

BAB II

TINJAUAN PUSTAKA

2.1 Studi Literatur

Kajian mengenai pariwisata telah selesai lebih awal dengan menggunakan metode analisis yang beragam. Setiap kajian menggunakan pendekatan yang berbeda sehingga mempengaruhi tingkat akurasi dan efektivitas analisis sentimen. Dalam konteks analisis sentiment pariwisata, perbedaan metode ini sangat penting karena dapat mempengaruhi pemahaman terhadap persepsi wisatawan dan efektivitas strategi pemasaran serta pengelolaan destinasi wisata. Untuk itu, guna memberikan gambaran yang jelas tentang perbandingan berbagai metode yang telah diterapkan, berikut adalah tabel kajian perbandingan antara penelitian sebelumnya hal ini telah selesai bersamaan dengan penelitian yang akan dilakukan.

Tabel 1. Studi Literatur

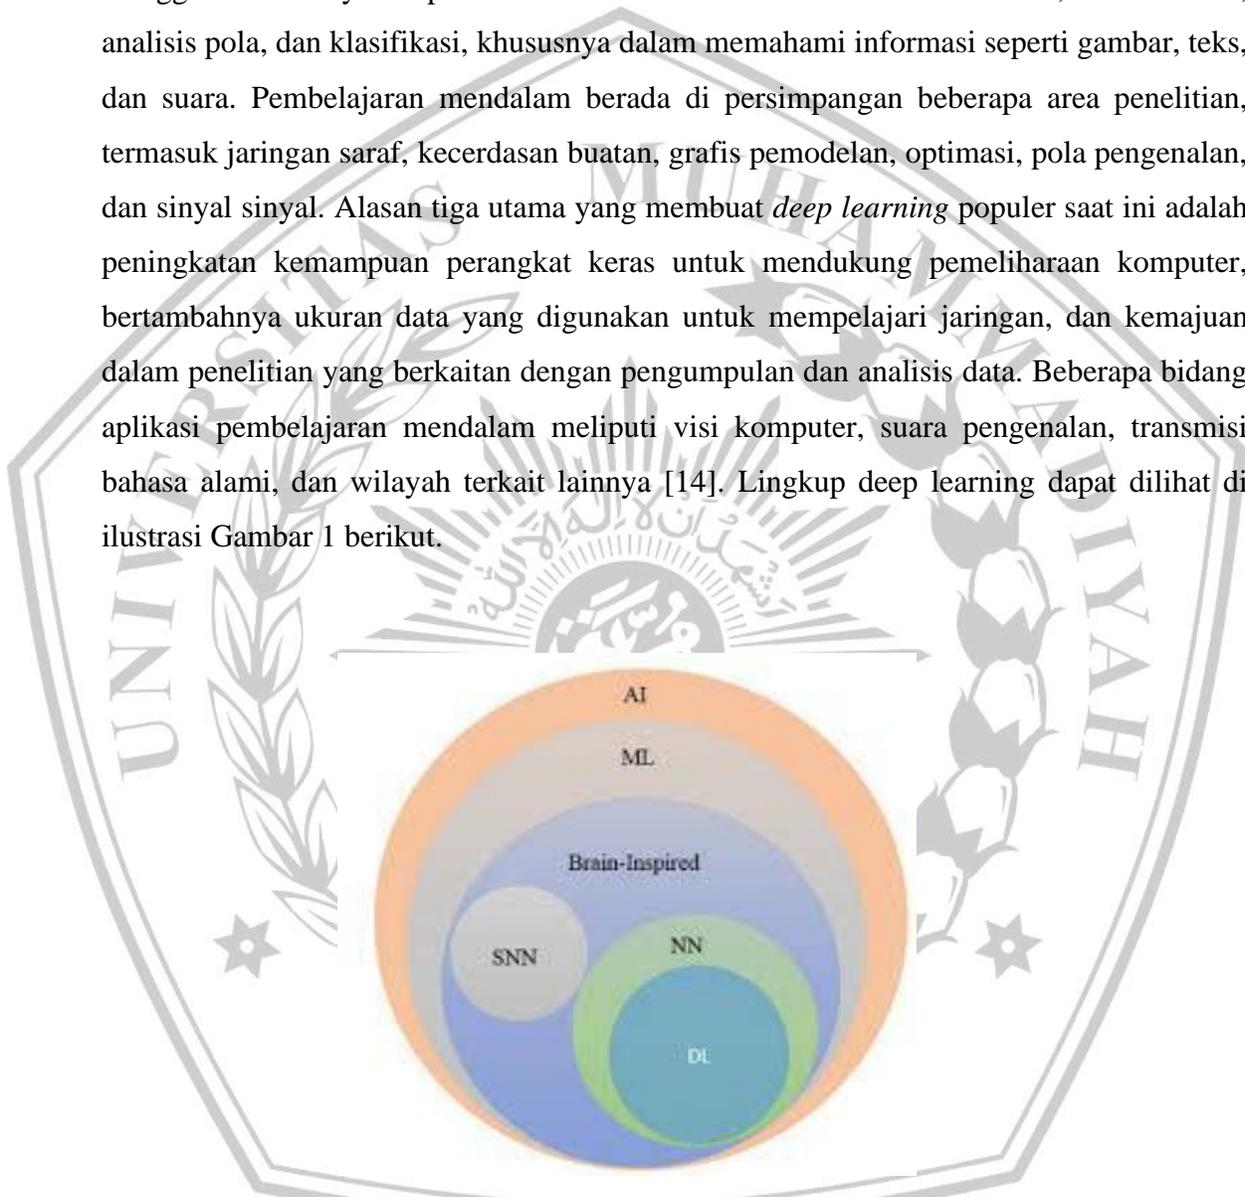
Penulis	Judul Penelitian	Metode	Hasil
Putri Rizki Amalia, Edi Winarko	<i>Aspec-Based Sentiment Analysis on Indonesia Restaurant Review using a Combination of CNN and Contextualized Word Embedding</i>	CNN, BERT, ELMo, Word2Vec	<ul style="list-style-type: none">• Model ELMo-CNN memberikan hasil terbaik dengan precision 0.88%, recall 0.89%, f1-score 0.86%• Model BERT-CNN memberikan klasifikasi sentimen hasil terbaik dengan precision 0.89%, recall 0.89%, f1-score 0.91%• Klasifikasi yang dilakukan dengan data tanpa <i>stemming</i> memiliki hasil yang lebih baik dibandingkan menggunakan data dengan <i>stemming</i>
Rysca Naquitasia, Dhomas Hatta Fudholi, Lizda Iswari	Analisis Sentimen Berbasis Aspek pada Wisata Halal dengan metode <i>Deep Learning</i>	CNN, BiLSTM, Deep Learning	<ul style="list-style-type: none">• Metode CNN mendapatkan hasil terbaik dibandingkan metode lainnya, dengan klasifikasi nilai aspek akurasi sebesar 98.299% dan klasifikasi sentimen sebesar 93.96%

Yung-Chung Chang, Chih-Hao Ku, Chein-Hung Chen	<i>Using Deep Learning and Visual Analytics to Explore Hotel Reviews and Responses</i>	CNN	<ul style="list-style-type: none"> • Metode multi-CNN dipilih untuk dibandingkan dengan pendekatan lainnya • Multi-CNN memiliki hasil terbaik dibandingkan metode lainnya
Dwi Intan Af'idah, Retno Kusumaningrum, Bayu Surarso	<i>Long Short Term Memory Convolutional Neural Network for Indonesia Sentiment Analysis towards Touristic Destination Reviews</i>	LSTM-CNN, Word2Vec	<ul style="list-style-type: none"> • Model gabungan LSTM-CNN dan Word2Vec digunakan untuk penilaian dalam sentimen • Hasil terbaik dengan metode LSTM-CNN 97.17% dibandingkan LSTM 90.82%
Siwi Cahyaningtyas, Dhomas Hatta Fudholi, Ahmad Fathan Hidayatullah	<i>Deep Learning for Aspect-Based Sentiment Analysis on Indonesia Hotels Review</i>	CNN	<ul style="list-style-type: none"> • Penelitian ini membandingkan metode ABSA yaitu RNN, LSTM, GRU, BiLSTM, CNN, CNN-LSTM, dan CNN-BiLSTM • Hasil penelitian menunjukkan bahwa LSTM mendapatkan akurasi terbaik untuk klasifikasi aspek 0.926% dan CNN mendapatkan akurasi terbaik untuk klasifikasi sentimen 0.904%
Nayoan, Royan Abida N, Ahmad Fathan Hidayatullah, Dhomas Hatta Fudholi	<i>Convolutional Neural Networks for Indonesian Aspect-Based Sentiment Analysis Tourism Review</i>	CNN	<ul style="list-style-type: none"> • Penelitian ini membandingkan metode CNN dengan CNN-LSTM dan CNN-GRU • Hasil akurasi tertinggi CNN dengan 0.9067 % sentimen dan aspek 0.9521%

2.2 Landasan Teori

2.2.1 Deep Learning

Pembelajaran mendalam adalah sejenis kelas dari mesin-learning teknik itu menggunakan banyak lapisan dalam analisis informasi untuk ekstraksi, transformasi, analisis pola, dan klasifikasi, khususnya dalam memahami informasi seperti gambar, teks, dan suara. Pembelajaran mendalam berada di persimpangan beberapa area penelitian, termasuk jaringan saraf, kecerdasan buatan, grafis pemodelan, optimasi, pola pengenalan, dan sinyal sinyal. Alasan tiga utama yang membuat *deep learning* populer saat ini adalah peningkatan kemampuan perangkat keras untuk mendukung pemeliharaan komputer, bertambahnya ukuran data yang digunakan untuk mempelajari jaringan, dan kemajuan dalam penelitian yang berkaitan dengan pengumpulan dan analisis data. Beberapa bidang aplikasi pembelajaran mendalam meliputi visi komputer, suara pengenalan, transmisi bahasa alami, dan wilayah terkait lainnya [14]. Lingkup deep learning dapat dilihat di ilustrasi Gambar 1 berikut.



Gambar 1. Ruang Lingkup *Deep Learning*

2.2.2 Text Mining

Text mining adalah bagian dari data *mining*, yaitu proses memperoleh pengetahuan dengan menggunakan seperangkat alat analisis tempat pengguna berinteraksi dengan kumpulan dokumen dari satu waktu ke waktu lainnya. Teks penambangan mengekstrasi informasi yang diperoleh dari ringkasan data (kumpulan dokumen) melalui identifikasi dan investigasi pola yang ada. *Text mining* untuk menangani *classification*, *information extraction* dan *information retrieval*. Konsep data mining dalam klasifikasi adalah mengelompokkan dokumen tekstual sesuai dengan topik pembahasan. Pada *preprocessing text mining* berfokus pada identifikasi dan ekstraksi fitur [6].

2.2.3 Analisis Sentimen

Analisis sentiment dikenal juga dengan penambangan opini, atau bahkan kecerdasan buatan emosi, berguna untuk meningkatkan bahasa inggris (NLP), analisis komputer dan analisis teks linguistic untuk tujuan mengidentifikasi, mendeteksi, dan mempelajari informasi dengan cara yang aman terstruktur [15]. Analisis sentiment karena metode ini berfokus pada temuan-temuan positif, maka dapat dibandingkan dengan penambangan opini negative ataupun netral. Analisis sentiment dapat diterapkan pada berbagai jenis data teks, termasuk termasuk kiriman media sosial, ulasan pelanggan, formular umpan balik, dan artikel daring. Tujuan analisis sentiment adalah untuk memahami opini, emosi dan sikap individu atau kelompok terhadap topik, produk, layanan, atau merek tertentu [16].

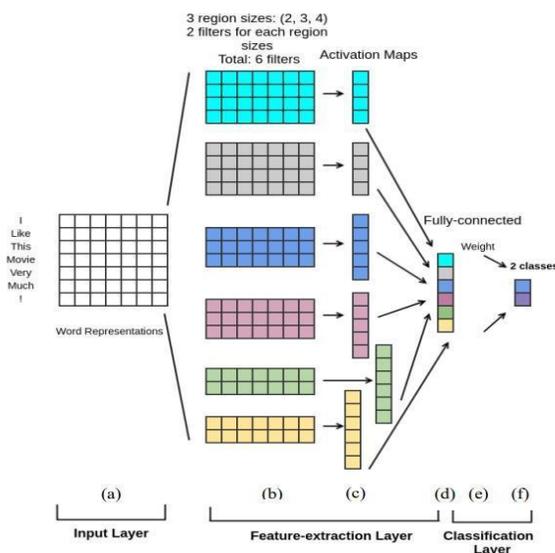
2.2.4 Aplikasi X

X adalah platform media sosial yang bermanfaat untuk mengungkapkan pendapat dan perasaan penggunanya tentang isu-isu atau masalah yang sedang berlangsung atau telah terjadi. X memungkinkan orang dari seluruh dunia untuk menyuarakan opini mereka. Platform ini diciptakan oleh Jack Dorsey pada bulan Maret 2006. Media sosial X menjadi media sosial itu populer digunakan sebagai sumber info untuk dianalisis sentiment. Media sosial X selain itu, meskipun tidak terlalu kuat akan terhubung dengan hal lain berteman satu sama lain. X juga berguna bagi pengguna untuk bertukar pikiran dan ide secara bebas,

baik ditingkat baik dalam negeri maupun internasional. Pengguna yang memiliki minat atau keahlian serupa dapat saling berinteraksi, dan mereka juga bisa terlibat dalam debat kritis melalui komentar X lebih sering digunakan dan dibandingkan dengan platform karena ketersediaan data media sosial lainnya, aksesibilitas yang mudah, dan beragam kontennya. Platform ini memiliki banyak tweet yang mencakup berbagai topik, menunjukkan bahwa media sosial ini adalah sebuah informasi yang sangat penting [17].

2.2.5 CNN

Convolutional Neural Network (CNN) adalah salah satu teknik pembelajaran mendalam dari bidang penelitian *Multilayer* perceptrons (MLP) dirancang untuk menganalisis data dalam dua dimensi. CNN mengacu pada jenis Deep Neural Network yang mempunyai tingkat jaringan yang tinggi. CNN memiliki dua metode yaitu fase klasifikasi menggunakan feed forward, dan fase pengajaran menggunakan backpropaganda. Cara bekerja di CNN seperti pada Gambar 2 memiliki kesamaan dengan MLP namun, neuron CNN direpresentasikan dalam dua dimensi, sedangkan MLP hanya menampilkan satu neuron berkurang satu dimensi CNN hanya dirancang untuk mengenal citra gambar namun dalam perkembangannya menjadi model serba guna dilakukan untuk berbagai CNN memiliki kemampuan untuk menganalisis kebugaran lokal dalam berbagai aspek [9]. Misalnya pada gambar CNN akan menyorot fitur tertentu seperti batang atau senyuman, dimanapun lokasinya.



Gambar 2. Arsitektur CNN

CNN seperti terlihat pada Gambar 2 bekerja dengan memanfaatkan data multidimensi (misal; gambar, embedding kata) ke lapisan konvolusional, yang terdiri dari beberapa filter yang akan mengajarkan fitur berbeda. Biasanya, keluaran dikumpulkan dan dikirim ke dimensi yang lebih kecil, kemudian dikirim ke lapisan yang terhubung. Arsitektur CNN memiliki tiga lapisan: lapisan masukan, lapisan ekstraksi fitur, dan *classification* lapisan. Arsitektur CNN ditentukan oleh beberapa parameter, seperti ukuran wilayah filter, jumlah filter, fungsi aktivitas dan bentuknya lagularisasi. Setiap lapisan memiliki lapisan yang berbeda, yang paling menonjol adalah lapisan konvolusional, penyatuan dan terhubung penuh dalam arsitektur CNN. Setiap arsitektur dapat disesuaikan untuk memenuhi kebutuhan spesifik. Desain arsitektur ini dapat menurunkan akurasi model berikut penjelasan dari setiap lapisan CNN :

2.2.5.1 *Input Layer*

Setiap kata yang muncul dalam suatu dokumen dijelaskan dalam matriks. Sel tersebut mempunyai nilai 1 mempresentasikan posisi kata, sedangkan cell tidak berisi kata dipresentasikan dengan nilai 0.

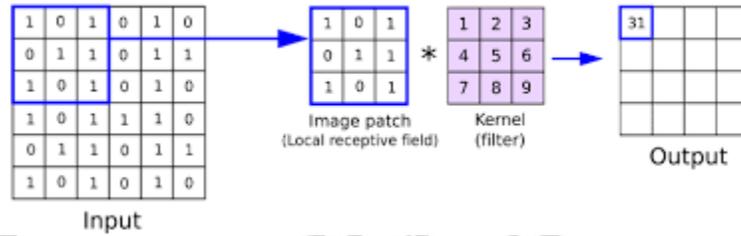
2.2.5.2 *Feature-extraction Layer*

Lapisan hadir dalam fitur mentranslasikan satu input sebagai fitur berdasarkan input yang dibentuk dari angka-angka di *vector*. Lapisan konvolusional dan penggabungan membentuk lapisan ekstraksi fitur.

a. *Convolutional Layer*

Lapisan konvolusional menentukan keluaran neuron yang terhubung dengannya area lokal di masukan, dan masing-masing neuron menentukan produk bobotnya dan area lebih kecil yang terhubung ke volume masukan. Fungsi aktivasi kemudian menentukan hasil lapisan konvolusional. Ada beberapa fungsi aktif

yang digunakan antara lain tag dan peran aktivasi ReLu. *Output layer* yang didapatkan dari konvolusi filter input, yaitu tumpukan kernel yang menghasilkan peta fitur.



Gambar 3. *Convolutional Layer*

Berdasarkan gambar diatas input yang terdiri dari array yang diambil sampel kira-kira 3x3 sesuai dengan bentuk filter dan kemudian dianalisis (dari segi elemen) menggunakan bobot karnel yang dianalisis lebih lanjut untuk menghasilkan peta fitur. Persamaan convolutional layer (PyTorch) dapat ditunjukkan pada persamaan ke-1 di bawah ini:

$$out(N_i, C_j) = bias(C_j) + \sum_{k=0}^{C_{in}-1} weight(C_j, k) * input(N_i, k)$$

Keterangan :

- N = Batch
- C_j = Channel output
- C_{in} = Channel input
- $out(N_i, C_j)$ = Output ke i pada batch dan ke j pada channel
- $bias(C_j)$ = Bias pada channel ke j
- $weight(C_j, k)$ = Weight pada channel ke j dan ke k pada C_{in}
- $*$ = Operasi Cross-Correlation
- $input(N_i, k)$ = Input ke I pada batch dan ke k pada C_{in}

b. *Pooling Layer*

Pooling layer merupakan lapisan yang memperkecil dimensi peta fitur atau lebih dikenal dengan teknik downsampling, yang meningkatkan komputasi karena parameter perlu disesuaikan secara bertahap dan dapat mencegah overfitting. Pooling yang paling umum digunakan adalah max pooling dan average pooling. Sementara pengumpulan rata-rata menentukan nilai pergeseran filter, pengumpulan maksimum menentukan pergeseran maksimum tiap berdasarkan rata-rata [5]. Berikut penjelasan visualisasi sederhana dari max pooling beserta perbandingannya dengan kumpulan rata-rata.



Gambar 4. *Max Pooling*

MaxPool (PyTorch) sebagai persamaan ke-2:

$$out(N_i, C_j, h, w) = m = 0, \dots, kH - 1 \quad n = 0, \dots, kW - 1$$

$$input(N_i, C_j, stride[0] \times h + m, stride[1] \times w + n)$$

EveragePool (PyTorch) sebagai persamaan ke-3:

$$out(N_i, C_j, h, w) =$$

$$\frac{1}{kH * kW} \sum_{m=0}^{kH-1} \sum_{n=0}^{kW-1} input(N_i, C_j, stride[0] * h + m, stride[1] * w + n)$$

Keterangan :

- $out(N_i, C_j, h, w) = Output$ ke i pada batch, ke j pada *channel*
- $kH = kernel\ size\ H$
- $kW = kernel\ size\ W$
- $stride = Langkah\ window$

2.2.5.3 Classification Layer

Lapisan ini berfungsi untuk mengklasifikasikan setiap *neuron* yang telah mengalami deformasi fitur sebelumnya. Terdiri dari:

a. Flatten

Membentuk fitur ulang (membentuk kembali peta fitur) menjadi a *vector* sehingga dapat dijadikan masukan dari lapisan terkait penuh.

b. Fully Connected (FC)

Lapisan FC menghitung skor akhir, mirip dengan saraf biasa jaringan dan sesuai dengan namanya setiap neuron di lapisan ini terhubung ke setiap angka di volume.

c. Output Layer

Ada dua jenis fungsi pada lapisan keluaran: fungsi softmax dan fungsi sigmoid. Fungsi sigmoid menghitung nilai rill saldo dan mengevaluasi nilai keluaran dalam rentang 0 hingga 1. Sigmoid biasanya digunakan untuk mengaktifkan fungsi keluaran dalam klasifikasi biner . Persamaan *sigmoid* dijelaskan pada persamaan (1):

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

Probabilitas setiap kelas target dihitung dengan fungsi softmax di setiap kelas target, sehingga memungkinkan penentuan kelas yang diinginkan

untuk input yang diberikan. Probabilitas keluaran berkisar antara 0 banding 1 dan jumlah total probabilitasnya akan sama dengan 1. Fungsi ini akan berguna dalam multiklasifikasi karena membandingkan probabilitas setiap baik tujuan maupun kelasnya akan memiliki probabilitas yang tinggi [18]. Hubungan softmax dijelaskan dalam persamaan (2):

$$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$$

2.2.6 Confusion Matrix

Confusion Matrix ini adalah salah satu metode penelitian di menentukan klasifikasi [19]. *Confusion Matrix* adalah table 4 dimensi, atau lebih berbeda dari aktual dan prediksi. Dalam penelitian ini menggunakan tabel *matrix* yang terdiri dari tiga kelas yaitu positif, negatif dan netral dan enam tabel dimensi yaitu TP (*True Positive*), TN (*True Negative*), TNeu (*True Neutral*), FP (*False Positive*), FN (*False Negative*), FNeu (*False Neutral*). Hasil proses klasifikasi pada matriks konfusi akurat dan persuasif, *recall* dan *F1 score* [20]. Terdapat rumus akurasi, presisi, *recall* dan *f1 score* yaitu diantaranya:

a. Akurasi

$$\frac{TP + TN + TNeu}{TP + TN + TNeu + FP + FN + FNeu}$$

b. Presisi

$$\frac{TP}{TP + FP}$$

c. Recall

$$\frac{TP}{TP + FN + FNeu}$$

d. F1 Score

$$F1 \text{ Score} = \frac{2 \times \text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}}$$

Keterangan:

- TP = *True Positive*
- TN = *True Negative*
- TNeu = *True Neutral*
- FP = *False Positive*
- FN = *False Negative*
- FNeu = *False Neutral*

