

BAB II

TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Berikut pada Tabel 2.1. Merupakan beberapa penelitian terdahulu yang menjadi acuan pada tugas akhir ini.

Tabel 2. 1. Penelitian Terdahulu

No.	Penulis (Tahun)	Kontribusi	Hasil
1.	M. S. Saputri, R. Mahendra, and M. Adriani, (2019)	Penelitian ini melibatkan klasifikasi emosi pada data Twitter dengan membandingkan beberapa metode machine learning, seperti Regresi Logistik, SVM, dan Hutan Acak, yang dikombinasikan dengan berbagai metode ekstraksi fitur, termasuk Bag-of-Words (BOW), Word2Vec (WV), dan Fast-Text (FT). Selain itu, penelitian ini mempertimbangkan tiga metode tambahan, yaitu Emotion Lexicons, Orthographic, dan POS Tag.	Hasil penelitian menunjukkan bahwa dengan menggunakan Random Forest dan menggabungkan berbagai ekstraksi fitur seperti Word2Vec (WV), Bag-of-Words (BOW), dan Fast-Text (FT), diperoleh skor F1 68,39%. Selanjutnya, dengan penambahan tiga metode tambahan, yaitu Orthographic, Emotion Lexicons, dan POS Tag, mendapatkan hasil penelitian mencapai skor F1 yang lebih tinggi sebesar

			69,73% dalam konteks "Indonesian Twitter."
2.	A. D. L, B. Harijanto, and F. Rahutomo, (2020)	Penelitian ini fokus pada klasifikasi emosi pada tweet menggunakan pendekatan Deep Learning LSTM-GloVe. Beberapa parameter yang digunakan dalam penelitian ini mencakup: Learning rate dengan dua nilai, yaitu 0,1 (half) dan 0,001. Dropout dengan dua nilai, yaitu 0,25 dan "half." Optimizer (pengoptimal) dengan dua jenis, yaitu SGD dan Adam. Penggunaan 50 epoch (siklus pelatihan) untuk proses pelatihan model. Ukuran batch sebesar 100 untuk mengelola sejumlah data yang diproses dalam satu iterasi pelatihan.	Hasil penelitian ini mengindikasikan bahwa model yang digunakan memiliki tingkat presisi sebesar 33%, tingkat recall sebesar 38%, dan skor F1 sebesar 35%. Selain itu, hasil uji model tersebut menunjukkan bahwa nilai loss (kerugian) sebesar 1,29 dan tingkat akurasi (accuracy) sebesar 0,5. Hasil ini memberikan gambaran tentang kinerja model dalam tugas klasifikasi emosi pada tweet.
3.	N. Hilmiaji, K. M. Lhaksana, and M. D.Purbolaksono, (2021).	Melakukan klasifikasi, menggunakan metode CNN dengan parameter, 50% dropout, dengan menggunakan regularisasi L2, dan mengatur learning rate	Didapatkan hasil penelitian ini menunjukkan model yang dipakaai mendapatkan hasil nilai precision

		Adam Optimizer menjadi 0,0003.	90,1%, recall 90,3%, dan F1 90,2%. Adapun nilai accuracy dari pengujian model tersebut sebesar 89,8%.
4.	T. I. Sari, Z. N. Ardilla, N. Hayatin, and R. Maskat (2022).	Penelitian ini berfokus pada identifikasi tweet kasar di media sosial Indonesia dengan menggabungkan dua arsitektur jaringan saraf, yaitu LSTM (Long Short-Term Memory) dan RNN (Recurrent Neural Network). Dengan penggabungan RNN-LSTM, penelitian ini bertujuan untuk meningkatkan kemampuan model dalam mengenali dan mengidentifikasi komentar-komentar kasar dalam konteks media sosial Indonesia.	Hasil penelitian ini menunjukkan bahwa model yang digunakan memiliki tingkat presisi (precision) sebesar 94%, tingkat recall sebesar 95%, dan skor F1 sebesar 94%. Selain itu, akurasi (accuracy) model dari pengujian mencapai sebesar 89,8%. Hasil ini menggambarkan kinerja yang sangat baik dalam identifikasi cuitan di lingkungan media sosial Indonesia dengan penggabungan arsitektur RNN-LSTM.

2.2. Depresi

Depresi menjadi salah satu masalah sosial utama dan terus meningkat setiap hari, Orang yang depresi merasa sedih, putus asa secara teratur, kehilangan minat dalam beraktivitas dan mengalami gejala fisik seperti sakit kronis atau masalah pencernaan , jutaan orang menderita depresi dan hanya sebagian kecil sebagian kecil dari mereka menjalani perawatan yang tepat. Jumlah orang yang depresi adalah 3,4% dari populasi dunia. Dibandingkan dengan gangguan mental lainnya, depresi menempati urutan ke-2 memiliki bagian tertinggi dari populasi global.

2.3. Long Short-Term Memory (LSTM)

Dalam LSTM (Long Short-Term Memory), terdapat komponen khusus yang disebut sebagai "blok memori" di dalam lapisan tersembunyi rekuren. Blok memori ini berisi sel memori yang memiliki koneksi internal yang memungkinkan mereka untuk menyimpan dan mempertahankan status temporal jaringan. Selain itu, terdapat juga unit pengendali khusus yang disebut "gerbang" yang digunakan untuk mengontrol aliran informasi dalam sel memori. Setiap blok memori dalam arsitektur LSTM memiliki dua jenis gerbang: gerbang input dan gerbang output. Gerbang input digunakan untuk mengatur berapa banyak informasi yang akan dimasukkan ke dalam sel memori, sedangkan gerbang output mengatur berapa banyak informasi yang akan dikeluarkan dari sel memori. Ini memberikan LSTM kemampuan yang kuat untuk mengingat informasi dalam jangka waktu yang panjang, yang sulit dicapai dengan teknik ekstraksi fitur tradisional dan RNN konvensional[18].

2.4. Recurrent Neural Network (RNN)

Dalam Jaringan Saraf Rekuren (RNN), terdapat koneksi siklik yang memungkinkan mereka menjadi alat yang kuat dalam memodelkan data berurutan. Hal ini membuat RNN lebih cocok untuk tugas yang melibatkan data urutan dibandingkan dengan jaringan saraf maju (feedforward). RNN telah berhasil digunakan dalam berbagai tugas, termasuk pelabelan urutan dan prediksi, seperti pengenalan tulisan tangan dan pemodelan bahasa. Kinerja yang baik dalam tugas-tugas ini menjadikan RNN sebagai pilihan yang populer dalam pengolahan data berurutan[17].

2.5. Embedding layer

Embedding Layer bekerja dengan cara yang mirip dengan perkalian matriks sederhana, di mana kata-kata digantikan oleh vektor padat yang sesuai atau mengubah indeks kata menjadi vektor dengan dimensi tetap. Penyisipan kata ini berfungsi sebagai representasi fitur tekstual, dan karena itu, seringkali dianggap sebagai langkah preprocessing penting dalam tugas pemrosesan bahasa alami Natural Language Processing [16].

2.6. Natural Language Toolkit (NLTK)

Dalam tahap tokenisasi menggunakan Natural Language Toolkit (NLTK), dilakukan pemecahan kalimat menjadi unit-unit kata, tanda baca, dan frasa-frasa yang memiliki makna berdasarkan aturan bahasa yang berlaku. Proses ini membantu dalam memahami struktur teks dan memungkinkan analisis lebih lanjut dalam pemrosesan bahasa alami.

2.7. Dense Layer

Lapisan Dense adalah bagian dari jaringan saraf yang memiliki koneksi yang mendalam dengan lapisan sebelumnya, di mana setiap neuron dalam lapisan tersebut terhubung ke setiap neuron pada lapisan sebelumnya. Lapisan Dense melakukan perkalian antara matriks dan vektor, menghasilkan vektor output dengan dimensi 'm'. Penggunaan Lapisan Dense adalah umum dalam pembentukan model jaringan saraf.

2.8. Dropout Layer

Dropout merupakan salah satu Teknik regularisasi yang sederhana dengan efisien untuk melakukan generalisasi yang lebih baik. Lapisan Dropout diterapkan dengan tujuan mengendalikan overfitting. Dropout bekerja dengan cara secara acak menonaktifkan sebagian neuron dalam lapisan dengan memberikan bobot pada setiap probabilitas posterior yang diberikan oleh data pelatihan. Hal ini membantu menjaga ukuran model tetap dengan merata-ratakan prediksi, sehingga mencegah model terlalu memfokuskan pada detail-detail kecil dalam data pelatihan dan meningkatkan generalisasi model terhadap data yang belum pernah dilihat sebelumnya[19].

Dropout melakukan pemutusan secara acak pada bagian neuron dalam proses

pelatihan. Dimana nilai dropout adalah antara 0 dan 1. Memaksa lapisan untuk penutupan beberapa bagian seperti 50% dari neuron mereka untuk mengurangi overfitting.

2.9. Rectified Linear Unit (Relu)

Reduce LR On Plateau adalah teknik penjadwalan yang berfungsi untuk mengawasi metrik tertentu, seperti loss atau akurasi, dan mengurangi laju pembelajaran (learning rate) ketika metrik tersebut telah mencapai tingkat yang stagnan atau berhenti meningkat. Penurunan laju pembelajaran ini didasarkan pada pemantauan apakah metrik tersebut telah mencapai ambang batas tertentu yang telah ditentukan. Teknik ini digunakan untuk membantu model jaringan saraf konvergen dengan lebih baik dan menghindari overshooting ketika metrik pelatihan tidak lagi memperlihatkan peningkatan yang signifikan.

2.10. Adam Optimizer

Adam Optimizer adalah algoritma pengoptimalan yang dirancang khusus untuk jaringan saraf. Algoritma ini menghitung laju pembelajaran secara individual untuk setiap parameter dalam jaringan. Adam merupakan pengembangan dari algoritma Stochastic Gradient Descent (SGD), yang digunakan untuk memperbarui parameter jaringan pada setiap iterasi pelatihan dengan mempertimbangkan data pelatihan.

Keunggulan utama dari Adam Optimizer adalah kemampuannya dalam mengatur laju pembelajaran secara adaptif untuk setiap parameter berdasarkan perubahan gradien. Hal ini membantu mempercepat pelatihan jaringan dan membuatnya lebih stabil. Adam adalah salah satu dari sejumlah algoritma pengoptimalan yang digunakan dalam pelatihan jaringan saraf untuk mengoptimalkan bobot dan parameter agar sesuai dengan data pelatihan.[20].