

Deep Learning Analysis for Predicting the Approval Time of Clinical Practice Guidelines (CPG) Based on Historical Administrative Data

Yuliana Pertiwi¹, **Musli Yanto²**, dan **Billy Hendrik³**

^{1,2,3}Ilmu Komputer, UPI YPTK Padang

^{1,2,3}Jl Raya Lubuk Begalung, kota Padang , 25145

E-mail: yulianapertiwi654@gmail.com ¹, musli_yanto@upiypk.ac.id², billy_hendrik@upiypk.ac.id³

ABSTRACT

This study aims to predict the processing time of the approval of Clinical Practice Guidelines (CPG), which exhibits considerable variation in duration and is difficult to predict accurately. In addition, the utilization of historical hospital administrative data to build effective predictive models for estimating the duration of the CPG approval process has not yet been optimized. Therefore, this research seeks to develop a predictive model to estimate the processing time of the CPG approval process. The proposed approach employs deep learning techniques by leveraging historical administrative data as the basis for modeling. The methods applied include K-Means Clustering, Decision Tree, and Long Short-Term Memory (LSTM). K-Means Clustering is used to group CPG data based on similar administrative characteristics, enabling the identification of approval time patterns. Subsequently, the Decision Tree method is utilized to analyze the relationships among variables and to generate classification rules that explain the factors influencing the duration of the CPG approval process. Meanwhile, LSTM serves as the primary model for predicting the processing time of CPG approval. This study uses 487 CPG records collected over the period from 2020 to 2024. The evaluation results indicate that the K-Means Clustering method achieves an accuracy rate of 87,36%. This level of accuracy reflects strong clustering performance and a high degree of conformity with actual conditions, indicating that the results are suitable to be used as a foundation for further analysis in the classification and prediction stages of the CPG approval process.

Keywords: LSTM, K-Means, Decision Tree, CPG, Time Prediction

Analisis Deep Learning dalam Prediksi Waktu Pengesahan Panduan Praktik Klinik (PPK) Berdasarkan Data Historis Administratif

ABSTRAK

Penelitian ini bertujuan untuk memprediksi waktu tempuh dalam proses pengesahan Panduan Praktik Klinik (PPK) yang menunjukkan variasi durasi dan sulit untuk diprediksi secara akurat. Selain itu, pemanfaatan data historis administratif rumah sakit dalam membangun model prediktif yang baik dalam memperkirakan durasi proses pengesahan PPK masih belum optimal. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan an model prediktif guna memperkirakan waktu tempuh proses pengesahan PPK. Pendekatan yang digunakan adalah deep learning dengan memanfaatkan data historis administratif sebagai dasar pemodelan. Metode yang diterapkan meliputi K-Means Clustering, Decision Tree, dan Long Short-Term Memory (LSTM). K-Means Clustering digunakan untuk mengelompokkan data PPK berdasarkan karakteristik administratif yang serupa sehingga pola pengelompokan waktu pengesahan dapat diidentifikasi. Selanjutnya, Decision Tree dimanfaatkan untuk menganalisis hubungan antarvariabel serta menghasilkan aturan klasifikasi yang menjelaskan faktor-faktor yang memengaruhi durasi pengesahan PPK. Adapun LSTM digunakan sebagai model utama untuk melakukan prediksi waktu tempuh pengesahan PPK. Penelitian ini menggunakan 487 data PPK yang dikumpulkan selama periode tahun 2020 hingga 2024. Hasil evaluasi menunjukkan bahwa metode K-Means Clustering menghasilkan tingkat akurasi sebesar 87,36%. Nilai akurasi tersebut mengindikasikan kinerja pengelompokan yang baik dan tingkat kesesuaian yang tinggi terhadap kondisi aktual, sehingga hasilnya layak digunakan sebagai dasar analisis lanjutan pada tahap klasifikasi dan prediksi waktu pengesahan PPK.

Kata Kunci: LSTM, K-Means, Decision Tree, PPK, Prediksi Waktu

1. PENDAHULUAN

Perkembangan teknologi informasi telah membawa perubahan yang sangat signifikan dalam administrasi kesehatan. Perubahan ini dapat dilihat bagaimana sistem administrasi manual berkembang menjadi sistem digital, yang mana perkembangannya ini sangat membantu dalam pengelolaan data pasien, rekam medis serta manajemen pengelolaan data rumah sakit secara cepat dan akurat. Peningkatan teknologi informasi dalam pengelolaan. Administrasi kesehatan ini juga bermanfaat dalam mendukung proses pengambilan keputusan berbasis data, serta dapat menciptakan layanan yang lebih transparan dan berkualitas, selain itu sistem informasi dalam dunia kesehatan telah menjadi bagian penting dalam perubahan sistem pada sektor kesehatan, terutama dalam era digital yang semakin berkembang. Beberapa implementasi teknologi pada administrasi kesehatan masih menghadapi sejumlah tantangan mendasar antara lain keterbatasan infrastruktur digital serta rendahnya keterampilan tenaga kesehatan dalam memanfaatkan teknologi. Tentunya permasalahan yang terjadi ini akan menghambat proses penerapan teknologi informasi pada sektor kesehatan dan. Tidak hanya itu, tentunya kualitas pelayanan juga akan mengalami penurunan apabila proses atau alurnya tidak dilakukan secara komputerisasi. Penelitian selanjutnya dilakukan oleh tentang mengklasifikasi tingkat waktu keterlambatan (*delay*) yang disebabkan oleh kegagalan sistem onboard pada kereta. Variabel seperti lokasi kerusakan, komponen sistem, fenomena kesalahan, digunakan sebagai fitur input. Teknologi informasi memiliki potensi besar untuk membawa perubahan signifikan dalam pengelolaan rumah sakit dan pelayanan kesehatan secara keseluruhan.

Salah satu solusi teknologi yang telah diterapkan di banyak rumah sakit di Indonesia adalah Sistem Informasi Manajemen Rumah Sakit (SIMRS). SIMRS adalah sebuah *platform* digital yang digunakan untuk mengelola berbagai aspek operasional rumah sakit, mulai dari pendaftaran pasien, rekam medis elektronik, manajemen keuangan, hingga pengelolaan sumber daya rumah sakit seperti obat-obatan dan peralatan medis. Tantangan yang dihadapi dalam implementasi SIMRS ini juga mempengaruhi kualitas pelayanan publik. Salah satu tantangan utama, yaitu infrastruktur yang tidak memadai sehingga dapat menyebabkan gangguan dalam proses pelayanan kesehatan, hal ini bisa menyebabkan keterlambatan dalam proses administrasi atau bahkan kegagalan dalam pengelolaan data medis pasien. Akibatnya, pelayanan kepada masyarakat bisa terganggu, yang mengarah pada pelayanan mutu rumah sakit.

Keterbatasan ini juga berdampak pada pengesahan PPK (Panduan Praktik Klinis). Dalam konteks pelayanan publik dan peningkatan mutu rumah sakit keterlambatan ini bisa mengurangi kepercayaan masyarakat terhadap rumah sakit dan sistem kesehatan secara keseluruhan. Strategi kebijakan yang mendorong percepatan digitalisasi agar permasalahan yang berkaitan dengan proses administratif rumah sakit, khususnya dalam manajemen dan prosedur pengesahan Panduan Praktik Klinis (PPK) dapat diatasi dan tidak semakin sulit dikelola oleh staf yang bersangkutan. Permasalahan ini berhubungan langsung dengan standar Akreditasi RS versi Komite Akreditasi menyebutkan bahwa standar Peningkatan Mutu dan Keselamatan Pasien rumah sakit harus membuat standar asuhan klinik, hal ini bertujuan sebagai standarisasi dari proses asuhan klinik di rumah sakit, memberikan asuhan klinik tepat waktu, dan menjaga keefektifan sumber daya secara efisien serta meningkatkan mutu pelayanan tinggi melalui cara-cara *evidence-based* sebagai standar asuhan kliniknya adalah Panduan Praktek Klinis (PPK) dan *clinical pathway*, kedua hal tersebut juga berfungsi untuk memastikan adanya integrasi dan koordinasi dari pelayanan dengan menggunakan sumber daya secara efektif dan efisien. Berdasarkan Peraturan Menteri Kesehatan Republik tentang Pedoman Praktik Klinis, penyusunan PPK harus memperhatikan standar profesi, serta kondisi nyata rumah sakit, termasuk ketersediaan tenaga, sarana, dan sistem penunjang. Sementara itu, *Clinical Practice Guidelines* (CPG) di berbagai negara telah menjadi rujukan utama dalam memastikan pelayanan kesehatan berbasis bukti dapat diterapkan secara konsisten. Dengan adanya PPK dan *clinical pathway*, staff medis diharapkan mampu memberikan pelayanan yang maksimal dan dapat dipertanggungjawabkan. Selain memberikan pelayanan yang baik tentunya PPK juga dapat memudahkan tenaga medis dalam mengambil keputusan klinis yang sesuai standar tanpa mengurangi aspek keselamatan pasien. Selain itu, implementasi pedoman yang konsisten dapat meningkatkan kepercayaan masyarakat terhadap mutu pelayanan rumah sakit.

Walaupun penelitian terdahulu menunjukkan keberhasilan metode *machine learning* dan *deep learning* dalam mendukung proses klasifikasi, prediksi, dan pengambilan keputusan di berbagai sektor, namun di lapangan masih terdapat kasus yang belum teratasi, khususnya dalam konteks implementasi Panduan Praktik Klinis (PPK). Di RSUP Dr. M. Djamil Padang, permasalahan utama yang sering muncul adalah keterlambatan dalam proses pengesahan PPK. Keterlambatan ini berdampak langsung terhadap efektivitas pelayanan, karena dokumen PPK berfungsi sebagai standar baku dalam pemberian asuhan klinik yang berbasis bukti dan terintegrasi. Jika proses pengesahan mengalami penundaan, maka standar pelayanan yang seharusnya dapat segera diterapkan

menjadi tertunda, sehingga dapat menurunkan mutu pelayanan rumah sakit secara keseluruhan.

Permasalahan tersebut juga berkaitan erat dengan kompleksitas administrasi rumah sakit, keterbatasan koordinasi antar-unit, serta belum optimalnya sistem digital dalam mendukung kelancaran alur pengesahan dokumen PPK. Oleh karena itu, diperlukan suatu pendekatan analitik yang tidak hanya mampu mengolah data dalam jumlah besar dan kompleks, tetapi juga mampu melakukan prediksi secara akurat terhadap estimasi waktu tempuh dalam proses pengesahan PPK. Pendekatan *deep learning*, khususnya dengan memanfaatkan model *Long Short-Term Memory* (LSTM), menjadi solusi yang relevan mengingat kemampuan metode ini dalam menganalisis data sekuensial dan memprediksi kejadian berikutnya berdasarkan pola historis. *Dataset* yang digunakan bersumber dari data historis administratif di RSUP Dr. M. Djamil Padang, yang mencakup informasi terkait proses, waktu, serta tahapan pengesahan PPK. Data tersebut menjadi dasar penting dalam membangun dan melatih model prediktif sehingga hasil yang diperoleh sesuai dengan konteks nyata yang dihadapi rumah sakit. Maka penelitian ini dilakukan untuk memprediksi waktu tempuh yang akan digunakan pada prediksi pengesahan panduan praktik klinik yang pastinya memiliki kontribusi penting dalam memaksimalkan proses administrasi

2. RUANG LINGKUP

Berdasarkan latar belakang serta rumusan masalah yang telah ditetapkan, diperlukan penetapan batasan masalah mengenai waktu tempuh pengesahan PPK di RSUP Dr. Mdjamil Padang agar memiliki fokus terhadap tujuan yang hendak dicapai.

Penelitian ini akan memprediksi waktu tempuh proses pengesahan PPK di RSUP M. Djamil Padang dengan pendekatan *deep learning*. Penelitian ini menggunakan *dataset* dari data *historis* administratif pengesahan Panduan Praktik Klinis (PPK) yang bersumber dari RSUP Dr. M. Djamil Padang pada periode 2020–2024.

Penelitian ini menggunakan delapan variabel yang menjadi pedoman dalam pengesahan Panduan Praktik Klinis (PPK) yang bersumber dari RSUP Dr. Mdjamil Padang. Penelitian ini menggunakan metode *K-Means Clustering* dengan jumlah klaster (K) sebanyak tiga kelompok yang merepresentasikan kategori tingkat keterlambatan yaitu cepat, sedang, dan lambat, di mana penentuan nilai $K = 3$

3. BAHAN DAN METODE

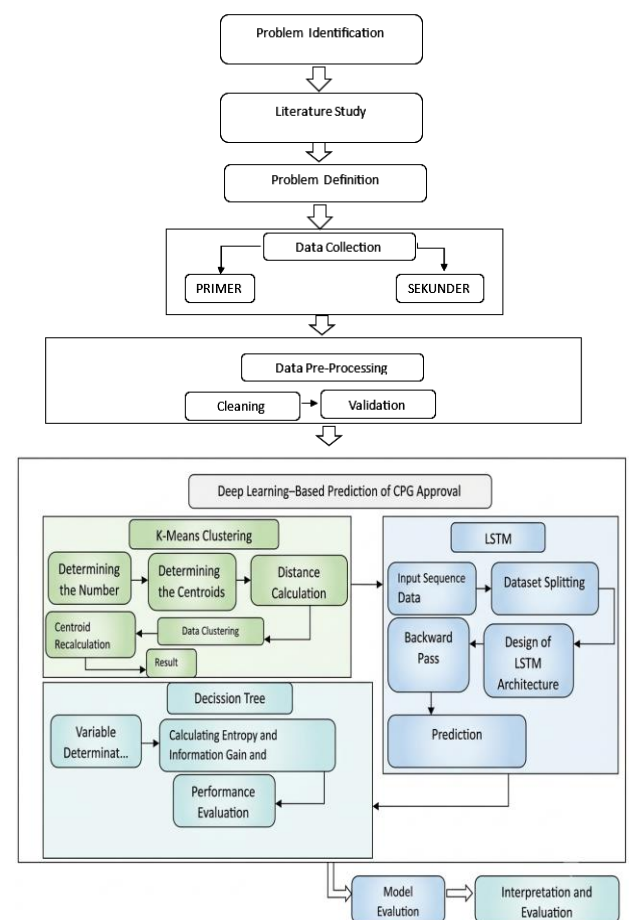
Bahan dan metode yang berperan pada penelitian ini

3.1 Waktu dan Tempat

Penelitian ini dilaksanakan selama 6 bulan dengan rentang waktu Juli – Desember 2025, di RSUP Dr. Mdjamil Padang dan memperoleh 487 data.

3.2 Metodologi Penelitian

Penelitian ini berfokus pada pencarian mode terbaik menggunakan pendekatan kuantitatif dengan metode eksperimen. Pendekatan kuantitatif dipilih karena penelitian ini memanfaatkan data *historis* yang diolah melalui serangkaian teknik analisis menggunakan algoritma *machine learning* dan *deep learning*. Pemanfaatan pendekatan ini memungkinkan peneliti untuk melakukan pengukuran secara objektif, terukur, dan dapat direplikasi, sehingga hasil penelitian memiliki tingkat validitas dan reliabilitas yang tinggi. Adapun tahapan prosesnya dapat dilihat pada Gambar 1.



Gambar 1. Metodologi Penelitian

Figure 1. Research Methodology

Pada gambar 1 Penelitian ini diawali dengan identifikasi permasalahan utama terkait keterlambatan proses pengesahan Panduan Praktik Klinis (PPK) di RSUP M. Djamil Padang melalui analisis awal terhadap data historis serta faktor-faktor administratif yang memengaruhi waktu pengesahan. Selanjutnya, dilakukan studi literatur dengan memahami jurnal, buku, dan penelitian terdahulu yang membahas penerapan data mining, *Long Short-Term Memory* (LSTM), dan *Decision Tree* guna memperoleh pemahaman teoritis mengenai algoritma dan pendekatan prediksi. Berdasarkan hasil identifikasi dan studi literatur tersebut,

ditentukan titik fokus penelitian yang diarahkan pada analisis faktor penyebab keterlambatan serta prediksi waktu pengesahan PPK melalui pemanfaatan data historis rumah sakit untuk menemukan pola dan kecenderungan waktu pengesahan. Tahap berikutnya adalah pengumpulan data yang bersumber dari data primer berupa data administrasi dan dokumen pengesahan PPK di RSUD M. Djamil Padang serta data sekunder sebagai pendukung, yang dilakukan secara sistematis dengan memperhatikan aspek kelengkapan, validitas, dan konsistensi data, sehingga dataset yang diperoleh dapat digunakan secara optimal dalam proses pelatihan dan pengujian model prediksi

1. Pra-Pemrosesan Data

Tahapan ini meliputi pembersihan data (*cleaning*) dari nilai kosong, kesalahan, dan duplikasi untuk menjaga kualitas dataset. Data kemudian diubah ke format yang sesuai melalui proses *Cleaning Data*. Tujuannya agar data siap digunakan dalam *K-means Clustering*, pelatihan model LSTM dan analisis *Decision Tree*.

2. Analisis Proses Metode K-Means Clustering

K-Means Clustering merupakan salah satu metode *unsupervised learning* yang digunakan untuk mengelompokkan data ke dalam sejumlah kelompok atau klaster berdasarkan tingkat kesamaan karakteristik antar data. Algoritma ini bekerja dengan cara menentukan sejumlah klaster (K) terlebih dahulu, kemudian secara iteratif menghitung jarak setiap data terhadap titik pusat klaster (*centroid*). Jumlah cluster pada penelitian ini ditetapkan sebanyak $K = 3$ sesuai dengan perancangan metodologi yang telah ditentukan. Penetapan tiga cluster tersebut bertujuan untuk mengelompokkan data waktu tempuh pengesahan PPK ke dalam tiga kategori utama yang berbeda. Masing-masing *cluster* merepresentasikan tingkat waktu tempuh pengesahan PPK yang bervariasi, yaitu kategori cepat, sedang, dan lambat. Penentuan keanggotaan *cluster* serta pembaruan posisi *centroid* pada metode K-Means dilakukan melalui perhitungan jarak matematis yang dirumuskan dalam persamaan 1 berikut:

$$d_{ij} = \sqrt{(x_{1i} - x_{1j})^2 + (x_{2i} - x_{2j})^2 + \dots + (x_{ki} - x_{kj})^2} \quad (1)$$

3. Analisis Proses Metode LSTM

Long Short-Term Memory (LSTM) adalah salah satu jenis jaringan saraf tiruan (*neural network*) yang termasuk dalam kategori *Recurrent Neural Network* (RNN) dan dirancang untuk mempelajari data berurutan atau data *time series*. LSTM mampu mengingat informasi penting dalam jangka waktu yang panjang dan melupakan informasi yang tidak relevan melalui mekanisme *gate* (*input gate*, *forget gate*, dan *output gate*).

Pada *forget-gates*, informasi pada setiap data input akan diproses dan data mana yang akan disimpan

atau dibuang di sel memori. Fungsi aktivasi yang digunakan pada *forget-gates* ini adalah fungsi aktivasi *sigmoid*. Dimana *outputnya* antara 0 dan 1. Jika *outputnya* 1 maka semua data akan disimpan dan sebaliknya jika *outputnya* 0 maka semua data akan dibuang menggunakan Persamaan 2 berikut :

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

Pada *input-gates* ada dua gerbang yang akan diimplementasikan, pertama akan ditentukan nilai mana yang akan diupdate menggunakan fungsi aktivasi *sigmoid*. Kemudian fungsi aktivasi *tanh* akan membuat vektor nilai baru yang akan disimpan di sel memori menggunakan Persamaan berikut

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$c_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

Cell-gates akan menggantikan nilai pada sel memori sebelumnya dengan nilai sel memori yang baru. Nilai ini didapat dari penggabungan nilai-nilai yang terdapat pada *forget-gates* dan *input-gates* menggunakan persamaan

$$c_t = f_t \cdot c_{t-1} + i_t \cdot c_t \quad (5)$$

Output gate Berfungsi untuk memilih bagian dari memory cell yang akan dihasilkan, dengan memanfaatkan fungsi aktivasi *sigmoid*. Nilai dari memory cell diproses melalui fungsi aktivasi *tanh*. Kemudian, kedua nilai dari *gate* tersebut dikalikan untuk menghasilkan n keluaran akhir (*ht*).

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

4. Analisis Proses Metode Decision Tree C45

Pada tahap ini, dilakukan penentuan variabel yang akan digunakan dalam pemrosesan menggunakan metode *Decision Tree C4.5*. Terdapat tiga variabel utama yang menjadi dasar dalam proses analisis, yaitu lama pengajuan, lama pengesahan, dan Jumlah Revisi. Atribut-atribut tersebut akan dikelompokkan dan dianalisis untuk membentuk struktur pohon keputusan yang merepresentasikan hubungan antarvariabel secara sistematis. Proses penyederhanaan pengklasifikasian dilakukan menggunakan rumus *Sturges* untuk membagi nilai hasil prediksi LSTM ke dalam beberapa kelas. Berikut adalah perhitungan jumlah kelas menggunakan rumus *Sturges*

$$\text{Jumlah Kelas} : 1 + 3.3 \log n \text{ (Jumlah Data)}$$

Untuk mendapatkan *range* dilakukan Langkah sebagai berikut:

$$\text{Range} : n \text{ tertinggi} - n \text{ terendah}$$

Menghitung nilai Entropy pada setiap atribut, terlebih dahulu dilakukan analisis terhadap distribusi data pada masing-masing atribut. Nilai Entropy yang dihasilkan menunjukkan tingkat homogenitas data pada suatu atribut, di mana nilai yang semakin kecil menandakan data semakin homogen. Hasil perhitungan Entropy ini selanjutnya digunakan sebagai dasar dalam proses pemilihan atribut terbaik pada algoritma *Decision Tree C4.5*. berikut adalah perhitungan Entropynya

$$Entropy(N) = \sum - p_i * \log_2 p_i \quad (2)$$

Setelah menghitung entropy setiap kasus maka selanjutnya menghitung nilai Gain menggunakan rumus sebagai berikut:

$$Gain = \sum_{i=1}^n \frac{Lama Pengesahan}{Total} * Entropy \quad (2)$$

4. PEMBAHASAN

Penelitian ini proses kerja yang akan dilakukan dalam pembangunan sistem ini disesuaikan dengan kebutuhan analisis dan prediksi waktu tempuh proses pengesahan Panduan Praktik Klinis (PPK). Tahapan awal dimulai dengan pengumpulan dan pra-pemrosesan data historis pengesahan PPK yang meliputi pembersihan data, normalisasi, serta transformasi data agar siap digunakan pada tahap analisis.

Setelah itu dilakukan pengelompokan data menggunakan algoritma K-Means untuk mengidentifikasi pola dan kelompok proses pengesahan dengan karakteristik waktu yang serupa. Hasil dari proses *clustering* tersebut kemudian digunakan sebagai masukan bagi model prediksi berbasis *deep learning* dengan *arsitektur Long Short-Term Memory (LSTM)* untuk memperkirakan waktu tempuh pengesahan berikutnya. Pada tahap akhir, dilakukan analisis faktor penyebab keterlambatan menggunakan algoritma *Decision Tree*, sehingga sistem tidak hanya mampu melakukan prediksi, tetapi juga memberikan pemahaman mengenai variabel-variabel yang paling berpengaruh terhadap lamanya proses pengesahan PPK.

4.1 Pra-pemrosesan Data

Pada prapemrosesan data dilakukan proses pembersihan data (*data cleaning*) dilakukan terhadap 487 data pengesahan Panduan Praktik Klinis (PPK) yang telah dikumpulkan dalam periode tahun 2020 hingga 2024. Pemeriksaan dilakukan secara menyeluruh menggunakan *Phyton* untuk memastikan tidak terdapat duplikasi data, kesalahan *entri*, maupun nilai yang hilang pada setiap atribut, dan untuk menghilangkan kolom yang tidak diperlukan. Hasil verifikasi menunjukkan bahwa seluruh data yang digunakan telah valid dan layak untuk dianalisis. Pada prapemrosesan data ini dapat dilihat hasilnya pada tabel 1

Tabel 1. Pembersihan Data

Table 1. Data Cleaning

Data	Submission Duration	Approval Time	Total Revision
1	16	87	1
2	7	93	2
3	27	26	0
4	60	34	0
5	58	36	0
6	57	34	1
7	3	98	1
8	26	65	1
9	40	189	1
10	39	62	1
11	83	30	1
12	12	142	2
.....
487	61	26	1

Berdasarkan Tabel 1, setelah dilakukan proses pembersihan data (*data cleaning*), diperoleh variabel-variabel yang layak digunakan dalam penelitian. Proses tersebut menghasilkan tiga variabel utama, yaitu lama pengajuan, lama pengesahan, dan jumlah revisi. Ketiga variabel ini selanjutnya digunakan sebagai atribut penting dalam analisis dan pemodelan prediktif waktu pengesahan Panduan Praktik Klinis (PPK).

4.2 K-Means Clustering

Algoritma ini bekerja dengan cara menentukan sejumlah kluster (K) terlebih dahulu, kemudian secara iteratif menghitung jarak setiap data terhadap titik pusat kluster (*centroid*). Setiap data akan dikelompokkan ke dalam kluster yang memiliki jarak terdekat dengan *centroid*-nya. Setelah semua data terkelompok, algoritma akan memperbarui posisi *centroid* berdasarkan rata-rata dari seluruh data dalam kluster tersebut hingga posisi *centroid* stabil atau tidak berubah lagi.

Tabel 2. Data Kluster

Table 2 Cluster Data


Data	Submission Duration	Approval Time	Total Revision	Cluster
1	16	87	1	Slow
2	7	93	2	Slow
3	27	26	0	Fast
4	60	34	0	Medium
5	58	36	0	Medium
6	57	34	1	Medium
7	3	98	1	Slow
8	26	65	1	Slow
9	40	189	1	Slow
10	39	62	1	Slow
11	83	30	1	Fast
12	12	142	2	Slow
.....
487	61	26	1	Fast

Tabel 2 menampilkan hasil pengelompokan data proses pengesahan Panduan Praktik Klinis (PPK) menggunakan

metode *K-Means Clustering* berdasarkan variabel lama pengajuan, lama pengesahan, dan jumlah revisi. Hasil pengelompokan menunjukkan bahwa sebagian besar data masuk ke dalam *cluster* Lambat, yang dicirikan oleh nilai lama pengesahan yang tinggi, sedangkan *cluster* Sedang dan Cepat memiliki durasi pengesahan yang relatif lebih singkat. Perbedaan karakteristik antar *cluster* ini menunjukkan bahwa metode *K-Means* mampu mengidentifikasi pola kecepatan proses pengesahan PPK secara objektif.

4.3 LSTM

Penelitian ini dirancang sebuah model prediktif berbasis *Long Short-Term Memory* (LSTM) untuk memodelkan pola data deret waktu yang bersumber dari data historis proses pengesahan Panduan Praktik Klinis (PPK). Pemilihan metode LSTM didasarkan pada kemampuannya dalam menangkap ketergantungan jangka pendek dan jangka panjang melalui mekanisme memori dan *gate*. Arsitektur model disusun secara bertingkat untuk meningkatkan kemampuan representasi fitur sebelum menghasilkan nilai prediksi waktu pengesahan PPK.



Gambar 2 Rancangan Arsitektur LSTM
Figure 2 Design of LSTM Architecture

Gambar 2 menunjukkan arsitektur *Long Short-Term Memory* (LSTM) bertingkat yang digunakan untuk memprediksi waktu pengesahan Panduan Praktik Klinis (PPK) berdasarkan data historis. Data *input* berupa beberapa variabel pada beberapa timestep sebelumnya diproses melalui tiga lapisan LSTM yang masing-masing memiliki empat *hidden* unit untuk menangkap pola ketergantungan *temporal* jangka pendek dan jangka panjang. Selisih antara y aktual dan y prediksi tersebut digunakan sebagai dasar dalam perhitungan *loss* guna mengevaluasi tingkat kesalahan dan kinerja model prediksi.

Tabel 2. Prediksi LSTM
Tabel 3 Prediction Of LSTM

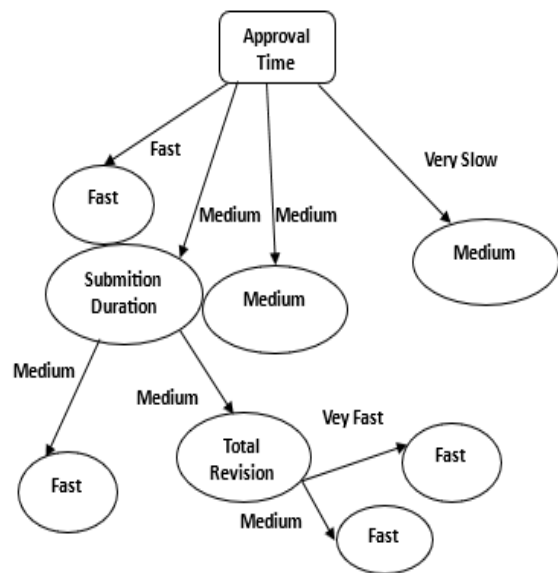
Data	Approval Time	Prediction
1	34	26
2	34	26
3	36	26
4	26	19
5	26	19
6	26	19
7	34	26
8	36	26
9	34	26
10	89	35
11	26	19
12	89	35

.....
87	26	19

Tabel 3 menyajikan perbandingan antara nilai lama pengesahan aktual dan hasil prediksi menggunakan model LSTM pada data uji. Berdasarkan tabel tersebut, terlihat bahwa nilai prediksi cenderung lebih rendah dibandingkan nilai aktual, yang menunjukkan bahwa model menghasilkan estimasi waktu pengesahan yang lebih *konservatif*. Pola prediksi yang relatif konsisten pada beberapa data dengan karakteristik serupa mengindikasikan bahwa model LSTM mampu menangkap kecenderungan umum durasi pengesahan.

4.4. Decision Tree

Metode *Decision Tree C4.5* digunakan untuk membentuk pohon keputusan berdasarkan data hasil prediksi yang diperoleh dari model *Long Short-Term Memory* (LSTM). Setelah proses pemodelan dan prediksi menggunakan LSTM selesai, nilai prediksi waktu pengesahan yang dihasilkan masih berupa data numerik sehingga perlu diproses lebih lanjut. Nilai prediksi tersebut kemudian digunakan sebagai data input untuk algoritma C4.5 guna menentukan pola dan membentuk aturan keputusan. Dengan demikian, metode C4.5 berfungsi untuk mengidentifikasi atribut yang paling berpengaruh terhadap kategori waktu pengesahan berdasarkan hasil prediksi LSTM. Pada hasil dari prosesnya dapat dilihat pada hasil keputusan pada Gambar 2



Gambar 3 Pohon Keputusan Decision Tree
Figure 3 Decision Tree Results

Gambar 3 menunjukkan struktur pohon keputusan (*decision tree*) yang digunakan untuk mengklasifikasikan lama pengesahan PPK berdasarkan beberapa atribut

penentu. Atribut utama yang menjadi *node* akar pada model ini adalah lama pengajuan, yang dianggap sebagai faktor awal paling berpengaruh dalam proses pengambilan keputusan. Pada kondisi lama pengajuan tergolong lambat, proses selanjutnya dipengaruhi oleh jumlah revisi yang dilakukan. Jika jumlah revisi relatif tinggi, maka hasil klasifikasi cenderung menunjukkan bahwa proses pengesahan berada pada kategori lambat. Sebaliknya, apabila jumlah revisi rendah, meskipun lama pengajuan tergolong lambat, proses pengesahan masih berpotensi berada pada kategori cepat. Sementara itu, pada kondisi lama pengajuan tergolong cepat, keputusan berikutnya ditentukan oleh lama pengesahan. Jika lama pengesahan juga termasuk cepat, maka hasil akhir diklasifikasikan sebagai cepat. Namun, apabila lama pengesahan tergolong lambat, maka proses pengesahan secara keseluruhan dikategorikan sebagai lambat. Berdasarkan struktur pohon keputusan tersebut, dapat disimpulkan bahwa lama pengajuan, jumlah revisi, dan lama pengesahan merupakan atribut-atribut penting yang saling berinteraksi dalam menentukan klasifikasi akhir proses pengesahan PPK. Model ini memberikan gambaran yang jelas mengenai pola dan aturan keputusan yang terbentuk dari data historis, sehingga dapat digunakan sebagai dasar analisis dan pengambilan keputusan dalam evaluasi kinerja proses pengesahan. Untuk hasilnya dapat dilihat pada tabel 4 berikut.

Tabel 4 Result Decission Tree

Dat a	Submissi on Duration	Approva l Time	Total Revisio n	Cluster	Predicti on
1	Moderate ly slow	Very Fast	Sufficie nt Highly accurat	Modera tly	Fast
2	Moderate ly slow	Very Fast	Highly accurat e	Modera tly	Fast
3	Moderate ly slow	Very Fast	Highly accurat e	Modera tly	Fast
4	Moderate ly slow	Very Fast	Sufficie nt Highly accurat	Fast	Fast
5	Moderate ly fast	Very Fast	Highly accurat e	Fast	Very Fast
6	Moderate ly fast	Very Fast	Highly accurat e	Fast	Very Fast
7	Moderate ly slow	Very Fast	Highly accurat e	Modera tly	Fast
8	Moderate ly slow	Very Fast	Highly accurat e	Modera tly	Fast
9	Moderate ly slow	Very Fast	Sufficie nt Highly accurat	Modera tly	Fast Fast
10	Moderate ly fast	Moderat ely fast	Highly accurat e	Slow	Fast
11	Moderate	Very	Sufficie nt	Fast	Fast

12	ly slow	Fast	nt	Sufficie nt	Modera tly	Fast
....
87	Moderatl y	Very Slow	Sufficie nt	Modera tly	Slow

Tabel 4 menunjukkan hasil klasifikasi waktu pengesahan PPK menggunakan metode *Decision Tree* berdasarkan variabel lama pengajuan, lama pengesahan, jumlah revisi, dan hasil clustering. Dari hasil tersebut terlihat bahwa sebagian besar data dengan kategori lama pengesahan sangat cepat dan jumlah revisi cukup hingga sangat bagus diprediksi berada pada kelas cepat atau sangat cepat, meskipun berasal dari cluster yang berbeda. Hal ini menunjukkan bahwa variabel lama pengesahan memiliki pengaruh yang kuat dalam proses pengambilan keputusan pada model.

Evaluasi Model

Pada tahap evaluasi akurasi, dilakukan perbandingan antara hasil prediksi model dengan data aktual untuk mengetahui tingkat ketepatan klasifikasi yang dihasilkan. Nilai akurasi dihitung berdasarkan rasio jumlah data yang diprediksi dengan benar terhadap total data pengujian. Tahap ini bertujuan untuk menilai sejauh mana model mampu menghasilkan prediksi yang sesuai dengan kondisi aktual pada proses pengesahan Panduan Praktik Klinik (PPK).

$$\text{Akurasi} = \frac{\text{Nilai Prediksi Benar}}{\text{Total Data}} \times 100\% \quad (1)$$

$$\text{Akurasi} = \frac{76}{87} \times 100\% = 87,36\% \quad (2)$$

Pada tahap evaluasi akurasi, model menghasilkan nilai akurasi sebesar 87,3%. Nilai ini menunjukkan bahwa sebagian besar data uji berhasil diprediksi dengan benar oleh model yang digunakan. Tingkat akurasi tersebut mengindikasikan bahwa model memiliki kinerja yang baik dan mampu merepresentasikan pola data administratif dalam memprediksi waktu pengesahan Panduan Praktik Klinik (PPK) secara efektif. Oleh karena itu, model yang dihasilkan dinilai layak untuk digunakan sebagai dasar analisis dan pengambilan keputusan pada tahap selanjutnya.

5. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan untuk menganalisa jarak tempuh pada pengesahan PPK dengan algoritma *K-Means Clustering*, LSTM dan *Decission Tree* telah memberikan hasil yang cukup akurat dalam pengolahannya. Hasil keakuratan yang didapat memiliki tingkat akurasi 87,36%. Berdasarkan hasil yang telah

diperoleh tersebut bahwa memprediksi jarak tempuh pengesahan PPK dengan pendekatan *deep learning* memiliki kinerja cukup baik. Melalui kinerja yang telah dilakukan model prediksi tersebut diharapkan dapat menangani permasalahan dalam pengolahan data

6. SARAN

Bagi peneliti selanjutnya, disarankan untuk mengembangkan penelitian ini dengan menambahkan atau menggunakan variabel lain yang belum digunakan pada penelitian ini guna meningkatkan akurasi dan kemampuan generalisasi model. Model yang telah dikembangkan pada penelitian ini dapat dijadikan sebagai acuan dasar karena terbukti mampu memprediksi waktu pengesahan Panduan Praktik Klinik (PPK) dengan kinerja yang baik.

7. KESIMPULAN

Aldino, A., Saputra, A., Nurkholis, A., & Setiawansyah, S. (2021). Application of support vector machine (SVM) algorithm in classification of low-cape communities in Lampung Timur. *Building Informatics, Technology and Science*, 3(3). <https://doi.org/10.47065/bits.v3i3.1041>

F. R. Adha, Y. Sahria, N. I. Febriani, R. Nurul Fauziah, W. Sa'adah, and A. Hidayati, "Analisis Literatur Sistem Informasi Kesehatan (SIK): Tren, Tantangan, dan Manfaat dalam Peningkatan Pelayanan Kesehatan di Indonesia," *Pros. Semin. Nas. UNIMUS*, vol. 6, pp. 928–942, 2023.

Gustientiedina, G., Adiya, M. H., & Desnelita, Y. (2019). Penerapan algoritma K-means untuk clustering data obat-obatan. *Jurnal Nasional Teknologi dan Sistem Informasi*, 5(1), 17–24.

G. Douzas, F. Bacao, and F. Last, "Improving imbalanced learning through a heuristic oversampling method based on k-means and SMOTE," *Inf. Sci. (Ny)*, vol. 465, pp. 1–20, 2018, doi: 10.1016/j.ins.2018.06.056. <https://doi.org/10.25077/teknosi.v5i1.2019.17-24>

I. I. J. Rifka Alkhilyatul Ma'rifat, I Made Suraharta, "No Title 濟無No Title No Title No Title," vol. 2, no. 1, pp. 306–312, 2024.

J. Jang, "Travel Time Prediction Using Machine Learning Algorithms: Focusing on k-NN, LSTM, and Transformer," *Open Transp. J.*, vol. 18, no. 1, pp. 1–13, 2024, doi: 10.2174/0126671212356139241101070347.

K. Laskhmaiah, S. M. Krishna, and B. E. Reddy, "An optimized k-means with density and distance-based clustering algorithm for multidimensional spatial databases," *Int. J. Comput. Netw. Inf. Secur.*, vol. 13, no. 6, pp. 70–82, 2021, doi: 10.5815/ijcnis.2021.06.06.

Muningsih, E., Nur, H. M., Imaniawan, F. F. D., Saifudin, Handayani, V. R., & Endiarto, F. (2020). Comparative analysis on dimension reduction algorithm of principal component analysis and

singular value decomposition for clustering. *Journal of Physics: Conference Series*, 1641(1), 012101. <https://doi.org/10.1088/1742-6596/1641/1/012101>

M. R. Fauzi, S. Saimi, and F. Fathoni, "Tantangan dan Solusi Administrasi Kesehatan di Era Digital (Tinjauan Literature Review atas Implementasi Teknologi)," *AL-MIKRAJ J. Stud. Islam dan Hum. (E-ISSN 2745-4584)*, vol. 5, no. 01, pp. 1093–1103, 2024, doi: 10.37680/almikraj.v5i01.6219.

N. G. Ramadhan, Y. S. R. Nur, and F. D. Adhinata, "Pendekatan Deep Learning Untuk Prediksi Durasi Perjalanan," *Teknika*, vol. 11, no. 2, pp. 85–89, 2022, doi: 10.34148/teknika.v11i2.460.

Patel, H. (2023). Study and analysis of decision tree based classification algorithms. *International Journal of Computer Sciences and Engineering*, 6(10). <https://doi.org/10.26438/ijcse/v6i10.7478>

Pratama, E. B., & Hendini, A. (2019). Sistem pakar diagnosa penyakit kulit pada kucing berbasis web menggunakan metode decision tree. *Sistemasi: Jurnal Sistem Informasi*, 8(2), 254–264. <https://doi.org/10.32520/stmsi.v8i2.459>

Patrício et al., "Using Resistin, glucose, age and BMI to predict the presence of breast cancer," *BMC Cancer*, vol. 18, no. 1, pp. 1–8, 2024, doi: 10.1186/s12885-017-3877-1.

R. Kurniawan, S. Defit, and S. Sumijan, "Prediksi Tingkat Kerugian Peternak Akibat Penyakit pada Sapi Menggunakan Algoritma K-Means Clustering," *J. Inf. dan Teknol.*, vol. 3, no. 1, pp. 29–35, 2021, doi: 10.37034/jidt.v3i1.87.

R. Indriasari, K. Yetti, and Y. Afriani, "Panduan Pembelajaran Klinik Keperawatan," *J. Kesehat. Tambusai*, vol. 4 (4), pp. 7175–7184, 2023.

Sagat, N. A., & Purnomo, A. S. (2021). Sistem pakar diagnosa penyakit kanker serviks menggunakan metode forward chaining. *Jurnal Pendidikan dan Teknologi Indonesia*, 1(8), 329–337. <https://doi.org/10.52436/1.jpti.73>

Shah, S., Mulahuwaish, A., Ghafoor, K. Z., & Maghdid, H. S. (2022). Prediction of global spread of COVID-19 pandemic: A review and research challenges. *Artificial Intelligence Review*, 55(3), 1607–1628. <https://doi.org/10.1007/s10462-021-09988-w>

S. Rustam, "Analisa Clustering Phising dengan K-Means dalam Meningkatkan Keamanan Komputer," *Ilk. J. Ilm.*, vol. 10, no. 2, pp. 175–181, 2018, doi: 10.33096/ilkom.v10i2.309.175-181.

Synowiec, A., Szczepański, A., Barreto-Duran, E., Lie, L. K., & Pyrc, K. (2021). Severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2): A systemic infection. *Clinical Microbiology Reviews*, 34(2). <https://doi.org/10.1128/CMR.00133-20>

Zheng, S., Fan, J., Yu, F., Feng, B., Lou, B., Zou, Q., Xie, G., Lin, S., Wang, R., Yang, X., Chen, W., Wang, Q., Zhang, D., Liu, Y., Gong, R., Ma, Z., Lu, S., Xiao, Y., Gu, Y., & Zhang, J. (2022). Viral load dynamics and disease severity in patients infected

with SARS-CoV-2 in Zhejiang province, China,
January–March 2020: Retrospective cohort study.
BMJ, m1443. <https://doi.org/10.1136/bmj.m1443>