

Gated Recurrent Unit for Clickbait and Non-Clickbait News Headlines Classification

Gated Recurrent Unit Untuk Klasifikasi Judul Berita Clickbait dan Non-Clickbait

Desriyanti Dea, Feisy Diane Kambey, Agustinus Jacobus

Dept. of Electrical Engineering, Sam Ratulangi University Manado, Kampus Bahu St., 95115, Indonesia

e-mail: desriyantidea026@student.unsrat.ac.id, feisykambey@unsrat.ac.id, a.jacobus@unsrat.ac.id

Received: 25 October 2025; revised: 20 December 2025; accepted: 5 March 2026

Abstract — *Clickbait refers to the practice of crafting sensational headlines to entice readers to click on links and read articles, often at the expense of accurately representing the underlying content. Amid fierce competition among online news portals and readers' tendency to focus only on headlines, this phenomenon can mislead audiences, thereby necessitating an automated system capable of distinguishing clickbait headlines from non-clickbait ones. This study classifies Indonesian news headlines using a Gated Recurrent Unit (GRU) architecture and compares two pre-trained word embedding models, FastText and Word2Vec. The data used in this study are taken from the CLICK-ID dataset on Kaggle and comprise 15,000 news headlines. The results show that GRU combined with Word2Vec provides the best performance, achieving 78.96% accuracy, 78.80% precision, 78.96% recall, and a 78.86% F1-score, while GRU with FastText achieves 77.04% accuracy, 77.06% precision, 77.04% recall, and a 77.05% F1-score. In the task of classifying Indonesian clickbait news headlines, the use of Word2Vec word embeddings in a GRU-based model is superior to FastText, as it yields higher classification accuracy as well as better computational efficiency.*

Key words— *Clickbait; FastText; GRU; Text Classification; Word2Vec.*

Abstrak — *Clickbait adalah praktik penyusunan judul yang sengaja dibuat sensasional agar pembaca tertarik untuk mengklik tautan dan membaca artikel, namun kerap tidak mewakili isi berita secara utuh. Di tengah persaingan portal berita dan rendahnya kebiasaan membaca isi secara lengkap, fenomena ini berpotensi menyesatkan pembaca sehingga diperlukan sistem otomatis untuk membedakan judul *clickbait* dan *non-clickbait*. Penelitian ini mengklasifikasikan judul berita berbahasa Indonesia menggunakan arsitektur *Gated Recurrent Unit* dan membandingkan dua *pretrained word embedding*, *FastText* dan *Word2Vec*. Data yang digunakan berasal dari kaggle sebanyak 15.000 judul. Hasil menunjukkan kombinasi GRU dengan *Word2Vec* memberikan kinerja terbaik dengan akurasi 78,96 %, presisi 78,8%, *recall* 78,96 %, dan *F1-Score* 78,86 %. Sementara itu, GRU dengan *FastText* mencapai akurasi 77,04 %, presisi 77,06 %, *recall* 77,04 %, dan *F1-Score* 77,05 %. Pada tugas klasifikasi judul berita *clickbait* berbahasa Indonesia, penggunaan *word embedding* *Word2Vec* pada model GRU lebih unggul dibandingkan *FastText* karena mampu memberikan akurasi klasifikasi yang lebih tinggi sekaligus efisiensi komputasi yang lebih baik.*

Kata kunci — *Clickbait; FastText; GRU; Klasifikasi Teks; Word2Vec.*

I. PENDAHULUAN

Kemajuan teknologi dan informasi terus meningkat seiring dengan kebutuhan manusia. Dari penemuan *internet* hingga pengembangan sistem kecerdasan buatan, kemajuan teknologi tidak hanya menghasilkan inovasi tetapi juga menciptakan realitas baru yang mengubah cara kita bekerja, berkomunikasi, dan menjalani kehidupan sehari-hari [1]. Dalam era digital saat ini, masyarakat dapat memperoleh banyak informasi melalui berita dengan berbagai cara. Salah satunya adalah dengan cara memanfaatkan media berita *online* [2]. Persaingan ketat di industri media *online* mendorong penulis berita untuk menarik sebanyak mungkin pembaca salah satunya dengan cara menggunakan judul berita yang bersifat *clickbait* [2].

Clickbait adalah metode yang digunakan oleh media untuk menarik perhatian pembaca melalui judul, gambar, atau potongan informasi yang bersifat sensasional atau menarik dengan maksud agar pembaca tertarik untuk mengklik tautan dan membaca artikel tersebut [3]. Masih banyak yang belum mampu membedakan antara berita yang benar, berita sindiran, maupun berita palsu. Kebiasaan membaca hanya dari judul tanpa menelusuri isi secara menyeluruh sering kali membuat pembaca menarik kesimpulan yang keliru [4]. Di Indonesia, kondisi ini menjadi lebih mengkhawatirkan mengingat negara Indonesia termasuk dalam daftar negara dengan tingkat literasi yang rendah menurut survei *Programme for International Student Assessment (PISA)* yang diterbitkan oleh *Organisation for Economic Co-operation and Development (OECD)* pada tahun 2019 [5]. Dalam menghadapi tantangan tersebut, diperlukan strategi untuk mengklasifikasikan judul berita yang termasuk *clickbait* dan yang bukan.

Penelitian terkait klasifikasi teks dan deteksi *clickbait* telah dilakukan dengan berbagai pendekatan *word embedding* dan model deep learning. Penelitian oleh Nurdin et al., (2020) [6] membandingkan *Word2Vec*, *GloVe*, dan *FastText* dalam klasifikasi teks menggunakan CNN dan menemukan bahwa *FastText* memberikan hasil terbaik dengan nilai *F-Measure* tertinggi. Penelitian oleh Liebenlito et al [5] mengembangkan sistem deteksi *clickbait* berbahasa Indonesia menggunakan *FastText* dan memperoleh akurasi 77%, menunjukkan bahwa metode ini lebih efektif dengan tidak menghilangkan

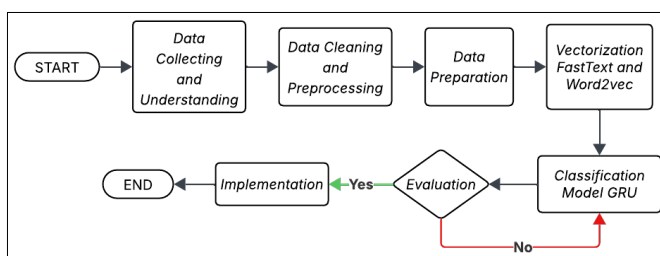
stopwords. Sementara itu, Al-Areef & Saputra S, (2023) [7] menerapkan LSTM dengan *embedding* FastText untuk analisis sentimen politik mengenai calon presiden Indonesia Tahun 2024 dan menghasilkan akurasi hingga 89%, menegaskan keunggulan representasi kata dalam memahami konteks teks pendek.

Beberapa penelitian lain turut menunjukkan potensi model GRU dalam pemrosesan bahasa alami. Anas Fikri Hanif et al 2023 [8] membandingkan LSTM, Bi-LSTM, dan GRU dalam klasifikasi *clickbait* dan menemukan bahwa GRU memberikan hasil terbaik dari segi akurasi maupun efisiensi waktu. Hasil serupa juga diperoleh oleh Ikhwan Saputra et al (2024) [9] yang menerapkan GRU untuk klasifikasi emosi, dengan tingkat akurasi mencapai 75%. Selain itu, Afidah et al (2021) [10] menunjukkan bahwa arsitektur CBOV pada Word2Vec lebih unggul dibandingkan Skip-gram untuk teks dengan kata-kata yang sering muncul. Studi Bouchra et al [11] dan Adrian et al. [12] juga menegaskan efektivitas kombinasi Word2Vec dan model LSTM/Bi-LSTM dalam klasifikasi teks berbahasa Indonesia dengan akurasi di atas 90%.

Berdasarkan berbagai penelitian tersebut, dapat disimpulkan bahwa FastText dan Word2Vec sama-sama memiliki potensi kuat dalam menghasilkan representasi kata yang efektif. Namun, masih terdapat kesenjangan penelitian, yaitu belum adanya kajian yang membandingkan performa kedua *embedding* tersebut pada arsitektur GRU yang sama dengan korpus judul berita berbahasa Indonesia. Selain itu, penelitian terdahulu belum banyak menyoroti hubungan antara cakupan kosakata (*coverage*) dengan kualitas representasi semantik, serta aspek efisiensi waktu pelatihan sebagai pertimbangan praktis. Oleh karena itu, penelitian ini berkontribusi dalam menghadirkan analisis komparatif FastText dan Word2Vec menggunakan GRU, yang tidak hanya menilai kinerja klasifikasi dari segi akurasi dan *F1-Score*, tetapi juga dari segi efisiensi komputasi, guna mendukung pengembangan sistem deteksi *clickbait* yang akurat dan hemat sumber daya.

II. METODE

Tahap awal penelitian adalah mengubah judul berita yang masih tidak terstruktur menjadi teks semi-terstruktur melalui pembersihan, normalisasi, tokenisasi, dan post-padding. Teks yang sudah rapi kemudian dipetakan ke vektor menggunakan dua word embedding pralatih berbahasa Indonesia, Word2Vec dan FastText. Vektor tersebut menjadi input bagi model GRU yang bertugas mengklasifikasikan judul ke dalam dua kelas: *clickbait* dan *non-clickbait*.



Gambar 1. Alur Penelitian

Untuk menjaga evaluasi yang objektif, data dibagi stratifikasi menjadi data latih, data validasi, dan data uji; pelatihan memakai *early stopping* dan *model checkpoint*. Alur lengkap proses dapat dilihat pada Gambar 1.

A. Data Collecting and Data Understanding

Pada penelitian ini data yang digunakan merupakan data yang diperoleh dari Kaggle *CLICK-ID: A Novel Dataset for Indonesian Clickbait Headlines* oleh Andika William dan Yunita Sari yang terbit pada 11 Mei 2020. Dari keseluruhan judul berita, sebanyak 8.710 data tergolong *non-clickbait*, dan sebanyak 6.290 data termasuk dalam kategori *clickbait*. Perbandingan ini menunjukkan bahwa kumpulan data tersebut cenderung seimbang, meskipun jumlah *non-clickbait* sedikit lebih tinggi. Oleh karena itu, dalam penelitian ini tidak diterapkan teknik *imbalancing* data agar distribusi asli judul berita tetap terpelihara. Data yang digunakan adalah data yang telah dianotasi yang memiliki tiga kolom yaitu *title*, *label*, dan *label_score*.

B. Data Cleaning and Preprocessing

Selanjutnya, data akan masuk pada tahap *data cleaning* dan *pre-processing* dengan tujuan membuat data judul berita lebih mudah untuk diproses dan dikelompokkan. Pada penelitian ini hanya mempertahankan dua kolom yang relevan yaitu *title* sebagai fitur dan *label* sebagai target serta menghapus *label_score* untuk menghindari duplikasi informasi; baris duplikat pada kolom judul dibuang, dan pemeriksaan missing values memastikan kolom utama bersih. Pembersihan isi teks dilakukan dengan menghapus karakter/tanda baca yang tidak informatif dan mengganti tanda baca tertentu yang bermakna dalam judul *clickbait* (titik, koma, "...", "!") menjadi token khusus (<d>, <c>, <ddd>, <e>) agar jejak gayanya tetap terbawa. Selanjutnya dilakukan normalisasi karakter; menghapus simbol khusus, penyeragaman spasi, serta penggabungan kata depan "di" agar tidak terpisah saat tokenisasi. Untuk menekan OOV, diterapkan kamus normalisasi buatan peneliti yang mengonversi slang dan singkatan ke bentuk baku, lalu seluruh teks di-case folding menjadi huruf kecil. Rangkaian langkah ini menghasilkan korpus judul yang rapi, seragam, dan siap diubah ke representasi vektor pada tahap pemodelan.

C. Data Preparation

Pada tahap *data preparation*, label "*clickbait*" dan "*non-clickbait*" diubah ke bentuk numerik agar kompatibel dengan klasifikasi biner, 1 untuk *clickbait* dan 0 untuk *non-clickbait*. Selanjutnya, dataset dibagi menjadi 49% data latih, 21% data validasi, dan 30% data uji. Setelah itu dilakukan tokenisasi menggunakan *Tokenizer Keras* berbasis kamus yang dibangun dari data latih lalu diterapkan konsisten ke validasi dan uji sehingga setiap kata dipetakan menjadi indeks bilangan bulat sesuai frekuensi kemunculannya. Terakhir, judul yang panjangnya bervariasi diseragamkan melalui *post-padding* hingga panjang maksimal yang ditetapkan, sehingga seluruh masukan memiliki dimensi yang konsisten.

D. Vectorization

Judul berita yang sudah dibersihkan direpresentasikan menjadi menjadi vektor numerik yang akan menjadi input pada GRU. Penelitian ini menggunakan dua *pretrained word embedding* berbahasa Indonesia berdimensi 300 yakni FastText dan Word2Vec.

1) FastText

FastText dikembangkan oleh Facebook AI Research (FAIR) dan merupakan sebuah pustaka pembelajaran mesin yang digunakan untuk memperoleh representasi kata secara efisien serta untuk klasifikasi kalimat. FastText cocok untuk mengelola kata-kata baru yang tidak ada dalam kamus karena memecah kata-kata yang tidak dikenal dari korpus menjadi n-gram. N-gram ini mungkin memiliki kesamaan dengan kata-kata yang ada dalam korpus kamus [13]. Pada penelitian ini digunakan pre-trained FastText bahasa Indonesia yang diperoleh dari website resmi FastText.

2) Word2Vec

Word2vec adalah salah satu algoritma *word embedding* yang mengonversi setiap kata dalam teks menjadi vektor. Mikolov dan rekannya mengembangkan algoritma Word2Vec dengan dua metode utamanya, Skip-gram dan Continuous Bag of Words (CBOW), pada tahun 2013. [6]. Word2vec bergantung pada informasi yang ada dalam konteks lokal bahasa. Kata-kata yang mengelilingi sebuah kata memiliki pengaruh pada makna yang dipelajari darinya. Model ini menunjukkan kemampuannya dalam mempelajari pola bahasa sebagai hubungan linier antarvektor kata [6].

E. Modelling

Pada penelitian ini algoritma yang digunakan adalah *Gated Recurrent Unit* (GRU). GRU adalah salah satu jenis arsitektur jaringan saraf berulang (RNN) yang memiliki mekanisme yang hampir sama dengan *Long Short-Term Memory* [14]. GRU diperkenalkan oleh Cho pada tahun 2014 dengan keunggulan proses komputasi yang lebih sederhana dibandingkan LSTM tanpa mengurangi tingkat akurasi. [15]. GRU memiliki dua gate dan tiga fungsi aktivasi. Jumlah *gate* dan fungsi yang lebih sedikit pada GRU membuat proses pengolahan data, khususnya pada *dataset* berukuran besar, dapat dilakukan dengan lebih cepat. Oleh karena itu, GRU dirancang agar mampu bekerja lebih efisien dibandingkan LSTM, terutama ketika digunakan pada dataset dengan ukuran yang relatif kecil. [15].

Rumus dari GRU dapat dilihat pada persamaan berikut:

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (1)$$

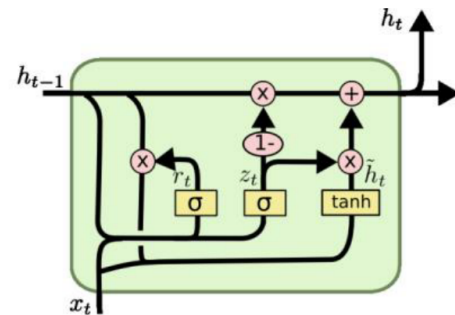
$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (2)$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h(r_t \odot h_{t-1}) + b_h) \quad (3)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (4)$$

F. Evaluasi

Confusion Matrix yang terdiri dari *True Positive (TP)*, *False Positive (FP)*, *False Negative (FN)*, dan *True Negative (TN)* digunakan untuk menilai kinerja dalam klasifikasi biner. Jumlah data yang diprediksi dengan benar sebagai positif diwakili oleh TP, jumlah data yang salah diprediksi sebagai positif oleh FP, jumlah data yang salah diprediksi sebagai negatif oleh FN, dan jumlah data yang diprediksi dengan benar sebagai negatif oleh TN [16].



Gambar 2. Arsitektur GRU

	title	label	label_score
0	Masuk Radar Pilwalkot Medan, Menantu Jokowi Be...	non-clickbait	0
1	Malaysia Sudutkan RI: Isu Kabut Asap hingga In...	non-clickbait	0
2	Virall Driver Ojol di Bekasi Antar Pesanan Mak...	clickbait	1
3	Kemensos Salurkan Rp 7,3 M bagi Korban Kerusuh...	non-clickbait	0
4	Terkait Mayat Bayi Mengenakan di Tangerang, S...	non-clickbait	0

Gambar 3. Kolom yang digunakan

1) Accuracy

Akurasi merupakan perbandingan antara jumlah prediksi yang benar dengan total keseluruhan prediksi yang dilakukan [17].

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (5)$$

2) Precision

Precision dalam menghitung bagian dari prediksi positif yang konsisten dengan nilai positif yang sebenarnya [17].

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

3) Recall

Recall yang juga disebut sebagai sensitivitas, mengukur seberapa banyak kasus positif yang benar-benar diidentifikasi dengan tepat oleh model [17].

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

4) F1-Score

F1-Score adalah rata-rata kombinasi dari *Precision* dan *Recall*, yang digunakan untuk mencapai keseimbangan antara kedua ukuran tersebut[17].

$$F1 - Score = 2 \left(\frac{Precision \times Recall}{Precision+Recall} \right) \quad (8)$$

III. HASIL DAN PEMBAHASAN

A. Data Collecting and Data Understanding

Pada penelitian ini, data yang akan digunakan adalah data yang telah dilabeli dengan kalimat judul sebagai satu-satunya dasar penilaian [18] seperti yang terlihat pada gambar 3.

TABEL 1
Slang Word Dictionary

Slang Word	Formal Word
....	...
pilwalkot	pemilihan wali kota
ri	republik indonesia
ortu	orang tua
gue	saya
...	...

TABEL 2
Hasil Data Cleaning dan Preprocessing

Sebelum	Sesudah
Viral! Driver Ojol di Bekasi Antar Pesanan Makanan Pakai Sepeda	viral <e> pengemudi ojek online dibekasi antar pesanan makanan pakai sepeda
Masuk Radar Pilwalkot Medan, Menantu Jokowi Bertemu DPW NasDem Sumut	masuk radar pemilihan wali kota medan <c> menantu jokowi bertemu dewan pimpinan wilayah nasdem sumatera utara
Malaysia Sudutkan RI: Isu Kabut Asap hingga Invasi Babi	malaysia sudutkan republik indonesia isu kabut asap hingga invasi babi

TABEL 3
Skenario Model

Skenario	Model
1	FastText + GRU
2	Word2Vec + GRU

B. Data Cleaning and Preprocessing

Setelah penghapusan kolom yang tidak digunakan dan data duplikat, proses dilanjutkan dengan pembersihan teks dan *pre-processing*. Tabel 1 adalah potongan kamus untuk menormalisasi *slang* atau *typo* pada *dataset*. Perubahan sebelum dan sesudah data dibersihkan dan dinormalisasikan sebagaimana yang ditunjukkan pada tabel 2 data teks lebih rapi, konsisten, dan siap diproses pada tahap berikutnya.

C. Data Preparation

Pada tahap *data preparation*, label dikonversi ke numerik, *clickbait* jadi 1 dan *non-clickbait* jadi 0, data dibagi menjadi tiga bagian, kemudian teks ditokenisasi dengan Tokenizer Keras berbasis kamus data latih, dan panjang judul diseragamkan melalui *post-padding* hingga panjang maksimum.

D. Modelling

Dalam penelitian ini, dirancang dua skenario model seperti pada tabel 3. Penelitian ini menggunakan dua *pretrained embedding*, yakni FastText dan Word2Vec, untuk menilai dampak perbedaan representasi kata terhadap kinerja model GRU dalam mengklasifikasikan judul *clickbait*.

1) Skenario 1

Arsitektur FastText dan GRU diawali dengan *embedding* berdimensi 300 yang memuat bobot FastText pre-trained, kemudian Dropout, dilanjutkan ke layer GRU dengan 32 unit tersembunyi. Output GRU diteruskan ke dua *fully connected layer* masing-masing 32 dan 16 neuron dan ditutup oleh layer keluaran sigmoid berukuran 1 untuk klasifikasi biner, sebagaimana ditunjukkan pada Gambar 4.

Layer (type)	Output Shape	Param #
embedding (Embedding)	(None, 29, 300)	3,894,600
dropout (Dropout)	(None, 29, 300)	0
gru (GRU)	(None, 32)	32,064
dense (Dense)	(None, 32)	1,056
dense_1 (Dense)	(None, 16)	528
dense_2 (Dense)	(None, 1)	17

Gambar 4. Arsitektur FastText + GRU

Layer (type)	Output Shape	Param #
embedding (Embedding)	(None, 29, 300)	3,894,600
dropout (Dropout)	(None, 29, 300)	0
gru (GRU)	(None, 32)	32,064
dense (Dense)	(None, 16)	528
dense_1 (Dense)	(None, 8)	136
dense_2 (Dense)	(None, 1)	9

Gambar 5. Arsitektur Word2Vec + GRU

TABEL 4
Hasil Terbaik *Tuning Hyperparameter* FastText + GRU

Batch Size	Dropout	Learning Rate	Accuracy	F1-Score	Loss
32	0.5	6e-4	0.7780	0.7705	0.4924

Untuk memperoleh konfigurasi terbaik, dilakukan *tuning hyperparameter* secara bertahap dengan memvariasikan *batch size*, *dropout*, dan *learning rate*. Setiap kombinasi dilatih dan dievaluasi pada data validasi, lalu dipilih yang memberi akurasi tertinggi dengan *loss* terendah. Proses dibantu *EarlyStopping* dan *ModelCheckpoint* agar pelatihan berhenti saat tidak ada perbaikan dan bobot terbaik tersimpan. Konfigurasi terpilih ini yang digunakan pada tahap pengujian akhir.

Tabel 4 merangkum konfigurasi terbaik untuk skenario FastText + GRU. Konfigurasi *batch size* 32, *dropout* 0.5, dan *learning rate* 6e-4 menghasilkan performa paling stabil di data validasi, dengan akurasi 0,7780, dan loss 0,4924. Konfigurasi ini kemudian dipakai sebagai model final untuk pengujian.

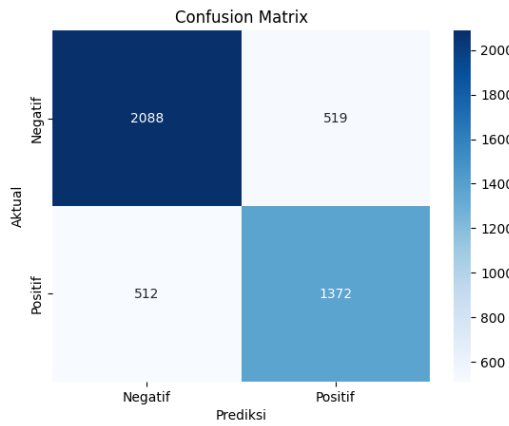
2) Skenario 2

Sama seperti FastText + GRU, arsitektur Word2Vec + GRU diawali dengan *embedding* berdimensi 300, layer dropout, layer GRU, dua *fully connected layer* yang lebih ringan berukuran 16 dan 8 neuron dan ditutup oleh layer keluaran sigmoid berukuran 1 untuk klasifikasi biner, seperti pada Gambar 5.

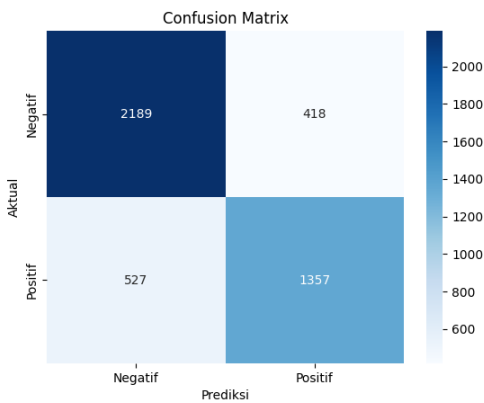
Dilakukan *tuning hyperparameter* yang sama seperti yang dilakukan pada FastText + GRU untuk mendapatkan konfigurasi terbaik.

TABEL 5
 Hasil Terbaik *Tuning Hyperparameter* Word2Vec + GRU

Batch Size	Dropout	Learning Rate	Accuracy	F1-Score	Loss
64	0.5	6e-4	0.7983	0.7886	0.4624



Gambar 6. Confusion Matrix FastText + GRU



Gambar 7. Confusion Matrix Word2Vec + GRU

Pada Tabel 5, konfigurasi Word2Vec + GRU terbaik adalah pada *batch size* 64, *dropout* 0,5, *learning rate* 6e-4 yang memberikan akurasi dan *F1-Score* tertinggi serta *loss* terendah di semua percobaan, sehingga dijadikan model final.

E. Evaluasi

1) FastText + GRU

Gambar 6 memperlihatkan *Confusion Matrix* model GRU yang menggunakan *embedding* FastText pada data uji. Dari total 2.607 sampel, model berhasil mengklasifikasikan 2.088 judul *non-clickbait* secara benar (*True Negative*), sedangkan 519 judul *non-clickbait* salah diprediksi sebagai *clickbait* (*False Positive*). Untuk kelas *clickbait* dengan total 1.884 sampel, terdapat 1.372 judul yang tepat diklasifikasikan sebagai *clickbait* (*True Positive*), sementara 512 judul masih salah dikenali sebagai *non-clickbait* (*False Negative*).

2) Word2Vec + GRU

Gambar 7 menampilkan *Confusion Matrix* untuk model GRU dengan *embedding* Word2Vec pada data uji. Model berhasil mengkategorikan 2.189 judul *non-clickbait* dengan tepat, namun masih ada 418 judul *non-clickbait* yang salah

TABEL 6

Contoh Kasus Kesalahan Prediksi (Error Analysis) Model GRU + Word2Vec

Judul	Label Asli	Hasil Prediksi	Jenis Error	Analisis Kesalahan
pemerintah provinsi jawa barat menandatangani kerja sama dengan grab <c> ini programnya	Non-Clickbait	Clickbait	False Positive	Frasa “ini programnya” memberi kesan seolah mengundang rasa ingin tahu, sehingga model cenderung menganggapnya clickbait walaupun informasinya bersifat resmi dan informatif.
revisi undang-undang komisi pemberantasan korupsi <c> ini sikap jokowi terkait dewan pengawas komisi pemberantasan korupsi	Non-Clickbait	Clickbait	False Positive	Pola “ini sikap” menekankan respons tokoh dan sering muncul pada judul yang bernuansa pemancing perhatian. Akibatnya model menggeneralisasi pola tersebut sebagai clickbait, meski konteksnya berita kebijakan.
rapat paripurna pengesahan tata tertib dewan perwakilan daerah berujung ricuh	Clickbait	Non-Clickbait	False Negative	Model cenderung menganggap non-clickbait karena struktur judulnya dominan informatif, dan menyerupai gaya pelaporan berita, sehingga unsur sensasionalnya tidak menjadi sinyal utama.
warga mestong digegerkan kemuculan harimau besar diperkebunan sawit	Clickbait	Non-Clickbait	False Negative	Tidak ada kata pemicu seperti “ini, ternyata”, sehingga terbaca seperti laporan kejadian; selain itu ada kesalahan penulisan “kemuculan” yang bisa mengurangi sinyal clickbait.

teridentifikasi sebagai *clickbait*. Sementara itu, dari kategori *clickbait*, model berhasil mengidentifikasi 1.357 judul dengan tepat, dan 527 judul *clickbait* diklasifikasikan secara keliru sebagai *non-clickbait*.

Pada Tabel 6 Contoh Kasus Kesalahan Prediksi (Error Analysis) Model GRU+Word2Vec menampilkan beberapa sampel judul berita yang masih mengalami kekeliruan klasifikasi oleh model, disertai informasi label aktual, label prediksi, serta nilai probabilitas. Penyajian ini bertujuan melengkapi evaluasi kuantitatif dengan memberikan gambaran kualitatif mengenai pola judul yang cenderung menimbulkan kebingungan, seperti adanya diksi yang ambigu atau struktur kalimat yang membuat judul terlihat mirip dengan kelas lainnya.

TABEL 7
Perbandingan Kinerja Model GRU dengan FastText dan Word2Vec

Model	Accuracy	Precision	Recall	F1-Score	Waktu Training
FastText	0.7704	0.7706	0.7704	0.7705	312 detik
Word2Vec	0.7896	0.7886	0.7896	0.7886	258 detik
Selisih	0.0192	0.0180	0.0192	0.0181	54 detik

Berdasarkan Tabel 7, Model GRU yang dikombinasikan dengan Word2Vec berhasil mencapai akurasi 0.7896, sementara kombinasi GRU dengan FastText mendapatkan akurasi 0.7704, dengan selisih sebesar 1,92%. Dari segi efisiensi, durasi pelatihan model Word2Vec selama 258 detik, lebih singkat dibandingkan dengan FastText selama 312 detik, dengan perbedaan waktu sebesar 54 detik. Pernyataan ini menunjukkan bahwa penggunaan *embedding* Word2Vec tidak hanya menghasilkan keluaran yang lebih tepat, tetapi juga lebih efisien dalam komputasi.

IV. KESIMPULAN DAN SARAN

Berdasarkan pengujian yang dilakukan, model GRU dengan *embedding* Word2Vec menunjukkan kinerja paling baik untuk klasifikasi judul berita *clickbait* dan *non-clickbait*—dengan akurasi 78,96%, *precision* 78,86%, *recall* 78,96%, *F1-Score* 78,86%, serta waktu pelatihan selama 258 detik dibandingkan GRU dengan FastText yang mencapai akurasi 77,04%, *precision* 77,06%, *recall* 77,04%, *F1-Score* 77,05%, dan waktu pelatihan selama 312 detik. Meskipun FastText memiliki cakupan kosakata sebesar 89,87% yang lebih tinggi daripada Word2Vec sebesar 86,34%, hasil menunjukkan bahwa representasi Word2Vec yang lebih tepat sasaran pada pola leksikal korpus berita memberikan klasifikasi yang lebih akurat. Secara keseluruhan, Word2Vec lebih unggul daripada FastText dalam mendukung GRU baik dari sisi akurasi maupun efisiensi pelatihan. Ke depan, kualitas model dapat ditingkatkan dengan memperluas normalisasi slang secara manual agar data latih lebih bersih, mengeksplorasi arsitektur lanjutan seperti BiGRU atau penambahan *attention mechanism*, serta melatih atau menyesuaikan *embedding* pada korpus berita Indonesia yang lebih luas agar representasi kata lebih sesuai dengan konteks *clickbait*.

KUTIPAN

- [1] N. S. Lubis and M. I. P. Nasution, "Perkembangan Teknologi Informasi Dan Dampaknya Pada Masyarakat," *KOHESI J. Multidisiplin Sainstek*, vol. 1, no. 12, pp. 41–50, 2023, [Online]. Available: <https://ejournal.warunayama.org/index.php/kohesi/article/view/1311>
- [2] Ambarul Fatima Setiawati, *RECOGNIZING ENGLISH CLICKBAIT HEADLINES: A SYNTACTIC ANALYSIS OF ENGLISH CLICKBAIT HEADLINES IN ONLINE NEWS MEDIA*, vol. 9, 2022.
- [3] M. Soedarsono, "Penggunaan Clickbait Media Online Indonesia dalam Pemberitaan Pilpres 2024," vol. 4, no. 4, pp. 938–948, 2024.
- [4] F. A. Ramadhan, S. H. Sitorus, and T. Rismawan, "Penerapan Metode Multinomial Naïve Bayes untuk Klasifikasi Judul Berita Clickbait dengan Term Frequency - Inverse Document Frequency," *J. Sist. dan Teknol. Inf.*, vol. 11, no. 1, p. 70, 2023, doi: 10.26418/justin.v11i1.57452.
- [5] M. Liebenlito, A. A. Yesinta, and M. I. S. Musti, "Deteksi Clickbait pada Judul Berita Online Berbahasa Indonesia Menggunakan FastText," *J. Appl. Comput. Sci. Technol.*, vol. 5, no. 1, pp. 56–62, 2024, doi: 10.52158/jacost.v5i1.655.

- [6] A. Nurdin, B. Anggo Seno Aji, A. Bustamin, and Z. Abidin, "Perbandingan Kinerja Word *Embedding* Word2Vec, Glove, Dan Fasttext Pada Klasifikasi Teks," *J. Tekno Kompak*, vol. 14, no. 2, p. 74, 2020, doi: 10.33365/jtk.v14i2.732.
- [7] M. H. Al-Areef and K. Saputra S., "Analisis Sentimen Pengguna Twitter Mengenai Calon Presiden Indonesia Tahun 2024 Menggunakan Algoritma LSTM," *J. SAINTIKOM (Jurnal Sains Manaj. Inform. dan Komputer)*, vol. 22, no. 2, p. 270, 2023, doi: 10.53513/jis.v22i2.8680.
- [8] Anas Fikri Hanif, Theopilus Bayu Sasongko, and Arif Dwi Laksito, "Perbandingan Kinerja LSTM, Bi-LSTM, dan GRU pada Klasifikasi Judul Berita Clickbait," *Indones. J. Comput. Sci.*, vol. 12, no. 4, pp. 2136–2150, 2023, doi: 10.33022/jics.v12i4.3281.
- [9] E. Ikhwan Saputra, Ts. Eiva Fatdha, M. Khairul Anam, and I. Artikel Abstrak, "Klasifikasi Emosi Terhadap Konflik Israel-Palestina Menggunakan Algoritma Gated Recurrent Unit," vol. 13, no. 4, pp. 6230–6242, 2024, [Online]. Available: <https://doi.org/10.33022/jics.v13i4.4106>
- [10] D. I. Af'idah, D. Dairoh, S. F. Handayani, and R. W. Pratiwi, "Pengaruh Parameter Word2Vec terhadap Performa Deep Learning pada Klasifikasi Sentimen," *J. Inform. J. Pengemb. IT*, vol. 6, no. 3, pp. 156–161, 2021, doi: 10.30591/jpit.v6i3.3016.
- [11] F. Bouchra, I. M. A. D. Suarjaya, and N. K. D. Rusjyanthi, "Analisis Sentimen Masyarakat terhadap Tayangan Televisi Nasional menggunakan Metode Deep Learning," *J. Buana Inform.*, vol. 15, pp. 89–99, 2024.
- [12] M. G. Adrian, S. S. Prasetyowati, and Y. Sibaroni, "Effectiveness of Word *Embedding* GloVe and Word2Vec within News Detection of Indonesian uUsing LSTM," *J. Media Inform. Budidarma*, vol. 7, no. 3, p. 1180, 2023, doi: 10.30865/mib.v7i3.6411.
- [13] R. Adipradana, B. P. Nayoga, R. Suryadi, and D. Suhartono, "Hoax analyzer for indonesian news using rnns with fasttext and glove *embeddings*," *Bull. Electr. Eng. Informatics*, vol. 10, no. 4, pp. 2130–2136, 2021, doi: 10.11591/eei.v10i4.2956.
- [14] K. Danil, "Pengenalan Jenis Kelamin dalam Lingkungan Multiaksen Menggunakan Metode Multi Layer Perceptron (MLP) dan Gated Recurrent Unit (GRU)," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 3, pp. 803–811, 2024, doi: 10.57152/malcom.v4i3.1323.
- [15] A. P. Meriani and A. Rahmatulloh, "Perbandingan Gated Recurrent Unit (Gru) Dan Algoritma Long Short Term Memory (Lstm) Linear Refression Dalam Prediksi Harga Emas Menggunakan Model Time Series," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 1, 2024, doi: 10.23960/jitet.v12i1.3808.
- [16] M. F. R. Akbari, B. Rahayudi, and L. Muflikhah, "Implementasi Deep Learning menggunakan Algoritma EfficientDet untuk Sistem Deteksi Kelayakan Penerima Bantuan Langsung Tunai berdasarkan Citra Rumah di Wilayah Kabupaten Kediri," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 4, pp. 1817–1825, 2023.
- [17] A. D. Salea, M. A. M. Hayat, and F. I. Rahman, "Penerapan Word *Embedding* Fasttext Dalam Analisis Sentimen Review Aplikasi JAKI Menggunakan Metode CNN," vol. 6, no. 2, pp. 102–107, 2024.
- [18] A. William and Y. Sari, "CLICK-ID: A novel dataset for Indonesian clickbait headlines," *Data Br.*, vol. 32, 2020, doi: 10.1016/j.dib.2020.106231.

TENTANG PENULIS



Bernama lengkap **Desriyanti Dea**. Lahir di Makale pada tanggal 8 Desember 2002. Penulis merupakan anak ketiga dari lima bersaudara. Penulis menempuh pendidikan dasar di SD Kristen Makale 2, kemudian melanjutkan pendidikan ke SMP Negeri 1 Makale, setelah itu melanjutkan pendidikan di SMA Negeri 5 Tana Toraja. Pada tahun 2021 penulis melanjutkan pendidikan di Universitas Sam Ratulangi Manado Program Studi S-1 Teknik Informatika Jurusan Teknik Elektro Fakultas Teknik.