

Analisis Sentimen Berbasis Fitur pada Ulasan Tempat Wisata Menggunakan Metode Convolutional Neural Network(CNN)

Ahmad Fathan Hidayatullah, Royan Abida N. Nayoan

Department of Informatics
Universitas Islam Indonesia, UII
Yogyakarta, Indonesia

e-mail: fathan@uii.ac.id, 15523084@students.uui.ac.id

Abstract— TripAdvisor merupakan salah satu aplikasi eWOM dengan pengunjung sebanyak 456 juta setiap bulannya. eWOM dapat memberikan wawasan kepada pengunjung mengenai apa yang mungkin mereka alami, sehingga mempermudah wisatawan untuk menentukan tempat tujuan wisata. Dengan kemudahan pengguna internet dalam membagikan penilaian baik ataupun buruk sebuah pariwisata dalam website TripAdvisor, dibuatlah penelitian ABSA (Aspect Based Sentiment Analysis) dengan memanfaatkan ulasan-ulasan tersebut. Penelitian ini bertujuan untuk mengimplementasikan sentimen analisis berbasis aspek dalam opini yang terdapat di TripAdvisor. ABSA akan mengolah serangkaian teks dari pengguna mengenai ulasan pariwisata yang dikunjungi dan mendeteksi aspek kategori beserta sentimen yang dibahas. ABSA dibangun menggunakan metode CNN, metode gabungan CNN dan LSTM, dan metode CNN dan GRU. Ekstraksi fitur dengan POS Tag dan negation handling digunakan untuk meningkatkan akurasi ABSA. Dari beberapa metode yang digunakan, CNN memberikan nilai akurasi tertinggi dengan akurasi sentimen sebesar 0.9085 dan akurasi aspek kategori mencapai 0.9569.

Keywords— Ekstraksi Fitur, Sentimen Analisis Berbasis Fitur, CNN, LSTM, GRU, POS Tag, Negation Handling

I. PENDAHULUAN

Saat ini kita sedang berada pada zaman dimana pertukaran data terjadi setiap saat dikarenakan pertumbuhan media sosial yang meledak-ledak, seperti, ulasan, diskusi forum, hingga blog. Tidak jarang individu maupun organisasi memanfaatkan ulasan dan opini dari pengguna di sosial media tersebut sebagai bahan pertimbangan untuk mengambil keputusan. Opini-opini dari pengguna lain atau orang yang ahli di bidang tertentu disebut dengan Word of Mouth(WOM) [1].

Berdasarkan data yang dihimpun dari WTTC, sektor pariwisata Indonesia telah menyumbang 13 juta lapangan kerja dan 6.0 % pemasukan pada Produk Domestik Bruto (PDB) Indonesia (WTTC, 2019). Wisatawan nusantara tercatat mengalami peningkatan setiap tahunnya hingga tahun 2017(KEMENPAR, 2018). Sebagai salah satu cara untuk mempromosikan destinasi Indonesia, Kementerian Pariwisata(KEMENPAR) merilis 100 Calendar of Events Wonderful 2019, dan menargetkan 275 juta kunjungan dari wisatawan nusantara di tahun ini (KOMINFO).

Indonesia dengan begitu banyak tempat wisata yang disediakan dari Sabang hingga Merauke, pastinya cukup sulit menentukan kemana akan berwisata dan berlibur. Banyak hal yang perlu dipertimbangkan dalam menentukan destinasi wisata, seperti layanan, lokasi, hingga biaya. Sebelum zaman digital, banyak orang mengandalkan ulasan dari WOM, namun dengan adanya website seperti TripAdvisor dapat menggantikan WOM dengan eWOM (Electronic Word of Mouth) yang lebih bisa dipercaya. Dengan banyaknya ulasan yang bermunculan ini, terutama dalam bidang pariwisata, tidak terbantahkan bahwa hal tersebut sangat berguna bagi traveler untuk merencanakan tempat wisata yang akan dikunjungi.

Ulasan pengguna online bisa dianggap sebagai sebuah bentuk dari eWOM karena mudahnya beropini maupun memberikan ulasan dalam menggunakan media sosial. TripAdvisor adalah salah satu aplikasi dengan pengunjung sebanyak 456 juta orang setiap bulannya, yang menerapkan eWOM dan memberikan wawasan kepada pengunjung mengenai apa yang mungkin mereka alami. Dalam mendapatkan sifat tak berwujud seperti pengalaman layanan, khususnya pariwisata, menyebabkan munculnya rasa takut akibat risiko dalam memilih penyedia layanan. Dengan adanya eWOM dapat meminimalkan risiko (risiko termasuk risiko fungsional, keuangan, psikologis, dan sosial) karena informasi ataupun ulasan yang diberikan pengguna independen dari pihak penyedia layanan [2].

Dengan kemudahan pengguna internet dalam membagikan penilaian baik ataupun buruk sebuah pariwisata dalam website TripAdvisor, dibuatlah penelitian ABSA (Aspect Based Sentiment Analysis) dengan memanfaatkan ulasan-ulasan tersebut. Penelitian ini bertujuan untuk mengimplementasikan sentimen analisis berbasis aspek dalam opini yang terdapat di TripAdvisor. ABSA akan mengolah serangkaian teks dari pengguna mengenai ulasan pariwisata yang dikunjungi dan mendeteksi aspek kategori beserta sentimen yang dibahas. Dengan demikian, sistem diharapkan akan sangat berguna bagi traveler untuk memilih tempat wisata yang diinginkan.

II. PENELITIAN TERKAIT

Bagian ini menjelaskan mengenai penelitian terkait untuk menjadi bahan acuan penelitian. Penelitian pertama dilakukan oleh Mubarak et al [3] yaitu sentimen analisis berbasis fitur

terhadap review produk online. Penelitian ini menggunakan pemilihan ekstraksi menggunakan Chi Square untuk memilih subset dengan kata yang relevan untuk digunakan pada model Naive Bayes. Hasil F1-measure pada model yang dibuat yaitu 78.12%. F1-measure yang didapatkan aspek menggunakan model Naive Bayes sebesar 88.13%, sedangkan F1-measure klasifikasi sentimen sebesar 75%. Li [4] membangun sebuah Pseudo Label Based Dataless Naive Bayes (PL-DNB) sebagai algoritma klasifikasi. PL-DNB dapat melatih data yang belum terlabeli menggunakan *seed words*. PL-DNB kemudian digunakan pada 2 data yang berbeda, data seimbang dan tidak seimbang. Selain itu PL-DNB juga dibandingkan dengan 4 metode lain yaitu Seed-Word Based Naive Bayes(SNB), Seed-guided Topic Modeling(STM), Naive Bayes(NB), dan Support Vector Machines(SVM). Hasilnya, PL-DNB mengungguli algoritma klasifikasi lain dan memiliki performa terbaik pada klasifikasi dataset yang tidak seimbang. Gozali [5] melakukan penelitian sentimen analisis berbasis fitur yang bertujuan untuk mendapatkan aspek dan sentimen pada ulasan ponsel. Data ulasan ponsel berbahasa Inggris diambil dari www.cnet.com. Pada tahap ekstraksi fitur digunakan template dependency relation dengan frasa yang sesuai, yang kemudian diikuti dengan penyaringan fitur. Pada tahap evaluasi didapatkan F1 Measure sebesar 86.25% untuk kelas positif dan 77.71% pada kelas negatif. Sedangkan untuk akurasi identifikasi aspek sebesar 82%.

Hughes et al [6] memanfaatkan CNN sebagai pendekatan untuk melakukan klasifikasi teks pada level kalimat berdasarkan semantik yang sering muncul dari ekstraksi korpus teks medis. Dilakukan perbandingan menggunakan 3 metode lainnya, yaitu : Sentence Embeddings, Mean Word Embeddings, dan Word Embeddings dengan BOW(bag-of-words). Dari evaluasi yang dilakukan secara mendetil pada setiap metode, metode CNN yang digunakan pada penelitian ini lebih baik dalam melkaukan klasifikasi dari pendekatan NLP dengan metode lain sebanyak 15%. Xue et al [7] merangkum pendekatan Gated Convolutional Networks ke dalam dua subtugas: sentimen kategori-aspek analisis (ACSA) dan analisis sentimen istilah-aspek (ATSA). Dua subtugas tersebut menggunakan model Gated Convolutional network with Aspect Embedding (GCAE). Gated Tanh-ReLU Units dapat memilih output fitur sentimen bergantung pada aspek ataupun entitas yang diberikan. Dengan digunakannya GTRU dapat secara efektif mengontrol aliran sentimen bergantung pada aspek yang diberikan. Model ini dibuat berdasarkan metode CNN dan mekanisme penggerbangan(gating) yang lebih akurat dan efisien. Model yang diaplikasikan pada dataset SemEval ini terbukti mampu menaikkan performa dibandingkan dengan metode neural network lainnya.


III. METODE

Beberapa metode yang digunakan untuk mendapatkan model sentimen analisis berbasis fitur terbaik yaitu metode CNN dan beberapa kombinasi metode CNN dengan metode lain. Pada kasus ini digunakan metode kombinasi CNN + LSTM dan CNN + GRU.

A. Convolutional Neural Network (CNN)


Convolutional neural network (CNN), adalah sebuah kelas dari jaringan syaraf tiruan yang telah dominan digunakan pada tugas visi komputer. CNN adalah sebuah konstruk matematika yang biasanya disusun oleh 3 tipe layer, yaitu convolution, pooling, dan layer yang sepenuhnya terhubung. Dua layer pertama, convolution dan pooling melakukan ekstraksi fitur, sedangkan layer ketiga, menempatkan fitur yang terekstraksi menjadi hasil akhir keluaran, seperti klasifikasi.

Konvolusi adalah sebuah tipe operasi linier khusus yang digunakan untuk ekstraksi fitur, dimana sebuah array angka, yang disebut kernel diimplementasikan pada masukan, yang merupakan array angka yang disebut tensor. Kalkulasi yang ditunjukkan pada Gambar 1 dilakukan pada masing-masing elemen matriks kernel dan masukan tensor dan dijumlahkan untuk mendapatkan keluaran yang disebut dengan feature map. Tahap ini dilakukan berulang hingga didapatkan feature map yang merepresentasikan karakteristik dari masukan tensor. Oleh karena itu, kernel dengan ukuran lain bisa memiliki hasil ekstraksi yang berbeda pula. Biasanya, kernel yang digunakan berukuran ganjil seperti array 3x3, namun bisa juga disusun oleh 5x5 atau 7x7.



Gambar 1 Contoh operasi konvolusi dengan kernel 3 x 3


Pooling disebut juga dengan penurunan sample(downsampling) yang mengurangi dimensionalitas bidang namun tetap menjaga informasi yang penting. Operasi pooling yang sering digunakan yaitu max pooling, dimana operasi ini mampu melakukan ekstraksi dari filter masukan feature maps, kemudian memilih nilai tertinggi di setiap filter dan membuang nilai lainnya. Operasi max pooling dapat dilihat pada Gambar 2. Filter 2x2 dengan stride 2 sering digunakan untuk melakukan max pooling.



Gambar 2 Contoh max pooling dengan filter 2x2 dan stride 2


Pooling memiliki beberapa jenis, pada kasus ini digunakan 1D global max pooling. 1D Global max pooling mengambil sebuah vektor dan menghitung nilai maksimum dari semua nilai untuk masing-masing saluran input. Pada Gambar 3

menampilkan pengambilan vektor dengan menggunakan 1D global max pooling.



Gambar 3 Contoh pengambilan vektor 1D global max pooling

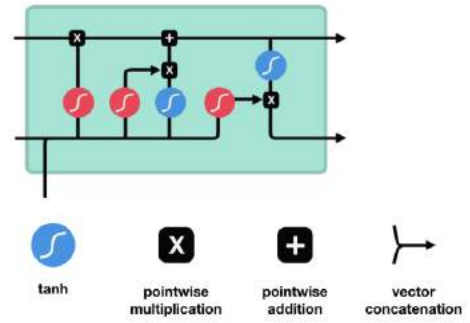
Layer FC yaitu lapisan neuron yang terhubung sepenuhnya. Seluruh neuron pada lapisan FC memiliki hubungan dengan seluruh aktivasi pada lapisan sebelumnya. Lapisan ini ditempatkan sebelum hasil klasifikasi CNN. Keluaran feature maps dari konvolusi akhir atau layer pooling biasanya flattened seperti diubah menjadi satu dimensi angka/vector array dan dihubungkan ke satu/lebih layer yang terhubung sempurna (FC) atau disebut juga dense layer yang ditunjukkan oleh Gambar 4, dimana setiap masukan yang terhubung ke setiap keluaran memiliki bobot. Setelah melalui ekstraksi fitur pada layer konvolusi dan dilakukan penurunan sample pada layer pooling, lalu keluaran dipetakan oleh FC layer menjadi keluaran akhir jaringan, seperti probabilitas setiap kelas pada tugas klasifikasi. Hasil akhir FC layer biasanya memiliki jumlah node yang sama dengan jumlah kelasnya.



Gambar 4 FC Layer

B. Long-Short Term Memory (LSTM)

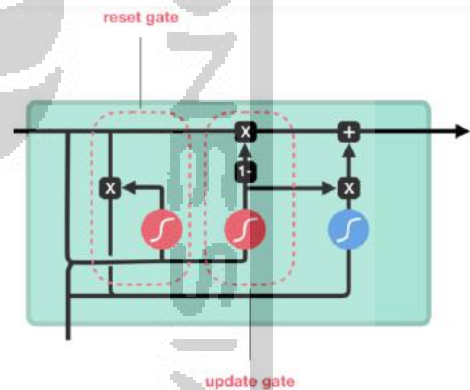
RNN bersamaan dengan LSTM telah dianggap sebagai model yang efektif untuk beberapa masalah pembelajaran terkait dengan data sekuensial [8]. Unit LSTM umumnya terdiri dari sel, gerbang input, gerbang keluaran dan gerbang lupa. Sel akan mengingat nilai selama interval waktu yang berubah-ubah dan tiga gerbang lupa lainnya mengatur aliran informasi masuk dan keluar dari sel. Gerbang lupa menentukan informasi mana yang harus dibuang atau disimpan. Untuk melakukan pembaruan sel digunakan gerbang input. Gerbang keluaran akan menentukan hidden state berikutnya [9]. Berikut pada Gambar 5 merupakan gambaran dari LSTM sel.



Gambar 5 LSTM sel

C. Gated Recurrent Unit (GRU)

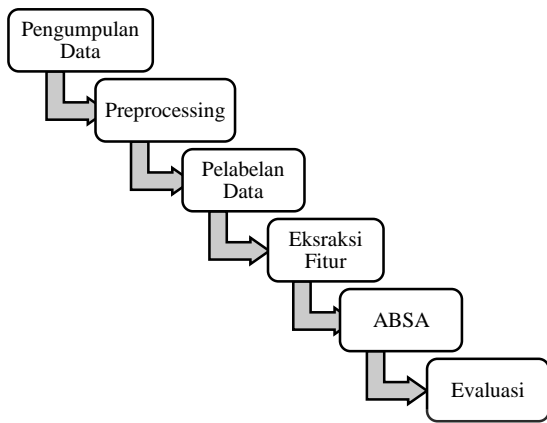
Pada GRU, hanya terdapat 2 gate yang digunakan, reset gate(gerbang pengulang) dan update gate(gerbang pembaharuan). Karena GRU merupakan generasi terbaru dari LSTM sehingga metode ini juga tidak terlalu berbeda dengan LSTM. Pada gerbang pengulang, terjadi proses yang sama seperti yang terjadi pada forget gate dan juga input gate. Gerbang ini akan memilih informasi mana yang harus disimpan atau harus dibuang. Sedangkan pada gerbang pembaharuan merupakan gerbang lain yang digunakan untuk menentukan seberapa banyak data yang perlu dilupakan/dibuang. Pada Gambar 6 di bawah ini merupakan gambaran dari sel dan gate yang ada pada metode GRU [9].



Gambar 6 sel dan gate GRU

IV. METODOLOGI PENELITIAN

Berikut ini merupakan langkah-langkah yang digunakan dalam mengerjakan Analisis Sentimen Berbasis Fitur. Langkah-langkah pengerjaan tugas akhir ini diawali dengan pengumpulan data, kemudian diikuti preprocessing, pelabelan data, ABSA, dan diakhiri dengan evaluasi. Pada Gambar 7 di bawah ini menunjukkan langkah-langkah ABSA.



Gambar 7 Langkah-langkah penelitian

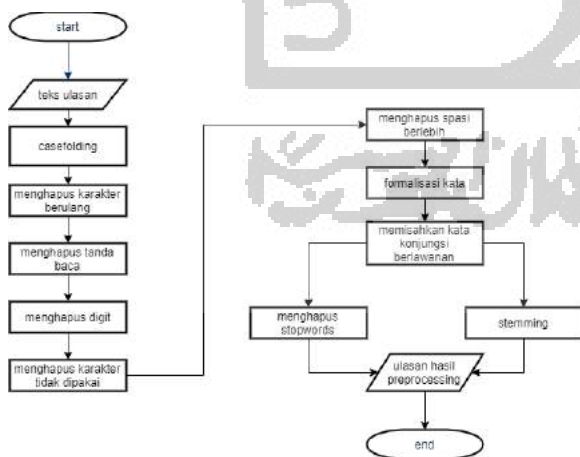
A. Pengumpulan Data

Pengumpulan data dilakukan dengan mengambil ulasan dari situs TripAdvisor (tripadvisor.co.id) dan menyimpan data tersebut dalam file berekstensi .csv. Data diambil secara acak pada pariwisata di seluruh Indonesia. Setelah data didapatkan, maka data dipisahkan menjadi kalimat-kalimat untuk diolah selanjutnya. Data ulasan akan digunakan sebagai data training untuk pembuatan model dan data testing untuk melihat hasil akhir dari klasifikasi dan uji akurasi.

B. Preprocessing

Preprocessing termasuk langkah yang krusial untuk dilakukan karena pada langkah ini akan dilakukan penghapusan kata ataupun simbol yang tidak diperlukan pada kalimat ulasan yang diberikan. Bentuk preprocessing yang dilakukan antara lain casefolding, menghapus karakter berulang, menghapus tanda baca, menghapus digit, menghapus karakter tidak dipakai, menghapus spasi berlebih, formalisasi kata, memisahkan kata konjungsi berlawanan, menghapus stopwords dan stemming.

Pada proses ini harus dilakukan secara berurutan dan tidak bisa dilakukan secara acak, oleh karena itu, susunan preprocessing pada setiap kasus memiliki susunan yang berbeda bergantung dengan kebutuhan pembersihan data pada data yang dimiliki. Pada Gambar 8 dibawah ini merupakan susunan preprocessing yang digunakan pada kasus ABSA pariwisata.



Gambar 8 Urutan langkah pembersihan data

C. Pelabelan Data

Pelabelan dilakukan pada data training setelah data berhasil didapatkan. Pelabelan data yang diperlukan yaitu pelabelan sentimen dan juga aspek kategori. Pelabelan sentimen ulasan dibagi menjadi 2, positif dan negatif. Sedangkan pelabelan aspek kategori dibagi menjadi lokasi, fasilitas, serbaneka, dan suasana. Metode yang digunakan untuk melakukan pelabelan data yaitu pseudo-labeling, yaitu memanfaatkan sejumlah data untuk memprediksi data lain yang belum terlabeli. Sebuah jaringan dilatih secara terawasi (supervised) menggunakan dataset baru tersebut secara bersamaan. Data yang belum terlabeli (pseudo-label) memilih kelas yang memiliki probabilitas prediksi tertinggi di setiap pembaruan bobot, kemudian hasil kelas tertinggi akan digunakan layaknya label aslinya [10].

Data label yang digunakan untuk melatih model pseudo berjumlah 1000 data yang dilabeli secara manual. Setiap data tersebut memiliki satu label aspek, dan satu label sentimen. Jumlah data pada setiap label tidak sama, sehingga data pada 1000 data di atas imbalance (tidak berimbang), maka dari itu dilakukan teknik oversampling untuk membuat data pada setiap kelas seimbang. Model ini menggunakan metode CNN untuk mendapatkan pseudo-label.

D. Ekstraksi Fitur

Pada tahap ini dilakukan ekstraksi fitur menggunakan negation handling dan POS tagging. Negation Handling yaitu menggabungkan kata yang didalamnya mengandung salah satu kata “tidak”, “kurang”, “jangan”, atau “bukan” yang diikuti oleh kata berikutnya.

POS tagging (part-of-speech tagging) yaitu proses untuk menandai kata-kata dalam sebuah teks/korpus sesuai dengan bagian tertentu dari pembicaraan, berdasarkan definisi dan konteksnya. Dengan POS Tagging ini dapat mengkategorikan kelas kata menjadi kata benda, kata sifat, kata kerja, dll [11]. Ekstraksi fitur dilakukan untuk masing-masing aspek dan sentimen. Pada ekstraksi sentimen, digunakan tag VB, NEG, dan JJ. Sedangkan pada ekstraksi aspek digunakan tag NN VB, dan NNP.

E. Aspect Based Sentiment Analysis (ABSA)

Pada metode CNN digunakan beberapa layer, yaitu embedding, konvolusi, pooling, dan lapisan dense atau fully connected (FC) layer. Lapisan embedding digunakan untuk memberikan representasi kata yang padat dan makna relatifnya. Embedding akan memetakan setiap kata menjadi ruang vektor berkelanjutan sehingga membuat sebuah kosa kata yang berkelanjutan dan terdistribusi. Lapisan konvolusi digunakan untuk ekstraksi fitur. Didalamnya dilakukan perhitungan untuk mendapatkan keluaran yang disebut dengan feature map, sehingga didapatkan feature map yang merepresentasikan karakteristik masukan. Lapisan pooling secara progresif mengurangi ukuran spasial dari representasi untuk mengurangi jumlah parameter dan perhitungan dalam jaringan. Lapisan FC berperan sebagai lapisan keluaran dari jaringan syaraf tiruan.

F. Evaluasi

Evaluasi dilakukan dengan menggunakan metode hold-out dan confusion matrix. Metode hold-out membagi data kedalam 2 bagian yakni data latih dan data uji. Data latih digunakan untuk

melatih model. Data validasi digunakan untuk melihat seberapa baik performa model. Confusion matrix biasa digunakan untuk mengukur kinerja suatu algoritma klasifikasi.

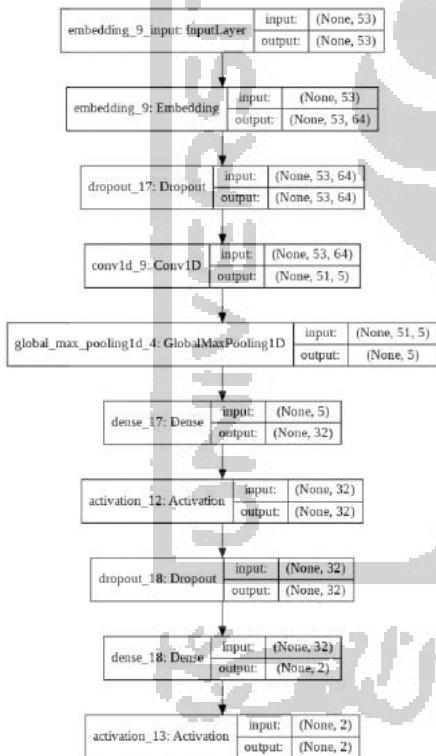
V. HASIL DAN PEMBAHASAN

A. Arsitektur Model

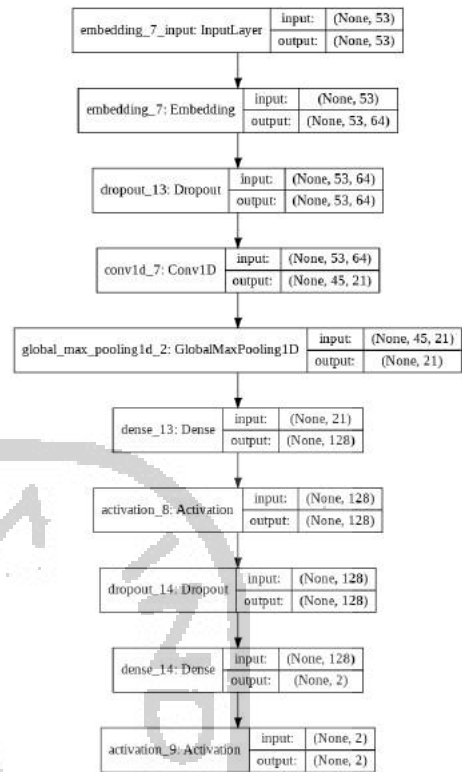
Dalam membuat model CNN untuk mendapatkan hasil terbaik ditambahkan 2 model berbeda yaitu CNN + LSTM dan CNN + GRU. Seluruh model skenario yang digunakan menggunakan 64 *embedding dimentions*, 64 *batch size* dan memanfaatkan *early stopping* dengan memonitor nilai *val_loss*. Untuk mengatasi *overfitting*, digunakan juga teknik *dropout*. Pada TABEL 1 merupakan skenario model sentimen analisis berbasis fitur. Berikut pada Gambar 9, Gambar 10, Gambar 11, dan Gambar 12 merupakan arsitektur model dari skenario yang sudah disiapkan.

TABEL 1. SKENARIO MODEL SENTIMEN ANALISIS BERBASIS FITUR

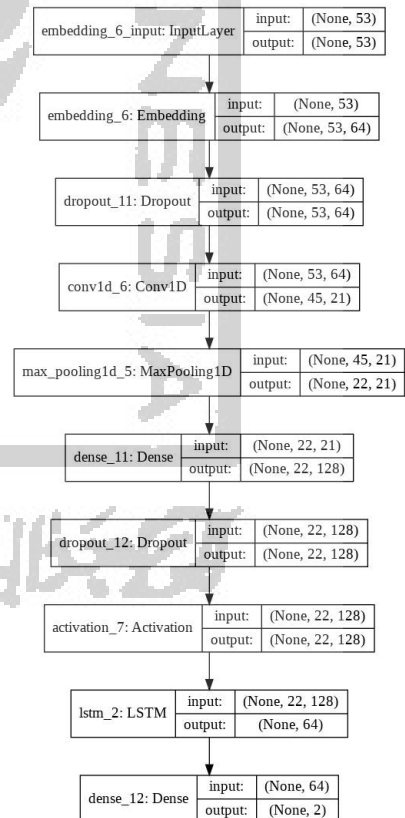
Skenario	Model	Metode	Kernel	Filter	Hidden_Dims	Dropout	Unit
1	M1	CNN	3	5	32	0.2	
	M2		9	21	128	0.2	
	M3		9	21	128	0.5	
2	M4	CNN +	9	21	128	0.5	64
	M5	LSTM	9	21	128	0.2	64
3	M6	CNN +	9	21	128	0.5	64
	M7	GRU	9	21	128	0.2	64



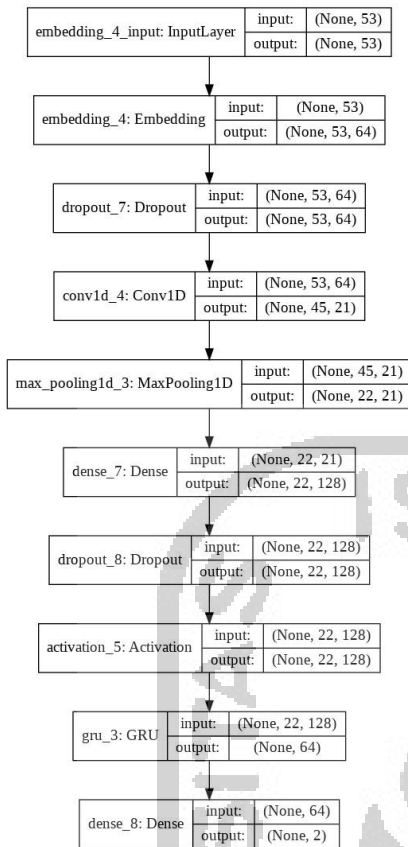
Gambar 9 Arsitektur M1



Gambar 10 Arsitektur M2 & M3



Gambar 11 Arsitektur Skenario 2



Gambar 12 Arsitektur Skenario 3

B. Hasil Performa Model

Pelatihan data yang dilakukan pada setiap skenario dilakukan dengan menggunakan metode *hold-out* dengan membagi dataset menjadi data uji sebesar 0.33. Pada TABEL 2 merupakan hasil akurasi, presisi, dan recall dari skenario sentimen. Dari beberapa skenario dan model yang digunakan, skenario 1 dengan M2 memiliki nilai akurasi tertinggi yaitu sebesar 0.9085, dengan presisi sebesar 0.9078 dan Recall 0.8915.

TABEL 2 HASIL ACCURACY, PRECISION, RECALL SKENARIO SENTIMEN


Skenario	Model	Epochs	Accuracy	Precision	Recall	Unit
1	M1	16	0.8883	0.8876	0.8915	
	M2	16	0.9085	0.9078	0.9111	
	M3	23	0.8730	0.8723	0.8772	
2	M4	16	0.7801	0.7815	0.7941	16
	M5	26	0.7771	0.7785	0.7902	26
3	M6	17	0.7836	0.7849	0.7951	17
	M7	29	0.7786	0.78	0.7921	29

Sedangkan pada TABEL 3 merupakan hasil akurasi, presisi, dan recall skenario aspek. Dari beberapa model yang digunakan, skenario 1 dengan M2 memiliki nilai akurasi tertinggi sebesar 0.9569, presisi 0.9568, dan recall sebesar 0.9567.

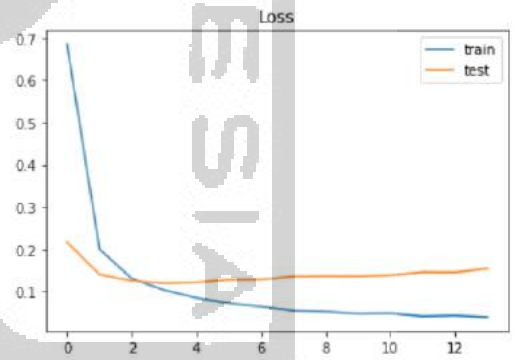
TABEL 3 HASIL ACCURACY, PRECISION, RECALL SKENARIO ASPEK

Skenario	Model	Epochs	Accuracy	Precision	Recall	Unit
1	M1	16	0.9308	0.9307	0.9318	
	M2	13	0.9569	0.9568	0.9567	
	M3	15	0.9524	0.9525	0.9533	
2	M4	23	0.9502	0.950	0.9506	23
	M5	15	0.9476	0.9478	0.9479	15
3	M6	12	0.9535	0.9534	0.9539	12
	M7	16	0.9502	0.9502	0.9501	16

Pada seluruh skenario diterapkan dropout layer agar dapat mengurangi overfitting ketika pelatihan data. Dari beberapa skenario aspek kategori dan sentimen, model M2 merupakan model yang memiliki akurasi tertinggi dibandingkan M3. M2 dengan dropout 0.2 memiliki loss 0.224, sedangkan M3 dengan dropout 0.5 memiliki loss 0.151. Pada Gambar 13 dan Gambar 14 merupakan loss pada model Aspek M2 dan Aspek M3.




Gambar 13 Loss M2 aspek dengan dropout 0.2



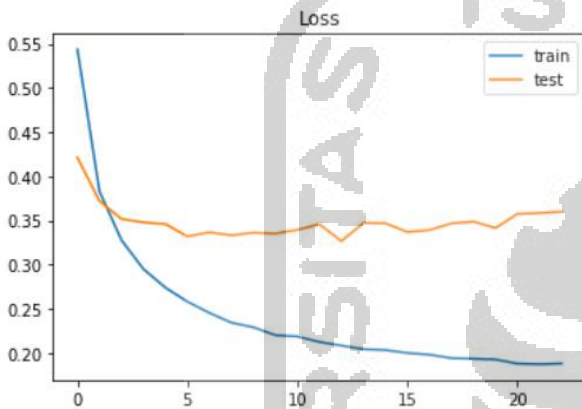
Gambar 14 Loss M3 aspek dengan dropout 0.5

Untuk sentimen, M2 dengan dropout 0.2 memiliki loss 0.379, sedangkan M3 dengan dropout 0.5 memiliki loss 0.364. Pada Gambar 15 dan Gambar 16 merupakan loss pada model Sentimen M2 dan Sentimen M3.

Dari kedua dropout yang digunakan, menunjukkan bahwa model sentimen maupun aspek kategori dengan dropout 0.5 memiliki nilai loss yang cukup rendah dibandingkan dengan nilai dropout 0.2.



Gambar 15 Loss M2 sentimen dengan dropout 0.2



Gambar 16 Loss M3 sentimen dengan dropout 0.5

VI. KESIMPULAN

Berdasarkan dari penelitian ini, maka dapat disimpulkan bahwa :

1. Dari beberapa model CNN, CNN + LSTM, dan CNN + GRU menunjukkan bahwa model CNN memberikan nilai akurasi

tertinggi dengan akurasi sentimen sebesar 0.9085 dan akurasi aspek kategori sebesar 0.9569. Model CNN tersusun dari embedding layer, dropout layer, convolution layer, pooling layer, dan FC layer.

2. Penerapan model CNN dengan menggunakan fitur ekstraksi dengan POS Tag dan negation handling terbukti membantu dalam mendapatkan sentimen dan aspek kategori ulasan pariwisata.

REFERENSI

- [1] Goldsmith, R, 2008, *Electronic Word-of-Mouth, E-commerce*, Idea Group ReferenceGlobal, Florida J. Clerk Maxwell, A Treatise on Electricity and Magnetism, 3rd ed., vol. 2. Oxford: Clarendon, 1892, pp.68-73.
- [2] Fodness, D., & Murray, B. (1997). Tourist information search. *Annals of Tourism Research*, 24(3), 503–523. [https://doi.org/10.1016/S0160-7383\(97\)00009-1](https://doi.org/10.1016/S0160-7383(97)00009-1). Elissa, "Title of paper if known," unpublished.
- [3] Mubarak, M. S., Adiwijaya, A., & Aldhi, M. D. (2017). Aspect-based sentiment analysis to review products using Naïve Bayes. *AIP Conference Proceedings*, 1867(August). <https://doi.org/10.1063/1.4994463>
- [4] Li, X. (2018). A Pseudo Label based Dataless Naive Bayes Algorithm for Text Classification with Seed Words. 1908–1917.
- [5] Gozali, A. A. (2017). ELECTRONIC PRODUCT FEATURE-BASED SENTIMENT ANALYSIS USING NU-SVM METHOD. (October). <https://doi.org/10.21108/IJOICT.2015.11.4>
- [6] Hughes, M., Li, I., Kotoulas, S., & Suzumura, T. (2017). Medical Text Classification using Convolutional Neural Networks.
- [7] Xue, W., & Li, T. (2018). Aspect Based Sentiment Analysis with Gated Convolutional Networks. 2514–2523.
- [8] Greff, K., Srivastava, R. K., Koutn, J., & Steunebrink, B. R. (n.d.). LSTM : A Search Space Odyssey. 1–12. <https://doi.org/10.1109/TNNLS.2016.2582924>
- [9] Nguyen, M. (2018). Illustrated Guide to LSTM's and GRU's: A step by step explanation. Retrieved September 10, 2019, from <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9cb85bf21>
- [10] Lee, D. (2013). Pseudo-Label: The Simple and Efficient Semi-Supervised Learning Method for Deep Neural Networks.
- [11] Kumawat, D. (2015). POS Tagging Approaches : A Comparison. 118(6), 32–38.