

# Perancangan Mesin Translasi berbasis *Neural* dari Bahasa Kawi ke dalam Bahasa Indonesia menggunakan *Microframework Flask*

I Gede Bintang Arya Budaya<sup>1</sup>, Made Windu Antara Kesiman<sup>2</sup>, I Made Gede Sunarya<sup>3</sup>

Universitas Pendidikan Ganesha

e-mail: <sup>1</sup>bintang.arya@undiksha.ac.id, <sup>2</sup>antara.kesiman@undiksha.ac.id, <sup>3</sup>sunarya@undiksha.ac.id

Diajukan: 19 Januari 2022; Direvisi: 20 Januari 2022; Diterima: 4 April 2022

## Abstrak

Mesin Translasi (MT) adalah pilihan utama bagi orang-orang, terutama untuk mempelajari pengetahuan yang tidak menggunakan bahasa asli mereka. Bahasa Kawi sebagai bahasa lokal, meskipun jarang digunakan secara aktif, merupakan bahasa yang banyak digunakan dalam berbagai literatur lama seperti lontar, khususnya di Bali yang masih dipelajari hingga saat ini. Banyak MT dengan pengguna aktif, seperti bahasa Indonesia yang terus dikembangkan tetapi tidak untuk bahasa Kawi. Perancangan MT berbasis neural menggunakan microframework Flask merupakan langkah awal pengembangan MT dari bahasa Kawi ke Bahasa Indonesia. Pengembangan dimulai dengan membuat korpus paralel Kawi ke Indonesia dan dilanjutkan dengan membuat arsitektur MT dengan model berbasis Recurrent Neural Network (RNN) yaitu simple RNN dan bidirectional RNN. Berdasarkan hasil pengujian, kedua model ini mampu mencapai skor BLEU sebesar 20.43 untuk simple RNN dan 17.6 untuk bidirectional RNN. Model MT yang diajukan masih belum mampu mencapai level standar seperti ahli manusia dan high resources MT yaitu berdasar Google dengan skor BLEU minimal 60. MT untuk bahasa Kawi ke bahasa Indonesia dapat dikembangkan kedepan dengan pemanfaatan microframework Flask, yang dapat membantu proses pengembangan lebih cepat.

**Kata kunci:** Mesin Translasi, RNN, Korpus Paralel Kawi-Indonesia, Skor BLEU, Flask.

## Abstract

Machine translation (MT) is the primary choice for people, especially learning the knowledge that does not use their native language. Kawi language as a local language, although rarely used actively, is a language that is widely used in various old literature such as lontar, especially in Bali, which is still being studied today. Many MT with active users, such as the Indonesian language, are developed but not Kawi language. Designing a neural-based MT using the Flask microframework was the first step in developing MT from Kawi to Indonesian. The development began with creating a Kawi to Indonesian parallel corpus and then develop the architecture with a Recurrent Neural Network (RNN) based model, namely simple RNN and bidirectional RNN. Based on the test results, these two models have achieved average BLEU scores of 20.43 for simple RNN and 17.6 for bidirectional RNN. The proposed MT model stills could not achieve the standard translation quality equal to those of human experts and high resources MT based on Google with BLEU scores equal to a minimal 60 points. MT for Kawi language to Indonesian can be developed in the future coupled with the Flask microframework, which can help the development process faster.

**Keywords:** Machine Translation, RNN, Kawi-Indonesia Parallel Corpora, BLEU Scores, Flask.

## 1. Pendahuluan

Mesin Translasi (MT) telah menjadi pilihan utama bagi orang-orang untuk memahami pengetahuan di luar bahasa asli mereka, khususnya dalam hal pembelajaran. Studi [1] menunjukkan bagaimana mesin translasi seperti *google translate* mampu membantu para pelajar untuk belajar bahasa asing dengan lebih efisien. Bahasa Kawi merupakan bahasa yang banyak digunakan dalam literatur kuno seperti naskah lontar, khususnya yang ada di provinsi Bali. Naskah lontar sendiri berisi berbagai pengetahuan dasar terkait agama, pengobatan (*usada*), dan catatan – catatan penting tentang peradaban di masa lalu [2]. Saat ini pembelajaran terhadap naskah lontar masih dilakukan oleh beberapa kelompok

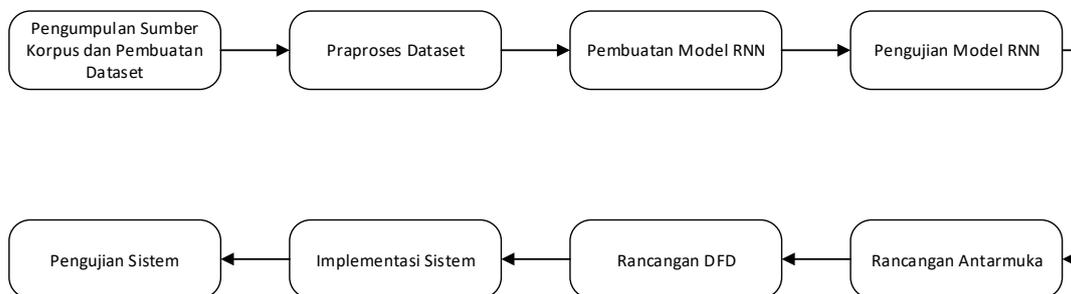
masyarakat sebagai pemenuhan tradisi maupun pembelajaran dan pengembangan kesusastraan yang dalam prosesnya didukung oleh para akademisi, komunitas lokal dan pemerintah [3]. Pembelajaran terhadap naskah lontar ini memiliki tantangan tersendiri. Salah satu tantangan adalah proses pemahaman konteks melalui alih bahasa, dimana dari bahasa Kawi yang ada pada naskah lontar ke dalam bahasa yang lebih umum digunakan, seperti bahasa Indonesia. Pengembangan model MT dari bahasa Kawi ke dalam bahasa Indonesia dapat menjadi langkah awal dalam proses meningkatkan kemudahan akses belajar khususnya bagi pemula yang tertarik dengan naskah- naskah (*lontar*) berbahasa Kawi.

Beberapa penelitian telah dilaksanakan dalam pengembangan model MT, yaitu MT berbasis aturan (*rule based*) [4], MT berbasis statistik [5], [6] dan MT berbasis jaringan syaraf (*neural network*) [7], [8]. Penelitian [9], [10] membandingkan performa dari MT berbasis statistik dan MT berbasis *neural* dimana MT berbasis *neural*, khususnya dengan menggunakan *recurrent neural network* (RNN) memiliki performa dan akurasi yang lebih baik dari pada MT berbasis statistik. Penelitian [11] melaporkan hasil penelitian terkait MT berbasis RNN yang diimplementasikan untuk bahasa yang memiliki sedikit sumber dan pengguna aktif (*low resource language*) dimana hasilnya lebih baik ketimbang MT berbasis statistik. Berdasarkan penelitian – penelitian tersebut diketahui bahwa MT berbasis RNN menghasilkan hasil terbaik, dan dapat diimplementasikan untuk pengembangan MT dari bahasa Kawi yang juga bersifat *low resource* ke dalam bahasa Indonesia.

Tujuan dari penelitian ini adalah untuk merancang model MT berbasis RNN yaitu *Simple RNN* dan *Bidirectional RNN* untuk proses alih bahasa dari bahasa Kawi ke dalam bahasa Indonesia dengan *microframework flask*. Saat ini masih sedikit penelitian yang mengembangkan model MT dari bahasa lokal khususnya Kawi ke dalam bahasa Indonesia. Dalam penelitian ini juga menghasilkan dataset korpus paralel Kawi – Indonesia yang digunakan dalam kasus perancangan MT berbasis neural dengan *microframework flask*.

## 2. Metode Penelitian

Alur penelitian dalam perancangan model MT berbasis RNN dari bahasa Kawi ke dalam bahasa Indonesia dengan *microframework flask* terlihat seperti pada **Error! Reference source not found.**



Gambar 1. Metode Penelitian

### 2.1. Pengumpulan Sumber Korpus dan Pembuatan Dataset

Berdasarkan hasil survei dan pengumpulan informasi yang dilaksanakan terdapat para ahli yang telah mempublikasikan hasil transliterasi dan translasi dari dokumen berbahasa Kawi ke Bahasa Indonesia. Namun masih belum dalam format yang dibutuhkan untuk mengembangkan model mesin translasi berbasis *neural*.

Tabel 1 dan Gambar 2 menampilkan informasi sumber korpus yang digunakan untuk dataset.

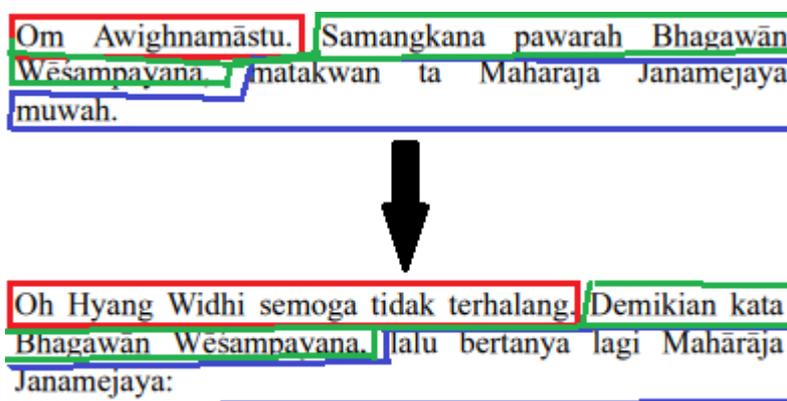
Tabel 1. Sumber Korpus

Korpus	Judul	Ahli atau Akademisi
1	<i>Musala Parwa</i>	Dr. Anak Agung Gde Alit Geria, M.Si.
2	<i>Phalawya Kapi Parwa</i>	Drs Komang Paramartha, M.S.
3	<i>Singhalangghyala Parwa</i>	Anak Agung Gde Alit Geria & I Gde Agus Darma Putra



Gambar 2. Sampul Buku Sumber Korpus

Proses selanjutnya adalah mengubah sumber korpus menjadi *dataset* dengan format yang sesuai. Model *dataset* yang digunakan untuk mesin translasi adalah *sequence to sequence* dimana kalimat merupakan sebuah susunan kata-kata, dari bahasa sumber ke bahasa target [12], [13]. Dalam pembuatan *dataset*, setiap kumpulan kata dalam bahasa Kawi ditentukan korepondensi artinya dalam bahasa Indonesia lalu dimasukkan ke dalam *Microsoft excel* dan disimpan dengan format “.xlsx”. Gambar 3 menampilkan proses pembuatan *dataset*.



Gambar 3. Contoh Proses Pemisahan Kalimat dalam Bahasa Kawi dan dipasangkan dengan Hasil Alih Bahasa dalam Bahasa Indonesia untuk *Dataset*

Dalam dokumen *excel* terdiri dari kolom *id*, *target language*, *source language*, *corpus title*, dan *expert name*. Setelah proses konversi sumber korpus menjadi *dataset* dihasilkan *dataset* Kawi- Indonesia paralel korpus sebanyak 1086 baris kalimat. Tabel 2 menampilkan struktur jumlah *dataset* dan Tabel 3 menampilkan sampel dari *dataset* yang sudah siap diolah.

Tabel 2. Jumlah *Dataset*

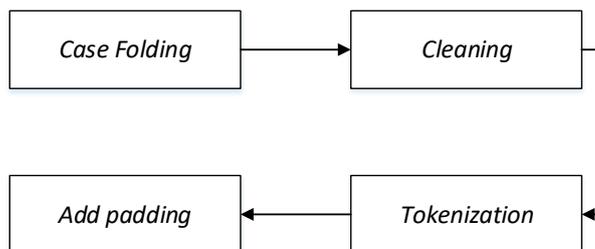
Korpus	Judul	Jumlah Kalimat
1	<i>Musala Parwa</i>	465
2	<i>Phalawky Kapi Parwa</i>	555
3	<i>Singhalangghyala Parwa</i>	66
<b>Total</b>		<b>1086</b>

Tabel 3. Sampel *Dataset* dalam Dokumen Excel

ID	Target Language	Source Language	Corpus Title	Experts
1	<i>Oh Hyang Widhi semoga tidak terhalang.</i>	<i>Om Awighnamāstu.</i>	<i>Musala Parwa</i>	Dr. Anak Agung Gde Alit Geria, M.Si.
2	<i>Demikian kata Wēsampayana,</i>	<i>Samangkana pawarah Bhagawān Wēsampayana,</i>	<i>Musala Parwa</i>	Dr. Anak Agung Gde Alit Geria, M.Si.
3	<i>lalu bertanya lagi Mahārāja Janamejaya:</i>	<i>matakwan ta Mahārāja Janamejaya muwah.</i>	<i>Musala Parwa</i>	Dr. Anak Agung Gde Alit Geria, M.Si.

## 2.2. Praproses Dataset

Pada tahap ini, *dataset* diolah sebelum digunakan untuk melatih model dengan tujuan akhir untuk mengubah dari urutan data teks menjadi urutan (*sequences*) data integer. Adapun langkah-langkah dalam proses ini seperti yang terlihat pada Gambar 4. *Case folding* adalah proses mengubah setiap huruf pada *dataset* menjadi huruf kecil, hal ini bertujuan untuk memudahkan mesin mendeteksi mana kata yang sama. Selanjutnya proses *cleaning* yaitu membersihkan tanda baca dan mengganti huruf latin menjadi ASCII dari *extended ASCII*. *Tokenization* adalah proses perubahan kamus kata dengan representasi integer agar dapat dipelajari oleh mesin, lalu penambahan *padding* bertujuan untuk menyamakan panjang dari *sequence* kalimat baik di bahasa Kawi dan Bahasa Indonesia. Ditemukan bahwa jumlah *sequence* kata terpanjang dalam kalimat bahasa Kawi adalah 15 dan pada kalimat bahasa Indonesia adalah 21.



Gambar 4. Tahapan Praproses Dataset

## 2.3. Pembuatan Model RNN

Model RNN yang dibuat berdasarkan arsitektur dasar pada penelitian [8] dengan menggunakan RNN dan *Bidirectional RNN*.

## 2.4. Pengujian Model RNN

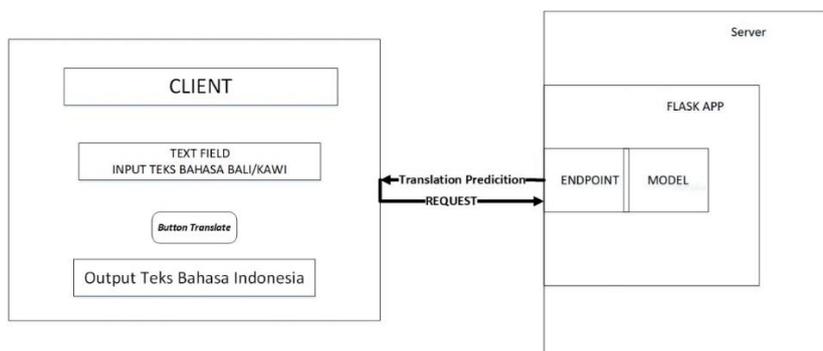
Sitem evaluasi otomatis yang dapat digunakan untuk tranlasi adalah BLEU (*Bilingual Evaluation Understudy*) [11], [14]. BLEU adalah sebuah algoritma yang berfungsi untuk mengevaluasi kualitas dari sebuah hasil terjemahan yang telah diterjemahkan oleh mesin dari satu bahasa alami ke bahasa lain. BLEU mengukur *modified n-gram precision score* antara hasil terjemahan otomatis dengan tejemahan rujukan dan menggunakan konstanta yang dinamakan *brevity penalty*. Nilai BLEU didapat dari hasil perkalian antara *brevity penalty* dengan rata-rata geometri dari *modified precision score*.

$$BLEU = BP \cdot \exp\left(\sum_{n=1}^N w \log p\right) \tag{1}$$

Dimana *BP* = *brevity penalty* dari mesin tranlasi, *w* = *weight* antara 0-1, *p* adalah modifikasi presisi dari *ngrams*, *base log* = *narutal base e*.

## 2.5. Pembuatan Antar Muka

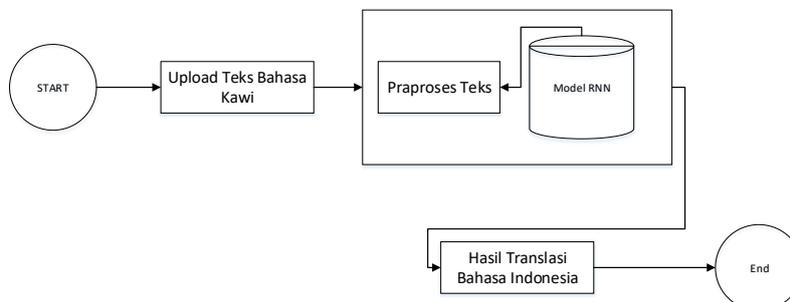
Adapun rancangan antar muka yang dikembangkan terlihat seperti pada untuk Gambar 5 bagian *client*. Terdapat *text field* untuk input teks bahasa Kawi, dan *output* hasil tranlasi dalam bahasa Indonesia. Tombol “*translate*” untuk memulai proses tranlasi.



Gambar 5. Rancangan Sistem Mesin Tranlasi berbasis *Neural*

## 2.6. Rancangan DFD

*Data Flow Diagram* (DFD) adalah sebuah teknik grafis yang menggambarkan aliran informasi dan transformasi yang diaplikasikan pada saat data bergerak dari masukan menjadi keluaran sehingga digunakan untuk membangun dan mengimplementasikan aplikasi sistem [15]. DFD dalam rancangan sistem mesin translasi berbasis *neural* ini terlihat seperti pada Gambar 6.



Gambar 6. Rancangan DFD Mesin Translasi berbasis *Neural*

## 2.7. Implementasi Sistem

Dalam proses implementasi sistem dilakukan dengan cara membuat kode dengan menggunakan *microframework flask* yang di dalamnya terdiri dari *file* HTML, CSS, dan *Python*. Model yang digunakan adalah model berbasis *neural* yaitu RNN.

## 2.8. Pengujian Sistem

Pengujian sistem menggunakan *black box testing* dengan mencoba program yang telah dibuat dan dengan memasukkan data untuk mengetahui apakah fungsi yang dirancang dapat berjalan [16]. Proses pengujian selanjutnya adalah dengan menggunakan kalimat di luar data latih untuk pengujian pada sistem.

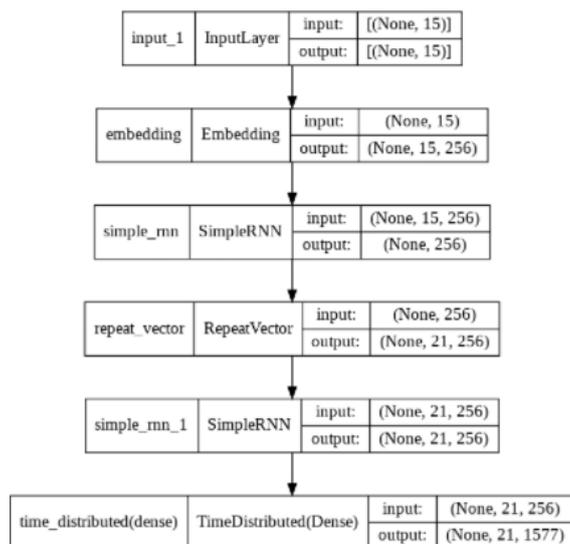
## 3. Hasil dan Pembahasan

Dalam pengembangan model MT ini beberapa nilai dari *hyperparameter* telah ditentukan seperti yang terlihat pada Tabel 4.

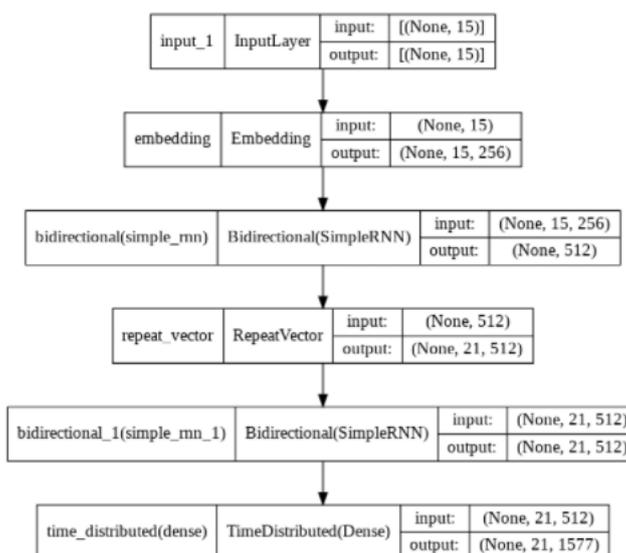
Tabel 4. Pengaturan *Hyperparamter* dan Pembagian *Dataset*

No.	Pengaturan	Nilai atau Jenis
1	<i>Batch Size</i>	128
2	<i>Dimensionality</i>	256
3	<i>Optimizer</i>	Adam
4	<i>Learning Rate</i>	0.001
5	<i>Epoch</i>	200
6	<i>Train : Test</i>	80% : 20%

Arsitektur berbasis RNN yang digunakan adalah *Simple RNN* dan *Bidirectional RNN* dengan menggunakan *library Tensorflow Keras*. Gambar 7 dan Gambar 8 memperlihatkan bagaimana arsitektur yang digunakan untuk model RNN.



Gambar 7. Arsitektur MT RNN



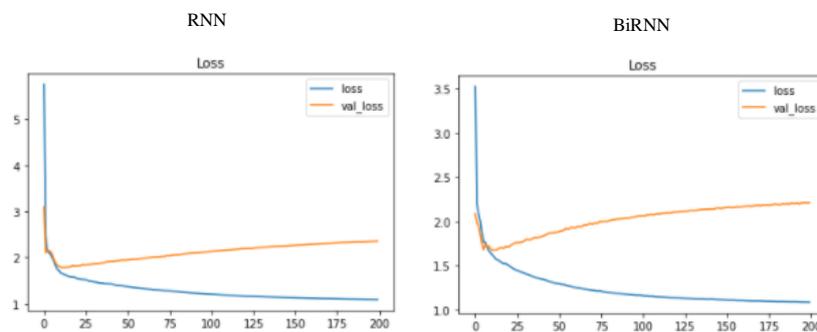
Gambar 8. Arsitektur MT Bidirectional RNN

Layer input membawa informasi fitur hasil tokenisasi teks bahasa kawi dari dataset. Embedding layer adalah layer yang digunakan untuk mengubah input diskrit menjadi vektor kontinu, dalam hal ini embedding layer menggunakan weight dari word vector yang dibuat dari dataset bahasa Kawi dengan Word2Vec [17]. RNN layer dan Bidirectional RNN layer adalah model neural yang dipilih untuk mengatasi model sequence to sequence [12] sebagai encoder dan decoder. Repeat vector adalah layer yang menghubungkan encoder layer dan decoder layer. Terakhir adalah Time Distributed yang berfungsi untuk membuat vektor dengan panjang yang sama sesuai fitur pada lapisan sebelumnya.

### 3.1. Komparasi Model dan BLEU Scores Model RNN

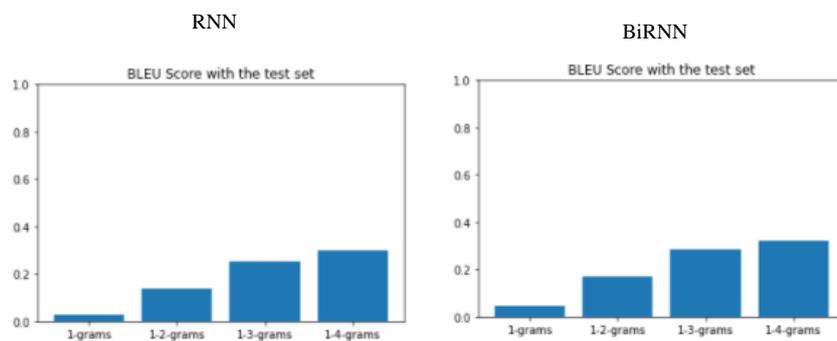
Model selanjutnya di training sesuai dengan pengaturan yang telah ditentukan pada Tabel 4. Setelah dilakukan proses training dihasilkan hasil seperti yang terlihat pada Gambar 9. Pada model RNN terlihat bahwa nilai validation loss terendah terjadi pada epoch ke 12, setelah epoch ke 12 nilai validation loss perlahan-lahan mulai naik kembali hingga epoch ke 200. Pada model Bidirectional RNN terlihat bahwa nilai validation loss juga terendah terjadi pada epoch ke 12, setelah epoch ke 12 nilai validation loss perlahan-lahan mulai naik kembali hingga epoch ke 200. Melihat trend tersebut dapat disimpulkan bahwa kedua model masih overfitting. Overfitting adalah kondisi ketika performa model terlihat bagus pada data latih sedangkan ketika menggunakan data uji mengalami penurunan yang signifikan [18]. Namun jika

dibandingkan, model RNN menunjukkan performa yang lebih (nilai *validation loss* mendekati 2) baik ketimbang model *Bidirectional RNN*, terlihat dari nilai *validation loss Bidirectional RNN* yang lebih tinggi hingga *epoch* ke 200 (nilai *validation loss* lebih dari 2 menuju 2.5).



Gambar 9. Tren *Training Loss* dan *Validation Loss*

Setelah model MT RNN dilatih lalu diuji dengan menghitung *BLEU Scores*. *BLEU Scores* dari kedua model dapat dilihat seperti pada Gambar 10 dan informasi lebih detail terdapat pada Tabel 5.



Gambar 10. *BLEU Scores* Model

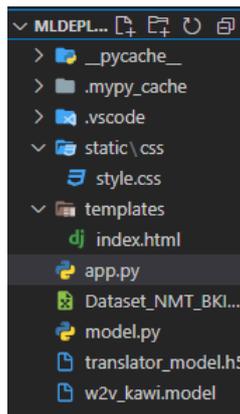
Tabel 5. Detail *BLEU score* dari Model

Model	BLEU Scores				
	1-Grams	2-Grams	3-Grams	4-Grams	BLEU
RNN	4.61	16.82	28.21	32.10	20.43
BiRNN	2.87	13.61	25.34	29.60	17.6

Berdasarkan hasil dari *BLEU scores* tersebut, model RNN memiliki nilai yang berada pada kisaran 4,6% pada 1-grams dan bertambah sesuai penambahan *n-grams* hingga 4-grams diangka 32,1% dengan rata-rata BLEU sebesar 20,43. Model *bidirectional RNN* memiliki nilai yang berada pada kisaran 2,8% pada 1-grams dan bertambah sesuai penambahan *n-grams* hingga 4-grams diangka 29,6% dengan rata-rata BLEU sebesar 17,6%. Model RNN memiliki performa yang lebih baik dari pada *bidirectional RNN* dengan selisih nilai pada rata-rata BLEU sebesar 2,83%. Namun kedua model memang belum mampu mencapai *BLEU scores* yang mampu diraih oleh translator manusia maupun mesin seperti *google translate* agar dapat dipahami konteksnya [13], [19].

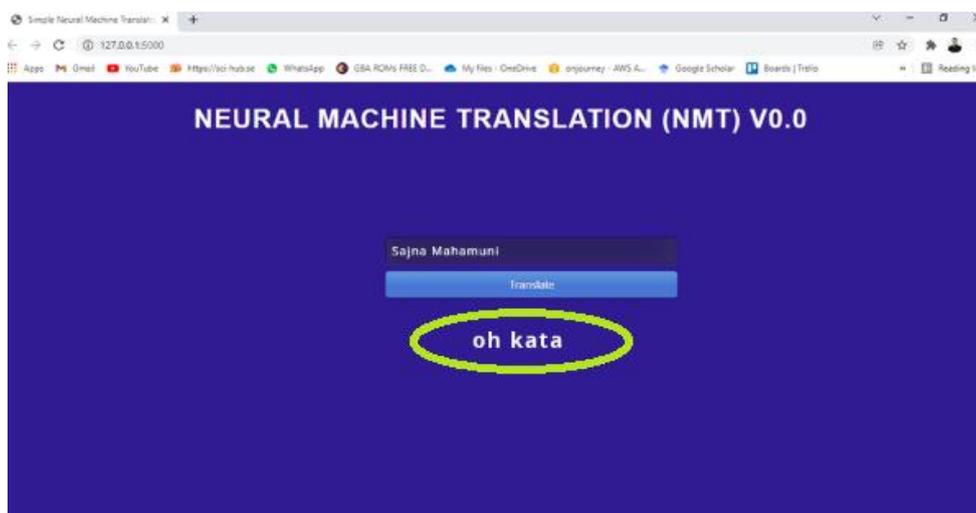
### 3.2. Hasil Implementasi Sistem

Proses implementasi yang dilaksanakan menggunakan Visual Studio Code dengan model RNN sebagai model yang dalam kasus ini menghasilkan dengan performa yang lebih baik. Struktur *file project* MT RNN terlihat seperti pada Gambar 11.



Gambar 11. Struktur *File Project* MT RNN

Selanjutnya diujicobakan dengan melakukan proses translasi pada salah satu kalimat pada *testing set*. Dalam bahasa Kawi adalah “*Sajna Mahamuni*” dalam bahasa Indonesia berdasarkan pada *ground truth* dataset berarti “oh paduka raja”. Berdasarkan percobaan dengan sistem menghasilkan hasil translasi “oh kata”, seperti yang terlihat pada Gambar 12.



Gambar 12. Implementasi Perancangan Sistem

### 3.3. Hasil *Black Box Testing*

Adapun hasil pengujian pada sistem dengan menggunakan metode *black box testing* seperti yang terlihat pada Tabel 6.

Tabel 6. Hasil Pengujian *Black Box Testing*

No.	Aktivitas Uji Coba	Hasil Uji Coba
1	Masuk halaman awal	Berhasil
2	Memasukkan teks bahasa Kawi	Berhasil
3	Klik tombol <i>translate</i>	Berhasil
4	Muncul hasil translasi	Berhasil

Pada Tabel 7 juga menampilkan hasil uji coba sistem dengan menggunakan beberapa kalimat di luar data latih. Berdasar hasil proses translasi dari sistem, menunjukkan bahwa memang belum mampu menghasilkan hasil yang diharapkan, namun dapat amati bahwa mesin sudah mengenali beberapa *index* kata.

Tabel 7. Hasil pengujian dengan kalimat bahasa Kawi.

No.	Kalimat Kawi	Hasil Translasi NMT	Translasi Seharusnya
1	<i>sajna mahamuni</i>	<i>oh kata</i>	<i>oh paduka raja</i>
2	<i>sajna aji</i>	<i>wahai sang</i>	<i>wahai maharaja</i>
3	<i>wilangnya kabeh petang puluh pat kwehnya</i>	<i>karena yang sang sang itu</i>	<i>berjumlah sekitar empat puluh empat</i>
4	<i>nahan ta paminta nira hyang narada</i>	<i>demikian kamu dewa yudhistira</i>	<i>demikian permintaan sang narada</i>

#### 4. Kesimpulan

Pengembangan MT telah banyak dilaksanakan dari berbagai penelitian dan industri, namun masih sedikit yang memfasilitasi bahasa lokal, salah satunya bahasa Kawi yang saat ini di Bali masih dipelajari yang berkaitan dengan kesusastraan Bali purwa. Pengembangan mesin translasi berbasis *neural* ini dapat menjadi langkah awal untuk pengembangan MT bagi bahasa lokal. Dataset yang dihasilkan yaitu paralel korpus Kawi-Indonesia dapat digunakan untuk pengembangan sistem MT kedepannya, namun dengan jumlah yang masih terbatas masih perlu bantuan ahli untuk menambah korpus dataset kedepan. MT yang dibuat dengan model RNN ini masih jauh dari berhasil melihat BLEU scores yang masih dibawah rata-rata nilai translasi yang konteksnya dapat dipahami, seperti pada translasi dari ahli manusia maupun mesin translasi seperti *google translate* dengan BLEU score di 60. Pengembangan kedepan dapat dilakukan dengan membuat arsitektur translasi berbeda menggunakan LSTM dengan mekanisme perhatian (*attention*) [7] dan arsitektur BERT [20].

#### Daftar Pustaka

- [1] T. F. Kai and T. K. Hua, "Enhancing english language vocabulary learning among indigenous learners through google translate," *J. Educ. e-Learning Res.*, vol. 8, no. 2, pp. 143–148, 2021, doi: 10.20448/JOURNAL.509.2021.82.143.148.
- [2] H. I. R. HINZLER, "BALINESE PALM-LEAF MANUSCRIPTS," *Bijdr. tot Taal-, Land- en Volkenkd.*, vol. 149, no. 3, pp. 438–473, Oct. 1993, [Online]. Available: <http://www.jstor.org/stable/27864483>.
- [3] N. S. Ardiyasa and M. K. S. E-mail, "Eksistensi Naskah Lontar Masyarakat Bali ( Studi Kasus Hasil Pemetaan Penyuuluh Bahasa Bali Tahun 2016-2018 )," vol. 11, no. 1, 2021.
- [4] M. L. Forcada *et al.*, "Apertium: a free/open-source platform for rule-based machine translation," *Mach. Transl.*, vol. 25, no. 2, pp. 127–144, Jun. 2011, doi: 10.1007/s10590-011-9090-0.
- [5] P. Koehn, F. J. Och, and D. Marcu, "Statistical Phrase-Based Translation," 2003.
- [6] P. Koehn, "Europarl: A Parallel Corpus for Statistical Machine Translation," *MT Summit*, vol. 11, pp. 79–86, 2005, Accessed: Jul. 20, 2021. [Online]. Available: <http://mt-archive.info/MTS-2005-Koehn.pdf>.
- [7] D. Bahdanau, K. H. Cho, and Y. Bengio, "Neural machine translation by jointly learning to align and translate," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, 2015.
- [8] K. Cho, B. van Merriënboer, D. Bahdanau, and Y. Bengio, "On the Properties of Neural Machine Translation: Encoder–Decoder Approaches," pp. 103–111, 2015, doi: 10.3115/v1/w14-4012.
- [9] M. K. Vathsala and G. Holi, "RNN based machine translation and transliteration for Twitter data," *Int. J. Speech Technol.*, vol. 23, no. 3, pp. 499–504, 2020.
- [10] S. Yang, Y. Wang, and X. Chu, "A Survey of Deep Learning Techniques for Neural Machine Translation," 2020, Accessed: Jul. 20, 2021. [Online]. Available: <http://arxiv.org/abs/2002.07526>.
- [11] R. Sennrich and B. Zhang, "Revisiting low-resource neural machine translation: A case study," *ACL 2019 - 57th Annu. Meet. Assoc. Comput. Linguist. Proc. Conf.*, pp. 211–221, 2020, doi: 10.18653/v1/p19-1021.
- [12] I. Sutskever, O. Vinyals, and Q. V. Le, "Sequence to sequence learning with neural networks," *Adv. Neural Inf. Process. Syst.*, vol. 4, no. January, pp. 3104–3112, 2014.
- [13] G. Tiwari, A. Sharma, A. Sahotra, and R. Kapoor, "English-Hindi Neural Machine Translation-LSTM Seq2Seq and ConvS2S," *Proc. 2020 IEEE Int. Conf. Commun. Signal Process. ICCSP 2020*, pp. 871–875, 2020, doi: 10.1109/ICCSP48568.2020.9182117.
- [14] K. Papineni, S. Roukos, T. Ward, and W.-J. Zhu, "Bleu: a method for automatic evaluation of machine translation," in *Proceedings of the 40th annual meeting of the Association for Computational Linguistics*, 2002, pp. 311–318.
- [15] Q. Li and Y.-L. Chen, "Data flow diagram," in *Modeling and Analysis of Enterprise and Information Systems*, Springer, 2009, pp. 85–97.
- [16] M. Khan, "Different approaches to black box testing technique for finding errors," *Int. J. Softw. Eng.*

- 
- Appl.*, vol. 2, no. 4, 2011.
- [17] T. P. Adewumi, F. Liwicki, and M. Liwicki, “Word2vec: Optimal hyper-parameters and their impact on nlp downstream tasks,” *arXiv Prepr. arXiv2003.11645*, 2020.
- [18] M. Belkin, D. Hsu, S. Ma, and S. Mandal, “Reconciling modern machine-learning practice and the classical bias–variance trade-off,” *Proc. Natl. Acad. Sci.*, vol. 116, no. 32, pp. 15849–15854, 2019.
- [19] Q. Wang *et al.*, “Learning Deep Transformer Models for Machine Translation,” *ACL 2019 - 57th Annu. Meet. Assoc. Comput. Linguist. Proc. Conf.*, pp. 1810–1822, Jun. 2019, doi: 10.18653/v1/p19-1176.
- [20] J. Zhu *et al.*, “Incorporating BERT into Neural Machine Translation,” Feb. 2020, Accessed: Nov. 26, 2021. [Online]. Available: <https://arxiv.org/abs/2002.06823v1>.