

Klasifikasi Pos Pengeluaran Perjalanan Dinas Menggunakan *Recurrent Neural Network* dan *Long Short-Term Memory*

Megandi¹; Mereditha Susanty^{1*}; Erwin Setiawan¹

1. Fakultas Sains dan Komputer, Program Studi Ilmu Komputer, Universitas Pertamina,
DKI Jakarta 12220, Indonesia

*Email: mereditasusanty@universitaspertamina.ac.id

Received: 8 September 2022 | Accepted: 21 Februari 2023 | Published: 25 April 2023

ABSTRACT

A travel report containing details related to activities carried out during official trips is a mandatory report that must be made by the traveler based on the Regulation of the Minister of Finance and the State Minister of State-Owned Enterprises. One of the things that must be reported is the use of funds during the activities carried out. The longer the official trip, the more expenses that must be reported, both the amount and proof of payment. This study aims to help streamline business travel financial reporting activities by automatically grouping each expense item using a machine learning approach. By using the Recurrent Neural Network architecture and the Long Short-Term Memory model, we classify each expenditure item into three expenditure items. The results show that the LSTM architecture performs better with the accuracy value of 86%.

Keywords: business travel, machine learning, sequential model, classification

ABSTRAK

Laporan perjalanan yang berisi hal-hal detail terkait dengan kegiatan yang telah dilakukan selama perjalanan dinas merupakan laporan wajib yang harus dibuat oleh pelaku perjalanan berdasarkan Peraturan Menteri Keuangan dan Menteri Negara Badan Usaha Milik Negara. Salah satu hal yang harus dilaporkan adalah penggunaan dana selama kegiatan dilakukan. Semakin lama perjalanan dinas, semakin banyak pengeluaran yang harus dilaporkan, baik jumlah maupun bukti pembayarannya. Penelitian ini bertujuan membantu mengefisienkan kegiatan pelaporan keuangan perjalanan dinas dengan melakukan pengelompokan secara otomatis setiap item pengeluaran menggunakan pendekatan machine learning. Dengan menggunakan arsitektur Recurrent Neural Network dan Long Short-Term Memory model mengklasifikasikan setiap item pengeluaran ke tiga pos pengeluaran. Hasil penelitian menunjukkan arsitektur LSTM memberikan performa lebih baik dengan nilai akurasi 86%.

Kata kunci: perjalanan dinas, pembelajaran mesin, model sekuensial, klasifikasi

1. PENDAHULUAN

Perjalanan dinas adalah sebuah kegiatan yang dilakukan karyawan ke suatu tempat yang berbeda yang ditentukan oleh pimpinan instansi atau perusahaan dalam jangka waktu tertentu. Perjalanan ini biasanya dilakukan karena berbagai kepentingan, antara lain pelaksanaan dan pengawasan di kantor cabang, diklat, tender, janji tertentu, penjajakan kerja sama, menghadiri acara seremonial, kegiatan sosial, memenuhi undangan tertentu, dan lain sebagainya. Dalam perjalanan dinas, tempat tujuan, dana, orang-orang yang akan ditemui dan ikut serta dalam perjalanan sudah dipersiapkan oleh instansi. Sebagai hasil dari perjalanan dinas, pelaku perjalanan dinas harus membuat sebuah laporan perjalanan yang berisi hal-hal detail terkait dengan kegiatan yang telah dilakukan selama perjalanan dinas.

Pelaporan perjalanan dinas sendiri diatur pada Peraturan Menteri Keuangan No.113/PMK.05/2012 [1] juga Peraturan Menteri Negara Badan Usaha Milik Negara Nomor PER-02/MBU/2011 [2]. Salah satu hal yang perlu dilaporkan dalam laporan perjalanan dinas adalah penggunaan dana selama kegiatan dilakukan. Dalam pelaporan ini, pelaku perjalanan dinas, harus menuliskan item pengeluaran, mengunggah bukti pengeluaran dan mengelompokkan item pengeluaran ke dalam pos pengeluaran tertentu. Misalnya, pembelian tiket pesawat, pembayaran taksi dimasukkan ke dalam pos transportasi.

Semakin lama perjalanan dinas, umumnya akan semakin banyak item pengeluaran yang harus dilaporkan sehingga akan membutuhkan waktu yang lebih lama untuk menyusun laporan pengeluaran perjalanan dinas. Penelitian ini bertujuan membantu mengefisienkan kegiatan pelaporan keuangan perjalanan dinas dengan melakukan pengelompokkan secara otomatis setiap item pengeluaran.

Dengan pengelompokkan secara otomatis, pengguna hanya perlu mengambil gambar atau memindai bukti pengeluaran selama perjalanan dinas. Penelitian lain sudah memanfaatkan teknologi *optical character recognition* (OCR) untuk mengubah gambar pada dokumen yang dipindai menjadi teks [3]. Pada penelitian ini, hasil pembacaan OCR dalam bentuk teks akan dikelompokkan ke dalam pos pengeluaran tertentu. Penelitian serupa sebelumnya menggunakan pendekatan *logistik regression*, *naive bayes*, *linear support vector machine*, dan *random forest* untuk mengelompokkan pengeluaran pribadi [4], [5]. Berbeda dengan penelitian sebelumnya, untuk dapat mengelompokkan item pengeluaran ke dalam pos tertentu, penelitian ini membandingkan dua buah model *deep learning* menggunakan pendekatan *sequence* model. Model pertama menggunakan arsitektur *Recurrent Neural Network* (RNN)[6] dan model kedua menggunakan arsitektur *Long Short-Term Memory* (LSTM) [7]. Kedua model digunakan karena keunggulannya dalam pengolahan data yang bersifat sekuensial seperti pengolahan kata-kata yang memiliki urutan tertentu dalam suatu kalimat [8].

Model terbaik dipilih berdasarkan nilai paling tinggi. Bobot yang diperoleh dari proses pelatihan disimpan dalam format h5 untuk digunakan sebagai model prediksi dalam sistem informasi laporan pertanggung jawaban dinas. Dengan otomasi yang dilakukan, diharapkan dapat mengurangi waktu yang dibutuhkan untuk memeriksa laporan keuangan, sehingga staf perusahaan dapat melakukan pekerjaan lain yang lebih strategis.

2. METODE PENELITIAN

Penelitian ini terdiri dari empat tahapan, pengumpulan data, pra-pemrosesan data, pembuatan model, dan evaluasi model seperti ditunjukkan pada Gambar 1.

Dataset yang digunakan pada penelitian ini dikumpulkan dari internet berupa gambar bukti pembayaran serta dari pembelanjaan pribadi yang dilakukan. Pada tahapan pra-pemrosesan, data yang dikumpulkan diubah ke dalam bentuk teks menggunakan *tools Optical Character Recognition*.

Setelah didapatkan data berbentuk teks dilakukan *lower casing* dan tokenisasi terhadap data. Selanjutnya, data yang berbentuk teks diberi label secara manual. Label yang digunakan terdiri dari tiga kelas yakni konsumsi, ATK, dan IT. Data kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20.



Gambar 1. Tahapan Penelitian

Penelitian ini mencoba membuat model klasifikasi menggunakan dua arsitektur *machine learning*, yakni *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM). Kedua arsitektur ini dipilih karena keunggulannya dalam pengolahan data sekuensial seperti teks yang tersusun dari urutan kata-kata. Arsitektur RNN sederhana terdiri dari satu lapisan RNN dengan simpul atau neuron yang saling terhubung dan berulang dalam siklus. Setiap simpul menerima input dari simpul sebelumnya dan menghasilkan output untuk simpul selanjutnya. Arsitektur RNN sederhana ini dapat mengalami masalah *vanishing gradient*, yang terjadi ketika gradien penyesuaian yang dikirim ke simpul yang lebih awal menjadi sangat kecil sehingga simpul itu tidak lagi berkontribusi pada output akhir. LSTM sendiri merupakan varian dari RNN yang mampu mengatasi permasalahan *vanishing gradient* pada arsitektur RNN. LSTM memiliki mekanisme gate, yaitu input gate, forget gate, dan output gate, yang membantu mengatur aliran informasi dalam jaringan. Input gate mengontrol seberapa banyak informasi baru yang akan dimasukkan ke dalam sel memori, forget gate mengontrol seberapa banyak informasi yang akan dihapus dari sel memori, dan output gate mengontrol seberapa banyak informasi yang akan dikeluarkan dari sel memori.

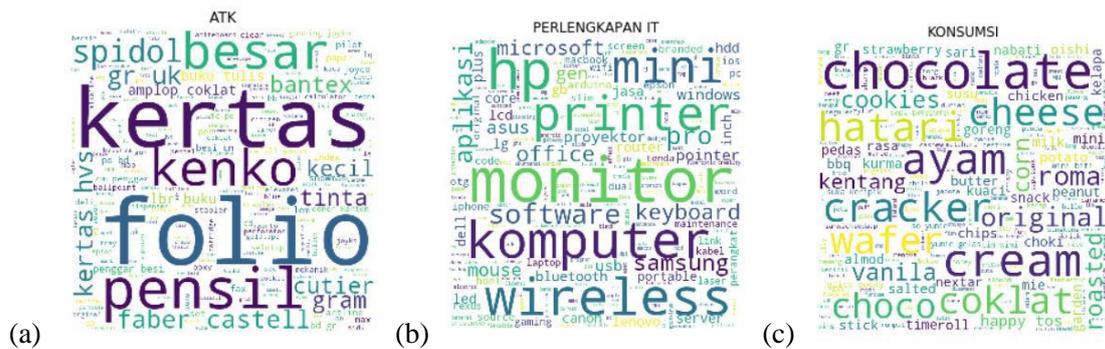
Model klasifikasi yang dibangun akan dievaluasi menggunakan metrics Accuracy dan F1-score yang dihitung menggunakan Persamaan (1) dan (2). Semakin tinggi nilai metrik performa menunjukkan hasil prediksi yang semakin baik.

$$Acc = \frac{TP+TN}{TP+FN+FP+TN} \quad (1)$$

$$F1 = 2 * \frac{Sn * (\frac{TP}{TP+FP})}{Sn + (\frac{TP}{TP+FP})} \quad (2)$$

3. HASIL DAN PEMBAHASAN

Dataset yang digunakan pada penelitian ini terdiri dari 453 data yang terbagi menjadi tiga kelas. Setiap kelas terdiri dari 151 data. Ilustrasi dataset untuk setiap *class* ditunjukkan pada Gambar 2. Pra-pemrosesan data menggunakan library `keras.preprocessing.text` dari Tensorflow. Data yang sudah diubah menjadi teks, diubah menjadi huruf kecil, dan dipecah menjadi token kemudian dibagi menjadi 362 data latih dan 91 data uji menggunakan library `sklearn.model_selection.train_test_split`. Label kelas juga diubah menjadi kategorikal menggunakan library `keras.utils.to_categorical` dari Tensorflow. Hasil dari tahapan pra-pemrosesan ditunjukkan pada Gambar 3(b).

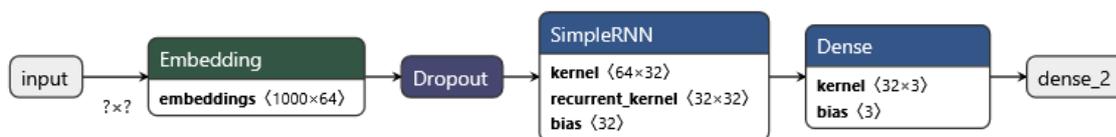


Gambar 2. Visualisasi (a) dataset kategori ATK, (b) dataset kategori IT, (c) dataset kategori konsumsi

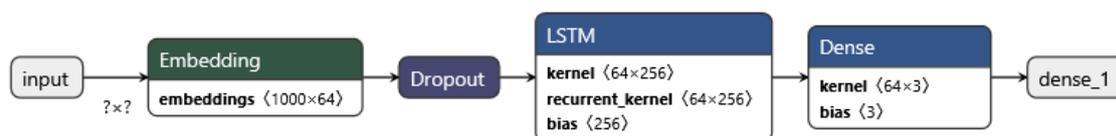
	Text	Label	
(a)	0	Roma Malkist Chocolate	1
	1	Software SPSS	2
	2	Energen Kurma	1
	3	Tujuh Kurma Susu Steril Kurma	1
	4	Jasa pembuatan software	2
(b)	0	roma malkist chocolate	1
	1	software spss	2
	2	energen kurma	1
	3	tujuh kurma susu steril kurma	1
	4	jasa buat software	2

Gambar 3. (a) dataset dalam bentuk teks (b) dataset setelah pra-pemrosesan *lower casing*

Model RNN yang dibangun terdiri dari tiga *layer*. *Layer* pertama adalah *embedding layer* yang digunakan untuk mengubah representasi teks menjadi numerik dengan dimensi tertentu. *Layer* berikutnya adalah vanilla RNN yang memroses input secara sekuensial untuk setiap *timestep*. *Layer* terakhir menggunakan *dense layer* yang menggunakan fungsi softmax karena klasifikasi yang dilakukan adalah klasifikasi multi-class. Arsitektur model ditunjukkan pada Gambar 4.



Gambar 4. Arsitektur Model RNN



Gambar 5. Arsitektur Model LSTM

Serupa dengan model RNN, model LSTM yang dibangun juga terdiri dari tiga *layer*. *Layer* pertama adalah *embedding layer*, *layer* berikutnya adalah LSTM dan *layer* terakhir menggunakan *dense layer* dengan fungsi softmax untuk klasifikasi multi-class. Arsitektur model ditunjukkan pada Gambar 5.

Kedua model dibangun menggunakan library *Keras.layers* dari Tensorflow. Dilakukan *hyperparameter* terhadap kedua model untuk mendapatkan performa model yang paling baik. *Hyperparameter* terbaik yang digunakan untuk kedua model dijabarkan pada Tabel 1.

Hasil pelatihan dan pengujian model RNN ditunjukkan pada Tabel 2. Untuk memeriksa apakah model mengalami *overfitting* atau *underfitting*, ditunjukkan pula nilai akurasi dan loss antara hasil pelatihan dan hasil validasi pada Gambar 6 dan Gambar 7.

Tabel 1. Hyperparameter Model

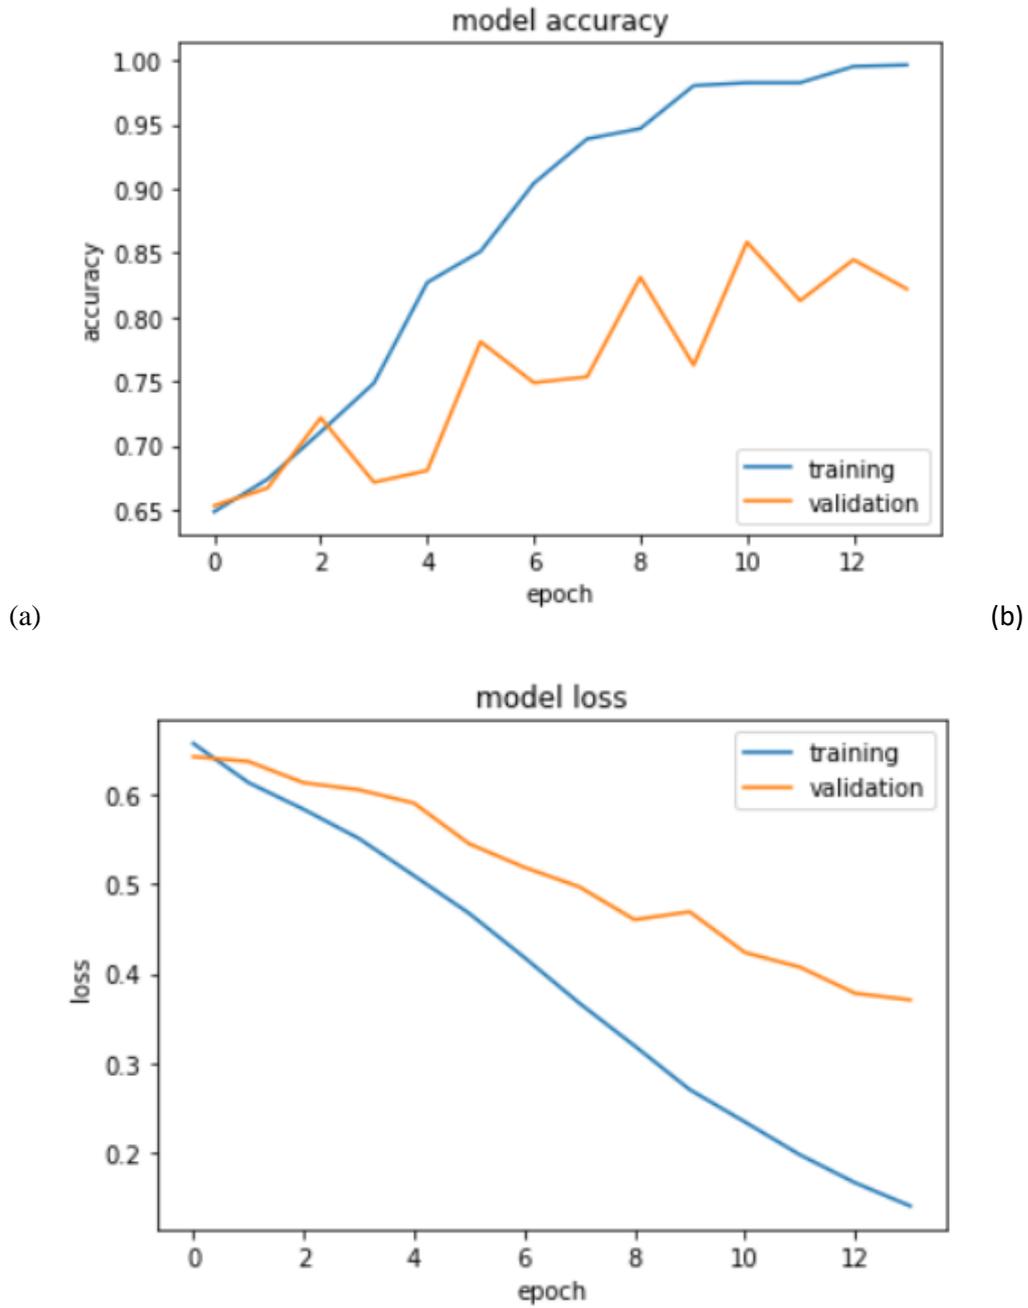
Hyperparameter	RNN	LSTM
Hidden_layer	3	3
Jumlah Neuron	1000-256-3	1000-32-3
Fungsi Aktivasi	Relu	Relu
Optimizer	Adam	Adam
Learning Rate	0,001	0,001
Dropout	0.5	0.3
Epoch	15	15

Tabel 2. Performa Model

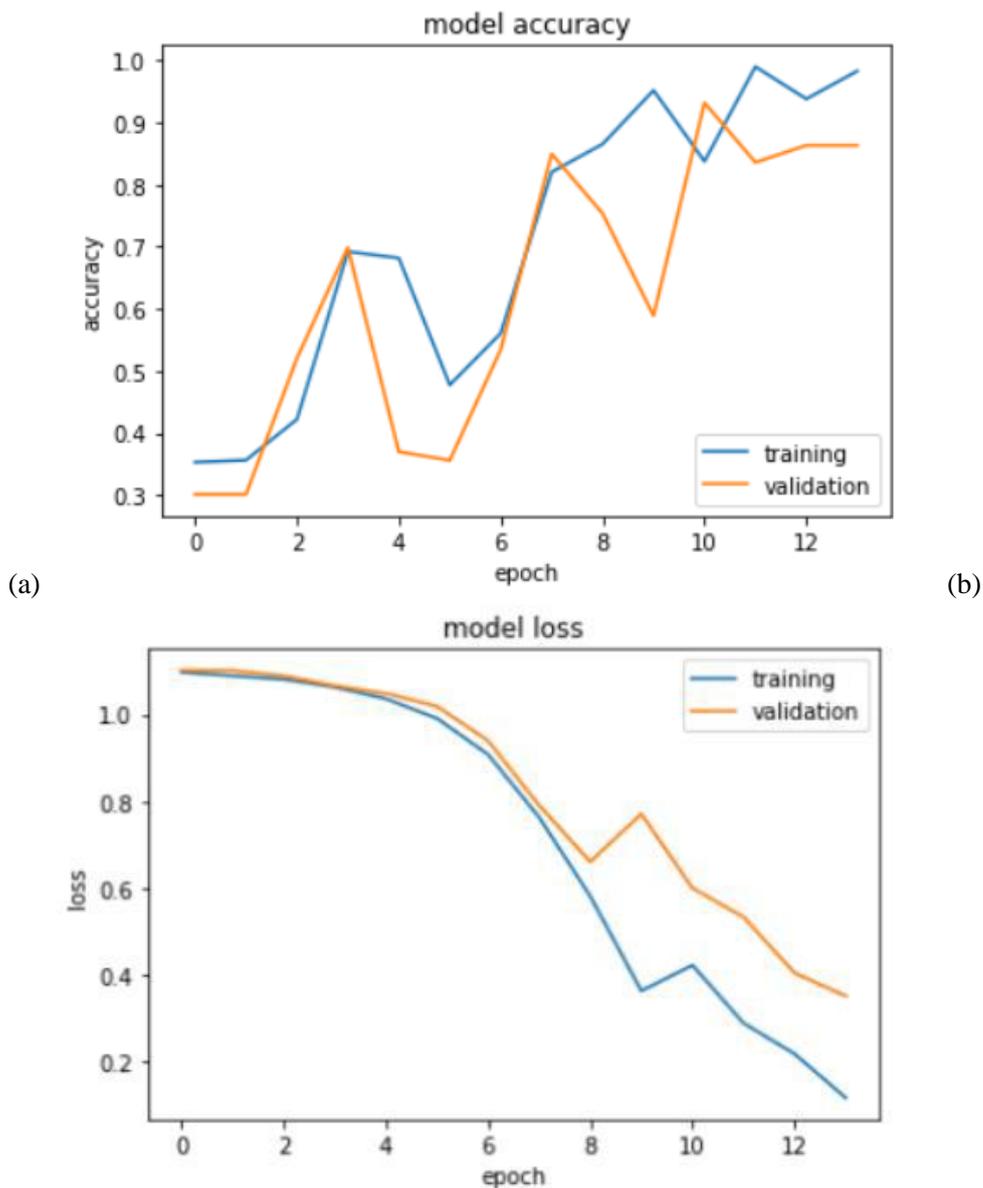
Metriks	RNN	LSTM
Train Accuracy	99,65%	98,27%
Val Accuracy	82,19%	86,30%
Test Accuracy	83%	86%
Rata-rata F1-score	79,19%	88,08%

Pada Tabel 2 dapat dilihat bahwa nilai akurasi LSTM unggul pada validation accuracy dan test accuracy, sedangkan RNN hanya unggul pada nilai *training accuracy*. Hal tersebut menandakan bahwa model RNN mengalami *overfit* sedangkan model LSTM lebih tahan terhadap *overfitting* dibanding RNN. Meskipun sudah dilakukan optimisasi dengan menggunakan *dropout* pada model, pada Gambar 6 dapat dilihat bahwa model masih mengalami *overfitting*. Grafik akurasi untuk data testing memiliki selisih cukup besar dengan data training juga kenaikan penurunnya juga cukup tinggi.

Pada perbandingan nilai rata-rata F1 score LSTM juga unggul dari RNN. Pada LSTM perbedaan nilai test accuracy dengan rata-rata F1 score nya hanya 0,08% saja. Hal tersebut menandakan bahwa pada LSTM performa untuk melakukan klasifikasi pada setiap kategorinya sama besar dan lebih tinggi, sedangkan pada RNN perbedaan antara test *accuracy* dengan rata-rata F1 score nya cukup tinggi, yaitu 3,81%. Hal tersebut menandakan bahwa pada RNN performa untuk melakukan klasifikasi pada setiap kelas tidak seimbang. Kelas yang jumlah datanya lebih banyak cenderung diprediksi benar sehingga nilai akurasinya tinggi.



Gambar 6. Grafik (a) akurasi dan (b) *loss* model RNN



Gambar 7. Grafik (a) akurasi dan (b) *loss* model LSTM

Performa model LSTM menunjukkan hasil klasifikasi yang baik untuk semua kelas dilihat dari nilai F1 score dan nilai akurasi yang relatif serupa. Grafik akurasi dan loss untuk antara pelatihan dan pengujian menunjukkan pola yang serupa. Hal ini menunjukkan bahwa model mampu menangkap pola secara general dan melakukan klasifikasi dengan baik.

Hasil penelitian menunjukkan model LSTM lebih baik dalam melakukan klasifikasi dibandingkan model RNN. Walaupun jumlah parameter pelatihan yang digunakan pada model LSTM lebih sedikit dibanding RNN, performa yang dicapai lebih baik.

Bobot hasil pelatihan model LSTM disimpan sebagai file .h yang kedepannya dapat digunakan untuk diintegrasikan dengan sistem pelaporan perjalanan dinas yang sudah ada dengan menggunakan application programming interface (API). Dengan integrasi ini, pengguna cukup mengunggah bukti pembayaran pada sistem pelaporan, sistem pelaporan akan mengubah gambar pada bukti pembayaran menjadi teks kemudian melakukan pengelompokan menggunakan model klasifikasi dan menampilkan hasilnya ke pengguna.

4. KESIMPULAN DAN SARAN

Dua model klasifikasi menggunakan sekuensial model dikembangkan untuk mengklasifikasikan item pengeluaran ke dalam tiga pos pengeluaran. Model pertama menggunakan arsitektur RNN dan model kedua menggunakan arsitektur LSTM. Kedua arsitektur dipilih karena keunggulannya dalam memproses data dalam bentuk teks dimana urutan kata dalam teks memiliki pengaruh terhadap hasil klasifikasi. Hasil penelitian menunjukkan performa model LSTM lebih baik dibandingkan model RNN. Selain memberikan akurasi yang lebih tinggi, hasil prediksi model LSTM untuk setiap kelas juga berimbang. Model yang sudah dikembangkan dapat digunakan pada sistem pelaporan perjalanan dinas dengan menggunakan *application program interface* untuk membangun sistem pelaporan perjalanan dinas yang terotomasi.

DAFTAR PUSTAKA

- [1] 'PMK No. 113/PMK.05/2012 tentang Perjalanan Dinas Dalam Negeri Bagi Pejabat Negara, Pegawai Negeri, Dan Pegawai Tidak Tetap [JDIH BPK RI]'. <https://peraturan.bpk.go.id/Home/Details/126950/pmk-no-113pmk052012> (accessed Sep. 02, 2022).
- [2] 'Peraturan Menteri BUMN PER-02/MBU/2011 tanggal 05 Agustus 2011 | JDIH Kementerian BUMN'. <https://jdih.bumn.go.id/lihat/PER-02/MBU/2011> (accessed Sep. 02, 2022).
- [3] M. Susanty and H. Nugroho, 'Optical Character Recognition Implementation for Admission System in Universitas Pertamina', *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 11, no. 1, pp. 165–170, 2020, doi: 10.24176/simet.v11i1.3838.
- [4] Susan Li, 'Multi-Class Text Classification with Scikit-Learn', *Towards Data Science*, Feb. 18, 2018. <https://towardsdatascience.com/multi-class-text-classification-with-scikit-learn-12f1e60e0a9f> (accessed Feb. 15, 2023).
- [5] Daniel Rojas Ugalde, 'Using sci-kit learn to categorize personal expenses', *Medium*, Apr. 18, 2019. <https://drojasug.medium.com/using-sci-kit-learn-to-categorize-personal-expenses-de07b6b385f5> (accessed Feb. 15, 2023).
- [6] A. Sherstinsky, 'Deriving the Recurrent Neural Network Definition and RNN Unrolling Using Signal Processing', no. March, 2018, [Online]. Available: <https://www.linkedin.com/in/alexsherstinsky>.
- [7] S. Hochreiter and J. Schmidhuber, 'Long Short-Term Memory', *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/NECO.1997.9.8.1735.
- [8] A. Sherstinsky, 'Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network', *Phys. D Nonlinear Phenom.*, vol. 404, Aug. 2018, doi: 10.1016/j.physd.2019.132306.