

# Komparasi Metode *Machine Learning* dan *Deep Learning* untuk Deteksi Emosi pada Text di Sosial Media

Rona Nisa Sofia Amriza\*<sup>1</sup>, Didi Supriyadi<sup>2</sup>

<sup>1,2</sup>Program Studi S1 Sistem Informasi, Fakultas Informatika, Institut Teknologi Telkom Purwokerto

Jl. DI Panjaitan No.128, Kec. Purwokerto Selatan, Kab. Banyumas, Jawa Tengah, 53147

e-mail: \*[rona@ittelkom-pwt.ac.id](mailto:rona@ittelkom-pwt.ac.id), [didisupriyadi@ittelkom-pwt.ac.id](mailto:didisupriyadi@ittelkom-pwt.ac.id)

## Abstrak

*Deteksi Emosi adalah proses pengenalan emosi manusia, merupakan proses mengekstrak emosi seperti bahagia, sedih, dan marah, yang diperoleh dari bahasa alami manusia. Gaya linguistik memiliki jangkauan yang luas, representasi emosional yang terjadi pada jutaan orang menyebabkan kesulitan untuk menyimpulkan keadaan emosi seseorang secara konkret. Multilabel dataset juga merupakan tantangan yang harus dihadapi dalam deteksi emosi. Oleh karena itu dibutuhkan studi mendalam mengenai metode yang cocok untuk proses identifikasi emosi tersebut. Penelitian ini melakukan analisis perbandingan antara metode machine learning dan metode deep learning. Metode machine learning yang digunakan dalam adalah Naïve Bayes, Random Forest, SVM, Gradient Boosting dan Logistic Regression. Sedangkan metode deep learning yang digunakan antara lain LSTM, CNN, MLP, GRU dan RNN. Pada penelitian ini diperoleh hasil bahwa Deep learning memiliki performa yang lebih baik dari machine learning, hal tersebut dapat dilihat dari nilai akurasi dari LSTM, CNN, MLP, GRU dan RNN yang melebihi nilai akurasi dari Naïve Bayes, Random Forest, SVM, Gradient Boosting dan Logistic Regression.*

**Kata kunci**— *Deteksi Emosi, Machine Learning, Deep Learning, Text, Media Sosial*

## Abstract

*Emotion Detection is the process of human emotions recognition, it extracting emotions such as happy, sad, and angry, which are obtained from human natural language. Linguistic Style has a wide range, emotional representations occur to millions of people and makes it difficult to infer a person's emotion in a concrete way. Multilabel datasets are also a challenge to deal in emotion detection. Therefore, an in-depth study of the appropriate method for emotional detection is needed. This study performs a comparative analysis between machine learning methods and deep learning methods. The machine learning methods used are Naïve Bayes, Random Forest, SVM, Gradient Boosting and Logistic Regression. The deep learning methods used in this study include LSTM, CNN, MLP, GRU and RNN. This research discovered that Deep learning has a better performance than machine learning, it seen from the accuracy values of LSTM, CNN, MLP, GRU and RNN which exceed the accuracy values of Naïve Bayes, SVM, Logistic Regression, Gradient Boosting and Random Forest.*

**Keywords**— *Emotion Detection, Machine Learning, Deep Learning, Text, Social Media*

## 1. PENDAHULUAN

Situs jejaring social seperti Twitter, Facebook, Instagram, Blog, dan berbagai jenis situs informal lainnya sangat berguna dalam kehidupan keseharian masyarakat. Twitter dan platform media sosial lainnya terus berkembang sebagai platform utama untuk mengekspresikan diri, memungkinkan orang untuk berbagi pemikiran, ide, dan pendapat dengan orang lain. Berbagi konten di sosial media juga dapat mewakili keadaan emosional pribadi

(misalnya, rasa tidak aman, depresi) sampai pembahasan global (misalnya, pemikiran tentang kandidat politik, mengomentari produk baru atau ekonomi global) [1, 2].

Deteksi emosi merupakan proses mengekstrak emosi seperti bahagia, sedih, dan marah, yang diperoleh dari bahasa alami manusia. Mendeteksi emosi dalam teks, terutama yang diposting atau beredar di media sosial, dapat menjadi sumber informasi berharga, yang dapat digunakan untuk mempelajari bagaimana orang yang berbeda bereaksi terhadap situasi dan peristiwa yang berbeda. Deteksi emosi dapat mempengaruhi pendukung keputusan dalam berbagai area, diantaranya manajemen dan marketing, interaksi pengguna, keuangan, politik, kesehatan dan pendidikan. Ullah et al [3] mengidentifikasi emosi terhadap produk sebagai landasan untuk mengembangkan produk tersebut. Selanjutnya, Al-Hajjar & Syed [4] melakukan analisis terhadap tweet terkait perusahaan untuk pengelolaan reputasi. Pemeriksaan perilaku konsumen dan sikap emosional yang terkait dengan preferensi produk diteliti oleh Chitturi et al [5] Dalam bidang interaksi pengguna, Marsden & Campbell [6] melakukan pengukuran kekuatan hubungan jejaring sosial dengan bahasa afektif sebagai indikator kedekatan emosional. Dalam keuangan, deteksi emosi digunakan untuk memberikan rekomendasi Keputusan investasi, melakukan prediksi pergerakan pasar saham berdasarkan konten emosional [7]. Pada bidang politik, deteksi emosi dimanfaatkan untuk monitoring publik, dengan melakukan deteksi ujaran kebencian di Twitter [8]. Analisis konten emosional mengenali gejala depresi dalam transkrip obrolan yang dilakukan oleh van der Zanden et al [9] merupakan pemanfaatan deteksi emosi bidang kesehatan. Pada bidang pendidikan, deteksi emosi dimanfaatkan untuk meningkatkan pengalaman belajar melalui pengklasifikasian dan pengaturan emosi e-peserta didik [10].

Metode *Machine Learning* dan *Deep Learning* telah banyak dilakukan oleh banyak peneliti sebelumnya [11, 12, 13, 14, 15, 16]. Namun, mengidentifikasi emosi dalam domain media sosial menghadirkan beberapa tantangan. Gaya linguistik memiliki jangkauan yang luas, representasi emosional yang terjadi pada jutaan orang menjadi sulit untuk menyimpulkan keadaan emosi seseorang secara konkret. Pada saat yang sama, membuat fitur standar melalui konten yang digunakan bersama juga sulit, oleh karena itu diperlukan metode yang tepat untuk mendeteksi emosi pada text. Untuk mengatasi permasalahan yang telah disebutkan sebelumnya, penelitian ini melakukan komparasi antara metode metode yang ada di machine learning dan metode yang ada di *deep learning* sehingga didapatkan pemahaman mendalam terhadap metode yang cocok untuk deteksi emosi pada text di sosial media. Metode deteksi emosi menggunakan machine learning yang digunakan dalam penelitian ini antara lain *Naïve Bayes*, *Random Forest*, *SVM*, *Gradient Boosting* dan *Logistic Regression*. Sedangkan metode deep learning yang digunakan dalam penelitian ini antara lain LSTM, CNN, MLP, GRU dan simple RNN.

## 2. METODE PENELITIAN

### 2.1 Machine Learning

*Machine learning* adalah bagian dari kecerdasan buatan, metode ini membangun model matematika berdasarkan data sampel, disebut "data latih", yang digunakan untuk membuat prediksi atau keputusan [17]. Pembelajaran mesin dapat menyimpulkan aturan keputusan untuk mengenali emosi berdasarkan kumpulan sampel pelatihan yang berlabel [11, 18].

Banyak peneliti Banyak peneliti menggunakan metode pembelajaran *Machine learning* untuk deteksi emosi. Misalnya, Sailunaz dan Alhaji [19] menggunakan pengklasifikasi Naive Bayes untuk mengidentifikasi dan menginterpretasikan sentimen dan emosi yang disampaikan oleh orang-orang di postingan twitter mereka dan menggunakannya untuk membuat rekomendasi. Thomas et al [20] mengusulkan sistem deteksi emosi yang bertujuan untuk mengklasifikasikan kelas emosi yang berbeda untuk kalimat. Jang et al [21] menggunakan SVM untuk mengklasifikasikan emosi pada dataset pasien. Winarsih dan Supriyanto [22] menilai kinerja berbagai pengklasifikasi pembelajaran mesin, seperti KNN, SVM, Naïve Bayes, dan teknologi pengoptimalan minimum (SVM-SMO) untuk pengenalan emosi pada teks berbahasa Indonesia. Alotaibi [23] melakukan pengenalan emosi pada konten tekstual menggunakan regresi logistik.

## 2. 2 Deep Learning

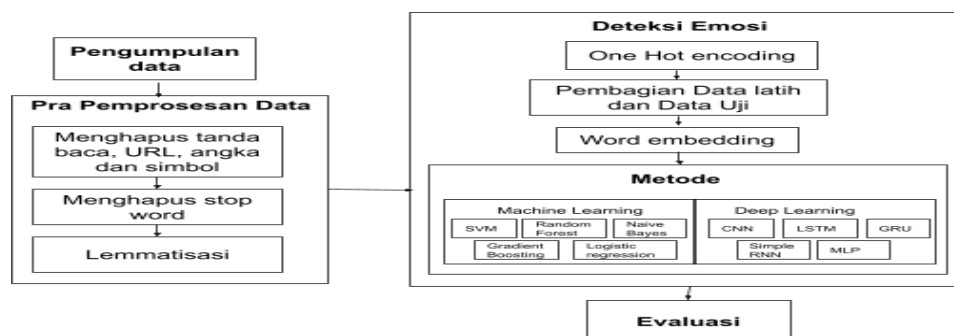
*Deep Learning* adalah kecerdasan buatan yang meniru cara manusia memperoleh jenis pengetahuan tertentu. Banyak peneliti telah mengusulkan metode untuk pengenalan emosi menggunakan *deep learning*. Misalnya, Gupta et al [24] mengusulkan untuk menggunakan model berbasis LSTM untuk mengenali emosi dalam percakapan tekstual. Kratzwald et al [25] meneliti penggunaan jaringan saraf berulang dua arah untuk pengenalan emosi. Namun, data latih nya bervariasi dari 1.000 hingga 7.902, data tersebut terlalu kecil untuk melatih *deep learning*. Akibatnya, akurasi model yang diusulkan tidak memadai. Sharifirad et al [26] menerapkan convolutional neural network (CNN) untuk pengenalan emosi dalam kasus pelecehan. Selanjutnya Goel et al [27] menggunakan *Long Short Term Memory* (LSTM) untuk memprediksi intensitas emosi yang berbeda. Ren et al [28] menggunakan LSTM dua arah untuk memprediksi emosi teks multibahasa menggunakan fitur lintas bahasa dan fitur level leksikal.

## 2. 3 Word Embedding

*Word Embedding* bertugas untuk memetakan setiap kata ke dalam ruang vektor berdimensi tinggi, mampu menangkap informasi kata semantik dan sintaksis [29]. Setiap kolom matriks menyimpan sebuah kata yang merepresentasikan *word embedding*.

## 2.4 Penelitian

Tahapan penelitian diawali dengan menentukan permasalahan yang ada, dengan menganalisis *business understanding* selanjutnya dilakukan pengumpulan data sosial media yang berkaitan dengan emosi. Sebelum data dimasukkan ke dalam model, perlu dilakukan pra pemrosesan data, pada tahap ini data dibersihkan dan disesuaikan sehingga dapat diproses ke tahap selanjutnya yaitu tahap deteksi emosi dengan menerapkan metode metode *machine learning* dan *deep learning*. Tahapan terakhir adalah evaluasi terhadap model seperti ditunjukkan pada Gambar 1.



Gambar 1. Kerangka Penelitian

### 2.4.1 Pengumpulan Data

Penelitian ini menggunakan data yang berasal dari sosial media Twitter. Terdapat empat dataset yaitu SemEval, WASSA, Tweet pemilu, dan CrowdFlower. SemEval 2018 mempunyai 11 tipe emosi yang sudah dilabelkan terhadap datanya. Dataset ini berisi tweet yang berisi emosi dari seseorang. Dataset yang kedua adalah WASSA 2017, dataset ini juga merupakan dataset yang berasal dari Twitter yang berisi intensitas dari emosi. Dataset yang ketiga adalah tweet pemilu. Dan dataset yang terakhir adalah dataset yang memiliki 14 label emosi. Penelitian ini menggunakan data Twitter dan masing masing dataset memiliki jumlah emosi yang berbeda. Detail dataset dapat dilihat pada Tabel 1.

Tabel 1. Dataset

No	Dataset	Ukuran	Kategori Emosi
1	SemEval	8201	Anger, disgust, anticipation, joy, fear, love, pessimism, optimism, sadness, trust dan surprise
2	WASSA	4937	Anger, joy, fear, dan sadness
3	Tweet Pemilu	4055	Anger, disgust, anticipation, fear, sadness, joy, trust, dan surprise
4	CrowdFlower	30649	Empty, enthusiasm, sadness, neutral, sadness, worry, love, hate, fun, happiness, boredom, relief, anger dan surprise

#### 2.4.2 Pra Pemrosesan Data

Sebelum data dimasukkan ke dalam model maka yang harus dilakukan adalah melakukan pembersihan data. Tujuan dari pembersihan data adalah agar data yang akan dimasukkan ke dalam model sesuai, meminimalkan noise dan dapat diolah pada tahap selanjutnya sehingga hasil klasifikasi yang diharapkan akan mendapatkan hasil yang maksimal, meminimalkan resiko eror. Dengan adanya pra pemrosesan data nantinya akan menghasilkan informasi yang akurat untuk pengambilan keputusan.

Tahapan awal dalam pra pemrosesan data adalah dengan menghapus tanda baca, URL, angka, dan simbol. Semua komponen tersebut tidak dibutuhkan dalam pemrosesan data harus dihapus. Stopwords adalah kata-kata yang disaring sebelum atau sesudah pemrosesan data bahasa alami (teks) [30]. Penghapusan stopword perlu dilakukan, hal tersebut dilakukan karena stopwords berisikan kata yang sering muncul dan makna dalam kata tersebut tidak diperlukan dalam proses deteksi emosi. Setelah membersihkan kata yang tidak dibutuhkan maka yang selanjutnya dilakukan adalah Lematisasi yang merupakan proses linguistik dalam mengelompokkan kata yang dapat dianalisis sebagai item yang sama dengan kata lain [31]. Dalam proses lematisasi, kata diubah ke bentuk dasarnya. Setelah data dibersihkan tahapan selanjutnya adalah tokenisasi, dalam proses ini kalimat dipecah menjadi kata, sehingga kata-katanya dapat terlihat dengan jelas. Setelah proses tokenisasi tahapan selanjutnya dapat dilakukan.

#### 2.4.3 Deteksi Emosi

Pada tahapan deteksi emosi, peneliti melakukan proses one hot encoding. One hot encoding adalah suatu metode untuk mengubah data sehingga data tersebut dapat diaplikasikan ke dalam model dan menghasilkan hasil yang baik. Penelitian ini menggunakan data yang berisikan label emosi pada setiap kalimatnya. Label emosi tersebut perlu diubah menjadi nilai biner dan one hot encoding digunakan pada proses ini. Sebelum proses deteksi emosi, proses pembagian data dilakukan. Data dibagi secara acak menjadi dua bagian yaitu data latih dan data uji dengan persentase 80/20. Tahapan selanjutnya adalah memasukkan data pada word embedding. Word embedding merupakan proses pemetaan kata ke dalam bentuk vektor, representasi dari kata yang memiliki kemiripan. Dalam penelitian ini word Embedding yang digunakan adalah GloVe. Maksimum epoch yang digunakan adalah 100 dengan ukuran batch 128. Untuk mengatasi overfitting, digunakan dropout layer. Kami melatih semua model menggunakan Adam Optimizer.

##### 2.4.3.1 Naïve Bayes

Naïve Bayes algoritma pembelajaran yang menerapkan teorema Bayes. Algoritma ini merupakan model pembelajaran mesin probabilistik yang digunakan untuk tugas klasifikasi.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (1)$$

Dengan menggunakan teorema Bayes, kita dapat mencari peluang terjadinya A, dengan syarat B telah terjadi. Di sini, B adalah bukti dan A adalah hipotesis. Asumsi yang dibuat di sini adalah bahwa prediktor/fiturnya independen. Artinya kehadiran satu fitur tertentu tidak mempengaruhi yang lain. Hal tersebut disebut naive.

##### 2.4.3.2 Support Vector Machine

*Support Vector Machine* (SVM) ilmu yang menerapkan pembelajaran statistik, algoritma ini salah satu algoritma pembelajaran mesin terbaik untuk klasifikasi dan telah berhasil diterapkan pada banyak masalah klasifikasi seperti pengenalan gambar, kategorisasi teks, diagnosis medis, penginderaan jauh, dan klasifikasi gerak [32, 33, 34, 35, 36, 37, 38]. Metode SVM merupakan algoritma klasifikasi yang diteliti karena kemampuannya dapat meminimalkan kesalahan klasifikasi empiris dan memaksimalkan margin geometri ruang klasifikasi.

##### 2.4.3.3 Random Forest

*Random forest* adalah kombinasi prediktor pohon hingga setiap pohon bergantung pada nilai vektor acak yang diambil sampelnya secara independen. Random forest dibangun dengan membangun banyak decision trees dan menggabungkan prediksi dari individual tree. Random forest dilakukan dengan membuat sampel data latih dan decision tree dari sampel. Proses ini

kemudian diulang sampai jumlah pohon yang diinginkan dibangun yang bersama-sama akan membentuk *random forest* [39]. Untuk membuat klasifikasi, semua pohon individu di hutan membuat prediksi dan pemenang ditentukan menggunakan suara terbanyak.

#### 2.4.3.4 Logistic Regression

*Logistic Regression* adalah metode statistik tradisional yang digunakan untuk klasifikasi biner dan telah diadopsi sebagai model *Machine Learning* dasar. Model regresi logistik menghitung probabilitas keanggotaan kelas untuk salah satu dari dua kategori dalam kumpulan data:

$$P(1|x, \alpha) = \frac{1}{1+e^{-(\alpha \cdot x)}} \quad (2)$$

$$P(0|x, \alpha) = 1 - P(1|x, \alpha) \quad (3)$$

Dapat ditunjukkan bahwa model ini benar apabila kepadatan kedua kelas kondisional  $P(1|x)$  dan  $P(0|x)$  multinormal dengan matriks kovarians yang sama [40].

#### 2.4.3.5 Gradient Boosting

*Gradient Boosting* merupakan algoritma machine learning yang merupakan pengembangan dari algoritma *adaptive boosting* [41]. *Gradient Boosting* mampu mencegah terjadinya *overfitting* dengan cara membuat *decision tree* berdasarkan peningkatan struktur pohon pada pembelajaran yang lemah, hal tersebut juga untuk memperbaiki kesalahan dari pohon.

#### 2.4.3.6 RNN dan LSTM

RNN adalah sejenis *feed forward neural network* yang memiliki *hidden state* berulang dan *hidden state* diaktifkan oleh keadaan sebelumnya pada waktu tertentu. RNN memungkinkan input sekuensial yang besar untuk diinterpretasikan ke dalam vektor yang berukuran tetap dengan tetap memperhatikan sifat-sifat terstruktur dari input. Oleh karena itu, RNN dapat memodelkan informasi kontekstual secara dinamis dan dapat menangani variabel yang berurutan panjang.

LSTM adalah evolusi dari arsitektur RNN dan telah menjadi struktur utama RNN saat ini. LSTM mengatasi masalah *vanishing gradient* dengan mengganti unit tersembunyi yang terhubung dengan blok memori dan LSTM dapat memproses data sekuensial yang panjang karena memiliki *memory cell*. Perbedaan antara RNN dan LSTM adalah dengan adanya sinyal yang diberikan pada langkah waktu ke langkah waktu berikutnya, sinyal tersebut dinamai konteks atau *memory cell* yang direpresentasikan dengan simbol  $c_t$ . Terdapat empat *Gates units*, *Gates units* berisikan proses fungsi aktivasi pada setiap masukan pada neurons. Keempat *Gates units* tersebut adalah *forget gates*, *input gates*, *cell gates*, dan *output gates*.

$$i_t = \sigma(W_i \cdot x_t + W_i \cdot h_{t-1} + W_i \cdot c_{t-1} + b_i) \quad (4)$$

$$f_t = \sigma(W_f \cdot x_t + W_f \cdot h_{t-1} + W_f \cdot c_{t-1} + b_f) \quad (5)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(W_c \cdot x_t + W_c \cdot h_{t-1} + b_c) \quad (6)$$

$$o_t = \sigma(W_o \cdot x_t + W_o \cdot h_{t-1} + W_o \cdot c_t + b_o) \quad (7)$$

$$h_t = o_t \tanh(c_t) \quad (8)$$

Dimana  $i_t$  adalah *input gates*,  $f_t$  adalah *forget gate*,  $c_t$  adalah *memory cell*,  $o_t$  adalah *output gates* dan  $h_t$  adalah *hidden states*.

#### 2.4.3.7 GRU

Cho et al (2014) menemukan Gated Recurrent Unit (GRU), GRU merupakan mekanisme gerbang yang memiliki gerbang yang lebih sedikit dibandingkan dengan LSTM. Unit sel GRU memiliki dua gerbang(*gate*); *reset gate* dan *update gate*. *Reset gate* menggabungkan input baru dan memori sebelumnya. *Update gate* memutuskan berapa banyak informasi memori sebelumnya yang akan disimpan untuk menghitung keadaan baru. Berikut adalah rumus untuk menghitung GRU:

$$r_t = \sigma(W_r \cdot x_t + W_r \cdot h_{t-1} + b_r) \quad (9)$$

$$z_t = \sigma(W_z \cdot x_t + W_z \cdot h_{t-1} + b_z) \quad (10)$$

$$\tilde{o}_t = \tanh(W_{\tilde{o}} \cdot x_t + U_{\tilde{o}} \cdot (r_t \otimes h_{t-1}) + b_{\tilde{o}}) \quad (11)$$

$$o_t = z_t \otimes h_{t-1} + (1 - z_t) \otimes \tilde{o}_t \quad (12)$$

Dimana  $x_t$  adalah input vektor,  $z_t$  merupakan *update gate* vektor,  $r_t$  adalah *reset gate* vektor,  $W$ ,  $U$ ,  $b$  merupakan parameter matriks dan  $o_t$  merupakan output vektor.

#### 2.4.3.8 CNN

*Convolutional Neural Network* (CNN) berfungsi dengan dua lapisan utama, lapisan konvolusi, dan lapisan pooling. Lapisan konvolusi digunakan untuk mengekstrak informasi input, disebut sebagai fitur. Di lapisan inilah beberapa konvolusi dilakukan menggunakan fungsi kernel menghasilkan peta fitur. Peta fitur yang telah diperoleh dari lapisan konvolusi ini kemudian diteruskan ke fungsi aktivasi (relu/tanh) yang membuat jaringan saraf nonlinier dan kuat [42].

#### 2.4.3.9 MLP

*Multilayer Perceptron* (MLP) merupakan bagian dari jaringan syaraf tiruan, sebuah feed-forward *neural network* dimana data mengalir melalui beberapa lapisan jaringan untuk mendapatkan output. Struktur MLP terdiri atas tiga bagian yaitu input layer, hidden layer dan output layer. Input layer berisikan representasi dari fitur vektor yang berisi informasi tentang kata-kata. Selanjutnya fungsi aktivasi digunakan untuk menghitung dan memasukkannya ke layer selanjutnya yang pada akhirnya akan masuk ke output layer yang merepresentasikan kelas yang dituju. MLP dilatih menggunakan backpropagation dengan menggunakan metode optimasi gradient descent.

#### 2.4.3.10 Metode Evaluasi

Kinerja yang dihasilkan dievaluasi dengan menggunakan pengukuran akurasi. Akurasi untuk setiap variabel didefinisikan sebagai bagian dari prediksi label yang benar terhadap jumlah total (diprediksi dan aktual) label untuk variabel tersebut. Rumus matematis dari pengukuran ini didefinisikan sebagai berikut:

$$\text{Acc} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (13)$$

Dimana TN (*True Negative*) merupakan data negatif yang ternyata mempunyai nilai benar, FP (*False Positive*) merupakan data negatif yang teridentifikasi sebagai data positif. TP (*True Positive*) adalah data positif yang memiliki nilai benar dan FN (*False Negative*) adalah data positif yang diidentifikasi sebagai data negatif.

### 3. HASIL DAN PEMBAHASAN

Penelitian ini melakukan perbandingan terhadap beberapa algoritma *machine learning* dan *deep learning* untuk mengetahui metode mana yang paling efektif dan cocok dalam melakukan deteksi emosi dalam text. Metode yang tepat akan membantu pengambilan keputusan secara tepat. metode machine learning yang digunakan dalam penelitian ini adalah naive bayes, gradient boosting, logistic regression, random forest dan SVM. Sedangkan untuk *deep learning* yaitu LSTM, CNN, GRU, MLP, dan RNN. Hasil dari pengujian model tersebut dapat dilihat pada Tabel 2. dan Tabel 3. Perbandingan kinerja masing masing metode diukur dengan akurasi.

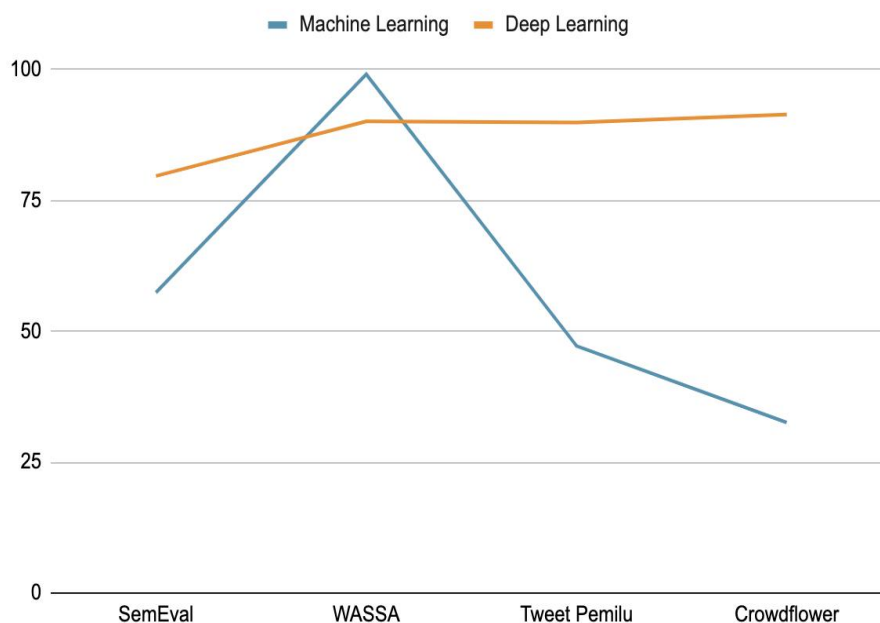
Tabel 2. Hasil Pengujian Machine Learning

Model	SemVal	WASSA	Tweet Pemilu	Crowdflower
Naïve Bayes	56.00%	96.07%	45.17%	30.99%
SVM	58.10%	99.93%	49.36%	34.37%
Logistic Regression	57.85%	99.93%	46.26%	34.64%
Gradient Boosting	57.48%	99.75%	47.35%	33.28%
Random Forest	57.59%	99.93%	47.90%	31.35%

Tabel 3. Hasil Pengujian Deep Learning

Model	SemVal	WASSA	Tweet Pemilu	Crowdflower
LSTM	78.71%	75.00%	<b>90.91%</b>	<b>92.33%</b>
CNN	<b>81.64%</b>	<b>100%</b>	89.21%	88.58%
MLP	80.65%	<b>100%</b>	88.77%	91.76%
RNN	78.71%	75.58%	89.68%	<b>92.30%</b>
GRU	78.71%	<b>100%</b>	<b>90.90%</b>	<b>92.30%</b>

Dari hasil pengujian model, secara keseluruhan metode *deep learning* memiliki akurasi yang lebih tinggi jika dibandingkan dengan metode machine learning. Pembelajaran menggunakan machine learning memiliki kekurangan yang sangat jelas, machine learning memperlakukan kalimat sebagai kumpulan kata-kata tanpa memperhitungkan urutan dan hubungan antar kata tersebut. Berbanding terbalik dengan metode yang ada di *deep learning*, RNN, GRU dan LSTM dapat menangkap informasi kontekstual, terutama semantik dari teks karena ketiga metode ini dapat menangkap hubungan antar kata. CNN dapat mengidentifikasi lokal fitur sehingga dapat mendeteksi emosi secara tepat. MLP bekerja dengan sangat baik dalam deteksi emosi pada text dikarenakan MLP memiliki banyak neuron sehingga mampu untuk untuk mendeteksi emosi pada dataset kompleks yang memiliki banyak label.



Gambar 2. Grafik Perbandingan Akurasi

#### 4. KESIMPULAN

Dari hasil eksperimen yang telah dilakukan dalam penelitian ini, didapatkan hasil sebagai berikut:

- Metode *Deep learning* metode terbaik untuk deteksi emosi dalam text sosial media.
- CNN menghasilkan tingkat tingkat keakuratan klasifikasi emosi tertinggi pada data set semeval dengan akurasi 81.64%. Untuk dataset WASSA akurasi ada pada CNN, MLP dan GRU. sedangkan untuk dataset tweet pemilu LSTM dan GRU menghasilkan akurasi yang tertinggi. Dan pada dataset yang terakhir Crowdfower, LSTM, RNN dan GRU menghasilkan performa yang terbaik untuk pendeteksian emosi ditunjukkan dengan nilai akurasi sebesar 92.33% untuk LSTM dan 92.30% untuk RNN dan GRU.

#### 5. SARAN

Penelitian ini dapat dikembangkan dengan menambah keragaman dataset dan menambah metode deep learning dan machine learning lain. Selain itu penelitian ini juga dapat

dikembangkan dengan mendeteksi emosi dalam bahasa Indonesia serta sumber data nya tidak hanya berasal dari Twitter saja melainkan dari Facebook, Instagram dan sosial media lainnya.

#### UCAPAN TERIMAKASIH

Terima kasih Kami ucapkan kepada semua pihak yang telah memberikan kontribusinya dalam penelitian ini, dan tak lupa juga kami ucapkan terima kasih kami kepada tim redaksi Jurnal Jupiter yang telah bersedia mempublish hasil penelitian kami .

#### DAFTAR PUSTAKA

- [1] J. Bollen, H. Mao, and A. Pepe, "Modeling public mood and emotion: Twitter sentiment and socio-economic phenomena," in *Proceedings of the international AAAI conference on web and social media*, Vol. 5, No. 1, 2011.
- [2] M. Thelwall, K. Buckley, and G. Paltoglou, "Sentiment in Twitter events," *Journal of the American Society for Information Science and Technology*. Vol. 62(2), pp. 406-418, 2011.
- [3] R. Ullah, N. Amblee, W. Kim, and H. Lee, "From valence to emotions: Exploring the distribution of emotions in online product reviews," *Decision Support Systems*, pp. 41-53, 2016.
- [4] D. Al-Hajjar, and A. Z. Syed, "Applying sentiment and emotion analysis on brand tweets for digital marketing," in *Applied Electrical Engineering and Computing Technologie. IEEE*, 2015.
- [5] R. Chitturi, R. Raghunathan, and V. Mahajan, "Form versus function: How the intensities of specific emotions evoked in functional versus hedonic trade-offs mediate product preferences," *Journal of Marketing Research*, Vol. 44, pp. 702-714, 2007.
- [6] P. V. Marsden, and K. E. Campbell, "Reflections on conceptualizing and measuring tie strength," *Social Forces*, pp. 17-23, 2012.
- [7] E. Gilbert, and K. Karahalios, "Widespread worry and the stock market," in *AAAI Conference on Web and Social Media*, pp. 59-65, 2010.
- [8] P. Burnap, and M. L. Williams, "Cyber hate speech on Twitter: An application of machine classification and statistical modeling for policy and decision making," *Policy & Internet*, Vol. 7, pp. 223-242, 2015.
- [9] R. Van der Zanden, K. Curie, M. Van Londen, J. Kramer, G. Steen, and P. Cuijpers, "Web-based depression treatment: Associations of clients' word use with adherence and outcome," *Journal of Affective Disorders*, pp. 10-13, 2014.
- [10] P. Rodriguez, A. Ortigosa, and R. M. Carro, "Extracting emotions from texts in e-learning environments," in *International Conference on Complex, Intelligent, and Software Intensive Systems*, IEEE, 2012, pp. 887-892.
- [11] T. Danisman, and A. Alpkocak, "Feeler: Emotion classification of text using vector space model," in *AISB 2008 Convention Communication, Interaction and Social Intelligence 1*, 53, 2008.
- [12] S. Chaffar, and D. Inkpen, "Using a heterogeneous dataset for emotion analysis in text," in *Canadian conference on artificial intelligence*, 2011, pp. 62-67.
- [13] K. Sailunaz, and R. Alhajj, "Emotion and sentiment analysis from Twitter text," *Journal of Computational Science* 36, 2019.
- [14] B. Thomas, P. Vinod, and K. A. Dhanya, "Multiclass emotion extraction from sentences," *International Journal of Scientific and Engineering Research*, 5(2), 2014.
- [15] Zulqarnain, M., Ghazali, R., Ghouse, M. G., & Mushtaq, M. F. (2019). Efficient processing of GRU based on word embedding for text classification. *JOIV: International Journal on Informatics Visualization*, 3(4), pp. 377-383.



- 
- [16] L. Li, G. Cai, and N. Chen, "A rumor events detection method based on deep bidirectional GRU neural network," in *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)*, 2018, pp. 755-759.
- [17] X. Yao, and Y. Liu, "Machine learning," in *Search Methodologies*, Springer, Boston, MA, 2014. pp. 477-517.
- [18] S. Chaffar, and D. Inkpen, "Using a heterogeneous dataset for emotion analysis in text," in *Canadian conference on artificial intelligence*, 2011, pp. 62-67.
- [19] K. Sailunaz, and R. Alhajj, "Emotion and sentiment analysis from Twitter text," *Journal of Computational Science* 36, 2019.
- [20] B. Thomas, P. Vinod, and K. A. Dhanya, "Multiclass emotion extraction from sentences," *International Journal of Scientific and Engineering Research* 5(2), 2014.
- [21] E. H. Jang, B. J. Park, S. H. Kim, and J. H. Sohn, "Emotion classification by machine learning algorithm using physiological signals," *Proc. of Computer Science and Information Technology* 25, 2012, 1-5.
- [22] N. A. S. Winarsih, and C. Supriyanto, "Evaluation of classification methods for Indonesian text emotion detection," in *2016 International Seminar on Application for Technology of Information and Communication (ISemantic)*, 2016, pp. 130-133.
- [23] F. M. Alotaibi, "Classifying Text-Based Emotions Using Logistic Regression," *VAWKUM Transactions on Computer Sciences* 16(2). 2019, pp. 31-37.
- [24] U. Gupta, A. Chatterjee, R. Srikanth, and P. Agrawal, "A sentiment-and-semantics-based approach for emotion detection in textual conversations," *arXiv preprint arXiv:1707.06996*, 2017.
- [25] B. Kratzwald, S. Ilić, M. Kraus, S. Feuerriegel, and H. Prendinger, "Deep learning for affective computing: Text-based emotion recognition in decision support," *Decision Support Systems* 115, 2018, pp. 24-35.
- [26] S. Sharifirad, B. Jafarpour, and S. Matwin, "How is your mood when writing sexist tweets? Detecting the emotion type and intensity of emotion using natural language processing techniques," *arXiv preprint arXiv:1902.03089*, 2019.
- [27] P. Goel, D. Kulshreshtha, P. Jain, and K. K. Shukla, "Prayas at EmoInt 2017: An ensemble of deep neural architectures for emotion intensity prediction in tweets," in *Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis*, 2017, pp. 58-65.
- [28] H. Ren, J. Wan, and Y. Ren, "Emotion detection in cross-lingual text based on bidirectional LSTM," In *International Conference on Security with Intelligent Computing and Big-data Services*, 2018, pp. 838-845.
- [29] F. K. Khattak, S. Jeblee, C. Pou-Prom, M. Abdalla, C. Meaney, and F. Rudzicz, "A survey of word embeddings for clinical text," *Journal of Biomedical Informatics: X* 4, 2019.
- [30] A. Rajaraman, J. D. Ullman, "Data Mining," *Mining of Massive Datasets*, pp. 1-17, 2011.
- [31] Collins English Dictionary, entry for "lemmatise"
- [32] Y. Bazi, and F. Melgani, "Toward an optimal SVM classification system for hyperspectral remote sensing images," *IEEE Transactions on Geoscience and Remote Sensing*, pp. 3374-3385, 2006.
- [33] T. Bellotti, and J. Crook, "Support vector machines for credit scoring and discovery of significant features," *Expert Systems with Applications*, 2008.
- [34] C. A. Burges, "tutorial on support vector machines for pattern recognition," *Data Mining and Knowledge Discovery*, 2, pp. 121-167, 1998.
- [35] C. Huang, H. Liao, and M. Chen, "Prediction model building and feature selection with support vector machines in breast cancer diagnosis," *Expert Systems with Applications*, 34, pp. 578-587, 2008.
- [36] R. Liu, Y. Wang, T. Baba, D. Masumoto, and S. Nagata, "SVM-based active feedback in image retrieval using clustering and unlabeled data," *Pattern Recognition*, 41, pp. 2645-2655, 2008.

- 
- [37] T. Shon, and J. Moon, “A hybrid machine learning approach to network anomaly detection,” *Information Sciences*, 177, pp. 3799–3821, 2007.
- [38] Z. Yan, Z. Wang, and H. Xie, “The application of mutual information-based feature selection and fuzzy LS-SVM-based classifier in motion classification,” *Computer Methods and Programs in Biomedicine*, 90, pp. 275–284, 2008.
- [39] J. Friedman, T. Hastie, and R. Tibshirani, “The elements of statistical learning,” volume 1. Springer series in statistics New York, 2001.
- [40] S. Dreiseitl, and L. Ohno-Machado, “Logistic regression and artificial neural network classification models: a methodology review,” *Journal of biomedical informatics*, 35(5-6), pp. 352-359, 2002.
- [41] J.H. Friedman, “Greedy Function Approximation: A Gradient Boosting Machine,” *Ann. Stat.*, Vol. 29, No. 5, pp. 1189–1232, 2014.
- [42] X. Zhang, J. Zhao, and Y. LeCun, “Character-level convolutional networks for text classification,” in *Advances in neural information processing systems*, 2015, pp. 649-657.