

# Chatbot Pemilihan Makanan dan Minuman Berdasarkan Kalori menggunakan Natural Language Processing

Nur Cholis Anggoro<sup>1</sup>, Mutaqin Akbar<sup>2</sup>

<sup>1,2</sup>Program Studi Informatika, Universitas Mercu Buana Yogyakarta  
<sup>1</sup>17111102@student.mercubuana-yogya.ac.id, <sup>2</sup>mutaqin@mercubuana-yogya.ac.id

---

## ABSTRACT

Chatbot is a computer program based on Artificial Intelligence (AI), or often called virtual robots that can simulate conversations like humans. This technology is also known as a digital assistant that can understand and process user requests, provide interactions, and provide relevant answers. Chatbot has many benefits, one of which can help determine food selection. In order for the chatbot to be able to understand the meaning of an input, it is necessary to have a training model as a reference. Models such as the Bag of words and the term frequency-inverse document frequency (TF-IDF) are examples of models that are commonly used. This research aims to implementing natural language processing on chatbots, determine the differences in the Bag of Words model and TF-IDF in terms of accuracy, time needed to train the model, and loss, and determine the calculation of calories using the basal metabolic rate method. In this research, a comparison will be made between the Bag of words and TF-IDF models for chatbots that will recommend food. Comparisons are made by looking at the model's performance when differentiating and how the model understands the meaning of a sentence. The results showed that the TF-IDF model has better performance than Bag of word with training loss of 0.00966 in 200 epochs and an average testing accuracy of 96.6%.

---

**Keyword:** Artificial neural network, Bag of words, Healthy food, Natural language processing, TF-IDF

---

## 1. Pendahuluan

Setiap individu memiliki kebutuhan kalori yang berbeda-beda, kebanyakan memang dapat dicukupi dengan makanan, tetapi makanan dan minuman yang dikonsumsi belum tentu sudah memenuhi kebutuhan kalori. Salah satu faktor yang penting untuk memiliki kesehatan yang baik adalah dengan mengonsumsi makanan dan minuman untuk memenuhi kebutuhan tubuh manusia. Kebutuhan asupan kalori pada manusia dapat bergantung pada beberapa faktor yaitu jenis kelamin, tinggi, berat, tingkat aktivitas, dan umur. Anak-anak tentu memiliki kebutuhan kalori yang berbeda dengan orang dewasa, begitupun laki-laki juga memerlukan asupan kalori yang berbeda dari Perempuan. Rata-rata, seorang Perempuan seharusnya makan dengan kandungan 2000 kalori per hari, sedangkan untuk laki-laki seharusnya membutuhkan 2500 kalori per hari[1]. Melakukan kendali untuk asupan kalori per hari tentunya merupakan sebuah pekerjaan yang tidak mudah. Oleh karena itu, berbagai teknologi telah diciptakan, beberapa contohnya adalah kalkulator kalori, kalkulator *basal metabolic rate* (BMR), dan lain sebagainya[2].

Chatbot adalah sebuah program komputer berbasis kecerdasan buatan, alias robot virtual yang dapat mensimulasikan percakapan layaknya manusia. Teknologi ini juga dikenal sebagai asisten digital yang dapat memahami dan memproses permintaan pengguna, memberikan interaksi, serta memberikan jawaban yang relevan[3]. Dalam memilih makanan dan minum yang akan dikonsumsi teknologi seperti chatbot dapat membantu untuk pemilihan makanan atau minuman yang tepat. Hal ini dilakukan berdasarkan perhitungan BMR yang dapat diambil dari masukan pengguna.

Beberapa penelitian terdahulu sudah membahas tentang chatbot. Yang pertama adalah chatbot yang digunakan pada suatu kampus, dimana terdapat fitur yang membantu memberikan informasi mengenai pembayaran dan seputar administrasi yang harus dibayar dan juga informasi mengenai tugas dan ujian secara interaktif[4]. Penelitian tentang chatbot pada bidang pertanian yang digunakan untuk perawatan sampai panen[5]. Penelitian tentang chatbot yang diterapkan pada customer service[6]. Terdapat penelitian mengenai chatbot pada tempat kerja dalam dunia digital[7]. Dewasa ini juga terdapat penggunaan chatbot pada desain interaksi[8] dan penilaian[9], dan juga pada aplikasi-aplikasi yang spesifik[10]. Kemudian penelitian tentang chatbot dalam membantu penggunaannya untuk merencanakan pola makan, dimana setiap harinya akan memberikan notifikasi mengenai jumlah gizi yang sudah dikonsumsi oleh pengguna[11]. Penelitian mengenai foodbot yang digunakan untuk menjadi pengingat dan tracking jumlah kalori yang sudah dikonsumsi[12]. Dan

yang terakhir adalah aplikasi penjualan makanan sehat berdasarkan perhitungan kalori menggunakan *basal metabolic rate* (BMR)[13].

Dalam pembuatan chatbot, perlu adanya model agar menjadi acuan chatbot untuk memahami apa yang user inginkan. Model seperti *bag of words* dan *term frequency-inverse document frequency* (TF-IDF) adalah model yang paling populer dalam membuat chatbot[14]. Pada artikel ini, disajikan penggunaan chatbot dalam pemilihan makanan dan minuman berdasarkan kalori yang didapatkan dari perhitungan BMR pengguna.

## 2. Landasan Teori

### 2.1. Makanan Sehat

Makanan sehat adalah makanan yang kaya nutrisi mengandung zat gizi makro (karbohidrat, protein, dan lemak sehat) serta zat gizi mikro (vitamin dan mineral), tetapi tidak terlalu padat kalori alias tidak melebihi kebutuhan tubuh akan kalori harian[15].

### 2.2. Chatbot

Chatbot merupakan sebuah program komputer yang dapat menjalankan percakapan cerdas dengan pengguna melalui media suara atau teks, seringkali dilakukan dengan percakapan yang singkat. Chatbot bekerja dengan mengartikan pesan yang diberikan oleh pengguna, kemudian memproses maksud dari pesan tersebut, selanjutnya menentukan dan mengeksekusi apa yang perlu chatbot lakukan berdasarkan perintah dari pengguna, dan terakhir menyampaikan hasil dari eksekusi kepada pengguna[16].

### 2.3. Deep Neural Network (DNN)

DNN adalah jaringan saraf tiruan yang memiliki beberapa lapisan diantara lapisan masukan dan keluaran yang biasanya disebut dengan lapisan tersembunyi (*hidden layer*). DNN memiliki beberapa fungsi komponen seperti: neuron, bobot, *bias* dan fungsi aktivasi.

Fungsi aktivasi didapatkan dari jumlah dari perkalian nilai masukan dengan bobot. Bobot merupakan nilai acak yang telah diinisialisasi. Fungsi aktivasi berfungsi untuk memproses informasi dan menghasilkan keluaran. Keluaran merupakan hasil akhir pada perseptron tunggal. Sedangkan pada perseptron banyak lapis, keluaran dari *neuron* pada lapisan sebelumnya berfungsi sebagai masukan dari *neuron* pada lapisan selanjutnya[17]. Berikut adalah persamaan untuk fungsi aktivasi softmax (rumus 1), fungsi aktivasi *rectified linear unit* atau ReLU (rumus 2)[18], dan fungsi nilai penjumlahan berbobot (rumus 3)[19].

$$f(y_i) = \frac{e^{y_i}}{\sum_{j=1}^n e^{y_j}} \quad (1)$$

$$f(y_i) = \max(0, y_i) \quad (2)$$

$$y = \sum_{i=1}^n (x_i w_i) + b \quad (3)$$

Dalam persamaan tersebut,  $w$  adalah bobot menunjukkan kekuatan node,  $x$  adalah masukan dari neuron dan  $b$  adalah bias yang menunjukkan nilai penjumlahan berbobot yang harus dicapai neuron untuk aktif. Berdasarkan penjumlahan berbobot, dapat diperoleh keluaran dengan fungsi aktivasi. DNN memiliki lapisan masukan, sejumlah lapisan tersembunyi serta terakhir lapisan keluaran. Pemodelan menggunakan DNN terdiri dari fase *feed-forward* dan *back-propagation*. Langkah yang dilakukan dalam fase *feed-forward*, antara lain:

1. Nilai pada lapisan masukan diterima dan dikalikan dengan bobot. Bias ditambahkan pada penjumlahan berbobot. Setiap neuron pada lapisan tersembunyi pertama menerima nilai berbeda dari lapisan masukan bergantung pada bobot dan bias.
2. Neuron memiliki fungsi aktivasi yang aktif berdasarkan nilai yang diterima dari masukan.
3. Keluaran dari lapisan tersembunyi pertama dikalikan dengan bobot pada lapisan tersembunyi berikutnya, hasilnya dijumlahkan dan diteruskan pada lapisan berikutnya. Proses ini berlangsung sampai lapisan terluar.

Parameter yang perlu ditetapkan yaitu jumlah lapisan tersembunyi, jumlah node pada setiap lapisan tersembunyi, jumlah iterasi atau *epoch*, activation function dan cost optimizer. Satu siklus yang meliputi *feed-forward* dan *back-propagation* disebut *epoch*. Langkah yang dilakukan dalam fase *back-propagation*, antara lain:

1. Fungsi *loss* digunakan untuk menghitung galat dengan mengukur perbedaan antara prediksi dan nilai sesungguhnya. Fungsi *loss* yang digunakan dapat berupa *mean squared error* atau *cross entropy*.
2. Penurunan gradien untuk meminimalisir galat dengan menghitung turunan parsial dari fungsi galat dengan bobot dan bias. Penurunan gradien digunakan untuk menemukan *local minimum* dari fungsi galat dengan mengubah nilai bobot dan bias menggunakan nilai turunan parsial dari fungsi galat[20].

$$L = -\log(p_c) \tag{4}$$

*Dropout* adalah teknik regularisasi jaringan syaraf tiruan dimana beberapa *neuron* yang terpilih secara acak akan tidak dipakai selama pelatihan. untuk menghindari *overfitting*. *Overfitting* terjadi karena model yang dibuat terlalu fokus pada pelatihan dataset tertentu, hingga tidak bisa melakukan prediksi dengan tepat jika diberikan dataset lain yang serupa. *Overfitting* biasanya akan menangkap data *noise* yang seharusnya diabaikan. Model yang mengalami *overfitting* akan memiliki *low loss* dan akurasi rendah[21].

### 2.4. Natural Language Processing (NLP)

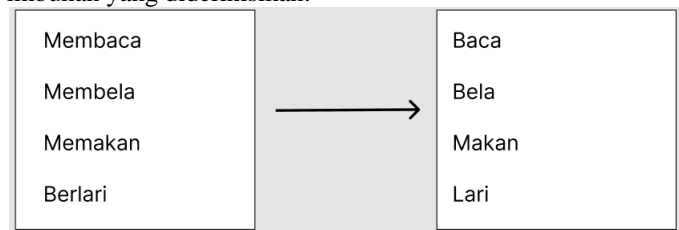
NLP menganalisis teks dengan cara terkomputasi, pada penelitian ini NLP digunakan untuk mencari kata dasar pada kalimat yang dimasukkan oleh user. Proses menjawab pertanyaan yang dimasukkan oleh user menggunakan metode *phrasing* kalimat, kemudian metode *lemmatization* untuk mencari kata dasar, lalu dari kata dasar menggunakan *rule-based* untuk mencari jawaban yang sesuai[5].

*Tokenization* pada umumnya, langkah pertama dalam penggunaan NLP, yaitu sebuah proses perubahan suatu kalimat menjadi sebuah token, yang biasanya suatu kata atau suatu tanda baca[22].



Gambar 1. Ilustrasi tokenization

*Stemming* adalah proses mencari kata dasar dari suatu kata, contohnya “bekerja” setelah dilakukan *stemming* maka kata dasarnya adalah “kerja”. Namun biasanya *stemming* mengabaikan arti dari suatu kata sehingga terkadang ada kesalahan[23]. *Over-stemming*, yaitu kondisi dimana dua atau lebih suatu kata memiliki akar kata yang sama namun seharusnya berbeda contoh: “universal” dan “university” terkadang terbaca “universe”). *Under-stemming*, yaitu kondisi dimana dua atau lebih suatu kata memiliki akar kata yang berbeda padahal memiliki akar kata yang sama (belajar menjadi ajar). Kesalahan ini dapat timbul karena kekurangan pada pola imbuhan yang didefinisikan.



Gambar 2. Ilustrasi stemming

### 2.5. Bag of Words (BoW)

Model BoW merupakan model sederhana yang digunakan pada NLP. BoW adalah sebuah model yang mempelajari sebuah kosakata dari seluruh dokumen, lalu memodelkan tiap dokumen dengan menghitung jumlah kemunculan setiap kata tanpa memandang urutan kata dan tata bahasa namun tetap mempertahankan keberagamannya[24]. Berikut contoh BoW:

- (1) Aku merasa sehat hari ini
- (2) Aku merasa demam hari ini
- (3) Aku berharap aku dapat ke luar

Dari dokumen diatas maka akan terbentuk list seperti:

- “aku”, “merasa”, “sehat”, “hari”, “ini”
- “aku”, “merasa”, “demam”, “hari”, “ini”
- “aku”, “berharap”, “aku”, “dapat”, “ke”, “luar”

Lalu untuk setiap kata dihitung jumlah kemunculannya dan dipetakan ke dalam suatu dokumen.

Tabel 1. Jumlah kemunculan kata

Aku	Merasa	Sehat	Hari	Ini	Demam	Berharap	Dapat	ke	luar
1	1	1	1	1	0	0	0	0	0
1	1	0	1	1	1	0	0	0	0
2	0	0	0	0	0	1	1	1	1

### 2.6. Term Frequency-Inverse Document Frequency (TF-IDF)

DNN adalah jaringan saraf tiruan yang memiliki beberapa lapisan diantara lapisan masukan dan keluaran yang biasanya disebut dengan lapisan tersembunyi (*hidden layer*). DNN memiliki beberapa fungsi komponen seperti: neuron, bobot, *bias* dan fungsi aktivasi.

TF-IDF adalah metode algoritma yang berguna untuk menghitung bobot setiap kata yang digunakan. Metode ini juga terkenal efisien, cepat, mudah dan memiliki hasil yang akurat. Metode ini menghitung nilai *term frequency* (TF) dan *inverse document frequency* (IDF) pada setiap token (kata) di suatu dokumen. Metode TF-IDF digunakan untuk mengetahui berapa sering suatu kata muncul dalam suatu dokumen. Pada model TF-IDF juga perlu dilakukan pengaturan n-gram untuk bagaimana struktur kalimat pada model. N-gram adalah jumlah urutan-n yang berasal dari suatu teks atau suatu percakapan. Dimana terdapat 3 jenis n-gram yaitu unigram, bigram, dan trigram. Rumus untuk n-gram adalah:

$$ngram_k = x - (n - 1) \tag{5}$$

Dimana  $x$  merupakan jumlah kata pada suatu kalimat  $k$ .

### 2.7. Basal Metabolic Rate (BMR)

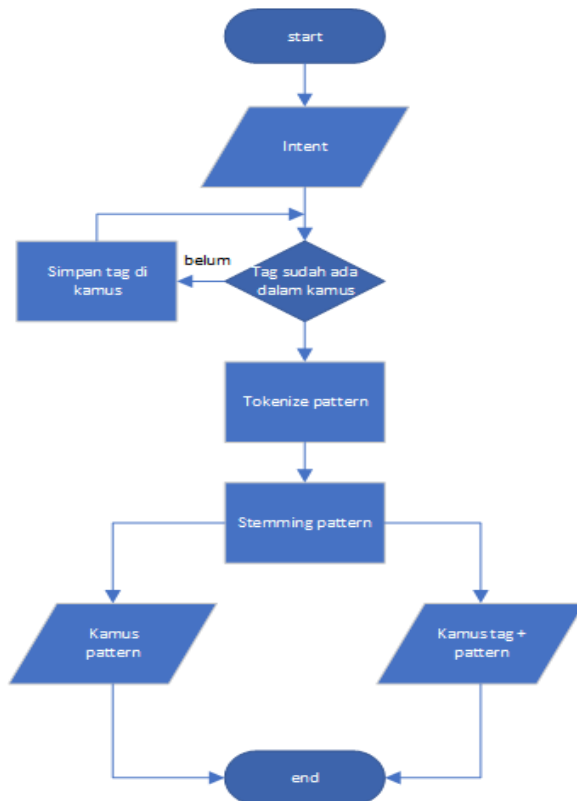
Basal Metabolic Rate (BMR) atau Angka Metabolisme Basal (AMB) adalah kebutuhan minimal energi untuk melakukan proses tubuh vital yang diantaranya yaitu meliputi mempertahankan tonus otot, sistem peredaran darah, pernapasan, metabolisme sel, dan mempertahankan suhu tubuh. Faktor-faktor lain yang mempengaruhi BMR, antara alain jenis kelamin, umur, berat dan tinggi badan, suhu tubuh, aktivitas, status gizi, kebiasaan merokok, suhu lingkungan, sekresi hormon dan keadaan hamil dan menyusui. Satuan BMR yaitu Kkal untuk kg berat badan/jam. Untuk perhitungan BMR bisa menggunakan rumus Harris-Benedict[25], berikut rumus BMR pada tiap gender:

$$BMR_{(pria)} = (10 \times berat) + (6.25 \times tinggi) - (5 \times umur) + 5 \tag{6}$$

$$BMR_{(wanita)} = (10 \times berat) + (6.25 \times tinggi) - (5 \times umur) - 161 \tag{7}$$

```
{
  {
    "tag": "pembukaan",
    "patterns": ["hallo", "halo", "hai", "hey", "hi"],
    "responses": ["hallo ada yang bisa saya bantu",
      "halo ndut, ada yang bisa saya bantu"],
  },
  {
    "tag": "thanks",
    "patterns": ["ok, terima kasih", "makasih", "Sangat
      membantu sekali", "wow, terima kasih sudah membantu", "ok,
      makasih", "suwun", "mantab"],
    "responses": ["Yoi, senang membantu", "Ya, sama-
      sama", "Senang membantu", "Sama-sama, dengan senang hati
      membantu"],
  },
  {
    "tag": "noanswer",
    "patterns": [""],
    "responses": ["Maaf, Bot tidak paham", "Maaf, dibot
      kurang paham, mungkin bisa diulangi", "Maaf, pernyataan kurang
      jelas"],
  },
  {
    "tag": "equation",
    "patterns": ["rumus mengukur kebutuhan kalori",
      "cara mengukur kebutuhan kalori", "rumus hitung kalorinya
      bagaimana"],
    "responses": ["untuk perhitungan kalori dibot paka
      rumus harris-benedict lebih selengkaapnya bisa di lihat di:
      https://en.wikipedia.org/wiki/Harris%E2%80%93Benedict_equation
      "],
  }
}
```

Gambar 3. Contoh intent



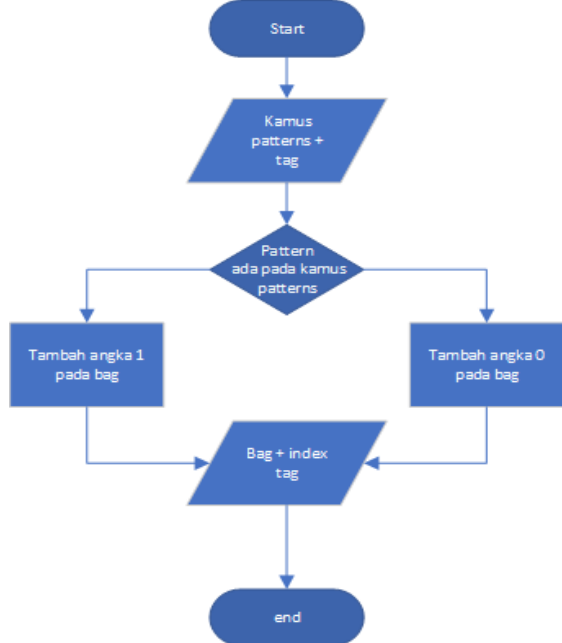
Gambar 4. Diagram alir praproses

## 3. Metodologi

### 3.1. Tahap Praproses

Tahapan pertama pembuatan model chatbot sebagai sistem inti yakni bagaimana chatbot akan menerima dan merespon masukan dari user. Pada tahap ini pembuatan intent atau asumsi yang berisikan pola-pola kalimat, terdiri dari 3 data yaitu tag atau nama kategori untuk tujuan yang dimaksud pengguna, patterns atau pola kalimat yang dapat membantu bot untuk menyimpulkan tujuan pengguna, dan yang ketiga yaitu respon atau kumpulan kalimat tentang bagaimana chatbot menjawab apabila chatbot sudah dapat menyimpulkan apa yang pengguna inginkan. Intent berbentuk JSON karena struktur data JSON mudah diolah, untuk contoh intent dapat dilihat pada gambar 3 dan alur praproses dapat dilihat pada gambar 4.

Data pada intent diproses menggunakan metode BoW dan TF-IDF sehingga diperoleh rangkaian angka yang menandakan kemunculan kata. Alur metode BoW dan TF-IDF dapat dilihat masing-masing pada gambar 5 dan gambar 6.



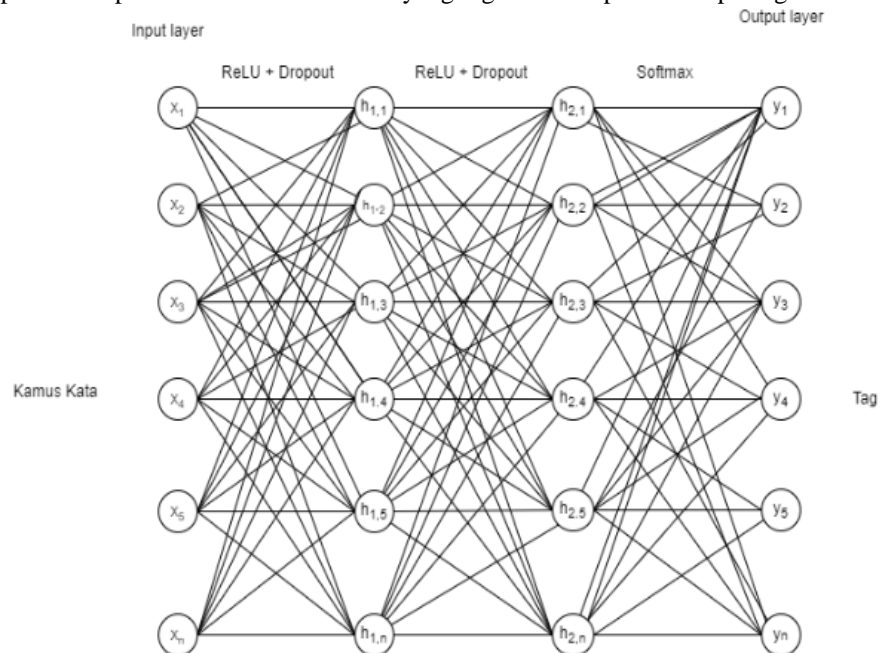
Gambar 5. Diagram alir metode BoW



Gambar 6. Diagram alir metode TF-IDF

### 3.2. Deep Neural Network (DNN)

Pada tahap ini, akan dilakukan pelatihan pada chatbot menggunakan DNN dengan menggunakan model sekuensial dengan 3 lapisan tersembunyi Dense dimana pada setiap lapisan Dense ditambahkan lapisan Dropout yang melakukan eliminasi pada masukan secara acak dengan nilai 0.5, fungsi aktivasi pada setiap lapisan tersembunyi adalah *rectified liner unit* (ReLU) dan fungsi aktivasi pada lapisan output adalah softmax, melakukan optimisasi terhadap model menggunakan metode *stochastic gradient descent* (SGD)+Nesterov sebagai optimizer, dengan *categorical cross entropy* sebagai fungsi galat dan pengukuran yang digunakan yaitu akurasi. Jumlah epoch yang digunakan untuk training yaitu sejumlah 200. Keseluruhan parameter yang digunakan dapat dilihat pada tabel 2 dan arsitektur yang digunakan dapat dilihat pada gambar 7.



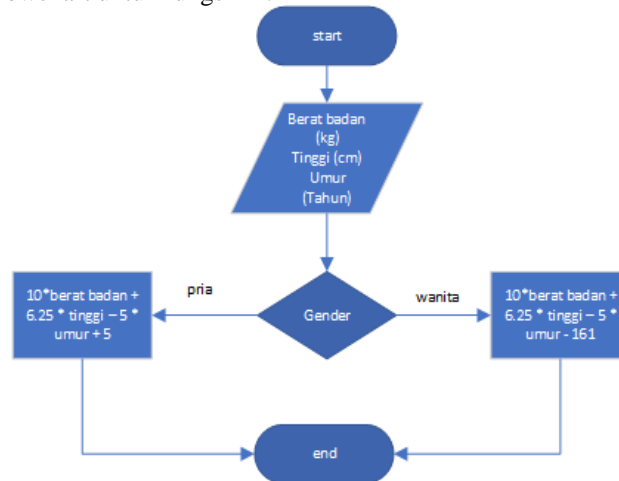
Gambar 7. Arsitektur model DNN

Tabel 2. Parameter DNN yang digunakan

Parameter	Nilai
Jumlah Input	54
Jumlah layer	3
Jumlah Neuron	128,64,13
Hidden Layer Activation	ReLU
Output Layer Activation	Softmax
Optimizer	SGD + Nesterov
Loss Function	Categorical Cross Entropy
Epoch	200

### 3.3. Perhitungan BMR

Perhitungan BMR dilakukan untuk mengetahui berapa kalori yang harus dikonsumsi dalam satu hari. Perhitungan BMR akan berbeda antara pria dan wanita dan keduanya dapat dihitung dengan rumus 6 dan 7. Gambar 8 menjelaskan flowchart untuk fungsi ini.



Gambar 8. Diagram alir perhitungan BMR

Halo, dengan dibot disini, dibot akan membantumu dalam menghitung jumlah kalori yang harus kalian konsumsi untuk menjaga kesehatan agar tidak berlebihan atau kekurangan, agar dibot bisa membantumu cukup masukkan berat badan(kg) tinggi(cm) umur(tahun)

halo

hallo ada yang bisa saya bantu

kalau boleh tahu perhitungan kalori nya bagaimana ?

untuk perhitungan kalori dibot paka rumus harris-benedict lebih selangkaapnya bisa di lihat di:  
[https://en.wikipedia.org/wiki/Harris%E2%80%93Benedict\\_equation](https://en.wikipedia.org/wiki/Harris%E2%80%93Benedict_equation)

berat saya 58kg tinggi saya 175 cm

okay, sudah dibot simpan jawabannya

data sekarang :  
berat: 58kg  
tinggi: 175 cm  
umur:

umur saya 24 tahun

okay, sudah dibot simpan jawabannya

Gambar 9. Halaman chat



Tabel 3. Nilai loss setelah proses pelatihan sebanyak 200 epoch

Model	Loss	Akurasi	Waktu (s)
Bag of words	0.02674	0.9829	19
TF-IDF	0.00966	0.9964	22

### 4.3. Pelatihan model

Pada tahap ini model akan dilatih dengan model sesuai dengan arsitektur DNN pada gambar7. Terdapat 3 lapisan pada model ini lapisan pertama terdapat 128 neuron layer kedua terdapat 64 neuron dan pada layer terakhir jumlah neuron akan disesuaikan dengan model, untuk model bag of words jumlah neuron berjumlah 12 sesuai dengan panjang dari intent, sedangkan pada model TF-IDF terdapat 12 sesuai dengan proses n-gram pada model TF-IDF dan pada setiap lapisan akan terdapat lapisan Dropout sebanyak 0.5.

Kedua model tersebut dilakukan proses pelatihan dengan SGD dengan Nesterov sebagai optimizer dan epoch sejumlah 200. Berikut hasil grafik untuk epoch *loss* dan epoch akurasi dimana semakin kecil galat maka semakin dekat prediksi benar, epoch akurasi adalah rasio jumlah prediksi benar dengan jumlah total data. Gambar 14 menunjukkan proses pelatihan dimana *loss* dan akurasi diukur untuk setiap epoch. Berdasarkan Tabel 3, dapat dikatakan bahwa model DNN dengan TF-IDF memperoleh *loss* terkecil yakni 0.00966 dan akurasi terbesar yakni 0.9964 daripada model BoW.

Setelah pelatihan selesai maka model tersebut siap untuk melakukan prediksi saat pengguna menginputkan kalimat pada sistem, bentuk output yang dihasilkan model melakukan prediksi seperti pada gambar 15.

berat saya 40 kg dan tinggi saya 180cm

```
[{'intent': 'data berat dan tinggi', 'probability': '0.9999863'}]
```

Gambar 15. Hasil prediksi

### 4.4. Pengujian sistem

Tabel 4 menyajikan hasil pengujian pertanyaan apakah chatbot mengenali pola pertanyaan dengan baik dan menghasilkan respon yang tepat dan sesuai dengan yang pengguna masukkan. Berdasarkan tabel 4 dapat disimpulkan dari 11 pesan yang dimasukkan kedalam chatbot bahwasannya BoW memperoleh rata-rata probabilitas kesesuaian sebesar 0.949051, sedangkan TF-IDF memperoleh rata-rata probabilitas kesesuaian sebesar 0.966046.

Tabel 4. Pengujian chatbot

Pesan	Intent	Probabilitas	
		BoW	TF-IDF
Halo	Pembukaan	0.997919	0.999907
Saya memiliki tinggi 180cm	Data tinggi	0.99974	0.9994
Saya memiliki tinggi 190cm dan berat 59kg	Data tinggi dan berat	0.9975	0.9491
saya memiliki tinggi 180kg dan berat 180cm	Data tinggi dan berat	0.9997	0.932
umur saya 20 tahun dan sberat saya 75kg	Data umur dan berat	0.8114	0.792
umur saya 28tahun tinggi saya 180cm berat saya 58kg	Semua data	0.9996	0.9902
tinggi saya 180cm umur saya 29 tahun	Data tinggi dan umur	0.8596	0.9925
umur saya 28 tahun	Data umur	0.999	0.999
baik terima kasih	Tidak ada	0.8125	0.9744
Saya memiliki berat badan sebanyak 48kg	penutup	0.994	0.999
	Data berat	0.9686	0.999

Tabel 5. Pengujian terhadap data BMR

No	Tinggi (cm)	Berat (kg)	Umur (tahun)	Gender	Hasil
1	175	80	27	Pria	"Bmr": 1763, "Kalori_sarapan": 546.7, "Kalori_makan_siang": 617.3, "Kalori_makan_malam":599.6, "Buah": [ Semangka, Pisang, Jeruk ] "Makanan_pagi":[ roti gandum isi selai ] "Makanan_siang":[ nasi merah,brokoli,sayur lodeh, bakso daging, tempe goreng, ayam goreng ] "Makanan_malam": [nasi putih, tempe goreng, tumis kangkung ] "snack": [ kacang ] "Bmr": 1325.25, "Kalori_sarapan": 410.8, "Kalori_makan_siang": 477., "Kalori_makan_malam":437.3, "Buah": [ Pepaya, Nanas, Stroberi ] "Makanan_pagi":[ bubur ayam, telur ceplok, telur dadar ]
2	165	55	19	Wanita	

No	Tinggi (cm)	Berat (kg)	Umur (tahun)	Gender	Hasil
3	180	67	54	Pria	"Makanan_siang": [ nasi putih, sayur lodeh, daging sapi panggang, tempe goreng ] "Makan malam": [ nasi putih, tempe goreng, tumis kangkung ] "snack": [ kacang ] "Bmr": 1530, "Kalori_sarapan": 474, "Kalori_makan_siang": 535.75, "Kalori_makan_malam": 520.75, "Buah": [ Blueberry, Nanas, Pisang ] "Makanan_pagi": [ Bubur putih, Telur rebus, Tahu goreng, Brokoli ] "Makanan_siang": [ Nasi Merah, Lele goreng, Bakso daging, Sayur Lodeh ] "Makan malam": [ Salad buah ] "Snack": [ Yogurt ] "Bmr": 1036, "Kalori_sarapan": 352.4, "Kalori_makan_siang": 393.8, "Kalori_makan_malam": 290.75, "Buah": [ Blueberry, Nanas, Pisang ]
4	158	52	62	Wanita	"Makanan_pagi": [ Bubur putih, Telur rebus, Tahu goreng, Brokoli ] "Makanan_siang": [ Nasi Merah, Lele goreng, Bakso daging, Sayur Lodeh ] "Makan malam": [ Salad buah ] "Snack": [ Yogurt ] "Bmr": 2326, "Kalori_sarapan": 697.8, "Kalori_makan_siang": 883.9, "Kalori_makan_malam": 744.4, "Buah": [ Blueberry, Semangka, Pisang ]
5	205	120	32	Pria	"Makanan_pagi": [ Nasi putih, Telur ceplok, Ikan tongkol goreng ] "Makanan_siang": [ Nasi Merah, Tumis kangkung, Bakso ayam, Ayam goreng ] "Makan malam": [ Sarden kentang ] "Snack": [ Yogurt ]

## 5. Kesimpulan

Artikel ini menyajikan implementasi chatbot dalam pemilihan makanan dan minuman berdasarkan kalori menggunakan natural language processing. Chatbot dapat memberikan rekomendasi makanan dan minuman sesuai dengan perhitungan BMR pengguna yang dihasilkan dari masukan tinggi badan, berat badan, umur, dan jenis kelamin. Mengacu pada data-data bagian hasil dan pembahasan, pelatihan model Bag of words jauh lebih cepat yakni 19 detik dibandingkan dengan model TF-IDF yang menghabiskan waktu 22 detik, namun model TF-IDF secara kinerja lebih baik karena memiliki nilai loss lebih kecil yakni 0.00966. Pada pengujian kedua metode, nilai akurasi kesesuaian rata-rata metode TF-IDF sebesar 0.966046 (96.6%) lebih baik daripada metode Bag of Words yakni sebesar 0.949051 (94.9%).

## References

- [1] E. V. Osilla, A. O. Safadi, and S. Sharma, "Calories," in *StatPearls*, Treasure Island (FL): StatPearls Publishing, 2023. Accessed: Sep. 17, 2023. [Online]. Available: <http://www.ncbi.nlm.nih.gov/books/NBK499909/>
- [2] P. Banerjee, V. V. R. Mendu, D. Korrapati, and S. M. Gavaravarapu, "Calorie counting smart phone apps: Effectiveness in nutritional awareness, lifestyle modification and weight management among young Indian adults," *Health Informatics J.*, vol. 26, no. 2, pp. 816–828, Jun. 2020, doi: 10.1177/1460458219852531.
- [3] N. Haristiani, "Artificial Intelligence (AI) Chatbot as Language Learning Medium: An inquiry," *J. Phys. Conf. Ser.*, vol. 1387, no. 1, p. 012020, Nov. 2019, doi: 10.1088/1742-6596/1387/1/012020.
- [4] T. Lalwani, S. Bhalotia, A. Pal, V. Rathod, and S. Bisen, "Implementation of a Chatbot System using AI and NLP," *SSRN Electron. J.*, 2018, doi: 10.2139/ssrn.3531782.
- [5] R. Khoirunisa, E. Apriliyanto, A. S. Sandi, and K. Kusriani, "Penggunaan Natural Language Processing Pada Chatbot Untuk Media Informasi Pertanian," *Indones. J. Appl. Inform.*, vol. 4, no. 2, p. 55, Aug. 2020, doi: 10.20961/ijai.v4i2.38688.
- [6] M. Adam, M. Wessel, and A. Benlian, "AI-based chatbots in customer service and their effects on user compliance," *Electron. Mark.*, vol. 31, no. 2, pp. 427–445, Jun. 2021, doi: 10.1007/s12525-020-00414-7.

- [7] University of Goettingen *et al.*, “Chatbots at Digital Workplaces – A Grounded-Theory Approach for Surveying Application Areas and Objectives,” *Pac. Asia J. Assoc. Inf. Syst.*, vol. 12, pp. 63–103, Jun. 2020, doi: 10.17705/1pais.12203.
- [8] M. Jain, P. Kumar, R. Kota, and S. N. Patel, “Evaluating and Informing the Design of Chatbots,” in *Proceedings of the 2018 Designing Interactive Systems Conference*, Hong Kong China: ACM, Jun. 2018, pp. 895–906. doi: 10.1145/3196709.3196735.
- [9] A. B. Kocaballi, L. Laranjo, and E. Coiera, “Understanding and Measuring User Experience in Conversational Interfaces,” *Interact. Comput.*, vol. 31, no. 2, pp. 192–207, Mar. 2019, doi: 10.1093/iwc/iwz015.
- [10] J. Seering, M. Luria, C. Ye, G. Kaufman, and J. Hammer, “It Takes a Village: Integrating an Adaptive Chatbot into an Online Gaming Community,” in *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, Honolulu HI USA: ACM, Apr. 2020, pp. 1–13. doi: 10.1145/3313831.3376708.
- [11] J. Casas, E. Mugellini, and O. A. Khaled, “Food Diary Coaching Chatbot,” in *Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers*, Singapore Singapore: ACM, Oct. 2018, pp. 1676–1680. doi: 10.1145/3267305.3274191.
- [12] P. K. Prasetyo, P. Achananuparp, and E.-P. Lim, “Foodbot: A Goal-Oriented Just-in-Time Healthy Eating Interventions Chatbot,” in *Proceedings of the 14th EAI International Conference on Pervasive Computing Technologies for Healthcare*, May 2020, pp. 436–439. doi: 10.1145/3421937.3421960.
- [13] D. P. Utama, P. Sudarmaningtyas, and A. D. Churniawan, “RANCANG BANGUN APLIKASI PENJUALAN MAKANAN SEHAT BEDASARKAN PERHITUNGAN KALORI MENGGUNAKAN BMR PADA RUMAH SAKIT ISLAM JEMURSARI,” *JSIKA*, vol. 9, no. 3, pp. 1–9, 2019.
- [14] Zhixiang, Xu, M. Chen, K. Q. Weinberger, and F. Sha, “An alternative text representation to TF-IDF and Bag-of-Words.” arXiv, Jan. 28, 2013. Accessed: Mar. 29, 2023. [Online]. Available: <http://arxiv.org/abs/1301.6770>
- [15] S. Oetoro, E. Parengkuan, and J. Parengkuan, *Smart Eating - 1000 Jurus Makan Pintar dan Hidup Bugar*. Gramedia Pustaka Utama, 2013.
- [16] E. Adamopoulou and L. Moussiades, “An Overview of Chatbot Technology,” in *Artificial Intelligence Applications and Innovations*, vol. 584, I. Maglogiannis, L. Iliadis, and E. Pimenidis, Eds., in IFIP Advances in Information and Communication Technology, vol. 584. , Cham: Springer International Publishing, 2020, pp. 373–383. doi: 10.1007/978-3-030-49186-4\_31.
- [17] A. A. Heidari, H. Faris, S. Mirjalili, I. Aljarah, and M. Mafarja, “Ant Lion Optimizer: Theory, Literature Review, and Application in Multi-layer Perceptron Neural Networks,” in *Nature-Inspired Optimizers*, vol. 811, S. Mirjalili, J. Song Dong, and A. Lewis, Eds., in Studies in Computational Intelligence, vol. 811. , Cham: Springer International Publishing, 2020, pp. 23–46. doi: 10.1007/978-3-030-12127-3\_3.
- [18] I. Firmansyah and B. H. Hayadi, “KOMPARASI FUNGSI AKTIVASI RELU DAN TANH PADA MULTILAYER PERCEPTRON,” *J. Inform. Dan Komput.*, vol. 6, no. 2, pp. 200–206, Sep. 2022.
- [19] M. Akbar, “Traffic sign recognition using convolutional neural networks,” *J. Teknol. Dan Sist. Komput.*, vol. 9, no. 2, pp. 120–125, Apr. 2021, doi: 10.14710/jtsiskom.2021.13959.
- [20] R. Umar, I. Riadi, and P. Purwono, “Klasifikasi Kinerja Programmer pada Aktivitas Media Sosial dengan Metode Stochastic Gradient Descent,” *JOINTECS J. Inf. Technol. Comput. Sci.*, vol. 5, no. 2, p. 55, May 2020, doi: 10.31328/jointecs.v5i2.1324.
- [21] X. Ying, “An Overview of Overfitting and its Solutions,” *J. Phys. Conf. Ser.*, vol. 1168, p. 022022, Feb. 2019, doi: 10.1088/1742-6596/1168/2/022022.
- [22] A. Pinto, H. Gonçalo Oliveira, and A. Oliveira Alves, “Comparing the Performance of Different NLP Toolkits in Formal and Social Media Text,” p. 16 pages, 2016, doi: 10.4230/OASICS.SLATE.2016.3.
- [23] N. Indurkha and F. J. Damerou, *Handbook of natural language processing*. Boca Raton, FL: Chapman & Hall/CRC, 2010.
- [24] W. T. H. Putri and P. Hendrowati, “PENGALIAN TEKS DENGAN MODEL BAG OF WORDS TERHADAP DATA TWITTER,” *J. Muara Sains Teknol. Kedokt. Dan Ilmu Kesehat.*, vol. 2, no. 1, pp. 129–138, Apr. 2018, doi: <https://doi.org/10.24912/jmstkk.v2i1.1560>.
- [25] St. Luke’s Medical Center, Quezon City, Philippines, S. C. Luy, and O. A. Dampil, “Comparison of the Harris-Benedict Equation, Bioelectrical Impedance Analysis, and Indirect Calorimetry for Measurement of Basal Metabolic Rate among Adult Obese Filipino Patients with Prediabetes or Type 2 Diabetes Mellitus,” *J. ASEAN Fed. Endocr. Soc.*, vol. 33, no. 2, pp. 152–159, Nov. 2018, doi: 10.15605/jafes.033.02.07.