



MULTI LABEL KLASIFIKASI GENRE FILM BERDASARKAN SINOPSIS MENGGUNAKAN METODE *LONG SHORT-TERM MEMORY (LSTM)*

Jihadul Akbar¹, Hairul Fahmi², Wafiah Murniati³

^{1,2,3}Program Studi Teknik Informatika, STMIK Lombok

Jln. Basuki Rahmat No.105 Praya Lombok Tengah 83511

¹jihadul4kbar@gmail.com, ²iroel.ami@gmail.com, ³wafiah.mr@gmail.com

Abstract

Film is a medium of entertainment that can be enjoyed by many people, not only as entertainment but also as a means of marketing, trade, and education. Genre is one of the important characteristics of a film. Therefore, genre classification is a way to identify relationships among films, making it easier for viewers to find films that suit their preferences. Genre classification can be very comprehensive or diverse based on certain criteria, as many films may include multiple genres within them. To address this issue, researchers propose a multi-label classification of film genres based on synopses using the Long Short Term Memory (LSTM) algorithm and comparing the performance of Word2Vec, GloVe, and FastText word embeddings. The proposed LSTM model architecture consists of several layers, namely Embedding, SpatialDropout1D, LSTM, and Dense layers. The values for each layer are 300, 0.5, 128, and 18, respectively. The testing was conducted with three scenarios, showing that the GloVe word embedding outperforms Word2Vec and FastText with F1-scores of 0.603, 0.591, and 0.580..

Keywords : Multilabel Classification, LSTM, Word Embedding, Word2Vec, GloVe, FastText

Abstrak

Film merupakan sarana hiburan yang dapat dinikmati oleh banyak orang, bukan hanya sebagai hiburan tetapi juga merupakan sarana pemasaran, perdagangan dan pendidikan. Genre merupakan salah satu karakteristik penting dari sebuah film. Oleh sebab itu klasifikasi genre merupakan cara untuk menemukan hubungan dari masing-masing film sehingga memudahkan penonton untuk menemukan film yang sesuai. Klasifikasi genre film mungkin sangat komprehensif atau beragam berdasarkan kriteria, ada banyak genre yang serupa dalam satu film mungkin termasuk beberapa genre di dalamnya. Untuk menyelesaikan masalah tersebut peneliti mengusulkan klasifikasi multilabel genre film berdasarkan sinopsis menggunakan algoritma *Long Short Term Memory (LSTM)* dan membandingkan kinerja *word embedding* *Word2Vec*, *GloVe* dan *FastText*. Arsitektur model *LSTM* yang diusulkan terdiri dari beberapa layer yakni layer *Embedding*, *SpatialDropout1d*, *LSTM* dan *Dense*. Nilai dari masing-masing layer yakni 300, 0.5, 128, dan 18. Pengujian dilakukan dengan tiga scenario menunjukkan *word embedding* *GloVe* mengungguli *Word2Vec* dan *FastText* dengan *f1-score* 0.603, 0.591 dan 0.580.

Kata kunci : Klasifikasi Multilabel, LSTM, Word Embedding, Word2Vec, GloVe, FastText

1. PENDAHULUAN

Kemajuan teknologi informasi khususnya perkembangan internet di Indonesia menciptakan

era digital dimana informasi, komunikasi, hiburan, bahkan kebutuhan sehari-hari dapat diakses dengan mudah. Jumlah masyarakat Indonesia



yang terhubung ke internet terus meningkat. Berdasarkan hasil Polling Indonesia yang bekerja sama dengan Asosiasi Penyelenggara Jasa Internet Indonesia (APJII), pada tahun 2024 jumlah pengguna internet di Indonesia sudah mencapai 221,56 juta jiwa atau setara dengan 79,5% dari total penduduk Indonesia. Kemajuan teknologi dapat berdampak pada industri hiburan termasuk industri film.

Film merupakan karya kreasi manusia yang berisikan unsur estetika tinggi sebagai media komunikasi yang menyalurkan dan menyebarkan pesan kepada publik. Film digunakan sebagai sarana hiburan yang menyajikan cerita, peristiwa, musik, drama, humor dan sajian teknis lainnya yang dapat dinikmati oleh banyak orang. Selain sebagai hiburan film juga merupakan sarana pemasaran, perdagangan dan dimanfaatkan juga dalam pendidikan[1]. Film dapat dibedakan menjadi beberapa kategori atau lebih dikenal dengan sebutan genre film. Genre merupakan salah satu karakteristik paling penting dari sebuah film menceritakan keseluruhan isi film. Fungsi dari genre yakni untuk memudahkan dalam klasifikasi dan membagi film dari seluruh film yang pernah diproduksi [2]. Jenis genre film yang ditayangkan di platform *streaming* secara online.

Streaming merupakan cara tak terbatas untuk mendistribusikan dan mengonsumsi konten media. Layanan *streaming* digital semakin umum di berbagai segmen industri media, seperti Youtube, Netflix, dan Spotify. Netflix merupakan salah satu penyedia layanan *streaming* video yang populer dan pada tahun 2015 hampir 100 layanan *streaming* berbeda yang ada di Amerika Serikat [3]. Pencarian adalah masalah utama yang menjadi perhatian pengguna, karena sulitnya menemukan film yang sesuai dengan keinginan penonton. Oleh sebab itu klasifikasi genre atau pengelompokan film merupakan cara untuk menemukan hubungan dari masing-masing film sehingga memudahkan penonton untuk menemukan film yang sesuai harapan.

Klasifikasi genre film mungkin sangat komprehensif atau beragam berdasarkan kriteria. Selain itu, ada banyak genre yang serupa, dalam satu film mungkin termasuk beberapa genre didalam-Nya, membuat klasifikasi yang akurat menjadi sulit [4]. Untuk mengatasi masalah ini dan melakukan klasifikasi genre secara efisien, banyak penelitian sebelumnya menggunakan *Machine Learning* dan *Deep Learning* untuk melakukan

klasifikasi genre film secara otomatis, berdasarkan berbagai data seperti poster film [5],[6], plot *summaries* [7], [8], sinopsis [9], [10], [11] dan trailer [12] yang digunakan secara terpisah atau dalam kombinasi [13]. Namun, penggunaan plot *summaries* film dibatasi oleh fakta bahwa plot *summaries* tersebut hanya mengungkapkan bagian pengantar dari sinopsis dan bukan keseluruhan isi film. Sebaliknya, sinopsis adalah merupakan ringkasan garis besar dari isi sebuah film. Trailer berisi berbagai jenis informasi, seperti bingkai gambar dan audio. Namun, trailer memerlukan kapasitas komputasi yang tinggi, karena ukuran datanya yang besar [6]. Begitu juga poster film merupakan gambar tunggal yang memiliki tingkat variabilitas yang tinggi dan kurangnya pembentukan pola [4].

Deep Learning telah mengungguli model *Machine Learning* pada banyak aplikasi terutama pada pendekatan analisis data tradisional [14]. *Recurrent Neural Networks* (RNNs) adalah salah satu arsitektur *neural network* yang digunakan dalam *deep learning* untuk menangani data yang diurutkan. RNN standar hanya dapat melihat ke belakang beberapa langkah karena masalah *vanishing* atau *exploding gradient* [15]. Untuk mengatasi masalah tersebut pendekatan yang paling efektif adalah menggunakan arsitektur LSTM [16]. LSTM terbukti lebih unggul dari algoritma seperti *Multilayer Perceptron* (MLP), *Support Vector Machine* (SVM) dan *Decision Tree* (DT) [17] pada klasifikasi genre multilabel.

Berdasarkan studi literatur yang dilakukan maka peneliti menggunakan LSTM yang terbukti unggul pada penelitian sebelumnya dan juga mengatasi masalah *exploding gradient* yang ada pada jaringan RNN standar, membandingkan kinerja *word embedding* Word2Vec, GloVe dan Fasttext. Hasil akhir dari penelitian adalah melihat performa LSTM dengan *word embedding*.

2. TINJAUAN PUSTAKA

Penelitian tentang klasifikasi genre telah banyak dilakukan sebelumnya, seperti melakukan klasifikasi genre multilabel berdasarkan fitur yang diekstraksi dari sinopsis film. Penelitian ini menggunakan 19 pendekatan ekstraksi fitur yang terpisah, 9 darinya menggunakan teknik *Term Frequency Inverse Document Frequency* (TF-IDF) dan sisanya menggunakan *word embedding* [10] Kumpulan data yang digunakan terdiri dari 12.094 sinopsis dalam bahasa Portugis Brazil yang dikumpulkan dari website TMDb serta dilabeli ke



dalam 12 genre. Mereka menggunakan empat pengklasifikasian yang berbeda (*Multilayer Perceptron* (MLP), *Decision Tree*, *Random Forest*, dan *Extra Tree*) Hasil terbaik yakni 54,8 % (*f1-score*) menggunakan *classifier* MLP yang dilatih pada fitur TF-IDF dengan mempertimbangkan *Trigram* dengan dimensi 1.000.

Pada penelitian selanjutnya [11] menambah dataset menjadi 13.394 sinopsis Portugis yang dilabeli menjadi 18 genre. Mereka juga melakukan percobaan dengan versi dataset *over sampling*. Dari percobaan tersebut menghasilkan skor 0,478 (*f1-score*) dengan menggunakan *classifier* berbasis TF-IDF. Sedangkan hasil terbaik untuk dataset yang sudah dilakukan *over sampling* dengan beberapa kombinasi ekstraksi fitur menghasilkan skor rata-rata 0,611 (*f1-score*).

Penelitian lain juga melakukan prediksi genre dan rating film berdasarkan sinopsis dengan menggunakan berbagai bahasa yakni Hindi, Telugu, Tami, Malayalam, Korea, Perancis dan Jepang [18]. Dataset yang digunakan yakni data ulasan multi bahasa yang diambil dari tujuh situs web yang berbeda. Total dataset yang terkumpul sejumlah 14.991 yang dilabel menjadi 9 genre. Hasil terbaik dari percobaan yang dilakukan yakni 91,2% pada bahasa Telugu dengan menggunakan model hibrid dengan tiga imputan yakni *word embedding*, *char embedding* dan *sentence embedding*. *Word Embedding* dan *char embedding* dimasukkan ke dalam jaringan *Long-Short Term Memory* (LSTM) yang berbeda. Sentence dimasukkan ke jaringan padat yang terhubung penuh. *Input* dari masing-masing yakni 300 dimensi dan *output* 100 dimensi. Nilai *dropout* 0,4 di seluruh model dan melatih model pada 300 *epoch* dengan ukuran *batch* 512.

Penelitian multimodal dengan menggunakan kumpulan data trailer, subtitle, sinopsis dan poster film dari 152.622 judul film dari Movie Database (TMDb) yang dilabeli dengan 18 genre [13]. Evaluasi eksperimen yang digunakan dalam penelitian ini yakni *Mel Frequency Cepstral Coefficients* (MFCCs), *Statistical Spectrum Descriptor* (SSD), *Local Binary Pattern* (LBP), *Long Short Term Memory* (LSTM), dan *Convolutional Neural Networks* (CNN). Hasil terbaik adalah dengan menggunakan LSTM yang dilatih pada dataset sinopsis dan subtitle film yakni 0,674 (*f1-score*) dan 0,725 (AUC-FR). Penelitian multilabel juga dilakukan menggunakan data poster film, trailer, plot dan menggunakan *deep network* [19]. Menggunakan dataset *Movi Scope* dengan total

dataset 5.043 yang dilabeli dengan 13 genre. Ringkasan plot dilakukan pemotongan panjang hingga 3000 kata, kemudian diubah menjadi 1 x 3000 menggunakan *word embedding* GloVe 42B. Hasil terbaik menunjukkan bahwa ringkasan plot sangat informatif dalam memprediksi genre dengan skor 0,631 (*micro AP*).

Klasifikasi multilabel menggunakan pendekatan *ensemble learning* pada masalah klasifikasi genre film menggunakan data tekstual dalam bentuk synopsis [20]. Dataset yang digunakan merupakan dataset *CMU Movie Summary Corpus* dengan memberi 5 label genre. Mereka menggunakan tiga model klasifikasi yakni *Naïve Bayes*, *Random Forest*, dan *XGBoost*. Ekstraksi fitur pada *Naïve Bayes* menggunakan *bag-of-word* dan sisanya menggunakan *word2vec*. Hasil dari masing-masing model yakni *Naïve Bayes* 0,568 (*micro-f-score*), *Random Forest* 0,576 (*micro-f-score*) dan *XGBoost* 0,652 (*macro-f-score*). Adapun hasil untuk model *ansambel* gabungan dari tiga model menghasilkan nilai 0,673 (*macro-f-score*).

Memprediksi multilabel genre film dengan menggunakan tiga model pengklasifikasian yakni *Logistic Regression* (LR), *Support Vector Machine* (SVM), *Artificial Neural Network* (ANN) [21]. Menggunakan dataset *CMU Movie Summary Corpus* berisikan 42.306 plot film, karena kumpulan data tidak seimbang sehingga label genre yang paling relevan yang digunakan. Tujuan penelitian ini adalah mencari pengaturan parameter *Doc2Vec* optimal untuk menghasilkan klasifikasi. Metode ANN memberikan nilai terbaik yakni 0,88 (*f1-score*) dengan pengaturan *windows size* 5 dan *vector size* 200.

Pendekatan klasifikasi genre menggunakan sinopsis film yang menggunakan model *supervised learning* (k-NN dan SVM) dan model *deep learning* (CNN dan RNN) [22]. Dataset yang digunakan adalah *Movie Database* (IMDb) yang terdiri dari 5000 film dari website *Kaggel* dan 10.000 sinopsis yang diunduh dari website *Rotten Tomatoes*, dataset dilabel menjadi 9 genre film. Skor terbaik 80,5 (*accuracy*) dengan menggunakan model *deep learning* RNN dengan LSTM layer dengan ekstraksi fitur menggunakan *Doc2Vec* dengan jumlah *epoch* 40.

Klasifikasi genre *multiclass* menggunakan sinopsis bahasa Indonesia dengan menggunakan algoritma *Support Vector Machine* (SVM), *Multinomial Naïve Bayes* (MNB), dan *Multilayer Perceptron* (MLP) [23]. Ekstraksi fitur



menggunakan *bag-of-word* dan TF-IDF. Model terbaik dengan skor 45% (*f1-score*) pada gabungan SVM+TF-IDF. Dataset yang digunakan di yakni data dari website IMDb dan website www.filmindonesia.or.id sejumlah 1.005 film yang di label menjadi 5 genre film.

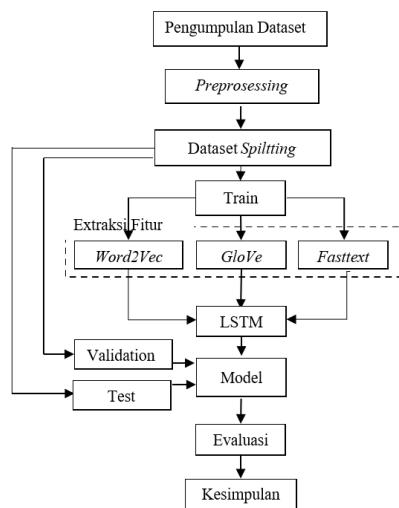
Peneliti melakukan klasifikasi genre berdasarkan plot dan membagi plot menjadi beberapa kalimat. Model klasifikasi yang digunakan yakni *Bidirectional LSTM* (Bi-LSTM) [8]. Total dataset yang dikumpulkan 6.360 plot film dengan 22.278 kalimat yang dilabel menjadi 4 genre film. Teknik ekstraksi fitur yang digunakan adalah *bag-of-word* dan TF-IDF. Hasil terbaik diperoleh dengan Bi-LSTM pada kalimat dengan skor 67,68 (*macro-f1-score*).

Penelitian saat ini adalah klasifikasi multilabel genre film berdasarkan sinopsis menggunakan algoritma *Long Short Term Memory* (LSTM) dengan tujuan mengetahui performa penerapan *word embedding* *Word2Vec*, *GloVe* dan *FastText*. Arsitektur model *LSTM* yang diusulkan terdiri dari beberapa layer yakni layer *Embedding*, *SpastialDropout1d*, *LSTM* dan *Dense*.

3. METODOLOGI PENELITIAN

3.1. Tahapan Penelitian

Dalam penelitian ini terdapat beberapa langkah alur penelitian yang digambarkan pada Gambar 1 berikut:



Gambar 1. Alur Penelitian

3.2. Pengumpulan Data Set

Pada tahap ini dilakukan *scraping* data dari website *Internet Movie Databases* (IMDb) untuk

mengumpulkan data film seperti *title*, *year*, *genre* dan sinopsis serta film yang di produksi antara tahun 1920 sampai dengan tahun 2022. Tabel 1 merupakan hasil scaraping data. Setelah data dikumpulkan selanjutnya disimpan dalam bentuk file CSV. Data selanjutnya dilakukan pembersihan data yakni proses untuk menghapus data yang duplikasi dan data yang kosong.

Tabel 1. Sampel Data

title	year	genre	synopsis
Das Cabinet des Dr. Caligari	1920	['Horror', 'Mystery', 'Thriller']	THE CABINET OF DR. CALIGARI Francis (Friedrich ...
Algol - Tragödie der Macht	1921	['Fantasy', 'Sci-Fi']	Algol, the star devil of ancient mythology, of...
Blade af Satans bog	1921	['Drama']	Carl Theodor Dreyer's classic silent film tell...
Dangerous Days	1920	['Drama']	In the period before World War I, Clayton Spen...

3.3. Preprocessing Dataset

Tahap ini melakukan *case folding*, *removing punctuation*, *stopword removal*, *lemmatization* dan *one-hot-encode*. Proses *case folding* yaitu mengubah semua karakter huruf pada kalimat menjadi huruf kecil. Proses *removing punctuation* yakni menghapus semua karakter yang tidak *valid* seperti angka, tanda baca, simbol dan URL (*Uniform Resource Locator*). Proses *stopword removal* digunakan untuk menghilangkan kata-kata yang tidak penting dan sering muncul seperti "i, me, my, we, our, you, your, him, his". Proses *lemmatization* merupakan proses mengubah kata menjadi kata dasar seperti "running" menjadi "run". *One hot encode* merupakan metode yang mempresentasikan data kategori menjadi biner yang bernilai 0 dan 1. Genre yang bernilai 0 merupakan genre yang bukan termasuk dalam sinopsis serta genre yang bernilai 1 merupakan genre yang termasuk dalam sinopsis tersebut. Total dataset setelah dilakukan preprosesing data yakni 19.407 baris data.

3.4. Splitting data

Splitting data merupakan proses membagi dataset menjadi tiga bagian yakni data *train* yang digunakan untuk melatih model, data *validation* digunakan untuk memvalidasi data *train* dan data *testing* digunakan untuk menguji seberapa baik



model yang telah di latih. Perbandingan data *training*, *validate* dan *testing* pada penelitian ini yakni 60:20:20.

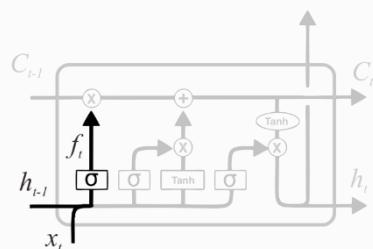
3.5. Ekstraksi Fitur

Salah satu dari teknik ekstraksi fitur adalah *word embedding* yang bekerja dengan cara mengonversi kata yang berupa karakter alfanumerik ke dalam bentuk vektor. Setiap kata dalam *vector* mempresentasikan sebuah titik pada *space* dengan dimensi tertentu. Dengan menggunakan *word embedding* kata-kata yang sama memiliki makna yang sama akan berada berdekatan. Pada penelitian ini *word embedding* yang digunakan adalah *Word2vec*, *GloVe* dan *FastText*.

3.6. Algoritma LSTM

Langkah pertama dalam algoritma LSTM yakni menentukan informasi apa yang akan dihapus dalam sel saat ini. Informasi tersebut ditentukan oleh gerbang *forget* yang berisikan lapisan *sigmoid*. Dapat dilihat pada gambar 2 Gerbang *forget*, h_{t-1} dan x_t yang berisikan angka antara 0 dan 1 di setiap keadaan sel C_{t-1} . Nilai 1 berarti simpan informasi dalam sel dan nilai 0 hapus informasi dalam sel. Gerbang *forget* dapat dihitung dengan persamaan 1

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

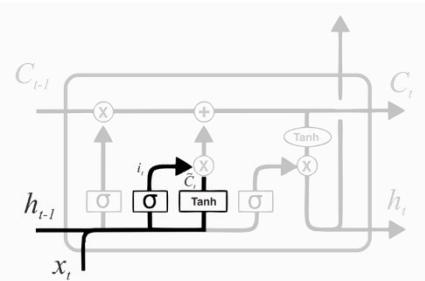


Gambar 2. Gerbang forget

Langkah selanjutnya yakni memutuskan informasi baru apa yang akan disimpan ke dalam sel saat ini. Dalam gerbang *input* terdapat dua bagian yakni pertama berisikan lapisan *sigmoid* yang bertugas untuk menentukan nilai yang akan diperbaharui, kedua merupakan lapisan *tanh* yang membuat kandidat *vector* baru \hat{C}_t yang akan ditambahkan dalam sel. Selanjutnya akan digabungkan kedua bagian untuk memperbaharui status *input*. Gambar 3 merupakan ilustrasi gerbang *input* dan dapat dihitung dengan persamaan 3.1

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

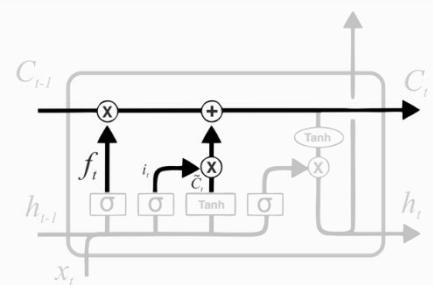
$$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$



Gambar 3. Gerbang Input

Tahap selanjutnya merupakan memperbaharui status sel lama, C_{t-1} ke dalam sel baru C_t . Di mana dalam langkah sebelumnya sudah mendapatkan nilai, sel lama dikalikan dengan f_t serta menghapus informasi pada gerbang *forget* dan menambah $i_t * \hat{C}_t$. Hasil dari operasi tersebut di gunakan untuk memperbaharui nilai sel. Gambar 4 merupakan ilustrasi memperbaharui nilai sel baru dari gerbang *forget* dan *input*. Persamaan 3.2 adalah perhitungannya.

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (3)$$

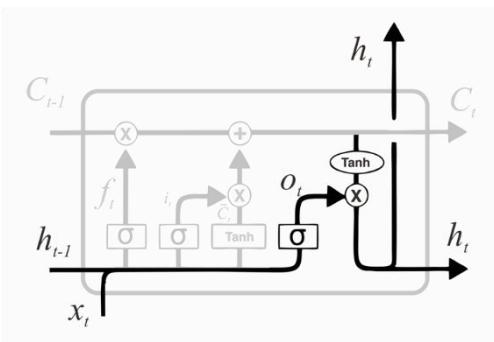


Gambar 4. Memperbaharui sel dari hasil gerbang forget dan input.

Gerbang terakhir yakni gerbang *output* yang menghasilkan sel baru (h_t). Gerbang *output* terdiri dari dua yakni lapisan *sigmoid* dan *tanh*. Lapisan *sigmoid* berfungsi untuk menentukan bagian dari sel yang akan dihasilkan. Lapisan *tanh* untuk menentukan nilai antara -1 dan 1. Hasil dari lapisan *sigmoid* dikalikan dengan lapisan *tanh* sehingga menghasilkan *output* baru. Gambar 5 ilustrasi gerbang *output* dan rumus untuk menghitungnya dapat dilihat pada persamaan 4.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t * \tanh(C_t)$$



Gambar 5. Gerbang Output

S

3.7. Evaluasi

Confusion Matrix adalah salah satu cara paling populer untuk mengevaluasi model klasifikasi. *Confusion matrix* dibuat dengan membandingkan label kelas yang diprediksi dari titik data dengan label kelas yang sebenarnya. Perbandingan ini diulang untuk seluruh kumpulan data dan hasil perbandingan ini dikompilasi dalam format matriks atau tabular [24].

Tabel 2. Confusion matrix

		Label yang diprediksi	
		Negative (PN)	Positive (PP)
Kondisi sebenarnya	Negative (N)	True negative (TN)	False positive (FP)
	Positive (P)	False negative (FN)	True positive (TP)

Dari tabel 2 merupakan struktur *confusion matrix*, Secara umum, memiliki kelas positif dan kelas lainnya adalah kelas negatif. Berdasarkan struktur ini, dapat dengan jelas melihat empat istilah penting.

- **True Positive (TP):** Merupakan data positif yang diprediksi benar.
- **True Negative (TN):** Merupakan data negatif yang diprediksi benar.
- **False Positive (FP):** Merupakan data negatif namun diprediksi sebagai data positif.
- **False Negative (FN):** Merupakan data positif namun diprediksi sebagai data negatif.

3.7.1 Accuracy

Pada klasifikasi multilabel, *accuracy* didefinisikan dengan persamaan (5) proporsi antara jumlah label yang diprediksi dengan benar dan jumlah total label yang aktif, baik dalam set

label asli maupun yang di prediksi. Metrik ini dihitung dengan menggunakan empat ukuran berbeda seperti pada tabel 2.2.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

3.7.2 Precision, Recall dan F1-Score

Precision pada persamaan 6 dianggap sebagai salah satu metrik yang lebih intuitif untuk menilai kinerja prediktif multilabel. Ini dihitung sebagai proporsi antara jumlah label yang diprediksi dengan benar dan jumlah total label yang diprediksi. Dengan demikian, dapat diartikan sebagai persentase label prediksi yang benar-benar relevan untuk instance. Metrik ini biasanya digunakan bersama dengan *Recall* persamaan 7 yang mengembalikan persentase label yang diprediksi dengan benar di antara semua label yang benar-benar relevan. Artinya, rasio label benar diberikan sebagai output oleh *classifier*.

$$\text{Precision} = \frac{TP}{TP+FP} \quad (6)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (7)$$

Penggunaan *Precision* dan *Recall* secara bersama-sama sangat umum di bidang pencarian informasi sehingga metrik yang menggabungkannya ditentukan. Ini dikenal sebagai *f1-score* pada persamaan 8 dan dihitung sebagai rata-rata harmonik dari yang sebelumnya. Dengan cara ini diperoleh ukuran bobot dari berapa banyak label relevan yang diprediksi dan berapa banyak label yang diprediksi relevan.

$$F1 - score = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

3.7.3 AUC-PR (Area Under the Precision-Recall Curve)

Area Under Curve (AUC) mengukur seberapa baik sebuah model membedakan antara dua kelas. Kurva dalam AUC adalah kurva ROC, yang merupakan kurva probabilitas yang diplot dengan TP pada sumbu y dan FP pada sumbu x. Ini adalah ukuran yang baik untuk masalah klasifikasi biner dengan distribusi miring. Rumus untuk AUC sama dengan akurasi Mikro, tetapi AUC mengambil probabilitas prediksi sebagai masukan alih-alih label yang diprediksi. Rumus untuk AUC adalah seperti pada persamaan 9 berikut:

$$AUC = \int_0^1 TPR(FPR^{-1})(x) dx \quad (9)$$



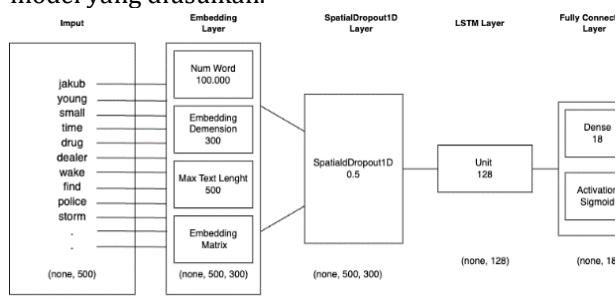
$$TPR(T) = \int_T^{\infty} f_1(x)dx$$

$$FPR(T) = \int_T^{\infty} f_0(x)dx$$

f_0 adalah fungsi kepadatan probabilitas untuk kelas negatif, dan f_1 adalah fungsi kepadatan probabilitas untuk kelas positif.

4. HASIL DAN PEMBAHASAN

Arsitektur model yang digunakan dalam penelitian ini diadopsi dari penelitian [25]. Arsitektur model terdiri dari *Embedding layer*, *SpatialDropout1d layer*, *LSTM layer* dan *Dense layer* pada lapisan terakhir. Gambar 6 merupakan detail arsitektur model yang diusulkan. Nilai dari input *sequence* 500, layer *embedding* dengan jumlah *token* 100.000, dimensi *embedding* yakni 300. Layer SpatialDropout1D dengan nilai 0.5 dan 1 layer LSTM berisikan 128 cell, serta layer terakhir yakni layer *output* dengan *dense* bernilai 18 sesuai dengan jumlah *output* dari total genre yang digunakan. *Loss function* menggunakan *binary crossentropy* dan *Optimizer Adam* dengan nilai *learning rate* default yakni 0.001. Ukuran *batch size* menggunakan 32 dan *epoch* sebanyak 200. Dengan menggunakan fungsi *early stopping* untuk menghindari *overfitting* dengan memonitoring *validation loss* serta mencari nilai minimal. Model akan berhenti apabila tidak ada peningkatan *validation loss* selama 5 kali. Selanjutnya diuji coba kan untuk masing-masing *word embedding* untuk menganalisis hasil dari model yang diusulkan.



Gambar 6. Arsitektur Model

4.1 Klasifikasi *word embedding* *Word2Vec*, *GloVe* dan *FastText*

1. LSTM *word embeddin* *Word2Vec*

Hasil model LSTM dengan *word embedding* *Word2Vec* dapat dilihat pada tabel 3 dalam bentuk *multilabel classification report*. Hasil rata-

rata *precision*, *recall* dan *f1-score* yakni 0.598, 0,584 dan 0.691.

Tabel 3. Classification report LSTM Word2Vec

	Precision	Recall	F1-Score	Support
action	0.444	0.723	0.550	573
adventure	0.593	0.453	0.513	559
animation	0.429	0.320	0.367	103
biography	0.383	0.109	0.170	165
comedy	0.685	0.486	0.569	1050
crime	0.603	0.637	0.620	587
documentary	0.971	0.604	0.744	328
drama	0.665	0.787	0.721	1912
family	0.548	0.382	0.450	225
fantasy	0.577	0.322	0.414	301
history	0.338	0.158	0.215	165
horror	0.857	0.697	0.769	644
music	0.763	0.155	0.258	187
mystery	0.415	0.267	0.325	439
romance	0.541	0.443	0.487	723
sci-fi	0.848	0.621	0.717	422
thriller	0.423	0.840	0.563	779
war	0.772	0.602	0.677	304
micro avg	0.598	0.584	0.591	9466
macro avg	0.603	0.478	0.507	9466
weighted avg	0.623	0.584	0.581	9466
samples avg	0.615	0.625	0.578	9466

Hasil perhitungan *score* dari model LSTM *word embedding* *Word2Vec* dapat dilihat pada Gambar 7.

LSTM-Word2Vec	
Accuracy	0.150
Precision	0.598
Recall	0.584
F1	0.591
ROC AUC	0.761

Gambar 7. Hasil LSTM Word2Vec

2. LSTM *word embeddin* *Glove*

Hasil model LSTM dengan *word embedding* *GloVe* yang disajikan dalam *multilabel classification report* dapat dilihat pada tabel 4 dengan hasil rata-rata *precision*, *recall* dan *f1-score* yakni 0.627, 0,580 dan 0.603.

Tabel 4. Classification report LSTM *GloVe*

	Precision	Recall	F1-Score	Support
Action	0.488	0.646	0.556	573
adventure	0.582	0.485	0.529	559
animation	0.429	0.350	0.385	103
biography	0.370	0.103	0.161	165



comedy	0.659	0.563	0.607	1050
crime	0.662	0.591	0.625	587
documentary	0.948	0.558	0.702	328
drama	0.687	0.749	0.717	1912
family	0.485	0.493	0.489	225
fantasy	0.497	0.502	0.499	301
history	0.367	0.176	0.238	165
horror	0.841	0.775	0.807	644
music	0.778	0.225	0.349	187
mystery	0.486	0.235	0.316	439
romance	0.544	0.393	0.456	723
sci-fi	0.825	0.671	0.740	422
thriller	0.495	0.703	0.581	779
war	0.717	0.641	0.677	304
micro avg	0.627	0.580	0.603	9466
macro avg	0.603	0.492	0.524	9466
weighted avg	0.632	0.580	0.593	9466
samples avg	0.645	0.622	0.592	9466

Hasil perhitungan *get_score* dari model LSTM *word embedding* Glove dapat dilihat pada gambar 8, di mana nilai *accuracy*, *precision*, *recall*, *f1-score* dan ROC AUC yakni 0.171, 0.627, 0.580, 0.603, dan 0.763.

LSTM-GloVe

Accuracy	0.171
Precision	0.627
Recall	0.580
F1	0.603
ROC AUC	0.763

Gambar 8. Hasil LSTM Glove

3. LSTM *word embedding* FastText

Hasil model LSTM dengan *word embedding* FastText yang disajikan dalam *multilabel classification report* dapat dilihat pada tabel 5 dengan hasil rata-rata *precision*, *recall* dan *f1-score* yakni 0.613, 0.551 dan 0.580.

Tabel 5. Classification report LSTM FastText

	Precision	Recall	F1-Score	Support
action	0.494	0.656	0.564	573
adventure	0.690	0.295	0.414	559
animation	0.522	0.117	0.190	103
biography	0.438	0.085	0.142	165
comedy	0.679	0.434	0.530	1050
crime	0.590	0.675	0.630	587
documentary	0.858	0.720	0.783	328
drama	0.665	0.806	0.729	1912
family	0.776	0.231	0.356	225
fantasy	0.803	0.203	0.324	301

history	0.444	0.073	0.125	165
horror	0.848	0.756	0.800	644
music	0.730	0.144	0.241	187
mystery	0.491	0.194	0.278	439
romance	0.613	0.297	0.400	723
sci-fi	0.742	0.697	0.719	422
thriller	0.399	0.861	0.546	779
war	0.835	0.365	0.508	304
micro avg	0.613	0.551	0.580	9466
macro avg	0.645	0.423	0.460	9466
weighted avg	0.646	0.551	0.552	9466
samples avg	0.637	0.597	0.574	9466

Hasil perhitungan *get_score* dari model LSTM *word embedding* FastText dapat dilihat pada gambar 9, di mana nilai *accuracy*, *precision*, *recall*, *f1-score* dan ROC AUC yakni 0.157, 0.613, 0.551, 0.580, dan 0.768.

LSTM-FastText

Accuracy	0.157
Precision	0.613
Recall	0.551
F1	0.580
ROC AUC	0.748

Gambar 9. Hasil LSTM FastText

Hasil pengujian dengan menggunakan arsitektur model dan masing-masing *word embedding* dapat dilihat pada tabel 6. Nilai *f1-score* tertinggi didapatkan pada model yang menggunakan *word embedding* GloVe yakni 0.603 dan nilai AUC tertinggi yakni 0,762. Diikuti oleh *word embedding* Word2Vec dengan nilai *f1-score* 0,591 dan nilai AUC 0,761. *Word embedding* FastText mendapatkan nilai terendah yakni *f1-score* 0,580 dan nilai AUC 0,748.

Tabel 6. Hasil model yang diusulkan pada tiga *word embedding*

	Accuracy	Precision	Recall	F1	AUC
LSTM Word2Vec	0,150	0,698	0,584	0,591	0,761
LSTM Glove	0,171	0,627	0,580	0,603	0,763
LSTM FastText	0,157	0,613	0,551	0,580	0,748

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian yang telah dilakukan, maka dapat disimpulkan bahwa hasil *f1-score* *word embedding* GloVe mengungguli Word2Vec dan FastText dengan nilai 0.578, 0.571 dan 0.548. Membuktikan bahwa dengan



menggunakan *pre-trained word embedding* dapat meningkatkan hasil *f1-score*.

Penelitian selanjutnya diharapkan dapat menambah dataset lebih banyak, melakukan oversampling atau under sampling pada dataset yang tidak seimbang antara label genre dan mencoba menggunakan algoritma Bidirectional LSTM (BiLSTM) untuk dapat meningkatkan hasil f1-score.

6. UCAPAN TERIMA KASIH

Terima kasih kami ucapkan kepada semua pihak yang telah memberikan kontribusi terhadap penelitian ini.

DAFTAR PUSTAKA:

- [1] R. Saptya, M. Permana, L. Puspitasari, and S. Indriani, “Industri film Indonesia dalam perspektif sineas Komunitas Film Sumatera Utara,” vol. 3, no. 2, pp. 185–199, 2019.
- [2] C. M. Karolina, E. Maryani, and W. Sjuchro, “Implikasi genre film dan pemahaman penonton film tuna netra di ‘ Bioskop Harewos ,’” vol. 4, no. 1, pp. 123–142, 2020.
- [3] H. S. Spilker, “The dimensions of streaming: toward a typology of an evolving concept,” 2020, doi: 10.1177/0163443720904587.
- [4] K. Kundalia, Y. Patel, and M. Shah, “Multi-label Movie Genre Detection from a Movie Poster Using Knowledge Transfer Learning,” *Augmented Human Research*, vol. 5, no. 1, 2020, doi: 10.1007/s41133-019-0029-y.
- [5] N. Hossain, M. Ahamad, S. Aktar, and M. A. Moni, “Movie Genre Classification with Deep Neural Network using Poster Images,” pp. 27–28, 2021.
- [6] J. A. Wi, S. Jang, and Y. Kim, “Poster-Based Multiple Movie Genre Classification Using Inter-Channel Features,” *IEEE Access*, vol. 8, no. April, pp. 66615–66624, 2020, doi: 10.1109/ACCESS.2020.2986055.
- [7] P. Matthews and K. Glitre, “Genre analysis of movies using a topic model of plot summaries,” *J Assoc Inf Sci Technol*, vol. 72, no. 12, pp. 1511–1527, 2021, doi: 10.1002/asi.24525.
- [8] A. M. Ertugrul and P. Karagoz, “Movie Genre Classification from Plot Summaries Using Bidirectional LSTM,” *Proceedings - 12th IEEE International Conference on Semantic Computing, ICSC 2018*, vol. 2018-Janua, pp. 248–251, 2018, doi: 10.1109/ICSC.2018.00043.
- [9] J. Wehrmann, M. A. Lopes, and R. C. Barros, “Self-attention for synopsis-based multi-label movie genre classification,” *Proceedings of the 31st International Florida Artificial Intelligence Research Society Conference, FLAIRS 2018*, pp. 236–241, 2018.
- [10] V. D. F. Giuseppe Portolese, “On the Use of Synopsis-based Features for Film Genre Classification,” 2018.
- [11] Giuseppe Portolese and V. D. F. Marcos Aurélio Domingues, “Exploring Textual Features for Multi-label Classification of Portuguese Film Synopses,” pp. 669–681, 2019.
- [12] P. G. Shambarkar, “Genre Classification of Movie Trailers using 3D Convolutional Neural Networks,” no. Icicc, pp. 850–858, 2020.
- [13] R. B. Mangolin *et al.*, “A multimodal approach for multi-label movie genre classification,” *Multimed Tools Appl*, vol. 81, no. 14, pp. 19071–19096, Jun. 2022, doi: 10.1007/s11042-020-10086-2.
- [14] J. Díaz-Ramírez, “Machine Learning and Deep Learning,” *Ingeniare*, vol. 29, no. 2, pp. 182–183, 2021, doi: 10.4067/S0718-33052021000200180.
- [15] Y. Bengio, P. Simard, and P. Frasconi, “Learning Long-Term Dependencies with Gradient Descent is Difficult,” 1994.
- [16] Sepp Hochreiter and Jürgen Schmidhuber, “LONG SHORT TERM MEMORY,” *Neural Comput*, 1997.
- [17] R. B. Mangolin *et al.*, “A multimodal approach for multi-label movie genre classification,” 2020.
- [18] V. Battu, V. Batchu, R. R. Reddy, M. K. Reddy, and R. Mamidi, “Predicting the genre and rating of a movie based on its synopsis,” *Proceedings of the 32nd Pacific Asia Conference on Language, Information and Computation, PACLIC 2018*, no. December, pp. 52–62, 2018.
- [19] D. A. Lebaron, “Multi-label Movie Genre Classification Using Multiple Modalities,” 2018.
- [20] S. Basu, S. Kumar, S. S. Banga, and H. Garg, “Using an Ensemble Learning Approach on Traditional Machine Learning Methods to Solve a Multi-Label Classification Problem,” pp. 761–772, 2021, doi: 10.1007/978-981-15-7533-4_60.
- [21] S. Guehria, H. Belleili, and N. Azizi, “One vs All’ Classifier Analysis for Multi-label



- Movie Genre Classification Using Document Embedding,” vol. 1, pp. 478–487, 2021.
- [22] J. Wang, “Using Machine Learning to Identify Movie Genres through Online Movie Synopses,” *Proceedings - 2020 2nd International Conference on Information Technology and Computer Application, ITCA 2020*, pp. 691–697, 2020, doi: 10.1109/ITCA52113.2020.00008.
- [23] A. C. Saputra, “Klasifikasi Genre Film berdasarkan Sinopsis Film Indonesia,” pp. 201–204, 2019.
- [24] D. Sarkar, *Text Analytics with Python*. Apress, 2019. doi: 10.1007/978-1-4842-4354-1.
- [25] M. Berranem, N. Azizi, A. Boukhamla, and I. Gasmi, “LSTMs Classifiers Fusion For Multi-Label Text Classification,” 2022.