



Studi Kasus

Pemodelan Text Mining dalam Pengkodean Penyakit Pasien Berdasar Kode ICD 10

Parjono ^a, Sri Kusumadewi ^{b*}

^{ab} Magister Teknik Informatika, Fakultas Teknologi Industri Universitas Islam Indonesia, Sleman, Yogyakarta

INFORMASI ARTIKEL

Sejarah Artikel:

Diterima Redaksi: 15 Mei 2023

Revisi Akhir: 07 September 2023

Diterbitkan Online: 16 September 2023

KATA KUNCI

rekam medis,

text mining,

neural network,

ICD 10

KORESPONDENSI

E-mail: sri.kusumadewi@uii.ac.id *

A B S T R A C T

Pengkodean penyakit yang lazim dilakukan oleh Rumah Sakit adalah menggunakan 2 metode, yang pertama adalah klinisi/ dokter menuliskan numenkatur penyakit berdasarkan kode ICD-10 dengan panduan kamus ICD-10 yang dapat berupa elektronik maupun buku. Metode kedua adalah klinisi/ dokter menulis secara free-text kemudian petugas koding dari rekam medis yang memberikan kode penyakit berdasar kode ICD-10 dan apabila ada hal yang sekiranya diragukan, petugas koding akan mengkonfirmasi ke dokter yang merawat pasien. Dari kebanyakan diagnosis medis yang berupa deskripsi free-text, kemiripan makna serta istilah medis yang memiliki kekhususan daripada istilah umum akan menjadi tantangan tersendiri dalam mengekstrak informasi yang berada di dalamnya. Hal ini yang mendorong penulis untuk membuat pendekatan koding penyakit dengan pemodelan Text Mining dalam membantu pengkodean penyakit tersebut melalui data diagnosis dokter sehingga diharapkan proses pengkodean penyakit menjadi lebih cepat dan mengurangi aspek human error khususnya untuk penyakit di Indonesia. Metode pendekatan yang diterapkan adalah Clinical Text Mining dengan Natural Language Processing dimana metode ini dirasa paling tepat untuk mengekstraksi informasi dari diagnosis dokter yang tidak terstruktur. Data diambil dari Rumah Sakit bagian poliklinik penyakit dalam sejumlah 3787 data dengan 5 kategori kode ICD 10 yakni E11.9 Type 2 diabetes mellitus without complications, I10 Essential (primary) hypertension, I11.9 Hypertensive heart disease without (congestive) heart failure, K21.9 Gastro-oesophageal reflux disease without oesophagitis, K30 Functional dyspepsia dengan pembagian komposisi data untuk training dan testing adalah 70:30 proses ekstraksi melalui tahapan case folding, contraction untuk pencocokan dengan kamus singkatan, tokenization, stop word removal dan menggunakan word2vec untuk proses konversi kata yang berupa karakter alphanumeric kedalam bentuk vector dari hasil pemodelan menggunakan Neural Network didapatkan nilai performa model cukup baik yakni memiliki akurasi 86.8%.

1. PENDAHULUAN

Menemukan pola dan hubungan dalam kumpulan data yang dihasilkan setiap hari menjadi tantangan tersendiri. Salah satu tantangan terbesar adalah text mining, yang terdiri dari penerapan teknik untuk mengekstrak informasi yang relevan dan informasi dalam volume besar yang berbentuk tekstual, biasanya dalam bahasa alami yang tidak terstruktur. Meskipun banyak kemajuan di bidang kesehatan, namun masih banyak bidang yang belum tereksplorasi dan masalah yang belum terpecahkan. Sebagai contoh masih terdapat keterbatasan dalam pengambilan informasi pasien dimana analisa dan pengambilan kesimpulan penyakit masih perlu ditingkatkan.

Penulisan rekam medis pasien sangat berbeda dengan standar penulisan lain seperti penulisan berita, buku, laporan dan lainnya, rekam medis pasien juga ditulis oleh para profesional pemberi asuhan lain yang terlibat dalam perawatan pasien dimana setiap profesional mempunyai kemampuan menulis yang berbeda-beda. Hal ini menjadikan pengambilan data atau informasi terkait pasien tersebut menjadi lebih sulit dikarenakan tidak adanya standar baku penulisan karena biasanya seperti diagnosa dokter ditulis secara deskriptif [1].

Di setiap Rumah Sakit biasanya terdapat unit khusus yang menangani dokumen-dokumen medis pasien yakni Unit Rekam Medis yang didalamnya ada petugas koding dimana petugas ini secara khusus meneliti kelengkapan dan kejelasan diagnosa,

tindakan medis dan masalah-masalah kesehatan yang di tulis oleh dokter kemudian menetapkan dan mencatat kode diagnosa, tindakan medis dan masalah-masalah kesehatan berdasarkan ICD 10, ICD 9 CM dan ICOPIM sehingga catatan medis yang awalnya berbentuk deskriptif diubah menjadi kode tertentu yang sudah terstandarisasi internasional.

Pengkodean penyakit yang dilakukan secara manual sangat bergantung pada kemampuan petugas koding, karena kemampuan petugas koding dalam menginterpretasikan diagnosa dan data pasien berdasarkan pengalaman petugas tersebut, juga dalam prosesnya membutuhkan waktu yang cukup lama serta memiliki potensi human error yang tinggi [2].

Di setiap Rumah Sakit biasanya terdapat unit khusus yang menangani dokumen-dokumen medis pasien yakni Unit Rekam Medis yang didalamnya ada petugas koding dimana petugas ini secara khusus meneliti kelengkapan dan kejelasan diagnosa, tindakan medis dan masalah-masalah kesehatan yang di tulis oleh dokter kemudian menetapkan dan mencatat kode diagnosa, tindakan medis dan masalah-masalah kesehatan berdasarkan ICD 10, ICD 9 CM dan ICOPIM sehingga catatan medis yang awalnya berbentuk deskriptif diubah menjadi kode tertentu yang sudah terstandarisasi internasional.

Pengkodean penyakit yang dilakukan secara manual sangat bergantung pada kemampuan petugas koding, karena kemampuan petugas koding dalam menginterpretasikan diagnosa dan data pasien berdasarkan pengalaman petugas tersebut, juga dalam prosesnya membutuhkan waktu yang cukup lama serta memiliki potensi human error yang tinggi [3].

Saat ini pengkodean penyakit menggunakan dua metode, yang pertama adalah dokter paham tentang pengkodean ICD-10 sehingga alih-alih menuliskan diagnosis secara free text dokter langsung menuliskan diagnosis dalam kode ICD-10 dengan bantuan aplikasi dari WHO berupa nomenklatur kode penyakit yang kemudian akan diaudit oleh petugas koding rekam medis. Metode ini tentu akan meningkatkan beban kerja dokter dimana dokter harus memeriksa pasien, memberikan tindakan pasien, meresepkan obat dan masih harus mencari kode penyakit berdasar ICD-10.

Metode kedua adalah petugas koding dari rekam medis yang memberikan kode penyakit berdasar diagnosis dokter dan apabila ada hal yang sekiranya diragukan, petugas koding akan mengkonfirmasi ke dokter yang merawat pasien. metode kedua ini akan memiliki kualitas yang lebih baik dibandingkan dengan metode pertama, namun metode pertama akan lebih efisien karena dokter langsung memberikan kode penyakit berstandar ICD-10 hanya saja perlu dilakukan review ulang oleh petugas koding rekam medik[4].

Pada pelaksanaannya pengkodean penyakit masih menggunakan metode kedua, yakni mengandalkan petugas koding untuk mengkodekan penyakit. Defa Miftara Agustine (2017) menyatakan bahwa erat kaitannya ketepatan terminologi medis dengan

keakuratan menyebutkan kode diagnosis rawat jalan oleh petugas koding, peluang terminologi tidak tepat akan menyebabkan ketidakakuratan kode diagnosis sebanyak 1,7 kali lebih besar dibanding dengan terminologi medis yang tepat [3].

Pada penelitian sebelumnya, Penerapan text mining pada pengkodean pemulangan pasien menggunakan data pasien berbahasa Bulgaria menggunakan Natural Language Processing dengan mengurangi multiple binnary classifiers berupa max-win voting strategy mendapatkan hasil Precision 97.3% Recall 74.68% F-measure 84.5% dan hanya terbatas pada diagnosa berbahasa Bulgaria [5], [6]. Kemudian publikasi "Using Deep Learning for Automatic Icd-10 Classification from Free-Text Data," membuat machine learning model utk pengkodean penyakit otomatis berdasarkan ICD-10 berdasarkan diagnosis free-text dengan menggunakan NLP dan Recurrent Neural Network (RNN) mendapatkan hasil F1-score 0.62 pada pengkodean berdasar ICD-10-CM [7]. Selanjutnya pada tahun 2018 Membuat model perbandingan text mining dari data diagnosa dengan metode Decision Tree, Naive Bayes, Support Vector Machine, dan Neural Network, diperoleh metode Neural Network memiliki nilai True Positive Rate sebesar 89.03% [8].

Dari kebanyakan diagnosis medis yang berupa deskripsi free text, kemiripan makna serta istilah medis yang memiliki kekhususan daripada istilah umum akan menjadi tantangan tersendiri dalam mengekstrak informasi yang berada di dalamnya[9]. Hal ini yang mendorong penulis untuk menerapkan Text Mining dalam membantu pengkodean penyakit melalui data diagnosis dokter sehingga diharapkan proses pengkodean penyakit menjadi lebih cepat dan mengurangi aspek human error khususnya untuk penyakit di Indonesia.

Tujuan dari pemodelan text mining untuk pendokedan penyakit ini adalah terbentuknya model machine learning untuk pengkodean penyakit berdasarkan kode ICD-10 yang dapat membantu Rumah Sakit dalam pengkodean penyakit dengan lebih cepat, berkurangnya tingkat human error dan mengurangi beban petugas rekam medis. Pada akhirnya program integrasi data yang dicanangkan oleh Kementerian Kesehatan dapat direalisasikan terutama dari penyajian data fasilitas layanan kesehatan yang mendekati realtime sehingga masyarakat sebagai pemilik data dapat memperoleh haknya sebagai pasien tepat setelah pasien meninggalkan fasilitas layanan kesehatan yang dipilihnya dan Kementerian Kesehatan sebagai pengatur regulasi memperoleh data agregasi dari seluruh fasyankes untuk kepentingan pengambilan kebijakan secara tepat dan cepat.

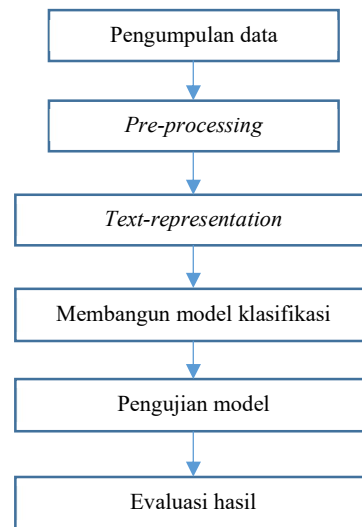
2. METODE

Text mining adalah suatu bidang baru yang sedang berkembang yang mencoba untuk mengumpulkan informasi yang memiliki arti dari teks bahasa alami [10]. Bidang ini mungkin lebih dikenal sebagai proses dalam menganalisis teks untuk mengekstrak informasi yang berguna untuk suatu tujuan tertentu. Dibandingkan dengan jenis data yang tersimpan dalam database, text mining

menggunakan data teks yang tidak terstruktur, tidak memiliki bentuk yang jelas dan sulit untuk diuraikan dengan pendekatan algoritma. [11] Namun, dalam budaya modern, teks adalah perantara yang paling umum untuk pertukaran secara formal dari informasi. Bidang text mining biasanya berkaitan dengan teks yang memiliki fungsi untuk komunikasi dari informasi yang faktual atau opini, dan keinginan untuk mencoba mengekstrak informasi dari sebuah teks secara otomatis merupakan hal yang menarik meskipun tingkat keberhasilan yang diperoleh hanyalah sebagian [12]. Text mining umumnya digunakan untuk menunjukkan sistem yang menganalisis sejumlah besar teks bahasa alami dan mendeteksi pola penggunaan leksikal atau bahasa dalam upaya untuk mengekstrak informasi yang mungkin berguna [13].

Clinical text mining adalah proses mengekstraksi informasi dan pengetahuan yang bermanfaat dari catatan kesehatan elektronik dan dokumen klinis lainnya menggunakan teknik *Natural Language Processing* (NLP) dan *Machine Learning* (ML). NLP merupakan salah satu cabang ilmu AI yang berfokus pada pengolahan bahasa natural. Bahasa natural adalah bahasa yang secara umum digunakan oleh manusia dalam berkomunikasi satu sama lain. Bahasa yang diterima oleh komputer butuh untuk diproses dan dipahami terlebih dahulu supaya maksud dari user bisa dipahami dengan baik oleh komputer. Ada berbagai terapan aplikasi dari NLP yaitu diantaranya adalah Chatbot yakni aplikasi yang membuat user bisa seolah-olah melakukan komunikasi dengan komputer, Translation Tools yaitu menterjemahkan Bahasa satu ke Bahasa yang lain dan aplikasi-aplikasi lain yang memungkinkan komputer mampu memahami instruksi bahasa yang diinputkan oleh user. Dalam bidang kesehatan pencatatan diagnosis pasien dicatat dalam rekam medis dalam unstructured text, berupa deskripsi tekstual yang sangat variatif. Salah satu pendekatan teknologi yang dapat diterapkan untuk mengekstrak informasi didalamnya adalah penggunaan NLP [14].

Metode penelitian yang digunakan adalah penelitian kuantitatif dimana tujuannya adalah membuat model text mining untuk klasifikasi kode penyakit dari data diagnosis, dilakukan pre-processing dimana diagnosis dokter yang berbentuk deskriptif tidak terstruktur akan dibakukan dengan membuang/menerjemahkan simbol, tanda baca dan akronim, selanjutnya adalah proses stemming dimana kata akan diubah menjadi kata dasar. Kemudian hasil *pre-processing* akan dilakukan *text-representation* dimana proses ini pada dasarnya akan mengubah kata menjadi angka biner yang akan dimasukkan ke dalam model machine learning. Tahapan skema penelitian digambarkan pada Gambar 2.



Gambar 1. Skema penelitian

2.1. Pengumpulan data dan Pre-processing

Tahapan persiapan data text yang wajib untuk dilakukan agar dapat diproses ke dalam suatu algoritma adalah tahapan mengubah data text menjadi data numerik karena suatu data text tidak akan bisa langsung diolah oleh algoritma, sehingga diperlukan pre-processing untuk mengubah data text diagnosa dokter ke dalam data numerik.

Tabel 1. Data Pengkodean Penyakit

DIAGNOSA DOKTER	KODE ICD-10
DM. HT	I10
HHD EC HT STG II. CEPHALGIA. DISPEPSIA	I10
GERD MIXED. OBS DIARE AKUT (MEMBAIK)	K21.9
PRO REPLACEMENT PEG DGN SEDASI 29112020	E11.9
JAM 10.00. GERIATRIC GIANT POST CARDIAC ARREST - ROSC. DISFAGIA PD SNH WITH PEG (PERCUTANEUS ENDOSCOPY GASTROSTOMI). DM2O. HHD - IHD DEKOMP ON TX. INSUFISIE...	
DM2 OBESE. HHD STABIL (CANDE 8 SDG CB STOP). POST ORIF A.I CF FIBULA S. CKR	E11.9
VERTIGO. HT STAG II. SUSSPEK SINUSITIS	I10
DM2 NO -- NEUROPATI DIABETIKA. ACUT OPN CKD EC ND CUM NEFROPATHY URAT. DISPEPSIA	I11.9
GERD. GASTROENTEROPATHY NSAIDS. SUSP. CHOLEYSTITIS. ASMA RELATED GERD	K21.9
.....

Penelitian ini menggunakan data primer penyakit dari Rumah Sakit X yang dikhususkan pada data penyakit di rawat jalan spesialis Penyakit Dalam yang diambil dari bulan januari sampai dengan bulan september 2020 selanjutnya data akan dilakukan sampling dan cleaning, adapun diagnosis yang masih terdapat kata singkatan akan disesuaikan dengan kamus singkatan yang ada di Unit Rekam Medis sehingga isian diagnosis menjadi lebih utuh, juga pada tahap pre-processing akan merubah kata menjadi bentuk dasar,

segmentasi per kata dan tokenisasi kalimat menjadi per kata, serta pemisahan dari tanda baca. Pada tahap pre-processing dilakukan dengan menggunakan data MS-Excel yang dirubah menjadi dataframe yang ditunjukkan pada Tabel 1.

Tabel 2. Kamus Singkatan

SINGKATAN	
...	...
WSD	water shield draineight
WT	Weight
WT+HT	wound toilet + hecting
X/ MNT	kali permenit
YANMED	pelayanan medis
YG	Yang
YL	yang lalu
EC	et causa
DGN	Dengan
STG	Stage
EC	et causa
GBS	guillain barre or syndrome
GCS	glasgo coma scale
GDP	glukosa darah puasa
GDS	glukosa darah sewaktu
GE	gastro enteritis
GEA	gastro enteritis akut
GEA-DRS	gastro enteritis dehidrasi ringan sedang
GED	gastroenteritis dehidrasi
GERD	gastroesophageal reflux disease
gg	gangguan
GGA	gagal ginjal akut
GGK	gagal ginjal kronik
GGT	gamma glutamil transferase
GIR	glukosa infusion rate
GI	gastrointestinal
GNA	glumerulo nephritis acute
HBsAg	hepatitis b surface antigen
HBV	hepatitis b virus
HCG	human chorionic gonadotropin
HCG EIA	pemeriksaan hcg dengan enzyme immuno assay
HCL	hydrochloric acid
HCV	hepatitis c virus
HD	hemodialisa
HD Cath	hemodialisa catheter
HDK	hipetensi dalam kehamilan
HDL	high density lipoprotein
.....

Selanjutnya data awal sebagaimana ditampilkan pada Tabel 2 akan dilakukan proses *cleaning*, proses *cleaning* merupakan proses

membersihkan review dari kata-kata yang tidak diperlukan untuk mengurangi proses noise pada proses klasifikasi. Kata-kata yang dihilangkan adalah karakter. Kemudian adalah pencocokan dengan singkatan yang sudah ditetapkan sebagaimana Tabel 3, proses *cleansing* akan melewati beberap tahapan yakni *case folding* merupakan proses mengubah semua huruf dalam dokumen menjadi huruf kecil. Hanya huruf a sampai z saja, penyeragaman kata dimana semua huruf akan diubah menjadi huruf kecil, selanjutnya adalah *stopword removal* merupakan hapus kumpulan kata-kata yang sering muncul dalam suatu dokumen. *stopword* pada umumnya adalah sebuah kata penghubung yang tidak begitu penting, maka *stopword* dapat diabaikan dan tidak ikut dalam proses pengindeksan, *stopword* adalah kata-kata yang tidak deskriptif yang dapat dibuang dalam pendekatan dengan regex, *contraction* yakni pencocokan kamus singkatan agar diperoleh data diagnosa yang lebih utuh, potensi akurasi akan bertambah lebih baik karena diagnosis dokter akan lebih mudah dipahami dengan menggunakan kata yang sudah dibakukan oleh Rumah Sakit. Tahap selanjutnya adalah proses *stemming* dan tokenisasi sebagaimana Tabel 4 untuk selanjutnya dilakukan ekstraksi fitur. *Tokenizing* merupakan proses pemotongan kalimat menjadi sebuah kata dengan melakukan analisa terhadap dengan melakukan analisa terhadap kumpulan data dengan memisahkan kata tersebut dan menentukan struktur dari setiap kata tersebut.

Hasil pre-processing didapatkan kata yang sudah dilakukan pencocokan pada kamus singkatan, tokenisasi dan pembersihan karakter selain huruf. Setelah itu menghilangkan stopwords untuk kata-kata umum yang biasanya muncul dalam jumlah besar dan dianggap tidak memiliki makna. Proses dilakukan menggunakan function *remove_stopwords* dan kamus English dan Indonesia pada library NLTK dan Sastrawi.

Tabel 3 adalah tabel hasil pre-processing dimana kolom "DIAGNOSIS" merupakan text diagnosa asli yang diambil dari data diagnosis pasien, kolom "ICD" adalah kolom hasil pengkodean yang diperoleh dari data diagnosis pasien, kemudian kolom "TIDY TEXT" adalah hasil pre-processing dimana teks sudah dilakukan pre-processing menjadi sebagaimana tersaji dalam kolom tersebut.

Dari semua data yang sudah melalui pre-processing telah dipetakan berdasarkan kode ICD-10 yang digunakan selanjutnya dapat dilihat jumlah data total 3786 yang pada masing-masing kategori di kolom ICD yakni :

K21.9	1246	data
E11.9	1010	data
K30	607	data
I11.9	475	data
I10	448	data

Tabel 3. Hasil Pre-processing

DIAGNOSIS	ICD	TIDY_TEXT
GERD MIXED. PARACERVICAL SPASM. TYPHOID FEVER. ALERGI LEVOFLOXACIN	K21.9	[gastroesophageal, reflux, disease, mixed, paracervical, spasm, typhoid, fever, alergi, levofloxacin]
GERD. ANXIETY	K21.9	[gerd, anxiety]
DM2 O DGN TRIGGER FINGER. HIPOTHYROIDISM SUBKLINIK. OA GENU BILATERAL. HHD EC HT. PASCA LAMINEKTOMI. GASTROENTEROPATHY NSAIDS	E11.9	[dm, objective, trigger, finger, hipothyroidism, subklinik, osteoarthritis, genu, bilateral, hypertensive, heart, disease, et, causa, ht, pasca, laminektomi, gastroenteropathy, nsaid]
OBS KOLIK ABDOMEN INTRACTABLE NON SPESIFIK EC GERD (ESOPHAGITIS LA GRADE B), GASTRITIS ANTHRAL EROSIVA, GASTRODUODENITIS NON SPESIFIK. DISPEPSIA TIPE ULCUS. KOINSIDENSI TYPHOID FEVER. URTICARIA NON...	K21.9	[obs, kolik, abdomen, intractable, non, spesifik, et, causa, gerd, esophagitis, left, atrium, light, adaptation, grade, b, gastritis, anthral, erosiva, gastroduodenitis, non, spesifik, dispepsia, ti...]
HT. GERD. CEPALGIA	I10	[ht, gerd, cephalgia]
OBS.CHRONIC ABDOMINAL PAIN. DISPEPSIA	K30	[obschronic, abdominal, pain, dispepsia]
POST COVID 19. GERD. CAD2VD POST PCI. DISLIPIDEMIA	K21.9	[posterior, covid, gerd, cadvd, posterior, pci, dislipidemia]
DISPEPSIA TIPE DISMOTILITAS - GERD. OBS POLINEUROPATI EC SUSP SPOND CERVICALIS. IDIOSINKRASI MOZUKU. HT STG I	K30	[dispepsia, tipe, dismotilitas, gerd, obs, polineuropati, ec, suspect, spond, cervicalis, idiosinkrasi, mozuku, hipertensi, stg]
DM 2 OBES DGN HIPERGLIKEMIA AKUT. ORAL ULCER. SPONDILOSIS LUMBALIS DG PARALUMBAL SPASM CUM FROZEN SHOULDER S. CKR. PARONOKIA DIG I MANUS D	E11.9	[diabetes, mellitus, obese, dgn, hiperglikemia, akut, oral, ulcer, spondilosis, lumbalis, paralumbal, spasm, cum, frozen, shoulder, ckr, paronokia, dig, manus]
OBS NAUSEA VOMITUS INTRACTABEL CUM VERTIGO. DISPEPSIA	K30	[obs, nausea, vomitus, intractabel, cum, vertigo, dispepsia]
.....

2.2. Text-representation

Setelah pre-processing selesai akan dilanjutkan tahap text-representation pada tahap ini diagnosis dokter yang sudah disegmentasi dan tokenisasi akan diubah menjadi data yang lebih terstruktur, sehingga data tersebut dapat diklasifikasi. Proses ini akan menggunakan metode word2vec yang dikembangkan oleh Thomas Mikolov, dimana merupakan implementasi jaringan syaraf tiruan yang dapat mengolah kata-kata dari dataset yang sangat besar dengan waktu yang relatif singkat dengan nilai akurasi yang lebih baik. Metode ini bekerja dengan cara mengambil korpus teks sebagai input, lalu menghasilkan representasi vektor dari setiap kata yang ada pada korpus teks tersebut sebagai output. Hasil dari file vektor ini dapat digunakan sebagai input model pada natural language processing dan aplikasi machine learning. Selain itu, vektor kata tersebut juga dapat digunakan dalam mengukur jarak kedekatan terhadap vektor kata yang lain [15]

Arsitektur neural network yang digunakan pada word2vec adalah neural network dengan sebuah hidden layer yang disebut dengan projection layer dan di-training menggunakan stochastic gradient descent dengan algoritma backpropagation. Projection layer adalah

Model: "sequential"

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 64)	6464
dense_1 (Dense)	(None, 16)	1040
dense_2 (Dense)	(None, 4)	68
dense_3 (Dense)	(None, 5)	25
Total params: 7,597		
Trainable params: 7,597		
Non-trainable params: 0		

Gambar 2. Metode sequential mapping dari kata yang ada pada konteks n-gram ke dalam bentuk continuous vectors. Kata-kata yang muncul bersamaan atau berulang kali pada konteks N-gram memiliki tendensi untuk teraktifasi oleh weight yang sama, sehingga terjadi korelasi antar kata-kata.

Weights menghubungkan input layer dengan hidden layer, dan hidden layer dengan output layer. Weights diantara input layer dan hidden layer direpresentasikan dengan matriks W berukuran V x N, dimana V adalah dimensi dari input layer dan N adalah dimensi dari hidden layer. Sedangkan diantara hidden layer dan output layer, matriks W direpresentasikan dengan matriks berukuran N x V.

2.3. Membangun model klasifikasi

Neural Network akan digunakan sebagai metode klasifikasi, adalah kumpulan neuron yang diatur dalam urutan beberapa lapisan, di mana neuron menerima sebagai input aktivasi neuron dari lapisan sebelumnya, dan melakukan perhitungan matematis sederhana (misalnya jumlah tertimbang dari input diikuti oleh aktivasi nonlinier). Neuron jaringan bersama-sama menerapkan pemetaan nonlinier yang kompleks dari input ke output. Pemetaan antara input dan output dipelajari dari data dengan mengadaptasi bobot setiap neuron menggunakan teknik yang disebut error backpropagation. Peneliti akan menggunakan set data latih berlabel untuk melakukan klasifikasi pada data yang serupa dan tidak berlabel [8].

Hasil dari *word embedding* dengan metode word2vec dimana proses ini adalah proses mentransformasikan teks ke dalam vector yang digunakan sebagai input pada pemodelan ANN. Data dilakukan pembagian dengan komposisi 70% untuk data training dan 30% untuk data testing, array hasil text-representation merupakan masukan dari bagi input layer model. Setiap kata masuk ke dalam embedding layer untuk ditransformasikan menjadi data vektor yang terdapat di vector conversion. Array hasil embedding layer Word2Vec dimodelkan dengan menggunakan fungsi sequential sebagaimana Gambar 3 dimana fungsi tersebut adalah model yang dinilai cocok untuk tumpukan layer biasa di mana setiap layer memiliki tepat satu tensor input dan satu tensor output. Diterapkan ketentuan pemodelan dengan jumlah input x dan 64 hidden layer dengan aktivasi relu.

Selanjutnya melakukan pelatihan model ANN pada data dengan model yang sudah didapat dengan ketentuan epoch = 20 dan batch size = 128, untuk memudahkan monitoring proses maka nilai verbose diberikan nilai 1 sebagaimana ditampilkan pada Gambar 4

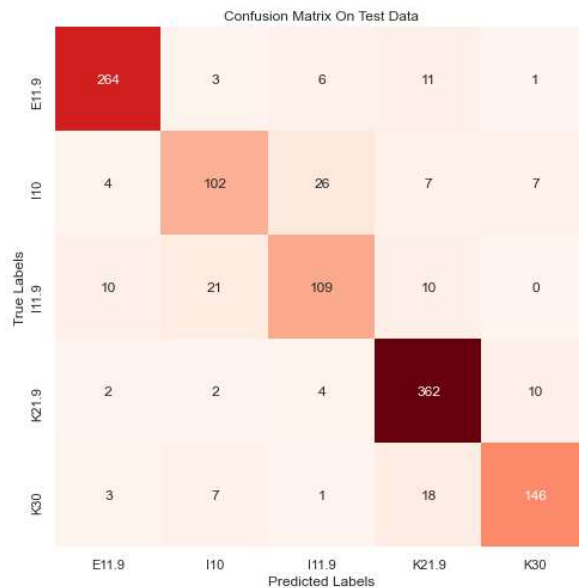
3. HASIL

```

Epoch 1/20
21/21 [=====] - 1s 2ms/step - loss: 1.4297 - accuracy: 0.4438
Epoch 2/20
21/21 [=====] - 0s 2ms/step - loss: 1.2012 - accuracy: 0.5060
Epoch 3/20
21/21 [=====] - 0s 2ms/step - loss: 1.0791 - accuracy: 0.5619
Epoch 4/20
21/21 [=====] - 0s 2ms/step - loss: 1.0032 - accuracy: 0.6132
Epoch 5/20
21/21 [=====] - 0s 2ms/step - loss: 0.9503 - accuracy: 0.6585
Epoch 6/20
21/21 [=====] - 0s 2ms/step - loss: 0.9076 - accuracy: 0.7321
Epoch 7/20
21/21 [=====] - 0s 2ms/step - loss: 0.8689 - accuracy: 0.7717
Epoch 8/20
21/21 [=====] - 0s 2ms/step - loss: 0.8359 - accuracy: 0.7909
Epoch 9/20
21/21 [=====] - 0s 2ms/step - loss: 0.8053 - accuracy: 0.8226
Epoch 10/20
21/21 [=====] - 0s 2ms/step - loss: 0.7789 - accuracy: 0.8355
Epoch 11/20
21/21 [=====] - 0s 2ms/step - loss: 0.7519 - accuracy: 0.8385
Epoch 12/20
21/21 [=====] - 0s 2ms/step - loss: 0.7282 - accuracy: 0.8434
Epoch 13/20
21/21 [=====] - 0s 2ms/step - loss: 0.7067 - accuracy: 0.8475
Epoch 14/20
21/21 [=====] - 0s 2ms/step - loss: 0.6866 - accuracy: 0.8570
Epoch 15/20
21/21 [=====] - 0s 2ms/step - loss: 0.6684 - accuracy: 0.8604
Epoch 16/20
21/21 [=====] - 0s 2ms/step - loss: 0.6502 - accuracy: 0.8672
Epoch 17/20
21/21 [=====] - 0s 2ms/step - loss: 0.6346 - accuracy: 0.8709
Epoch 18/20
21/21 [=====] - 0s 2ms/step - loss: 0.6180 - accuracy: 0.8755
Epoch 19/20
21/21 [=====] - 0s 2ms/step - loss: 0.6034 - accuracy: 0.8830
Epoch 20/20
21/21 [=====] - 0s 2ms/step - loss: 0.5893 - accuracy: 0.8857
    
```

Gambar 3. Proses pelatihan model

Untuk mengetahui performa dari Algoritma Artificial Neural Network, maka dilakukan pengujian terhadap model. Hasil klasifikasi akan ditampilkan dalam bentuk confusion matrix. heatmap confusion matrix terdiri dari predicted labels sebagai hasil prediksi dan true labels sebagai labels aktual. Model confusion matrix 3x3 ditunjukkan pada Gambar 4.



Gambar 4. Hasil evaluasi

	Precision	recall	f1-score	support
E11.9	0.933	0.926	0.930	285
I10	0.756	0.699	0.726	146
I11.9	0.747	0.727	0.736	150
K21.9	0.887	0.953	0.919	380
K30	0.890	0.834	0.861	175
Accuracy			0.865	1136
macro avg	0.842	0.828	0.834	1136
weighted avg	0.864	0.865	0.864	1136

Dari output di atas, dapat dilihat bahwa performa model cukup baik karena memiliki akurasi 86.5%. Pada interpretasi hasil yang akan digunakan adalah F-1 score dimana F-1 score adalah harmonic mean dari precision dan recall dengan semakin tinggi nilainya akan mengindikasikan bahwa model memiliki precision dan recall yang cukup baik.

Dapat dilihat pada kode E11.9 memiliki F-1 paling tinggi yakni 0.930 dari jumlah total data sebanyak 1010 data, selanjutnya kode K21.9 dengan total data 1246 memiliki nilai F-1 score sebanyak 0.919, lalu kode K30 dengan total data 607 data memiliki nilai F-1 score cukup baik yakni 0.861, dan dua kode terakhir yaitu I11.9 dan I10 dengan total data dibawah 500 mendapatkan nilai F-1 score yang tidak jauh berbeda yaitu 0.736 untuk I11.9 dan 0.726 untuk I10.

4. PEMBAHASAN

Dalam penelitian ini, telah dikembangkan dan dilatih model klasifikasi teks dari diagnosis dokter menggunakan teknik deep learning untuk mengidentifikasi diagnosis tersebut masuk pada katedori ICD-10 yang mana. Kemudian model ini telah diuji dan dievaluasi dengan dataset kumpulan penyakit dari Klinik Penyakit Dalam dengan jumlah 3786 data pasien. Hasil evaluasi metrik dapat dilihat bahwa model yang dihasilkan cukup baik yakni rata-rata 0.83. Kami menemukan bahwa model cenderung memiliki performa yang lebih baik dalam mengklasifikasikan kode E11.9 Type 2 diabetes mellitus without complications dan K21.9 Gastro-oesophageal reflux disease without oesophagitis daripada 3 penyakit yg lain. Hal ini mungkin karena adanya ketidakseimbangan kelas dalam dataset kami.

Dari rerata nilai F1-score yang 0.83 dimana F1-score adalah harmonic mean (rata-rata harmonik) antara presisi dan recall. Ini memberikan gambaran tentang keseimbangan antara presisi dan recall. Nilai F1-score yang tinggi menunjukkan bahwa model memiliki keseimbangan yang baik antara kemampuan untuk menghindari positif palsu (*false positive*) dan mengabaikan positif sebenarnya (*false negative*). Namun apabila dilihat dari hasil setiap kode dimana data sample semakin kecil maka nilai akurasi juga semakin kecil seperti halnya digambarkan oleh kode I11.9 dan I10 namun nilai akurasi masih cukup baik yakni masih dikisaran 70%

dari hasil pemodelan yang diperoleh dapat disimpulkan bahwa *unstructured text* dari diagnosis dokter masih bisa dipertahankan maknanya melalui proses ekstraksi fitur dengan menggunakan Word2vec dimana metode ini dikenal cukup baik dalam merepresentasikan kata ke dalam vektor yang dapat membawa makna semantik dari kata tersebut. Sehingga model tersebut bisa digunakan sebagai referensi dalam membangun model klasifikasi pengkodean penyakit berdasarkan ICD10.

5. KESIMPULAN

Berdasarkan dari hasil pemodelan text-mining untuk pengkodean penyakit berdasarkan kode ICD-10 dapat disimpulkan bahwa Text-mining dapat digunakan untuk membantu petugas rekam medis dalam pengkodean penyakit berdasarkan kode ICD-10 penggunaan model deep learning mempercepat proses pengkodean penyakit, menghemat waktu dan sumber daya kesehatan. Yang memungkinkan pemberian perawatan yang lebih cepat dan efisien kepada pasien.

Algoritma Artificial Neural Network (ANN) memiliki nilai akurasi yang cukup baik dalam mengklasifikasikan penyakit berdasarkan kode ICD-10 yakni sebesar 86.5% model deep learning mampu mencapai tingkat akurasi yang tinggi dalam pengklasifikasian penyakit ke dalam kode ICD-10. Ini mengurangi risiko kesalahan manusia dalam proses pengkodean penyakit, yang dapat memiliki dampak besar pada diagnosis dan pengelolaan pasien. Pengujian di Lingkungan Klinis yang Nyata yakni penelitian ini akan digunakan untuk membantu petugas rekam medis dalam pengkodean penyakit pada Rumah Sakit dimana data tersebut diambil dan keberhasilan penggunaan model deep learning dalam pengklasifikasian penyakit ke dalam kode ICD-10 memerlukan kolaborasi erat antara profesional medis yang memahami konteks klinis dan ilmuwan data yang memiliki keahlian dalam pengembangan model. Dengan demikian, penggunaan deep learning dalam pengklasifikasian penyakit ke dalam kode ICD-10 menjanjikan berbagai manfaat dalam meningkatkan akurasi, efisiensi, dan produktivitas dalam sektor perawatan kesehatan. Namun, perlu perhatian yang cermat terhadap implementasi yang aman dan kebutuhan untuk pemeliharaan serta pembaruan model seiring berjalannya waktu.

Saran untuk penelitian selanjutnya adalah peneliti dapat membuat interface yang terintegrasi dengan Sistem Manajemen Rumah Sakit

(SIMRS) sehingga proses klasifikasi dapat berjalan realtime untuk kebutuhan data pola penyakit. Selanjutnya dalam proses *word embedding* peneliti dapat melakukan kombinasi dengan metode lain untuk meningkatkan akurasi model.

Conference on Computer Engineering & Systems (ICCES), IEEE, 2014, pp. 192–197.

- [15] Y. Mardi, “Data Mining Rekam Medis Untuk Menentukan Penyakit Terbanyak Menggunakan Decision Tree C4. 5,” *Jurnal Sains dan Informatika: Research of Science and Informatic*, vol. 4, no. 1, pp. 40–53, 2018.

DAFTAR PUSTAKA

- [1] Y. Chen, H. Lu, and L. Li, “Automatic ICD-10 coding algorithm using an improved longest common subsequence based on semantic similarity,” *PLoS One*, vol. 12, no. 3, p. e0173410, 2017.
- [2] H. Dalianis, *Clinical text mining: Secondary use of electronic patient records*. Springer Nature, 2018.
- [3] D. M. Agustine and R. D. Pratiwi, “Hubungan Ketepatan Terminologi Medis dengan Keakuratan Kode Diagnosis Rawat Jalan oleh Petugas Kesehatan di Puskesmas Bambanglipuro Bantul,” *Jurnal Kesehatan Vokasional*, vol. 2, no. 1, pp. 113–121, 2017.
- [4] L. Zhou, C. Cheng, D. Ou, and H. Huang, “Construction of a semi-automatic ICD-10 coding system,” *BMC Med Inform Decis Mak*, vol. 20, pp. 1–12, 2020.
- [5] S. Boytcheva, “Automatic matching of ICD-10 codes to diagnoses in discharge letters,” in *Proceedings of the second workshop on biomedical natural language processing*, 2011, pp. 11–18.
- [6] U. Raja, T. Mitchell, T. Day, and J. M. Hardin, “Text mining in healthcare. Applications and opportunities,” *J Healthc Inf Manag*, vol. 22, no. 3, pp. 52–56, 2008.
- [7] S. Wang *et al.*, “Using Deep Learning for Automatic Icd-10 Classification from FreeText Data,” *Eur J Biomed Inform*, vol. 16, no. 1, pp. 1–10, 2020.
- [8] N. N. Widyastuti, A. A. Bijaksana, and I. L. Sardi, “Analisis word2vec untuk perhitungan kesamaan semantik antar kata,” *eProceedings of Engineering*, vol. 5, no. 3, 2018.
- [9] Y. Wang *et al.*, “MedSTS: a resource for clinical semantic textual similarity,” *Lang Resour Eval*, vol. 54, pp. 57–72, 2020.
- [10] L. Pereira, R. Rijo, C. Silva, and M. Agostinho, “ICD9-based text mining approach to children epilepsy classification,” *Procedia Technology*, vol. 9, pp. 1351–1360, 2013.
- [11] J. Nielsen, “Usability 101: Introduction to Usability,” <https://www.nngroup.com/articles/usability-101-introduction-to-usability>.
- [12] D. R. Prajapat, “Text Classification: BERT vs DNN,” <https://eng.zemosolabs.com/text-classification-bert-vs-dnn-b226497c9de7>.
- [13] M. K. Ross, W. Wei, and L. Ohno-Machado, ““Big data” and the electronic health record,” *Yearb Med Inform*, vol. 23, no. 01, pp. 97–104, 2014.
- [14] R. Mahmoud, N. El-Bendary, H. M. O. Mokhtar, and A. E. Hassanien, “ICF based automation system for spinal cord injuries rehabilitation,” in *2014 9th International*