



SISTEM REKOMENDASI OBAT PENGGANTI MENGUNAKAN METODE CNN

Aditya Dwi Aryanto¹, Joan Santoso², Devi Dwi Purwanto³

¹Departemen Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Indonesia, Email: aditya.aryanto@gmail.com

²Departemen Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Indonesia, Email: joan@ists.ac.id

³Departemen Sistem Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Indonesia, Email: devi@sts.edu

STATUS ARTIKEL

Dikirim 1 November 2021

Direvisi 30 November 2021

Diterima 22 Desember 2021

Kata Kunci:

Rekomendasi Obat, CNN, Drug

Similarity

ABSTRAK

Dengan semakin banyaknya merk obat yang beredar dengan indikasi dan fungsi yang sama membuat dokter maupun apoteker dijadikan sebagai pilihan untuk memberikan obat yang tepat sesuai dengan penyakit yang diderita oleh pasien. Dengan semakin banyaknya merk dan jenis obat yang beredar saat ini, dimana tiap merk yang ada kadang kala memiliki bahan dasar dan indikasi yang sama ataupun berbeda. Selain itu, Obat-obatan yang tertera pada resep terkadang tidak dapat disajikan sepenuhnya karena berbagai alasan. Oleh karena itu, perlu dilakukan penggantian obat oleh apoteker. Penggantian obat tersebut dapat dilakukan oleh apoteker selama dokter mengizinkan penggantian dilakukan. Penelitian ini dilakukan untuk membuat rekomendasi obat pengganti saat obat tersebut dalam keadaan kosong. Penelitian ini menggunakan metode CNN. Hasil rekomendasi obat yang didapat, digunakan untuk mengurangi waktu proses pencarian obat yang dibutuhkan oleh pasien. Metode CNN digunakan untuk menentukan rekomendasi obat pengganti berdasarkan pemilihan obat yang paling ideal. Bahan obat yang direkomendasikan sama persis dengan obat-obatan sebelumnya yang dicari.

1. PENDAHULUAN

Dengan berkembangnya dunia kesehatan, dimana telah banyak dilakukan penelitian mengenai berbagai jenis penyakit, maka dikembangkan pula obat sebagai alat untuk membantu penyembuhan maupun digunakan sebagai penangkal untuk suatu penyakit. Saat ini, di Indonesia banyak beredar berbagai macam obat dengan indikasi yang berbeda-beda, yang digunakan baik untuk membantu penyembuhan, ataupun digunakan sebagai penangkal penyakit.

Dengan semakin banyaknya merk obat yang beredar dengan indikasi dan fungsi yang sama membuat dokter maupun apoteker dijadikan sebagai pilihan untuk memberikan obat yang tepat sesuai dengan penyakit yang diderita oleh pasien. Banyak lembaga farmasi yang telah menerbitkan daftar informasi mengenai obat yang beredar di Indonesia. Terdapat beberapa permasalahan terkait semakin banyaknya merk dan jenis obat yang beredar tersebut, dimana tiap merk yang ada kadang kala memiliki bahan dasar dan indikasi yang sama ataupun berbeda. Selain itu, Obat-obatan yang tertera pada resep terkadang tidak dapat disajikan sepenuhnya karena berbagai alasan, umumnya yang terjadi adalah obat tersebut habis, stok tidak tersedia di fasilitas kesehatan pemerintah dan swasta maupun di pasar. Permasalahan tersebut terkait kebutuhan informasi mengenai obat yang beredar tersebut. Sebenarnya pada beberapa obat memiliki kesamaan bahan dasar dan indikasi, sehingga apabila ada obat yang sudah tidak beredar di pasar, akan tetapi obat tersebut dibutuhkan oleh pasien berdasarkan resep yang telah diberikan oleh dokter, maka obat tersebut bisa dicarikan penggantinya berdasarkan bahan dasar yang dimilikinya.

Pergantian obat dapat dilakukan bila obat yang dibutuhkan pasien di apotek habis. Di dalam mengganti obat yang ada didalam resep dokter, apoteker harus memberitahukan pasien

bahwa penggantian obat mengandung zat aktif yang sama, bahan kandungan obat dalam jumlah yang sama, jenis obat yang sama, dan tentunya memiliki perbedaan dalam harga. Hak substitusi obat adalah milik apoteker selama dokter mengizinkan penggantian.

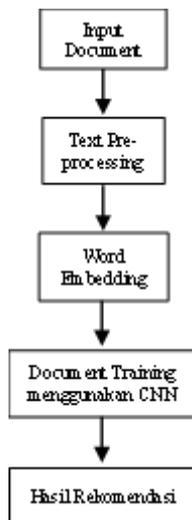
Saat ini, para apoteker masih menggunakan cara manual, dimana apabila ada obat yang diresepkan oleh seorang dokter, ternyata obat tersebut sedang tidak tersedia. Maka, para apoteker akan membuka informasi pengganti obat tersebut di buku obat, yang biasa disebut ISO Indonesia (Informasi Spesialite Obat Indonesia), atau melalui website Mim's [1], untuk mencari informasi mengenai kesamaan indikasi atau kandungan pada sebuah obat. Hal ini kadang kala membutuhkan waktu yang sedikit lama. Oleh karena itu, dibutuhkan sebuah Sistem Informasi Rekomendasi mengenai obat yang saat ini beredar di Indonesia.

Penggantian obat tersebut dengan persetujuan dari dokter yang meresepkan, setelah apoteker dan pasien berkonsultasi dengan dokter untuk meminta persetujuan penggantian obat. Berdasarkan PP No. 5, tahun 2009, tentang kefarmasian, pasal 24 ayat b yang berbunyi "mengganti obat merek dagang dengan obat generik yang sama komponen aktifnya atau obat merek dagang lain atas persetujuan dokter dan/atau pasien". Setelah mendapat persetujuan dokter dan pasien, apoteker dapat mengganti obat yang dibutuhkan pasien. Dalam mengganti obat yang diresepkan, apoteker harus memberitahukan kepada pasien mengenai penggantian obat tersebut mengandung zat aktif yang sama, dalam jumlah yang sama, sediaan yang sama, dan perbedaan harga.

Penelitian ini menggunakan metode Convolutional Neural Network (CNN) dalam mencari dokumen yang sama. Dengan penelitian ini, diharapkan dapat digunakan untuk mengurangi waktu proses pencarian obat yang dibutuhkan pasien. Metode pencocokan dokumen digunakan untuk memberikan rekomendasi obat pengganti berdasarkan dokumen dari obat yang paling ideal dan memiliki nilai yang tertinggi. Kandungan Obat yang direkomendasikan persis sama dengan obat - obatan sebelumnya yang tercantum dalam resep yang didapat dari dokter.

2. METODE

Penelitian ini dilakukan untuk membuat sistem yang dapat memberikan rekomendasi obat pengganti apabila obat yang diresepkan oleh dokter sedang kosong. Tahapan penelitian yang dilakukan yaitu dengan mencari bahan penyusun obat yang memiliki kesamaan kandungan, indikasi, dan kontra-indikasinya, kemudian dilakukan pengolahan menggunakan metode CNN.



Gambar 2.1 Tahapan Penelitian

2.1 Dataset

Dataset yang digunakan pada penelitian ini adalah data obat. Data obat tersebut diambil dari website mim's Indonesia [1]. Data obat ini berbahasa inggris, terdiri dari 21 atribut. Dari 21 atribut tersebut akan diambil 4 atribut yang akan digunakan sebagai data input pada

penelitian ini. Atribut yang diambil tersebut terdiri dari nama obat, bahan kandungan, indikasi, dan kontra-indikasinya. Data input tersebut kemudian dianalisa dan dilakukan proses training, untuk kemudian dibuat menjadi sebuah sistem rekomendasi obat.

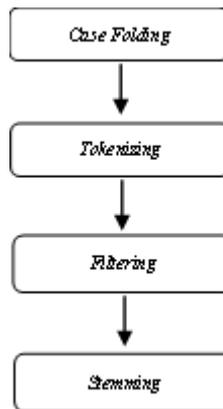
Data obat yang digunakan pada penelitian ini sejumlah 1.000 data obat, yang terdiri obat, bahan kandungan, indikasi, dan kontra-indikasinya.

Tabel 2.1. Data Obat

Nama Obat	Bahan Kandungan	Indikasi	Kontra Indikasi
3TC	Lamivudine	3TC, in combination with other antiretroviral agents, is indicated for the treatment of HIV infected adults and children.	The use of lamivudine is contraindicated in patients with known hypersensitivity to lamivudine or to any ingredient of 3TC.
3TC-HBV	Lamivudine	Treatment of patients with chronic hepatitis B infection with evidence of hepatitis B viral replication.	Patients with known hypersensitivity to lamivudine or to any ingredient of 3TC-HBV.
8Y	Antihemophilic factor VIII (human)	Classic hemophilia A.	Known anaphylactic or severe systemic response to Ig (human); patients w/ selective IgA deficiencies

2.2 Pre-Processing Data

Data yang diperoleh pada tahapan pengumpulan data, masih berupa data mentah, sehingga diperlukan tahapan pre-processing data [10]. Gambar dibawah menunjukkan tahapan pada Text Pre-processing yang dilakukan.



Gambar 2.2. Text Pre-Processing

Tahapan Pre-processing data ini meliputi:

1. Text Pre-processing

Tahap text pre-processing adalah tahapan dimana aplikasi melakukan seleksi data yang akan diproses pada setiap dokumen. Proses text-preprocessing ini meliputi :

a. Case folding

Pada proses ini, Seluruh dokumen dikonversi menjadi suatu bentuk standar yaitu huruf kecil atau lowercase.

products	contents	indications	contraindications
3TC	lamivudine	tc in combination with other antiretroviral a...	the use of lamivudine is contraindicated in pa...
3TC-HBV	lamivudine	treatment of patients with chronic hepatitis b...	patients with known hypersensitivity to lamivu...
8Y	antihemophilic factor viii human	classic hemophilia a	known anaphylactic or severe systemic response...
A-B Vask	amlodipine besylate	htn angina pectoris heart	hypersensitivity to dihydropridine
Abbotc/Abbotc Granule/Abbotc XL	clarithromycin	upper lower resp tract infections pharyngitis...	hypersensitivity to macrolide antibiotic drugs...
Abilify Discmelt	aripiprazole	acute agitation in schizophrenia and bipolar d...	hypesensitivity to aripiprazole

Gambar 2.3. Proses Case Folding

b. Tokenizing

Pada proses ini, akan dilakukan pemotongan string input berdasarkan tiap kata yang menyusunnya. Pemotongan string input berdasarkan tiap kata yang menyusunnya.

```
403
['ketoconazole']
Erazol
51
['emergency', 'treatment', 'of', 'shock', 'other', 'similar', 'conditions', 'prevention', 'of', 'marked', 'hemoconcentration', 'maintenance', 'of',
'electrolyte', 'balance', 'hypoproteinemia', 'w', 'or', 'wo', 'edema']
Albuminar-25
45
['active', 'pathological', 'bleeding', 'eg', 'peptic', 'ulcer', 'intracranial', 'hemorrhage', 'severe', 'liver', 'impairment', 'lactation']
Agrelano
```

Gambar 2.4 Proses Tokenizing

c. Filtering (delete stopwords)

Pada proses ini, dilakukan pengambilan kata penting dari hasil proses tokenizing.

```
234
['vit', 'b', 'vit', 'c', 'vit', 'ca', 'carbonate']
Caldece
645
['newly', 'diagnosed', 'philadelphia', 'chromosome', 'bcrabl', 'positive', 'ph+', 'chronic', 'myeloid', 'leukaemia', 'cml', 'well', 'patients', 'w', 'ph+',
'cml', 'chronic', 'phase', 'failure', 'interferona', 'therapy', 'blast', 'crisis', 'accelerated', 'phase', 'adult', 'ped', 'yr', 'w', 'newly', 'diagnosed',
'philadelphia', 'chromosome', 'positive', 'acute', 'lymphoblastic', 'leukaemia', 'ph+', 'integrated', 'chemotherapy', 'adult', 'patients', 'w', 'relapsed',
'refractory', 'ph+', 'monotherapy', 'adult', 'patients', 'w', 'myelodysplasticmyeloproliferative', 'disease', 'mdsmpd', 'associated', 'w', 'plateletderived',
'growth', 'factor', 'receptor', 'pdgfr', 'gene', 'rearrangements', 'adult', 'patients', 'w', 'systemic', 'mastocytosis', 'sm', 'wo', 'dv', 'ckit', 'mutation',
'w', 'ckit', 'mutational', 'status', 'unknown', 'adult', 'patients', 'w', 'hypereosinophilic', 'syndrome', 'hes', 'chronic', 'eosinophilic', 'leukemia', 'cel',
'adult', 'patients', 'w', 'unresectable', 'recurrent', 'metastatic', 'dermatofibrosarcoma', 'protuberans', 'dfsp']
Imatero
24
['severe', 'htn', 'pregnancy']
Actapin
```

Gambar 2.5. Proses Filtering

d. Stemming.

Pada proses ini, dilakukan proses untuk menemukan kata dasar dari sebuah kalimat. Kata yang ada didalam dokumen akan ditrasformasikan kedalam kata dasarnya. Karena data yang digunakan pada penelitian ini dalam bahasa Inggris, maka proses yang dilakukan hanya proses menghilangkan sufiksnya saja.

```
745
['amethylprednisolon']
Lameson
191
['tn', 'monotherapi', 'combin', 'w', 'antihypertens']
Bipro
566
```

Gambar 2.6. Stemming

2. Word Embedding

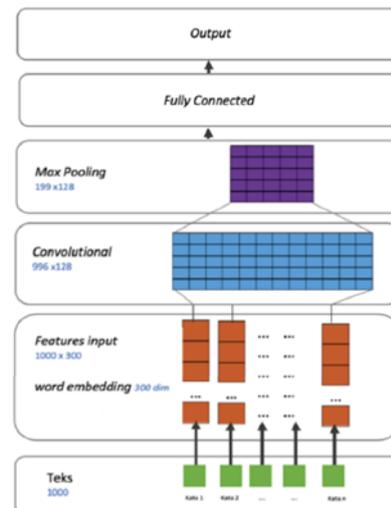
Pada proses ini, dokumen yang sudah melalui tahap Preprocessing Data, terlebih dahulu ditransformasikan ke dalam representasi vektor kata. Proses konversi kata yang berupa karakter alphanumeric kedalam bentuk vektor. Setelah terkonversi menjadi bentuk vektor, kemudian dokumen dimasukkan ke input layer dari proses CNN. Tf-Idf digunakan untuk menghitung bobot setiap kata yang umum digunakan. Tf-Idf menghitung nilai Term Frequency (TF) dan Inverse Document Frequency (IDF) pada setiap token (kata) di setiap dokumen. Secara sederhana, metode TF-IDF digunakan untuk mengetahui berapa sering suatu kata muncul di dalam dokumen.

3. Cosine simialirity

Digunakan untuk menghitung jumlah kata yang muncul pada dokumen. Cosine Similarity digunakan untuk menghitung jumlah kata istilah yang muncul pada halaman-halaman yang diacu pada daftar indeks. Semakin banyak jumlah kata istilah yang muncul pada suatu halaman semakin tinggi nilai Cosine Similarity yang diperoleh.

2.3 Permodelan Data

Proses training text menggunakan metode Convolution Neural Network (CNN) untuk melakukan ekstraksi fitur yang terdapat pada text . Proses yang terdapat pada convolution layer yaitu melakukan menghitung bobot pada query dan dokumen yang telah diproses pada tahapan sebelumnya.



Gambar 2.7. Alur Proses CNN

Gambar 2.7 di atas menunjukkan arsitektur CNN yang digunakan, terdiri dari layer input, convolutional, max pooling, dan fully connected. Pada penelitian ini, CNN satu dimensi digunakan untuk pemodelan klasifikasi pada dataset obat. CNN satu dimensi ini sangat efektif dalam menurunkan fitur dari segmen dengan panjang yang tetap dari keseluruhan dataset dan bekerja dengan baik untuk permasalahan Natural Language Processing (NLP). Semua fitur dipelajari oleh algoritma langsung dari dataset.

- **Input Layer**
Layer pertama menyimpan input dari word embedding. Teks dari setiap dataset obat terlebih dahulu ditransformasikan ke dalam representasi vektor kata menggunakan word embedding kemudian dimasukkan ke input layer. Maksimum panjang sekuens dari input adalah 1.000, sehingga input akan berupa matriks berukuran 1.000 x 300.
- **Proses Deteksi Dokumen**
Proses Deteksi dokumen obat adalah sebuah proses mengetahui dokumen yang dimaksud diantara dokumen obat lainnya. Metode Convolution Neural Network (CNN) digunakan untuk proses ekstraksi fitur yang terdapat pada teks. Data set obat yang sudah dikonversi menjadi vektor dokumen, akan dibagi menjadi dua, yaitu data training dan data testing. Tahapan berikutnya adalah menjalankan program sliding windows. Pada saat forward pass, tiap kernel menyusuri input matrix sehingga menghasilkan activation map berukuran 2 dimensi untuk kernel tersebut. Hasilnya network mempelajari filter/kernel yang aktif ketika mendeteksi beberapa jenis fitur tertentu pada posisi spasial dalam input. Arsitektur dari CNN yang digunakan yaitu 1 convolutional layer, dengan 64 filter dengan kernel size 3 yang akan bergerak vertikal menyusuri keseluruhan matriks input. Setiap convolutional layer diikuti dengan max-pool layer dengan ukuran 2 x 2, selanjutnya terdapat fully connected layer dengan 1.000 neuron dan diakhiri dengan softmax layer dengan 5 neuron yang mempunyai rekomendasi yang tertinggi.

Metode CNN adalah jenis klasik Metode Deep Learning. Terdiri tiga lapisan utama di CNN:

- a. Lapisan konvolusional (convolution layer)
- b. Lapisan penyatuan (connected layer)
- c. Lapisan fully connected (lapisan FC).

Setelah beberapa kali bergantian lapisan konvolusional dan penyatuan, lapisan FC dilatih untuk klasifikasi terakhir. Pada lapisan ini, CNN telah menyelesaikan tugasnya dalam pengenalan dokumen yang digunakan pada penelitian ini.

- Activation Function

Proses konvolusi diikuti oleh fungsi aktivasi non-linier yang diterapkan pada keluaran lapisan sebelumnya. Fungsi ini memungkinkan transformasi sinyal input dalam neuron menjadi sinyal output. Penelitian ini menggunakan fungsi aktivasi Relu (Rectified linear unit).

Relu (Rectified linear unit) adalah fungsi aktivasi yang berfungsi mengaktifkan dan menonaktifkan neuron. Fungsi ReLU digunakan untuk mempercepat proses training. ReLU memiliki kecepatan yang lebih baik, sehingga sesuai untuk digunakan dalam mencegah overfitting. Formula Relu dapat dilihat pada formula dibawah :

$$\alpha(x) = \max(0, x) \dots\dots\dots (2.1)$$

dimana X adalah input dari neuron. Nilai hasil konvolusi yang di bawah 0 diubah jadi 0. Fungsi ReLU memastikan bahwa nilai neural yang ditransmisikan ke lapisan berikutnya selalu positif, lebih efisien, sederhana dan memungkinkan untuk mengurangi kompleksitas dan waktu perhitungan.

- Pooling layer bertujuan untuk mengumpulkan informasi, mengurangi representasi, dan mengekstrak fitur global dari fitur lokal pada convolutional layer.

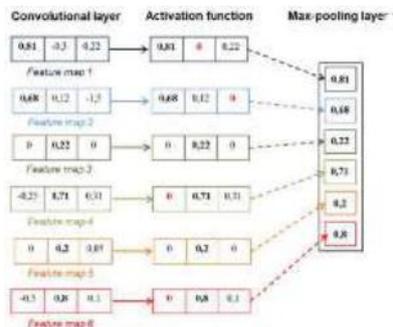
Selain itu, pooling layer berfungsi untuk mengurangi dimensi dari feature maps yang akan digunakan di layer selanjutnya. Hasil dari operasi pooling adalah :

$$C_{pooled} = \begin{bmatrix} pool(\alpha(c_1 + b_1 * e)) \\ \dots \dots \dots \\ pool(\alpha(c_n + b_n * e)) \end{bmatrix} \dots\dots\dots (2.2)$$

Dimana c_i adalah fitur peta fitur konvolusi ke-i, dengan bias tambahan (bias ditambahkan ke setiap elemen c_i dan e adalah vektor satuan dengan ukuran yang sama dengan c_i) dan melewati fungsi aktivasi.

Terdapat 2 tipe operator pada pooling layer, yaitu Average dan Max. Pada penelitian ini menggunakan tipe Max Pooling. Max pooling mengubah input menjadi output dengan cara memilih angka piksel terbesar terhadap piksel tetangganya tergantung dari ukuran filter. Formula max pooling dapat dilihat pada formula dibawah dimana D adalah tetangga yang digunakan untuk kernel (biasanya berbentuk kotak), X adalah input, dan Y adalah output.

$$(c, x, y) = \max_{\Delta} \Delta Y \in D X (c, x - \Delta X, y - \Delta Y) \dots\dots\dots (2.3)$$



Gambar 2.8. Max Pool Layer

Lapisan pooling menggunakan salah satu operasi maksimal yang merupakan operasi yang paling umum. Gambar dibawah menunjukkan operasi dengan langkah 2 dan ukuran filter 2x2. Dari ukuran input 4x4, pada masing-masing 4 angka pada input operasi mengambil nilai maksimalnya dan membuat ukuran output baru menjadi 2x2.

- Pencocokkan Queri dan Dokumen
Output dari proses konvolusi digunakan untuk memproses kueri dan dokumen, representasi vektor yang dihasilkan adalah x_q dan x_d , dapat digunakan untuk menghitung skor kesamaan kueri-dokumen.

$$sim(x_q, x_d) = x_q^T M x_d \dots\dots\dots (2.4)$$

Formula diatas digunakan sebagai model pendekatan kueri dan dokumen dari proses sebelumnya. Selain itu, formula diatas juga digunakan sebagai model penilaian dalam pencarian informasi. Dalam model ini, peneliti mencari transformasi dari calon dokumen $x_d = M x_d$ yang paling dekat dengan input query x_q . Matriks kesamaan M adalah parameter jaringan dan akan dioptimalkan selama training.

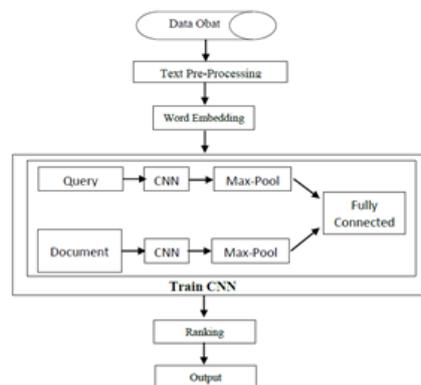
- Fully Connected Layer
Lapisan Fully-connected adalah lapisan dimana semua neuron aktivitas dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya. Setiap aktivitas dari lapisan sebelumnya perlu diubah menjadi data satu dimensi sebelum dapat dihubungkan ke semua neuron di lapisan Fully-Connected. Sebelum hasil pooling digunakan sebagai input, hasil pooling terlebih dahulu diubah menjadi vektor (x_1, x_2, x_3, \dots) kemudian dari sini diproses ke dalam Fully Connected Layer. Pada layer terakhir di dalam Fully Connected layer akan digunakan fungsi aktifasi sig softmax untuk menentukan klasifikasi dari teks masukan dari Input Layer CNN.

Output yang dihasilkan dari convolutional neural network adalah 5 neuron yang mempunyai rekomendasi yang tertinggi. Peneliti menggunakan ukuran pada filter size convolution layer, jumlah neuron pada fully connected layer, dan banyak filter pada jumlah neuron untuk mendapatkan akurasi tertinggi.

3. HASIL DAN PEMBAHASAN

Proses training data menggunakan laptop dengan spesifikasi Core i7- 10510U, memory 8 GB, dengan CPU 2,30 GHz. Library yang digunakan pada penelitian ini adalah Tensorflow, Keras dan SKlearn.

Dataset yang digunakan sejumlah 1.000 data obat, yang terdiri nama obat, bahan kandungan, indikasi, dan kontra-indikasi. Data obat tersebut dibagi menjadi 2 bagian yaitu 80% untuk proses training, dan 20% untuk proses validasi.



Gambar 3.1 Proses Rekomendasi

Pada proses penelitian ini, dibuat 2 (dua) aplikasi berbeda, yaitu aplikasi untuk melakukan training data dengan menggunakan algorithma CNN, dan aplikasi untuk memberikan

rekomendasi dari input yang dimasukkan oleh pengguna, untuk kemudian memberikan output berdasarkan hasil training yang telah dilakukan pada aplikasi pertama. Tujuan dari dibuatnya 2 aplikasi ini adalah apabila tidak ada data baru, maka pengguna tidak perlu melakukan training data lagi, sehingga proses rekomendasi obat yang dicari, bisa lebih cepat dilakukan.

Pada tahapan training data, semua dokumen dilatih dan dijadikan model, tahap selanjutnya adalah melakukan rekomendasi data sesuai dengan data yang dicari. Pada proses ini, akan dilakukan pencocokan data input dengan data training.

Dataset yang digunakan sejumlah 1.000 data obat. Pada proses training ini parameter yang digunakan sejumlah 100 epoch, 1 input layer, 1 hidden layer yang masing-masing hidden layer terdapat 5 neuron dan 5 output. Arsitektur dari CNN yang digunakan yaitu 1 convolutional layer, dengan 64 filter dan kernel size sebesar 3 yang akan bergerak vertikal menyusuri keseluruhan matriks input. Setiap convolutional layer diikuti dengan max-pool layer dengan ukuran 2 x 2, selanjutnya terdapat fully connected layer dengan 1.000 neuron dan diakhiri dengan softmax layer yang menghasilkan 5 neuron yang mempunyai rekomendasi yang tertinggi.

Data training yang mempunyai kesesuaian dengan data input akan ditampilkan sebagai output rekomendasi. Data tersebut dirangking sesuai dengan nilai yang dimiliki. Nilai tertinggi, menempati urutan pertama, dan Nilai terendah menempati peringkat selanjutnya. Nilai ini adalah representasi dari kesesuaian dokumen.

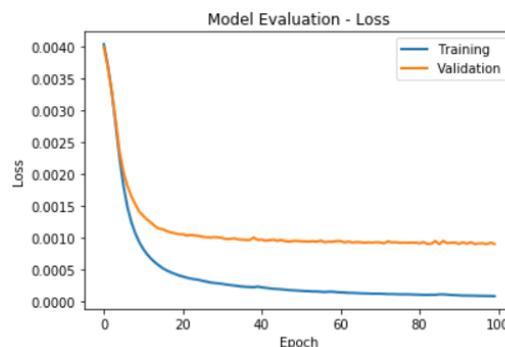
Gambar dibawah adalah proses training untuk data indikasi. Proses ini dilakukan untuk melakukan proses pembelajaran pada data indikasi. Apabila hasil akurasi sudah baik, maka proses selanjutnya adalah proses training untuk data kontra-indikasi.

Apabila akurasi dari data pada kedua proses diatas dinilai kurang baik, mungkin terjadi overfitting atau lainnya, maka perlu dimodifikasi lagi parameter yang digunakan. Apabila hasil akurasi dari hasil training pada data indikasi dan kontra-indikasi sudah baik, untuk selanjutnya data tersebut akan disimpan dan akan dijadikan sebagai model data pada proses berikutnya.

```
6/6 [=====] - 17s 3s/step - loss: 9.0927e-05 - accuracy: 0.9807
Epoch 100/100
6/6 [=====] - 19s 3s/step - loss: 8.8371e-05 - accuracy: 0.9807
```

Gambar 3.2. Proses training untuk indikasi

Pada proses training untuk indikasi diatas menghasilkan accuracy sebesar 0.9807. Pada akhir proses training diatas menghasilkan output berupa model evaluation dan grafik pelatihan 100 iterasi (epoch) yang di dalamnya terdapat training dan Validation. Grafik hasil pelatihan ini ditunjukkan pada Gambar dibawah.

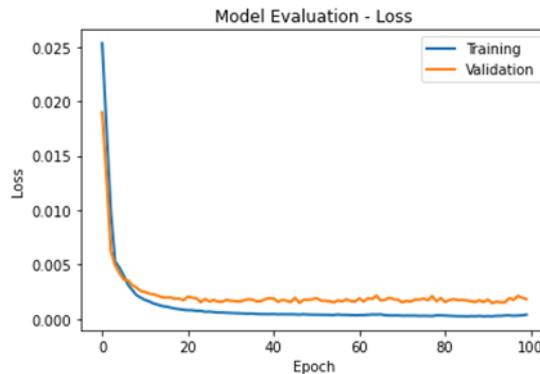


Gambar 3.3. Grafik *Model Evaluation* untuk Indikasi

```
6/6 [=====] - 8s 1s/step - loss: 2.5848e-04 - accuracy: 0.7761
Epoch 100/100
6/6 [=====] - 8s 1s/step - loss: 2.4458e-04 - accuracy: 0.7683
```

Gambar 3.4. Proses training untuk kontra-indikasi

Pada proses training untuk kontra-indikasi diatas menghasilkan accuracy sebesar 0.7683. Pada akhir proses training data kontra indikasi diatas dihasilkan output berupa model evaluation dan grafik pelatihan dari 100 iterasi (epoch) yang digunakan, yang di dalamnya terdapat diagram training dan Validation. Grafik hasil training data kontra indikasi ditunjukkan pada Gambar dibawah.



Gambar 3.5. Grafik *Model Evaluation* untuk Kontra Indikasi

Setelah proses training dilakukan, tahapan berikutnya adalah melakukan pengujian sistem. Pada proses pengujian ini, diberikan data obat sesuai dengan yang diinginkan oleh pengguna. Data hasil training pada proses sebelumnya, dijadikan sebagai model data yang akan dicari kesesuaian datanya dengan data yang akan di input oleh pengguna. Data yang dapat di input oleh pengguna antara lain bahan kandungan obat, indikasi, dan kontra-indikasi. Setelah pengguna memasukkan data yang diinginkan, sistem akan mencari data yang ada pada model yang sudah di training sebelumnya. Data yang mempunyai kesesuaian akan diperingkat sesuai dengan kemiripan data yang dimiliki. Data yang memiliki kemiripan yang tinggi, akan dijadikan sebagai peringkat 1, sedangkan data yang memiliki sedikit kemiripan akan dijadikan sebagai peringkat berikutnya. Demikian seterusnya.

Proses pengujian ini digunakan untuk mengevaluasi model pelatihan CNN yang telah dilakukan sebelumnya apakah sudah sesuai dengan rekomendasi data obat yang dilakukan secara oleh apoteker, baik bahan kandungan, indikasi, dan kontra indikasi. Langkah-langkah yang dilakukan pada tahap ini adalah:

1. Input bahan kandungan obat (content), indikasi (indication), dan kontra indikasi (contra indication) dari obat yang akan dicari.
2. Proses sliding windows pada dokumen.
3. Load fitur, ambil model CNN arsitektur model rekomendasi obat.
4. Prediksi data obat, diurutkan sesuai dengan bobot dokumen.

Berikut hasil dari pengujian sistem rekomendasi obat di penelitian ini, dapat dilihat pada gambar dibawah.

```

Contents : glimepiride
Indications : type 2 dm
Contraindications :
(1, 4708)

-----
Recommendations by Indication
-----
70- Amadiab      0.2753746510
25- Actaryl     0.2645384669
335- Diamicon PR 60  0.2591546178
71- Amaryl     0.2542027235
586- Gluvas     0.2479518652
    
```

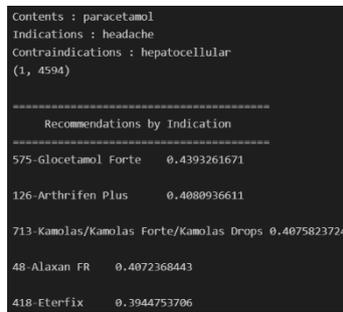
Gambar 3.6. Hasil Uji Coba 1

Pada uji coba pertama, obat dengan bahan kandungan glimepiride, dengan indikasi type 2 dm. Output yang dihasilkan adalah:

Tabel 3.1 Hasil Uji Coba 1

No	Hasil Rekomendasi	Akurasi
1	Amadiab	0.275
2	Actaryl	0.265
3	Diamicron MR 60	0.259
4	Amaryl	0.254
5	Gluvas	0.248

Pada tabel 3.1 diatas adalah nama obat hasil uji coba. Kolom nomer 1 sampai nomer 5 adalah nama obat hasil rekomendasi yang mempunyai nilai tertinggi. Dengan input bahan kandungan glimepiride, dengan indikasi type 2 dm, hasil rekomendasi tertinggi tertinggi adalah obat Amadiab, kemudian hasil rekomendasi berikutnya adalah Actaryl, dan seterusnya. Hasil akurasi yang kecil, sebagai contoh pada obat Amadiab yaitu sebesar 0.275. Hal tersebut disebabkan nilai akurasi hasil rekomendasi yang didapat di atas adalah sebesar 99,7% atau mendekati 100%. Demikian juga dengan obat hasil rekomendasi berikutnya.



Gambar 3.7. Hasil Uji Coba 2

Pada uji coba kedua, obat dengan bahan kandungan paracetamol, dengan indikasi headache, dan kontra indikasi hepatocellular. Output yang dihasilkan adalah:

Tabel 3.2. Hasil Uji Coba 2

fNo	Hasil Rekomendasi	Akurasi
1	Glocetamol	0.439
2	Arthrifen Plus	0.408
3	Kamolas/Kamolas Forte	0.407
4	Alaxan FR	0.407
5	Eterfix	0.390

Pada tabel 3.2 diatas berisi nama obat hasil uji coba. Sama dengan uji coba 1, kolom nomer 1 sampai nomer 5 adalah nama obat hasil rekomendasi yang mempunyai nilai tertinggi. Dengan input bahan kandungan paracetamol, dengan indikasi headache, dan kontra indikasi hepatocellular, hasil rekomendasi tertinggi tertinggi adalah obat Glocetamol, kemudian hasil rekomendasi berikutnya adalah Arthrifen Plus, dan seterusnya. Hasil akurasi yang kecil, sebagai contoh pada obat Glocetamol yaitu sebesar 0.439. Hal tersebut disebabkan nilai akurasi hasil rekomendasi yang didapat di atas adalah sebesar 99,6% atau mendekati 100%. Demikian juga dengan obat hasil rekomendasi berikutnya.

4. KESIMPULAN

Berdasarkan uji coba yang telah dilakukan maka kesimpulan yang dapat diambil dari penelitian ini adalah:

1. Dalam memperoleh hasil akhir pada penelitian Information Retrieval Untuk Rekomendasi Obat Pengganti Menggunakan Metode ANN dipengaruhi oleh jumlah data, jumlah iterasi, dan jumlah kata. Semakin banyak data maka akan semakin kompleks proses yang dijalankan dan membutuhkan waktu cukup lama dalam melakukan training data.
2. Ketepatan dalam merekomendasi pada Neural Network tergantung oleh jumlah node Hidden Layer dan Learning Rate yang digunakan.
3. Dengan nilai parameter yang digunakan sejumlah 100 epoch, 1 input layer, 1 hidden layer, dan pada masing – masing hidden layer terdapat 5 neuron dan 5 output. Dengan menggunakan 1 convolutional layer dengan 64 filter dan kernel size sebesar 3, maka didapatkan akurasi sebesar 98% pada proses training, hasil ini mengasumsikan bahwa nilai akurasi rekomendasi yang didapat cukup baik.
4. Jika dibandingkan dengan penelitian yang dilakukan sebelumnya dengan menggunakan K-means dan profil matching, maka ada peningkatan sebesar 5%.

5. DAFTAR PUSTAKA

- Database of prescription and generic drugs, clinical guidelines | MIMS online [Online]. Available: [https:// www.mims.com/indonesia](https://www.mims.com/indonesia).
- Peraturan Pemerintah Republik Indonesia Nomor 51 Tahun 2009 Tentang Pekerjaan Kefarmasian. Available: <https://peraturan.bpk.go.id/Home/Details/4975/pp-no-51-tahun-2009>
- Bao, Youjun, and Jiang, Xiaohong, “An Intelligent Medicine Recommender System Framework”, 2016 IEEE 11th Conference on Industrial Electronics and Applications (ICIEA), page 1383-1388, 2016, doi: 10.1109/ICIEA.2016.7603801.
- Paembonan, Solmin, Manga’, Abdul Rachman, Jusmidah, Atmajaya, Dedy, Waluyantari, Ayu Vina, Astuti, Wistiani, Mansyur, St. Hajrah, “Combination of K-Means and Profile Matching for Drug Substitution”, The 2nd East Indonesia Conference on Computer and Information Technology (EIconCIT), page 180-183, 2018, doi: 10.1109/EIconCIT.2018.8878539.
- Meina Song, Qing Liu and Haihong E, “Deep Hierarchical Attention Networks for Text Matching in Information Retrieval”, International Conference on Information Systems and Computer Aided Education (ICISCAE), page 476-481, 2018, doi: 10.1109/ICISCAE.2018.8666926.
- Han Jiawei. Kamber Micheline, “Data Mining Concepts and Techniques”, 2012.
- Christopher D. Manning, Prabhakar Raghavan, Hinrich Schütze, “An Introduction to Information Retrieval”, 2009.
- Keputusan Menteri Kesehatan Republik Indonesia nomor Hk.02.02/menkes/514/2015 tentang panduan praktik klinis bagi dokter di fasilitas pelayanan kesehatan tingkat pertama.
- Nurdin, Arliyanti, Aji, Bernadus Anggo Seno, Bustamin, Anugrayani, Abidin, Zaenal, “Perbandingan Kinerja Word Embedding Word2vec, Glove, Dan Fasttext Pada Klasifikasi Teks”, Jurnal TEKNOKOMPAK, vol. 14, page 74-79, 2020.
- Kalchbrenner, Nal Grefenstette, Edward Blunsom, Phil, “A Convolutional Neural Network for Modelling Sentences”, Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, page 655–665, 2014.
- Severyn, Aliaksei, Moschittiy, Alessandro, “Learning To Rank Short Text Pairs With Convolutional Deep Neural Networks”, SIGIR 2015 - Proceedings of the 38th

- International ACM SIGIR Conference on Research and Development in Information Retrieval, page 373-382, 2015, doi: 10.1145/2766462.2767738.
- Gerald J. Kowalski, “Information Retrieval Systems, Theory and Implementation”, 1997, ISBN: 978-0-585-32090-8.
- Jacovi, Alon, Shalom, Oren Sar, Goldberg, Yoav, “Understanding Convolutional Neural Networks for Text Classification”, Proceedings of the 2018 EMNLP Workshop Blackbox, Page 55-56, 2018.