

PENERAPAN WESTCLASS UNTUK ANALISIS SENTIMEN KEBIJAKAN PPN 12% BERBASIS DATA MEDIA SOSIAL X

Muhammad Shidiq Waliuddin^{1*}, Oddy Virgantara Putra², Triana Harmini³
dan Nurhana Marantika⁴

^{1,2,3,4} Jurusan Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Darussalam Gontor
Jl. Raya Siman, Dusun I, Demangan, Kec. Siman, Kabupaten Ponorogo, Jawa Timur 63472.

*Email: muhammadshidiqwaliuddin43@student.cs.unida.gontor.ac.id

Abstrak

Kenaikan Pajak Pertambahan Nilai (PPN) menjadi 12% memunculkan respons publik yang luas di platform X, sehingga diperlukan analisis sentimen untuk memahami persepsi masyarakat. Namun, dominasi data tidak berlabel menjadikan pendekatan supervised learning kurang optimal. Penelitian ini menerapkan WeSTClass sebagai metode weakly supervised learning dengan memanfaatkan seed word dan pseudo-document berbasis distribusi von Mises–Fisher (vMF) untuk membangun representasi awal tanpa memerlukan banyak data berlabel. Data penelitian terdiri dari 13.962 tweet terkait isu PPN 12%, dengan 2.980 data diberi label manual oleh seorang pakar. Proses pembangkitan pseudo-document menghasilkan 150 dokumen semu yang memperkaya distribusi semantik tiap kelas sentimen. Model CNN digunakan sebagai classifier utama, dilatih melalui tahapan pre-training dan self-training berbasis pseudo-label berkeyakinan tinggi. Hasil evaluasi menunjukkan bahwa CNN memberikan performa terbaik dengan akurasi 0.83 dan F1-Macro 0.72, mengungguli BiLSTM dan SVM. Temuan ini menunjukkan bahwa pendekatan weak supervision melalui WeSTClass efektif dalam mengatasi keterbatasan data berlabel dan meningkatkan stabilitas model pada analisis sentimen berbasis media sosial.

Kata kunci: Analisis Sentimen, CNN, PPN 12%, Pseudo-Document, WeSTClass

1. PENDAHULUAN

Kebijakan kenaikan Pajak Pertambahan Nilai (PPN) menjadi 12% menimbulkan dinamika opini publik yang cukup kuat, khususnya di platform X (Twitter), yang banyak digunakan masyarakat untuk menyampaikan respons secara langsung. Menurut (Duei Putri, Nama and Sulistiono, 2022), pada awal 2013 pengguna Twitter mengirimkan lebih dari 500 juta kicauan per hari. Analisis sentimen terhadap isu ini diperlukan untuk memahami persepsi publik, namun penelitian berbasis media sosial umumnya menghadapi keterbatasan data berlabel dan dominasi data tidak berlabel. Kondisi ini membuat metode supervised learning kurang efektif, terutama pada teks pendek dan distribusi kelas yang tidak seimbang. Untuk mengatasi tantangan tersebut, pendekatan weakly supervised learning seperti WeSTClass menjadi relevan karena memanfaatkan seed keywords dan pseudo-document berbasis distribusi von Mises–Fisher (vMF) untuk membentuk representasi awal tanpa memerlukan banyak label. WeSTClass kemudian menggabungkan tahap pre-training dan self-training, di mana pseudo-label berkeyakinan tinggi digunakan untuk memperluas data latih. Penelitian ini mengimplementasikan WeSTClass bersama CNN untuk menganalisis sentimen publik terkait kenaikan PPN 12%, dengan evaluasi menggunakan Accuracy, F1-Macro, dan F1-Micro.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

2.1.1 Preprocessing

Pada tahap ini, preprocessing dilakukan untuk meningkatkan konsistensi representasi kata dan mengurangi *noise* pada data teks sehingga lebih siap digunakan dalam analisis sentimen. Proses ini meliputi *lowercasing* untuk menyeragamkan huruf, penghapusan URL yang tidak relevan, penyaringan karakter non-alfanumerik, serta normalisasi spasi agar teks lebih rapi dan terstruktur.

Dengan tahapan ini, data mentah dapat diubah menjadi teks yang bersih dan konsisten sebelum masuk ke tahap representasi fitur ataupun *embedding*.

2.1.2 Tokenisasi dan Embedding FastText

Setelah tahap preprocessing, dilakukan tokenisasi menggunakan modul *Tokenizer* dari Keras untuk mengubah teks yang telah dibersihkan menjadi representasi numerik melalui pembentukan kamus kata dan konversi setiap tweet menjadi urutan indeks menggunakan *texts_to_sequences*, kemudian diseragamkan panjangnya dengan *padding*. Representasi numerik ini selanjutnya menjadi input bagi *word embedding FastText* yang dikembangkan oleh (Grave *et al.*, 2019), yang membangun vektor kata berbasis *subword* melalui *character n-grams*, sehingga mampu merepresentasikan kata jarang maupun kata baru. FastText dilatih menggunakan korpus besar Wikipedia dan Common Crawl, di mana penggunaan Common Crawl yang bersifat *noisy* justru memberikan cakupan representasi kata yang lebih luas dan terbukti meningkatkan kualitas model pada bahasa dengan sumber data terbatas (Grave *et al.*, 2019).

2.1.3 Pseudo-documents dengan vMF

Pada penelitian ini, pseudo-document dihasilkan untuk memperkaya data latih yang terbatas. Pembangkitan dilakukan dengan memanfaatkan *seed word* tiap kelas sentimen yang diproyeksikan ke ruang embedding sehingga diperoleh representasi semantik kelas (Meng *et al.*, 2018). Distribusi von Mises–Fisher (vMF) digunakan karena efektif memodelkan data pada permukaan unit *sphere* dan memberikan struktur kluster yang lebih baik dibandingkan Gaussian (Xu *et al.*, 2023). Fungsi densitasnya didefinisikan sebagai:

$$f(x | \mu, \kappa) = C_d(\kappa) \exp(\kappa \mu^T x), \quad x \in R^d, |x| = 1$$

Dengan μ sebagai mean direction dan κ sebagai parameter konsentrasi. Nilai κ mengatur tingkat keterpusatan distribusi, sedangkan konstanta normalisasi $C_d(\kappa)$ bergantung pada modified Bessel function.

Mean direction untuk setiap kelas diperoleh dari rata-rata *embedding seed* yang dinormalisasi:

$$\mu = \frac{\sum_{i=1}^n v_i}{|\sum_{i=1}^n v_i|}, \quad v_i = \frac{w_i}{|w_i|}$$

Parameter konsentrasi κ dihitung menggunakan panjang resultan rata-rata \bar{R} :

$$\bar{R} = \left| \frac{1}{n} \sum_{i=1}^n v_i \right|, \quad \kappa \approx \frac{\bar{R}(d - \bar{R}^2)}{1 - \bar{R}^2}$$

Dengan μ dan κ tersebut, vektor baru disampling menggunakan algoritme Wood/Ulrich, lalu diproyeksikan ke kata terdekat dalam ruang embedding untuk membentuk *pseudo-document* sesuai kelas sentimen. *Pseudo-document* selanjutnya digabungkan dengan data berlabel asli untuk membentuk dataset latih yang lebih besar dan representatif sebelum digunakan pada pelatihan CNN.

2.1.4 Arsitektur CNN dan WeSTClass

Arsitektur yang digunakan dalam penelitian ini menggabungkan metode Weakly-Supervised Text Classification (WeSTClass) dengan Convolutional Neural Network (CNN) sebagai model klasifikasi utama. Dataset gabungan yang terdiri dari data berlabel dan pseudo-document digunakan pada tahap pre-training untuk memperkuat representasi awal model. CNN dipilih karena efektif dalam mengekstraksi pola lokal melalui operasi satu dimensi (Conv1D), yang lebih sesuai untuk

pemrosesan teks dibandingkan konvolusi dua dimensi (He *et al.*, 2024). Input berupa urutan token bertipe tetap (*maxlen*) dipetakan ke ruang embedding berdimensi *emb_dim* melalui lapisan embedding non-trainable yang menggunakan matriks *emb_matrix* hasil pelatihan FastText.

2.1.5 Pre-training dan Self-training

Pada tahap pretraining, model CNN dilatih menggunakan data gabungan berupa data berlabel dan pseudo-document hasil distribusi von Mises–Fisher (vMF) untuk memperoleh representasi awal yang kaya meskipun data berlabel terbatas, karena metode unsupervised murni tidak mampu memberikan kinerja yang sebanding meskipun telah menggunakan seed word terbaik (Xu *et al.*, 2023). Setelah pretraining, dilakukan self-training berbasis *confidence*, di mana data tak berlabel dengan prediksi berkeyakinan tinggi digunakan sebagai pseudo-label menggunakan $\hat{y}_i = \arg \max(p_i)$ dan hanya sampel dengan $\max(p_i) \geq \tau$ yang ditambahkan ke training set. Strategi ini memastikan bahwa data tambahan memiliki kualitas tinggi dan sejalan dengan prinsip yang dijelaskan oleh (He *et al.*, 2024), bahwa hanya data dengan tingkat keyakinan tinggi yang efektif dimanfaatkan dalam pembelajaran model. Tahapan ini menghasilkan mekanisme pelatihan adaptif yang relevan untuk kondisi data berlabel terbatas

2.1.6 Evaluasi

Evaluasi kinerja dilakukan setelah pre-training dan self-training menggunakan dua metrik utama, yaitu F1-macro dan F1-micro, untuk tiga kelas sentimen: positif, netral, dan negatif. F1-macro memberikan rata-rata F1 tiap kelas sehingga efektif menangani ketidakseimbangan data, sedangkan F1-micro menghitung performa agregat berdasarkan total *true positives*, *false positives*, dan *false negatives*. Pendekatan ini sejalan dengan rekomendasi Hinojosa Lee *et al.* (Cristina *et al.*, 2024), yang menekankan pentingnya kombinasi varian F1-score untuk memperoleh gambaran evaluasi yang lebih komprehensif pada data tidak seimbang.

2.2 Dataset

Kumpulan data pada studi ini berasal dari tweet berbahasa Indonesia yang berisi opini publik mengenai kebijakan kenaikan Pajak Pertambahan Nilai (PPN) 12% di Indonesia. Media sosial X terbukti relevan untuk analisis opini masyarakat terhadap isu nasional, sebagaimana dijelaskan dalam studi (Bere *et al.*, 2024). Data dikumpulkan secara daring melalui Tweet Harvest menggunakan autentikasi token, sehingga proses pengambilan data berlangsung otomatis dan efisien. Pengumpulan dilakukan mulai 20 Oktober 2024 hingga 28 Februari 2025 dengan kata kunci PPN 12%, menghasilkan 13.962 tweet dalam format CSV. Dari jumlah tersebut, 2.980 data dipilih untuk pelabelan manual oleh seorang Dosen Ilmu Komunikasi. Data berlabel ini menjadi dasar penting bagi pelatihan model agar konsistensi linguistik tetap terjaga meskipun pendekatan yang digunakan bersifat weak supervision.

3. HASIL DAN PEMBAHASAN.

3.1 Deskripsi Dataset

Dataset penelitian ini berjumlah 13.965, terdiri dari 2.980 data berlabel yang terbagi ke dalam tiga kelas sentimen: positif, negatif, dan netral dan 10.985 data tidak berlabel. Dominasi data tidak berlabel (lebih dari 78%) membuat pendekatan fully supervised kurang efektif, sehingga diperlukan strategi weakly supervised learning. Studi sebelumnya menunjukkan bahwa ketika data berlabel terbatas namun data tidak berlabel melimpah, metode weak supervision atau pseudo-labeling mampu meningkatkan performa klasifikasi dibandingkan supervised learning murni (Chen and Ding, 2022).

3.2 Preprocessing

Tahap preprocessing membersihkan data mentah X dengan menghapus elemen non-teks seperti tautan, hashtag, dan karakter khusus melalui case folding, penghapusan URL, simbol, dan normalisasi spasi. Proses ini menghasilkan teks terstruktur dalam format lowercase yang siap untuk

ekstraksi fitur model deep learning (Handoko et al., 2024). Tabel 1 menyajikan contoh hasil preprocessing. Kolom *full_text* menunjukkan teks asli, sedangkan kolom *text* menampilkan hasil pembersihan setelah proses cleaning. Terlihat bahwa tautan dan simbol khusus berhasil dihapus tanpa mengubah makna utama teks.

Tabel 1. Hasil Preprocessing

No	Full Text	Text
1	Kena juga ppn 12% #PPN12Persenhttps://t.co/...	kena juga ppn 12 ppn12persen
2	PPN 12% buat barang mewah solusi tepat yang berbeda...	ppn 12 buat barang mewah solusi tepat yang berbeda
3	Dengan PPN 12% dana bantuan sosial tetap dapat disalurkan...	dengan ppn 12 dana bantuan sosial tetap dapat disalurkan
4	Ini kayaknya total harga langsung di x 12% ya kak...	ini kayaknya total harga langsung di x 12 ya kak
5	Semua untuk keadilan ekonomi PPN 12% mencerminkan...	semua untuk keadilan ekonomi ppn 12 mencerminkan

Preprocessing yang efektif memerlukan tahapan case folding, tokenizing, stopword removal, dan normalization untuk mengurangi *noise* dan meningkatkan akurasi model (Dianda et al., 2023). Pada penelitian ini, stemming dan lemmatization tidak diterapkan karena arsitektur *CNN* secara *inheren* mampu mengekstraksi pola dan fitur dari variasi kata (word variations) dalam data pelatihan.

3.3 Tokenisasi dan Embedding

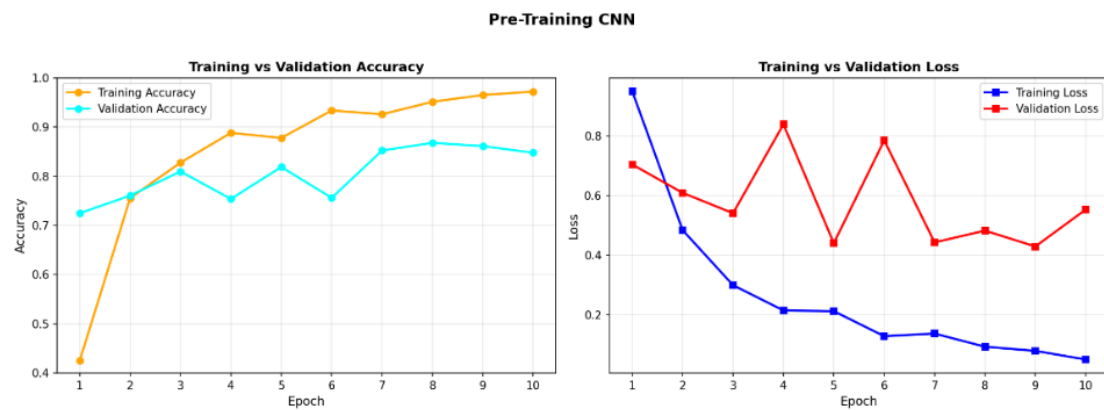
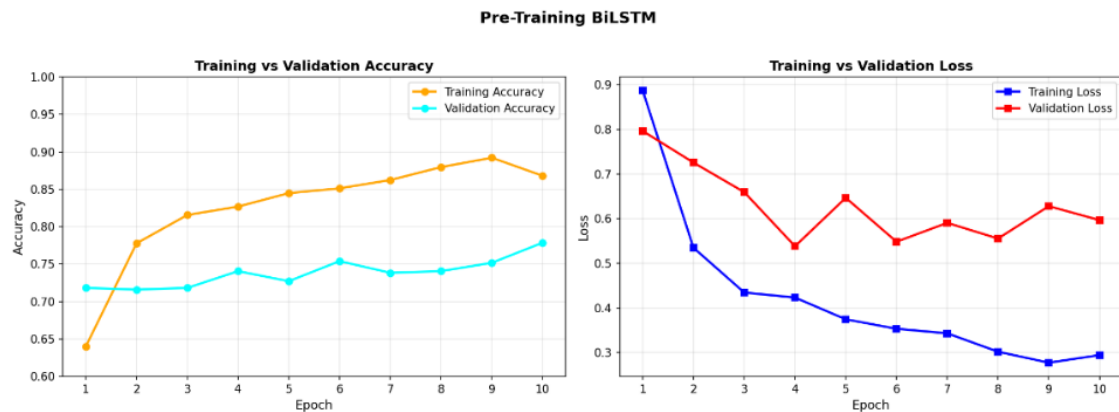
Penerapan tokenisasi dan embedding terbukti membantu model *CNN* dalam mengekstraksi pola semantik secara lebih stabil pada data sentimen. Representasi numerik yang dihasilkan Tokenizer dan padding (Satrio et al., 2024) membuat distribusi input lebih konsisten, sehingga model tidak sensitif terhadap variasi panjang teks. Penggunaan embedding Word2Vec berdimensi 300 (GeeksforGeeks, 2024) meningkatkan kemampuan *CNN* dalam menangkap hubungan semantik antar kata, yang berkontribusi pada peningkatan akurasi dan konsistensi prediksi. Temuan ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa *embedding* yang kaya informasi dapat memperbaiki performa model *neural* dalam tugas klasifikasi teks (Yuhana et al., 2022).

3.4 Pembuatan Pseudo-doc berbasis vMF

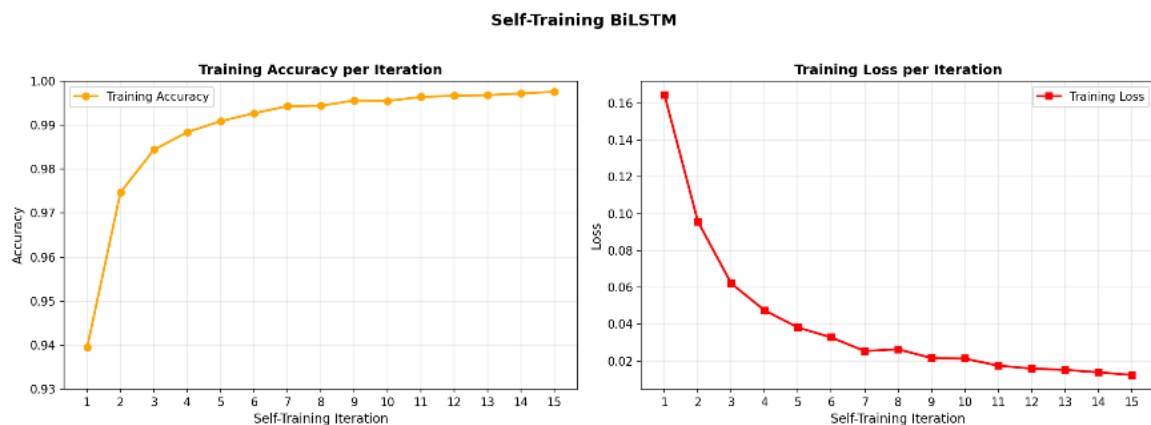
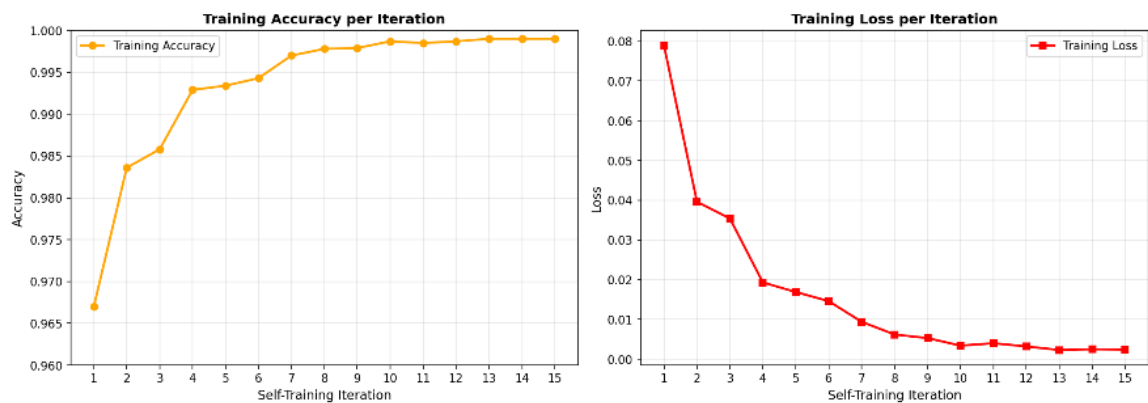
Proses pembangkitan dokumen semu menggunakan distribusi von Mises–Fisher (vMF) menghasilkan 150 pseudo-document yang tetap mempertahankan ciri semantik tiap kelas sentimen. Nilai konsentrasi vMF menunjukkan perbedaan struktur makna: kelas positif memiliki konsentrasi tertinggi ($\kappa = 408.53$), sedangkan kelas negatif lebih rendah ($\kappa = 313.31$) sehingga variasinya lebih luas. Selain menambah data, pseudo-document ini memperkaya variasi leksikal yang relevan. Pendekatan ini efektif dalam memperluas informasi seed secara fleksibel sebagaimana dijelaskan oleh Meng et al. (2018).

3.5 Hasil Pre-Train dan Self-Train

Pada tahap pre-training, performa model BiLSTM dan *CNN* dianalisis melalui grafik akurasi dan loss untuk melihat pola pembelajaran awal sebelum memasuki fase *fine-tuning*. Berdasarkan grafik, model BiLSTM menunjukkan peningkatan akurasi pelatihan yang konsisten, namun akurasi validasi cenderung fluktuatif sehingga memunculkan indikasi *overfitting* ringan. Sebaliknya, *CNN* memperlihatkan pola pembelajaran yang lebih stabil dan seimbang, dengan tren akurasi validasi yang meningkat dan loss yang lebih terkendali. Kedua hasil visualisasi tersebut ditampilkan pada Gambar 1 sebagai dasar interpretasi performa awal model sebelum evaluasi kuantitatif lebih lanjut.



Gambar 1. Hasil Epoch Pre-training



Gambar 2. Hasil Epoch Self-training

Pada tahap self-training, data tidak berlabel dimanfaatkan melalui pseudo-labeling (threshold ≥ 0.9), di mana sampel berkonfiden tinggi ditambahkan secara bertahap ke dataset. Pada CNN, akurasi pelatihan meningkat hampir sempurna dan loss turun drastis, namun performa uji justru menurun, mengindikasikan noise accumulation akibat sensitivitas CNN terhadap pseudo-label yang keliru. Sebaliknya, BiLSTM menunjukkan peningkatan akurasi dan penurunan loss yang lebih stabil, disertai kenaikan performa uji. Mekanisme gating pada LSTM membantu menyaring pseudo-label secara lebih selektif sehingga generalisasi model tetap terjaga. Grafik pelatihan kedua model ditunjukkan pada Gambar 2.

3.6 Hasil Evaluasi

Hasil evaluasi menunjukkan adanya perbedaan sensitivitas model terhadap ketidakseimbangan kelas. CNN mencapai akurasi tertinggi sebesar 0.83 dengan F1-Macro 0.72, menegaskan kemampuannya dalam mengekstraksi pola lokal pada teks. BiLSTM memperoleh akurasi 0.77 dengan F1-Macro 0.42 karena kesulitan mengenali kelas minoritas sehingga prediksinya kurang seimbang. SVM meraih akurasi 0.72 dan F1-Macro 0.28, menunjukkan keterbatasan representasi TF-IDF dalam menangkap konteks sentimen. Secara keseluruhan, CNN merupakan model yang paling stabil dalam kondisi data tidak seimbang. Ringkasan lengkap performa seluruh model disajikan pada Tabel berikut.

Tabel 2. Hasil Evaluasi

Model	Accuracy	F1-Macro
CNN	0.83	0.72
BiLSTM	0.77	0.42
SVM	0.72	0.28

4. Kesimpulan

Penelitian ini menunjukkan bahwa pendekatan weakly supervised learning melalui WeSTClass efektif digunakan pada kondisi data berlabel minim dan ketidakseimbangan kelas. Pseudo-document berbasis vMF dan pseudo-labeling terbukti meningkatkan kualitas representasi semantik sehingga model dapat belajar lebih stabil. CNN memberikan performa terbaik dibandingkan BiLSTM dan SVM, menunjukkan efektivitas ekstraksi fitur lokal pada teks pendek. Secara keseluruhan, metode weak supervision sangat relevan untuk analisis sentimen media sosial berskala besar dengan label terbatas.

DAFTAR PUSTAKA

- Bere, M.E. *et al.* (2024) 'Implementasi Algoritma Naive Bayes Classifier Terhadap Analisis Sentimen Kondisi Stunting di Indonesia Pada Media Sosial X', 7(4), pp. 598–605.
- Cristina, M. *et al.* (2024) 'applied sciences Performance Metrics for Multilabel Emotion Classification : Comparing Micro , Macro , and Weighted F1-Scores'.
- Duei Putri, D., Nama, G.F. and Sulistiono, W.E. (2022) 'Analisis Sentimen Kinerja Dewan Perwakilan Rakyat (DPR) Pada Twitter Menggunakan Metode Naive Bayes Classifier', *Jurnal Informatika dan Teknik Elektro Terapan*, 10(1), pp. 34–40. Available at: <https://doi.org/10.23960/jitet.v10i1.2262>.
- GeeksforGeeks (2024) *Word Embeddings in NLP*. Available at: <https://www.geeksforgeeks.org/nlp/word-embeddings-in-nlp/> (Accessed: 11 November 2025).
- Grave, E. *et al.* (2019) 'Learning word vectors for 157 languages', *LREC 2018 - 11th International Conference on Language Resources and Evaluation*, pp. 3483–3487.
- He, Y. *et al.* (2024) 'Semi-Supervised Reward Modeling via Iterative Self-Training', pp. 7365–7377.
- Meng, Y. *et al.* (2018) 'Weakly-supervised neural text classification', *International Conference on Information and Knowledge Management, Proceedings*, pp. 983–992. Available at:

<https://doi.org/10.1145/3269206.3271737>.

Satrio, B. *et al.* (2024) 'Klasifikasi Sentimen Emosi Pada Dataset Goemotion Menggunakan LSTM', 7(1), pp. 21–25.

Xu, W. *et al.* (2023) 'vONTSS: vMF based semi-supervised neural topic modeling with optimal transport', *Proceedings of the Annual Meeting of the Association for Computational Linguistics*, pp. 4433–4457. Available at: <https://doi.org/10.18653/v1/2023.findings-acl.271>.

Yuhana, U.L. *et al.* (2022) 'EFFECTIVENESS OF DEEP LEARNING APPROACH FOR TEXT CLASSIFICATION IN ADAPTIVE LEARNING', 11(3), pp. 137–144.