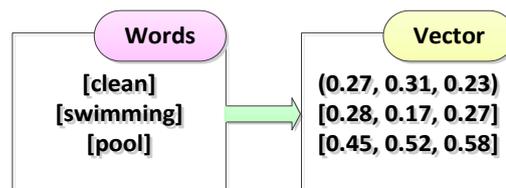
#### 4.1.6.1 *Sentiment Classification 1 (SC1)*

Pada *Sentiment Classification 1 (SC1)*, data diproses menggunakan *Word Embedding* untuk memperoleh representasi vector dari kata-kata pada setiap dokumen *term list*. Karena metode LSTM hanya akan memproses data yang berupa angka. Penelitian ini menggunakan GloVe sebagai *Word Embedding*. GloVe dipilih karena merupakan model dari *Word Embedding* yang telah terlatih. GloVe dalam penelitian ini digunakan untuk melakukan *expand term list* saat *training* data dan saat klasifikasi.

Setelah memperoleh vektor yang digunakan sebagai nilai fitur dalam proses klasifikasi, selanjutnya LSTM digunakan sebagai metode klasifikasi. Pada penelitian ini, setiap dokumen *term list* akan diklasifikasikan kedalam *cluster* puas (*positive*) dan *cluster* tidak puas (*negative*). Proses klasifikasi dengan menggunakan data yang didapatkan dari *Word Embedding* di kenal sebagai *binary classification*.

##### A. *Word Embedding*

Metode *Word embedding* yang digunakan peneliti adalah GloVe. Ilustrasi *Word embedding* yang berada pada BAB 3 sub bab 3.2.6.1 *Sentiment Classification 1 (SC1)* poin A. *Word Embedding (Word + Topic Vector Learning)*. Ilustrasi hasil akan digambarkan pada Gambar 4.4 GloVe dalam penelitian ini digunakan untuk melakukan *expand term list* saat *training* data dan saat klasifikasi.



**Gambar 4.4** Ilustrasi Penerapan Model ke Setiap Kata dalam *Corresponding Vector*

Pada metode LSTM, terdapat pustaka thesaurus untuk mengimplementasikan model dari *Neural Networks* dalam bahasa Inggris. Penelitian ini menggunakan fungsional *Application Programming Interface* (API) pada Keras, untuk menentukan model yang lebih kompleks. Keras adalah *library* dalam *Neural Networks*, yang dapat berjalan pada TensorFlow dengan bahasa pemrograman Python. Sehingga, dalam melakukan proses pencarian *vector* kata, *Word embedding* menggunakan GloVe pada bantuan TensorFlow untuk menyelesaikan permasalahan di sektor *Neural Networks*. Hasil *Word Embedding* yang berupa *Sentence Vector* akan menjadi masukan untuk proses klasifikasi sentimen menggunakan metode LSTM.

### B. *Long-Short Term Memory* (LSTM)

Klasifikasi sentimen menggunakan LSTM telah dijelaskan dalam BAB 3 sub bab 3.2.6.1 *Sentiment Classification 1* (SC1) poin B. *Long-short Term Memory* (LSTM). Hasil yang didapatkan dari proses klasifikasi dapat dilihat pada Tabel 4.12 berikut ini:

**Tabel 4.12** Hasil Klasifikasi Sentimen Menggunakan *Word Embedding* + LSTM

id_rev	Document Term List (direpresentasikan dalam bentuk angka Vector)	Aspect (Hasil AC3)	Hasil Analisa Sentimen	
			Positive	Negative
1	'clean', 'swimming', 'pool', 'manhattan'	<i>Cleanliness</i>	0.673	0.437
2	'staff', 'unable', 'prepare', 'cue', 'pool'	<i>Service</i>	0.319	0.824
3	'receptionist', 'unfriendly', 'rude'	<i>Service</i>	0.244	0.717
4	'poor', 'breakfast'	<i>Meal</i>	0.449	0.539

Proses klasifikasi yang terlihat pada Tabel 4.12 dilakukan dengan menggunakan bantuan *library* TensorFlow dan Keras. Hasil nilai *sentence vector* dari *word embedding* pada GloVe, akan diklasifikasikan menggunakan metode LSTM untuk menghasilkan analisa sentimen yang *positive* atau *negative*.

#### 4.1.6.2 Sentiment Classification 2 (SC2)

Pada proses *Sentiment Classification 2* (SC2) dilakukan perhitungan dengan mengambil nilai *positive* dan *negative* pada kata yang dianalisa. Dimana skor nilai akan didapatkan dari *dictionary* SentiWordNet untuk mencari sentimen setiap ulasan yang dianalisa. Proses klasifikasi dengan menggunakan SentiWordNet telah dijelaskan pada BAB 3 sub bab 3.2.6.2 *Sentiment Classification 2* (SC2). Hasil dari proses klasifikasi sentimen menggunakan SentiWordNet akan ditampilkan pada Tabel 4.13 berikut ini:

**Tabel 4.13** Tabel Hasil Klasifikasi Sentimen Menggunakan SentiWordNet

Id rev	Doc Term List	Words	PosScore	NegScore	Label Sentiment	Label Sebenarnya
1	'clean', 'swimming', 'pool'	Clean	0.5	0	Positive	Positive
		Swimming	0	0		
	Aspect (Hasil AC3) : <b>Cleanliness</b>	Pool	0	0		
	<b>Total</b>	<b>0.17</b>	0			
2	'staff', 'unable', 'prepare', 'cue', 'pool'	Staff	0	0	Negative	Negative
		Unable	0	0.75		
		Prepare	0	0		
	Aspect (Hasil AC3) : <b>Service</b>	Cue	0	0		
		pool	0	0		
<b>Total</b>	<b>0</b>	<b>0.25</b>				
3	'receptionist', 'unfriendly', 'rude'	Reception	0	0	Negative	Negative
		Unfriendly	0	0.75		
	Aspect (Hasil AC3) : <b>Service</b>	rude	0	0.625		
	<b>Total</b>	<b>0</b>	<b>0.125</b>			
4	"Sound", "Bathtub", "Clear", "Easy", "Use"	Sound	0	0.125	Negative	Positive
		bathub	0	0		
		clear	0.125	0.625		
		easy	0.125	0		
	Aspect (Hasil AC3) : <b>Comfort</b>	use	0	0.125		
	<b>Total</b>	<b>0.05</b>	<b>0.175</b>			

Tabel 4.13 adalah contoh dari penggunaan *dictionary* SentiWordNet versi 3.0. Kesalahan dalam klasifikasi sentimen adalah hasil yang diberi warna **merah**.

Hal ini terjadi karena SentiWordNet hanya menganalisa kata sifat dan telah memiliki 3 penilaian secara *default* oleh *dictionary* (*positive*, *negative* dan *objective*). Sedangkan *Word Embedding* + LSTM mampu menganalisa sentimen 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* + LSTM untuk klasifikasi sentimen akan memiliki performa yang lebih tinggi dibandingkan SentiWordNet.

#### 4.1.6.3 Sentiment Classification 3 (SC3)

Pada proses *Sentiment Classification 3* (SC3), klasifikasi sentimen dilakukan menggunakan *word embedding* pada Word2Vec + LSTM untuk mengklasifikasikan setiap dokumen *term list* pada sentimen. Hasil dari Klasifikasi Sentimen pada SC3 ini akan mirip dengan hasil klasifikasi pada pendekatan SC1. Hasil dari proses klasifikasi menggunakan LSTM akan mirip dengan hasil dari *Word Embedding* + LSTM. Hasil akan ditampilkan pada Tabel 4.14 berikut ini:

**Tabel 4.14** Hasil Klasifikasi Sentimen Menggunakan metode LSTM

Doc Term List	Similarity		LSTM	Label Annotator
	1	0		
	(+)	(-)		
'clean', 'swimming', 'pool', 'manhattan'	<b>0.516</b>	0.330	1	1
'staff', 'unable', 'prepare', 'cue', 'pool'	0.216	<b>0.719</b>	0	0
'receptionist', 'unfriendly', 'rude'	0.146	<b>0.616</b>	0	0
'poor', 'breakfast'	0.337	<b>0.477</b>	0	0
'crowd', 'lobby', 'scary', 'corridor'	0.224	<b>0.577</b>	0	0
'dont', 'deceive', 'nice', 'smell', 'lobby'	0.318	<b>0.386</b>	0	0
'hotel', 'fab', 'locate', 'attract', 'great', 'review'	<b>0.723</b>	0.125	1	1
'breakfast', 'great'	<b>0.729</b>	0.042	1	1

Tabel 4.14 adalah hasil klasifikasi sentimen menggunakan metode LSTM. Hasil skor dalam Tabel 4.14 menunjukkan adanya perbedaan secara signifikan dalam angka yang diperoleh dengan pendekatan SC1 dan SC2.

## 4.2 Hasil Pengujian dan Evaluasi

Penulis telah menyebutkan pada BAB 3 mengenai evaluasi yang akan dilakukan untuk melakukan evaluasi hasil pada sub bab 3.2.7 Evaluasi. Evaluasi akan dilakukan untuk mencari performa terbaik dari *Aspect Categorization* (AC) dan *Sentiment Classification* (SC) dengan metode yang digunakan. Masing-masing performa terdiri dari beberapa pendekatan dan akan dievaluasi menggunakan *confusion matrix*: *Precision*, *Recall* dan *F1-Measure* menggunakan rumus (2.20), (2.21), dan (2.22). Peneliti hanya menggunakan performa terbaik dari metode kategorisasi aspek maupun klasifikasi sentimen untuk mengukur sentimen pelanggan berdasarkan aspek pada ulasan hotel di Traveloka.

### 4.2.1. Pendekatan Evaluasi untuk Kategorisasi Aspek (AC)

Berdasarkan 529 data ulasan pelanggan yang telah di *crawling* dan diproses melalui *preprocessing*, maka langkah selanjutnya adalah melakukan percobaan untuk mencari performa terbaik dalam kategorisasi aspek dari metode yang digunakan. Metode untuk kategorisasi aspek terdiri dari metode untuk mencari *hidden topic*, perluasan *term list* serta kategorisasi menggunakan metode *Semantic Similarity*. Peneliti akan menghitung setiap performa uji cobanya dengan *Precision*, *Recall* dan *F1-Measure* menggunakan rumus (2.20), (2.21), dan (2.22). Kemudian, performa terbaik akan di jadikan kesimpulan dalam penelitian ini. Untuk menghitung performa dari setiap metode, peneliti menggunakan 3 pendekatan pengujian dalam kategorisasi aspek yang akan di jelaskan dalam Tabel 4.15 berikut ini:

**Tabel 4.15** Pendekatan untuk Kategorisasi Aspek

<b>Aspect Categorization (AC)</b>	<b>Langkah dalam Kategorisasi Aspek</b>
<b>Pendekatan AC1</b>	Melakukan evaluasi dengan menggunakan data hasil <i>crawling</i> yang sudah melalui tahap <i>pre-processing</i> (Tabel 4.1 Hasil <i>Pre-processing</i> untuk Masukan Proses Klasifikasi) data tersebut diolah menggunakan metode <i>Probabilistic Latent Semantic Analysis</i> (PLSA) untuk menghasilkan <i>hidden topic</i> . Kemudian metode <i>Semantic Similarity</i> akan menghitung kemiripan dokumen <i>term</i>

Aspect Categorization (AC)	Langkah dalam Kategorisasi Aspek
	<i>list</i> (Tabel 4.5 Hasil <i>Hidden Topic</i> dari metode PLSA), terhadap data aspek yang tampilkan dalam Tabel 2.1 ( <i>Keyword Term List</i> Aspek Hotel) untuk dikategorisasikan setiap ulasan kedalam 5 aspek hotel yang telah ditemukan. Proses kategorisasi dapat dilihat pada tahap poin “B. Kategorisasi Aspek Menggunakan Semantic Similarity”.
Pendekatan AC2	Pendekatan AC1 + <i>Expanding term list</i> yang dihasilkan dari tahap perluasan <i>term list</i> ( <b>Term Frequency-Inverse Cluster Frequency (TF-ICF)</b> yang dijelaskan pada “Tabel 4.4 Contoh Hasil Perhitungan TF-ICF” sebanyak 20% dari total <i>synonym</i> . Penambahan dilakukan pada saat proses perhitungan <i>Semantic Similarity</i> untuk mengkategorisasikan setiap ulasan dalam 5 aspek hotel yang telah ditentukan. Data TF-ICF 20% akan ditambahkan pada data aspek dalam Tabel 2.1.
Pendekatan AC3	Pendekatan AC1 + <i>Expanding term list</i> yang dihasilkan dari perhitungan modul perluasan <i>term list</i> ( <b>Term Frequency-Inverse Cluster Frequency (TF-ICF)</b> yang dijelaskan dalam “Tabel 4.4 Contoh Hasil Perhitungan TF-ICF” sebanyak 100% dari total <i>synonym</i> .

Tabel 4.15 menjelaskan tentang pendekatan-pendekatan yang dilakukan oleh peneliti dalam evaluasi performa metode dari kategorisasi lima aspek. Hasil kinerja AC1, AC2 dan AC3 pada *aspect categorization performance evaluation* kami tampilkan dalam Tabel 4.22.

Evaluasi dari kategorisasi aspek Tabel 4.22 dan Gambar 4.5 ditinjau dari *confusion matrix* (*Precision, Recall, F1-Measure*) menggunakan rumus (2.20), (2.21), dan (2.22). Berikut ini adalah *confusion matrix* pada AC1, AC2 dan AC3 menggunakan 529 data yang akan ditampilkan pada Tabel 4.16 - 4.21 berikut ini;

Tabel 4.16 *Confusion Matrix* Kategorisasi Aspek 1 (AC1)

<b>Confusion Matrix AC1</b>						
<b>Predicted Value</b>		<b>Actual Value</b>				
		<b>Location</b>	<b>Meal</b>	<b>Service</b>	<b>Comfort</b>	<b>Cleanliness</b>
	<b>Location</b>	77	0	14	2	10
	<b>Meal</b>	0	9	3	8	1
	<b>Service</b>	4	1	172	7	5
	<b>Comfort</b>	2	9	25	94	0
	<b>Cleanliness</b>	0	5	3	1	77

**Keterangan:**

\**True Positive* (TP) = Warna Orange

\**False Positive* (FP) = Arah Vertikal ( ↓ )

\**False Negative* (FN) = Arah Horizontal ( → )

Tabel 4.17 Evaluasi Kelima Aspek Hotel pada AC1

<b>Aspect Categorization 1 (AC1)</b>		
<b>Aspek Hotel</b>	<b>Evaluasi</b>	<b>Hasil Evaluasi Aspek</b>
<b>Location</b>	<i>Precision</i>	0,928
	<i>Recall</i>	0,748
	<i>F1-Measure</i>	0,828
<b>Meal</b>	<i>Precision</i>	0,375
	<i>Recall</i>	0,429
	<i>F1-Measure</i>	0,400
<b>Service</b>	<i>Precision</i>	0,793
	<i>Recall</i>	0,910
	<i>F1-Measure</i>	0,847
<b>Comfort</b>	<i>Precision</i>	0,839
	<i>Recall</i>	0,723
	<i>F1-Measure</i>	0,777
<b>Cleanliness</b>	<i>Precision</i>	0,828
	<i>Recall</i>	0,895
	<i>F1-Measure</i>	0,860

**Hasil Evaluasi Keseluruhan pada AC1 :**

*Precision* = 0,753 = 0,75

*Recall* = 0,741 = 0,74

*F1 - Measure* = 0,742 = **74%**

Tabel 4.18 *Confusion Matrix* Kategorisasi Aspek 2 (AC2)

<b>Confusion Matrix AC2</b>						
<b>Predicted Value</b>		<b>Actual Value</b>				
		<b>Location</b>	<b>Meal</b>	<b>Service</b>	<b>Comfort</b>	<b>Cleanliness</b>
	<b>Location</b>	88	2	0	2	0
	<b>Meal</b>	0	9	3	9	0
	<b>Service</b>	3	0	179	7	3
	<b>Comfort</b>	4	9	15	93	5
	<b>Cleanliness</b>	0	5	3	2	88

**Keterangan:**

\**True Positive* (TP) = Warna Orange

\**False Positive* (FP) = Arah Vertikal ( $\downarrow$ )

\**False Negative* (FN) = Arah Horizontal ( $\rightarrow$ )

Tabel 4.19 Evaluasi Kelima Aspek Hotel pada AC2

<b>Aspect Categorization 2 (AC2)</b>		
<b>Aspek Hotel</b>	<b>Evaluasi</b>	<b>Hasil Evaluasi Aspek</b>
<b>Location</b>	<i>Precision</i>	0,926
	<i>Recall</i>	0,957
	<i>F1-Measure</i>	0,941
<b>Meal</b>	<i>Precision</i>	0,360
	<i>Recall</i>	0,429
	<i>F1-Measure</i>	0,391
<b>Service</b>	<i>Precision</i>	0,895
	<i>Recall</i>	0,932
	<i>F1-Measure</i>	0,913
<b>Comfort</b>	<i>Precision</i>	0,823
	<i>Recall</i>	0,738
	<i>F1-Measure</i>	0,778
<b>Cleanliness</b>	<i>Precision</i>	0,917
	<i>Recall</i>	0,898
	<i>F1-Measure</i>	0,907

**Hasil Evaluasi Keseluruhan pada AC2 :**

$$Precision = 0,784 = 0,78$$

$$Recall = 0,791 = 0,79$$

$$F1 - Measure = 0,786 = 79\%$$

Tabel 4.20 *Confusion Matrix* Kategorisasi Aspek 3 (AC3)

<b>Confusion Matrix AC3</b>						
<b>Predicted Value</b>		<b>Actual Value</b>				
		<b>Location</b>	<b>Meal</b>	<b>Service</b>	<b>Comfort</b>	<b>Cleanliness</b>
	<b>Location</b>	88	2	0	2	0
	<b>Meal</b>	0	8	3	3	0
	<b>Service</b>	3	0	202	6	4
	<b>Comfort</b>	6	0	16	89	5
	<b>Cleanliness</b>	0	2	3	2	85

**Keterangan:**

\**True Positive* (TP) = Warna Orange

\**False Positive* (FP) = Arah Vertikal ( ↓ )

\**False Negative* (FN) = Arah Horizontal ( → )

Tabel 4.21 Evaluasi Kelima Aspek Hotel pada AC3

<b>Aspect Categorization 3 (AC3)</b>		
<b>Aspek Hotel</b>	<b>Evaluasi</b>	<b>Hasil Evaluasi Aspek</b>
<b>Location</b>	<i>Precision</i>	0,907
	<i>Recall</i>	0,957
	<i>F1-Measure</i>	0,931
<b>Meal</b>	<i>Precision</i>	0,667
	<i>Recall</i>	0,571
	<i>F1-Measure</i>	0,615
<b>Service</b>	<i>Precision</i>	0,902
	<i>Recall</i>	0,940
	<i>F1-Measure</i>	0,920
<b>Comfort</b>	<i>Precision</i>	0,873
	<i>Recall</i>	0,767
	<i>F1-Measure</i>	0,817
<b>Cleanliness</b>	<i>Precision</i>	0,904
	<i>Recall</i>	0,924
	<i>F1-Measure</i>	0,914

**Hasil Evaluasi Keseluruhan pada AC3 :**

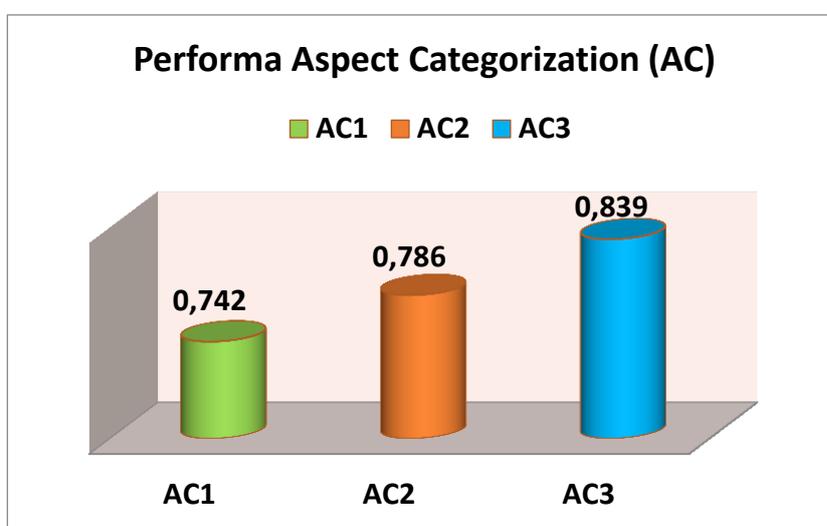
*Precision* = 0,850 = 0,85

*Recall* = 0,832 = 0,83

*F1 – Measure* = 0,839 = **84%**

Tabel 4.22 Evaluasi Kinerja *Aspect Categorization Performance Evaluation*

ASPECT CATEGORIZATION PERFORMANCE		
Aspect Categorization (AC)	Evaluation	F1-Measure
Pendekatan AC1	PLSA + Semantic Similarity	0.742
Pendekatan AC2	PLSA + TF ICF 20% + Semantic Similarity	0.786
Pendekatan AC3	PLSA + TF ICF 100% + Semantic Similarity	<b>0.839</b>



Gambar 4.5 Performa metode dari *Aspect Categorization (AC)*

Tabel 4.22 dan Gambar 4.5 adalah hasil evaluasi dari keseluruhan kategorisasi aspek menggunakan beberapa pendekatan metode yang dirangkum menjadi satu sebagai perbandingan. Pendekatan AC1 (PLSA + *Semantic Similarity*) mendapatkan nilai paling rendah yaitu 0.742, dari pendekatan AC2 dan AC3. Sehingga, pendekatan AC1 dianggap kurang efektif dalam proses kategorisasi lima aspek. Pendekatan AC2 (PLSA + TF ICF 20% + *Semantic Similarity*) mendapatkan nilai lebih tinggi yaitu 0.786 dari pendekatan AC1, namun memiliki nilai yang lebih rendah dari pendekatan AC3. Perolehan nilai yang semakin baik, membuat peneliti menambahkan keseluruhan TF-ICF sebesar 100% agar performa metode menjadi lebih maksimal dari sebelumnya. Pendekatan AC3 (PLSA + TF ICF 100% + *Semantic Similarity*) mendapatkan nilai tertinggi dari pendekatan AC1 dan AC2 yaitu 0.839. Semakin efektif

pendekatan yang digunakan, maka metode tersebut dianggap mampu menangkap 5 aspek hotel yang dapat mempengaruhi penilaian pelanggan terhadap kualitas hotel. Hasil tertinggi juga mengindikasikan bahwa *term list* yang digunakan sangat deskriptif dan memiliki ekstraksi aspek yang lebih baik daripada pendekatan yang lain. Hasil performa pendekatan terbaik, akan digunakan sebagai *input* awal dalam tahap selanjutnya yaitu klasifikasi sentimen.

#### 4.2.2. Pendekatan Evaluasi untuk Klasifikasi Sentimen (SC)

Dokumen *term list* yang dikumpulkan pada setiap aspek, akan diklasifikasikan menggunakan sentimen. Klasifikasi sentimen menggunakan dua parameter yaitu *positive* dan *negative*. Jika ada kata *adjective* (Adj.) yang memiliki nilai sentimen “netral” maka anatator mengklasifikasikan menjadi *positive* atau *negative*, tergantung dari setiap *sentence*. Sistem akan belajar secara otomatis, dari data *training* yang diberi label oleh anatator. Hal ini dikarenakan kami ingin mempertegas hasil menjadi “puas” atau “tidak puas”.

**Tabel 4.23** Pendekatan untuk Klasifikasi Sentimen

Sentiment Classification (SC)	Langkah dalam Klasifikasi Sentimen
<b>Pendekatan SC1</b>	Menggunakan data hasil kategorisasi aspek dari pendekatan AC3. Selanjutnya, melalui tahap “4.1.5 <i>Pre-Process Aspect based Sentiment Classification</i> ”. Setelah itu peneliti melakukan <i>training</i> dan <i>testing</i> pada dokumen <i>term list</i> berdasarkan aspek. <i>Training</i> ini bertujuan untuk melatih data klasifikasi sentimen terhadap aspek. Data akan diklasifikasi menggunakan metode <i>Word Embedding + LSTM</i> . Hasil dari pendekatan Klasifikasi Sentimen (SC1) dapat dilihat pada “Tabel 4.12 Hasil Klasifikasi Sentimen Menggunakan <i>Word Embedding + LSTM</i> ”. Hasil klasifikasi adalah sentimen berdasarkan aspek hotel.
<b>Pendekatan SC2</b>	Seperti dalam pendekatan SC1, namun proses klasifikasi sentimen menggunakan SentiWordNet. Hasil dari pendekatan ini dapat dilihat pada “Tabel 4.13 Hasil

Sentiment Classification (SC)	Langkah dalam Klasifikasi Sentimen
	Klasifikasi Sentimen Menggunakan <i>Dictionary SentiWordNet</i> ". Hasil klasifikasi adalah sentimen berdasarkan aspek hotel.
<b>Pendekatan SC3</b>	Seperti dalam pendekatan SC1, namun proses klasifikasi sentimen menggunakan metode LSTM. Peneliti merepresentasikan kata dalam bentuk angka vektor menggunakan Word2Vec. Hasil dari pendekatan ini ditampilkan dalam "Tabel 4.14 Hasil Klasifikasi Sentimen Menggunakan metode LSTM". Hasil klasifikasi adalah sentimen berdasarkan aspek hotel.

Tabel 4.23 menjelaskan 3 pendekatan metode yang dilakukan oleh peneliti dalam Klasifikasi Sentimen (SC). Klasifikasi sentimen menggunakan data dari AC3 (di pilih berdasarkan kategorisasi aspek terbaik) sebesar 447 data dengan 80% *training* (358 data) dan 20% *testing* (89 data). Berikut ini adalah *confusion matrix* dari 3 pendekatan SC1, SC2, dan SC3 yang direpresentasikan pada Tabel 4.24, Tabel 4.25 dan Tabel 4.26 yang ditinjau dari (*Precision*, *Recall*, *F1-Measure*) menggunakan rumus (2.20), (2.21), dan (2.22).

**Tabel 4.24** *Confusion Matrix SC1*

Prediction	Actual		
	<i>Confusion Matrix SC1</i>		
		TP	FP
	TP	79	6
FN	4	0	

**Hasil perhitungan Evaluasi SC1 :**

$$Precision = 0,929 = 0,93$$

$$Recall = 0,952 = 0,95$$

$$F1 - Measure = 0.940 = \mathbf{94\%}$$

Tabel 4.25 *Confusion Matrix SC2*

Prediction	Actual		
	<i>Confusion Matrix SC2</i>		
		TP	FP
	TP	45	21
FN	20	3	

Hasil perhitungan Evaluasi SC2 :

$$Precision = 0,682 = 0,68$$

$$Recall = 0,692 = 0,69$$

$$F1 - Measure = 0.687 = \mathbf{69\%}$$

Tabel 4.26 *Confusion Matrix SC3*

Prediction	Actual		
	<i>Confusion Matrix SC3</i>		
		TP	FP
	TP	67	12
FN	8	2	

Hasil perhitungan Evaluasi SC3 :

$$Precision = 0,848 = 0,85$$

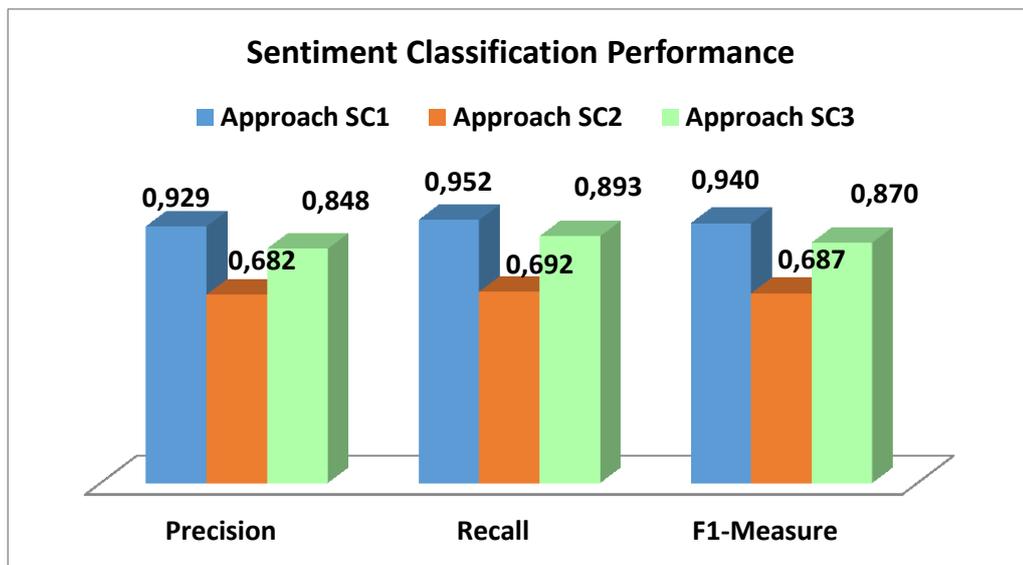
$$Recall = 0,893 = 0,89$$

$$F1 - Measure = 0.870 = \mathbf{87\%}$$

*Confusion matrix* yang direpresentasikan pada Tabel 4.24, Tabel 4.25 dan Tabel 4.26 akan ditampilkan dalam Tabel 4.27 untuk mengetahui keseluruhan performa evaluasi metode pada klasifikasi sentimen (SC).

**Tabel 4.27** Performa dari *Sentiment Classification* (SC)

SENTIMENT CLASSIFICATION PERFORMANCE			
Evaluation	Precision	Recall	F1-Measure
Pendekatan SC1	0.929	0.952	0.940
Pendekatan SC2	0.682	0.692	0.687
Pendekatan SC3	0.848	0.893	0.870



**Gambar 4.6** Performa metode dari *Sentiment Classification* (SC)

Tabel 4.27 dan Gambar 4.6 adalah hasil evaluasi dari keseluruhan klasifikasi sentimen menggunakan beberapa pendekatan metode yang dirangkum menjadi satu sebagai perbandingan. Pendekatan SC1 (*Word Embedding + LSTM*) mendapatkan nilai paling tinggi yaitu 0.940, dari pendekatan SC2 dan SC3. Pendekatan SC2 (*SentiWordNet*) mendapatkan nilai paling rendah yaitu 0.687 dari pendekatan SC1 dan SC3. Pendekatan SC3 (*LSTM*) mendapatkan nilai tertinggi dari pendekatan SC2 yaitu sebesar 0.870. Pendekatan SC1 dianggap paling efektif dan lebih maksimal dalam proses klasifikasi sentimen pelanggan. Semakin efektif pendekatan yang digunakan, maka metode tersebut dianggap mampu menangkap *feelings, opinions, emotions* (kepuasan pelanggan) dari banyak pelanggan secara jelas. Hasil performa terbaik, akan digunakan sebagai *input* awal dalam tahap selanjutnya.

### 4.3 Kesimpulan Metode yang akan di Gunakan

Kesimpulan dari metode yang akan digunakan adalah hasil performa terbaik dari setiap *approach* yang telah di evaluasi. Untuk *approach for aspect categorization*, unggul pada *approach* AC3. Sehingga, peneliti menggunakan *approach* AC3 untuk mengklasifikasikan setiap dokumen *term list* pada lima aspek hotel dengan pendekatan dari metode PLSA + *TF ICF 100%* + *Semantic Similarity*.

Pada *approach for sentiment classification* SC1 memiliki nilai yang lebih unggul. Sehingga, kami menggunakan *approach* SC1 untuk klasifikasi sentimen dari metode *Word Embedding* + LSTM. Hasil *selection* untuk setiap *approach* akan kami representasikan dalam Tabel 4.28.

**Tabel 4.28** Evaluasi dari Klasifikasi Sentimen Berbasis Kategorisasi Aspek

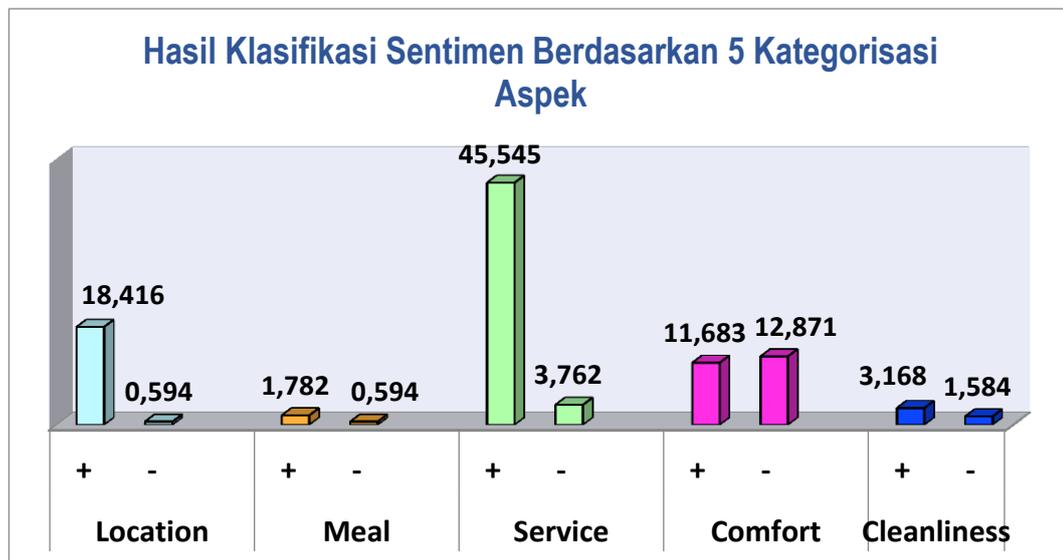
<b>Aspect Based Sentiment Classification</b>	
<b>Pendekatan AC3</b>	<b>Pendekatan SC1</b>
<ul style="list-style-type: none"><li>• Metode PLSA akan menemukan <i>hidden topic</i> dan menghasilkan dokumen <i>term list</i>. Dokumen <i>term list</i> dikelompokkan kedalam lima aspek hotel dengan menggunakan metode <i>Semantic Similarity</i>. <i>Semantic Similarity</i> digunakan untuk menghitung kemiripan <i>term list</i> terhadap aspek hotel yang dijelaskan pada Tabel 2.1 (<i>Keyword Term List Aspek Hotel</i>) + <i>Expanded Term List</i> menggunakan TF-ICF, yang diambil sebesar 100% dari keseluruhan total sinonim.</li></ul>	<ul style="list-style-type: none"><li>• Dataset pada hasil pendekatan AC3 digunakan untuk <i>Approach</i> SC1. Dataset akan diklasifikasikan menggunakan metode <i>Word Embedding</i> + LSTM. Hasil dari klasifikasi adalah sentimen berdasarkan aspek hotel.</li></ul>

#### 4.4 Evaluasi Analisis Sentimen berdasarkan 5 Aspek Hotel

Peneliti melakukan evaluasi dengan menggunakan setiap *approach* terbaik. Evaluasi dari analisis sentimen berdasarkan aspek hotel ditinjau dari *confusion matrix* (*Precision*, *Recall*, *F1-Measure*) menggunakan rumus (2.20), (2.21), dan (2.22). Hasil dari kategorisasi lima aspek hotel dan klasifikasi sentimen akan ditampilkan pada Tabel 4.29.

**Tabel 4.29** Hasil Klasifikasi Sentimen berdasarkan Kategorisasi Aspek

5 Aspect	Sentiment	Evaluation Results
Location	Positive	18.416
	Negative	0.594
Meal	Positive	1.782
	Negative	0.594
Service	Positive	<b>45.545</b>
	Negative	3.762
Comfort	Positive	11.683
	Negative	<b>12.871</b>
Cleanliness	Positive	3.168
	Negative	1.584



**Gambar 4.7** Grafik Hasil Klasifikasi Sentimen berdasarkan Kategorisasi Aspek

Pada Tabel 4.29 memberikan kesimpulan secara sistem bahwa sentimen *positive* yang tertinggi, terletak pada aspek *Service* dengan nilai 45.545. Pada Gambar 4.7 dapat disimpulkan bahwa banyak pelanggan yang merasa puas

dengan *service* yang diberikan oleh hotel Times Square, Manhanttan, New York dalam periode tiga tahun (2015-2018). Sentimen *negative* yang tertinggi terletak pada aspek *Comfort* dengan nilai 12.871. Dapat disimpulkan bahwa banyak pelanggan yang merasa tidak nyaman menginap di hotel Times Square, Manhanttan, New York (periode 2015-2018), meskipun *service* yang diberikan pihak hotel sangat memuaskan.

Sentimen *positive* yang terendah adalah aspek *Meal* dengan nilai 1.782 dan sentimen *negative* terendah di aspek *Location* dan *Meal* dengan nilai 0.594. Dapat disimpulkan bahwa banyak pelanggan yang merasa tidak puas terhadap makanan yang disajikan oleh pihak hotel dan hotel Times Square, Manhanttan, New York memiliki lokasi yang sangat strategis, sehingga banyak pelanggan merasa puas dengan lokasi hotel.

#### **4.4.1 Hubungan Kategorisasi Aspek Hotel dengan Analisis Sentimen**

Penelitian ini menggunakan taraf signifikansi yang telah ditetapkan yaitu 0,05 untuk mengukur korelasi hubungan antara aspek dengan sentimen menggunakan *Chi-Square*. *Chi-Square* diuji menggunakan perangkat lunak SPSS versi 23. Variabel penelitian ini terdiri dari 5 aspek hotel (*Location*, *Meal*, *Service*, *Comfort* dan *Cleanliness*) dan sentimen (*positive* dan *negative*). Hal ini didasari bahwa sentimen dapat mempengaruhi aspek hotel. Kesalahan dalam mendeteksi aspek, dapat menimbulkan persepsi (opini) yang berbeda bagi pelanggan dalam memilih dan menilai hotel.

Pada Tabel 4.29 akan dihitung tingkat hubungan korelasinya menggunakan *Chi-Square* dan hasil uji korelasi antar variabel akan di representasikan dalam Tabel 4.30.

##### **A. Hipotesis Penelitian:**

**H<sub>0</sub>** : Tidak ada pengaruh yang nyata (signifikan) pada variabel aspek hotel terhadap variabel sentimen pelanggan.

**H<sub>1</sub>** : Ada pengaruh yang nyata (signifikan) pada variabel aspek hotel terhadap variabel sentimen pelanggan.

## B. Pengambilan Keputusan Berdasarkan Nilai Chi-Square:

1. Jika nilai Chi-Square hitung  $>$  Chi-Square tabel, maka artinya  $H_0$  ditolak dan  $H_1$  diterima.
2. Jika nilai Chi-Square hitung  $<$  Chi-Square tabel, maka artinya  $H_0$  diterima dan  $H_1$  ditolak.

Tabel 4.30 Hasil Uji Korelasi Antar Variabel dengan *Chi-Square*

Chi-Square Tests			
	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	147,295 <sup>a</sup>	10	,000
Likelihood Ratio	54,660	10	,000
N of Valid Cases	107		

a. 12 cells (66,7%) have expected count less than 5. The minimum expected count is ,01.

**Sumber:** Data peneliti yang telah diolah SPSS 23 pada tahun 2019

Dari *output* Tabel 4.30 dapat diketahui nilai Asymp. Sig. (2-sided)  $< 0,05$  maka nilai signifikansinya adalah  $0,000 < 0,05$  yang memiliki makna hipotesis  $H_0$  ditolak dan  $H_1$  diterima, yang berarti “Ada pengaruh yang nyata (signifikan) variabel aspek hotel terhadap variabel sentimen pelanggan”. Hasil uji korelasi *Chi-square* dalam Tabel 4.30 juga membuktikan bahwa ada korelasi hubungan pada *aspect* dengan *sentiment*. Dapat disimpulkan bahwa *aspect* dipengaruhi oleh *sentiment* secara signifikan dengan nilai signifikan yakni  $p < 0,001$  (Cara membaca signifikansi dapat menggunakan Tabel *Chi-Square* pada lampiran 1 atau dapat dilihat pada Gambar 4.8).

Hubungan variabel pada Tabel 4.30 adalah signifikan karena angka signifikansi lebih kecil dari 0,05 (Nisfiannoor, 2009). Korelasi Signifikan atau peluang kesalahan *alpha* ini diberi lambang huruf *p* (*probability of Alpha Error*). Besar peluang kesalahan (tertulis “*sig*” pada *output* program SPSS 23) dapat dilihat pada taraf signifikansi, pada Tabel 4.31.

Tabel 4.31 Taraf Signifikansi Korelasi

Taraf Signifikasi	Tingkat Signifikasi
Jika sig (p) < 0,01	Sangat signifikan (signifikan yang kuat)
Jika sig (p) < 0,05	Signifikan
Jika sig (p) > 0,05	Tidak signifikan

Sumber : Data Taraf Signifikasi Berdasarkan Nisfiannoor (2009)

df	$\chi^2_{.995}$	$\chi^2_{.990}$	$\chi^2_{.975}$	$\chi^2_{.950}$	$\chi^2_{.900}$	$\chi^2_{.100}$	$\chi^2_{.050}$	$\chi^2_{.025}$	$\chi^2_{.010}$	$\chi^2_{.005}$
1	0.000	0.000	0.001	0.004	0.016	2.706	3.841	5.024	6.635	7.879
2	0.010	0.020	0.051	0.103	0.211	4.605	5.991	7.378	9.210	10.597
3	0.072	0.115	0.216	0.352	0.584	6.251	7.815	9.348	11.345	12.838
4	0.207	0.297	0.484	0.711	1.064	7.779	9.488	11.143	13.277	14.860
5	0.412	0.554	0.831	1.145	1.610	9.236	11.070	12.833	15.086	16.750
6	0.676	0.872	1.237	1.635	2.204	10.645	12.592	14.449	16.812	18.548
7	0.989	1.239	1.690	2.167	2.833	12.017	14.067	16.013	18.475	20.278
8	1.344	1.646	2.180	2.733	3.490	13.362	15.507	17.535	20.090	21.955
9	1.735	2.088	2.700	3.325	4.168	14.684	16.919	19.023	21.666	23.589
10	2.156	2.558	3.247	3.940	4.865	15.987	18.307	20.483	23.209	25.188

Gambar 4.8 Chi Square Tabel

Karena nilai Chi Square hitung = 147,295 > Chi-Square tabel = 18.307, maka keputusannya adalah  $H_0$  ditolak dan  $H_1$  diterima. Sehingga, dari Gambar 4.8 dapat disimpulkan bahwa “Ada pengaruh yang nyata (signifikan) variabel aspek hotel terhadap variabel sentimen pelanggan”.

#### 4.5 Pengaruh Sentimen terhadap Aspek Hotel

Peran dalam klasifikasi sentimen terhadap aspek, dinilai sangat penting. Kesalahan dalam kategorisasi aspek, dapat berpengaruh terhadap hasil analisa sentimen. Pada penelitian ini, kami menemukan contoh dari ulasan produk mengenai pentingnya sentimen terhadap sebuah aspek. Berikut adalah contoh dari pentingnya sentimen terhadap aspek yang akan ditampilkan dalam Tabel 4.32.

**Tabel 4.32** Efek dari pentingnya Aspek terhadap Sentimen

Effect of Sentiment on Aspects			
Reviews	Aspects	Sentiments	Results
a clean swimming <b>pool</b> at Manhattan	Cleanliness	Positive	Customers are satisfied with hotel cleanliness
The Staff unable to prepare cue <b>Pool</b>	Service	Negative	Customers are dissatisfied with the hotel service.

Pada ulasan “*a clean swimming **pool** at Manhattan*” dan ulasan “*The Staff unable to prepare cue **Pool***” memiliki kata yang sama yaitu “**pool**”. Kata yang sama dalam suatu kalimat, dapat memiliki arti yang berbeda pada aspek dan sentimen. Kalimat pada “*a clean swimming **pool** at Manhattan*” secara keseluruhan, terdeteksi sebagai aspek *Cleanliness* dan ulasan tersebut memiliki sentimen *positive*. Kalimat pada “*The Staff **unable** to prepare **cue Pool***” terdeteksi sebagai aspek *Service* dan ulasan tersebut memiliki sentimen *negative*.

Kedua ulasan, memiliki makna kata yang dapat berubah dan bergantung pada konteks dari suatu kalimat. Sehingga, sentimen dapat berubah karena aspek. Kesalahan dalam mendeteksi aspek, dapat menimbulkan persepsi yang berbeda bagi pelanggan dalam memilih dan menilai hotel. Penelitian ini memiliki dampak bagi manajer bisnis yang sangat krusial dalam memahami kebutuhan pelanggan di era Industri 5.0 untuk persaingan bisnis secara global.

*[Halaman ini sengaja dikosongkan]*

## BAB 5

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan hasil penelitian analisis sentimen berdasarkan aspek pada *review* hotel menggunakan *Probabilistic Latent Semantic Analysis*, *Word Embedding*, dan LSTM, maka dapat ditarik beberapa kesimpulan yaitu;

1. Hasil pada sistem menunjukkan bahwa proses kategorisasi 5 aspek dan serangkaian pengujian pada *Aspect Categorization* (AC) dapat dilakukan dengan baik menggunakan metode *Probabilistic Latent Semantic Analysis* (PLSA) dengan menambahkan perluasan *term list* berbasis *Term Frequency-Inverse Cluster Frequency* (TF-ICF). Proses untuk *Sentiment Classification* (SC) dapat dilakukan dengan baik menggunakan metode *Word Embedding* pada GloVe + metode *Long Short Term Memory* (LSTM).
2. Pendekatan *Aspect Categorization* 3 (PLSA + TF ICF 100% + Semantic Similarity) pada kategorisasi 5 aspek menghasilkan performa terbaik dengan nilai tertinggi sebesar 0.839 atau **84%**. Pendekatan SC1 (*Word Embedding* + LSTM) pada klasifikasi sentimen menghasilkan performa terbaik dengan nilai 0.940 atau **94%**. Sehingga, metode yang diusulkan dalam penelitian ini dapat diterima dan dibuktikan dengan baik.
3. Perluasan *term list* berbasis *Term Frequency-Inverse Cluster Frequency* (TF-ICF) dan *keyword term list* hotel dari beberapa peneliti, membuat nilai akurasi sistem pada *Aspect Categorization* (AC) menjadi lebih baik. Sehingga, pendekatan yang menggunakan metode PLSA untuk mencari *hidden topic* + TF-ICF sebesar 100% turut memaksimalkan kinerja dalam kategorisasi 5 aspek hotel (Hasil perbandingan dari pendekatan AC dapat dilihat pada BAB 4 Tabel 4.22). Penggunaan *word embedding* pada GloVe juga dapat memaksimalkan proses *Sentiment Classification* (SC) pada metode

LSTM (Hasil perbandingan dari pendekatan SC dapat dilihat pada BAB 4 Tabel 4.27).

4. *Review* hotel memiliki pengaruh pada kepuasan pelanggan terhadap 5 aspek hotel. Hal tersebut sejalan dengan Gambar 1.1 yang membuktikan bahwa aspek *service* mendapatkan rating bintang paling rendah yaitu 3 dari skala 1-5. Sedangkan secara sistem, hasil pada aspek *service* memiliki nilai sentimen *positive* tertinggi yaitu 45.545. Aspek *comfort* memiliki nilai *negative* tertinggi yaitu 12.871. Oleh sebab itu, dengan penelitian ini sistem membuktikan bahwa rating bintang tidak merepresentasikan kepuasan pelanggan dengan baik, tanpa melihat 5 aspek hotel yang dapat mempengaruhinya.
5. Hasil evaluasi dapat memberikan kesimpulan yaitu banyak pelanggan yang merasa tidak nyaman ketika menginap di hotel Times Square, Manhanttan, New York (pada periode 2015-2018), meskipun *service* yang diberikan pihak hotel sangat memuaskan. Karena *service* yang baik, belum tentu dapat membuat pelanggan menjadi nyaman. Persepsi atau opini pelanggan seperti ini yang perlu digali lagi untuk pengembangan pada penelitian selanjutnya.
6. Hasil uji korelasi *Chi-square* membuktikan bahwa ada korelasi hubungan pada 5 *aspect* hotel dengan *sentiment* pelanggan. Hal ini sejalan dengan *aspect* yang dipengaruhi oleh *sentiment* secara signifikan dengan nilai signifikansi sebesar  $p < 0,001$  (Cara membaca signifikansi dapat menggunakan Tabel *Chi-Square* pada lampiran 1 atau dapat dilihat pada Gambar 4.8) dan angka signifikansi yang dihasilkan lebih kecil dari 0,05. Dari *output* Tabel 4.30 dapat diketahui nilai Asymp. Sig. (2-sided)  $< 0,05$  maka nilai signifikansinya adalah  $0,000 < 0,05$ . Nilai Chi Square hitung = 147,295 > Chi Square tabel = 18.307, maka keputusannya adalah  $H_0$  ditolak dan  $H_1$  diterima yang memiliki makna “Ada pengaruh yang nyata (signifikan) variabel aspek hotel terhadap variabel sentimen pelanggan”.

7. Sentimen pelanggan dapat dipengaruhi oleh 5 aspek hotel (*Location, Meal, Service, Comfort* dan *Cleanliness*) dibuktikan dengan hasil dari efek sentimen terhadap aspek dalam Tabel 4.32. Hasil menjelaskan bahwa kedua ulasan, memiliki kata yang sama yaitu “*Pool*” dengan makna kata yang dapat berubah dan bergantung pada konteks dari suatu kalimat. Sehingga, sentimen dapat berubah karena aspek. Kesalahan dalam mendeteksi aspek, dapat menimbulkan opini yang berbeda bagi pelanggan dalam memilih dan menilai hotel. Penelitian ini memiliki dampak bagi manajer bisnis yang sangat krusial dalam memahami kebutuhan pelanggan di era Industri 5.0 untuk persaingan bisnis secara global.
8. Penelitian ini juga memberikan kontribusi (*best practice*) terhadap manajemen hotel untuk terus meningkatkan kualitas dan layanan hotel agar pelanggan menjadi lebih nyaman. Bagi praktisi bisnis lain, diharapkan dapat dengan mudah memahami kebutuhan pelanggan, dalam pelayanan dan keberlanjutan perusahaan di era industri 5.0.

## 5.2 Saran

1. Saran bagi pembaca, dengan penelitian ini diharapkan dapat menambah wawasan baru tentang “analisis sentimen berdasarkan aspek pada *review* hotel menggunakan *Probabilistic Latent Semantic Analysis, Word Embedding*, dan LSTM”.
2. Saran bagi manajemen hotel, perlu ditingkatkan lagi dalam hal pelayanan teknis dan jasa agar pelanggan merasa lebih puas dan nyaman di hotel Times Square, Manhattan, New York. Kelima aspek hotel (*Location, Meal, Service, Comfort*, dan *Cleanliness*) dapat dijadikan tolak ukur dalam memperbaiki kualitas dan pelayanan hotel untuk kepuasan pelanggan. Kepuasan pelanggan dinilai sangat penting, karena pelanggan dapat merekomendasikan hotel dengan memberikan ulasan dan promosi secara *Word of Mouth* (WOM) yang dapat meningkatkan profit perusahaan.
3. Saran bagi penelitian selanjutnya, diharapkan untuk mengadopsi pendekatan semantik dalam kategorisasi 5 aspek hotel dan klasifikasi sentimen yang

lebih baik dari metode peneliti. Disamping itu, peneliti dapat menganalisis lebih detail dan fokus dalam meninjau aspek-aspek lain yang dapat mempengaruhi sentimen pelanggan (misalnya, selain dari 5 aspek hotel pada website Traveloka). Karena penelitian yang baik adalah penelitian yang dapat memberikan peluang bagi peneliti lain untuk mengembangkan penelitian di masa depan.

## DAFTAR PUSTAKA

- Akhtar, N., Zubair, N., Kumar, A., dan Ahmad, T. (2017), "Aspect based Sentiment Oriented Summarization of Hotel Reviews", In: *Proc. of International Conf. On Computer Science*, Cochin, India, Vol.115, hal.563-571.
- Alexa an Amazon.com Company. (2019), <https://www.alex.com/siteinfo/traveloka.com>.
- AL-Sharuee, M. T., Liu, F., dan Pratama, M. (2018), "Sentiment analysis: An automatic contextual analysis and ensemble clustering approach and comparison", *International Journal of Data & Knowledge Engineering*, Vol.115, hal.194-213.
- Araque, O., Corcuera-Platas, I., Sánchez-RadaCarlos, J. F., dan Iglesias, C. A. (2017), "Enhancing deep learning sentiment analysis with ensemble techniques in social applications", *International Journal of Expert Systems with Applications*, Vol.77, hal.236-246.
- Aryanto, A., dan Tjendrowasono, T. I. (2012), "Pembangunan Sistem Penjualan online Pada toko indah jaya furniture surakarta". *Indonesian Journal of Computer Science-Speed (IJCSS)*, Vol.10, No.1, hal.56-62.
- Aziz, M. N., Firmanto, A., Fajrin, A. M., dan Ginardi, R. V. H. (2018), "Sentiment Analysis and Topic Modelling for Identification of Government Service Satisfaction", In: *Proc. Of 2018 5th International Conf. On Information Tech., Computer, and Electrical Engineering (ICITACEE)*, Semarang, Indonesia, hal.125-130.
- Barnaghi, P., Ghaffari, P., dan Breslin, J. G. (2016), "Opinion Mining and Sentiment Polarity on Twitter and Correlation Between Events and Sentiment", *IEEE Second International Conf. On Big Data Computing Service and Applications*, Oxford, UK, hal.52-57.
- Berezina, K., Bilgihan, A., Cobanoglu, C., dan Okumus, F. (2016), "Understanding Satisfied and Dissatisfied Hotel Customers: Text Mining of

- Online Hotel Reviews”, *International Journal of Hospitality Marketing & Management*, Vol.25, No.1, hal.1-24.
- Blokh, I., dan Alexandrov, V. (2017), “News Clustering based on similarity Analysis”, In: *Proc. of International Conf. On Computer Science*, Vol.122, hal.715-719.
- Chaudhuri, A., dan Ghosh, S. K. (2016), “Sentiment Analysis of Customer Reviews Using Robust Hierarchical Bidirectional Recurrent Neural Network”, *International Journal of Artificial Intelligence Perspectives in Intelligent Systems*, Vol.464, hal.249-261.
- Chen, G., dan Chen, L. (2015), “Augmenting service recommender systems by incorporating contextual opinions from user reviews”, *International Journal of User Modeling and User-Adapted Interaction*, Vol.25, No.3, hal.295-329.
- Do, H. H., Prasad, P., Maag, A., dan Alsadoon, A. (2019), “Deep Learning for Aspect-Based Sentiment Analysis: A Comparative Review”, *International Journal of Expert Systems with Applications*, Vol.118, hal.272-299.
- Ekinci, E., dan Omurca, S. I. (2018), “An Aspect-Sentiment Pair Extraction Approach Based on Latent Dirichlet Allocation”, *International Journal of Intelligent System and Applications in Engineering (IJISAE)*, Vol.6, No.3, hal.209-213.
- Fernandez-Beltran, R., dan Pla, F. (2015), “Incremental probabilistic Latent Semantic Analysis for video retrieval”, *International Journal of Image and Vision Computing*, Vol.38, hal.1-12.
- Fernandez-Beltran, R., dan Pla, F. (2016), “Latent topics-based relevance feedback for video retrieval”, *International Journal of Pattern Recognition*, Vol.51, hal.72-84.
- Fu, X., Sun, X., Wu, H., Cui, L., dan Huang, J. Z. (2018), “Weakly supervised topic sentiment joint model with word embeddings”, *International Journal of Knowledge-Based Systems*, Vol.147, hal.43-54.
- Gandomi, A., dan Haider, M. (2015), “Beyond the hype: Big data concepts, methods, and analytics”, *International Journal of Information Management*, Vol.35, No.2, hal.137-144.

- Gao, C., dan Ren, J. (2019), "A topic-driven language model for learning to generate diverse sentences", *International Journal of Neurocomputing*, Vol.333, hal.374-380.
- Hnin, C. C., Naw, N., dan Win, A. (2018), "Aspect Level Opinion Mining for Hotel Reviews in Myanmar Language", *International Conf. On Agents (ICA)*, Singapore, hal.132-135.
- Karimuddin, A. (2019), "Retrieved from Traveloka Jadi Situs Pemesanan Kamar Hotel dan Tiket Pesawat Terpopuler Menurut Survei Nusaresearch" <https://dailysocial.id>.
- Kaspa, L. P., Akella, V. N. S. S., Chen, Z., dan Shi, Y. (2018), "Towards Extended Data Mining: An Examination of Technical Aspects", In: *Proc. of International Conf. On Computer Science*, Vol.139, hal.49-55.
- Khotimah, D. A. K., dan Sarno, R. (2018), "Sentiment Detection of Comment Titles in Booking.com Using Probabilistic Latent Semantic Analysis", *International Conf. On Information and Communication Technology (ICoICT)*, Bandung, Indonesia, hal.514-519.
- Kim, K. (2018), "An improved semi-supervised dimensionality reduction using feature weighting: Application to sentiment analysis", *International Journal of Expert Systems with Applications*, Vol.109, hal.49-65.
- Ladhari, R., dan Michaud, M. (2015), "EWOM effects on hotel booking intentions, attitudes, trust, and website perceptions", *International Journal of Hospitality Management*, Vol.46, No.3, hal.36-45.
- Nisfiannoor, Muhammad. (2009), *Pendekatan Statistika Modern Untuk Ilmu Sosial*. Jakarta: Salemba Humanika.
- Özdemir, V., dan Hekim, N. (2018), "Birth of Industry 5.0: Making Sense of Big Data with Artificial Intelligence, "The Internet of Things" and Next-Generation Technology Policy", *OMICS: International Journal of Integrative Biology*, Vol.22, No.1, hal.1-12.
- Pennington, J., Socher, R., dan Manning, C. D. (2014), "Glove: global vectors for word representation", In: *Proc. of International Conf. On Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qatar, hal.1532-1543.

- Pham, D., dan Le, A. (2018), "Exploiting multiple word embeddings and one-hot character vectors for aspect-based sentiment analysis", *International Journal of Approximate Reasoning*, Vol.103, hal.1-10.
- Prastito, A. (2000), *Statistik Menjadi Lebih Mudah Dengan SPSS 17*. Jakarta: PT. Elex Media Koputindo.
- Puspaningrum, A., Siahaan, D., dan Fatichah, C. (2018), "Mobile App Review Labeling Using LDA Similarity and Term Frequency-Inverse Cluster Frequency (TF-ICF)", *International Conf. On Information Technology and Electrical Engineering (ICITEE)*, Kuta, Indonesia, hal.365-370.
- Rao, G., Huang, W., Feng, Z., dan Cong, Q. (2018), "LSTM with sentence representations for document-level sentiment classification", *International Journal of Neurocomputing*, Vol. 308, hal.49-57.
- Reddy, B. K., dan Delen, D. (2018), "Predicting hospital readmission for lupus patients: An RNN-LSTM-based deep-learning methodology", *International Journal of Computers in Biology and Medicine*, Vol.101, hal.199-209.
- Revindasari, F., Sarno, R., dan Solichah, A. (2016), "Traceability Between Business Process and Software Component using Probabilistic Latent Semantic Analysis", *International Conf. On Informatics and Computing (ICIC)*, Mataram, Indonesia, hal.3-8.
- Rezaeinia, S. M., Rahmani, R., Ghodsi, A., dan Veisi, H. (2019), "Sentiment analysis based on improved pre-trained word embeddings", *International Journal of Expert Systems with Applications*, Vol.117, hal.139-147.
- Rintyarna, B. S., Sarno, R., dan Fatichah, C. (2018), "Enhancing the performance of sentiment analysis task on product reviews by handling both local and global context", *International Journal of Information and Decision Science*, Vol.11.
- Schumaker, R. P., Jarmoszko, A. T., dan Labeledz, C. S. (2016), "Predicting wins and spread in the Premier League using a sentiment analysis of twitter", *International Journal of Information and Decision Support Systems*, Vol. 88, hal.76-84.

- Stein, R. A., Jaques, P. A., dan Valiati, J. F. (2019), “An analysis of hierarchical text classification using word Embeddings”, *International Journal of Information Sciences*, Vol.471, hal.216-232.
- Suadana, L. H., dan Purwarianti, A. (2016), “Combination of Latent Dirichlet Allocation (LDA) and Term Frequency-Inverse Cluster Frequency (TFxICF) in Indonesian text clustering with labeling”, *International Conf. On Information and Communication Technology (ICoICT)*, Bandung, Indonesia, hal.1-6.
- Suhariyanto, Firmanto, A., dan Sarno, R. (2018), “Prediction of Movie Sentiment Based on Reviews and Score on Rotten Tomatoes Using SentiWordNet”, *International Conf. On Application for Technology of Information and Communication (iSemantic)*, Semarang, Indonesia, hal.202-206.
- Tai, K. S., Socher, R., dan Manning, C. D. (2015), “Improved semantic representations from tree-structured long short-term memory networks”, In: *Proc. of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conf. On Natural Language Processing*, Beijing, China, hal.1556-1566.
- Thomas, A. M., dan Resmipriya, M. G. (2016), “An Efficient Text Classification Scheme Using Clustering”, In: *Proc. of International Conf. On Procedia Technology*, Vol.24, hal.1220-1225.
- Wang, J., Peng, B., dan Zhang, X. (2018), “Using a stacked residual LSTM model for sentiment intensity prediction”, *International Journal of Neurocomputing*, Vol.322, hal.93-101.
- Wang, P., Xu, B., Xu, J., Tian, G., Liu, C. L., dan Hao, H. (2016), “Semantic Expansion using Word Embedding Clustering and Convolutional Neural Network for Improving Short Text Classification”, *International Journal of Neurocomputing*, Vol.174, hal.806-814.
- Wang, X., Chang, M., Wang, L., dan Lyu, S. (2019), “Efficient algorithms for graph regularized PLSA for probabilistic topic modeling”, *International Journal of Pattern Recognition*, Vol. 86, hal.236-247.

- Wang, X., Chang, M., Ying, Y., dan Lyu, S. (2016), "Co-regularized PLSA for multi-modal learning", In: *Proc. of International Conf. On Artificial Intelligence (AAAI-16)*, Phoenix, Arizona, hal.2166-2172.
- Witkowski, K. (2017), "Internet of Things, Big Data, Industry 4.0 - Innovative Solutions in Logistics and Supply Chains Management", In: *Proc. of International Conf. On Engineering, Project, and Production Management*, Vol.182, hal.763-769.
- Xiang, Z., Schwartz, Z., Gerdes, J. H., dan Uysal, M. (2015), "What can big data and text analytics tell us about hotel guest experience and satisfaction?" *International Journal of Hospitality Management*, Vol.44, hal.120-130.
- Xu, X., Wang, X., Li, Y., dan Haghghi, M. (2017), "Business intelligence in online customer textual reviews: Understanding consumer perceptions and influential factors", *International Journal of Information Management*, Vol.37, No.6, hal.673-683.
- Yoo, S., Song, J., dan Jeong, O. (2018), "Social media contents based sentiment analysis and prediction system", *International Journal of Expert Systems with Applications*, Vol.105, hal.102-111.
- Zhao, Y., Xu, X., dan Wang, M. (2019), "Predicting overall customer satisfaction: Big data evidence from hotel online textual reviews", *International Journal of Hospitality Management*, Vol. 76, hal.111-121.

## BIODATA PENULIS



Penulis lahir di Surabaya, Jawa Timur pada 18 Agustus 1992 dan merupakan anak kedua dari dua bersaudara. Penulis telah menempuh studi formal di SMAN 1 Driyorejo Gresik dan Sarjana (S1) Jurusan Sistem Informasi di Institut Bisnis dan Informatika Stikom Surabaya. Penulis juga telah menempuh studi non formal seperti sekolah *modelling* di *Draps School Of Talent* Surabaya dan sekolah *Disc Jockey* (DJ) di *Enemy DJ Production* Surabaya. Selama kuliah S1 di Stikom, penulis melakukan penelitian dengan judul “Analisis Penerimaan Penerapan PARIS (*Parking Information System*) dengan *Metode Technology Acceptance Model* (TAM) pada Area Parkir Stikom Surabaya” di jurnal Sistem informasi & Komputer Akuntansi (JSIKA). Selama menempuh kuliah S2 di MMT, penulis mulai tertarik untuk menekuni bidang data mining, statistik dan sentimen analisis. Rasa ketertarikan penulis dalam mempelajari ilmu baru, membuat penulis melakukan penelitian kembali dengan mengikuti seminar internasional pada *International Conference on Information and Communication Technology* (ICOICT) di Bandung, Indonesia yang berjudul “*Sentiment Detection of Comment Titles in Booking.com Using Probabilistic Latent Semantic Analysis*”. Seolah tak kenal lelah, penulis yang gemar membuat puisi dan starbucks *addict* ini juga membuat jurnal internasional yang berjudul “*Sentiment Analysis of Hotel Aspect using Probabilistic Latent Semantic Analysis, Word Embedding, and LSTM*” pada *International Journal of Intelligent Engineering and Systems* (IJIES) di Jepang. Keseluruhan penelitian dari penulis, dapat di unduh melalui ResearchGate atau menghubungi langsung pada alamat email: [dewiyukk@gmail.com](mailto:dewiyukk@gmail.com) atau nomor whatsapp penulis yaitu 08113922226. Penulis berharap, beberapa penelitian yang dilakukan dapat memberikan manfaat dan celah bagi pembaca dalam mengembangkan, berinovasi dan membakar semangat mahasiswa dalam belajar ilmu baru.

*[Halaman ini sengaja dikosongkan]*

## LAMPIRAN 1

### Hasil Uji Korelasi *CHI-SQUARE*

- Hasil Uji Korelasi X1 dengan Y1

Chi-Square Tests			
	Value	df	Asymptotic Significance (2-sided)
<b>Pearson Chi-Square</b>	147,295 <sup>a</sup>	10	,000
<b>Likelihood Ratio</b>	54,660	10	,000
<b>N of Valid Cases</b>	107		

a. 12 cells (66,7%) have expected count less than 5. The minimum expected count is ,01.

➤ **Cara membaca menggunakan Tabel Chi-Square**

Berikut ini adalah tabel *Chi-Square* dengan derajat kebebasan dari 1-100 dan alpha 0,001, 0,01, dan 0,05.

<i>df</i>	$\chi^2_{.995}$	$\chi^2_{.990}$	$\chi^2_{.975}$	$\chi^2_{.950}$	$\chi^2_{.900}$	$\chi^2_{.100}$	$\chi^2_{.050}$	$\chi^2_{.025}$	$\chi^2_{.010}$	$\chi^2_{.005}$
1	0.000	0.000	0.001	0.004	0.016	2.706	3.841	5.024	6.635	7.879
2	0.010	0.020	0.051	0.103	0.211	4.605	5.991	7.378	9.210	10.597
3	0.072	0.115	0.216	0.352	0.584	6.251	7.815	9.348	11.345	12.838
4	0.207	0.297	0.484	0.711	1.064	7.779	9.488	11.143	13.277	14.860
5	0.412	0.554	0.831	1.145	1.610	9.236	11.070	12.833	15.086	16.750
6	0.676	0.872	1.237	1.635	2.204	10.645	12.592	14.449	16.812	18.548
7	0.989	1.239	1.690	2.167	2.833	12.017	14.067	16.013	18.475	20.278
8	1.344	1.646	2.180	2.733	3.490	13.362	15.507	17.535	20.090	21.955
9	1.735	2.088	2.700	3.325	4.168	14.684	16.919	19.023	21.666	23.589
<b>10</b>	<b>2.156</b>	<b>2.558</b>	<b>3.247</b>	<b>3.940</b>	<b>4.865</b>	<b>15.987</b>	<b>18.307</b>	20.483	23.209	25.188
11	2.603	3.053	3.816	4.575	5.578	17.275	19.675	21.920	24.725	26.757
12	3.074	3.571	4.404	5.226	6.304	18.549	21.026	23.337	26.217	28.300
13	3.565	4.107	5.009	5.892	7.042	19.812	22.362	24.736	27.688	29.819
14	4.075	4.660	5.629	6.571	7.790	21.064	23.685	26.119	29.141	31.319
15	4.601	5.229	6.262	7.261	8.547	22.307	24.996	27.488	30.578	32.801
16	5.142	5.812	6.908	7.962	9.312	23.542	26.296	28.845	32.000	34.267
17	5.697	6.408	7.564	8.672	10.085	24.769	27.587	30.191	33.409	35.718
18	6.265	7.015	8.231	9.390	10.865	25.989	28.869	31.526	34.805	37.156
19	6.844	7.633	8.907	10.117	11.651	27.204	30.144	32.852	36.191	38.582
20	7.434	8.260	9.591	10.851	12.443	28.412	31.410	34.170	37.566	39.997
21	8.034	8.897	10.283	11.591	13.240	29.615	32.671	35.479	38.932	41.401
22	8.643	9.542	10.982	12.338	14.041	30.813	33.924	36.781	40.289	42.796
23	9.260	10.196	11.689	13.091	14.848	32.007	35.172	38.076	41.638	44.181
24	9.886	10.856	12.401	13.848	15.659	33.196	36.415	39.364	42.980	45.559
25	10.520	11.524	13.120	14.611	16.473	34.382	37.652	40.646	44.314	46.928

<b>df</b>	<b><math>\chi^2_{.995}</math></b>	<b><math>\chi^2_{.990}</math></b>	<b><math>\chi^2_{.975}</math></b>	<b><math>\chi^2_{.950}</math></b>	<b><math>\chi^2_{.900}</math></b>	<b><math>\chi^2_{.100}</math></b>	<b><math>\chi^2_{.050}</math></b>	<b><math>\chi^2_{.025}</math></b>	<b><math>\chi^2_{.010}</math></b>	<b><math>\chi^2_{.005}</math></b>
26	11.160	12.198	13.844	15.379	17.292	35.563	38.885	41.923	45.642	48.290
27	11.808	12.879	14.573	16.151	18.114	36.741	40.113	43.195	46.963	49.645
28	12.461	13.565	15.308	16.928	18.939	37.916	41.337	44.461	48.278	50.993
29	13.121	14.256	16.047	17.708	19.768	39.087	42.557	45.722	49.588	52.336
30	13.787	14.953	16.791	18.493	20.599	40.256	43.773	46.979	50.892	53.672
40	20.707	22.164	24.433	26.509	29.051	51.805	55.758	59.342	63.691	66.766
50	27.991	29.707	32.357	34.764	37.689	63.167	67.505	71.420	76.154	79.490
60	35.534	37.485	40.482	43.188	46.459	74.397	79.082	83.298	88.379	91.952
70	43.275	45.442	48.758	51.739	55.329	85.527	90.531	95.023	100.425	104.215
80	51.172	53.540	57.153	60.391	64.278	96.578	101.879	106.629	112.329	116.321
90	59.196	61.754	65.647	69.126	73.291	107.565	113.145	118.136	124.116	128.299
100	67.328	70.065	74.222	77.929	82.358	118.498	124.342	129.561	135.807	140.169

## LAMPIRAN 2

“ Selalu ada langit tak berwarna,  
dan perempuan yang menulis di bawah langit seperti itu...”



Kelak ketika tak ada lagi kata persembahan, maka tidak ada lagi kata untuk ku tulis. Hurufku akan gersang dan kelaparan, berbaring dengan alas berlembar-lembar kertas. Kata terima kasih ini butuh satu kata yang belum pernah menyentuh pikiran dan hati siapapun.

Seandainya aku bisa memilih kata itu, maka aku hanya akan memilih satu bidang putih selebar lengan, sepanjang tahun, setebal sunyi, yang kugantung tanpa tali, dan setinggi memori. Dalam *memory* terpatri “Melawan gravitasi sama mudahnya dengan menangkap mimpi”. Terima kasih untuk Bapak Prof. Drs.Ec. Ir. Riyanarto Sarno, M.Sc. selaku dosen pembimbing tesis yang telah memacu adrenalin, mendidik dan memperkuat mental penulis dalam menyelesaikan tesis ini.