

Identifikasi dan Penanganan Sentimen Konflik pada Analisis Sentimen Berbasis Aspek

RINGKASAN DISERTASI

Nuryani

NIM: 33219005

(Program Studi Doktor Teknik Elektro dan Informatika)



Institut Teknologi Bandung

2025

Identifikasi dan Penanganan Sentimen Konflik pada Analisis Sentimen Berbasis Aspek

Disertasi ini dipertahankan pada Sidang Terbuka Komisi Sekolah
Pascasarjana sebagai salah satu syarat untuk memperoleh gelar
Doktor Institut Teknologi Bandung

—————, — Juni 2025

Nuryani

NIM: 33219005

(Program Studi Doktor Teknik Elektro dan Informatika)

Promotor : Dr. Ir. Rinaldi, M.T.

Ko-Promotor 1 : Dr. Eng. Ayu Purwarianti, S.T., M.T.

Ko-Promotor 2 : Dessi Puji Lestari, ST, M.Eng, Ph.D.

Institut Teknologi Bandung

2025

Identifikasi dan Penanganan Sentimen Konflik pada Analisis Sentimen Berbasis Aspek

Nuryani

NIM: 33219005

(Program Studi Doktor Teknik Elektro dan Informatika)

1. Latar Belakang

Ulasan atau opini masyarakat terhadap sesuatu menjadi salah satu hal yang penting dalam setiap pengambilan keputusan. Dan saat ini, pesatnya pertumbuhan internet dan semakin populernya penggunaan aplikasi media sosial memungkinkan orang untuk memberikan opini serta mengekspresikan sentimen dan pengalaman tentang sesuatu kepada publik secara terbuka. Dengan menganalisis sentimen publik dapat membantu manajer, pejabat, pemegang kebijakan dan pembuat keputusan untuk dapat meningkatkan kualitas produk atau layanannya, memprediksi permintaan dan selera pelanggan, mengukur kepuasan pelanggan, mengukur dampak kebijakan, dll. Hal tersebut telah mendorong penelitian yang ekstensif pada *opinion mining* (penambangan opini) atau analisis sentimen.

Analisis sentimen adalah *task* komputasi untuk menganalisa, mengidentifikasi dan mengekstraksi opini atau sentimen pengguna terhadap sebuah produk, layanan, dll pada sebuah teks yang biasanya diungkapkan melalui blog, jejaring sosial, forum diskusi atau situs web *e-commerce*. Berbeda dengan analisis sentimen umum (analisis sentimen level dokumen dan analisis sentimen level kalimat), yang menganggap sentimen pada keseluruhan dokumen atau kalimat adalah sama, analisis sentimen level aspek atau analisis sentimen berbasis aspek (ASBA) memprediksi polaritas sentimen terhadap target tertentu dari sebuah kalimat opini. Sebagai contoh dalam ulasan restoran berikut ini “*Great food but the service was dreadful.*” berisi sentimen positif dari kata “*great*” untuk aspek “*food*” dan sentimen negatif dari kata “*dreadful*” untuk aspek “*service.*” Mengklasifikasikan keseluruhan sentimen menjadi negatif akan mengabaikan fakta bahwa aspek “*food*” memiliki sentimen positif dan begitu juga sebaliknya, mengklasifikasikan keseluruhan sentimen menjadi positif

akan mengabaikan fakta bahwa aspek “*service*” mempunyai sentimen negatif. Oleh karena itu, analisis sentimen berbasis aspek (ASBA) muncul untuk menjawab tantangan tersebut.

Telah banyak penelitian yang dilakukan untuk menyelesaikan persoalan dalam ASBA. Awal penelitian tentang ABSA adalah pendekatan *non deep learning*, diikuti oleh metode berbasis *deep learning* dengan *word embedding*. Kemudian model *deep learning* dengan *contextual embedding* yang mendasari pendekatan dengan menggunakan PLMs (*pre-trained language models*) modern, baik yang berbasis *bi-directional LSTM* seperti eLMO, maupun berbasis Transformer seperti BERT, GPT, BART, T5, dan lain-lain, banyak digunakan untuk meningkatkan kinerja pada *task NLP*, termasuk ASBA. Lebih lanjut, kemunculan LLMs (*large language models*) seperti GPT-3 dan GPT-4 (yang digunakan dalam aplikasi ChatGPT) dan Llama telah menunjukkan penggunaan dan penerapan yang luas pada berbagai aplikasi NLP generatif, sehingga menarik banyak studi untuk mengevaluasi kinerja LLMs pada ABSA. Meskipun demikian, mayoritas penelitian tentang ASBA hanya fokus ke klasifikasi sentimen dua kelas (positif dan negatif) atau tiga kelas (positif, negatif dan netral) saja, dan tidak memasukkan sentimen konflik pada klasifikasi sentimennya. Sebuah aspek mempunyai sentimen konflik jika aspek tersebut mengekspresikan sentiment positif dan negatif sekaligus, seperti dalam contoh kalimat berikut ini “*The service is a quite slow, but friendly.*”. Aspek “*service*” mempunyai sentimen negatif dari kata sentimen “*quite slow*” dan sekaligus mempunyai sentimen positif dari kata sentimen “*friendly.*” Mengabaikan sentimen konflik akan menyebabkan hasil klasifikasi menjadi kurang akurat.

Terbatasnya penelitian tentang ASBA dengan klasifikasi sentimen empat-kelas, yang memasukkan sentimen konflik selain sentimen positif, negatif, dan netral, disebabkan oleh beberapa faktor. Diantaranya adalah terbatasnya *dataset* yang tersedia, kemudian jumlah data aspek dengan sentimen konflik pada dataset publik yang biasa digunakan untuk penelitian ASBA sangat kecil, yang menyebabkan dataset menjadi tidak seimbang. Lebih lanjut mayoritas metode menganggap setiap aspek hanya memiliki satu sentimen saja, padahal sentimen konflik merupakan

kombinasi dari sentimen positif dan negatif sekaligus, sehingga identifikasinya menjadi lebih sulit. Selain itu, sentimen konflik biasanya diungkapkan dalam kata atau frase yang tidak sederhana, terdapat pada kalimat yang panjang dan kompleks, serta melibatkan aspek implisit, yang mungkin memerlukan penanganan lebih dalam.

Berdasarkan uraian tersebut, maka masalah yang diselesaikan dalam penelitian ini adalah bagaimana merancang model yang tepat yang mampu mengidentifikasi dan menangani aspek dengan sentimen konflik pada ASBA. Pendekatan yang diusulkan dibagi menjadi dua bagian. Bagian pertama adalah perancangan metode untuk menyederhanakan sentimen konflik yang merupakan gabungan dari sentimen positif dan negatif sekaligus. Hal ini dilakukan dengan memodelkan aspek dengan klasifikasi sentimen multi-label dimana setiap aspek diatur untuk mempunyai nilai baik untuk sentimen positif maupun negatifnya. Kemudian bagian kedua ditujukan untuk mengatasi masalah yang berkaitan dengan keterbatasan dan ketidakseimbangan dataset. Hal ini dilakukan dengan pembangkitan data sintetik dengan model bahasa besar (*large language models/LLM*).

2. Tujuan Penelitian

Berdasarkan permasalahan yang sudah dirumuskan, tujuan dari kegiatan penelitian ini adalah sebagai berikut:

1. Mengembangkan model berbasis BERT untuk ASBA yang mampu mengidentifikasi dan menangani aspek dengan sentimen konflik dengan lebih baik.
2. Membuat data sintetik dengan model bahasa besar (*large language models/LLM*) yang diharapkan dapat menyelesaikan permasalahan yang berhubungan dengan keterbatasan dan ketidakseimbangan dataset untuk penelitian ini.
3. Penggabungan dari model berbasis BERT serta pembuatan data sintetik diharapkan akan menghasilkan model yang lebih akurat ditandai dengan peningkatan kinerja dibandingkan dengan model BERT-kalimat bantu sebagai *baseline*.

3. Metode Penelitian

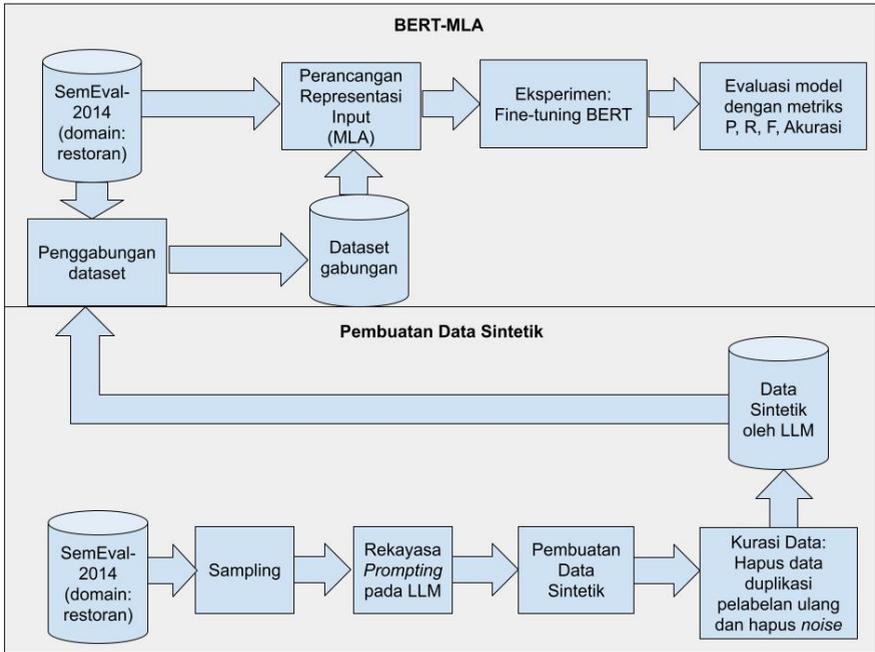
Metode yang diusulkan adalah model berbasis BERT dengan aspek multi-label (BERT-MLA), dimana setiap aspek didesain untuk memiliki nilai sentimen positif dan negatifnya. Dalam metode ini, dikembangkan kalimat semu (*pseudo-sentence*) dari setiap aspek, kemudian dipasangkan dengan kalimat ulasan sebagai representasi input untuk BERT. Selanjutnya, dilakukan *fine-tuning* BERT untuk *task* klasifikasi sentimen multi-label dan hasilnya diterjemahkan ke dalam klasifikasi sentimen empat-kelas. Untuk mengatasi masalah yang berkaitan dengan kelangkaan dan ketidakseimbangan *dataset*, maka dilakukan pembangkitan data sintetik dengan menggunakan Llama. Dalam studi ini, dilakukan evaluasi *few-shot prompting* dengan empat komponen yaitu *role-play* dan *task specification* untuk menetapkan konteks yang tepat, *generation conditionals* untuk menentukan tipe data yang diinginkan, dan *in-context demonstrations* untuk memberikan panduan yang berupa *implicit human guidance* kepada model.

Usulan metode untuk melakukan identifikasi dan penanganan sentimen konflik pada analisis sentimen berbasis aspek ditampilkan pada Gambar 1. Penjelasan dari kedua bagian usulan tersebut, (BERT-MLA) dan pembangkitan data sintetik berbasis LLM *open source* diuraikan pada sub-bab 3.1 dan 3.2.

3.1 BERT-kalimat semu dengan aspek multi-label (BERT-MLA)

Metode berbasis BERT-kalimat semu dengan aspek multi-label, yang selanjutnya akan disebut dengan BERT dengan *multi-label aspect* (BERT-MLA), diusulkan untuk menyederhanakan sentimen konflik, dimana setiap aspek dirancang untuk mempunyai komponen sentimen positif dan negatif sekaligus yang selanjutnya disebut sebagai aspek dengan sentimen multi-label (aspek multi-label). Aspek multi-label didefinisikan sebagai aspek dengan beberapa label. Dalam metode yang diusulkan ini, setiap aspek akan diberi nilai untuk label *positive*, *negative*, dan *none*. Konversi sentimen pada aspek multi-label ditunjukkan pada Tabel 1.

Ada tiga tahap pada metode ini, yaitu yang pertama merancang representasi input untuk *task* klasifikasi pasangan kalimat pada model berbasis BERT. Tahap yang kedua melakukan *task* klasifikasi sentimen multi-label untuk masing-masing aspek



Gambar 1 Usulan metode

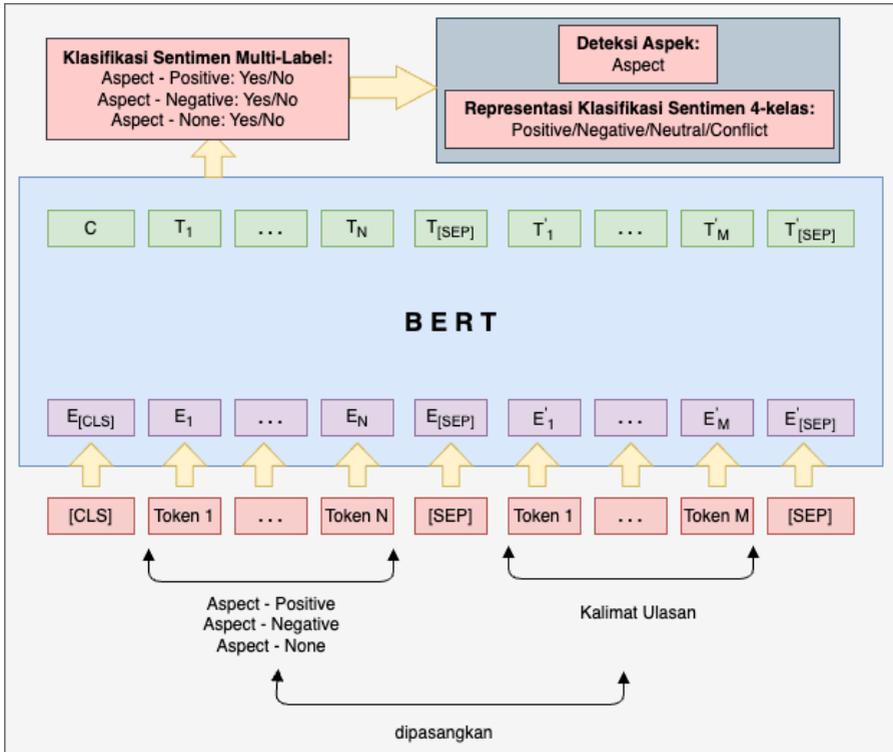
dan yang terakhir adalah melakukan representasi hasil dari tahap kedua ke dalam *task* klasifikasi 4-kelas (positif, negatif, netral, dan konflik). Pada metode yang diusulkan ini, dilakukan evaluasi terhadap dua *task* sekaligus yaitu deteksi kategori aspek (ACD) dan analisis sentimen kategori aspek (ACSA). Arsitektur model BERT dengan aspek multi-label diberikan pada Gambar 2.

3.2 Pembangkitan Data Sintetik Berbasis LLM *open source*

Pembangkitan data sintetik menggunakan model bahasa besar (*large language models/LLMs*) berbasis *open source* diusulkan untuk mengatasi permasalahan yang berkaitan dengan keterbatasan dataset serta mengurangi ketidakseimbangan data pada dataset SemEval-2014 domain restoran yang digunakan dalam penelitian ini. Pada proses pembentukan data sintetik ini, akan dibuat kalimat yang berisi

Tabel 1 Konversi sentimen pada aspek multi-label

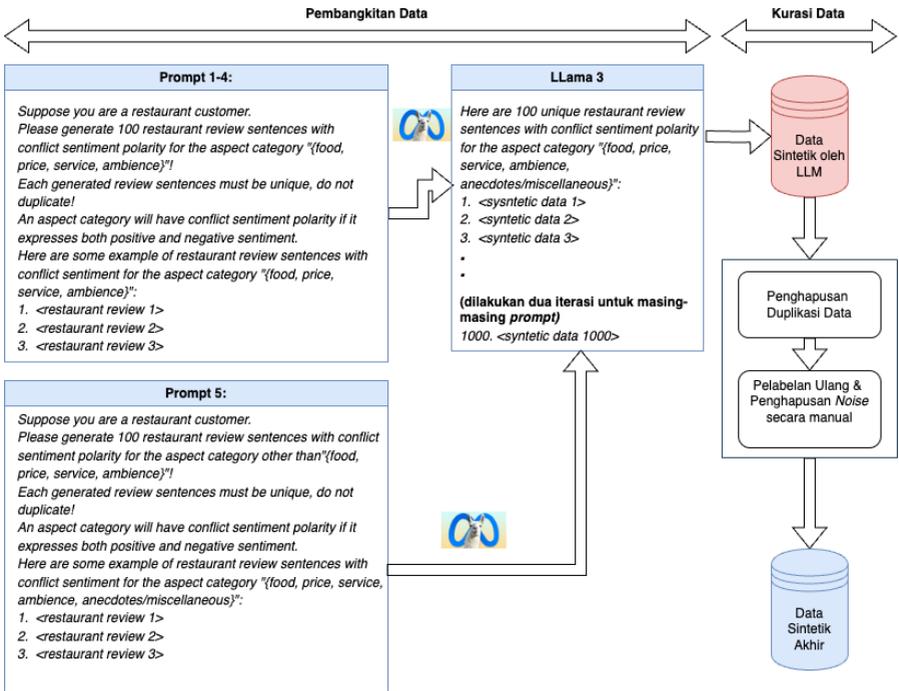
Label/sentimen	aspect_positive	aspect_negative	aspect_none
unrelated_aspect	0	0	1
neutral	0	0	0
negative	0	1	0
positive	1	0	0
conflict	1	1	0



Gambar 2 Arsitektur model BERT-kalimat semu dengan aspek multi-label

aspek dengan sentimen konflik dengan menggunakan Llama-3, yang merupakan sebuah LLM berbasis *open source* yang dikembangkan oleh Meta (Touvron dkk., 2023). Proses pembangkitan data sintetik dibagi menjadi dua tahap, yaitu tahap pembangkitan data (*data generation*) dan tahap kurasi data (*data curation*). Ilustrasi

untuk proses pembangkitan data sintetik dalam penelitian ini (untuk dataset dengan domain restoran) diberikan pada Gambar 3.



Gambar 3 Ilustrasi pembangkitan data sintetik

Pada tahap pembangkitan data (*data generation*), digunakan teknik *few-shot prompting* dengan tiga komponen yaitu spesifikasi tugas (*task specification*), kondisi pembangkitan data sintetik (*generation conditions*) dan contoh dalam konteks (*in-context demonstrations*). *Task specification* dimaksudkan untuk memberikan konteks yang sesuai untuk LLM dalam membuat data. Dalam *task specification* ini juga digunakan *role-playing* untuk menetapkan skenario yang tepat (?). *Generation conditions*, digunakan untuk menggambarkan jenis data spesifik yang diinginkan dan secara eksplisit serta langsung mengkomunikasikannya kepada LLM supaya membuat data yang beragam. Dan untuk *in-context demonstrations*, dalam penelitian ini disediakan tiga contoh dari dataset beranotasi (diambil dari dataset pelatihan

SemEval-2014) untuk memberikan panduan bagi LLM dalam membuat data yang akurat. Sedangkan pada tahap kurasi data (*data curation*), diterapkan dua jenis penyaringan yaitu (1) penghapusan duplikasi data dan (2) pelabelan ulang serta penghapusan *noise* secara manual.

4. Eksperimen, Hasil, dan Evaluasi

Untuk pembangkitan data sintetik, digunakan model Llama 3 dengan versi llama3-70b dan dijalankan melalui Groq AI Inference (<https://groq.com>). *Hyperparameter* yang digunakan adalah *temperature* yang diatur ke nilai 0.7 untuk mengatur tingkat keacakan (*randomness*) keluaran atau hasil dari model. Pada setiap *prompt* dibuat 100 kalimat untuk setiap kategori aspek dan proses pembangkitan data sintetik dijalankan dalam dua kali. Sehingga pada tahap pertama pembangkitan data sintetik (*data generation*) didapatkan sebanyak 1000 kalimat sintetik.

Dalam pembangkitan data sintetik dengan Llama 3 ini dibandingkan dengan Gemma dan Mixtral. Versi Gemma yang digunakan adalah gemma2-9b sedangkan versi Mixtral yang digunakan adalah mixtral-8x7b. Untuk melihat pengaruh komponen dan teknik *prompting* dalam pembangkitan data sintetik dengan LLMs, maka dilakukan eksperimen dengan berbagai skenario *prompting*. Diantaranya adalah teknik *3-shot* dibandingkan dengan *zero-shot*, *1-shot* dan *2-shot prompting*. Selain itu untuk melihat pengaruh skema *roleplay*, *prompt* dengan *roleplay* juga akan dibandingkan dengan *prompt* tanpa skema *roleplay*.

Untuk *fine-tuning* BERT, dilakukan pengaturan *hyperparameter* mengikuti pengaturan pada metode *baseline* (BERT-kalimat bantu) dengan beberapa modifikasi. Versi BERT yang digunakan adalah versi *pre-trained uncased* BERTBASE dengan jumlah blok transformer L=12, jumlah *hidden-layer* H=768, jumlah *self-attention* head A=12 dan total parameter=110M). *Learning rate* yang digunakan adalah $2e-5$, *dropout probability*=0.1, jumlah *epoch*=4, dan *cross entropy* sebagai *loss function*. Parameter *batch-size* yang digunakan adalah 12 dan *seed*=21, lebih rendah dari parameter yang digunakan oleh metode *baseline* untuk menyesuaikan ketersediaan infrastruktur.

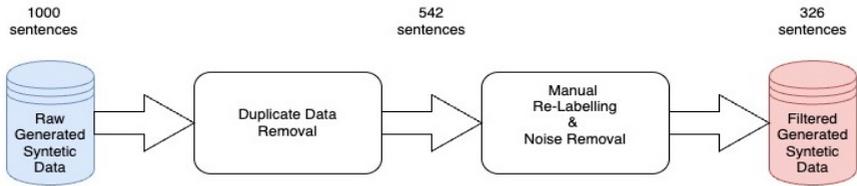
Infrastruktur yang digunakan untuk melakukan eksperimen adalah Google Colab Pro+ *version* untuk *fine-tuning* BERT dengan GPU versi A100 dan *memory* 40 GB, serta HPC-BRIN untuk pembangkitan data sintetik dengan versi GPU dan besar *memory* yang sama yaitu A100 dan *memory* 40 GB. Parameter evaluasi yang digunakan adalah Macro-F1 untuk *task* deteksi kategori aspek (*aspect category detection/ACD*) dan nilai akurasi untuk *task* klasifikasi sentimen kategori aspek (*aspect category sentiment analysis/ACSA*).

Evaluasi pada keberagaman data yang dihasilkan

Parameter yang digunakan untuk mengukur tingkat keberagaman atau *diversity* dari data sintetik yang dihasilkan oleh LLM dalam eksperimen ini adalah besar data akhir setelah proses pembangkitan dan kurasi data, serta ukuran kosakata (*vocabulary size*). Llama 3, meskipun memiliki potensi yang besar untuk dapat menghasilkan data sintetik berkualitas tinggi, namun data duplikasi yang dihasilkan juga cukup tinggi. Hal ini masih terjadi meskipun temperatur (*temperature*) pada *hyperparameter* sudah diatur dengan nilai yang relatif tinggi dan sudah dikomunikasikan langsung kepada Llama untuk menghasilkan data *unique* melalui *prompt*.

Eksperimen ini menggunakan temperatur 0,7 dan menggunakan teknik *3-shot prompting* dengan memberi tiga contoh kalimat bersentimen konflik yang diambil dari data latih SemEval-2014 domain restoran untuk setiap kategori aspek sebagai *in-context demonstration*. Pada kurasi data, penyaringan pertama atau penghapusan duplikasi data, dari 1000 data yang dibangkitkan oleh Llama, hanya diperoleh data *unique* sebesar 54,2% atau 542 kalimat. Setelah penyaringan yang kedua atau pelabelan ulang dan penghapusan *noise* hanya diperoleh data sebesar 32,6% atau 326 kalimat. Ilustrasi tahap kedua pembangkitan data sintetik, yaitu kurasi data (*data curation*), diberikan pada Gambar 4.

Hasil akhir dari proses pembangkitan data sintetik oleh Llama 3 ini yang kemudian ditambahkan ke data asli dari dataset SemEval-2014 untuk digunakan sebagai data latih pada proses *fine-tuning* model berbasis BERT dengan aspek multi-label yang telah diusulkan. Statistik data latih dari gabungan dataset asli dan data sintetik



Gambar 4 Ilustrasi proses kurasi data pada pembentukan data sintetik

diberikan pada Tabel 2. Setelah penambahan data sintetik, presentasi data aspek dengan label konflik meningkat menjadi 12,9%.

Tabel 2 Statistik dataset SemEval-2014 domain restoran

Dataset	Positif	Negatif	Netral	Konflik
Data latih awal: 3044 kalimat				
3712 kategori aspek	2176 (58,7%)	839 (22,6%)	501 (13,5%)	196 (5,3%)
Data latih baru: 3370 kalimat				
4038 kategori aspek	2176 (53,9%)	839 (20,8%)	501 (12,4%)	522 (12,9%)
Data uji: 800 kalimat				
1025 kategori aspek	657 (64,1%)	222 (21,7%)	94 (9,2%)	52 (5,1%)

Dibandingkan dengan Gemma dan Mixtral, Llama menghasilkan data akhir yang paling sedikit. Llama menghasilkan data akhir sebesar 32,6%, Gemma sebesar 57,2% dan Mixtral sebesar 51,3%. Demikian juga dengan ukuran kosakata (*vocabulary size*) yang dihasilkan, Llama menghasilkan *vocabulary size* paling kecil dibandingkan LLM lainnya yang digunakan dalam penelitian ini. Data akhir yang dihasilkan oleh Llama adalah 768, Gemma 1102 dan Mixtral 1003. *Vocabulary size* didefinisikan sebagai jumlah token *unique* yang terdapat dalam sebuah dataset. Besar ukuran *vocabulary* berbanding lurus dengan besar data akhir yang dihasilkan oleh

LLM. Perbandingan presentasi besar data akhir dan besar kosakata (*vocabulary size*) yang dihasilkan oleh Llama, Gemma dan Mixtral setelah melalui proses kurasi data ditampilkan pada Tabel 3.

Tabel 3 Perbandingan besar data akhir dan ukuran *vocabulary* yang dihasilkan oleh LLM

Model	Llama	Gemma	Mixtral
Data akhir yang dihasilkan (%)	32,6	57,2	51,3
Ukuran <i>vocabulary</i>	768	1102	1003

Untuk melihat hubungan antara keberagaman data, besar data akhir, besar kosakata (*vocabulary size*) dan bagaimana cara kerja Llama, Gemma, dan Mixtral dalam melakukan pembangkitan data sintetik, berikut ini ditampilkan contoh data sintetik yang dibuat oleh masing-masing LLM berbasis *open source* tersebut. Tabel 4 merupakan kalimat sintetik dengan aspek bersentimen konflik yang dibuat oleh Llama, Tabel 5 oleh Gemma, dan Tabel 6 oleh Mixtral untuk kategori aspek *food*. Tiga contoh kalimat yang digunakan dalam *prompt* sebagai *in context demonstration* adalah:

1. *The fish is fresh but the variety of fish is nothing out of ordinary.*
2. *The first time the sushi was outstanding, the second time it was a little bland.*
3. *Despite a slightly limited menu, everything prepared is done to perfection, ultra fresh and a work of food art.*

Contoh kalimat untuk *in-context demonstration* tersebut diambil dari data latihan SemEval-2014 domain restoran. Pemilihan tiga contoh kalimat tersebut berdasarkan pada bentuk kalimat dan pemilihan kata yang berbeda dengan tujuan untuk memberi panduan kepada LLM untuk membangkitkan kalimat yang bervariasi. Contoh kalimat (1) adalah kalimat dengan menggunakan *but* dan menggunakan kata aspek berbeda untuk klausa pertama dan kedua (*fish* dan *variety of fish*). Contoh kalimat (2) menggunakan kata aspek yang sama antara klausa pertama dan kedua, dan tanpa kata *but*. Contoh kalimat (3) menggunakan kata *despite* dan menggunakan

ungkapan yang kompleks untuk mengekspresikan sentimennya (yaitu pada klausa kedua menggunakan dua frase yang tidak sederhana ”*done to perfection*” dan ”*ultra fresh and a work*” untuk mengekspresikan bagian sentimen positifnya).

Tabel 4 Contoh data sintetik yang dihasilkan oleh Llama

No	Kalimat sintetik
1	The food was beautifully plated, but some dishes lacked texture.
2	The food was beautifully presented, but some dishes lacked depth of flavor.
3	The food was beautifully presented, but some dishes lacked flavor.
4	The food was expertly prepared, but the menu was too complicated.
5	The food was expertly prepared, but the menu was too limited.
6	The food was generally good, but the portion sizes varied greatly.
7	The food was generally good, but the wine list was limited.
8	The food was mostly delicious, but the wine list was limited.
9	The food was mostly excellent, except for the underwhelming dessert.
10	The food was mostly flavorful, but some dishes were overpowered by one ingredient.
11	The food was mostly flavorful, but some dishes were too spicy.
12	The food was mostly flavorful, but some dishes were too sweet.

Tabel 5 Contoh data sintetik yang dihasilkan oleh Gemma

No	Kalimat sintetik
1	The burger was cooked to my liking, but the fries were cold and soggy.
2	The burger was cooked to perfection, but the fries were cold and limp.
3	The burger was juicy and flavorful, but the bun was dry and crumbly.

5 lanjutan dari halaman sebelumnya

No	Kalimat sintetik
4	The burger was juicy and flavorful, but the bun was stale.
5	The burger was juicy and flavorful, but the bun was too dry.
6	The burger was juicy and flavorful, but the bun was too soft and fell apart.
7	The burger was juicy and flavorful, but the bun was too soft.
8	The burger was juicy and flavorful, but the buns were stale.
9	The burger was juicy and flavorful, but the cheese was not melted properly.
10	The burger was juicy and flavorful, but the fries were soggy.
11	The burger was juicy and flavorful, but the pickles were too sour.
12	The burger was juicy and flavorful, but the toppings were unimaginative.

Tabel 6 Contoh data sintetik yang dihasilkan oleh Mixtral

No	Kalimat sintetik
1	The restaurant has a great selection of appetizers, but they are too small.
2	The restaurant has a great selection of ballottines, but they are not the right size.
3	The restaurant has a great selection of beans, but they are not the right soak.
4	The restaurant has a great selection of beers, but they are not cold enough.
5	The restaurant has a great selection of braises, but they are not the right tenderness.
6	The restaurant has a great selection of bread, but it is served cold.
7	The restaurant has a great selection of casseroles, but they are not the right richness.

6 lanjutan dari halaman sebelumnya

No	Kalimat sintetik
8	The restaurant has a great selection of chasers, but they are too sweet.
9	The restaurant has a great selection of cheeses, but they are not served at the right temperature.
10	The restaurant has a great selection of chutneys, but they are not the right spiciness.
11	The restaurant has a great selection of cocktails, but they are too weak.
12	The restaurant has a great selection of coffees, but they are too strong.

Tabel 4, Tabel 5 dan Tabel 6 menunjukkan bahwa baik Llama, Gemma maupun Mixtral menggunakan pola yang sama untuk membangkitkan kalimat sintetik bersentimen konflik untuk kategori aspek *food* yaitu menggunakan kata hubung yang sama yaitu *but*. Untuk Llama, Gemma dan Mixtral, kalimat pertama diasumsikan sebagai kalimat pertama yang dibangkitkan oleh LLM, kemudian kalimat selanjutnya adalah hasil augmentasi dari kalimat pertama. Pada Tabel 4, Llama melakukan augmentasi kalimat (1) dengan mengganti kata *plated* dengan *presented* dan *texture* dengan *depth of flavor* untuk kalimat (2). Kemudian dari kalimat (2), Llama melakukan augmentasi dengan menghapus kata *depth of*. Sedangkan dari kalimat (3) menjadi kalimat (4) dilakukan dengan mengganti kata *complicated* menjadi *limited*. Llama dalam melakukan augmentasi data, menggunakan teknik augmentasi yang sama (misalnya menghapus kata, mengganti kata, dll) untuk menghasilkan kalimat dengan jumlah tidak lebih dari tiga kalimat.

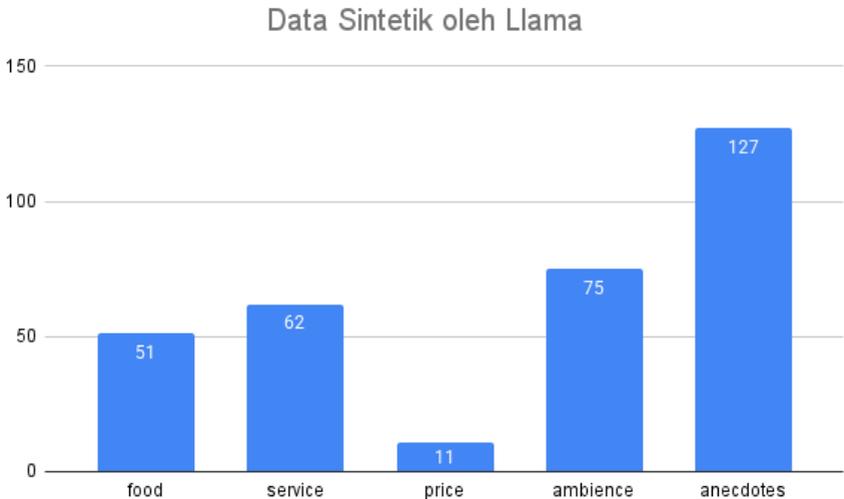
Contoh kalimat sintetik (1) dan (2) pada Tabel 5 menunjukkan bahwa Gemma melakukan augmentasi kalimat (1) dengan mengganti kata penanda sentimen *my liking* menjadi *perfection* pada klausa pertama untuk mengekspresikan sentimen positif dan *soggy* menjadi *limp* pada klausa kedua untuk mengekspresikan sentimen

negatif pada kalimat (2). Sedangkan pada contoh kalimat (3) sampai kalimat (7), Gemma menggunakan teknik penggantian kata penanda sentimen negatif pada klausa kedua. Gemma menggunakan teknik yang sama untuk melakukan augmentasi menjadi 5 kalimat. Contoh kalimat sintetik pada Tabel 6 menggunakan teknik mengganti kata aspek pada klausa pertama (kata *appetizer* menjadi *ballottines*, *beans*, *beers*, dll) dan kata penanda opini pada klausa kedua (dari *too small* menjadi *not the right*, *not cold enough*, *too weak*, *too strong*, dll). Mixtral menggunakan teknik yang sama untuk melakukan augmentasi menjadi lebih dari 5 kalimat. Llama melakukan augmentasi data, dengan teknik yang sama, dari satu kalimat menjadi maksimal tiga kalimat, sedangkan Gemma dan Mixtral melakukan augmentasi menjadi lebih dari tiga kalimat. Hal inilah yang membuat ukuran data akhir yang dihasilkan oleh Llama lebih kecil daripada yang dihasilkan oleh Gemma dan Mixtral.

Dalam pembangkitan data sintetis ini, untuk memperoleh data yang lebih beragam, digunakan satu *prompt* untuk satu kategori aspek. Dan khususnya untuk kategori aspek "*anecdotes/miscellaneous*" pada komponen "*generation conditions*" dalam *prompt* digunakan "*other than food, price, service, and ambience*" daripada menggunakan "*anecdotes/miscellaneous*" itu sendiri. Skenario ini dimaksudkan untuk memberikan panduan yang lebih jelas kepada Llama untuk membuat data pada domain restoran selain untuk aspek yang sudah disebutkan dalam *prompt* tersebut. Untuk kategori aspek "*anecdotes/miscellaneous*", Llama mampu menghasilkan data yang lebih beragam dibandingkan dengan data dari kategori aspek lainnya. Dari 326 data sintetis berkualitas tinggi yang dihasilkan oleh Llama, 127 nya adalah data dengan kategori aspek "*anecdotes/miscellaneous*."

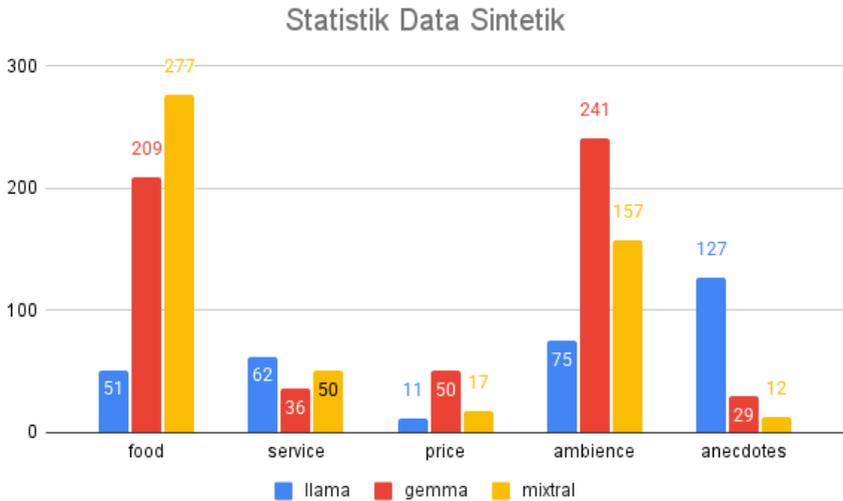
Data yang dihasilkan untuk kategori aspek "*price*" memiliki jumlah paling rendah yaitu hanya sebesar 11 dari total 326 data berkualitas tinggi yang dihasilkan oleh Llama, sedangkan untuk kategori aspek "*food*" sebesar 51, kategori aspek "*service*" sebesar 62, dan kategori aspek "*ambience*" sebesar 75. Perbandingan distribusi kategori aspek dengan yang sentimen konflik yang dihasilkan oleh Llama diberikan pada Gambar 6. Rendahnya jumlah data yang dihasilkan untuk kategori aspek "*price*" mungkin disebabkan karena terbatasnya jumlah komponen atau cara untuk

mendefinisikan aspek kategori “*price*” dan sentimennya. Aspek kategori “*price*” atau harga hanya dapat didefinisikan dengan kata-kata atau frase-frase yang mengekspresikan “mahal” atau “murah” saja. Hal ini berbeda dengan kategori aspek lainnya yang memiliki banyak komponen atau banyak cara untuk mendefinisikannya, seperti untuk kategori aspek “*food*” atau makanan dapat didefinisikan melalui berbagai jenis makanan, menu, porsi, dan lain-lain, dan sentimen untuk makanan dapat didefinisikan untuk mengekspresikan rasa, porsi, menu, penyajian makanan, dan lain-lain. Atau untuk kategori aspek “*ambience*” dapat didefinisikan melalui musik, tempat, lingkungan, dan lain lain.



Gambar 5 Distribusi data sintetik oleh Llama per kategori aspek

Namun distribusi data sintetik per kategori aspek yang dihasilkan oleh Llama berbeda dengan yang dihasilkan oleh Gemma dan Mixtral. Pada Gemma dan Mixtral, jumlah terbanyak adalah kalimat sintetik untuk kategori aspek *ambience* dan *food*. Perbandingan distribusi jumlah kalimat sintetik per kategori aspek yang dihasilkan oleh Llama, Gemma dan Mixtral diberikan pada Gambar 6.



Gambar 6 Distribusi data sintetik oleh Llama per kategori aspek

Evaluasi pada task klasifikasi sentimen empat kelas

Hasil eksperimen model yang diusulkan pada dataset SemEval-2014 domain restoran dirangkum dalam Tabel 7. Pada tabel hasil eksperimen tersebut, nilai tertinggi ditandai dengan angka yang dicetak tebal. Kinerja model yang diusulkan dibandingkan dengan model BERT-NLI-B (Sun et al., 2019) sebagai *baseline* untuk menunjukkan efektivitas aspek multi-label yang dirancang, selanjutnya ditampilkan sebagai ¹BERT-MLA (*BERT multi-label aspect*). Untuk menunjukkan signifikansi data sintetik yang dihasilkan oleh Llama 3, maka model yang diusulkan juga dibandingkan dengan metode augmentasi lain yaitu augmentasi data teks berbasis *embedding*, selanjutnya ditampilkan sebagai ²BERT-MLA-Emb (*BERT-MLA with embedding-based augmentation*) dan augmentasi data teks berbasis model bahasa yang telah dilatih sebelumnya (*pre-trained language models/PLMs*), selanjutnya ditampilkan sebagai ³BERT-MLA-PLM (*BERT-MLA with PLM-based augmentation*).

Dalam eksperimen ini, model BERT-NLI-B dan ¹BERT-MLA menggunakan dataset SemEval-2014 domain restoran, ²BERT-MLA-Emb dan ³BERT-MLA-PLM menggunakan dataset gabungan dari SemEval-2014 domain restoran dan dataset hasil augmentasi dari masing-masing metode, sedangkan ⁴BERT-MLA-Llama menggunakan dataset gabungan dari SemEval-2014 domain restoran dan dataset hasil pembangkitan data sintetik dengan Llama. Eksperimen tersebut sekaligus untuk mengukur kriteria *faithfulness* dari data sintetik yang dihasilkan oleh Llama, selanjutnya ditampilkan sebagai ⁴BERT-MLA-Llama (*BERT-MLA with Llama-based synthetic data*).

Tabel 7 Perbandingan kinerja model *baseline* dan model yang diusulkan

Model	P	R	F1	Accuracy (%)			
				Positif	Netral	Negatif	Konflik
BERT-NLI-B	0,929	0,893	0,911	85,39	53,19	69,82	36,54
BERT-MLA ¹	0,935	0,897	0,915	88,28	55,32	65,32	44,23
BERT-MLA-Emb ²	0,932	0,899	0,915	82,50	55,32	69,82	32,69
BERT-MLA-PLM ³	0,936	0,906	0,921	83,56	58,51	66,67	38,46
BERT-MLA-Llama ⁴	0,927	0,899	0,913	84,63	62,77	67,12	51,92

Tabel 7 menunjukkan bahwa pada *task* klasifikasi sentimen kategori aspek (*aspect category sentiment analysis/ACSA*), model BERT dengan aspek multilabel (BERT-MLA) yang diusulkan mampu mengungguli model *baseline* dalam perolehan nilai akurasi konflik label. Model BERT-MLA mampu meningkatkan akurasi label konflik sebesar 7,69% dibandingkan dengan model *baseline*. Hal ini menunjukkan bahwa perancangan aspek multi-label dan pembangkitan kalimat semu (*pseudo-sentence*) dari aspek, efektif dalam mengenali sentimen dengan kelas konflik pada ASBA. Selain itu, model yang diusulkan dengan penambahan data sintetik yang dihasilkan Llama untuk data latihnya (BERT-MLA-Llama) mencapai akurasi tertinggi untuk label konflik. Dengan menambahkan data sintetik untuk kelas sentimen konflik sebesar 326 kalimat (menjadikan presentasi kelas konflik dari 5,3% menjadi 12,9% dari total data latih), model yang diusulkan mampu meningkatkan akurasi untuk label konflik sebesar 15,38% dari *baseline* dan 7,69% dari model berbasis BERT dengan aspek multi-label tanpa penambahan data sintetik

pada pelatihan datanya (BERT-MLA). Hasil ini menunjukkan bahwa data sintetik berkualitas tinggi yang dihasilkan oleh Llama 3 memiliki potensi yang signifikan dalam menyediakan data dengan sumber daya rendah untuk mendukung pelatihan model. Namun untuk kelas sentimen negatif, model *baseline* mempunyai akurasi yang paling tinggi, sama dengan model BERT-MLA dengan penambahan data augmentasi menggunakan *embedding*.

Selain dilihat dari perolehan nilai P, R, F, dan akurasi, untuk melihat perbandingan distribusi prediksi benar dari masing-masing kelas sentimen, maka hasil evaluasi dari model BERT-MLA juga ditampilkan dalam bentuk matriks konfusi (*confusion matrix*). Matriks konfusi untuk model BERT-MLA ditampilkan pada Gambar 7.

		<u>kelas prediksi</u>				
		positive	neutral	negative	conflict	none
<u>kelas aktual</u>	positive	580	8	15	9	45
	neutral	21	52	10	1	10
	negative	19	17	145	11	30
	conflict	17	1	6	23	5
	none	35	26	11	3	2900

Gambar 7 Matriks konfusi untuk model BERT-MLA

Dibandingkan dengan teknik augmentasi data teks lainnya, yaitu augmentasi data berbasis *word embedding* dan augmentasi data berbasis PLMs, pembangkitan

data sintetik berbasis Llama mencapai kinerja tertinggi dalam mengenali sentimen konflik. Dalam eksperimen ini, penambahan data dengan teknik augmentasi berbasis *word embedding* pada model BERT-MLA menyebabkan akurasi pada sentimen konflik mengalami penurunan sebesar 11,54%, sementara dengan teknik augmentasi berbasis PLMs mengalami penurunan sebesar 5,77% dibandingkan akurasi pada model BERT-MLA tanpa penambahan data augmentasi. Augmentasi data teks berbasis *word embedding* dan PLMs berpengaruh negatif terhadap kinerja *task* klasifikasi. Hal tersebut disebabkan karena augmentasi data teks berbasis *word embedding* dan PLMs dapat menghasilkan sampel dengan pergeseran ruang fitur (*embedding space*) yang dapat mengubah klasifikasi sentimennya sehingga dapat menghasilkan kinerja yang lebih rendah pada *task* klasifikasi (?).

Namun untuk *task* deteksi kategori aspek (*aspect category detection/ACD*) model BERT-MLA dengan augmentasi data berbasis PLM mempunyai kinerja paling tinggi dibandingkan dengan model lainnya. Dalam penelitian ini, augmentasi data teks berbasis *embedding* dan PLM dilakukan pada kalimat-kalimat dengan aspek bersentimen konflik menjadi tiga kali lipat dari data yang ada pada SemEval-2014. Sehingga total data yang digunakan untuk training sebesar 3632 kalimat. Sedangkan pada model BERT-MLA dengan data sintetik berbasis Llama (BERT-MLA-Llama), total data training setelah penambahan data sintetik adalah 3370 kalimat. Dilihat dari banyaknya data total untuk training, ada hubungan antara besar data training dengan perolehan kinerja untuk *task* deteksi kategori aspek (*aspect category detection/ACD*). Pembahasan lebih lanjut mengenai hubungan besar data dengan perolehan kinerja untuk *task* ACD akan dibahas pada bagian selanjutnya.

Penambahan data sintetik yang dihasilkan oleh Llama pada model BERT-MLA, juga dibandingkan dengan penambahan data sintetik yang dibuat dengan LLMs *open source* lain yaitu Gemma dan Mixtral. Perbandingan hasil penambahan data sintetik berbasis LLMs *open source* pada dataset SemEval-2014 domain restoran untuk klasifikasi sentimen berbasis aspek empat-kelas oleh Llama, Gemma (yang dalam tabel disajikan sebagai BERT-MLA-Gemma⁵) dan Mixtral (yang disajikan sebagai BERT-MLA-Mixtral⁶) diberikan pada Tabel 8. Selain itu, perbandingan hasil penambahan

data sintetik dengan LLM juga disajikan dalam bentuk matriks konfusi. Gambar 8 menunjukkan matriks konfusi untuk model BERT-MLA-Llama, Gambar9 untuk model BERT-MLA-Gemma, dan Gambar 10 untuk BERT-MLA-Mixtral.

		<u>kelas prediksi</u>				
		positive	neutral	<u>negatif</u>	conflict	none
<u>kelas aktual</u>	positive	556	19	11	15	56
	neutral	21	56	7	0	10
	negatif	17	20	148	7	30
	conflict	10	2	6	27	7
	none	31	29	13	0	2902

Gambar 8 Matriks konfusi untuk model BERT-MLA-Llama

Untuk melihat pengaruh komponen *role-play* pada *prompt* diberikan perbandingan hasil dari skenario *prompt* tanpa *role-play* dan dengan *role-play* yang ditampilkan pada Tabel 9. Sedangkan untuk melihat perbandingan teknik *prompting*, dalam penelitian ini adalah *prompt* dengan dan tanpa *shot* atau contoh data real dan juga perbandingan banyaknya contoh data yang diberikan pada *prompt*, hasilnya disajikan pada Tabel 10.

Pada Tabel 8 dapat dilihat bahwa Llama 3 mampu mengungguli kinerja Gemma dan Mixtral untuk *task* klasifikasi sentimen kategori aspek (*aspect category sentiment analysis/ACSA*). Namun kinerja untuk *task* deteksi kategori aspek (*aspect*

		kelas prediksi				
		positive	neutral	negatif	conflict	none
kelas aktual	positive	548	22	14	20	53
	neutral	24	48	4	1	17
	negatif	12	19	156	7	28
	conflict	10	3	8	25	6
	none	28	28	13	1	2905

Gambar 9 Matriks konfusi untuk model BERT-MLA-Gemma

category detection/ACD) berada di bawah keduanya. Sebagaimana telah disinggung sebelumnya pada penjelasan Tabel 7, bahwa ada hubungan antara besarnya data dengan kinerja *task* deteksi kategori aspek (*aspect category detection/ACD*). Dalam hal ini, data sintetik yang dihasilkan oleh Llama adalah yang paling kecil dibandingkan dengan data yang dihasilkan oleh Gemma dan Mixtral, termasuk juga lebih kecil daripada data yang dihasilkan oleh proses augmentasi berbasis *embedding* dan PLM. Untuk penjelasan lebih lanjut, akan diberikan pada bagian selanjutnya tentang evaluasi terhadap keberagaman (*diversity*) data yang dihasilkan.

Tabel 9 menunjukkan bahwa penambahan skema *role-play* pada *prompt* (dalam penelitian ini *roleplay: Suppose you are a restaurant customer*) untuk pembangkitan data sintetik dengan Llama berpengaruh positif terhadap perolehan kinerja baik untuk *task* deteksi kategori aspek (*aspect category detection/ACD*) maupun klasifikasi sentimen kategori aspek (*aspect category sentiment analysis/ACSA*). Pada *task*

		kelas prediksi				
		positive	neutral	negatif	conflict	none
kelas aktual	positive	549	26	11	15	56
	neutral	15	59	4	1	15
	negatif	13	24	149	8	28
	conflict	18	1	7	20	6
	none	29	25	9	1	2911

Gambar 10 Matriks konfusi untuk model BERT-MLA-Mixtral

ACD, nilai F1 pada penggunaan skema *role-play* lebih tinggi dibandingkan dengan tanpa *role-play*. Pada *task* ACSA, perolehan akurasi klasifikasi sentimen konflik lebih tinggi daripada tanpa skema *role-play*.

Dari Tabel 10 dapat dilihat bahwa penambahan contoh dari data real sebagai *in-context demonstration* pada komponen *prompt* (*few-shot prompting*) mampu meningkatkan kinerja model, baik pada *task* ACD maupun ACSA. *Prompt* dengan contoh data real mempunyai kinerja yang lebih tinggi daripada *prompt* tanpa contoh data real (*zero-shot prompting*). Sedangkan untuk melihat pengaruh jumlah contoh data real atau *shot* dalam *prompt*, dalam penelitian ini hanya diberikan contoh data real sampai dengan maksimal tiga contoh saja untuk masing-masing kategori aspek. Dan hasil eksperimen menunjukkan bahwa ada kecenderungan peningkatan kinerja pada salah satu *task*, ACD atau ACSA. Semakin besar jumlah contoh data real yang

Tabel 8 Perbandingan kinerja Llama, Gemma, dan Mixtral

Model	P	R	F1	Accuracy (%)			
				Positif	Netral	Negatif	Konflik
BERT-MLA-Llama ⁴	0,927	0,899	0,913	84,63	59,57	66,67	51,92
BERT-MLA-Gemma ⁵	0,929	0,899	0,914	83,41	51,06	70,27	48,08
BERT-MLA-Mixtral ⁶	0,935	0,898	0,916	83,56	62,77	67,12	38,46

Tabel 9 Perbandingan skenario *prompting* pada Llama

Model	P	R	F1	Accuracy (%)			
				Positif	Netral	Negatif	Konflik
3-shot-non-roleplay	0,919	0,903	0,911	84,93	58,51	70,72	34,62
3-shot-roleplay	0,927	0,899	0,913	84,63	59,57	66,67	51,92

diberikan atau semakin besar jumlah *shot* nya, semakin tinggi juga perolehan nilai F1 untuk ACD atau nilai akurasi baik untuk sentimen konflik, namun tidak pada kedua *task* sekaligus. Sebagai contoh, hasil dari teknik *2-shot prompting* dibandingkan dengan hasil dari teknik *1-shot prompting*, terjadi penurunan akurasi sentimen konflik dengan akurasi kelas lainnya meningkat. Peningkatan terjadi pada kinerja untuk *task* ACD yaitu F1. Sedangkan hasil pada teknik *3-shot prompting* dibandingkan hasil pada *2-shot prompting* maupun *1-shot prompting*, penurunan terjadi pada kinerja ACD (nilai F1 turun) sedangkan kinerja ACSA mengalami peningkatan.

Perbedaan pola perolehan kinerja untuk *task* ACD dan ACSA tersebut diduga berhubungan dengan contoh kalimat dengan aspek bersentimen konflik yang diberikan pada *prompt*. Contoh kalimat yang dimaksud adalah apakah contoh kalimat yang diberikan bervariasi, apakah mempunyai pola dan struktur kalimat yang sederhana dan mudah dipahami, dan lain sebagainya. Untuk mendukung dan memastikan dugaan ini, maka perlu dilakukan eksperimen lebih lanjut dengan skenario penambahan contoh data real (jumlah *shot*) dan tipe kalimat dengan aspek bersentimen konflik yang diberikan pada komponen *in-context demonstration* untuk melihat dengan lebih pasti pengaruhnya terhadap kenaikan kinerja ACD maupun ACSA.

Tabel 10 Perbandingan teknik *prompting* pada Llama (dan jumlah *shot*)

Model	P	R	F1	Accuracy (%)			
				Positif	Netral	Negatif	Konflik
zero-shot	0,927	0,888	0,907	82,19	55,32	62,61	32,69
1-shot	0,929	0,899	0,914	83,40	51,06	70,27	48,08
2-shot	0,930	0,910	0,920	84,47	59,57	68,02	40,38
3-shot	0,927	0,899	0,913	84,63	59,57	66,67	51,92

5. Kesimpulan dan Saran

Dari hasil analisis dan evaluasi dari penelitian ini, penulis dapat menarik kesimpulan sebagai berikut:

1. Model yang diusulkan mampu mengungguli kinerja metode *baseline* dalam mengidentifikasi sentimen konflik pada analisis sentimen berbasis aspek. Hal tersebut dapat diraih karena dua hal yaitu perancangan aspek multi-label dan pembuatan data sintetik dengan Llama-3.
2. Aspek multi-label memungkinkan model mampu mengenali ungkapan kompleks dari sentimen konflik, sehingga perancangan aspek multi-label sebagai input untuk model berbasis BERT mampu mengidentifikasi sentimen konflik dalam analisis sentimen berbasis aspek secara efektif.
3. Data sintetik yang dihasilkan oleh Llama-3 mampu memberikan solusi terhadap keterbatasan dan ketidakseimbangan *dataset*. Hal ini menunjukkan bahwa pembuatan data sintetik dengan Llama-3 memiliki potensi yang besar untuk mengatasi masalah yang berhubungan dengan *dataset* dengan ketersediaan yang terbatas (*low resource dataset*).
4. Untuk memperoleh data sintetik yang berkualitas tinggi, maka selain diperlukan perancangan *prompt* yang teliti, juga diperlukan penyaringan data yang tepat juga karena data mentah hasil dari proses pembuatan data sintesis oleh Llama-3 masih disertai dengan data duplikasi yang cukup besar dan juga masih terdapat data yang berisi *noise* dan pelabelan yang salah.

Meskipun model yang diusulkan mampu menunjukkan hasil yang kompetitif dalam

mengidentifikasi sentimen konflik pada analisis sentimen berbasis aspek, namun model tersebut juga memiliki beberapa keterbatasan. Oleh karena itu, saran yang dapat bermanfaat untuk penelitian selanjutnya adalah sebagai berikut:

1. Mencari teknik untuk menangani masalah yang berkaitan dengan data bahwa kalimat yang mengandung aspek dengan sentimen konflik biasanya berupa kalimat yang panjang dan kompleks.
2. Sebagian besar kalimat dengan aspek bersentimen konflik menggunakan kata sambung *but* yang biasa digunakan untuk menghubungkan dua klausa yang saling bertentangan. Hal ini mungkin bisa dimanfaatkan untuk mengimplementasikan model berbasis aturan (*rule*) atau segmentasi kalimat yang dikombinasikan model yang telah diusulkan.
3. Melakukan evaluasi terhadap lebih banyak LLM dalam pembuatan data sintetik untuk mendukung penelitian dengan *dataset* bersumberdaya rendah, untuk mendapatkan perbandingan yang lebih baik.
4. Melakukan evaluasi model pada berbagai domain dan berbagai bahasa.
5. Selain itu, karena terbatasnya *dataset* publik untuk penelitian di bidang analisis sentimen berbasis aspek dengan polaritas sentimen empat-kelas ini, maka pengembangan *dataset* untuk menjadi *benchmark* baru dalam penelitian di bidang ini sangat dibutuhkan. Dengan kata lain, pembaharuan terhadap dataset SemEval-2014 untuk penelitian di bidang ASBA empat-kelas sangat diperlukan.

UCAPAN TERIMA KASIH

Penulis sangat berterima kasih kepada Dr. Ir. Rinaldi, M.T., Dr. Eng. Ayu Purwariyani, S.T., M.T. dan Dessi Puji Lestari, S.T., M, Eng., Ph.D, selaku Pembimbing yang telah meluangkan waktu dan memberikan arahan serta bimbingan untuk penelitian dan penulisan laporan disertasi ini. Juga kepada (Alm) Prof. Ir. Dwi Hendratmo Widyantoro, M.Sc., Ph.D., yang telah memberikan bimbingan, semangat, dan inspirasi kepada penulis pada masa awal studi dan masa awal penelitian ini.

Terima kasih juga kepada Badan Riset dan Inovasi Nasional (BRIN), yang sebelumnya adalah Lembaga Ilmu Pengetahuan Indonesia (LIPI) dan Program Sainstek Kemenristekdikti yang telah memberikan pendanaan dan dukungan dalam menempuh pendidikan ini.

Dan tidak lupa juga untuk orang tua, suami, anak-anak serta segenap keluarga yang telah memberikan cinta, pengertian serta mengijinkan dan mendukung penuh penulis dalam menempuh pendidikan ini.

Bandung, – Juni 2025

Penulis

RIWAYAT HIDUP

Kandidat Doktor Nuryani, dengan NIM 33219005, menamatkan pendidikan taman kanak-kanak di TK Pertiwi 38 Jetis pada tahun 1986, sekolah dasar di SDN Gatak Jetis pada tahun 1992, sekolah menengah pertama di SMP 1 Imogiri pada tahun 1995, dan sekolah menengah atas di SMA 8 Yogyakarta pada tahun 1998. Pada tahun 2003, Kandidat Doktor meraih gelar Sarjana Komputer (S.Kom) dari program studi Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), Universitas Gadjah Mada (UGM). Gelar Magister Teknik (M.T.) diperoleh dari jurusan Teknik Elektro, Sekolah Teknik Elektro dan Informatika (STEI), Institut Teknologi Bandung (ITB) pada tahun 2013.

Sejak April 2006, Kandidat Doktor bergabung sebagai peneliti di Pusat Penelitian Informatika, Lembaga Ilmu Pengetahuan Indonesia (LIPI), yang kemudian sejak 28 April 2021 bergabung menjadi Badan Riset dan Inovasi Nasional (BRIN).