

BAB II

TINJAUAN PUSTAKA

2.1 Studi Terdahulu

Sebelumnya, Terdapat penelitian terdahulu yang mengandalkan jurnal yang melakukan tinjauan literatur sistematis untuk mengidentifikasi dan menganalisis berbagai studi mengenai penggunaan deep learning dalam analisis sentimen. Tinjauan literatur sistematis ini mengumpulkan data dari berbagai penelitian yang dipublikasikan antara tahun 2020 hingga 2023, dengan tujuan mengidentifikasi tren dalam penggunaan model deep learning untuk analisis sentimen. Fokus utama dari tinjauan ini adalah mengevaluasi model-model deep learning yang paling banyak digunakan oleh para peneliti dan menilai tingkat akurasi yang dicapai oleh masing-masing model tersebut dalam klasifikasi sentimen.

Dalam penelitian ini [11], perhatian khusus diberikan kepada teknik-teknik deep learning yang terbukti memberikan hasil akurasi tertinggi dalam analisis sentimen. Dengan memahami model mana yang paling efektif dan mengapa, peneliti dapat memperoleh wawasan yang berharga tentang perkembangan terbaru dalam bidang ini serta bagaimana teknik deep learning dapat dioptimalkan untuk tugas-tugas analisis sentimen di masa depan. Hasil dari tinjauan literatur sistematis ini diharapkan dapat memberikan panduan bagi peneliti lain dalam memilih dan menerapkan model deep learning yang paling sesuai untuk analisis sentimen, serta berkontribusi terhadap peningkatan akurasi dan efisiensi dalam penelitian di bidang ini.

Penelitian ini mengadopsi pendekatan yang sistematis dalam mengumpulkan dan menilai artikel-artikel yang relevan dengan topik analisis sentimen berbasis deep learning. Dengan menggunakan alat bantu seperti Publish or Perish 8, peneliti berhasil mengidentifikasi 400 artikel terindeks di Scopus yang berkaitan dengan topik penelitian. Setelah itu, artikel-artikel ini dianalisis lebih lanjut menggunakan berbagai aplikasi manajemen referensi seperti Zotero dan Mendeley, serta alat analisis seperti Microsoft Excel dan VOS Viewer. Proses ini membantu peneliti

menyaring artikel-artikel yang paling relevan dan bermanfaat untuk penelitian mereka.

Hasil analisis menunjukkan bahwa metode LSTM (Long Short-Term Memory) dan CNN (Convolutional Neural Network) merupakan teknik yang paling umum digunakan dalam analisis sentimen berbasis deep learning. Kedua metode ini digunakan secara individual maupun dalam kombinasi untuk mencapai hasil analisis yang lebih baik. Selain itu, temuan menunjukkan bahwa metode LSTM secara konsisten mencapai tingkat akurasi yang tinggi, dengan nilai tertinggi mencapai 99% dan rata-rata sebesar 89%.

2.2 Sentimen

Sentimen atau opini merupakan evaluasi atau pandangan seseorang terhadap suatu subjek, topik, atau peristiwa. Ini mencakup perasaan, sikap, dan keyakinan yang bisa positif, negatif, atau netral. Sentimen bisa dipengaruhi oleh berbagai faktor, termasuk pengalaman pribadi, nilai-nilai budaya, informasi yang diterima, dan konteks sosial. [12]

Dalam konteks analisis data, sentimen sering kali diidentifikasi melalui teks atau data lainnya dengan menggunakan teknik-teknik pemrosesan bahasa alami atau analisis data, seperti analisis teks untuk menentukan apakah suatu teks mengandung sentimen positif, negatif, atau netral. Sentimen atau opini sering kali penting dalam berbagai bidang, termasuk pemasaran, politik, dan penelitian pasar, karena dapat memberikan wawasan tentang persepsi dan preferensi masyarakat. [13].

2.3 Sentiment analysis

Analisis sentimen menggunakan berbagai teknik pemrosesan bahasa alami (NLP) dan pembelajaran mesin untuk mengekstrak dan mengklasifikasikan sentimen yang terkandung dalam teks. Ini memungkinkan perusahaan untuk memahami opini dan pandangan pelanggan, serta mendeteksi isu-isu yang mungkin perlu ditangani. [14]

Data teks yang tersedia dalam volume besar, seperti email, obrolan dukungan pelanggan, dan komentar media sosial, dapat memberikan wawasan berharga tentang persepsi pelanggan terhadap produk atau layanan. Dengan menggunakan alat analisis sentimen, perusahaan dapat secara efisien menganalisis data ini untuk mengidentifikasi tren, menanggapi masalah yang muncul, dan membuat keputusan yang didukung oleh data.

Alat analisis sentimen dapat memberikan nilai tambah yang signifikan bagi perusahaan dalam mengelola hubungan dengan pelanggan, meningkatkan kepuasan pelanggan, dan meningkatkan pemahaman tentang pasar dan pesaing. Dengan memahami sentimen pelanggan secara tepat waktu, perusahaan dapat mengambil langkah-langkah yang diperlukan untuk memperbaiki pengalaman pelanggan dan memperkuat hubungan mereka dengan basis pelanggan. [15].

2.4 Literatur Review

Literatur review adalah metode yang digunakan untuk mengidentifikasi dan mengumpulkan artikel, buku, serta sumber-sumber lain yang relevan dengan topik, teori, atau riset yang menarik bagi peneliti. Ini membentuk dasar analisis dan pengklasifikasian fakta yang diperoleh selama penelitian. Penting bagi sumber-sumber yang dirujuk untuk sesuai dan relevan dengan literatur yang telah ada. [16]

Tujuan dari literatur review adalah untuk membangun landasan teori yang mendukung pemecahan masalah yang sedang diselidiki, memberikan pemahaman awal kepada peneliti tentang permasalahan yang diteliti, dan menyusun kerangka berpikir ilmiah yang tepat.

Selain itu, literatur review juga membantu dalam merumuskan tujuan penelitian dan menjelaskan proses pelaksanaannya. Hal ini termasuk menjelaskan variabel yang digunakan, model dan desain penelitian, teknik pengambilan sampel, serta analisis dan interpretasi data. Dengan demikian, literatur review memungkinkan peneliti untuk merencanakan studi dengan lebih baik dan memfasilitasi replikasi penelitian oleh orang lain. [10].

2.5 Deep Learning

Deep learning menggunakan jaringan saraf tiruan yang terdiri dari banyak lapisan (disebut "deep" karena memiliki banyak lapisan) untuk mempelajari representasi data yang semakin abstrak dan kompleks seiring dengan lapisan yang lebih dalam. Proses pembelajaran ini terinspirasi dari cara otak manusia memproses informasi, di mana lapisan-lapisan neuron di otak bekerja bersama-sama untuk memahami pola dan informasi yang rumit.[17]

Model deep learning dapat dilatih untuk melakukan berbagai tugas, seperti klasifikasi gambar, pengenalan wajah, penerjemahan bahasa, dan lain-lain. Kemampuan deep learning dalam mengenali pola kompleks membuatnya sangat berguna dalam berbagai aplikasi, termasuk analisis data, pengolahan bahasa alami, visi komputer, dan pengenalan suara.

Dengan kemajuan dalam deep learning, banyak tugas yang sebelumnya membutuhkan intervensi manusia dapat dilakukan secara otomatis dan efisien oleh komputer. Ini membuka pintu untuk berbagai inovasi baru dan meningkatkan produktivitas di berbagai bidang, mulai dari layanan pelanggan hingga penelitian ilmiah [18].

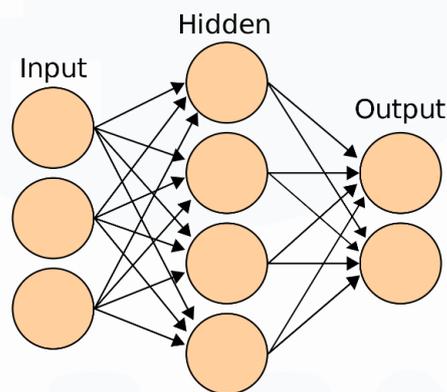
Deep learning memiliki kemampuan untuk secara otomatis memahami representasi fitur yang rumit. Selain itu, deep learning juga bisa menyesuaikan dan meningkatkan parameter-parameter mereka menggunakan algoritma pembelajaran yang disebut backpropagation. Deep learning memiliki beberapa algoritma yang bisa digunakan seperti recurrent neural network, self-organizing maps, convolutional neural network, dan long short-term memory network. Dengan menggunakan algoritma-algoritma ini, mereka mampu menghasilkan output yang akurat dan tepat [6].

2.5.1 Neural Network / ANN

Artificial Neural Network (ANN) adalah model kompleks yang mampu menganalisis dan memprediksi respons terhadap perubahan variabel. Model ini terinspirasi dari cara kerja sel otak manusia dalam memproses informasi. ANN menggunakan algoritma yang umumnya dikenal sebagai supervised learning, di

mana model diajarkan menggunakan data yang telah diberi label untuk membuat prediksi. Meskipun supervised learning merupakan pendekatan yang paling populer, ANN juga dapat diterapkan dalam algoritma semi-supervised dan unsupervised learning. Hal ini menunjukkan fleksibilitas ANN dalam menangani berbagai jenis data dan masalah dalam machine learning [19].

Neuron-neuron dalam Artificial Neural Network (ANN) dikelompokkan ke dalam lapisan atau layer. Penyusunan neuron dalam setiap layer dan pola koneksi di antara neuron-neuron tersebut disebut sebagai arsitektur jaringan. Arsitektur ini merupakan salah satu ciri khas utama yang membedakan antara berbagai jenis jaringan neural network. Secara umum neural network terbagi menjadi ada tiga lapis:



Gambar 2. 1 Arsitektur dari Artificial Neural Network

- *Input layer*: Layer dimana data diterima atau dimasukkan kedalam arsitektur neural network. Jumlah neuron dalam lapis input bergantung pada jumlah input variable pada model dan setiap input atau variable menentukan satu neuron.
- *Hidden layer*: Lapis tersembunyi terletak di antara *input layer* dan *output layer* yang dapat terdiri dari beberapa lapis tersembunyi.

- *Output layer*: Lapis yang akan mengeluarkan hasil dari *training* pada hidden layer. Setelah melakukan proses *training*, NN akan menghasilkan output berupa hasil prediksi.

Dalam *neural network*, jika jaringan neural terdiri dari tiga lapis atau lebih, maka disebut *multilayer network*. Sebaliknya, jika NN hanya memiliki lapisan input dan lapisan output, disebut sebagai *single-layer network*. Single-layer network biasanya digunakan untuk tugas-tugas sederhana, seperti regresi linier atau klasifikasi biner [20].

2.5.2 Convolutional Neural Network

Convolutional Neural Network (CNN) membedakan dirinya dari jaringan saraf lainnya melalui kinerja superior pada input gambar, teks, atau sinyal audio. Ini karena CNN secara khusus dirancang untuk menangani data spasial, seperti gambar, dengan efisien [21]. CNN memiliki tiga jenis lapisan utama yang bekerja secara bersama-sama untuk melakukan tugas-tugas analisis yang kompleks:

- **Lapisan Konvolusi**: Lapisan konvolusi adalah inti dari CNN. Lapisan ini terdiri dari sejumlah filter atau kernel yang digunakan untuk mengekstrak fitur-fitur penting dari input gambar. Setiap filter bergerak melintasi gambar secara berulang, melakukan operasi konvolusi untuk menghasilkan peta fitur yang menyoroti area-area yang relevan. Ini memungkinkan CNN untuk secara efisien menangkap pola-pola hierarkis dalam gambar, seperti tepi, garis, dan tekstur.
- **Lapisan Penyatuan (Pooling)**: Setelah melewati lapisan konvolusi, peta fitur yang dihasilkan akan melewati lapisan penyatuan. Lapisan ini bertujuan untuk mengurangi dimensi spasial dari peta fitur dengan menggabungkan nilai-nilai yang berdekatan. Ini membantu mengurangi jumlah parameter dan komputasi yang diperlukan dalam jaringan, sambil menjaga informasi yang penting.
- **Lapisan Yang Sepenuhnya Terhubung (Fully Connected)**: Lapisan yang sepenuhnya terhubung berada di bagian akhir CNN. Lapisan ini terdiri dari neuron-neuron yang setiap neuronnya terhubung dengan semua neuron dari

lapisan sebelumnya, seperti pada jaringan saraf biasa (ANN). Lapisan ini bertanggung jawab untuk menggabungkan informasi yang telah diekstraksi dari lapisan-lapisan sebelumnya dan menggunakannya untuk membuat prediksi atau klasifikasi akhir.

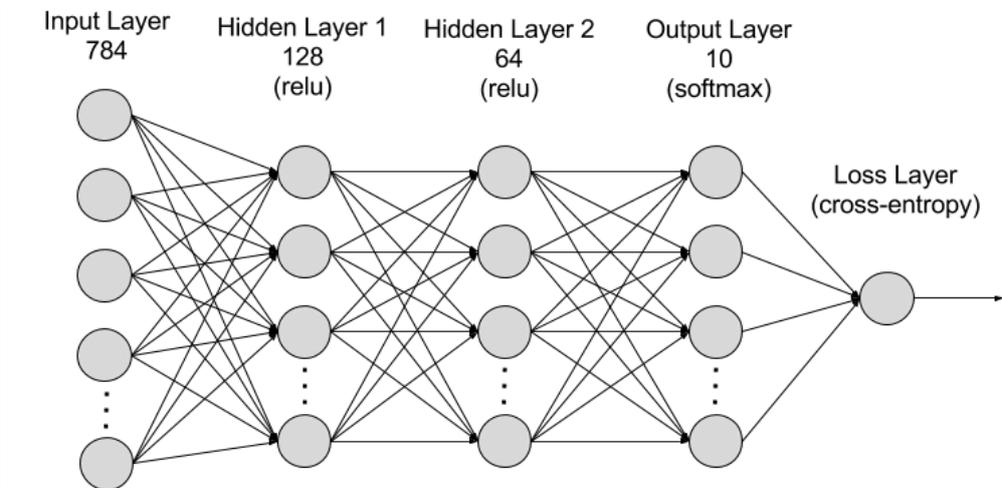
Dengan kombinasi ketiga jenis lapisan ini, CNN dapat menghasilkan representasi fitur yang semakin abstrak dari input gambar, yang kemudian dapat digunakan untuk tugas-tugas seperti klasifikasi objek, deteksi objek, dan segmentasi gambar. Ini membuat CNN menjadi alat yang sangat efektif dalam visi komputer dan berbagai aplikasi analisis gambar [22].

2.5.3 Recurrent Neural Network

Recurrent Neural Network (RNN) adalah model deep learning yang dirancang untuk memproses dan mengubah data input berurutan menjadi output data berurutan tertentu. Data berurutan adalah jenis data seperti kata, kalimat, atau data deret waktu, di mana setiap komponen berurutan saling terkait berdasarkan semantik kompleks dan aturan sintaks. Setiap elemen dalam data input diurutkan secara berurutan, dan RNN menggunakan struktur berulang untuk mengingat dan mempertimbangkan informasi dari langkah-langkah sebelumnya dalam urutan tersebut. Salah satu kegunaan utama RNN adalah dalam tugas-tugas yang melibatkan data berurutan, seperti penerjemahan bahasa, pengenalan tulisan tangan, analisis sentimen teks, dan prediksi deret waktu. [23]

Kelebihan utama RNN adalah kemampuannya dalam menangani data berurutan dengan panjang yang bervariasi dan kemampuannya untuk "mengingat" informasi dari langkah-langkah sebelumnya. Namun, RNN juga memiliki batasan, seperti kesulitan dalam menangani ketergantungan jarak yang panjang dan masalah pelatihan yang dikenal sebagai masalah menghilang atau ledakan gradien.

UNIVERSITAS
MULTIMEDIA
NUSANTARA



Gambar 2. 2 Arsitektur RNN

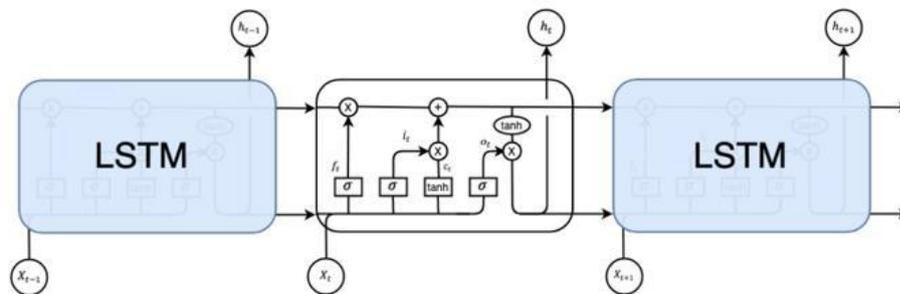
RNN dibuat dari neuron, yang merupakan simpul pemrosesan data yang bekerja sama untuk mengeksekusi tugas-tugas yang kompleks. Neuron-neuron ini diatur sebagai input, output, dan lapisan tersembunyi. Lapisan input menerima informasi yang akan diproses, sedangkan lapisan output memberikan hasil akhir dari proses tersebut. Selama pemrosesan data, analisis, dan prediksi, proses inti terjadi di lapisan tersembunyi. [24].

2.5.4 Long-Short Term Memory (LSTM)

LSTM (Long Short-Term Memory) merupakan turunan dari Recurrent Neural Network (RNN) yang diciptakan khusus untuk menangani data berurutan. Salah satu masalah utama yang dihadapi oleh RNN adalah gradien yang hilang atau meledak selama proses pelatihan, yang dapat mengakibatkan kesulitan dalam mengambil informasi jangka panjang. LSTM muncul sebagai solusi untuk masalah ini dengan memperkenalkan struktur memori yang kompleks yang mampu "mengingat" informasi penting dalam jangka panjang dan jangka pendek dari data berurutan. [25]

Dengan kemampuan ini, LSTM dapat menangani masalah gradien dengan lebih baik daripada RNN konvensional, sehingga meningkatkan kinerja dan stabilitas dalam proses pelatihan model. Ini membuat LSTM menjadi pilihan yang populer

untuk berbagai tugas pemrosesan bahasa alami, analisis deret waktu, dan banyak lagi, di mana hubungan temporal kompleks perlu dipelajari dari data berurutan.



Gambar 2. 3 Arsitektur LSTM

Pada bagian lapisan tersembunyi dalam LSTM (Long Short-Term Memory), terdapat sel memori yang memainkan peran penting dalam mempertahankan informasi jangka panjang dari data berurutan. Setiap sel memori memiliki tiga gate yang mengontrol aliran informasi: input gate, forget gate, dan output gate.

Input gate bertanggung jawab untuk mengontrol jumlah informasi yang harus disimpan dalam sel memori. Gate ini memungkinkan model untuk memutuskan seberapa banyak informasi baru dari input yang harus disimpan dalam sel memori.

Forget gate berperan dalam mengontrol nilai-nilai yang harus dipertahankan atau dihapus dari sel memori. Hal ini memungkinkan sel memori untuk "mengingat" informasi penting dari masa lalu sambil melupakan informasi yang tidak relevan atau usang.

Output gate bertugas untuk menghitung dan menentukan nilai sel yang akan digunakan sebagai output dari sel memori tersebut. Output ini kemudian akan digunakan sebagai input untuk proses berikutnya dalam jaringan.

Dengan adanya mekanisme gate ini, LSTM mampu mengelola informasi jangka panjang dan pendek dengan lebih efektif daripada RNN tradisional, sehingga meningkatkan kemampuan model dalam memahami dan memproses data berurutan dengan lebih baik [26].

2.6 Evaluasi

2.6.1 Accuracy Score

Accuracy test merupakan metrik evaluasi yang mengukur seberapa baik model dapat melakukan klasifikasi atau prediksi data dengan akurat. Akurasi dinyatakan sebagai rasio antara jumlah prediksi yang positif dan negatif dengan total jumlah prediksi yang dilakukan oleh model [27]. Secara matematik, Rumus tes akurasi adalah sebagai berikut:

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Jumlah Prediksi}}$$

2.6.2 F1-Score

F1-Score merupakan ukuran yang menggabungkan *precision* dan *recall* dimana digambarkan sebagai harmonic mean dari keduanya. *Precision* merupakan perbandingan antara *True Positive* (TP) dengan seluruh data yang diprediksi positif. Secara matematis dapat ditulis dengan demikian:

$$\text{precision} = \frac{TP}{TP + FP}$$

Untuk Recall, merupakan perbandingan antara True Positive (TP) dengan data yang sebenarnya positif. Secara matematis dapat ditulis dengan demikian:

$$\text{Recall} = \frac{TP}{TP + FN}$$

Harmonic mean merupakan cara lain untuk menghitung "rata-rata" nilai, umumnya digambarkan sebagai lebih sesuai untuk rasio daripada mean aritmatika tradisional. Maka secara matematik F1-Score dapat ditulis seperti dibawah ini:

$$\frac{1}{F1} = \frac{1}{2} \left(\frac{1}{precision} + \frac{1}{recall} \right)$$

Dalam evaluasi F1-Score, skor terbaiknya adalah 1, sedangkan skor terburuknya adalah 0. Ketika F1-Score mendekati 1, itu menunjukkan bahwa model klasifikasi memiliki nilai precision dan recall yang tinggi atau seimbang. Sebaliknya, jika mendekati 0, itu menandakan bahwa perbandingan antara nilai precision dan recall jauh atau tidak seimbang pada model klasifikasi [28].