

DETEKSI HOAKS PADA BERITA LOKAL INDONESIA MENGUNAKAN MODEL BERBASIS RECURRENT NEURAL NETWORK

Marvel Timothy Raphael Manullang¹, Kresna Hafizh Muhaimin², Alfirsa Damasyifa Fauzulhaq³, Riza Setiawan Soetedjo⁴, Putu Rama Bena Putra⁵, Novanto Yudistira⁶

^{1, 2, 3, 4, 5, 6} Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya, Jl. Veteran No. 8, Malang, 65145, Indonesia

E-mail: ¹marvelmanullang@student.ub.ac.id ²kresnahm@student.ub.ac.id ³alfirsafauzulh@student.ub.ac.id ⁴riz_stwn@student.ub.ac.id ⁵ramabenarb@student.ub.ac.id ⁶yudistira@ub.ac.id

ARTICLE INFO

ABSTRAK

Kata kunci:

Hoaks, Indonesia, Klasifikasi, Recurrent Neural Network

Perkembangan teknologi mempermudah akses segala macam informasi apapun. Bersamaan dengan hal tersebut, banyak situs yang mengadopsi format berita daring untuk berbagai macam topik dan jumlahnya meningkat secara eksponensial. Situs tersebut dibuat tanpa adanya filter sehingga tidak sedikit pula informasi palsu ada di dalam situs tersebut. Penelitian ini dilakukan untuk mengklasifikasikan berita yang sifatnya hoaks dan valid dengan menggunakan dataset yang telah disediakan oleh situs Mendeley. Dataset tersebut berisi cuplikan berita dalam bahasa Indonesia yang diberi kelas valid dan hoax. Klasifikasi akan dilakukan dengan menerapkan variasi algoritma *Recurrent Neural Network* (RNN). Penelitian ini memperoleh hasil yaitu model *Long-Short Term Memory* (LSTM) dengan *Cross Entropy Loss* dan *Gated Recurrent Unit* (GRU) dengan *Binary Cross Entropy Loss* memberikan akurasi terbaik yaitu sebesar 80%.

1. Pendahuluan

Berita adalah cerita atau keterangan mengenai kejadian atau peristiwa yang pernah terjadi [1]. Berita menjadi cara bagaimana informasi terbarukan disampaikan ke masyarakat umum dengan tujuan untuk mengabarkan kejadian terkini yang terjadi baik dalam skala nasional maupun internasional. Saat ini internet menjadi salah satu media untuk membuat artikel berita dan sangat mudah untuk mengakses berita-berita yang tersebar di internet hanya dengan melakukan pencarian di mesin pencarian internet seperti Google dan Bing. Berita yang ada di internet banyak ditulis oleh media yang terpercaya tetapi tidak sedikit pula berita di internet dibuat oleh orang-orang tidak bertanggung jawab tanpa ada dasar sehingga menghasilkan berita bohong atau hoaks.

Hoaks atau berita bohong adalah sekumpulan informasi yang pada kenyataannya tidak benar tetapi seakan-akan dibuat benar adanya. Saat ini banyak berita hoaks bertebaran di internet yang menciptakan keresahan dan kebingungan di kalangan masyarakat. Selain itu keberadaan berita hoaks dapat mengadu domba dua atau lebih kelompok masyarakat yang tersinggung akan suatu berita sehingga tidak menutup kemungkinan untuk terjadinya keributan yang disebabkan dari informasi yang tidak benar.

Kementerian Komunikasi dan Informatika Republik Indonesia [2] mengatakan bahwa pada tahun 2017 terdapat kurang lebih 800.000 situs Indonesia yang terindikasi sebagai situs penyebar hoaks. Hal ini menunjukkan bahwa sulitnya menyaring informasi yang bergerak di internet. Seluruh informasi di internet dapat muncul tanpa ada verifikasi kebenaran mengenai berita yang tersebar.

Dari pemaparan pada paragraf sebelumnya, dibutuhkan sebuah metode untuk mendeteksi apakah suatu berita merupakan berita bohong atau berita valid. Maka dari itu penelitian ini dilakukan untuk memenuhi tujuan tersebut. Penelitian ini akan menggunakan metode Deep Learning untuk melakukan klasifikasi berita bohong.

Deep Learning adalah sistem pembelajaran mesin yang menggunakan lebih dari satu lapisan pada proses pembelajaran mesin [3]. Penelitian ini akan menggunakan variasi dari deep learning yang dapat melakukan klasifikasi data yang bersifat sekuens, yaitu Recurrent Neural Network (RNN). RNN sesuai namanya merupakan sebuah model Deep Learning yang melakukan pelatihan secara berulang dan RNN dapat melakukan proses pembelajaran untuk data yang bersifat sekuens atau data yang memiliki hubungan dengan data selanjutnya [3]. Varian RNN yang digunakan untuk menangkap pola yang panjang baik pada teks maupun deret waktu adalah LSTM. Beberapa aplikasi LSTM digunakan dalam prediksi deret waktu COVID-19 [9], penggunaan listrik [10], polusi [11].

RNN memiliki beberapa pengembangan yang nantinya akan digunakan pada penelitian ini, yaitu LSTM dan GRU. Ketiga model tersebut akan dibentuk untuk melakukan klasifikasi pada data hoaks dan dibandingkan bagaimana performa antara satu model dengan model lainnya.

2. Metodologi

2.1 Research Goal

Berdasarkan permasalahan yang ada, penelitian ini kemudian ditujukan untuk membandingkan performa dari ketiga model yang diuji, yaitu Vanilla Recurrent Neural Network, Long-Short Term Memory (LSTM), dan Gated Recurrent Unit (GRU). *Metric* pembanding yang digunakan pada penelitian ini meliputi nilai akurasi, precision, recall, dan F1-score dari hasil model. Persebaran hasil prediksi akan dilakukan visualisasi menggunakan *confusion matrix*. Hasil dari penelitian ini akan diperoleh model dengan performa tertinggi hingga performa terendah dari tiga model yang diujikan.

2.2 Retrieving Data

Data yang digunakan merupakan data berita hoaks berbahasa Indonesia yang dihasilkan dari penelitian yang dilakukan oleh (Pratiwi, et al, 2017) [4]. Klasifikasi pada data ini pernah dilakukan dan memberikan hasil akurasi sebesar 78,6%. Pada datanya terdapat 5 jenis data seperti yang diperlihatkan pada Tabel 1. Tetapi, untuk penelitian ini menggunakan data yang memiliki 600 teks berita yang diberikan label “valid” atau “hoax” sesuai beritanya.

Tabel 1. Detail Data yang diperoleh

Nama Fail	Deskripsi
250 news with valid hoax label.csv	Fail yang berisi 250 teks berita berbahasa Indonesia dengan label valid atau hoax
250 news labelling process.xlsx	Fail yang berisi informasi proses pelabelan pada 10 topik berita berdasarkan suara terbanyak dari 3 juri
250 news experiment documentation.xlsx	Fail yang berisi dokumentasi eksperimen terhadap data menggunakan model Naïve Bayes menggunakan 3 perbandingan data latih dan data uji yang berbeda
600 news with valid hoax label.csv	Fail yang berisi 600 teks berita berbahasa Indonesia dengan label valid atau hoax
600 news labelling process.xlsx	Fail yang berisi informasi proses pelabelan pada 12 topik berita berdasarkan suara terbanyak dari 3 juri

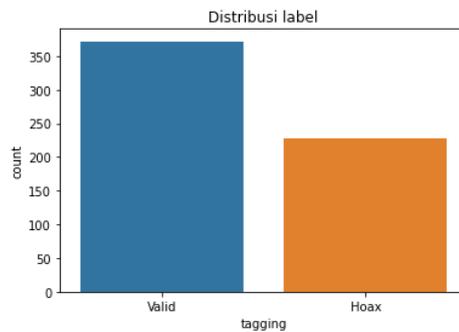
2.3 Data Preparation

Data melewati 7 tahap *preprocessing* sebelum dimasukkan ke dalam model. Pertama, data dinormalisasi yaitu tiap huruf pada teks berita diubah menjadi huruf kecil. Selanjutnya adalah proses *cleaning* data dimana

data dibersihkan seperti penghilangan huruf yang bukan alfabet dan penghilangan *whitespace*. Tahap selanjutnya adalah proses *stemming* data dimana tiap-tiap kata diubah menjadi kata dasarnya. Selanjutnya adalah melakukan *tokenizing* pada data yang mana tiap-tiap kata diubah menjadi nilai dan kemudian dilakukan *padding*. Selain pada teks berita, label juga dilakukan *preprocessing* yang mana tiap-tiap label dilakukan *mapping* sehingga label hoaks menjadi nilai 0 dan label valid menjadi nilai 1. Selanjutnya, data dipisah menjadi 2 jenis data yaitu data latih dan data uji dengan perbandingan 9:1 sehingga data latih berjumlah 540 dan data uji berjumlah 60. Terakhir data dikonversi ke bentuk tensor agar dapat dimasukkan ke dalam model.

2.4 Data Exploration

Beberapa eksplorasi pada data dilakukan untuk mendapatkan *insight* dari data sehingga jika diperlukan, dapat melakukan *preparation* tambahan agar dapat menghasilkan akurasi yang lebih tinggi. Gambar 1 memberikan informasi bahwa data ini memiliki ketidakseimbangan antara label valid dan label hoaks.

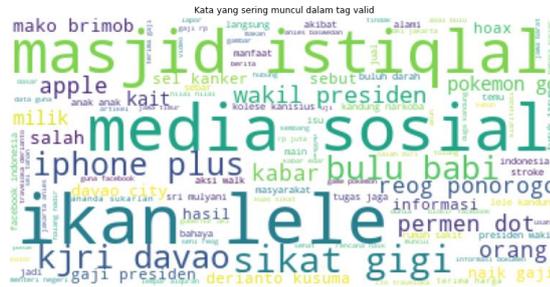


Gambar 1. Distribusi label

Selain pada label, eksplorasi pada teks berita juga dilakukan dengan menggunakan Wordcloud yang menunjukkan frekuensi kemunculan kata. Semakin sering kata tersebut muncul, maka semakin besar kata tersebut pada Wordcloud. Pada Gambar 2, 3 kata yang paling sering muncul adalah ikan lele, sikat gigi, dan bulu babi. Selain Wordcloud terhadap keseluruhan data, Gambar 3 menunjukkan wordcloud kata yang sering muncul pada data dengan label valid sedangkan Gambar 4 menunjukkan wordcloud kata yang sering muncul pada data dengan label hoax. 3 kata terbanyak pada Gambar 3 adalah ikan lele, media sosial, dan masjid istiqlal. 3 kata terbanyak pada Gambar 4 adalah ikan lele, bulu babi, dan sikat gigi.



Gambar 2. Wordcloud kata yang sering muncul dalam dataset



Gambar 3. Wordcloud kata yang sering muncul dalam data berlabel valid



Gambar 4. Wordcloud kata yang sering muncul dalam data berlabel hoax

2.5 Data Modeling

Pada penelitian ini membandingkan 3 jenis model yang berbeda. Untuk memberikan perbandingan yang jelas, penelitian ini menggunakan 2 jenis fungsi loss yang berbeda pada tiap model, yaitu *Binary Cross Entropy Loss* (BCEL) dan *Cross Entropy Loss* (CEL). Untuk memudahkan perbandingan, digunakanlah *hyperparameter* yang sama pada tiap fungsi loss untuk tiap model. *Hyperparameter* yang digunakan untuk BCEL dan CEL dapat dilihat pada Tabel 2.

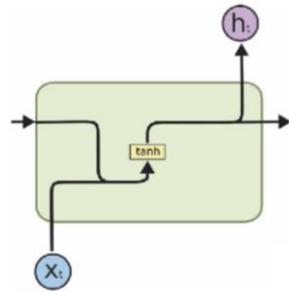
Tabel 2. *Hyperparameter* yang digunakan

<i>Hyperparameter</i>	BCEL	CEL
Input_size	Tokenizer.vocab length + 4	Tokenizer.vocab length + 4
Embedding_size	1024	1024
Hidden_size	512	512
Num_layers	1	1
Num_classes	1	2
Dropout_rate	.1	.1
Batch_size	32	32
Learning_rate	0.001	0.001
epochs	15	15
optimizer	Adam	Adam

Ketiga model yang akan dibandingkan yaitu Recurrent Neural Network, Long-Short Term Memory dan Gated Recurrent Unit

2.5.1 Recurrent Neural Network(RNN)

RNN merupakan pengembangan dari *Neural Network*. Pada *Neural Network* prosesnya dari *input* masuk *hidden layer* lalu menghasilkan *output*. Namun dalam RNN terjadi perulangan pada prosesnya. Pada RNN yang terjadi dalam *hidden layer* adalah setiap *input* yang masuk dan menghasilkan *output* akan masuk kembali menjadi *input* untuk iterasi berikutnya [5]. Arsitektur dari RNN Cells ada pada Gambar 5.



Gambar 5. RNN Cells

$$h_t = \tanh(W_{ih}x_t + b_{ih} + W_{hh}h_{(t-1)} + b_{hh}) \quad (1)$$

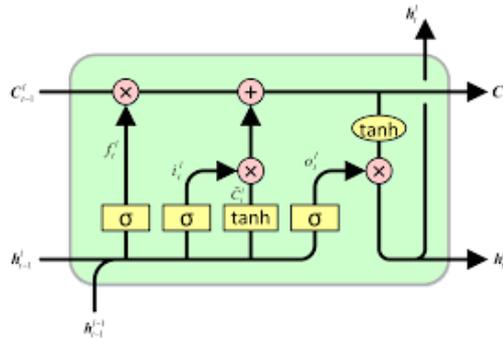
Keterangan :

- h_t = *Hidden state* pada waktu t
- x_t = Masukkan pada waktu t
- h_{t-1} = *Hidden state* sebelumnya (t-1)
- W_{ih} = Bobot perhitungan terhadap masukkan
- W_{hh} = Bobot perhitungan terhadap *hidden state*
- b_{ih} = Bias perhitungan terhadap masukkan
- b_{hh} = Bias perhitungan terhadap *hidden state*

2.5.2 Long Short Term Memory(LSTM)

Salah satu variasi RNN adalah LSTM. Pada RNN memiliki kelemahan yaitu tidak mampu dalam menyimpan terlalu banyak informasi pada proses *learning*. Masalah ini dapat diselesaikan dengan teknik LSTM. Penggunaan LSTM digunakan untuk menggantikan *node* RNN dalam *hidden layer* yang dapat disebut juga LSTM Cells [6]. Didalam LSTM Cells terdapat 3 *gates* yaitu *Input Gate*, *Forget Gate*, dan *Output Gate*. Pada Gambar 6 menunjukkan bagaimana arsitektur dari LSTM Cells itu sendiri.

Proses perhitungan yang terjadi pada sel LSTM dimulai pada perhitungan *forget gate* menggunakan Persamaan (2). Langkah selanjutnya adalah melakukan perhitungan pada *input gate* dan menghitung nilai *candidate cell state* menggunakan Persamaan (3) dan Persamaan (4). Setelah nilai pada *input gate* didapat, selanjutnya melakukan perhitungan nilai *cell state* menggunakan Persamaan (5). Langkah terakhir pada sel LSTM adalah menghitung nilai *output gate* dan *hidden state* menggunakan Persamaan (6) dan Persamaan (7).



Gambar 6. LSTM Cells

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (4)$$

$$C_t = (f_t * C_{t-1} + i_t * \tilde{C}_t) \quad (5)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \tanh(C_t) \quad (7)$$

Keterangan:

f_t = forget gate

i_t = input gate

\tilde{C}_t = candidate cell state

C_t = cell state

o_t = output gate

h_t = hidden state pada timestep t

x_t = data pada timestep t

h_{t-1} = hidden state pada timestep sebelumnya

C_{t-1} = cell state pada timestep sebelumnya

σ = fungsi aktivasi sigmoid

\tanh = fungsi aktivasi Hyperbolic Tangent

W_f = Bobot forget gate

W_i = Bobot input gate

W_C = Bobot candidate cell state

W_o = Bobot output gate

b_f = Bias forget gate

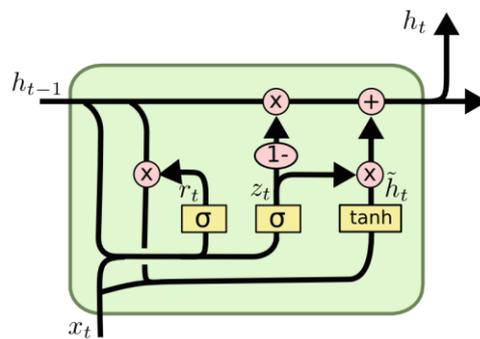
b_i = Bias input gate

b_C = Bias candidate cell state

b_o = Bias output gate

2.5.3 Gated Recurrent Unit(GRU)

GRU merupakan variasi dari RNN dan LSTM. GRU hadir untuk menyelesaikan masalah pada RNN standar mengenai *vanishing gradient* [7]. Mekanisme khusus yang ada pada GRU adalah adanya *gating* pada *hidden state*. Fungsi ini memungkinkan GRU Cells untuk menentukan kapan *hidden state* harus diperbarui dan juga kapan *hidden state* harus disetel ulang. Arsitektur pada GRU Cells dapat dilihat pada Gambar 7. Proses yang terjadi di dalam GRU diawali dengan melakukan perhitungan pada *update gate* dengan menggunakan Persamaan (8). Langkah selanjutnya adalah untuk melakukan perhitungan pada *reset gate* dengan menggunakan Persamaan (9). Setelah proses pada *update* dan *reset gate* selesai maka GRU akan melakukan perhitungan terhadap kandidat vektor menggunakan Persamaan (10) dilanjutkan dengan menghitung keluaran vektor menggunakan Persamaan (11).



Gambar 7. GRU Cells

$$z_t = \sigma(W_z \times [h_{t-1}, X_t] + b_{iz} + b_{hz}) \quad (8)$$

$$r_t = \sigma(W_r \times [h_{t-1}, X_t] + b_{ir} + b_{hr}) \quad (9)$$

$$n_t = \tanh(W_n \times [r_t \times h_{t-1}, X_t] + b_{in} + b_{nn}) \quad (10)$$

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \quad (11)$$

Keterangan :

z_t = Update gate

σ = Fungsi sigmoid

h_t = Hidden state

X_t = Masukkan data pada waktu t

h_{t-1} = Hidden state sebelumnya (t-1)

$W_{z,r,n}$ = Bobot perhitungan

$b_{iz,ir,in}$ = Bias perhitungan terhadap masukkan

$b_{hz,hr,hn}$ = Bias perhitungan terhadap hidden state

r_t = Reset Gate

\tilde{h}_t = Kandidat hidden state

2.6 Evaluasi Model

Performa tiap-tiap model dievaluasi dengan cara menghitung akurasi, *precision*, *recall*, dan f1-score yang diperoleh model. Untuk rumus dari akurasi, *precision*, *recall*, dan f1-score ditunjukkan sebagai berikut :

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

$$precision = \frac{TP}{TP + FP} \quad (13)$$

$$recall = \frac{TP}{TP + FN} \quad (14)$$

$$F1\ Score = \frac{2 \times precision \times recall}{precision + recall} \quad (15)$$

Keterangan :

TP = Jumlah data diprediksi positif yang diklasifikasikan benar oleh model

TN = Jumlah data diprediksi negatif yang diklasifikasikan benar oleh model

FP = Jumlah data diprediksi positif yang diklasifikasikan salah oleh model

FN = Jumlah data diprediksi negatif yang diklasifikasikan salah oleh model

2.7 Cross Entropy Loss (CEL)

Fungsi loss *Cross Entropy Loss* (CEL) adalah gabungan dari fungsi *LogSoftmax* dan *Negative Log Likelihood Loss* atau *NLLLoss* (Pytorch, 2019). Fungsi CEL akan membandingkan semua probabilitas hasil prediksi terhadap nilai yang sebenarnya menggunakan Persamaan (16).

$$Loss = - \sum_{i=1}^n y_i \cdot \log(\hat{y}_i) \quad (16)$$

Keterangan:

Loss = nilai loss

n = jumlah *output*

y_i = label ke – i sebenarnya

\hat{y}_i = hasil prediksi label ke-I

2.8 Binary Cross Entropy Loss (BCEL)

Fungsi loss *Binary Cross Entropy Loss* (BCEL) adalah fungsi loss yang digunakan untuk mengklasifikasikan label biner yang mana kelasnya hanya 2. Pada saat menggunakan BCEL sebagai fungsi lossnya, maka fungsi *softmax* yang digunakan oleh CEL diganti menjadi fungsi sigmoid. Persamaan (17) merupakan persamaan yang digunakan pada BCEL.

$$Loss = - \frac{1}{n} \sum_{i=1}^n y_i \cdot \log \log \hat{y}_i + (1 - y_i) \cdot \log \log (1 - \hat{y}_i) \quad (17)$$

Keterangan:

Loss = nilai loss

n = jumlah *output*

y_i = label ke – i sebenarnya

\hat{y}_i = hasil prediksi label ke-I

3. Hasil dan Pembahasan

3.1 Hasil LSTM

Performa LSTM baik pada BCEL dan CEL memberikan nilai akurasi yang baik dengan nilai masing-masing adalah 70% dan 80%. Performa LSTM pada CEL lebih baik dibanding menggunakan BCEL terutama untuk mendeteksi berita yang memiliki label bernilai 1. Untuk performa model LSTM yang lebih detail ditunjukkan pada Tabel 3.

Tabel 3. Performa LSTM

Fungsi Loss	Precision		Recall		F1-Score		Accuracy
	0	1	0	1	0	1	
	BCEL	72%	65%	84%	48%	77%	
CEL	82%	76%	86%	70%	84%	73%	80%

3.2 Hasil GRU

Performa kedua fungsi loss pada GRU terlihat sangat berbeda jauh dikarenakan GRU menggunakan CEL memiliki performa yang buruk yaitu hanya dengan 38% akurasi sedangkan GRU yang menggunakan BCEL memiliki akurasi sebesar 80%. Untuk performa model GRU yang lebih detail ditunjukkan pada Tabel 4.

Tabel 4. Performa GRU

Fungsi Loss	Precision		Recall		F1-Score		Accuracy
	0	1	0	1	0	1	
	BCEL	80%	79%	89%	65%	85%	
CEL	50%	37%	11%	83%	18%	51%	38%

3.3 Hasil RNN

Sama halnya seperti LSTM, selisih performa kedua fungsi loss pada RNN tidak banyak. Akurasi pada RNN dengan BCEL lebih baik dengan nilai 60% sedangkan pada CEL hanya bernilai 58%. Walaupun akurasi yang diberikan RNN terlihat tinggi, tetapi nilai tersebut dikarenakan RNN lebih berhasil mendeteksi label yang hoaks. Nilai pada label yang valid sangatlah rendah sehingga performa RNN dapat dibilang sangatlah buruk dibanding kedua model sebelumnya. Untuk performa model RNN yang lebih detail ditunjukkan pada Tabel 5.

Tabel 5. Performa RNN

Fungsi Loss	Precision		Recall		F1-Score		Accuracy
	0	1	0	1	0	1	
	BCEL	62%	43%	89%	13%	73%	
CEL	62%	38%	86%	13%	72%	19%	58%

4. Kesimpulan

Pada penelitian ini, diperoleh dua model yang menghasilkan performa terbaik. Yang pertama adalah LSTM dengan fungsi loss CEL yang memberikan akurasi 80% dan juga nilai *precision*, *recall*, dan f1-score yang tidak berselisih jauh antar kedua label. Yang kedua adalah GRU dengan fungsi los BCEL yang memberikan akurasi 80% dan nilai *precision*, *recall*, dan f1-score yang juga tidak berselisih jauh antar kedua label.

Walaupun model LSTM dan GRU menunjukkan bahwa label 1 lebih susah dideteksi dibandingkan label 0 dikarenakan nilai pada label 1 lebih kecil dari label 0, hasil pada RNN yang paling menunjukkan bahwa pernyataan tersebut benar dengan hasil f1-score yang sangat buruk pada label 1 yaitu hanya dengan nilai yang lebih kecil sama dengan 20%.

Daftar Pustaka

- [1] KEMENTRISTEKDIKTI, 2021. *Kamus Besar Bahasa Indonesia*. s.l.:s.n.
- [2] KEMENTERIAN KOMUNIKASI dan INFORMATIKA Republik Indonesia, 2017. *Ada 800.000 Situs Penyebar Hoax di Indonesia*. [Online] Available at: https://kominfo.go.id/content/detail/12008/ada-800000-situs-penyebar-hoax-di-indonesia/0/sorotan_media
- [3] GOODFELLOW, I., BENGIO, Y. & COURVILLE, A., 2016. *Deep Learning*. s.l.:s.n.
- [4] Pratiwi, Ingrid Yanuar Risca, Rosa Andrie Asmara, and Faisal Rahutomo. "Study of hoax news detection using naïve bayes classifier in Indonesian language." *2017 11th International Conference on Information & Communication Technology and System (ICTS)*. IEEE, 2017.
- [5] GRAVES, A., 2012. Sequence transduction with recurrent neural networks. *arXiv preprint arXiv:1211.3711*.
- [6] HOCHREITER, S. & SCHMIDHUBER, J., 1997. LSTM can solve hard long time lag problems. *Advances in neural information processing systems*, pp. 473-479.
- [7] CHUNG, J., GULCEHRE, C., CHO, K. & BENGIO, Y., 2014. Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*.
- [8] Paszke, Adam, et al. "Pytorch: An imperative style, high-performance deep learning library." *Advances in neural information processing systems* 32 (2019).
- [9] Yudistira, Novanto. "COVID-19 growth prediction using multivariate long short term memory." *arXiv preprint arXiv:2005.04809* (2020).
- [10] Selle, Nurfatima, Novanto Yudistira, and Candra Dewi. "Perbandingan Prediksi Penggunaan Listrik dengan Menggunakan Metode Long Short Term Memory (LSTM) dan Recurrent Neural Network (RNN)." *Jurnal Teknologi Informasi dan Ilmu Komputer* 9.1 (2022): 155-162.
- [11] Vidianto, Angga, Achmad Sindunata, and Novanto Yudistira. "Air Pollution Particulate Matter (PM2.5) Forecasting using Long Short Term Memory Model." *6th International Conference on Sustainable Information Engineering and Technology 2021*. 2021.