

Article history

Received April 6, 2021

Accepted December 29, 2021

ANALISA REKAM MEDIS ELEKTRONIK UNTUK MENENTUKAN DIAGNOSA MEDIS DALAM KATEGORI BAB ICD 10 MENGGUNAKAN MACHINE LEARNING**Zulius Akbar Amin, Widya Cholil, M. Izman Herdiansyah, Edi Surya Negara**

Program Pasca Sarjana/Magister Teknik Informatika, Universitas Bina Darma Palembang

Email: zulius.akbar.amin@gmail.com, widya@binadarma.ac.id, m.herdiansyah@binadarma.ac.id, e.s.negara@binadarma.ac.id

Abstract

Based on observations of the business process flow at the Siti Fatimah Hospital, the background for this study was the medical record document and ICD-10 code which was carried out manual diagnosis, making it difficult for the medical record section in the proper and fast CHAPTER arrangement of the ICD-10 code. The International Statistical Classification of Diseases and Related Health Problems (ICD) can be used to calculate or record a valid patient history of hospitalization. The Cross-Industry Standard Process For Data Mining (CRISP-DM) method is used in this study to become a strategy to describe the problem in general from the domain or research unit. While the machine learning algorithm for multiclass classification uses the Naïve Bayes algorithm, Support Vector Machine, Logistic Regression to create a diagnostic model for medical action. This study predicts ICD-10 chapter categories from medical action records from electronic medical records. With this research, it is hoped that machine learning can facilitate the medical record section in predicting the ICD-10 chapter category by analyzing electronic medical record data using the Chapter ICD-10 Decision Support System information system.

Keywords: Electronic Medical Records, ICD-10, Machine Learning.

Abstrak

Berdasarkan observasi di alur proses bisnis pada rumah sakit RSUD Siti Fatimah, Maka yang melatarbelakangi penelitian ini adalah dokumen rekam medis dan kode ICD-10 yang dilakukan diagnosis manual sehingga menyulitkan bagian rekam medis dalam menetapkan BAB kode ICD-10 yang tepat dan cepat. *International Statistical Classification of Diseases and Related Health Problems (ICD)* dapat digunakan dalam menghitung atau membuat catatan riwayat perawatan pasien yang valid di rumah sakit. Metode *Cross-Industry Standard Process For Data Mining (CRISP-DM)* digunakan dalam penelitian ini menjadi strategi menguraikan masalah secara umum dari *domain* atau unit penelitian. Sedangkan algoritma *machine learning* untuk pengklasifikasian *multiclass* menggunakan algoritma *Naïve Bayes*, *Support Vector Machine*, *Logistic Regression* untuk membuat model diagnosa tindakan medis. Penelitian ini memprediksi kategori bab ICD-10 dari catatan tindakan medis dari rekam medis elektronik. Dengan adanya penelitian ini diharapkan *machine learning* dapat mempermudah bagian rekam medis dalam memprediksi kategori bab ICD-10 dengan menganalisa data rekam medis elektronik menggunakan sistem informasi *Chapter ICD-10 Decision Support System*.

Kata Kunci: Rekam Medis Elektronik, ICD-10, *Machine Learning*

1. PENDAHULUAN

Catatan medis atau rekam medis pasien merupakan catatan, berkas pasien, serta dokumen tentang identitas, laporan pemeriksaan, informasi pengobatan, dan tindakan medis pasien pada sarana pelayanan untuk rawat jalan dan rawat inap baik yang dikelola pemerintah maupun dikelola swasta [1]. Untuk diagnosis penyakit, Indonesia menggunakan ICD-10 sedangkan untuk prosedur/tindakan Indonesia menggunakan ICD-9-CM [2]. *International Statistical Classification of Diseases and Related Health Problems* (ICD) digunakan untuk menganalisa dan mendiagnosa penyakit. kode alfanumerik memungkinkan digunakan untuk penyimpanan informasi, pengambilan data, dan analisis data yang mudah. ICD menjadi sebuah klasifikasi untuk diagnose berstandarisasi internasional dalam semua tujuan epidemiologis manajemen kesehatan dan umum [3].

Electronic healthy record (EHR) mencakup berbagai informasi klinis pasien seperti riwayat medis, tanda-tanda vital, hasil tes laboratorium, dan catatan klinis. Data tersebut dapat membantu dalam membangun informasi yang berkelanjutan antara dokter dan pasien. Lebih dari itu, tinjauan sistematis telah menunjukkan bahwa kualitas perawatan klinis dapat ditingkatkan dengan menggunakan analisis prediktif berdasarkan data EHR [4]. *Electronic healthy record* juga dapat meningkatkan kualitas perawatan klinis menggunakan berbagai analisis berbasis prediksi data. *Electronic healthy record* berisi data terstruktur dan tidak terstruktur, banyak sistem yang fokus terhadap data terstruktur untuk membangun sebuah sistem pengambilan keputusan klinis [5]. Sementara lebih dari 80% data kesehatan adalah teks. Contohnya, catatan klinis berisi informasi tentang riwayat medis pasien dan pengamatan serta pendapat dokter mengenai interaksinya dengan pasien [6].

Elektronik healthy record sangat banyak manfaat seperti membantu untuk menyimpan data pasien, mengurangi kehilangan berkas rekam medis secara fisik, mempercepat tindakan pendukung lain (obat, laboratorium, radiologi, tindakan), mempermudah mengetahui untuk ketersediaan obat, serta mempermudah dalam transaksi pembayaran. *International Statistical Classification of Diseases and Related Health Problems* (ICD) dapat digunakan dalam menghitung atau membuat catatan riwayat perawatan pasien yang valid. Saat ini, tugas

menetapkan kode diagnosis dilakukan secara manual oleh bagian rekam medis. Dokumen rekam medis dan kode ICD-10 yang banyak membuat klasifikasi diagnosis manual menyulitkan bagian rekam medis dalam menetapkan kode ICD-10 yang tepat dan cepat. Dengan dokumen rekam medis yang telah diklasifikasi maka dapat memudahkan pencarian informasi dalam menemukan Bab ICD-10 yang tepat karena dokumen rekam medis telah dikelompokkan berdasarkan kategori yang mencerminkan isi rekam medis tersebut.

Text mining merupakan proses pembelajaran yang berkelanjutan dari user yang berinteraksi terus menerus menggunakan tools analisis. Hampir mirip pada data *mining*, teks *mining* akan mengekstrak informasi yang tepat dari berbagai sumber data dengan cara identifikasi dan eksplorasi pola yang menarik. Tetapi dalam masalah text *mining* sumber data yang digunakan adalah golongan pola yang menarik yang tidak dapat ditemukan pada *database* terstruktur tetapi dari teks yang tidak terstruktur dalam kumpulan dokumen [7]. Dalam penelitian ini, dokumen-dokumen akan ditraining kedalam sesuai label ICD-10. Prediksi ini akan mempelajari kumpulan data yang berupa data *training* sehingga terbentuk suatu pola atau model yang dapat digunakan untuk penentuan suatu kelas pada data test. Di dalam aplikasi modern khususnya dalam proses klasifikasi seperti klasifikasi teks, klasifikasi buku, klasifikasi film, klasifikasi gambar atau klasifikasi berita, sangat dimungkinkan apabila kategori kelas data yang ada lebih dari 2. Banyak metodologi *machine learning* yang dapat digunakan untuk pengklasifikasian multiclass seperti adalah *Naïve Bayes*, *Support Vector Machine*, *Logistic Regression*. Penelitian ini akan memprediksi kategori bab ICD-10 dari catatan tindakan medis dari rekam medis elektronik. Berdasarkan latar belakang permasalahan yang telah diuraikan, maka peneliti merasa tertarik dalam melakukan Analisa rekam medis elektronik untuk membuat model diagnosa medis untuk memprediksi kategori bab ICD10 menggunakan *machine learning*.

2. METODE PENELITIAN

Penelitian ini menggunakan Metode CRISP-DM merupakan standarisasi proses *data mining* sebagai strategi pemecahan masalah secara umum dari bisnis atau unit penelitian [8].

Pendekatan ini secara garis besar terdiri dari 6 fase, sebagai berikut :

1. *Business Understanding Phase*. Pada tahap persiapan penelitian, penulis melakukan pengamatan (observasi) alur proses bisnis terlebih dahulu pada objek secara langsung.
2. *Data Understanding Phase*. Pada fase ini peneliti mempelajari alur proses data didalam rumah sakit yang sudah berjalan menggunakan Sistem Informasi Manajemen Rumah Sakit (SIM-RS).
3. *Data preparation phase*. Peneliti melakukan seleksi data tindakan yang telah dilabeli dengan BAB ICD-10 dari *database* SIM RS menggunakan *SQL Query*.
4. *Modeling phase*, pada fase ini data yang sudah dimiliki dilakukan *text preprocessing*, *training* dan *testing* menggunakan algoritma *machine learning* yang digunakan yaitu *naïve bayes*, *support vector machine*, *logistic regression* menggunakan data training dan testing.
5. *Evaluation Phase*, pada fase ini akan dilakukan pengukuran kesalahan, analisis akan mengukur *precision*, *recall* dan *F1-score*.
6. *Development Phase*, pada fase ini akan dilakukan pembuatan program menggunakan model yang telah dibuat untuk menunjang proses keputusan diagnose medis.

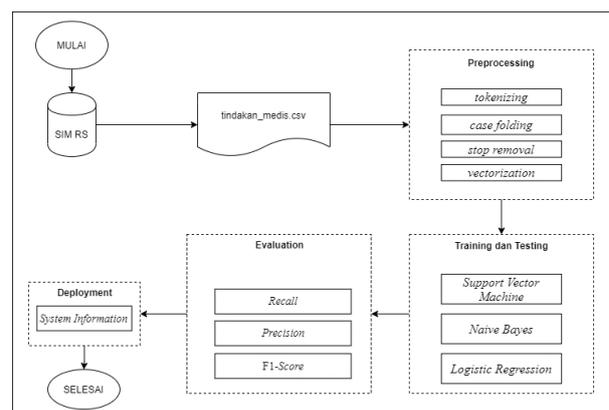


Gambar 1. Kerangka Pikiran Penelitian

Dataset yang akan digunakan pada penelitian ini menggunakan Data dari *Database* SIM RS Di RSUD Siti Fatimah Provinsi Sumatera Selatan. Penelitian ini peneliti menggunakan tabel tindakan medis dan diagnose penyakit ICD-10 berupa data CSV dari tindakan medis yang merupakan kata-kata dalam bentuk teks. Data penunjang yang lain adalah data sekunder yang terdiri dari beberapa jurnal dan buku yang berkaitan dengan penelitian. Teknik studi dokumentasi tentang catatan medis dari tahun 2019 dan 2020 di RSUD Siti Fatimah Provinsi Sumatera Selatan.

3. HASIL DAN PEMBAHASAN

Pada bagian ini dilakukan pembahasan pengembangan dalam klasifikasi tindakan medis dalam memprediksi BAB ICD-10 menggunakan algoritma *naive bayes*, *support vector machine*, *logistic regression*. Model prediksi dikembangkan dan dievaluasi pada bab ini. Bagian ini juga dilakukan pembahasan tentang proses pembuatan model dan evaluasi hasilnya menggunakan *precision*, *recall* dan *f1-score* lalu dibuatkan program untuk mendukung pengambilan keputusan BAB ICD-10.



Gambar 2. Model Penelitian

Preprocessing

Dataset tindakan medis yang digunakan pada penelitian ini dilakukan preprocessing menggunakan *tokenizing*, *case folding* proses *preprocessing* dilakukan dataset dilakukan pengisian teks pada data yang kosong menggunakan modul python *fillna()*. Selanjutnya mengubah teks menjadi huruf kecil dan melakukan proses data *reduction* menghapus simbol dan angka pada kolom tindakan menggunakan modul *.re()*. *Tokenizing* dilakukan

menggunakan modul python `.split()` dan melakukan data *cleaning* menggunakan *stopword*, hasil dari *preprocessing* di simpan *variable array* bernama `corpus_indo`. Pada kode selanjutnya membuat kolom baru bernama *tindakan_cleaning* dengan *value array* berdasarkan *index variable* bernama `df` selanjutnya menghapus kolom *tindakan_refill*. Setelah proses *preprocessing* dilakukan dataset siap digunakan untuk proses *training* dan *testing*.

Training dan Testing

Setelah data tindakan medis berhasil dilakukan proses *preprocessing* selanjutnya dilakukan membagi data *training* dan *testing dataset* yang digunakan untuk proses *training* adalah 0.9 atau 90% dari jumlah dataset dan untuk proses *testing* adalah 0.1 atau 10% dari jumlah *dataset*. *Random state* 42 digunakan agar hasil pembagian *split* tetap sama. Proses *classification* penelitian ini menggunakan algoritma *machine learning Naïve Bayes, Support Vector Machine, Logistic Regression*. proses menempatkan dokumen teks secara otomatis ke dalam suatu *class* atau kategori berdasarkan isi dari teks tersebut.

Support Vector Machine

Module python yang utama digunakan yaitu *SGDClassifier*, selain itu penelitian ini juga menggunakan *CountVectorizer* dan *TfidfVectorizer* dari module *sklearn* yang dikemas menggunakan *pipeline* karena dapat dilakukan sejumlah kerja secara bersamaan dalam tahap yang berbeda yang dilakukan secara kontinu pada algoritma SVM yang diproses. *SGDClassifier* menggunakan parameter *hinge loss* yang digunakan untuk klasifikasi, *penalty* 12 standar regular untuk *linear Support vector machine*, *alpha* menggunakan nilai *default* 0.0001, *random state* = 42 untuk membagi *array* dalam untuk mendapatkan hasil yang sama, *max_iter* nilai yang digunakan untuk mengulang kembali ke awal *training*. Tol *none* pelatihan akan berhenti jika *loss* melebihi nilai titik *loss* yang ada.

Tabel 1. *Precision, recall, dan F1-Score Support Vector Machine*

Class	Support Vector Machine		
	precision	recall	f1-score
X0099^001	0.36	0.43	0.40
X0099^002	0.25	0.05	0.08
X0099^003	0.29	0.06	0.10
X0099^004	0.58	0.16	0.25
X0099^005	0.00	0.00	0.00
X0099^006	0.38	0.35	0.36
X0099^007	0.66	0.61	0.63
X0099^008	0.53	0.60	0.56
X0099^009	0.30	0.75	0.64
X0099^010	0.38	0.55	0.39
X0099^011	0.44	0.37	0.38
X0099^012	0.50	0.27	0.33
X0099^013	0.49	0.32	0.39
X0099^014	0.80	0.28	0.36
X0099^015	0.65	0.92	0.85
X0099^016	0.00	0.68	0.66
X0099^017	0.39	0.00	0.00
X0099^018	0.69	0.19	0.26
X0099^019	1	0.61	0.65
X0099^020	0.69	0.25	0.40
X0099^021	0.00	0.77	0.73
X0099^022	0.00	0.00	0.00

Hasil pengukuran menunjukkan algoritma untuk dengan nilai *precision* 1 dan nilai *recall* 0.61 sehingga bisa dikatakan model dapat mengklasifikasi hampir seluruh tindakan medis pada *class X0099^019 (XIX-Injury, poisoning and certain other consequences of external causes)*.

Logistic Regression

Module python yang utama digunakan yaitu *LogisticRegression*, selain itu penelitian ini menggunakan *CountVectorizer* dan *TfidfVectorizer* dari module *sklearn* yang dikemas menggunakan *pipeline* karena dapat dilakukan sejumlah kerja secara bersamaan dalam tahap yang berbeda yang dilakukan secara kontinu pada algoritma *Logistic Regression* yang diproses. *LogisticRegression* menggunakan parameter *n_jobs* yang memiliki *value* bilangan *integer* digunakan untuk menentukan jumlah *CPU Cores* yang digunakan, *n_jobs* diberi nilai 1 tetapi parameter ini akan diabaikan jika parameter *solver* = *liblinear*, parameter *C* memiliki *value* bilangan *float*, parameter ini untuk meningkatkan besaran nilai parameter dalam menerapkan penalti untuk mengurangi *overfitting* saat melatih model.

Tabel 2. Precision, recall, dan F1-Score Logistic Regression

Class	Logistic Regression		
	precision	recall	f1-score
X0099^001	0.47	0.43	0.45
X0099^002	0.35	0.20	0.25
X0099^003	0.11	0.06	0.08
X0099^004	0.34	0.26	0.29
X0099^005	0.00	0.00	0.00
X0099^006	0.27	0.35	0.31
X0099^007	0.50	0.83	0.62
X0099^008	0.58	0.58	0.58
X0099^009	0.48	0.69	0.57
X0099^010	0.41	0.44	0.43
X0099^011	0.40	0.38	0.39
X0099^012	0.50	0.17	0.25
X0099^013	0.48	0.32	0.39
X0099^014	0.52	0.36	0.43
X0099^015	0.86	0.91	0.88
X0099^016	0.72	0.71	0.71
X0099^017	0.33	0.06	0.11
X0099^018	0.37	0.30	0.33
X0099^019	0.64	0.62	0.63
X0099^020	0.00	0.00	0.00
X0099^021	0.69	0.72	0.70
X0099^022	0.00	0.00	0.00

Naïve Bayes

Module python yang utama digunakan seperti *MultinomialNB*, selain itu penelitian ini menggunakan *CountVectorizer* dan *TfidfVectorizer* dari module *sklearn* yang dikemas menggunakan *pipeline* karena dapat dilakukan sejumlah kerja secara bersamaan dalam tahap yang berbeda yang dilakukan secara kontinu pada algoritma *MultinomialNB* yang diproses. Proses klasifikasi dengan algoritma *Multinomial Naïve Bayes* untuk dengan menghitung kemungkinan kalimat tindakan medis terhadap kelas/labelnya.

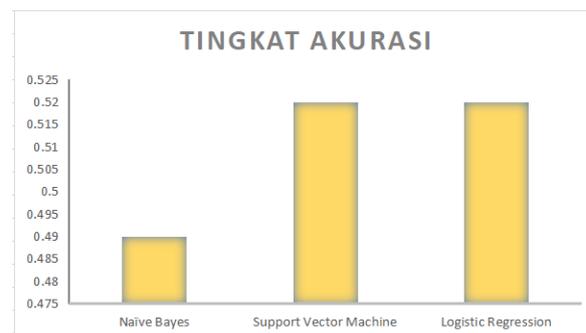
Tabel 3. Precision, recall, dan F1-Score Naïve Bayes

Class	Naïve Bayes		
	precision	recall	f1-score
X0099^001	0.44	0.35	0.39
X0099^002	0.50	0.05	0.09
X0099^003	0.00	0.00	0.00
X0099^004	0.59	0.13	0.21
X0099^005	0.00	0.00	0.00
X0099^006	0.75	0.12	0.20
X0099^007	0.48	0.78	0.59
X0099^008	0.78	0.52	0.62
X0099^009	0.43	0.83	0.57
X0099^010	0.42	0.38	0.40
X0099^011	0.38	0.37	0.37
X0099^012	0.80	0.13	0.23
X0099^013	0.67	0.32	0.44
X0099^014	0.33	0.02	0.03
X0099^015	0.69	0.91	0.78
X0099^016	0.59	0.79	0.67
X0099^017	0.00	0.00	0.00
X0099^018	0.30	0.39	0.34
X0099^019	0.58	0.45	0.51
X0099^020	0.00	0.00	0.00
X0099^021	0.69	0.67	0.68
X0099^022	0.00	0.00	0.00

Hasil pengukuran menunjukkan algoritma untuk dengan nilai *precision* 0.80 dan nilai *recall* 0.13 sehingga bisa dikatakan model dapat mengklasifikasi hampir seluruh tindakan medis pada class X0099^012 (*XII-Diseases of the musculoskeletal system and connective tissue*)

Evaluasi

Secara keseluruhan class, *Support Vector Machine* dan *Logistic Regression* memiliki tingkat akurasi yang sama 0.52% sedangkan naïve bayes memiliki akurasi sebenar 0.49% dari *multi class* dengan jumlah class sebanyak 22 *chapter* diagnosa penyakit, tingkat akurasi ketiga algoritma yang tertera dalam gambar 3.



Gambar 3. Tingkat Akurasi Algoritma

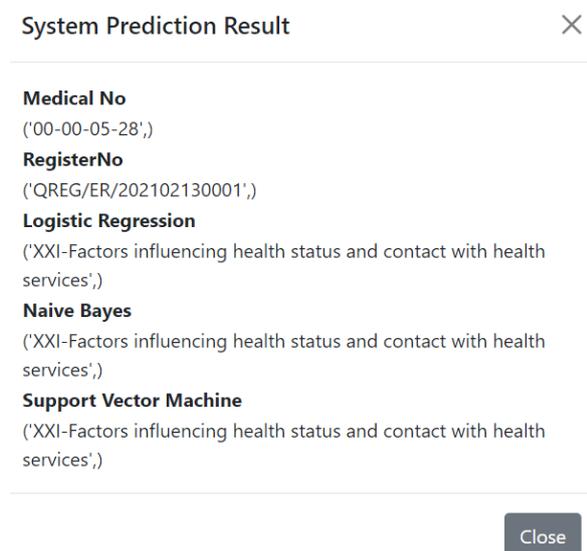
DEPLOYMENT

Perencanaan untuk *Deployment* yang dimulai dari langkah awal dan terlaksana menjadi satu kesatuan dalam CRISP-DM menjadi sistem informasi *Chapter ICD-10 Decision Support System* yang berguna untuk proses bisnis dalam hal ini dibuat dan digunakan untuk membantu penetapan BAB ICD-10 yang digunakan oleh bagian rekam medis.

Menu	RegisteNo	MedicalNo	Unit Rawatan	Lokasi
Yes	QREG/ER/202101130010	00-00-28-54	IGD	RUANG IGD
Yes	QREG/ER/202101140003	00-01-28-32	IGD	RUANG IGD
Yes	QREG/RI/202101190001	00-01-29-42	NICU	RUANG BMRP NICU
Yes	QREG/ER/202101110009	00-00-16-87	IGD	RUANG IGD
Yes	QREG/RI/202102080008	00-01-36-72	RAWAT INAP LT 6	RAWAT INAP LT 6
Yes	QREG/ER/202101110013	00-01-13-93	IGD	RUANG IGD
Yes	QREG/RI/202102080002	00-01-36-49	RAWAT INAP LT 7	RAWAT INAP LT 7
Yes	QREG/ER/202102130001	00-00-05-28	IGD	RUANG IGD
Yes	QREG/ER/202101280011	00-01-34-11	IGD	RUANG IGD
Yes	QREG/RI/202101300001	00-01-34-27	RAWAT INAP LT 7	RAWAT INAP LT 7

Gambar 3. Chapter ICD-10 Decision Support System

Sistem akan menampilkan daftar pasien yang masih aktif dan secara sistem masih dilayani dalam SIM RS untuk membantu memprediksi BAB ICD-10 oleh bagian rekam medis. Sistem menampilkan informasi nomor pendaftaran, nomor rekam medis, unit Pelayanan, lokasi Pelayanan. Menu dengan nama ML yang berwarna biru akan menampilkan hasil prediksi dari model yang telah dibuat sebelumnya yaitu *Naïve Bayes*, *Support Vector Machine*, *Logistic Regression*.



Gambar 4. *System Prediction Result*

Hasil Prediksi BAB ICD-10 diperoleh sesuai dengan informasi dan dokumen daftar tindakan yang diberikan oleh Para Medis Untuk Pasien, Sehingga Informasi dapat membantu bagian rekam medis untuk menetapkan BAB ICD-10 pada pasien. Dimana sebelumnya rekam medis melakukan proses penetapan diagnosa secara manual setelah pasien pulang dengan membaca dokumen rekam medis, hasil pemeriksaan labor / radiologi selama pasien di rumah sakit.

4. PENUTUP

Kesimpulan

System Prediction Result yang memiliki perbedaan hasil karena perbedaan karakter dokumen tindakan medis yang dibaca oleh model penelitian.

Diketahui bahwa Diagnosa ICD-10 pada Class X0099^015 (*XV-Pregnancy, Childbirth and the Puerperium*) memiliki *Precision, Recall, F1-Score* dengan nilai tinggi.

Model penelitian dapat digunakan dalam sistem informasi Chapter ICD-10 *Decision Support System* yang diharapkan membantu bagian rekam medis dalam menentukan BAB ICD-10.

Saran

Perlunya Penelitian lebih lanjut untuk mengetahui faktor perbedaan hasil antar model dan penggunaan variatif metode lain menggunakan dataset penelitian ini untuk meningkatkan nilai akurasi algoritma.

Perlunya Penelitian lebih lanjut penyebab Rendahnya *Class* Lain selain *class* X0099^015.

Hasil dari analisis rekam medis dapat digunakan sebagai penyediaan *Knowledge Manajemen* bagi Rumah Sakit.

5. REFERENSI

- [1] R. Depkes, *Peraturan Menteri Kesehatan Republik Indonesia Nomor 269 Tahun 2008 Tentang Rekam Medis*. Indonesia, 2008, p. 7.
- [2] R. Depkes, “Peraturan Menteri Kesehatan Republik Indonesia Nomor 27 Tahun 2014 tentang Petunjuk Teknis Sistem Indonesian Case Base Groups (INACBGs),” p. 50, 2014.
- [3] World Health Organization, *International Statistical Classification of Diseases and Related Health Problems*. 2010.
- [4] A. D. Black *et al.*, “The impact of ehealth on the quality and safety of health care: A systematic overview,” *PLoS Med.*, vol. 8, no. 1, pp. 1–16, 2011, doi: 10.1371/journal.pmed.1000387.
- [5] E. Choi, M. T. Bahadori, A. Schuetz, W. F. Stewart, and J. Sun, “Doctor AI: Predicting Clinical Events via Recurrent Neural Networks,” *JMLR Workshop Conf. Proc.*, vol. 56, pp. 301–318, 2016.
- [6] J. Huang, C. Osorio, and L. W. Sy, “An empirical evaluation of deep learning for ICD-9 code assignment using MIMIC-III clinical notes,” *Comput. Methods Programs Biomed.*, vol. 177, pp. 141–153, 2019, doi: 10.1016/j.cmpb.2019.05.024.
- [7] R. Feldman and J. Sanger, *The Text Mining Handbook*. 2006.
- [8] C. McCue, *Data Mining and Predictive Analytics*. 2015.