

Model Recurrent Neural Network-Gated Recurrent Unit untuk Membangun Mesin Penerjemah Bahasa Indonesia-Banyumasan

Andik Wijanarko¹, Adzkiyatun Nisa Al Haura², Indar Puspitaningrum³, Dhanar Intan Surya Saputra⁴

¹Program Studi Teknologi Informasi, ^{2,3,4}Program Studi Informatika
Universitas Amikom Purwokerto
Banyumas, Indonesia

e-mail: ¹andikwijanarko@amikompurwokerto.ac.id, ²adzkiyaanis4@gmail.com,
³indar.puspitaningrum16@gmail.com, ⁴dhanarsaputra@amikompurwokerto.ac.id

Diajukan: 17 Juli 2023; Direvisi: 7 September 2023; Diterima: 28 Desember 2023

Abstrak

Bahasa Banyumasan berakar dari bahasa Jawa dengan dialek Banyumasan, dituturkan di bagian barat Jawa Tengah dan sebagian bagian timur provinsi Jawa Barat. Undang-undang mengungkapkan perlunya upaya pelestarian bahasa daerah. Salah satu upayanya adalah membangun mesin penerjemah bahasa Indonesia-Banyumasan. Model yang digunakan adalah Recurrent Neural Network yang digunakan untuk membangun mesin penerjemah beberapa bahasa daerah di Indonesia, tapi belum pernah digunakan untuk bahasa Indonesia-Banyumasan, khususnya Gated Recurrent Unit. Tujuan penelitian ini membangun mesin penerjemah bahasa Indonesia-Banyumasan dan mengukur kualitas terjemahannya. Metode yang digunakan adalah eksperimen mulai dari pembuatan korpus paralel yang dilanjutkan melakukan training korpus menggunakan, dan langkah terakhir adalah melakukan evaluasi menggunakan metrik Bilingual Evaluation Understudy. Korpus paralel yang digunakan berisi 1.302 kalimat dengan panjang kalimat rata-rata 20 kata perkalimat. Waktu training yang diperlukan adalah 72 jam. Skor metrik yang dihasilkan adalah 34.1 yang berarti model tersebut dan paralel korpus menghasilkan kualitas terjemahan yang masih dapat ditingkatkan.

Kata kunci: Mesin penerjemah, Banyumas, Indonesia, RNN, GRU.

Abstract

The Banyumasan language has its roots in the Javanese language with the Banyumasan dialect, spoken in the western region part of Central Java and parts of the eastern part of West Java province. Protecting regional languages is important, and the law reflects that. To help preserve Banyumasan, they're making a machine that can translate between it and Indonesian. The model used is a Recurrent Neural Network which is used to build translation machines for several regional languages in Indonesia, but has never been used for the Indonesian-Banyumasan language, especially the Gated Recurrent Unit. The primary purpose of this research is to construct an Indonesian-Banyumasan language translation machine and measure the quality of the translation. The research approach involves a structured experiment, beginning with the development of a parallel corpus, then training the translation model on this corpus, and culminating in a comprehensive evaluation using the Bilingual Evaluation Understudy metric. The training data consists of 1,302 sentences, each averaging 20 words, in both Indonesian and Banyumasan. The training time required is 72 hours. The resulting metric score is 34.1, which means that the model and the parallel corpus produce translation quality that can still be improved.

Keywords: RNN, GRU, Machine Translation, Banyumasan, Indonesia.

1. Pendahuluan

Indonesia merupakan negara dengan banyak suku dan bahasa. Berdasarkan data tahun 2019 dari peta bahasa kementerian pendidikan dan kebudayaan, Indonesia memiliki 718 bahasa daerah [1] salah satunya adalah bahasa daerah Banyumasan. Bahasa Banyumasan digunakan di wilayah Jawa Tengah

bagian barat yang berdekatan dengan wilayah Jawa Barat bagian timur. Pengguna bahasa Banyumasan antara lain adalah wilayah kabupaten Kebumen, Banyumas, Cilacap, Purbalingga, Tegal, Brebes, dan sebagian wilayah kabupaten Cirebon. Melihat luasnya wilayah penggunaan bahasa Banyumasan maka perlu dilakukan pelestarian bahasa ini, salah satunya adalah dengan membuat mesin penerjemah, yang mana dapat menerjemahkan kalimat-kalimat dari dua bahasa yang berbeda [2].

Bahasa Banyumasan sebagai kekayaan intelektual cenderung kurang disadari pemakaiannya oleh masyarakat penutur bahasa [3]. Selain itu bahasa Banyumasan mengalami *stereotype* sebagai bahasa kaum marjinal sehingga penuturnya enggan menggunakannya dalam percakapan sehari-hari di luar wilayahnya [4]. Meskipun demikian konten video yang berisi bahasa Banyumasan banyak penontonnya, hal ini menunjukkan bahasa Banyumasan banyak peminatnya. Permasalahannya adalah karena *stereotype* membuat penutur bahasa ini semakin sedikit, oleh karena ini perlu dibuat alat untuk mempermudah untuk mengerti bahasa ini, salah satunya adalah mesin penerjemah. Hal ini karena mesin penerjemah populer yang sudah ada belum menyediakan fitur bahasa Banyumasan.

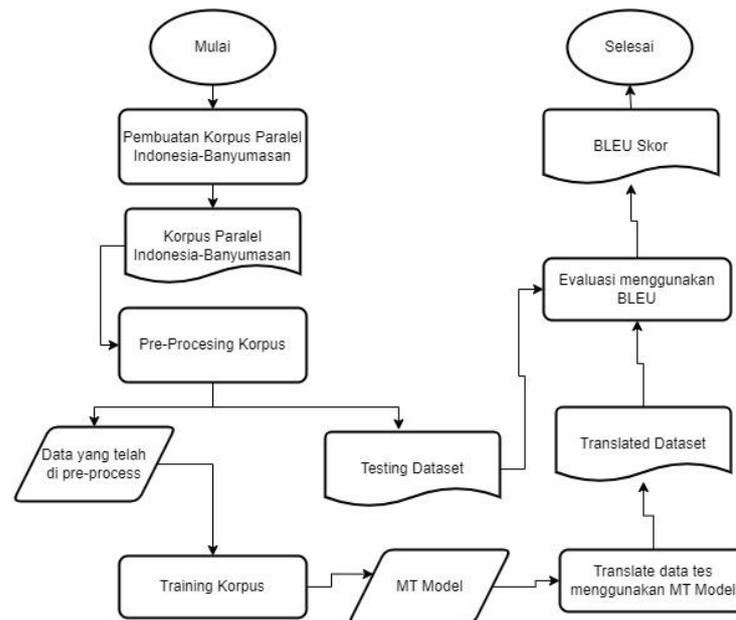
Tujuan penelitian ini adalah membangun mesin penerjemah bahasa Indonesia-bahasa Banyumas dan sebaliknya. Model yang akan digunakan adalah RNN-GRU yang merupakan singkatan dari *Recurrent Neural Network Gated Recurrent Unit*. Model ini telah digunakan untuk membangun mesin penerjemah bahasa Indonesia-bahasa daerah, antara lain bahasa Lampung [5], Ketapang [6] dan Kawi [7]. Sedangkan GRU merupakan *state of the art* dari *inside RNN* yang telah digunakan untuk membangun mesin penerjemah bahasa Indonesia-Sunda [8].

Sebanyak 1.302 pasangan kalimat bahasa Indonesia-Banyumasan digunakan sebagai dataset yang disebut dengan korpus paralel. Kalimat-kalimat yang dipergunakan merupakan kalimat panjang yang rata-rata lebih dari 10 kata setiap kalimat. Aspek yang diukur dalam penelitian ini adalah kualitas hasil terjemahan, waktu training dataset dan waktu penerjemahan untuk beberapa kalimat. Pengukuran kualitas hasil terjemahan menggunakan metode *Bilingual Evaluation Understudy* (BLEU) yang merupakan *state of the art* metrik pengukuran kualitas mesin penerjemah saat ini. Sedangkan untuk pengukuran waktu training dan proses penerjemahan dilakukan menggunakan modul *Timeit* pada pustaka standar bahasa pemrograman Python.

Penelitian tentang mesin penerjemah bahasa Indonesia – bahasa daerah sebelumnya antara bahasa Lampung [9], bahasa Dayak [10], bahasa Sambas [11], bahasa Sunda [8]. Sedangkan penelitian tentang mesin penerjemah bahasa Indonesia-Banyumasan belum pernah dilakukan sebelumnya, hal ini merupakan peluang penelitian dengan menggunakan model yang telah dipergunakan sebelumnya. Kontribusi baru penelitian ini adalah tersedianya korpus paralel bahasa Indonesia-Banyumasan, selain itu juga sebagai referensi tentang penggunaan model RNN-GRU untuk membangun *prototype* mesin penerjemah bahasa Indonesia-Banyumasan yang belum pernah dilakukan sebelumnya.

2. Metode Penelitian

Penelitian dilakukan dengan cara eksperimen yang dimulai dari pengumpulan data berupa korpus paralel bahasa Indonesia-bahasa Banyumasan, selanjutnya adalah melakukan *pre-processing* terhadap korpus untuk selanjutnya dilakukan training menggunakan model RNN-GRU sehingga menghasilkan model terjemahan. Model terjemahan digunakan untuk menerjemahkan kalimat-kalimat bahasa Indonesia ke bahasa Banyumasan. Langkah terakhir adalah melakukan pengujian hasil terjemahan menggunakan model dengan hasil terjemahan yang dilakukan oleh manusia (*human translator*) menggunakan standar pengukuran BLEU. Gambar di bawah ini merupakan skema langkah penelitian.



Gambar 1. Skema langkah penelitian

Penjelasan gambar tersebut adalah.

2.1. Pembuatan korpus paralel

Korpus paralel bahasa Indonesia-bahasa Banyumasan dibuat dengan cara menerjemahkan kalimat-kalimat bahasa Indonesia ke bahasa Banyumasan. Kegiatan penerjemahan ini dilakukan oleh *native speaker* bahasa banyumasan. Korpus paralel berisi 1.203 pasangan kalimat bahasa Indonesia-bahasa Banyumasan.

2.2. Pre-processing

Sebelum dilakukan *training* terhadap dataset menggunakan model, dilakukan *pre-processing* terhadap korpus paralel dengan tujuan proses training menjadi lebih optimal. Langkah *pre-processing* adalah sebagai berikut.

2.2.1. Lowercase

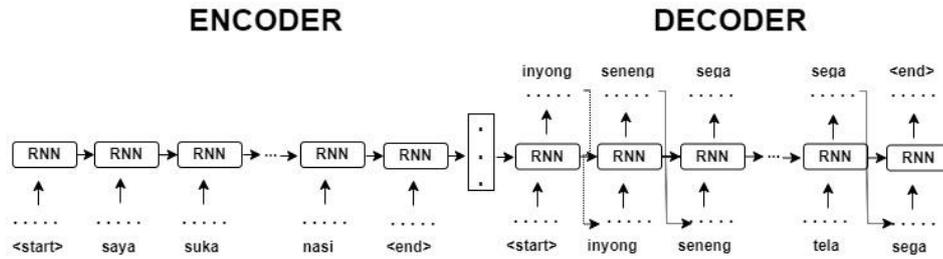
Lowercase mengubah seluruh karakter menjadi huruf non-kapital, hal ini bertujuan untuk memastikan kata yang sama benar-benar sama dan tidak dibedakan dengan huruf [12]. Misalnya kata bagus dan Bagus adalah kata yang sama. *Lowercase* untuk merupakan standar *pre-processing* untuk mesin penerjemah [13] yang berakibat jumlah kata unik semakin sedikit, sehingga dapat mereduksi fitur[14].

2.2.2. Punctuation

Proses ini menghilangkan tanda baca pada semua kalimat [15]. Tujuan menghilangkan tanda baca adalah agar tidak ada kata-kata tambahan yang berisi tanda baca sehingga jumlah kata unik yang merupakan fitur menjadi lebih sedikit [16]. Hal ini akan mengakibatkan proses trainingnya menjadi lebih cepat dan akurat. Sama seperti lowercase, punctuation banyak digunakan sebagai pre-process dalam membangun mesin penerjemah [17] [18] [19].

2.3. Training

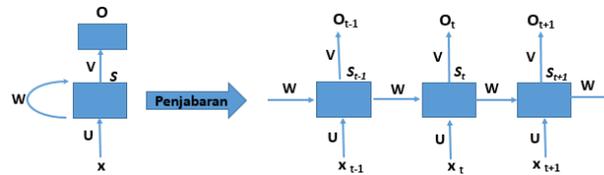
Langkah utama penelitian ini adalah *training dataset*. Dataset yang berupa korpus paralel di *train* menggunakan model RNN-GRU. Model RNN-GRU telah beberapa kali digunakan untuk membangun mesin penerjemah seperti mesin penerjemah bahasa German-Inggris [20], bahasa Prancis, Arab dan China ke bahasa Urdu [21] Bahasa China-Inggris [22] dengan hasil yang bervariasi. Skema model RNN adalah sebagai berikut.



Gambar 2. Skema model RNN Encoder-Decoder [8]

Gambar 2 di atas menjelaskan bahwa model yang digunakan terdiri dari 2 bagian yaitu Encoder dan Decoder. Fungsi Encoder adalah untuk melakukan vektorisasi input, sedangkan Decoder berfungsi untuk memprediksi kata berdasarkan informasi yang diperoleh dari bagian Encoder.

Tiap bagian model RNN yang merupakan model jaringan syaraf tiruan berulang (*recurrent*). Skema RNN dapat digambarkan sebagai berikut.



Gambar 3. Model RNN [23]

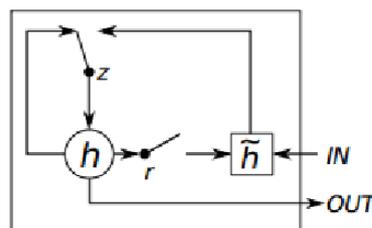
Gambar 3 kanan adalah RNN yang dibuka menjadi *full network* dengan urutan yang lengkap. Misalnya jika *urutan* adalah satu kalimat yang terdiri dari 5 kata, maka *5-layer akan terbuka pada network*, yang mana 1 layer per kata. x_t merupakan *input* pada *time step*. Vektor x_1 adalah representasi one-hot dari kata kedua dalam kalimat yang dianalisis. s_t merupakan *hidden state* untuk tiap-tiap *time step t* yang dapat diperoleh menggunakan persamaan (1). *Hidden state* berfungsi menyimpan hasil perhitungan dan rekaman sehingga disebut sebagai disebut sebagai “*memory*” *network*.

$$s_t = f(Ux_t + Ws_{t-1}) \tag{1}$$

Status terkini (s_t) dihitung dengan menggabungkan status tersembunyi sebelumnya (h_{t-1}) dan masukan saat ini (x_t). Fungsi f merupakan fungsi non-linear seperti \tanh . s_{t-1} dipergunakan untuk menghitung *hidden state* yang pertama, yang mana inisialisasinya selalu diawali 0 (nol). o_t merupakan *output* pada *step t* yang dapat ditemukan pada persamaan (2) berikut.

$$o_t = \text{softmax}(Vs_t) \tag{2}$$

Jika ingin memprediksi “*next word*” suatu kalimat, maka o_t adalah vektor probabilitas di semua kosakata dalam *database* yang dimiliki. Setiap *cell* RNN yang dipergunakan merupakan model GRU. Skema dari model GRU adalah sebagai berikut.



Gambar 4. Model GRU [24]

Ide di balik pendekatan ini adalah untuk menyimpan konten saat ini di setiap langkah dalam jaringan saraf, dan menambahkan konten baru ke dalamnya, sambil melupakan informasi masa lalu yang tidak lagi menambahkan informasi tambahan ke keadaan saat ini. GRU mereset *gate* dan hanya menyimpan konten baru yang relevan ke unit. Setting parameter-parameter training dataset dalam penelitian ini tertera dalam table berikut.

Tabel 1. Setting Parameter

Nomor	Parameter	Nilai
1	Layer Drop Out	0.5
2	GRU Unit	1024
3	Activation Function	Softmax
4	Loss Function	Sparse categorical crossentropy
5	Validation Percentage	15
6	Epoch	10.000
7	Batch Size	64
8	Optimizer	RMSprop

Penggunaan jumlah unit GRU dan Epoch besar diharapkan dapat menghasilkan model yang maksimal karena jumlah dataset yang kecil.

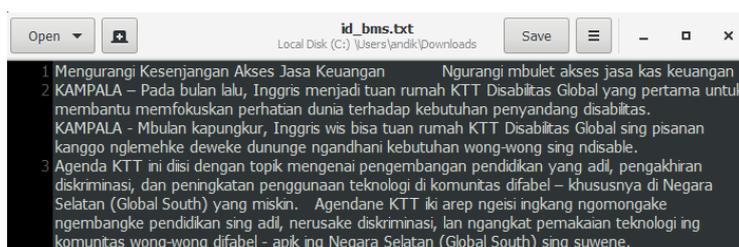
2.4. Pengujian

Pengujian bertujuan untuk menguji kualitas hasil terjemahan mesin. Pengujian dilakukan dengan cara membandingkan terjemahan menggunakan model mesin penerjemah dengan terjemahan yang dilakukan manusia (*Human translator*). Standar pengujian menggunakan standar BLEU yang merupakan salah satu standar pengujian untuk hasil terjemahan [25][26]. Selain kualitas terjemahan, pengujian juga dilakukan dengan melihat akurasi dan validasi pada saat training dataset untuk melihat jumlah epoch optimal, yaitu jumlah epoch ketika nilai akurasi dan validasi mencapai maksimal. Selain itu juga untuk melihat pada jumlah epoch ke berapa nilai akurasi dan validasi mulai menurun. Hasil pengujian ini akan disajikan dalam bentuk grafik.

3. Hasil dan Pembahasan

3.1. Deskripsi Dataset

Dataset yang dipergunakan adalah berbentuk korpus paralel, yaitu pasangan bahasa Indonesia dan bahasa Banyumasan yang mana rata-rata tiap kalimat bahasa Indonesia mengandung 21 kata. Tiap kalimat bahasa Indonesia dipasangkan dengan kalimat bahasa Banyumasan dengan tanda pemisah berupa Tab. Artefak korpus paralel dapat dilihat pada gambar berikut.

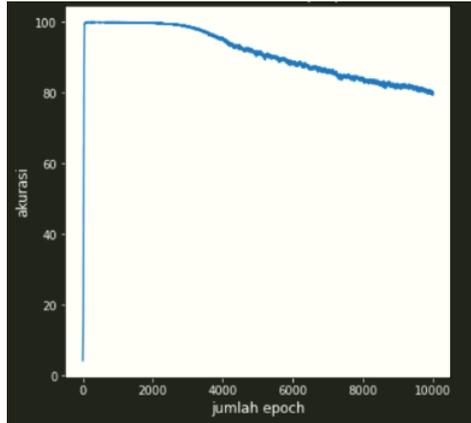


Gambar 5. Artefak korpus paralel

Tampilan isi korpus paralel bahasa Indonesia-Banyumasan seperti yang terlihat pada gambar 5 bahwa tiap baris merupakan pasangan kalimat bahasa Indonesia di bagian kiri dan bahasa Banyumasan di bagian kanan yang dipisahkan dengan karakter “tab”. Korpus paralel tersebut berisi 1.302 pasangan kalimat bahasa Indonesia bahasa Banyumasan dengan rata-rata panjang kalimat bahasa Indonesia adalah 20 kata.

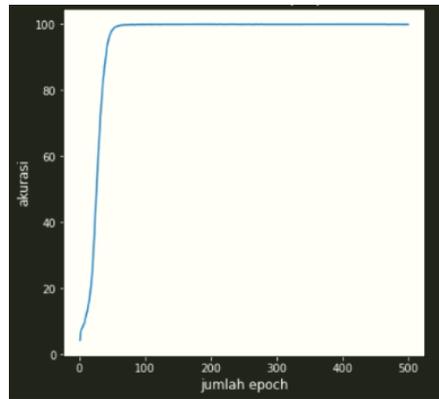
3.2. Training Dataset

Training korpus paralel menggunakan perangkat hardware dengan spesifikasi prosesor intel core 15 gen 11, RAM 16 GB, SSD 500 GB. *Software* sistem operasi adalah Linux Ubuntu 22, bahasa pemrograman Python 3. Waktu training dataset adalah 3 hari atau sekitar 72 jam tanpa menggunakan GPU (*Graphich Processing Unit*). Grafik di bawah ini menggambarkan tingkat akurasi pada setiap epoch.



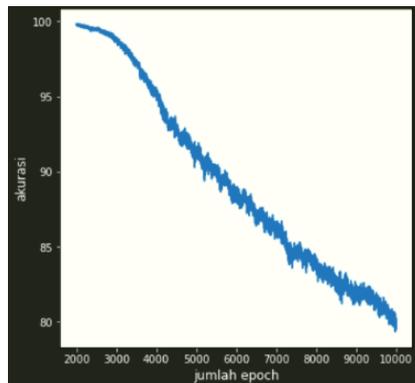
Gambar 6. Grafik Akurasi pada training dataset

Gambar 6 di atas menjelaskan bahwa akurasi training dapat mencapai maksimal ketika epoch mencapai kurang dari 2000, dan menurun ketika epoch antara 2000 sampai 4000. Grafik di bawah ini menggambarkan secara lebih detail titik kenaikan akurasi.



Gambar 7. Grafik kenaikan akurasi pada training dataset

Gambar 7 merupakan *plotting* dengan jumlah *epoch* yang lebih sedikit untuk memperjelas batas-batas titik kenaikan dan titik puncak akurasi. Gambar 7 di atas menunjukkan akurasi training mencapai maksimum ketika jumlah epoch sekitar 80 epoch. Grafik di bawah ini menggambarkan penurunan akurasi.



Gambar 8. Grafik penurunan akurasi pada training dataset

Gambar 8 di atas menunjukkan mulai terjadi penurunan akurasi training data dimulai ketika epoch mencapai 2000 epoch. Sedangkan contoh hasil terjemahan menggunakan model RNN-GRU tampak pada gambar 9 berikut.

```
print(decode_sequence('Mengurangi Kesenjangan Akses Jasa Keuangan'))
1/1 [=====] - 2s 2s/step
1/1 [=====] - 0s 39ms/step
1/1 [=====] - 0s 39ms/step
1/1 [=====] - 0s 39ms/step
1/1 [=====] - 0s 40ms/step
1/1 [=====] - 0s 40ms/step
1/1 [=====] - 0s 41ms/step
[start] ngurangi mbulet akses jasa kas keuangan [end]
```

Gambar 9. Contoh hasil terjemahan

Gambar 9 di atas menunjukkan proses penerjemahan kalimat menggunakan model RNN-GRU yang telah terbentuk dalam proses training data. Terlihat pada gambar 9 tersebut bahwa terdapat 5 kata, prosesnya menjadi 7 bagian karena ditambahkan <start> di awal dan <end> di akhir.

3.3. Evaluasi menggunakan BLEU

Tahap terakhir adalah melakukan evaluasi menggunakan BLEU. Tampilan skor BLEU dalam bentuk file adalah seperti pada gambar 10 berikut.

```
BLEU+case.mixed+numrefs.1+smooth.exp+tok.
13a+version.1.4.14 = 34.1 53.8/43.4/41.2/39.4
(BP = 0.773 ratio = 0.795 hyp_len = 1204
ref_len = 1514)
```

Gambar 10. Artifak evaluasi BLEU

Penjelasan gambar di atas tertera pada tabel berikut.

Tabel 2. Hasil Evaluasi terjemahan

Nomor	Skor	Evaluasi
1	34.1	BLEU
2	53.8	Unigram
3	43.4	Bigram
4	41.2	Trigram
5	39.4	4-gram
6	1.204	Jumlah kata Hipotesis
7	1.514	Jumlah kata Referensi

Tabel 2 di atas menunjukkan skor BLEU adalah skor 34.1, artinya dapat digunakan sebagai alat terjemahan, tetapi masih dapat ditingkatkan.

4. Kesimpulan

Berdasarkan eksperimen yang telah dilakukan dan analisis terhadap hasil eksperimen yang telah dijelaskan di atas, maka dapat disimpulkan sebagai berikut.

- Model RNN-GRU dapat dipergunakan untuk membangun *prototype* mesin penerjemah bahasa Indonesia-bahasa Banyumasan.
- Proses dimulai dari membuat korpus paralel, *pre-processing* (*lowercase* dan *punctuation*), *training* dataset menggunakan model RNN-GRU dan evaluasi menggunakan BLEU.
- Jumlah epoch yang banyak tidak meningkatkan akurasi saat training, hal ini terlihat akurasi maksimal pada saat epoch 250 dan setelah itu terjadi fluktuasi akurasi dan terus menurun saat epoch mencapai 10.000.
- Kualitas hasil terjemahan setelah dilakukan evaluasi menggunakan metrik BLEU menunjukkan skor 34.1, yang mana skor BLEU yang baik adalah 30 sampai 60. hal ini menunjukkan bahwa kualitasnya terjemahan termasuk baik dan masih berpeluang untuk dapat ditingkatkan.

5. Acknowledgement

Penelitian ini didanani oleh Universitas Amikom Purwokerto melalui skema program pendanaan Penelitian Dosen Muda Amikom (PDMA) Universitas Amikom Purwokerto Tahun Anggaran 2023.

Daftar Pustaka

- [1] Badan Pengembangan Bahasa dan Perbukuan Kemdikbud, “Peta Bahasa,” *Petabahasa.Kemdikbud.Go.Id*, 2019. <https://petabahasa.kemdikbud.go.id/>.
- [2] A. A. Suryani, I. Arieshanti, B. W. Yohanes, M. Subair, S. D. Budiwati, and B. S. Rintyarna, “Enriching English into Sundanese and Javanese translation list using pivot language,” in *2016 International Conference on Information & Communication Technology and Systems (ICTS)*, 2016, pp. 167–171, doi: 10.1109/ICTS.2016.7910293.
- [3] E. Nurdiyanto, G. A. Resticka, and S. N. H. Yanti, “KONSERVASI BAHASA JAWA BANYUMAS: SEBUAH TANTANGAN, STRATEGI DAN PELUANG MASYARAKAT BANYUMAS YANG MULTILINGUALISM,” in *Prosiding Seminar Nasional dan Call for Papers ”Pengembangan Sumber Daya Perdesaan dan Kearifan Lokal Berkelanjutan XI”*, 2021, pp. 369–374.
- [4] Ananda Galuh Pawestri, “Membangun Identitas Budaya Banyumasan melalui Dialek Ngapak di Media Sosial,” *J. Pendidik. Bhs. dan Sastra*, vol. 19, no. 2, pp. 245–254, 2020, doi: 10.17509/bs_jpbsp.v19i2.24790.
- [5] Z. Abidin, “Penerapan Neural Machine Translation untuk Eksperimen Penerjemahan secara Otomatis pada Bahasa Lampung – Indonesia,” *Pros. Semin. Nas. Metod. Kuantitatif 2017*, no. 978, pp. 53–68, 2017.
- [6] W. Gunawan, H. Sujaini, and T. Tursina, “Analisis Perbandingan Nilai Akurasi Mekanisme Attention Bahdanau dan Luong pada Neural Machine Translation Bahasa Indonesia ke Bahasa Melayu Ketapang dengan Arsitektur Recurrent Neural Network,” *J. Edukasi dan Penelit. Inform.*, vol. 7, no. 3, p. 488, 2021, doi: 10.26418/jp.v7i3.50287.
- [7] I. G. B. A. Budaya, M. W. A. Kesiman, and I. M. G. Sunarya, “Perancangan Mesin Translasi berbasis Neural dari Bahasa Kawi ke dalam Bahasa Indonesia menggunakan Microframework Flask,” *J. Sist. dan Inform.*, vol. 16, no. 2, pp. 94–103, 2022.
- [8] Y. Fauziyah, R. Ilyas, and F. Kasyidi, “Mesin Penerjemah Bahasa Indonesia-Bahasa Sunda Menggunakan Recurrent Neural Networks,” *J. Teknoinfo*, vol. 16, no. 2, p. 313, 2022, doi: 10.33365/jti.v16i2.1930.
- [9] Z. Abidin, “Translation of Sentence Lampung-Indonesian Languages with Neural Machine Translation Attention Based Approach,” *Inov. Pembang. J. Kelitbangan*, vol. 6, no. 02, pp. 191–206, 2018, doi: 10.35450/jip.v6i02.97.
- [10] H. Sujaini, “Meningkatkan Peran Model Bahasa dalam Mesin Penerjemah Statistik (Studi Kasus Bahasa Indonesia-Dayak Kanayatn),” *Khazanah Inform. J. Ilmu Komput. dan Inform.*, vol. 3, no. 2, pp. 51–56, 2017, doi: 10.23917/khif.v3i2.4398.
- [11] I. Hadi, “Uji Akurasi Mesin Penerjemah Statistik (MPS) Bahasa Indonesia Ke Bahasa Melayu Sambas Dan Mesin Penerjemah Statistik (MPS) Bahasa Melayu Sambas Ke Bahasa Indonesia,” *J. Sist. dan Teknol. Inf.*, vol. 2, pp. 1–6, 2014.
- [12] Z. Thihlum, V. Khenglawt, and S. Debnath, “Machine Translation of English Language to Mizo Language,” in *2020 IEEE International Conference on Cloud Computing in Emerging Markets (CEEM)*, 2020, pp. 92–97, doi: 10.1109/CEEM50674.2020.00028.
- [13] B. N. V. Narasimha Raju, M. S. V. S. Bhadri Raju, and K. V. V. Satyanarayana, “Effective preprocessing based neural machine translation for english to telugu cross-language information retrieval,” *IAES Int. J. Artif. Intell.*, vol. 10, no. 2, pp. 306–315, 2021, doi: 10.11591/ijai.v10.i2.pp306-315.
- [14] K. Dedes *et al.*, “Neural Machine Translation of Spanish-English Food Recipes Using LSTM,” *Int. J. Informatics Vis.*, vol. 6, no. June, pp. 290–297, 2022, [Online]. Available: www.joiv.org/index.php/joiv.
- [15] C. Bei, H. Zong, C. Yuan, Q. Liu, and B. Fan, “GTCOM neural machine translation systems for WMT19,” *WMT 2019 - 4th Conf. Mach. Transl. Proc. Conf.*, vol. 2, no. Day 1, pp. 116–121, 2019, doi: 10.18653/v1/w19-5305.
- [16] T. van der Werff, R. van Noord, and A. Toral, “Automatic Discrimination of Human and Neural Machine Translation: A Study with Multiple Pre-Trained Models and Longer Context,” *EAMT 2022 - Proc. 23rd Annu. Conf. Eur. Assoc. Mach. Transl.*, no. Lm, pp. 161–170, 2022.
- [17] A. Roy, A. C. Dhar, M. A. H. Akhand, and M. A. S. Kamal, “Bangla-English Neural Machine Translation with Bidirectional Long Short-Term Memory and Back Translation,” *Int. J. Comput. Vis. Signal Process.*, vol. 11, no. 1, pp. 25–31, 2021, [Online]. Available: <http://cennser.org/IJCVSP>.
- [18] R. Prajapati, V. Parikh, and P. Majumder, “IRLAB-DAIICT@DravidianLangTech-EACL2021:

- Neural Machine Translation,” in *Proceedings of the 1st Workshop on Speech and Language Technologies for Dravidian Languages, DravidianLangTech 2021 at 16th Conference of the European Chapter of the Association for Computational Linguistics, EACL 2021*, 2021, pp. 262–265.
- [19] D. Rose, K. Vijayakumar, D. Kirubakaran, R. Pugalenti, and G. Balayaswantasaichowdary, “Neural Machine Translation Using Attention,” in *2023 International Conference on Artificial Intelligence and Knowledge Discovery in Concurrent Engineering (ICECONF)*, 2023, pp. 1–7, doi: 10.1109/ICECONF57129.2023.10083569.
- [20] L. Corallo, G. Li, K. Reagan, A. Saxena, A. S. Varde, and B. Wilde, “A Framework for German-English Machine Translation with GRU RNN,” in *CEUR Workshop Proceedings*, 2022, vol. 3135.
- [21] A. Khan and A. Sarfaraz, “RNN-LSTM-GRU based language transformation,” *Soft Comput.*, vol. 23, no. 24, pp. 13007–13024, 2019, doi: 10.1007/s00500-019-04281-z.
- [22] B. Zhang, D. Xiong, J. Xie, and J. Su, “Neural Machine Translation With GRU-Gated Attention Model,” *IEEE Trans. Neural Networks Learn. Syst.*, vol. 31, no. 11, pp. 4688–4698, 2020, doi: 10.1109/TNNLS.2019.2957276.
- [23] H. Lee and J. Song, “Understanding recurrent neural network for texts using English-Korean corpora,” *Commun. Stat. Appl. Methods*, vol. 27, no. 3, pp. 313–326, 2020.
- [24] R. Wang, M. Panju, and Mahmood Gohari, “Classification-based RNN machine translation using GRUs,” *ArXiv*, vol. 1, no. 1, pp. 1–7, 2017.
- [25] Y. Graham and B. Haddow, “Statistical Power and Translationese in Machine Translation Evaluation,” in *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. Association for Computational Linguistics*, 2020, pp. 72–81.
- [26] S. Lee *et al.*, “A Survey on Evaluation Metrics for Machine Translation,” *Mathematics*, vol. 11, pp. 1–22, 2023.