

Peringkasan Multi Dokumen Berbahasa Indonesia Menggunakan Metode *Recurrent Neural Network* *Multi-Document Summarization for Indonesian Document Using Recurrent Neural Network*

Moh Alfin¹, Zainal Abidin², Puspa Miladin³

^{1,2,3}Program Studi Teknik Informatika, Universitas Islam Negeri Maulana Malik Ibrahim
Malang

E-mail: ¹19650024@student-uin-malang.ac.id, ²zainal@ti.uin-malang.ac.id,
³puspa.miladin@uin-malang.ac.id

Abstrak

Peringkasan dokumen berita adalah sebuah aspek penting dalam pemrosesan bahasa alami dan jurnal ini bertujuan untuk menggambarkan perkembangan terbaru dalam bidang ini. Dengan ledakan informasi dan jumlah berita yang terus meningkat, peringkasan dokumen berita menjadi kunci dalam menghadapi tantangan untuk mengakses informasi yang relevan dan berharga. Pada paper ini dilakukan peringkasan multi dokumen berbahasa Indonesia dengan menggunakan metode RNN (Recurrent Neural Network) variasi yang digunakan adalah Long Short-Term Memory (LSTM), dengan ekstraksi fitur menggunakan dua model Word2Vec yang berbeda, yaitu CBOW (Continuous Bag of Words) dan Skip-gram. Hasilnya menunjukkan nilai recall, presisi, dan F-measure yang signifikan. Untuk model CBOW, nilai recall, presisi, dan F-measure yang ditemukan adalah 0.487, 0.704, dan 0.550. Sementara itu, untuk model Skip-gram, hasil pengujian menunjukkan nilai recall sebesar 0.414, presisi sebesar 0.687, dan F-measure sebesar 0.504.

Kata kunci: Peringkasan, *Recurrent Neural Network*, *Long Short-Term Memory*, *Word2vec*.

Abstract

Document summarization is an important aspect of natural language processing, and this journal aims to describe the latest developments in this field. With the explosion of information and the ever-increasing volume of news, document summarization becomes a key solution to address the challenges of accessing relevant and valuable information. In this paper, multi-document summarization in the Indonesian language is performed using the Recurrent Neural Network (RNN) method, with feature extraction employing two different Word2Vec models, namely, Continuous Bag of Words (CBOW) and Skip-gram. The results reveal significant recall, precision, and F-measure values. For the CBOW model, the discovered values are 0.487 for recall, 0.704 for precision, and 0.550 for F-measure. Meanwhile, for the Skip-gram model, the test results indicate a recall value of 0.414, a precision value of 0.687, and an F-measure value of 0.504.

Keywords: *Summarization, Recurrent Neural Network, Long Short-Term Memory, Word2vec.*

1. PENDAHULUAN

Kemajuan teknologi pada zaman sekarang menyebabkan jumlah dokumen dan artikel yang dapat diakses melalui internet meningkat secara signifikan[1]. Banyaknya pertumbuhan dokumen dan artikel menyebabkan banjir informasi (*information overload*). *Information overload* tersebut memengaruhi minat baca berita seseorang, membuat banyak orang merasa bosan dan mengalami kesulitan dalam mendapatkan esensi dari suatu berita. Kesulitan tersebut dapat membuat pengguna untuk membaca ulang, sehingga menghabiskan banyak waktu. Oleh karena itu, peringkasan teks otomatis, yang merupakan proses menyederhanakan teks panjang menjadi versi singkat yang mencerminkan esensi aslinya, muncul sebagai solusi untuk mengatasi masalah ini.[2]

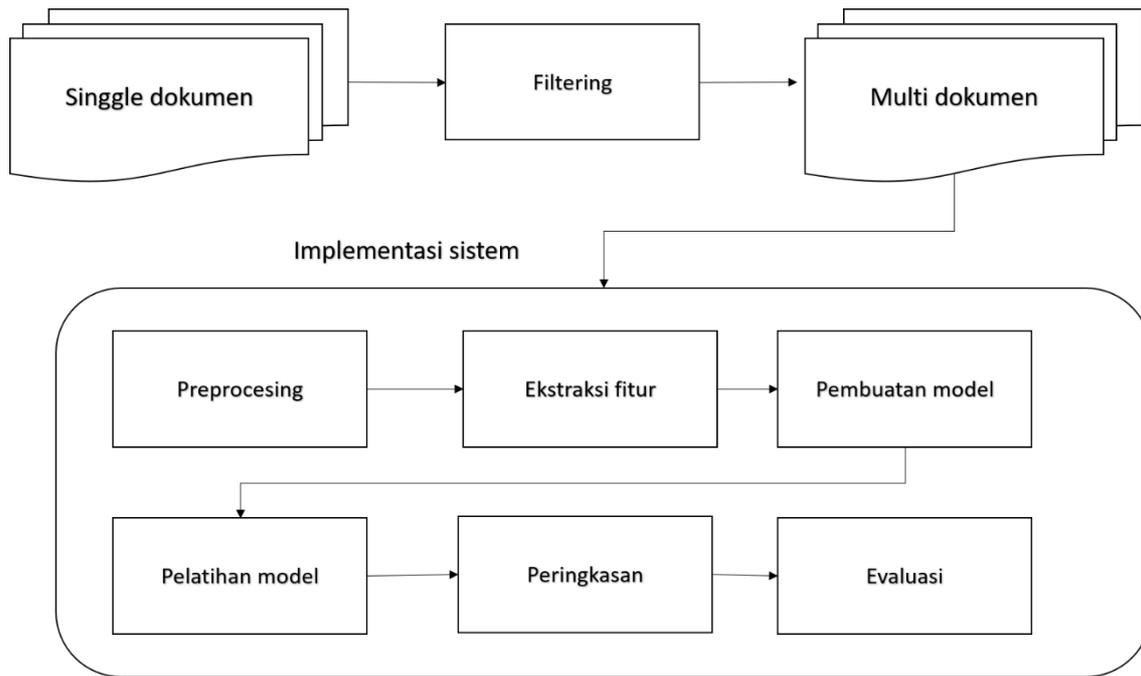
Peringkasan teks dibagi menjadi dua, yaitu peringkasan single dokumen dan multi dokumen. Peringkasan single dokumen adalah teknik meringkas yang diambil dari satu dokumen tunggal, [3]Tujuan utamanya adalah merangkum atau mengambil esensi informasi yang terkandung dalam satu sumber dokumen. Peringkasan multi dokumen adalah teknik peringkasan dimana dokumen yang diringkas lebih dari satu atau lebih. Tujuannya adalah untuk menyajikan ringkasan yang mencakup dari berbagai perspektif atau informasi dari sumber yang berbeda.[4]

Penelitian Adelia [5] melakukan peringkasan dokumen jurnal berbahasa Indonesia menggunakan RNN BiGRU. Dalam penelitiannya, ia menggunakan metode RNN BiGRU. Penelitian tersebut digunakan dua skenario yaitu menggunakan 128 dan 64 hidden units. Hasil yang diperoleh menunjukkan bahwa pada hidden 128, nilai Rouge-1 mencapai 0.11975 dan Rouge-2 sebesar 0.01199, sementara pada hidden 64, Rouge-1 mencapai 0.06745 dan Rouge-2 sebesar 0.00550. Penelitian M Saputra [6] melakukan peringkasan teks otomatis dengan pendekatan abstraktif menggunakan metode *Long Short-Term Memory* (LSTM). Model LSTM dibangun dalam model *encoder-decoder* dengan 3-layer LSTM. Data yang digunakan pada paper ini adalah kumpulan dokumen berita berbahasa Indonesia IndoSum. Penelitian ini juga mendefinisikan tiga skenario yang berbeda dalam hal *preprocessing*, yaitu skenario dengan *stemming* dan *stopword removal*, hanya *stemming*, dan tanpa keduanya. Hasil pengujian menunjukkan hasil yang rendah untuk skenario pertama (*stemming* dan *stopword removal*) karena pengurangan kata yang signifikan akibat *stopword removal*. Hasilnya memiliki F1-score rata-rata sekitar 0.08612 dan F1-score maksimum sekitar 0.45977. Penelitian menggunakan metode LSTM juga dilakukan oleh Mustikasari [7]. Paper tersebut melakukan peringkasan abstraktif menggunakan metode LSTM pada *news* atau berita dari *Hindu*, *Indian Times*, dan *Guardian*. Dataset ini terdiri dari 4515 buah artikel beserta ringkasan teks sebagai target output. Penelitian juga melakukan dua pengujian yaitu dengan evaluasi metode intrinsik pada artikel *non-stemming* dan pada artikel *Stemming*. Nilai rata-rata recall artikel berita *non-stemming* adalah sebesar 41%, precision sebesar 81%, dan F-measure sebesar 54,27%. Sedangkan nilai rata-rata recall artikel berita dengan teknik *stemming* sebesar 44%, precision sebesar 88%, dan F-measure sebesar 58,20%. [8]

Peringkasan otomatis pada paper sebelumnya masih menggunakan dataset single dokumen, oleh karena itu paper ini ingin melakukan peringkasan menggunakan dataset multi dokumen. Dataset multi dokumen sendiri adalah gabungan dari beberapa dataset single dokumen yang dijadikan satu menjadi dokumen utuh. Tujuannya adalah untuk merangkum informasi dari berbagai sumber yang berbeda sehingga pembaca dapat memahami gambaran keseluruhan dari beberapa berita sekaligus.

2. METODE PENELITIAN

Penelitian dimulai dengan proses pengumpulan dokumen yang berasal dari kumpulan artikel berbahasa Indonesia IndoSum. Setelah dokumen-dokumen terkumpul, langkah selanjutnya adalah melakukan *preprocessing*. *Preprocessing* melibatkan serangkaian langkah, termasuk *text cleaning*, tokenisasi, *stopword removal*, dan *stemming*. *Text cleaning* bertujuan untuk membersihkan dokumen dari karakter khusus, tanda baca, dan elemen yang tidak diperlukan. Tokenisasi membagi teks menjadi unit-unit seperti kata atau frasa. *Stopword removal* menghilangkan kata-kata umum yang tidak memberikan makna khusus. Sedangkan *stemming* mengubah kata-kata menjadi bentuk dasarnya.[9]



Gambar 1. Alur Peringkasan Multi dokumen

Setelah *preprocessing* selesai, langkah berikutnya adalah ekstraksi fitur menggunakan metode Word2Vec, yang membantu dalam menganalisis hubungan antar kata dalam teks. Selanjutnya, model peringkasan dibangun dengan menggunakan algoritme seperti LSTM (*Long Short-Term Memory*) untuk melatih model peringkasan. Proses pelatihan dilakukan pada data latih, di mana model belajar untuk merangkum teks dengan menggunakan informasi dari dokumen-dokumen yang telah diolah sebelumnya.[10]

Terakhir, hasil peringkasan dievaluasi menggunakan metrik seperti Rouge-1, yang mengukur sejauh mana ringkasan yang dihasilkan oleh model mencerminkan kesamaan dengan ringkasan referensi. Evaluasi ini membantu menentukan sejauh mana model peringkasan telah berhasil dalam menangkap inti dari dokumen-dokumen yang telah diolah. Dengan demikian, melalui metode ini, peringkasan teks yang akurat dan informatif dapat dihasilkan dari kumpulan dokumen yang relevan.

2.1 Single-document

Dataset yang dipakai dalam penelitian ini merupakan kumpulan artikel berita *single-document* Bahasa Indonesia bernama IndoSum yang dianggap sebagai benchmark untuk kasus peringkasan teks otomatis. IndoSum terdiri dari 19 ribu pasangan artikel berita dan ringkasan yang dibuat oleh dua penutur asli bahasa Indonesia. Artikel-artikel pada dataset tersebut diambil dari beberapa portal berita online seperti CNN Indonesia dan Kumparan. Terdapat enam kategori berita pada dataset ini, yaitu hiburan, inspirasi, olahraga, industri hiburan, headline, dan teknologi. Dalam penelitian ini, digunakan 150 sampel data dari dataset tersebut dan setiap kategori dianggap sama penting.[11]

2.2 Filtering

Filtering merupakan proses untuk menggabungkan dan mengelompokkan beberapa dokumen berdasarkan kategori dan topik yang sama menjadi satu story. Proses ini dilakukan untuk menyusun multi-dokumen yang saling terkait, sehingga informasi yang relevan dapat ditemukan secara efisien.

2.3 multi-document

berdasarkan hasil pengelompokan objek berita, penelitian ini menghasilkan 50 story dengan masing-masing story berisi 3 hingga 5 berita single dokumen. Kemudian *Story* tersebut akan dilabeli oleh 5 responden, label dengan pilihan terbanyak akan digunakan untuk menentukan

label pada setiap kalimat dalam rangkuman.

Berita tersebut kemudian dipisah menjadi per kalimat untuk dijadikan kalimat yang bisa dipilih oleh responden. Kemudian mengambil data kalimat mana yang paling banyak dipilih oleh 5 responden.

Tabel 1 Label tiap responden

No. Kalimat	R1	R2	R3	R4	R5	Label	No. Kalimat
1	1	1	0	1	0	1	1
2	0	1	1	0	1	1	2
3	0	0	0	0	0	0	3
4	0	1	1	1	1	1	4
5	0	1	0	0	0	0	5
.....
60	0	0	1	0	1	0	60

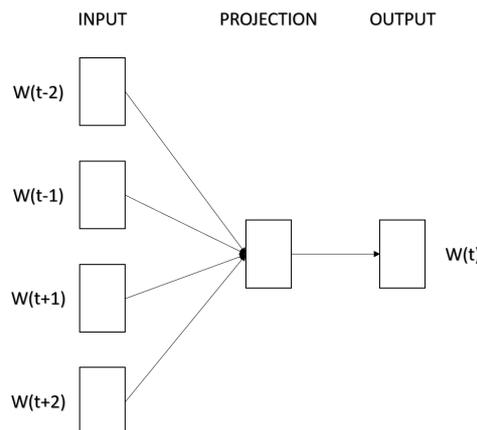
2.4 Pre-processing

Preprocessing adalah tahap awal dalam pemrosesan teks yang melibatkan serangkaian langkah untuk membersihkan dan mempersiapkan data teks agar dapat digunakan untuk pembuatan model peringkasan. Langkah-langkah preprocessing yang dilakukan dalam penelitian ini mencakup *text cleaning*, tokenisasi, *stopword removal*, dan *stemming*. [12]

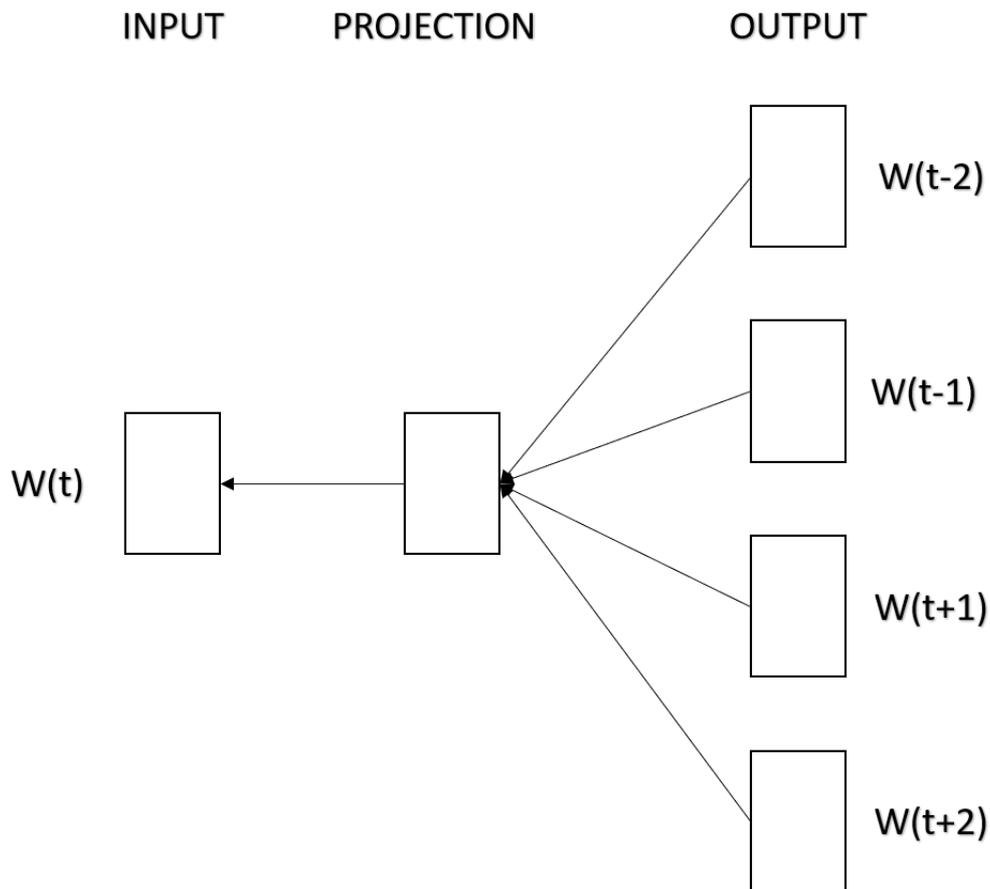
2.5 Ekstraksi Fitur

Ekstraksi fitur pada peringkasan teks berita ini digunakan teknik *Word2Vec* untuk melakukan Ekstraksi fitur. *Word2Vec* digunakan sebagai salah satu metode untuk mengubah teks menjadi representasi vektor yang dapat digunakan sebagai input pada model LSTM. Hal ini dilakukan dengan mengubah setiap kata dalam teks menjadi vektor *Word2Vec* yang kemudian dijadikan input pada model LSTM. [13]

Word2vec memiliki dua model yaitu *Continous Bag of Word (CBOW)* dan *Skip-gram*. Model CBOW bekerja dengan mengambil beberapa kata di sekitar kata target (yang ingin di-representasikan sebagai vektor) dan mencoba memprediksi kata target tersebut. Model CBOW menggunakan informasi dari kata-kata di sekitar kata target untuk memprediksi kata target. Model *Skip-gram* bekerja dengan cara sebaliknya. Model ini mengambil sebuah kata target dan mencoba memprediksi kata-kata yang mungkin muncul di sekitarnya.



Gambar 2. Arsitektur CBOW



Gambar 3 Arsitektur Skip-gram

2.6 Pelatihan Data

Model untuk melatih data menggunakan metode LSTM. LSTM (*Long Short-Term Memory*) adalah varian dari jenis jaringan saraf tiruan RNN (*Recurrent Neural Network*). LSTM pertama kali diusulkan oleh [14]. LSTM dikembangkan untuk mengatasi masalah yang dihadapi oleh RNN dalam mengingat informasi yang lama dalam sekuensial panjang. LSTM memiliki kemampuan yang lebih baik dalam menangani masalah yang lebih kompleks, seperti pemrosesan bahasa alami, teks generasi, dan pengenalan suara [15]

LSTM memiliki struktur yang lebih kompleks dibandingkan RNN, yang terdiri dari beberapa "unit LSTM" yang dapat mengingat informasi yang lama dan melupakan informasi yang tidak relevan. Setiap unit LSTM memiliki tiga jenis operasi yang disebut "*input gate*", "*forget gate*", dan "*output gate*". *Input gate* digunakan untuk menentukan informasi yang akan disimpan dalam hidden state, *forget gate* digunakan untuk menentukan informasi yang akan dihapus dari *hidden state*, dan *output gate* digunakan untuk menentukan informasi yang akan digunakan untuk membuat prediksi. [8]

2.7 Peringkasan

Setelah model LSTM dilatih dan dievaluasi, Model tersebut dapat digunakan untuk melakukan peringkasan teks ekstraktif. Caranya adalah dengan memberikan teks berita sebagai input, dan model akan memberikan label true atau false pada setiap kalimat dalam teks. Kalimat dengan label true akan dipertahankan dan dijadikan sebagai ringkasan teks, sedangkan kalimat dengan label false akan dihapus.

2.8 Evaluasi

Proses evaluasi menggunakan metode ROUGE. Model ROUGE yang digunakan adalah model ROUGE-1, ROUGE-1 adalah salah satu metode evaluasi yang digunakan untuk mengukur sejauh mana sebuah sistem ringkasan teks mampu menghasilkan ringkasan yang sesuai dengan dokumen aslinya. ROUGE-1 umumnya digunakan dalam penelitian dan pengembangan sistem ringkasan otomatis. Model ROUGE bekerja dengan cara menghitung kesamaan kata-kata yang terdapat dalam ringkasan yang dihasilkan oleh sistem dengan gold summaries pada setiap data uji secara unigram atau satu kata demi satu kata. Dari hasil perhitungan tersebut, akan dihitung nilai recall, precision, dan f1-score untuk mengevaluasi kinerja sistem. [16].

$$precision = \frac{(jumlah\ kata\ overlapping)}{(jumlah\ kata\ di\ ringkasan\ otomatis)}$$

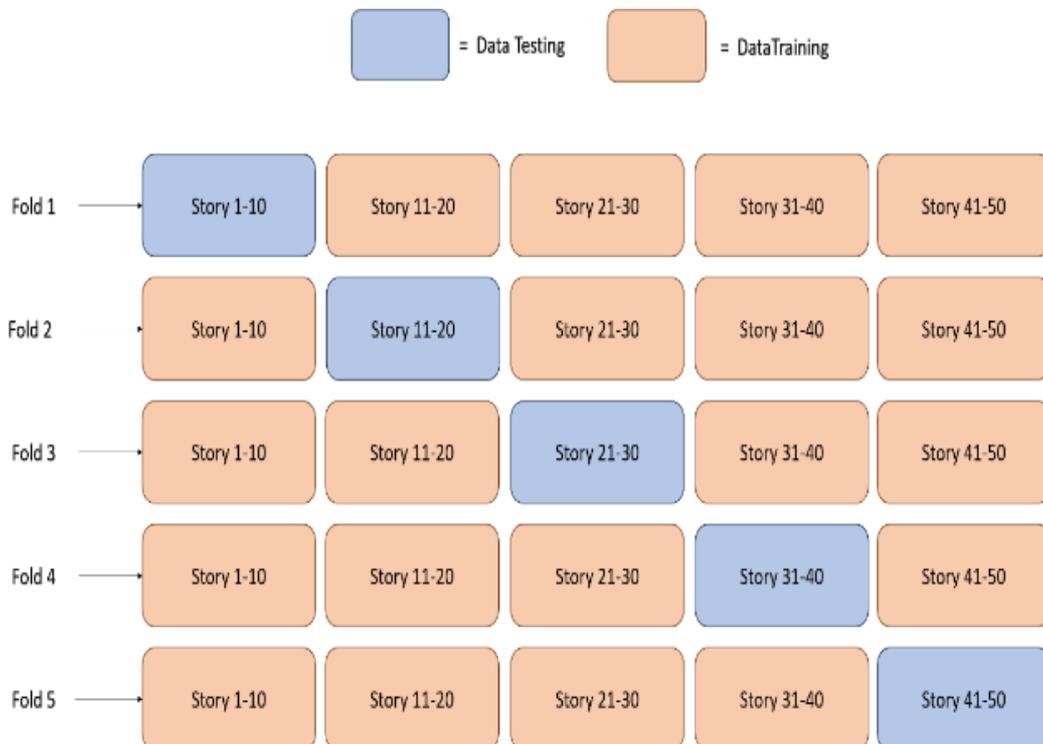
$$recall = \frac{(jumlah\ kata\ overlapping)}{(jumlah\ kata\ di\ ringkasan\ manusia)}$$

$$recall = f - measure = \frac{(2 * precision * recall)}{(precision + recall)}$$

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pelatihan Data

Data yang akan dilatih akan dibagi menjadi data latih dan uji menggunakan metode *K-Fold Cross-Validation* untuk membagi data menjadi 5-fold. Pendekatan ini memungkinkan untuk menguji dan melatih model pada setiap fold secara bergantian, memastikan hasil pelatihan yang lebih kuat dan evaluasi yang lebih reliabel. Langkah-langkah pelatihan dan evaluasi model akan dilakukan pada setiap fold secara berulang untuk memastikan hasil yang konsisten dan akurat.

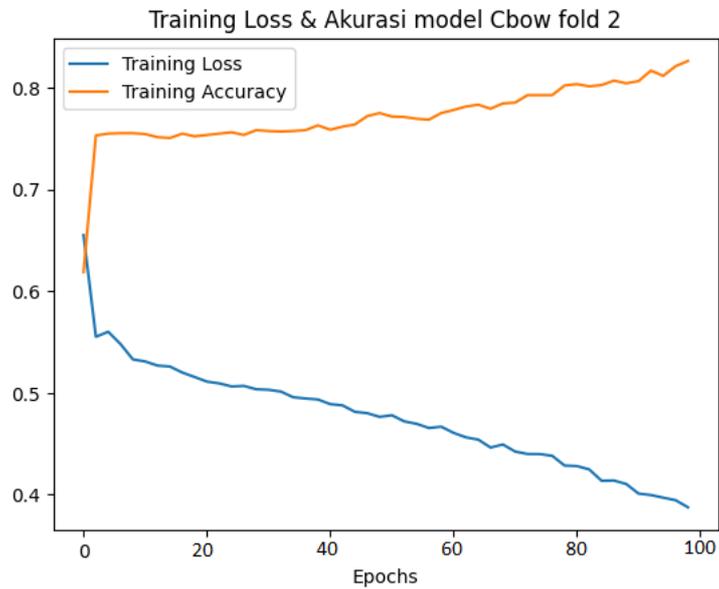


Gambar 4. *Splitting data*

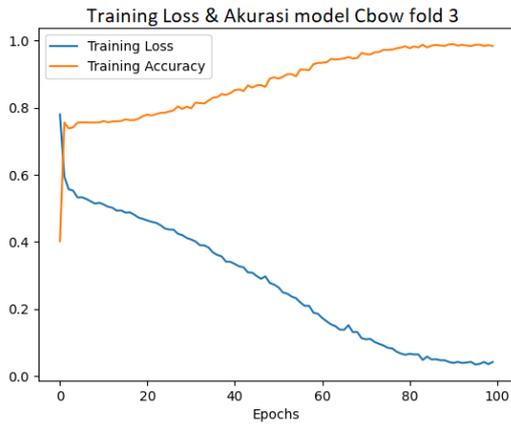
Setelah data di bagi menjadi dua, data latih akan dilakukan pelatihan menggunakan metode LSTM. Data yang dilatih akan ada dua model yaitu CBOW dan Skip-gram(sg). Hasil loss dan akurasi dari pelatihan data ditunjukkan pada gambar dibawah.



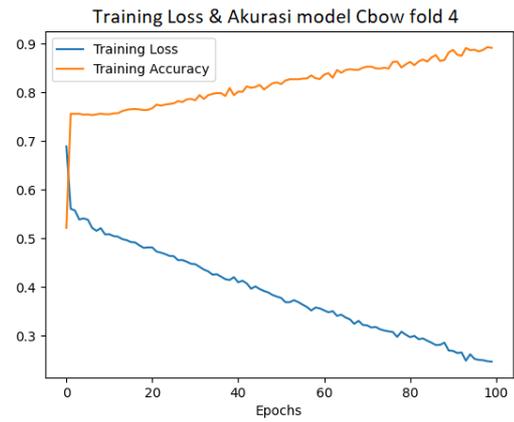
Gambar 5. Grafik model cbow fold-1



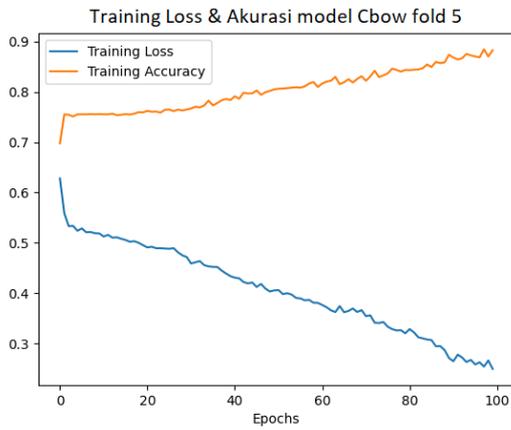
Gambar 6. Grafik model cbow fold-2



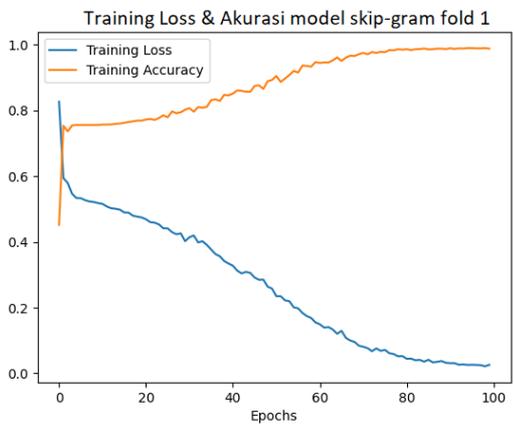
Gambar 7 Grafik model cbow fold-3



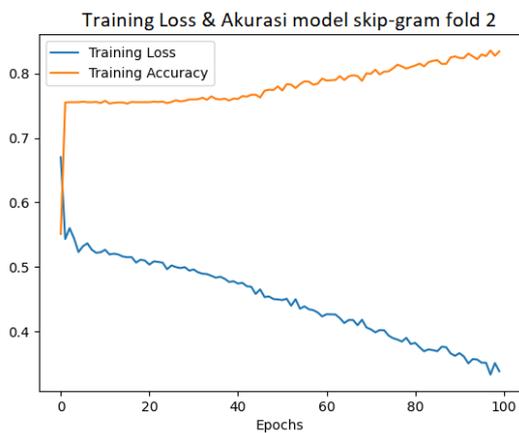
Gambar 8 Grafik model cbow fold-4



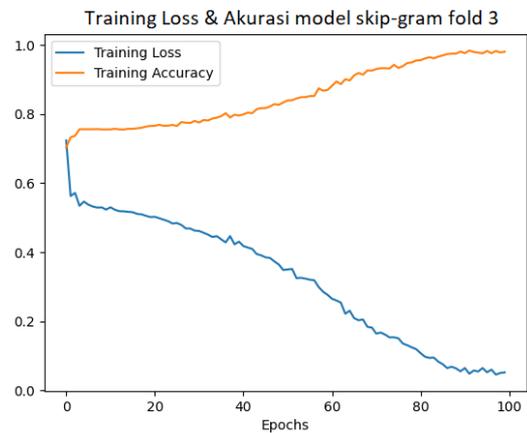
Gambar 9 Grafik model cbow fold-4



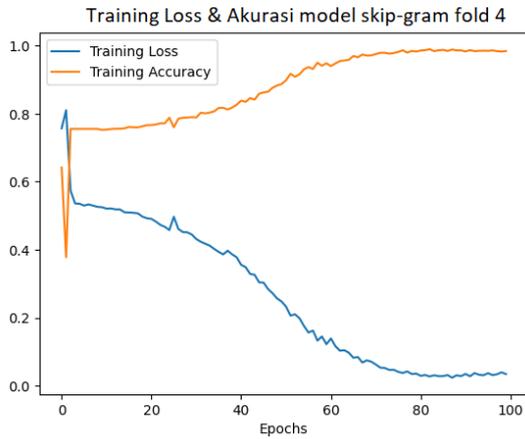
Gambar 10 Grafik model sg fold-1



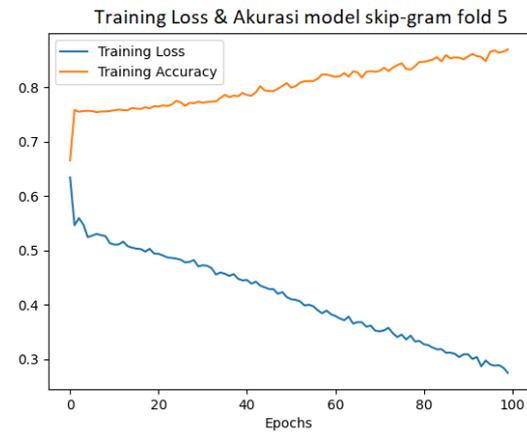
Gambar 11 Grafik model sg fold-2



Gambar 12 Grafik model sg fold-3



Gambar 13 Grafik model sg fold-4



Gambar 14 Grafik model sg fold-5

Pada Gambar 6 sampai gambar sepuluh menunjukkan grafik loss akurasi pada model CBOW sedangkan pada gambar 11 sampai 14 merupakan grafik loss akurasi pada model Skip-gram. Grafik menunjukkan bahwa nilai loss turun dan nilai akurasi naik secara stabil pada setiap *epoch*-nya. Penurunan nilai loss menunjukkan bahwa model semakin mampu meminimalisir kesalahannya, peningkatan akurasi menunjukkan bahwa model semakin mampu memprediksi hasil yang benar. Dengan demikian dapat disimpulkan bahwa model LSTM telah berhasil menghasilkan model yang konvergensi, mampu menggeneralisasi dengan baik, dan memiliki kinerja yang stabil pada data *training*.

3.4 Hasil Evaluasi

Model yang telah dilatih akan digunakan untuk memprediksi setiap label pada kalimat data uji yang mana label tersebut digunakan sebagai acuan peringkasan. Setelah mendapatkan ringkasan sistem, ringkasan tersebut akan dievaluasi dan dibandingkan dengan ringkasan asli. Evaluasi dilakukan menggunakan metode Rouge-1 untuk mendapatkan nilai *recall*, *precision*, dan *F-measure*. Pada tabel 3 dan 4 menampilkan nilai rata-rata *recall*, *precision*, dan *f-measure* pada tiap fold-nya

Tabel 2 Hasil rata-rata

Rouge-1 tiap fold pada model CBOW

Fold	Recall	Precision	F-measure
1	0.462	0.683	0.532
2	0.473	0.687	0.546
3	0.534	0.715	0.592
4	0.490	0.711	0.550
5	0.479	0.724	0.529
Rata-rata	0.487	0.704	0.550

Tabel 3 Hasil rata-rata Rouge-1 tiap fold pada model Skip-gram

Fold	Recall	Precision	F-measure
1	0.422	0.677	0.510
2	0.436	0.701	0.516
3	0.460	0.710	0.579
4	0.354	0.597	0.436
5	0.398	0.751	0.479
Rata-rata	0.414	0.687	0.504

Untuk uji coba pertama digunakan model CBOW dengan 5-fold didapatkan nilai rata-rata *F-measure* tertinggi sebesar 0.592 yaitu pada fold-3, nilai rata-rata *recall* tertinggi sebesar 0.5341 pada fold ke-3 dan nilai rata-rata *precision* tertinggi sebesar 0.724 pada fold ke-5. Untuk uji coba kedua digunakan model *Skip-gram* dengan 5-fold didapatkan nilai rata-rata *F-measure* tertinggi sebesar 0.579 yaitu pada fold ke-3, nilai rata-rata *recall* tertinggi sebesar 0.460 pada fold ke-3 dan nilai rata-rata presisi tertinggi sebesar 0.751 pada fold ke-5.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil uji coba yang telah dilakukan menunjukkan bahwa metode RNN dapat melakukan peringkasan multi dokumen dengan baik. Dari dua model word2vec yang digunakan menunjukan bahwa model CBOW menghasilkan nilai Rouge-1 lebih baik dari pada model *Skip-gram* dengan rata-rata nilai *f-measure* sebesar 0.5502 sedangkan nilai rata-rata *f-measure* dari model *Skip-gram* sebesar 0.504. Kemudian, dari hasil uji coba diatas menunjukan nilai rouge-1 terbaik dari masing-masing model terdapat pada fold-3 dengan nilai rata-rata *f-measure* dari model CBOW dan *Skip-gram* adalah 0.592 dan 0.5793.

Saran untuk penelitian ini adalah penambahan jumlah dataset. Dataset yang lebih banyak akan membuat model yang lebih optimal karena model akan belajar dengan lebih banyak berita dengan berbagai topik yang berbeda. Kemudian untuk ekstraksi fitur mungkin bisa menggunakan metode yang lebih bari seperti *fasttext* atau *Glove*.

DAFTAR PUSTAKA

- [1] S. N. Asiyah and K. Fitrhasari, "Klasifikasi Berita Online Menggunakan Metode Support Vector Machine dan K- Nearest Neighbor," *JURNAL SAINS DAN SENI ITS*, vol. 5, no. 2, pp. 317–322, 2016.
- [2] D. Anjar Prabowo, M. Fhadli, M. Ainun Najib, H. Agus Fauzi, I. Cholissodin, and P. Studi Informatika, "TF-IDF-Enhanced Genetic Algorithm untuk Extractive Automatic Text Summarization," 2016.
- [3] I. M. Suwija Putra, Y. Adiwinata, D. P. Singgih Putri, and N. P. Sutramiani, "Extractive Text Summarization of Student Essay Assignment Using Sentence Weight Features and Fuzzy C-Means," *International Journal of Artificial Intelligence Research*, vol. 5, no. 1, Jan. 2021, doi: 10.29099/ijair.v5i1.187.
- [4] I. P. G. H. Saputra, "Peringkasan Teks Otomatis Untuk Dokumen Bahasa Bali Berbasis Metode Ekstraktif," *Jurnal Ilmiah ILMU KOMPUTER Universitas Udayana*, vol. X, no. 1, pp. 33–38, 2017.
- [5] R. Adelia, S. Suyanto, and U. N. Wisesty, "Indonesian Abstractive Text Summarization Using Bidirectional Gated Recurrent Unit," *Procedia Comput Sci*, vol. 157, pp. 581–588, 2019, doi: 10.1016/j.procs.2019.09.017.
- [6] M. A. Saputra, "Peringkas Teks Otomatis Bahasa Indonesia secara Abstraktif Menggunakan Metode Long Short-Term Memory," *e-Proceeding of Engineering*, pp. 3473–3488, 2021.
- [7] K. Ivanedra and M. Mustikasari, "Implementasi Metode Recurrent Neural Network Pada Text Summarization dengan Teknik Abstraktif," vol. 6, no. 4, pp. 377–382, 2019, doi: 10.25126/jtiik.201961067.
- [8] M. Vebika Shyahrin, Y. Sibaroni, and D. Puspendari, "Penerapan Metode Long Short-Term Memory dan Word2Vec dalam Analisis Sentimen Ulasan pada Aplikasi Ferizy LSTM and Word2Vec Application for Sentiment Analysis of Reviews on Ferizy," 2023.
- [9] N. Savanti Widya Gotami and R. Kartika Dewi, "Peringkasan Teks Otomatis Secara Ekstraktif Pada Artikel Berita Kesehatan Berbahasa Indonesia Dengan Menggunakan Metode Latent Semantic Analysis," 2018. [Online]. Available: <http://j-ptiik.ub.ac.id>

- [10] M. M. Rahman and F. H. Siddiqui, “An Optimized Abstractive Text Summarization Model using Peephole Convolutional LSTM,” *Symmetry (Basel)*, vol. 11, no. 10, Oct. 2019, doi: 10.3390/sym11101290.
- [11] K. Kurniawan and S. Louvan, “IndoSum: A New Benchmark Dataset for Indonesian Text Summarization,” in *Proceedings of the 2018 International Conference on Asian Language Processing, IALP 2018*, Institute of Electrical and Electronics Engineers Inc., Jan. 2019, pp. 215–220. doi: 10.1109/IALP.2018.8629109.
- [12] F. Hasibuan, W. Priatna, and T. Sri Lestari, “Analisis Sentimen Terhadap Kementerian Perdagangan Pada Sosial Media Twitter Menggunakan Metode Naïve Bayes Sentiment Analysis Of The Ministry Of Trade On Twitter Social Media Using Naïve Bayes Method,” 2022.
- [13] T. Mikolov, K. Chen, G. Corrado, and J. Dean, “Distributed Representations of Words and Phrases and their Compositionality,” 2013.
- [14] S. Hochreiter and J. Jürgen Schmidhuber, “Long Short-Term Memory,” 1997.
- [15] P. Liu, X. Qiu, and X. Huang, “Recurrent Neural Network for Text Classification with Multi-Task Learning,” May 2016, [Online]. Available: <http://arxiv.org/abs/1605.05101>
- [16] A. Naufal Ammar, “Peringkasan Teks Ekstraktif Menggunakan Binary Firefly Algorithm,” *Ind. Journal on Computing*, vol. 5, no. 2, pp. 32–42, 2020, doi: 10.21108/indojc.2020.5.2.440.