

Penerapan *Nonpooling* CNN-LSTM Untuk Prediksi Pemakaian Obat Rumah Sakit

Jason Nathaniel^{#1}, Ventje Jeremias Lewi Engel ^{*2}

[#]Departemen Informatika, Institut Teknologi Harapan Bangsa

Jalan Dipatiukur No. 80-84, Bandung, Indonesia

¹jason.nathaniel1@gmail.com

²ventje@ithb.ac.id

Abstract—Hospital budget to stockpile medicine is the biggest expense (40-50%) and the government with JKN also mandate hospital to give the best service especially on pharmacy stock. Therefore, hospital needs to predict precisely how much it uses medicine to supply the needs. To make such prediction, *Nonpooling* CNN-LSTM will be used and the model performance will be compared with other models such as CNN-LSTM and LSTM. All models will be trained using medicine usage per day of particular medicine of the year 2021 and prediction result will be validated using medicine usage per day of particular medicine of the year 2022. Each model will predict medicine usage for the next 30 and 90 days respectively. Model testing includes three model architectures that combine parameter value such as filter, units, epoch, learning rate as well as Max Pooling layers to produce the lowest error average (RMSE) possible. Based on testing results, the *Nonpooling* CNN-LSTM has the lowest RMSE with 39.63529315 for prediction of the next 30 days and 54.68132489 for prediction of the next 90 days.

Keywords—Pharmacy, prediction, hospital medicine usage, Convolutional Neural Network (CNN), Long-Short Term Memory (LSTM), CNN-LSTM, *Nonpooling* CNN-LSTM.

Abstrak—Anggaran belanja obat di rumah sakit merupakan komponen terbesar dari pengeluaran rumah sakit (40-50%) dan pemerintah juga melalui JKN mewajibkan rumah sakit untuk memberikan pelayanan terbaik terutama sediaan farmasi yang baik. Maka dari itu, perlu adanya prediksi berapa keperluan pemakaian obat di rumah sakit sehingga dapat memenuhi sesuai dengan kebutuhan. Metode yang digunakan untuk melakukan prediksi adalah *Nonpooling* CNN-LSTM dan dibandingkan performanya dengan metode CNN-LSTM serta LSTM. Seluruh model akan dilatih menggunakan data pemakaian sebuah obat per hari di sebuah rumah sakit selama tahun 2021 dan akan dilakukan validasi hasil prediksinya menggunakan data pemakaian per hari selama tahun 2022. Model akan melakukan prediksi pemakaian obat untuk 30 hari dan 90 hari ke depan. Pengujian dilakukan dengan tiga rancangan arsitektur dengan mengombinasikan nilai jumlah filter, units, epoch, learning rate serta jumlah lapisan Max Pooling untuk menghasilkan nilai rata-rata error (RMSE) terendah. Berdasarkan hasil pengujian, model *Nonpooling* CNN-LSTM yang dibangun dapat menghasilkan nilai RMSE terendah sebesar 39.63529315 untuk prediksi 30 hari ke depan dan 54.68132489 untuk prediksi 90 hari ke depan.

Kata Kunci—Farmasi, prediksi, pemakaian obat rumah sakit, Convolutional Neural Network (CNN), Long-Short Term Memory (LSTM), CNN-LSTM, *Nonpooling* CNN-LSTM

I. PENDAHULUAN

Anggaran belanja obat di rumah sakit merupakan komponen terbesar dari pengeluaran rumah sakit dan dapat mencapai hingga 40-50% dari keseluruhan biaya rumah sakit [1]. Hal ini ditambah adanya perubahan Jaminan Kesehatan Nasional (JKN) yang mengacu kepada peraturan Menteri Kesehatan Nomor 72 tahun 2016 tentang Standar Pelayanan Kefarmasian di Rumah Sakit juga menyebutkan bahwa penyelenggara pelayanan kefarmasian di rumah sakit harus menjamin ketersediaan sediaan farmasi, alat kesehatan, dan bahan medis habis pakai yang aman, bermutu, bermanfaat, dan terjangkau membuat rumah sakit harus memastikan kesediaan dan mutu dari obat yang ada di farmasinya [1]. Selain itu, beberapa rumah sakit mengeluhkan bahwa rumus perhitungan pedoman Kementerian Kesehatan terlalu sederhana dan kurang akurat. Maka dari itu penting bagi rumah sakit untuk melakukan perkiraan akan pemakaian obat sehingga dapat selalu memastikan kesediaan, mutu dan lebih memperketat anggaran belanja dengan perhitungan yang lebih akurat.

Untuk melakukan prediksi pemakaian obat di rumah sakit biasanya dilakukan dengan menggunakan model statistika seperti *Exponential Smoothing* dan *Autoregressive Integrated Moving Average* (ARIMA) yang melihat berdasarkan data riwayat pemakaian obat dalam rentang waktu tertentu. Data yang digunakan merupakan data *time-series* riwayat pemakaian obat pada rumah sakit. Namun metode pembelajaran mesin juga sudah mulai banyak dilirik untuk menyelesaikan, terutama model *Artificial Neural Network* (ANN) [2]. Pada penelitian tersebut didapatkan bahwa model *Recurrent Neural Network* (RNN) *Long-Short Term Memory* (LSTM) memiliki performa yang baik, yaitu dengan nilai *Root Mean Squared Error* (RMSE) adalah 40,3 dengan *range data* 1500 sampai 2500.

ANN juga memiliki model lain yang lebih cocok untuk digunakan pada masalah data *time-series* yaitu *Convolutional Neural Network* (CNN). Pada penelitian [3], model CNN digunakan untuk melakukan prediksi menggunakan listrik berdasarkan data *time-series* riwayat penggunaan listrik. CNN dipilih menggunakan *Support Vector Machine* (SVM) untuk mengatasi masalah tersebut karena dapat mengekstrak fitur non linear dengan baik, selain itu CNN juga dapat mengatasi masalah *short range forecast* atau prediksi untuk rentang

waktu yang pendek. Pada penelitian ini [3], model yang digunakan mendapatkan nilai RMSE yaitu 0,698 *range data* 0 sampai 30. Namun CNN memiliki lapisan *Max Pooling* yang dapat menyebabkan informasi yang mungkin dibutuhkan untuk prediksi hilang. Maka dari itu, penelitian [4] menggagaskan sebuah model CNN yang tidak menggunakan lapisan *Max Pooling* untuk melakukan prediksi berdasarkan data *time-series*. Penelitian [4] menggunakan data riwayat kunjungan sebuah halaman web dan mendapatkan kesimpulan bahwa terdapat pengaruh lapisan *Max Pooling* pada model CNN terhadap hasil prediksi. Pada penelitian [4] juga, disarankan untuk menggunakan *Nonpooling* CNN untuk mengolah data *time-series*. Penelitian ini mendapatkan hasil yang lebih baik jika menggunakan CNN tanpa *Max Pooling* yaitu dengan nilai RMSE 2,33453 jika dibandingkan dengan CNN biasa yaitu 2,704774 dengan *range data* untuk keduanya adalah 0 sampai 600. Dari penelitian [3] dan [4], CNN memiliki kelemahan yaitu lapisan *Max Pooling* cenderung menghilangkan informasi yang berguna untuk prediksi dan dependensi yang dapat dipelajari merupakan dependensi pendek sehingga kurang cocok untuk *Long-Term Load Forecasting* atau prediksi untuk rentang waktu yang panjang.

Selain menggunakan CNN, melakukan prediksi untuk data *time-series* juga dapat dilakukan dengan menggunakan model RNN. Pada kasus prediksi data *time-series*, biasanya menggunakan varian RNN, yaitu LSTM. Keunggulan LSTM adalah adanya penyaringan informasi yang akan diekstrak melalui *gate* untuk memperbaharui *cell* yang bersifat sebagai tempat menyimpan informasi. Pada penelitian [5], LSTM digunakan dengan untuk melakukan prediksi harga saham. LSTM dipilih karena pada dasarnya RNN sangat baik untuk menangani masalah mengenai data *time-series* dimana adanya korelasi antara data sebelum dan sesudah. Penelitian ini mendapatkan hasil RMSE yaitu 4,8291 untuk LSTM memiliki *range data* 676,53 sampai 2664,11. Namun LSTM memiliki kelemahan yaitu *overfitting* dan sulit untuk menerapkan *drop out algorithm* untuk menghindari masalah tersebut.

Dapat dilihat bahwa penelitian [6] dan [7] menggunakan gabungan antara CNN dengan LSTM untuk mengatasi masalah di atas. Pada penelitian [6], data yang digunakan adalah data riwayat harga emas, sedangkan pada penelitian [7] digunakan untuk memprediksi konsentration partikel polusi *Particulate Matter* (PM2.5) untuk 24 jam ke depan di kota Beijing. Dengan menggabungkan model CNN dan LSTM, kedua penelitian tersebut dapat memanfaatkan kelebihan CNN untuk melakukan ekstraksi fitur jarak pendek serta kelebihan LSTM yang dapat mempelajari keterkaitan antar titik pada data *time-series* dan melakukan penyaringan data yang lebih relevan terhadap prediksi. Pada penelitian [6], modelnya dapat mempelajari *seasonality* dan *trend* lebih baik jika dibandingkan dengan model CNN dan LSTM saja. Hal ini terlihat dari nilai rata-rata RMSE pada model CNN-LSTM yaitu 0,00767 jika dibandingkan dengan model LSTM yaitu 0,012273 dengan *range data* untuk keduanya adalah 100,50 sampai 113,10. Sedangkan pada penelitian [7], model CNN-LSTM memiliki rata-rata nilai RMSE yang lebih kecil jika dibandingkan den-

gan model LSTM saja (nilai RMSE 3,4954 lebih baik untuk model CNN-LSTM dengan *range data* 0 sampai 994).

Berdasarkan permasalahan dan potensi yang telah dibahas, penelitian ini akan melakukan pemodelan prediksi dengan menggunakan CNN-LSTM tanpa menggunakan lapisan *Max Pooling* atau dapat disebut sebagai model *Nonpooling* CNN-LSTM sebagai alternatif dari kekurangan yang dimiliki oleh pemodelan CNN, serta membandingkan hasil prediksinya dengan model CNN-LSTM. Penelitian ini akan menggunakan data riwayat pemakaian obat dari sebuah rumah sakit di Jakarta, Indonesia untuk melakukan prediksi. Diharapkan pemodelan *Nonpooling* CNN-LSTM yang diajukan dapat menjadi solusi atas permasalahan yang telah dibahas.

II. METODOLOGI

A. Demand Forecasting

Demand atau dalam bahasa Indonesia memiliki arti permintaan atau tuntutan. Permintaan adalah prinsip ekonomi untuk memenuhi kebutuhan dengan membeli barang atau jasa dan bersedia membayar harga yang telah ditetapkan. Dalam lingkup pembahasan rumah sakit, *demand* merupakan kebutuhan atas inventori alat kesehatan maupun obat [1]. Sesuai dengan [1], rumah sakit diberikan arahan untuk melakukan manajemen inventornya dengan melakukan perencanaan yang melihat pemakaian obat selama rentang waktu tertentu. Terdapat 3 metode utama untuk menghitung perencanaan obat pada rumah sakit [1], yaitu metode konsumsi, metode morbiditas dan metode *proxy consumption*.

Metode konsumsi didasarkan pada data konsumsi kesediaan farmasi dan sering dijadikan perkiraan yang paling telat dalam perencanaan sediaan farmasi [1]. Perhitungan metode ini didasarkan atas analisa data konsumsi/penggunaan obat di rumah sakit di periode sebelumnya, ditambahkan dengan stok penyangga, stok waktu tunggu dan sisa stok yang ada. Stok penyangga merupakan stok yang sengaja dilebihkan untuk kejadian-kejadian khusus seperti perubahan pola penyakit yang menyebabkan naiknya jumlah kunjungan. Jumlah stok penyangga sendiri bervariasi, namun biasanya menggunakan antara 10% sampai 20% dari kebutuhan keseluruhan [1].

Metode morbiditas adalah metode perhitungan kebutuhan obat yang didasarkan kepada pola penyakit [1]. Metode ini memperkirakan keperluan obat-obat tertentu berdasarkan dari jumlah obat dan kejadian penyakit umum serta mempertimbangkan pola standar pengobatan untuk penyakit tertentu. Metode ini merupakan metode yang paling rumit dan lama dikarenakan sulitnya data morbiditas yang *valid* terhadap rangkaian penyakit tertentu.

B. Convolutional Neural Network (CNN)

Convolutional neural network (CNN) merupakan ANN yang dapat memproses data yang memiliki topologi seperti *grid* seperti data *time-domain* yang dianggap seperti *grid* 1 dimensi atau data Gambar yang memiliki 2 sampai 3 dimensi (spektrum warna RGB). Data *time-domain* salah satu contohnya adalah data *time-series* merupakan data yang melakukan pengambilan sampel data pada dimensi waktu

tertentu secara berurutan terhadap waktu. Nama *convolutional neural network* menunjukkan bahwa jaringan saraf melakukan operasi secara konvolusi, yang merupakan operasi linear khusus. Jaringan konvolusi adalah NN yang menggunakan operasi konvolusi sebagai ganti dari penerapan matriks umum pada lapisan-lapisannya [9].

Pada umumnya, konvolusi adalah operasi dua fungsi yang bernilai *real*. Dua buah argumen yang diperlukan adalah nilai masukan serta *kernel*. Hasil dari konvolusi yang telah dilakukan disebut *feature map*. Pada umumnya, tipe pembelajaran mesin CNN biasanya digunakan untuk mempelajari data Gambar dengan data masukan multidimensi serta *kernel* merupakan larik multidimensi. Namun pada kasus data *time-series*, operasi konvolusi akan dilakukan terhadap data masukan 1 dimensi dan *kernel* merupakan larik 1 dimensi saja. Proses pelatihan CNN terdiri atas 2 proses besar, yaitu *forward propagation* dan *backward propagation*. nolistsep,leftmargin=0.5cm

- 1) *Forward propagation* berfungsi untuk mencari nilai probabilitas dari data yang diproses dari *layer* pertama hingga *layer* terakhir dan menentukan ke kelas mana suatu data akan dimasukkan. Selain itu, ada juga perhitungan *loss function* yang berfungsi untuk mencari nilai *error*.
- 2) *Backward propagation* berfungsi untuk melakukan optimasi arsitektur CNN dengan melakukan pembaharuan bobot (*weight*) dari hasil perhitungan pada proses *forward propagation* sebagai masukan. Proses ini dilakukan dari *layer* terakhir sampai *layer* pertama.

Pada penelitian ini, karena data yang dimasukkan merupakan sebuah data *time-series* yang membentuk sebuah sekuens, digunakan operasi konvolusi yang bersifat satu dimensi. Perbedaan operasi konvolusi pada matriks 1 dimensi dan 2 dimensi ada di pergerakan *kernel*, dimana pada matriks 2 dimensi pergerakan *kernel* ke samping dan ke bawah, sedangkan pada matriks 1 dimensi pergerakan hanya ke samping mengikuti sekuens waktu dari data. Transformasi masukan yang sama dilakukan pada setiap *data patch*, pola yang dipelajari pada posisi tertentu dalam sebuah data nantinya dapat dikenali pada posisi yang berbeda. Gambar 1 menunjukkan Gambaran dari operasi konvolusi 1 dimensi, dimana pergerakan *kernel* ke arah samping kanan berdasarkan dimensi waktu [12].

C. Long-Short Term Memory (LSTM)

Long-Short Term Memory (LSTM) adalah model versi perbaikan dari *Recurrent Neural Network* (RNN) yang lebih baik karena LSTM dapat menyelesaikan masalah RNN yaitu *Vanishing* dan *Exploding gradient* serta kekurangannya untuk mengingat serta melupakan informasi dari masukan sekuens [13]. LSTM memiliki lapisan *state* (keadaan) yang berperan untuk menyimpan informasi yang dapat digunakan pada lapisan berikutnya. Lapisan lain adalah *gates* (gerbang) yang berfungsi sebagai penentu mengenai informasi untuk diingat atau dilupakan. Kemudian fungsi aktivasi akan digunakan untuk membantu model jaringan saraf tiruan mempelajari pola kompleks pada data. Gambar 2 merupakan contoh Gambaran




Fig. 1. Contoh operasi konvolusi pada matriks satu dimensi [12]




Fig. 2. Contoh Gambaran arsitektur LSTM.

arsitektur LSTM yang menggunakan *tanh* sebagai fungsi aktivasinya. LSTM sendiri memiliki 3 mekanisme utama, antara lain:

- 1) *Output control* merupakan banyak *neuron* yang berpengaruh terhadap keluaran sebelumnya dan keadaan yang sekarang.
- 2) *Memory control* merupakan banyak dari keadaan sebelumnya yang akan dilupakan pada keadaan sekarang.
- 3) *Input control* merupakan banyak dari keluaran sebelumnya dan keadaan sekarang yang akan dipertimbangkan untuk keadaan berikutnya.

D. CNN-LSTM

CNN-LSTM merupakan metode yang menggabungkan lapisan konvolusi dari CNN serta jaringan LSTM untuk melakukan prediksi [6]. Penggabungan kedua model ini bertujuan untuk memanfaatkan kemampuan CNN untuk mengidentifikasi *short-term dependency* serta kemampuan memori dari sel LSTM. Gambar 3 merupakan contoh arsitektur dari CNN-LSTM.

E. Nonpooling CNN-LSTM

CNN biasanya memiliki 2 bagian utama yaitu lapisan konvolusi dan lapisan *Max Pooling*. *Nonpooling* CNN meru-




Fig. 3. Contoh arsitektur CNN-LSTM [6]

pakan arsitektur CNN yang tidak memiliki lapisan *Max Pooling* sehingga arsitektur CNN tersebut hanya memiliki lapisan konvolusi saja [4]. Istilah *Nonpooling* sendiri berarti Non Max Pooling atau tanpa *Max Pooling* diambil dari istilah yang digunakan pada penelitian [4]. Sehingga *Nonpooling* CNN-LSTM adalah arsitektur CNN-LSTM hanya saja pada bagian CNN arsitektur tersebut tidak memiliki lapisan *Max Pooling* sama sekali. Gambar 8 merupakan contoh gambaran arsitektur *Nonpooling* CNN-LSTM.

F. Perancangan Sistem

1) Kerangka Pemikiran

Gambar 4 adalah kerangka pemikiran dari metode yang diusulkan untuk melakukan prediksi pemakaian obat rumah sakit. *Indicators* adalah variabel yang akan memengaruhi hasil dari metode utama. Indikator dinilai pada saat pengujian CNN-LSTM dimulai. Setelah dilakukan pemodelan menggunakan indikator yang telah ditentukan, model akan dievaluasi akurasi dengan membandingkan hasil prediksi model dengan data asli untuk dihitung RMSEnya. Indikator yang diobservasi selama penelitian ini antara lain sebagai berikut.

- 1) *Filters* merupakan banyak *feature map* yang akan dihasilkan dalam satu kali konvolusi pada *CNN* serta menentukan banyak *kernel* untuk memproses *feature map*.
- 2) *Max Pooling Layer* merupakan lapisan pada *CNN* yang berfungsi untuk mengambil nilai maksimum dari hasil konvolusi dan akan menghasilkan lapisan baru dengan ukuran yang lebih kecil. Pengambilan nilai maksimum ini berdasarkan ukuran *kernel* yang telah ditentukan sebelumnya.
- 3) *Units* merupakan konfigurasi jumlah *hidden neuron* yang akan dihitung pada arsitektur *LSTM*.
- 4) *Epoch* merupakan jumlah iterasi selama proses pelatihan berlangsung.
- 5) *Learning rate* merupakan seberapa besar nilai hasil pelatihan dari satu iterasi akan mempengaruhi hasil iterasi berikutnya.

2) Flowchart Global

Penelitian ini akan menggunakan CNN-LSTM dengan dan tanpa lapisan *Max Pooling* untuk melakukan prediksi pemaka-




Fig. 4. Kerangka Pemikiran




Fig. 5. Flowchart urutan proses global

ian obat. Setelah dilakukan pelatihan, diharapkan arsitektur yang dibangun dapat melakukan prediksi pemakaian obat dengan tepat. Hasil estimasi pemakaian obat kemudian akan diuji kembali dengan *dataset*. Gambar 5 menunjukkan urutan proses global pada penelitian ini dalam bentuk *flowchart*.

3) Dataset

Dataset untuk penelitian ini diambil dari sebuah perusahaan Sistem Informasi Manajemen Rumah Sakit (SIMRS) yang ada di Jakarta, Indonesia. Data yang akan digunakan untuk membangun model merupakan data pemakaian obat pada rumah sakit tertentu selama tahun 2021. Pembagian data latih dan data pengujian sebagai berikut, data pengujian berupa data 30 hari terakhir pada tahun 2021, selain itu akan digunakan untuk pelatihan. Data akan dilakukan pembagian kembali terlebih dahulu di awal setiap 30 hari dengan bergeser 1 harinya kemudian dimasukkan ke dalam larik 2 dimensi. Kemudian hasil prediksi dari model akan dibandingkan dengan data pemakaian obat 90 hari pertama tahun 2022 untuk dihitung errornya dalam bentuk RMSE. Tabel I merupakan rincian pembagian dari *dataset* yang akan digunakan.

TABLE I
PERINCIAN PENGGUNAAN *Dataset* UNTUK IMPLEMENTASI

Dataset	Total	Pelatihan	Pengujian
Pemakaian tahun 2021	365	335	30
Pemakaian tahun 2022	90	-	-

III. HASIL DAN PEMBAHASAN

A. Hasil Pengujian

Pengujian dilakukan dengan mengombinasikan seluruh nilai *filter*, *units*, *epoch* dan *learning rate* untuk 30 dan 90 hari ke depan pada tiga bah arsitektur yang berbeda berdasarkan jumlah lapisan *Max Pooling* yang ada pada masing-masing arsitektur. Jumlah kombinasi untuk model CNN-LSTM adalah 648 buah dan sebagai pembanding yaitu model LSTM memiliki kombinasi sebanyak 72 buah. Pada masing-masing arsitektur (Gambar 6 hingga 8) diujikan 108 kombinasi parameter *filter*, *units*, *epoch* dan *learning rate* untuk 30 dan 90 hari ke depan, akan dicari kombinasi yang menghasilkan nilai RMSE terkecil. Tabel II merupakan rangkuman parameter seluruh model. Setiap pengujian yang dilakukan akan dihitung metrik penilaian yang dijadikan sebagai tolak ukur penilaian sebuah model. Pada penelitian ini digunakan nilai *error* RMSE untuk mengevaluasi sebuah model. RMSE dihitung dengan mencari rata-rata selisih dari hasil prediksi dengan data validasi. Tabel III merupakan ringkasan nilai RMSE keseluruhan pengujian berdasarkan arsitektur yang diuji.

Arsitektur CNN-LSTM memiliki performa rata-rata yang lebih baik jika dibandingkan dengan model LSTM saja. Hal ini dapat dilihat dari nilai rata-rata RMSE dan nilai minimum RMSE yang lebih kecil. Akan tetapi, model LSTM memiliki nilai maksimum RMSE yang lebih kecil jika dibandingkan dengan arsitektur CNN-LSTM. Hal ini dapat terjadi karena adanya pemrosesan oleh lapisan CNN terlebih dahulu sebelum diproses oleh LSTM. Sehingga ketika lapisan CNN tidak dapat mempelajari data dengan baik, maka lapisan LSTM akan mempelajari *feature map* yang kurang baik. Sedangkan pada model LSTM saja, model langsung mempelajari dari data bukan dari *feature map* yang dihasilkan oleh lapisan CNN.

Nonpooling CNN-LSTM (arsitektur 3) memiliki nilai maksimum RMSE paling medekati jika dibandingkan dengan model LSTM saja pada *forecasting horizon* 30 hari, yaitu 131.1586901 untuk *Nonpooling CNN-LSTM* dan 129.5106816 untuk model LSTM saja. Hal ini dapat terjadi karena disaat nilai parameter yang sedikit menyebabkan model kurang belajar, *Nonpooling CNN-LSTM* tidak memiliki lapisan *Max Pooling* sehingga lebih banyak pola yang dapat dipelajari oleh model.

CNN-LSTM (arsitektur 1 dan 2) jika dibandingkan dengan *Nonpooling CNN-LSTM* (arsitektur 3) adalah sensitifitas model terhadap perubahan nilai parameter. *Nonpooling CNN-LSTM* terlihat lebih sensitif terhadap perubahan nilai parameter, hal ini dapat dilihat pada Tabel III dimana *Nonpooling CNN-LSTM* memiliki nilai rata-rata RMSE yang lebih besar. Akan tetapi *Nonpooling CNN-LSTM* memiliki kelebihan jika dibandingkan dengan CNN-LSTM dimana saat nilai parameter yang kecil (terutama nilai parameter *learning rate*), nilai maksimum RMSE yang dihasilkan lebih kecil seperti dapat dilihat pada Tabel III baik untuk *forecasting horizon* 30 hari maupun 90 hari.

Overfitting terjadi pada model dengan nilai parameter tinggi terutama pada jumlah *filter* yang tinggi. Hal ini Membuat model terlalu banyak mempelajari pola pada data latih sehingga kurang performanya kurang baik pada saat melakukan prediksi. Selain itu, kasus *overfitting* banyak terjadi pada model *Nonpooling CNN-LSTM* (arsitektur 3) dibandingkan dengan model CNN-LSTM (arsitektur 1 dan 2). Hal ini terjadi karena lapisan CNN pada model *Nonpooling CNN-LSTM* terlalu banyak belajar pola data yang disebabkan tidak adanya lapisan *Max Pooling*.

Untuk keseluruhan hasil pengujian, nilai *error* ketika melakukan prediksi 30 hari ke depan lebih kecil dibandingkan dengan ketika melakukan prediksi 90 hari ke depan. Hal ini dikarenakan data hasil prediksi akan digunakan untuk melakukan prediksi kembali. Pada rentang 90 hari, semakin banyak data hasil prediksi yang digunakan untuk memprediksi kembali maka hasilnya nilai *error* menjadi lebih tinggi. Selain itu, seluruh model memiliki kenaikan nilai RMSE yang cukup tinggi ketika nilai parameter *learning rate* = 0.001 namun perlahan kembali menurun saat nilai parameter lain mulai bertambah. Kombinasi nilai parameter terhadap nilai parameter *learning rate* terlihat sangat berpengaruh terhadap nilai RMSE.

TABLE II
RANGKUMAN PARAMETER PENGUJIAN

Metode	Parameter Pengujian	Nilai yang Diujikan
CNN-LSTM	Filter	16, 32, 64, 128
	Units	100, 200, 300
	Epoch	100, 150, 200, 250
	Learning rate	0.001, 0.01, 0.1
	Lapisan Max Pooling	2, 1, 0
	Forecasting Horizon	30 hari, 90 hari
LSTM	Units	100, 200, 300
	Epoch	100, 150, 200, 250
	Learning rate	0.001, 0.01, 0.1




Fig. 6. Arsitektur CNN-LSTM dengan 2 lapisan *Max Pooling*




Fig. 8. Arsitektur CNN-LSTM tanpa lapisan *Max Pooling*

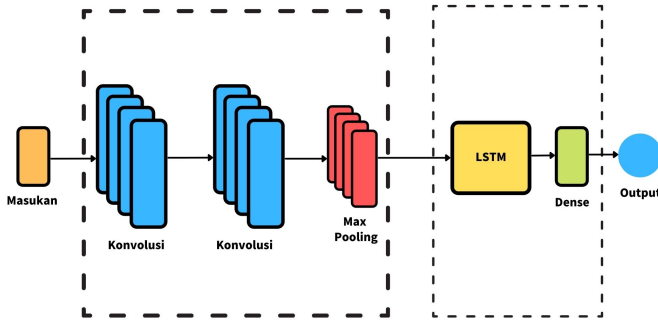


Fig. 7. Arsitektur CNN-LSTM dengan 2 lapisan *Max Pooling*

TABLE III
RINGKASAN KESELURUHAN HASIL PENGUJIAN

Model	Forecasting Horizon	RMSE		
		Min	Max	Average
Arsitektur 1	30 hari	41.94	159.96	59.88
	90 hari	56.33	161.45	73.88
Arsitektur 2	30 hari	39.92	131.36	59.86
	90 hari	56.46	133.70	72.34
Arsitektur 3	30 hari	39.63	130.20	60.68
	90 hari	54.68	131.158	73.09
LSTM	30 hari	60.60	123.27	82.23
	90 hari	75.50	129.51	91.59

IV. SIMPULAN

Secara umum, dapat diambil kesimpulan bahwa kombinasi yang tepat dari jumlah *filter*, *units*, *learning rate*, *epoch* serta lapisan *Max Pooling* memiliki pengaruh terhadap kemampuan sistem untuk mempelajari data. Terutama jumlah *filter* sangat berpengaruh terhadap terjadinya *overfitting* pada model *Nonpooling* CNN-LSTM. Selain itu nilai parameter *learning rate* juga berpengaruh terhadap kombinasi nilai parameter lain yang dipilih. Jika nilai parameter *learning rate* terlalu kecil, maka perlu dikompensasikan oleh nilai parameter lain yang lebih tinggi. Namun, dari pembahasan hasil arsitektur tersebut, untuk menentukan keputusan pengambilan hasil model yang terbaik, pada dasarnya bergantung dari sudut pandang kepada hasil pengujian. Model yang terbaik tidak dapat ditentukan

hanya dalam sebuah kesimpulan tunggal karena ada beberapa hal yang dapat dipertimbangkan lebih lanjut sebelum menyatakan suatu model merupakan model yang terbaik. Hal yang perlu diperhatikan dalam menentukan hasil prediksi model merupakan prediksi setiap harinya. Jika dibutuhkan rata-rata penggunaan selama 1 bulan maka akan lebih baik untuk melihat rata-rata dari keseluruhan hasil prediksi model.

Dalam penelitian lanjutan, dapat mempertimbangkan untuk melakukan dekomposisi sinyal CEEMDAN pada data obat dengan karakteristik tingkat fluktuasi cukup tinggi seperti pada penelitian [5]. Metode dekomposisi sinyal CEEMDAN pada penelitian [5] dapat membagi-bagi data atau sinyal fluktuasi pemakaian obat pada data *time-series* menjadi beberapa bagian sesuai tingkat fluktuasinya dari rendah ke tinggi. Dengan melakukan metode dekomposisi sinyal CEEMDAN, model mungkin dapat menghasilkan performa lebih baik serta lebih general dapat diterapkan kepada data obat lain karena model dapat mempelajari tingkat fluktuasi yang berbeda pada data secara terpisah.

REFERENCES

- [1] Kementerian Kesehatan Republik Indonesia. *Pedoman Penyusunan Rencana Kebutuhan Obat dan Pengendalian Persediaan Obat di Rumah Sakit*. 2019.
- [2] S. Kaushik, A. Choudhury, P. K. Sheron, N. Dasgupta, S. Natarajan, L. A. Pickett, and V. Dutt, "AI in Healthcare: Time-series Forecasting Using Statistical, Neural, and Ensemble Architectures," in *Frontiers in Big Data*, vol. 3, 2020..
- [3] S., Chan, Oktavianti, I., and Puspita, V., "A Deep Learning CNN and AI-tuned SVM for Electricity Consumption Forecasting: Multivariate Time Series Data," in *IEEE 10th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*, 2019.
- [4] S. Liu, H. Ji, and M. C. Wang, "Nonpooling Convolutional Neural Network Forecasting for Seasonal Time Series with Trends," in *IEEE Transactions on Neural Networks and Learning Systems*, vol. 31, no. 8, pp. 2879–2888, 2020.
- [5] J. Cao, Z. Li, and J. Li, "Financial Time Series Forecasting Model Based on CEEMDAN and LSTM," in *Physica A: Statistical Mechanics and its Applications*, vol. 519, pp. 127–139, 2019.
- [6] I. E. Livieris, E. Pintelas, and P. Pintelas, "A CNN-LSTM Model For Gold Price Time-series Forecasting," in *Neural Computing and Applications*, vol. 32, no. 23, pp. 17351–17360, 2020.
- [7] T. Li, M. Hua, and X. Wu, "A Hybrid CNN-LSTM Model for Forecasting Particulate Matter (PM2.5)," in *IEEE Access*, vol. 8, pp. 26933–26940, 2020.
- [8] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Pearson, 2008.

- [9] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning, An MIT Press book*, 2016.
- [10] J. Heaton, *Artificial Intelligence for Humans: Deep Learning and Neural Networks*, Volume 3, 1st ed. CreateSpace Independent Publishing Platform, 2015.
- [11] S. Khan, H. Rahmani, Syed Afaq Ali Shah, M. Bennamoun, "A Guide to Convolutional Neural Networks for Computer Vision", 1st ed, Gérard Medioni and Sven Dickinson, Ed. California: Morgan and Claypool, pp. 45, 53, 56, 67-80, 2018.
- [12] F. Chollet, *Deep Learning with Python*, 1st ed. New York: Manning Publications, 2018.
- [13] P. Rivas, *Deep Learning for Beginners: A beginner's guide to getting up and running with deep learning from scratch using Python*. Packt Publishing Ltd, 2020.
- [14] D. Rothman, *Artificial Intelligence by Example: Acquire Advanced AI, Machine Learning, and Deep Learning Design Skills*, 2nd ed. Birmingham: Packt Publishing Limited, 2020, pp.215-217.
- [15] Jeff Heaton, in *Artificial Intelligence for Humans: Deep Learning and Neural Networks*, Volume 3, CreateSpace Independent Publishing Platform, 2015
- [16] J., Brownlee, *Long Short-Term Memory Networks With Python*. Machine Learning Mastery, 2017.
- [17] Statistical Office of the European Union, *Glossary:Forecast*, 2014.
- [18] Statistical Office of the European Union, *Glossary:Forecast horizon*, 2014.

Jason Nathaniel, menerima gelar Sarjana Komputer dari Institut Teknologi Harapan Bangsa (ITHB) Bandung tahun 2022. Saat ini aktif sebagai *Backend Developer* di Periksa.id. Minat penelitian pada bidang *machine learning* dan *data science*.

Ventje Jeremias Lewi Engel, menerima gelar Sarjana Teknik dari Institut Teknologi Bandung (ITB) pada tahun 2012 dan Magister Teknik dari Institut Teknologi Bandung pada tahun 2013. Aktif sebagai dosen Institut Teknologi Harapan Bangsa (ITHB). Minat penelitian pada bidang *Deep Learning*, *Cyber-security* dan *Malware Analysis*.