

# PENGEMBANGAN MODEL *DEEP LEARNING* UNTUK PEMBANGKIT SOAL OTOMATIS MENGGUNAKAN *RECURRENT NEURAL NETWORK*

## *DEEP LEARNING MODEL BUILDING FOR AUTOMATIC QUESTION GENERATOR USE RECURRENT NEURAL NETWORK*

**Danang Wijaya, Handaru Jati**

Fakultas Teknik Universitas Negeri Yogyakarta,  
[danangwijaya.2018@student.uny.ac.id](mailto:danangwijaya.2018@student.uny.ac.id)

### ABSTRACT

*The application of Artificial Intelligence in the field of education, especially learning evaluation is still lacking. There are no tools for teachers in developing questions for learning evaluation. The aims of this study are: (1) To develop a deep learning model for automatic question generation using a recurrent neural network. (2) Guarantee the accuracy and performance obtained from the deep learning that has been developed with an evaluation using untrained automatic metrics. The method used is Research and Development with deep learning model development stages consisting of translating datasets, preparing datasets, building deep learning models, and evaluating models. The model was developed with the SQuAD2.0 dataset which was translated into Indonesian and built using OpenNMT. The subject of this research is the result of the evaluation of the model's performance using untrained automatic metrics. The results of this study are: (1) A deep learning model for automatic question generation using a recurrent neural network, which consists of several configurations of the BiGRU and BiLSTM models with variations of cased and uncased training datasets. (2) The best model evaluation results were obtained on the Uncased BiLSTM model with a score of BLEU-1 38.10, BLEU-2 20.69, BLEU-3 10.58, BLEU-4 5.78, ROUGE-L 42.98, METEOR 18.31.*

**Keywords:** *Artificial Intelligence, Deep Learning, Automatic Question Generator, Recurrent Neural Network, SQuAD v2.0, OpenNMT, Untrained Automatic Metrics*

### ABSTRAK

Penerapan *Artificial Intelligence* di bidang pendidikan khususnya evaluasi pembelajaran masih kurang. Selain itu belum adanya alat bantu untuk guru dalam mengembangkan soal untuk evaluasi pembelajaran. Tujuan dari penelitian ini adalah: (1) Mengembangkan model *deep learning* untuk pembangkit soal otomatis menggunakan *recurrent neural network*. (2) Menjamin akurasi dan kinerja yang diperoleh dari model *deep learning* yang telah dikembangkan dengan evaluasi menggunakan *untrained automatic metric*. Metode yang digunakan adalah *Research and Development* dengan tahapan pengembangan model *deep learning* yang terdiri dari menerjemahkan dataset, menyiapkan dataset, membangun model *deep learning*, evaluasi model. Model dikembangkan dengan dataset SQuAD2.0 yang diterjemahkan ke bahasa Indonesia dan dibangun menggunakan OpenNMT. Subjek dari penelitian ini adalah hasil dari evaluasi kinerja model yang dilakukan dengan menggunakan *untrained automatic metrics*. Hasil dari penelitian ini adalah: (1) Model *deep learning* untuk pembangkit soal otomatis menggunakan *recurrent neural network*, yang terdiri dari beberapa konfigurasi model BiGRU dan BiLSTM serta variasi dataset latihan *cased* dan *uncased*. (2) Hasil evaluasi model terbaik diperoleh pada model BiLSTM *Uncased* dengan skor BLEU-1 38.10, BLEU-2 20.69, BLEU-3 10.58, BLEU-4 5.78, ROUGE-L 42.98, METEOR 18.31.

**Kata Kunci:** *Artificial Intelligence, Deep Learning, Pembangkit soal otomatis, Recurrent Neural Network, SQuAD2.0, OpenNMT, Untrained Automatic Metrics.*

### PENDAHULUAN

Teknologi saat ini sudah banyak dimanfaatkan untuk membantu pekerjaan manusia disegala aspek kehidupan, seperti pada bidang kesehatan, industri, bahkan pendidikan. Salah satu teknologi yang paling banyak penerapannya dalam kehidupan sehari-hari adalah teknologi kecerdasan buatan atau *Artificial Intelligence (AI)*. Kecerdasan Buatan yang sering disebut dengan *Artificial Intelligence* atau AI adalah bidang ilmu komputer yang berfokus pada penciptaan

mesin cerdas yang dapat bekerja dan bereaksi seperti manusia. Beberapa kegiatan komputer yang memiliki kecerdasan buatan adalah seperti pengenalan ucapan, belajar, perencanaan dan pemecahan masalah (Habeb, 2017). Penerapan AI sendiri sudah banyak, akan tetapi penggunaan AI dalam bidang pendidikan masih kurang.

Pendidikan khususnya di Indonesia sendiri masih memiliki banyak masalah terkait dengan akses dan kualitasnya. Secara umum, AI dapat dikatakan

sebuah ilmu yang digunakan untuk meniru kecerdasan yang dimiliki oleh makhluk hidup untuk diterapkan didalam sebuah mesin dengan tujuan untuk memecahkan suatu masalah, dengan adanya AI dapat dimungkinkan permasalahan didalam bidang pendidikan dapat kurangi. Salah satu permasalahan dibidang pendidikan Indonesia adalah pada proses evaluasi pembelajaran, hal ini terkait dengan belum adanya pemanfaat teknologi informasi secara maksimal. Evaluasi pembelajaran adalah suatu kegiatan yang penting untuk dilakukan, karena merupakan sebuah alat untuk tolak ukur hasil dari sebuah proses pembelajaran yang telah dilakukan sebelumnya. Menurut Gronlund (1976) dalam (Purwanto, 2009) evaluasi adalah suatu proses yang sistematis untuk menentukan atau membuat keputusan sampai sejauh mana tujuan-tujuan pembelajaran telah dicapai oleh siswa. Evaluasi pembelajaran yang sering dilakukan adalah dengan memberikan soal yang terkait dengan materi yang diberikan saat proses pembelajaran berlangsung. Tugas seorang pendidik atau guru dalam proses evaluasi pembelajaran adalah membuat soal-soal yang digunakan dalam evaluasi pembelajaran. Soal-soal yang dibuat oleh guru juga dapat digunakan untuk latihan siswa.

Permasalahan yang muncul pada saat proses evaluasi pembelajaran adalah ketika guru harus membuat butir soal yang jumlahnya tidak sedikit, sedangkan seorang guru juga memiliki tugas lain yang berkaitan dengan administrasi sekolah dan lain sebagainya, serta waktu yang dimiliki oleh seorang guru juga sedikit. Selain itu kendala lain yang dimiliki oleh seorang guru dalam proses evaluasi pembelajaran adalah guru kesulitan dalam mengembangkan instrumen dalam membuat soal tes (Asarina, 2014). Banyaknya tugas seorang guru, dan guru juga sering mendapatkan kesulitan ketika mengembangkan soal untuk evaluasi pembelajaran, maka sering sekali soal-soal yang digunakan pada evaluasi pembelajaran tahun sebelumnya digunakan kembali dan membuat siswa hanya menghafalkan jawaban yang benar dari soal-soal tersebut, maka diperlukannya alat bantu untuk guru mengembangkan dalam mengembangkan soal yang digunakan untuk proses evaluasi pembelajaran. Alat bantu yang sudah ada belum memiliki tingkat akurasi dan kinerja yang baik, dari masalah-masalah tersebut untuk dapat mengurangi dan mengatasinya, maka dapat diimplementasikannya sebuah teknologi dari bidang AI yaitu *Natural Language Processing* (NLP).

NLP adalah sebuah ilmu gabungan antara AI dan linguistik pada tahun 1950-an. Sebelumnya NLP berbeda dengan *Text Information Retrieval* (IR), yang menggunakan teknik statistika yang skalabel untuk melakukan pengindeksan dan pencarian teks dalam

volume yang besar secara efisien (Garbade, 2018). NLP yang populer dan saat ini banyak pengaplikasiannya seperti untuk *text summarization*, *machine translation*, *question answering*, dan *automatic question generator*. Teknologi NLP yang penulis usulkan adalah *Automatic Question Generator* (AQG). AQG merupakan sebuah sistem yang dapat membuat pertanyaan dari informasi yang ada berupa teks dengan menggunakan algoritma tertentu dan pola tertentu. AQG termasuk salah satu tugas NLP yaitu *Natural Language Generation* (NLG) yang implementasinya dapat dilakukan menggunakan *Machine Learning* (ML) dengan algoritma *Deep Learning* (DL) seperti *Sequence-to-Sequence* yaitu *Recurrent Neural Network* (RNN) yang terdiri dari *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Hasil model dari NLG dapat dilakukan pengukuran untuk mengetahui tingkat performanya menggunakan metode *Untrained Automatic Metric* (UAM). Standar UAM yang digunakan untuk evaluasi otomatis saat ini adalah *Bilingual Evaluation Understudy* (BLEU) (Papineni dkk., 2001), selain itu metrik selain BLEU adalah *Metric for Evaluation of Translation with Explicit Ordering* (METEOR) (Lavie & Agarwal, 2007) dan *Recall-Oriented Understudy for Gisting Evaluation* (ROUGE) (Lin, 2004).

Dengan adanya AQG diharapkan dapat bekerja seperti halnya seorang pengajar yang dapat membuat sebuah soal dari pengetahuan yang dimiliki dan teks yang dibaca dan dipahaminya, sehingga dapat membantu tugas seorang guru dalam membuat soal yang akan digunakan untuk proses evaluasi pembelajaran atau digunakan untuk memberikan stimulus siswa dan mengetahui kemampuan siswa terhadap materi yang telah diberikan oleh guru. Pada teknologi pembelajaran *Intelligent Tutoring System* (ITS) sistem AQG menjadi sebuah komponen yang penting (Fattoh dkk., 2015), yaitu dalam penerapan pada salah satu module ITS pada tahap *domain knowledge*, dalam tahap ini AQG dapat digunakan sebagai latihan soal yang dibuat berdasarkan konsep pengetahuan.

## METODE PENELITIAN

Penelitian “Pengembangan model *deep learning* untuk pembangkit soal otomatis menggunakan *recurrent neural network*” ini menggunakan metode *Research and Development* (R&D) dengan tahapan pengembangan model *deep learning* yang terdiri dari menerjemahkan dataset, menyiapkan dataset, membangun model *deep learning*, evaluasi model.

## Waktu dan Tempat Penelitian

Penelitian ini dimulai pada bulan Mei 2021 sampai dengan bulan Januari 2022. Tempat penelitian dilaksanakan di Program Studi Pendidikan Teknik Informatika, serta tempat-tempat lain di lingkungan Universitas Negeri Yogyakarta yang diperlukan untuk mendukung pelaksanaan penelitian.

## Sumber Data/Subjek Penelitian

Subjek dari penelitian ini adalah akurasi dari produk yang dihasilkan atau prototipe model *deep learning* yaitu berasal dari hasil evaluasi mesin saraf penerjemah yang dilakukan dengan *automated measures* menggunakan *untrained automatic metrics* yaitu metrik evaluasi BLEU, ROUGE dan METEOR. Objek dari penelitian ini adalah prototipe dari model *deep learning* itu sendiri.

## Prosedur Pengembangan

Prosedur pengembangan model *Deep Learning* terdiri dari 4 tahapan yaitu: Menerjemahkan dataset, Menyiapkan dataset, Membangun model *deep learning*, Evaluasi model. Prosedur pengembangan dapat dilihat pada Gambar x.



Gambar 1. Tahapan Pengembangan

Fase tersebut dijabarkan sebagai berikut:

### 1. Menerjemahkan Dataset

Dataset yang digunakan dalam penelitian ini adalah dataset SQuAD v2.0 yang merupakan dataset pemahaman bacaan (*reading comprehension*) yang digunakan untuk *machine reading comprehension* yang berisi paragraf artikel dan pasangan pertanyaan-jawaban dalam bahasa Inggris. Pada tahap ini dilakukan penerjemahan dataset dari bahasa Inggris ke bahasa Indonesia dengan bantuan Google Translate.

### 2. Menyiapkan Dataset

Dataset SQuAD v2.0 yang telah diterjemahkan ke dalam bahasa Indonesia selanjutnya dilakukan pemrosesan untuk dapat digunakan di dalam proses pembuatan atau melatih model. Fokus pada tahap ini adalah menentukan posisi jawaban di dalam paragraf artikel dari pertanyaan yang ada. Selain itu juga dilakukan penyiapan fitur linguistik untuk *POS tagging* dan *NER*, selanjutnya teks paragraf digunakan untuk input dan pertanyaan untuk target. Pada tahap ini juga membuat variasi input untuk *uncased* dan *cased* input. Selanjutnya membuat representasi untuk setiap input, fitur, target. Dalam tahap ini juga

dilakukan pemisahan dataset yang digunakan untuk data latih dan data uji.

### 3. Membangun Model *Deep Learning*

Tahap membangun model *deep learning* dilakukan dengan proses latihan model menggunakan *library* OpenNMT-py yang berbasis *framework* PyTorch dan mengimplementasikan RNN model yaitu *Bidirectional Recurrent Unit* (BiGRU) dan *Bidirectional Long-Short Term Memory* (BiLSTM) dengan variasi dataset *cased* dan *uncased*. Pembuatan dan pelatihan model menggunakan *pre-trained word embedding* dari FastText Indonesia.

### 4. Evaluasi Model

Tahap evaluasi model dilakukan dengan metode *automatic measures* menggunakan *Untrained Automatic Metrics* (UAM) terhadap model yang telah dibuat menggunakan metrik BLEU, ROUGE, dan METEOR.

## Data, Instrumen, dan Teknik Pengumpulan

Setelah semua model dengan berbagai konfigurasi selesai dibangun kemudian dilakukan proses evaluasi dengan menggunakan beberapa *untrained automatic metrics*. Hasil evaluasi dari setiap konfigurasi model dengan setiap metrik dikumpulkan untuk dibandingkan. Metrik yang digunakan adalah BLEU, ROUGE, dan METEOR.

## Teknik Analisis Data

Teknik analisis data adalah sebuah cara untuk mengolah dan menganalisis data yang telah dikumpulkan, berdasarkan instrumen penelitian yang digunakan. Analisis data yang dilakukan dari hasil evaluasi setiap konfigurasi model yang telah melalui tahap latihan menggunakan *untrained automatic metric* adalah melakukan perbandingan kinerja hasil evaluasi dari proses latihan model untuk kemudian diputuskan manakah konfigurasi model yang memiliki kinerja terbaik.

## HASIL DAN PEMBAHASAHAN

### 1. Menerjemahkan Dataset

Pada tahap ini dilakukan penerjemahan dataset dari bahasa Inggris ke bahasa Indonesia dengan bantuan *google translate API V2*. Hasil dari penerjemahan dataset menggunakan *google translate* belum dilakukan perbaikan, karena banyaknya jumlah data yang ada di dataset. Berikut adalah dataset latih dan uji asli dari SQuAD2.0.



```

train feature shoppe: [1843]: 3)
Vocab feature shoppe: [13597]: 3)
Data are saved in data/processed/train
Data are saved in data/processed/val
Data are saved in data/processed/test
Train data
184371 data/processed/train/squad_id_split0_9_cased_source.txt
Pertanyaan | <none> | NMD yang | <none> | PUN harus | <none> | TAME dijawab | <none> | VBP adalah | <none> | VBL apakah | <none> | Sentara | <none> | CNJ perjanjian | <none> | NMD membutuhkan | <none> | VBT nasihat | <none> | NMD dan | <none> | CNJ persetujuan |
Sebaliknya | <none> | ADV | <none> | PUN seorang | <none> | CRD NMR Eternalis | <none> | NMP berpandang | <none> | VBT bahwa | <none>
Apa pertimbangan utama untuk menentukan apakah proyek dapat dilakukan di daerah dengan spesies yang terancam punah ?
Berapa persen dari seorang Amerika Serikat yang harus menerima saran dan persetujuan agar AS dapat menandatangani perjanjian ?
Siapa yang percaya bahwa waktu adalah dimensi realitas setara dengan tiga dimensi spasial ?
Vocab data
11597 data/processed/val/squad_id_split0_9_cased_source.txt
Penemuan | <none> | NMD itu | <none> | ART diberi | <none> | VBP nama | <none> | NNO Batmania | <none> | NMP setelah | <none> |
Nenyusil | <none> | VBT pendorong | <none> | NMD kakalisan | <none> | NMD Chalunya | <none> | PER | NMP menjadi | <none> | VBI tepat | <none> |
Video | <none> | NMD | <none> | PUN Open | <none> | NMD Your | <none> | PUN Heart | <none> | NMD | <none> | PUN melihat | <none>
Apa nama pemukiman yang awalnya disebut ?
Apa ibukota Gokonda di pertengahan abad ke-12 ?
Di video mana itu menunjukkan Madonna dinarasi oleh bosnya di Italia ?
Test data
18488 data/processed/test/squad_id_split0_9_cased_source.txt
Bergas | <none> | NMD Normandia | <none> | PER | NMP | <none> | PUN Norman | <none> | NOR | NMP | <none> | PUN Normands | <none> | NMP | <none> |
Bergas | <none> | NMD Normandia | <none> | PER | NMP | <none> | PUN Norman | <none> | NOR | NMP | <none> | PUN Normands | <none> | NMP | <none> |
Mereka | <none> | PRR diturunkan | <none> | VBP dari | <none> | PPO Norse | <none> | NNP | <none> | PUN | <none> | PUN Norman
Di negara apa Normandia berada ?
Kapan Normandia di Normandia ?
Dari negara mana asal Norse ?

```

Gambar 7. Pembagian dataset varian *cased*

b. Data Preprocessing

Tahap *preprocessing* ditujukan untuk membuat data *vocab dictionary* yang diperlukan untuk membuat *embedding* dari *pretrained* model FastText Indonesia. Data yang digunakan pada tahap *preprocessing* adalah data latih dan data validasi dari setiap variasi dataset.

```

1 !omni_preprocess -train_src 'data/processed/train/squad_id_split0_9_uncased_source.txt' \
2 -train_tgt 'data/processed/train/squad_id_split0_9_uncased_target.txt' \
3 -valid_src 'data/processed/val/squad_id_split0_9_uncased_source.txt' \
4 -valid_tgt 'data/processed/val/squad_id_split0_9_uncased_target.txt' \
5 -save_data 'data/processed/omni/squad_id_split0_9_uncased' \
6 -overwrite \
7 -dynamic_dict \
8 -src_vocab_size 50000 \
9 -tgt_vocab_size 30000 \
10 -src_seq_length 64 \
11 -tgt_seq_length 28
[2022-03-18 15:45:34,856 INFO] Extracting features...
[2022-03-18 15:45:34,862 INFO] * number of source features: 4.
[2022-03-18 15:45:34,866 INFO] * number of target features: 8.
[2022-03-18 15:45:34,872 INFO] Building Fields object...
[2022-03-18 15:45:34,892 INFO] Building & saving training data...
[2022-03-18 15:45:34,681 INFO] Building shard 0.
[2022-03-18 15:47:01,972 INFO] * src vocab size: 30004.
[2022-03-18 15:47:02,000 INFO] * src vocab size: 30004.
[2022-03-18 15:47:02,048 INFO] * src-feat_0 vocab size: 4.
[2022-03-18 15:47:02,080 INFO] * src-feat_1 vocab size: 4.
[2022-03-18 15:47:02,112 INFO] * src-feat_2 vocab size: 21.
[2022-03-18 15:47:02,144 INFO] * src-feat_3 vocab size: 27.
[2022-03-18 15:47:02,176 INFO] Building & saving validation data...
[2022-03-18 15:47:02,657 INFO] Building shard 0.
[2022-03-18 15:47:02,576 INFO] * saving 0th valid data shard to data/processed/omni/squad_id_split0_9_uncased_valid_0.pt.

```

Gambar 8. *Preprocessing* varian *uncased*

```

1 !omni_preprocess -train_src 'data/processed/train/squad_id_split0_9_cased_source.txt' \
2 -train_tgt 'data/processed/train/squad_id_split0_9_cased_target.txt' \
3 -valid_src 'data/processed/val/squad_id_split0_9_cased_source.txt' \
4 -valid_tgt 'data/processed/val/squad_id_split0_9_cased_target.txt' \
5 -save_data 'data/processed/omni/squad_id_split0_9_cased' \
6 -overwrite \
7 -dynamic_dict \
8 -src_vocab_size 50000 \
9 -tgt_vocab_size 30000 \
10 -src_seq_length 64 \
11 -tgt_seq_length 28
[2022-03-18 15:49:48,655 INFO] Extracting features...
[2022-03-18 15:49:48,659 INFO] * number of source features: 3.
[2022-03-18 15:49:48,663 INFO] * number of target features: 8.
[2022-03-18 15:49:48,667 INFO] Building Fields object...
[2022-03-18 15:49:48,685 INFO] Building & saving training data...
[2022-03-18 15:49:48,656 WARNING] Shards for corpus train already exist, will be overwritten because '-overwrite' option is set.
[2022-03-18 15:49:48,656 WARNING] Shards for corpus train already exist, will be overwritten because '-overwrite' option is set.
[2022-03-18 15:49:49,250 INFO] Building shard 0.
[2022-03-18 15:51:18,449 INFO] * saving 0th train data shard to data/processed/omni/squad_id_split0_9_cased_train_0.pt.
[2022-03-18 15:51:18,467 INFO] * src vocab size: 30002.
[2022-03-18 15:51:18,496 INFO] * src-feat_0 vocab size: 4.
[2022-03-18 15:51:18,524 INFO] * src-feat_1 vocab size: 21.
[2022-03-18 15:51:18,552 INFO] * src-feat_2 vocab size: 27.
[2022-03-18 15:51:18,580 INFO] Building & saving validation data...
[2022-03-18 15:51:18,454 WARNING] Shards for corpus valid already exist, will be overwritten because '-overwrite' option is set.
[2022-03-18 15:51:18,454 WARNING] Shards for corpus valid already exist, will be overwritten because '-overwrite' option is set.
[2022-03-18 15:51:18,714 INFO] Building shard 0.
[2022-03-18 15:51:18,521 INFO] * saving 0th valid data shard to data/processed/omni/squad_id_split0_9_cased_valid_0.pt.

```

Gambar 9. *Preprocessing* varian *cased*

c. Embedding to torch

Pada tahap ini dilakukan pembuatan *word embedding* yaitu pembuatan representasi dari kata ke dalam bentuk vektor dari data latih dan data validasi dengan *pretrained* model FastText Indonesia yang diubah ke format GloVe dengan *dictionary vocab* dari data hasil *preprocessing* dataset

```

14 !python3 src/omni/embeddings_to_torch.py --emb_file_both 'models/word-embedding/ft_to_g1_300_id_vec' \
15 --dict_file 'data/processed/omni/squad_id_split0_9_uncased_vocab.pt' \
16 --output_file 'data/processed/omni/embeddings_uncased'
[2022-03-18 15:52:44,867 INFO] From: data/processed/omni/squad_id_split0_9_uncased_vocab.pt
[2022-03-18 15:52:44,868 INFO] * source vocab: 50002 words
[2022-03-18 15:52:44,868 INFO] * target vocab: 30004 words
[2022-03-18 15:52:44,882 INFO] Reading encoder and decoder embeddings from models/word-embedding/ft_to_g1_300_id_vec
[2022-03-18 15:53:25,374 INFO] Found 2000000 total vectors in file
[2022-03-18 15:53:25,396 INFO] * enc: 35276 match, 14726 missing, (70.55%)
[2022-03-18 15:53:25,410 INFO] * dec: 22938 match, 7066 missing, (76.45%)
[2022-03-18 15:53:25,410 INFO]
Saving embedding as:
  * enc: data/processed/omni/embeddings_uncased.enc.pt
  * dec: data/processed/omni/embeddings_uncased.dec.pt
[2022-03-18 15:53:26,742 INFO] Done.
1 !python3 src/omni/embeddings_to_torch.py --emb_file_both 'models/word-embedding/ft_to_g1_300_id_vec' \
2 --dict_file 'data/processed/omni/squad_id_split0_9_cased_vocab.pt' \
3 --output_file 'data/processed/omni/embeddings_cased'
[2022-03-18 15:53:48,212 INFO] From: data/processed/omni/squad_id_split0_9_cased_vocab.pt
[2022-03-18 15:53:48,213 INFO] * source vocab: 50002 words
[2022-03-18 15:53:48,213 INFO] * target vocab: 30004 words
[2022-03-18 15:53:48,225 INFO] Reading encoder and decoder embeddings from models/word-embedding/ft_to_g1_300_id_vec
[2022-03-18 15:54:23,683 INFO] Found 2000000 total vectors in file
[2022-03-18 15:54:23,683 INFO] After filtering to vectors in vocab:
[2022-03-18 15:54:23,684 INFO] * enc: 44875 match, 5127 missing, (89.75%)
[2022-03-18 15:54:23,638 INFO] * dec: 27654 match, 2356 missing, (92.17%)
[2022-03-18 15:54:23,638 INFO]
Saving embedding as:
  * enc: data/processed/omni/embeddings_cased.enc.pt
  * dec: data/processed/omni/embeddings_cased.dec.pt
[2022-03-18 15:54:25,223 INFO] Done.

```

Gambar 10. Pembuatan *Word Embedding* setiap varian dataset

3. Membangun Model Deep Learning

Proses membangun model adalah proses latih model yang dilakukan didalam google colab dengan tipe *runtime* GPU dan menggunakan beberapa *toolkit*, *library*, dan *framework* seperti OpenNMT-py, dan PyTorch. Arsitektur RNN yang digunakan adalah menggunakan arsitektur dari (Du dkk., 2017) dengan menambahkan fitur linguistik pada konteks input. Berikut adalah hasil dari proses latih model dari setiap konfigurasi model dan data latih.

Nama Model	Validation Accuracy	Step	Time (s)
BiGRU <i>Uncased</i>	50.15	32100	6136
BiGRU <i>Cased</i>	49.63	32100	3105
BiLSTM <i>Uncased</i>	50.91	16050	1888
BiLSTM <i>Cased</i>	50.50	16050	1861

4. Evaluasi Model

Tahap evaluasi model dilakukan dengan metode *automatic measures* terhadap prototipe model yang telah dibuat menggunakan metrik BLEU, ROUGE, dan METEOR. Sebelum melakukan evaluasi setiap model, dilakukan inferensi yaitu pembuatan soal menggunakan setiap model yang telah dibangun dari dataset uji. Inferensi dilakukan dengan menggunakan data uji dari setiap variasi dataset. Berikut ini adalah beberapa sampel hasil inferensi yang telah dilakukan.

Keterangan	Kalimat
1 Input	Teori kompleksitas komputasi adalah cabang dari teori komputasi

Jawaban	dalam ilmu komputer teoretis yang berfokus pada pengelompokan masalah komputasi sesuai dengan kesulitan yang melekat, dan menghubungkan kelas-kelas tersebut satu sama lain. Cabang dari teori komputasi dalam ilmu komputer teoretis yang berfokus pada pengelompokan masalah komputasi sesuai dengan kesulitan yang melekat, dan menghubungkan kelas-kelas tersebut satu sama lain
Target	Apa yang dimaksud dengan teori kompleksitas komputasi ?
BiGRU <i>Cased</i>	Apa yang dimaksud dengan teori kompleksitas komputasi ?
BiGRU <i>Uncased</i>	apa yang dimaksud dengan teori kompleksitas komputasi ?
BiLSTM <i>Cased</i>	Teori kompleksitas komputasi adalah cabang dari teori apa ?
BiLSTM <i>Uncased</i>	teori kompleksitas komputasi berfokus pada apa ?

2

Input	Mesin uap adalah mesin pembakaran eksternal, di mana fluida kerja terpisah dari produk pembakaran.
Jawaban	Mesin pembakaran eksternal
Target	Apa itu mesin uap?
BiGRU <i>Cased</i>	Mesin uap apa yang digunakan untuk membuat motor uap ?
BiGRU <i>Uncased</i>	apa itu mesin uap ?
BiLSTM <i>Cased</i>	Apa itu mesin uap ?
BiLSTM <i>Uncased</i>	apa itu mesin uap ?

3

Input	Siklus termodinamika ideal yang digunakan untuk menganalisis proses ini disebut siklus Rankine.
Jawaban	Siklus Rankine
Target	Apa nama siklus termodinamika dalam proses mesin uap?
BiGRU <i>Cased</i>	Apa nama lain untuk siklus termodinamika ideal ?
BiGRU <i>Uncased</i>	apa siklus termodinamika ideal yang digunakan untuk menganalisis proses ini ?
BiLSTM <i>Cased</i>	Siklus termodinamika ideal disebut siklus apa ?
BiLSTM <i>Uncased</i>	apa siklus termodinamika ideal yang digunakan untuk menganalisis proses ini ?

4

Input	Oksigen adalah unsur kimia dengan simbol O dan nomor atom 8.
Jawaban	8
Target	Nomor atom oksigen adalah?
BiGRU <i>Cased</i>	Berapa angka atom ?
BiGRU <i>Uncased</i>	berapa nomor atom yang oksigen ?
BiLSTM <i>Cased</i>	Berapa nomor atom untuk Oksigen ?
BiLSTM <i>Uncased</i>	berapa nomor atom oksigen ?

Evaluasi dilakukan terhadap hasil inferensi dari setiap model pada setiap varian dataset dengan cara membandingkan hasil inferensi dengan data uji *target* menggunakan *tools* nlg-eval dari (Sharma dkk., 2017). Berikut adalah hasil evaluasi yang telah dilakukan menggunakan *untrained automatic metrics* dengan bantuan *tools* nlg-eval.

Nama Model	BL EU -1	BL EU -2	BL EU -3	BL EU -4	ROUGE -L	MET EOR
BiGRU U	37.	20.2	10.	5.4	42.80	17.9
BiGRU <i>Uncased</i>	58	1	19	7		
BiGRU U	33.	17.4	8.6	4.7	39.63	17.5
BiGRU <i>Cased</i>	92	7	4	2		
BiLSTM M	38.	20.6	10.	5.7	42.98	18.3
BiLSTM <i>Uncased</i>	10	9	58	8		
BiLSTM M	34.	17.7	8.9	4.9	39.62	17.7
BiLSTM <i>Cased</i>	37	0	3	1		

## SIMPULAN DAN SARAN

### Simpulan

Berdasarkan hasil penelitian dapat disimpulkan bahwa Pengembangan Model *Deep Learning* untuk Pembangkit Soal Otomatis Menggunakan *Reccurent Neural Network* selesai dilakukan. Pengembangan model menggunakan dataset dari SQuAD v2.0 yang diterjemahkan ke bahasa Indonesia. Pengembangan model *deep learning* menggunakan metode yang terdiri dari (1) Menerjemahkan dataset, (2) Menyiapkan dataset, (3) Membangun model *deep learning*, (4) Evaluasi model.

Evaluasi untuk mengetahui kinerja model telah dilakukan terhadap seluruh model yang dihasilkan. Terdapat empat model *deep learning* yang dihasilkan dari penelitian ini yaitu model BiGRU dan BiLSTM dengan kedua model menggunakan dua variasi dataset *cased* dan *uncased*. Proses evaluasi dilakukan dengan menggunakan *untrained automatic metrics* yang terdiri dari BLEU-1,2,3,4, METEOR, dan ROUGE-L mendapatkan hasil terbaik yaitu pada model BiLSTM *Uncased* dengan skor BLEU-1 38.10, BLEU-2 20.69, BLEU-3 10.58, BLEU-3 5.78, ROUGE-L 42.98, METEOR 18.31..

Model *deep learning* yang dihasilkan sudah dapat digunakan untuk membuat soal pertanyaan dari input materi yang diberikan walaupun masih memiliki keterbatasan dan dapat ditingkatkan kembali untuk penelitian selanjutnya.

### Saran

Dari hasil uraian simpulan serta masih adanya keterbatasan produk dari penelitian, terdapat saran bagi penelitian mendatang adalah sebagai berikut:

1. Melakukan pengujian lebih lanjut dengan metode *Human Subjective Judgment* untuk mendapatkan penilaian dari sudut pandang pemahaman manusia.
2. Melakuakn proses latih model dengan mekanisme model lain seperti *Transformer*.
3. Melakukan perbaikan terhadap hasil terjemahan dataset latih dan uji.

### DAFTAR PUSTAKA

- Asarina, R. (2014). *STUDI EKSPLORASI KENDALA-KENDALA GURU DALAM PEMBELAJARAN IPS DI SMP WILAYAH KECAMATAN MOYUDAN*.
- Bangor, A., Kortum, P. T., & Miller, J. (2009). Determining what individual SUS scores mean: Adding an adjective rating scale. *Journal of usability studies*, 114–223.
- Du, X., Shao, J., & Cardie, C. (2017). *Learning to Ask: Neural Question Generation for Reading Comprehension* (arXiv:1705.00106). arXiv. <http://arxiv.org/abs/1705.00106>
- Fattoh, I. E., Aboutabl, A. E., & Haggag, M. H. (2015). *Semantic Question Generation Using Artificial Immunity*. 9.
- Garbade, D. M. J. (2018, Oktober 15). *A Simple Introduction to Natural Language Processing*. Medium. <https://becominghuman.ai/a-simple-introduction-to-natural-language-processing-ea66a1747b32>
- Habeeb, A. (2017). *Introduction to Artificial Intelligence*. <https://doi.org/10.13140/RG.2.2.25350.88645/1>
- Lavie, A., & Agarwal, A. (2007). Meteor: An automatic metric for MT evaluation with high levels of correlation with human judgments. *Proceedings of the Second Workshop on Statistical Machine Translation - StatMT '07*, 228–231. <https://doi.org/10.3115/1626355.1626389>
- Lin, C.-Y. (2004). ROUGE: A Package for Automatic Evaluation of Summaries. *Text Summarization Branches Out*, 74–81. <https://aclanthology.org/W04-1013>
- Papineni, K., Roukos, S., Ward, T., & Zhu, W.-J. (2001). BLEU: A method for automatic evaluation of machine translation. *Proceedings of the 40th Annual Meeting on Association for Computational Linguistics - ACL '02*, 311. <https://doi.org/10.3115/1073083.1073135>
- Purwanto, P. (2009). *Evaluasi Hasil Belajar*. Pustaka Pelajar.
- Sudaryono, D. (2015). *Metodologi Riset di Bidang TI: (Panduan Praktis, Teori dan Contoh Kasus)*. Penerbit Andi.