

**KLASIFIKASI KELUHAN PELANGGAN MENGGUNAKAN METODE
CONVOLUTIONAL NEURAL NETWORK (CNN)
STUDI KASUS PT TELKOM AKSES
WITEL SURABAYA SELATAN**

M Rizal Yogaswara

1461700046

**Prodi Teknik Informatika
Universitas 17 Agustus 1945 Surabaya**

2021

rizalyoga5@gmail.com

Abstrak

Pentingnya pengolahan data di era modern ini membuat manusia membutuhkan *tools* yang efektif untuk mengolah data. Pemanfaatan kecerdasan buatan di berbagai aspek kehidupan manusia saat ini semakin banyak digunakan. *Deep learning* merupakan cabang dari pembelajaran mesin dan memiliki keunggulan ketika digunakan untuk melakukan klasifikasi data. Klasifikasi data didapatkan dengan menggunakan model identifikasi yang dibentuk dengan algoritma *convolutional neural network* (CNN) yang menerapkan konsep dari *deep learning*. Penelitian ini bertujuan untuk mengklasifikasikan data keluhan pelanggan menjadi 4 kelas yaitu internet, iptv, *voice* dan other (nn) menggunakan metode CNN. Data dari keluhan pelanggan diambil dari aplikasi *website* NOSSA yang biasa dioperasikan oleh *helpdesk assurance* PT Telkom Akses. Pada penelitian ini diperoleh akurasi sebesar 77 % dari sebanyak 114 data yang diujikan.

Kata Kunci : klasifikasi data, deep learning, pembelajaran mesin, convolutional neural network

Abstract

The importance of data processing in this modern era makes humans need effective tools to process data. The use of artificial intelligence in various aspects of human life is now increasingly being used. Deep learning is a branch of machine learning and has advantages when used to classify data. Data classification is obtained by using an identification model formed by the convolutional neural network (CNN) algorithm that applies the concept of deep learning. This study aims to classify customer complaint data into 4 classes, namely internet, iptv, voice and other (nn) using the convolutional neural network (CNN) method. Data from customer complaints is taken from the NOSSA website application which is usually operated by the helpdesk assurance PT Telkom Access. In this study, an accuracy of 77% was obtained from as many as 114 data tested.

Keywords : data classification, deep learning, machine learning, convolutional neural network

1. PENDAHULUAN

Pengolahan data dibutuhkan untuk mengetahui laporan dari setiap kegiatan manusia yang dilakukan dalam sebuah perusahaan untuk kebutuhan laporan ke atas maupun untuk melihat performansi sudah sejauh mana progresnya. Sehingga dapat membuat kesimpulan, strategi apa yang akan dilakukan kedepannya.

Bidang dari kecerdasan buatan yang digunakan dalam riset ini adalah *machine learning*.

2. TINJAUAN PUSTAKA

2.1. Teks

Teks merupakan kumpulan dari beberapa karakter yang biasanya dituliskan oleh seorang pengirim ke penerima yang tersusun menjadi sebuah satu kesatuan yang utuh sehingga dapat digunakan sebagai media komunikasi yang memiliki banyak arti ketika penerima membacanya.

2.2. Data

Data sendiri bisa diartikan sebagai kumpulan dari fakta-fakta yang digunakan untuk menggambarkan sebuah kejadian atau keadaan. Manusia menggunakan data untuk menyimpulkan sebuah kejadian, biasanya digunakan sebagai acuan untuk melakukan langkah selanjutnya ataupun untuk memprediksi kejadian yang akan datang. Data biasanya dikumpulkan sedemikian rupa dan disusun semenarik atau se informatif mungkin agar memudahkan untuk memahaminya.

2.3. Klasifikasi

Klasifikasi merupakan suatu tata cara penyusunan yang didasarkan pada sebuah kategori tertentu. Dari beberapa kategori ini akan memunculkan kesamaan dalam suatu kategori tertentu. Jadi kategori ini bisa diartikan sebagai penyusunan berdasarkan suatu jenis

Klasifikasi adalah bagian dari data mining yang digunakan untuk memperkirakan kategori suatu obyek menjadi tiap tiap kelas.

Pada riset ini algoritma dari CNN di implementasikan untuk mengklasifikasikan data keluhan pelanggan pada layanan internetnya. Algoritma CNN dipilih karena dapat bekerja optimal pada data dalam jumlah yang besar. Sehingga diharapkan dapat memberikan efisiensi dalam melakukan pengklasifikasian jenis gangguan layanan internet.

atau kesamaan dari sebuah benda maupun sifat. Misalkan kita ingin memilah milah buah dan ditempatkan pada keranjang sesuai dengan jenisnya.

2.4. Kecerdasan Buatan

Kecerdasan buatan adalah sistem dengan konsep meniru dari kecerdasan manusia yang diterapkan pada komputer. Contoh dari system AI ini seperti sistem pakar, *face recognition*, robot dan masih banyak lagi.

Komputer saat ini digunakan untuk mempermudah semua jenis kegiatan yang dilakukan manusia di berbagai aspek. Banyak sekali pada kehidupan manusia ini sudah memanfaatkan komputer sebagai efektifitas waktu dalam mengerjakan tugas.


2.5. *Machine Learning*

Arthur Samuel mendefinisikan machine learning di tahun 1959. *Machine learning* didefinisikan sebagai komputer yang dapat mempelajari inputan berupa pengalaman dan pengetahuan yang dimiliki manusia. Dari pengalaman yang dimiliki oleh manusia dituangkan ke mesin untuk dilakukan pelatihan / pembelajaran sehingga mesin dapat mempunyai pengalaman yang sama seperti manusia dan dapat melakukan pekerjaan layaknya manusia.

2.6. Deep Learning

Adalah salah satu bidang riset yang berada pada area pembelajaran mesin. *Deep learning* telah banyak digunakan dan menjadikan *deep learning* sebagai bidang yang memberikan kontribusi besar dalam perkembangan kecerdasan. (Vargas, Mosavi and Ruiz, 2018)


Ilustrasi dan model matematika dari sebuah saraf ditunjukkan pada gambar 2.1.



Gambar 2. 1. Ilustrasi Neuron (Li, Karpathy and Johnson, 2016)

2.7. Artificial Neural Network

Merupakan permodelan dari AI yang menirukan kinerja otak manusia. Gambar 2.3. digambarkan ilustrasi neuron.




Gambar 2. 2. Ilustrasi Neuron

2.8. Konsep Neural Network


2.8.1. Jaringan Syaraf Pada Otak Manusia

Digambarkan pada gambar 2.3.



Gambar 2. 3. Skema Neuron

2.8.2. Struktur Neural Network




Gambar 2. 4. Struktur Artificial Neural Network

Gambar 2.5. menjelaskan secara sederhana struktur dari ANN

2.8.3. Arsitektur Jaringan Syaraf Tiruan


Arsitektur JST diilustrasikan sebagai gambar 2.6. :



Gambar 2. 5. Arsitektur Jaringan Syaraf Tiruan


2.8.4. Activation Function


a. Linear Function



Gambar 2. 6. Linear Function


b. Sigmoid and Tanh Function (Non-Linear)





Gambar 2. 7. Sigmoid and Tanh Function (Non-Linear)

c. ReLU (Non-Linear)



Gambar 2. 8 . ReLU (Non-Linear)


d. Pembelajaran Backpropagation

Backpropagation merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot- bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyi. (Kiki and Kusumadewi, 2004)

2.9. Algoritma Convolutional Neural

Network

Arsitektur keseluruhan dari sebuah CNN ditunjukkan pada gambar 2.7 (Murugan, 2017).



Gambar 2. 9. Arsitektur CNN (Murugan, 2017)

2.9.1. Convolution Layers

Lapisan konvolusi terbentuk dari sekumpulan feature map. Lapisan ini dilakukan dengan menggerakkan kernel map.

Dimensi dari lapisan konvolusi dihitung menggunakan persamaan 2.2. Convolution Layer (Murugan, 2017)


$$Dimc(H1, W1, D1 = [(H + 2Zp - k1) + 1], \tag{2. 1.}$$

$$[W + 2Zp - k2 + 1] , [KD] \dots ZsZs$$

Dengan :

- Dimc : Dimensi lapisan konvolusi
- H1 : Tinggi lapisan konvolusi
- W1 : Lebar lapisan konvolusi
- D1 : Kedalaman lapisan konvolusi
- H : Tinggi citra
- W : Lebar citra
- Zp : Nilai zeropadding
- K₁ : Lebar kernel konvolusi
- K₂ : Tinggi kernel konvolusi
- Z_s : Nilai stride
- K_D : Jumlah kernel

Ilustrasi dari lapisan konvolusi ditunjukkan pada gambar 2.12.



Gambar 2. 10. Ilustrasi Lapisan Konvolusi

2.9.2. Pooling Layers

Operasi pooling dilakukan setelah aktivasi non-linier dimana lapisan pooling akan mengurangi jumlah data dan mencegah terjadinya overfit. Lapisan ini juga bisa berperan sebagai proses smoothing (mengurangi noise). Pada riset ini digunakan operasi maxpooling, yaitu dilakukan dengan mengambil nilai terbesar dari masukan berdasarkan ukuran kernel map. Dimensi dari

lapisan *pooling* ini dihitung dengan persamaan 2.3 (Murugan, 2017)

$$Dim_p(H_2, W_2, D_2) = [H_1 - k + 1], [W_1 - k + 1], [D_n] \dots Z_s Z_s \quad (2.2)$$

Dengan :

Dimp : Dimensi lapisan *pooling*

H2 : Tinggi lapisan *pooling*

W2 : Lebar lapisan *pooling*

D2 : Kedalaman lapisan *pooling*

H : Tinggi citra

W : Lebar citra


k : Lebar dan tinggi kernel lapisan

pooling

ZS : Nilai *stride*

Dn : Jumlah kernel lapisan *pooling*

Gambar 2.13. menampilkan ilustrasi dari lapisan *pooling* pada sebuah citra berukuran 4x4 dengan kernel map berukuran 2x2.



Gambar 2. 11. Ilustrasi Lapisan *Pooling*

2.9.3. Fully-connected Dense Layers

Setelah melalui serangkaian lapisan konvolusi dan *pooling*, setiap piksel pada lapisan *pooling* direntangkan menjadi vektor berdimensi satu. Data yang telah direntangkan dan digabungkan diumpankan ke lapisan dense, yang dikenal juga sebagai lapisan *fully-connected* dan digunakan pada tahapan klasifikasi. Fungsi dari lapisan ini akan sama seperti fungsi *multi layer perceptron* pada *deep learning* pada umumnya (Murugan, 2017).

2.9.4. Fungsi Aktivasi

Fungsi aktivasi mendefinisikan output dari sebuah neuron berdasarkan sekelompok input. Persamaan 2.4. menunjukkan fungsi-fungsi aktivasi yang terdapat pada CNN (Murugan, 2017).

Tabel 2. 1. Fungsi Aktivasi

Nama	Fungsi
Sigmoid	$\sigma(x) = \frac{1}{1 + e^{-x}}$
tanh	$\sigma(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
ReLU	$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$
Leaky ReLU	$f(x) = \begin{cases} 0.01x & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$
Softmax	$f(x) = \frac{e^x}{\sum_1^j e^x}$

Fungsi aktivasi *softmax* dipilih karena dapat merepresentasikan diferensiasi dari kelas sebanyak N. Fungsi aktivasi yang digunakan pada *convolution layer* adalah fungsi aktivasi *ReLU*. Penggunaan *ReLU* akan mempercepat pelatihan karena perhitungannya yang sederhana (bernilai 0 jika $x < 0$ atau 1)

2.9.5. Fungsi Loss

Fungsi *loss* atau disebut juga fungsi cost digunakan untuk mengukur kinerja dari modal dan ketidakkonsistenan antara nilai aktual y_i dengan nilai prediksi y_{iL+1} . persamaan 2.5. (Murugan, 2017).

$$L(y^{L+1}, y) = \sum_{i=1}^t (y_i, (\sigma(x), w, b)) \dots \dots \quad (2.3)$$

L+1 : Lapisan klasifikasi pada fully-


- L : Lapisan akhir pada *fully-connected layer connected layer* t : Jumlah keseluruhan sampel data latih
- y_i : Nilai aktual dari data latih yang telah diberi label kelas σ : Fungsi aktiva
- y^{L+1} : Matriks nilai prediksi w : Parameter *weight*
- b : Parameter bias

Tabel 2. 2. Fungsi-Fungsi *Loss* yang Terdapat Pada CNN

Nama	Fungsi
Mean Squared Error	$L(y_i^{L+1}, y_i) = \frac{1}{t} \sum_{i=1}^{i=t} (y_i - y_i^{L+1})^2$
Mean Squared Logarithmic Error	$L(y_i^{L+1}, y_i) = \frac{1}{t} \sum_{i=1}^{i=t} (\log(y_i + 1) - \log(y_i^{L+1} - 1))^2$
L_2	$L(y_i^{L+1}, y_i) = \sum_{i=1}^{i=t} (y_i - y_i^{L+1})^2$
L_1	$L(y_i^{L+1}, y_i) = \sum_{i=1}^{i=t} y_i - y_i^{L+1} $
Mean Absolute Error	$L(y_i^{L+1}, y_i) = \frac{1}{t} \sum_{i=1}^{i=t} y_i - y_i^{L+1} $
Mean Absolute Percentage Error	$L(y_i^{L+1}, y_i) = \frac{1}{t} \sum_{i=1}^{i=t} \left \frac{y_i - y_i^{L+1}}{y_i} \right \times 100$
Cross Entrophy	$L(y_i^{L+1}, y_i) = \frac{1}{t} \sum_{i=1}^{i=t} ((y_i) \log(y_i^{L+1}) + (1 - y_i) \log(1 - y_i^{L+1}))$


Pada riset ini digunakan fungsi *loss Cross Entrophy*. Dengan data kelas berbentuk kategori digunakan vektor bernilai 1 pada indeks kelas dan 0 di luar indeks kelas (Keras, 2018).

2.10. Pengembangan Perangkat Lunak



Gambar 2. 12. *Waterfall Model* (Sommerville, 2011)

3. METODE PENELITIAN




Gambar 3. 1. *Flowchart* Gambaran Umum Riset

Gambaran umum dari riset skripsi ini dapat dilihat pada Gambar 3.1.

1.1. Pengambilan Data

Pengambilan data didapatkan dari keluhan pelanggan yang di inputkan pada *website* NOSSA yang biasanya dioperasikan oleh helpdesk assurance. Tahapannya telah digambarkan pada *flowchart* gambar 3.2. :



Gambar 3. 2. *Flowchart* Pengambilan Data


1.2. Preprocessing

Preprocessing dilakukan dengan tujuan untuk mempersiapkan data dari bentuk data mentah (*raw data*) menjadi data yang siap

digunakan pada tahapan selanjutnya. Tahapannya dijelaskan sebagai berikut :

1. Menghilangkan *Punctuation*
2. Menghilangkan *Stopwords*
3. *Case Folding*
4. *Tokenize*
5. *Padding*

Ke lima tahapan diatas digambarkan pada *flowchart* gambar 3.3. :




Gambar 3. 3. *Flowchart* Tahap *Preprocessing*

1.3. Klasifikasi dengan *Convolutional Neural Network*

Langkah-langkah secara umum dari algoritma CNN adalah sebagai berikut:


1. Menerima masukan data berupa data teks yang telah melalui proses *preprocessing*
2. Melalui proses *embedding*
3. Melalui proses konvolusi satu dimensi
4. Melalui proses *max pooling*
5. *Flatten* terhadap data
6. *Dense* sebanyak 2 kali

Untuk penjelasan secara lebih terstruktur langkah-langkah dari algoritma CNN dapat melihat *flowchart* pada gambar 3.8.




Gambar 3. 4. *Flowchart Tahap Klasifikasi dengan Convolutional Neural Network*

1.4. Usecase Diagram



Gambar 3. 5. *Usecase Register dan Login*


Pada *usecase register* dan *login* dapat dijelaskan, pelanggan dapat melakukan *register* dengan mengisi setiap kolom-kolom pengisian data yang dibutuhkan, sedangkan sistem akan merecord data dari pelanggan. Setelah proses register berhasil pelanggan dapat melakukan *login*. Tentunya dengan mengisi data yang sebelumnya telah diisikan. Dari sisi sistem menampilkan halam login untuk kemudian masuk ke halaman utama.



Gambar 3. 6. *Usecase Input Keluhan Gangguan*

Selanjutnya pada *usecase input keluhan gangguan*, disini dijelaskan bahwa pelanggan dapat melakukan *input* data keluhan gangguan pada kolom yang telah disediakan. Setelah pelanggan mengisi keluhan dan menekan tombol *submit*. Sistem akan memberikan ID nomor gangguan, mengklasifikasikan jenis gangguan apa yang diinputkan oleh pelanggan.

Sedangkan di sisi admin, dapat melihat order untuk selanjutnya di evaluasi dan di cek.



Gambar 3. 7. *Usecase Cek Progres*

Yang terakhir adalah *usecase cek progres*, pada *usecase* ini pelanggan dapat melihat progres dari laporannya apakah sudah ditindaklanjuti atau belum. Dari sisi admin apabila terdapat kesalahan data, maka admin dapat mengubahnya. Serta dapat mensortir apakah gangguan tersebut layak diprogres atau tidak. Setelah data dipastikan benar, admin dapat mengubah status order dari pelanggan. Dan sistem akan menampilkannya di halaman pelanggan.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pengembangan Aplikasi

Pengembangan aplikasi meliputi lingkungan implementasi aplikasi dan implementasi antarmuka.

4.1.1. Lingkungan Implementasi

Pelatihan model identifikasi pada riset ini dilakukan dengan menggunakan *Google Colab*. Ketika riset ini dilakukan, *Google Colab* memiliki spesifikasi sebagai berikut:

1. *Processor* : 1x single core hyper threaded Xeon Processor@2.3 Ghz
2. *GPU* : 1x Tesla K80, 2496 CUDA cores, 12GB DDRV5VRAM
3. *RAM* : 12.6 GB
4. *Disk* : 33 GB

Pengujian dan penggunaan kamera untuk melakukan klasifikasi keluhan pelanggan pada riset ini dikembangkan pada lingkungan perangkat keras dengan spesifikasi sebagai berikut:

1. *Processor* : Apple M1
2. *GPU* : Integrated 7-core GPU
3. *RAM* : 8 GB
4. *Harddisk* : SSD 256 GB

dan lingkungan perangkat lunak sebagai berikut:

1. MacOS Big Sur
2. Python 3
3. Keras
4. Tensorflow
5. Sublime Text

4.1.2. Implementasi Antarmuka

Hasil implementasi dari aplikasi klasifikasi keluhan pelanggan menghasilkan sebuah website pelaporan, dimana pelanggan menginputkan sendiri keluhannya pada website.

A. Halaman Interface User Pelanggan

1. Halaman Register Pelanggan

Gambar 4. 1. Halaman Registrasi Pelanggan

Gambar 4.1. merupakan halaman registrasi pelanggan, pelanggan dapat melakukan registrasi user untuk melakukan pelaporan gangguan. Pelanggan cukup menginputkan data di kolom nama, alamat *email* serta *password*. Setelah semua data terisi, pelanggan dapat memilih register untuk melanjutkan ke langkah selanjutnya.

2. Halaman *Login* Pelanggan

Gambar 4. 2. Halaman *Login* Pelanggan

Gambar 4.2. merupakan halaman awal login. Setelah pelanggan melakukan proses registrasi, pelanggan dapat melakukan *login* di halaman web pelaporan, pada halaman *login* ini, pelanggan bisa menginputkan email dan *password* yang telah di inputkan pada halaman registrasi sebelumnya.

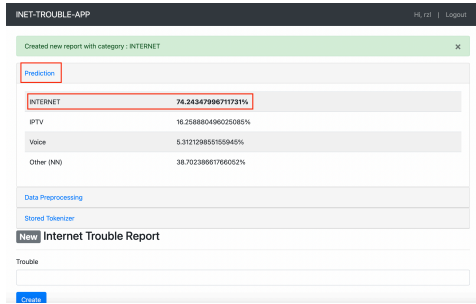
3. Halaman Pelaporan Pelanggan

Gambar 4. 3. Halaman Pelaporan Pelanggan

Gambar 4.3. merupakan halaman pelaporan pelanggan, pelanggan dapat menginputkan keluhannya pada kolom trouble. Pelanggan dapat mengisikan kolom isian sesuai dengan jenis keluhan yang akan dilaporkan. Pada aplikasi akan memberikan rekomendasi keluhan agar pengguna tidak bisa sembarang mengetik gangguan dan sesuai dengan kategori


gangguan pada aplikasi. Pada gambar 4.3. pelanggan menginputkan keluhan “Wifi Putus Putus”. Setelah mengisi kolom pengisian keluhan, pelanggan dapat memilih tombol create agar tercatat di sistem.

4. Halaman Dashboard Pelaporan Pelanggan



Gambar 4. 4. Dashboard Pelaporan Pelanggan – Prediction

Gambar 4.4. merupakan halaman dashboard pelaporan pelanggan, setelah pelanggan menginputkan keluhan, system memprediksi termasuk jenis gangguan apa keluhan pelanggan pada fitur prediction. Fitur ini menampilkan ke 4 kelas dengan persentase dari prediksi sistem. Dengan catatan persentase terbesar yang dicetak tebal dan muncul popup berwarna hijau “Created new report with category : INTERNET”. Itulah prediksi dari system yang menunjukkan hasil dari klasifikasi gangguannya dengan persentase sebesar 74,24 %



Gambar 4. 5. Dashboard Pelaporan Pelanggan – Preprocessing

Gambar 4.5. berisi tentang proses preprocessing dari sistem. Gambaran dari masing masing fitur bisa dilihat pada gambar 4.5.



Gambar 4. 6. Halaman Dashboard Pelanggan – Stored Tokenizer

Gambar 4.6. merupakan tampilan dari stored tokenizer, berisi indeks kamus dari kata kata yang nantinya dicocokkan dengan kebutuhan machine learning.

5. Halaman Pengecekan Laporan Pelanggan

Gambar 4. 7. Halaman Pengecekan Laporan Pelanggan

Gambar 4.7. berisi halaman pengecekan laporan pelanggan. Setelah melakukan laporan dan mendapatkan nomer ID, pelanggan bisa mengecek status laporan yang telah dibuat hanya dengan mengisikan alamat email dan nomer ID gangguan tanpa melakukan login terlebih dahulu. Setelah menginputkan email dan nomer ID gangguan. Pelanggan bisa memilih tombol view untuk melihat progres pelaporannya.

6. Halaman Progres Laporan Pelanggan

Here are summary of your report:	
ID	89
Trouble	Wifi Putus Putus
Status	PENDING
Category	INTERNET

Gambar 4. 8. Halaman Progres Laporan Pelanggan

Gambar 4.8. merupakan halaman progres laporan pelanggan, berisi data nomer ID, keluhan, status gangguan, dan kategori gangguan. Di halaman ini pelanggan dapat melihat status laporannya apakah sudah di kerjakan atau belum. Di halaman ini pelanggan juga dapat mengisikan apabila ada laporan lain yang telah di inputkan sebelumnya.

B. Halaman *Interface User Admin*

1. Halaman *Dashboard User Admin*

#	ID	Trouble	Status	Category	Predicted from ML
1	89	Wifi Putus Putus	PENDING	INTERNET	True
2	88	Tidak bisa browsing	PENDING	INTERNET	True
3	87	Internet Lambat	PENDING	INTERNET	True
4	86	Tidak bisa browsing	PENDING	INTERNET	True
5	85	Non Teknis - PSB belum aktif	PENDING	INTERNET	True

Gambar 4. 9. Halaman *Dashboard Admin*

Gambar 4.9. merupakan halaman *dashboard* admin. Setelah admin melakukan *login* pada *website*, pada halaman *dashboard* admin dapat melihat laporan dari keluhan pelanggan yang berisi ID gangguan, keluhan pelanggan, status progres, kategori gangguan dan prediksi dari sistem.

2. Halaman Evaluasi Keluhan Pelanggan dari Sisi Admin

Form details: Trouble: Wifi Putus Putus; Status: PENDING; Category (predicted from ML): INTERNET.

Gambar 4. 10. Halaman Evaluasi Keluhan Pelanggan dari sisi Admin

Gambar 4.10. merupakan halaman evaluasi keluhan pelanggan dari sisi admin, admin dapat mengedit status dan kategori apabila dibutuhkan.

Form details: Status dropdown menu with options: PENDING, ON_PROGRESS, DONE.

Gambar 4. 11. Halaman Evaluasi Keluhan Pelanggan dari sisi Admin

Gambar 4.11. menunjukkan proses dari edit keluhan dari sisi admin. Pada halaman evaluasi keluhan pelanggan, admin dapat melakukan *edit* data jenis kategori gangguan apabila keliru. Dan dapat edit data progress pengerjaan oleh teknisi. Sehingga pelanggan dapat melihat update sudah sampai mana progress pengerjaan gangguan. Gambaran hasil setelah edit di sisi admin dapat dilihat pada gambar 4.12.

Form details: Status dropdown menu with 'ON_PROGRESS' selected.

Gambar 4. 12. Halaman Evaluasi Keluhan Pelanggan dari sisi Admin

4.2. Skenario Pengujian Aplikasi

4.2.1. Skenario Pengujian Fungsional Aplikasi

Tabel 4.1 menampilkan poin- poin pengujian fungsional aplikasi.

Tabel 4. 1. Pengujian Fungsional Aplikasi

No	Deskripsi	Cara Uji	Jenis Pengujian
1	Melakukan preprocessing terhadap data	Melakukan preprocessing terhadap data latih dan data uji	Black box


2	Melakukan proses pengujian dan menghitung akurasi	<ol style="list-style-type: none"> Melakukan pengujian menggunakan data uji dan model identifikasi Menampilkan hasil perhitungan akurasi 	Black box
3	Melakukan klasifikasi gangguan dan menampilkan	Melakukan proses dari klasifikasi gangguan dan menampilkan hasil prediksi dari klasifikasi	Black box

4.2.2. Skenario Pengujian Kinerja Aplikasi

Skenario pengujian kinerja aplikasi terdiri dari data pengujian kinerja aplikasi dan skenario pengujian kinerja aplikasi.


4.2.2.1. Data Pengujian Kinerja Aplikasi

Proses pelatihan aplikasi menggunakan data latih sebanyak 6722 data. Dari 398 data tersebut terbagi menjadi 4 kelas klasifikasi dengan persebaran 4094 data dengan label internet, 22 data dengan label iptv, 1969 data dengan label nn dan 437 data dengan label voice. Grafik persebaran data latih secara mendetil terdapat pada gambar 4.13.



Gambar 4.13. Grafik Persebaran Data Latih

Proses pelatihan aplikasi menggunakan data uji sebanyak 114 data. Dari 114 data tersebut terbagi menjadi 4 kelas klasifikasi dengan persebaran 62 data dengan label internet, 8 data dengan label iptv, 27 data dengan label nn dan 19 data dengan label voice. Grafik persebaran data latih secara mendetil terdapat pada gambar 4.14.



Gambar 4.14. Grafik Persebaran Data Uji

4.2.2.2. Skenario Pengujian Kinerja Aplikasi

Pengujian aplikasi dilakukan dengan menginputkan keluhan gangguan pelanggan, berikut merupakan hasil dari percobaan uji yang ditampilkan pada tabel 4.2. Dijelaskan *input* data dengan hasilnya berupa prediksi serta persentase tiap tiap kelas, hasil dari prediksi tiap inputan data ditandai dengan blok kuning.

Tabel 4. 2. Pengujian Kinerja Aplikasi

Perobaan ke	Input	Hasil Prediksi Sistem dan Persentase			
		INTER NET	IPTV	VOIC E	Other (NN)
1	Tidak bisa menghubungi nomor tertentu	93,97%	7,21%	3,29%	0,86%
2	Perangkat Pelanggan - Petugas Diminta Datang	79,05%	26,71%	16,76%	0,22%
3	Non Teknis - PSB belum aktif	68,07%	22,75%	10,57%	3,61%
4	Jaringan Layak - STB Error (User tidak terdaftar)	6,91%	99,99%	99,84%	0,02%
5	Jaringan Layak - Fiber - Telepon mati/Tidak ada nada	0,51%	99,21%	99,99%	4,38%
6	Tidak Bisa Browsing - Tidak Bisa Koneksi	99,95%	3,02%	0,57%	2,33%
7	Jaringan Tidak Layak - Fiber - Telepon mati/Tidak ada nada	0,52%	99,21%	99,99%	4,38%
8	Bisa Browsing (FISI K) - Intermitten / Putus-Putus	99,79%	1,11%	1,52%	3,19%
9	Jaringan Tidak Layak - Telepon mati/Tidak ada nada	0,52%	99,21%	99,99%	4,38%
10	Jaringan Tidak Layak - Fiber - Tidak bisa memanggil	1,75%	97,73%	99,99%	2,56%

Untuk mengukur performa algoritma dari ML digunakanlah acuan *confusion matrix*. *Confusion matrix* menggambarkan prediksi dan kondisi sebenarnya (aktual) dari data yang dihasilkan oleh algoritma ML. Tabel 4.2. menggambarkan confusion matrix dari data uji tiap kelas.

Tabel 4. 3. Tabel *Confusion Matrix* Data Uji

aktual/ prediksi	internet (P0)	iptv (P1)	voice (P2)	nn (P3)
internet (A0)	62	0	0	0
iptv (A1)	8	0	0	0
voice (A2)	18	0	0	0
nn (A3)	0	0	0	26

Tabel 4. 4. Akurasi dari aplikasi

kategori	precision	recall	f1-score	support
INTERNET	0,70	1,00	0,83	62
IPTV	0,00	0,00	0,00	8
VOICE	0,00	0,00	0,00	18
NN	1,00	1,00	1,00	26

accuracy			0,77	114
macro avg	0,43	0,50	0,46	114
weighted avg	0,61	0,77	0,68	114

Berdasarkan *confusion matrix*, kita bisa menentukan *Precision*, *Recall* dan *F1-Score* Dari table diatas kita dapat mengambil kesimpulan bahwa tingkat akurasi pada aplikasi klasifikasi keluhan gangguan ini sebesar 77% dari 114 data uji.

5. KESIMPULAN DAN SARAN

5.1. Kesimpulan

1. Klasifikasi keluhan pelanggan dengan arsitektur CNN yang digunakan pada riset ini memperoleh akurasi sebesar 77 %.
2. Pemilihan arsitektur CNN akan memengaruhi kinerja dari model yang dibentuk.
3. Persebaran data yang tidak seimbang pada setiap kelas (*imbalanced dataset*) akan memengaruhi hasil prediksi dari algoritma CNN. Hasil prediksi akan didominasi oleh

kelas-kelas dengan jumlah data latih lebih besar dari kelas lainnya.

5.2. Saran

1. Menggunakan dataset dengan persebaran kelas setiap data berimbang. *Imbalanced dataset* atau persebaran data yang tidak berimbang pada setiap kelas data akan sangat memengaruhi kinerja dari *deep learning*.
2. Memastikan setiap kelas pada data latih mudah untuk dibedakan antara satu dengan lainnya. Pemilihan dataset dengan persebaran kelas dengan perbedaan data

yang jelas pada setiap kelas data akan mempermudah model untuk melakukan prediksi dengan lebih akurat.

DAFTAR PUSTAKA

- Danakusumo, K. P. (2017) 'Implementasi Deep Learning Menggunakan Convolutional Neural Network Untuk Klasifikasi Citra Candi Berbasis Gpu', *Tugas Akhir*.
- Du, X. *et al.* (2017) 'Overview of deep learning', in *Proceedings - 2016 31st Youth Academic Annual Conference of Chinese Association of Automation, YAC 2016*. doi: 10.1109/YAC.2016.7804882.
- Goodfellow, I. J. *et al.* (2015) 'Challenges in representation learning: A report on three machine learning contests', *Neural Networks*. doi: 10.1016/j.neunet.2014.09.005.
- Kiki, K. and Kusumadewi, S. (2004) 'Jaringan Saraf Tiruan dengan Metode Backpropagation untuk Mendeteksi Gangguan Psikologi', *Media Informatika*. doi: 10.20885/informatika.vol2.iss2.art1.
- LeCun, Y., Bengio, Y., Hinton, G. (2015) 'Deep learning. nature 521 (7553): 436', *Nature*.
- Li, F.-F., Karpathy, A. and Johnson, J. (2016) 'Convolutional Neural Networks for Visual Recognition, <http://cs231n.stanford.edu/>', *CS231n Lecture Notes, Stanford University*.
- Lorentius, C. A., Adipranata, R. and Tjondrowiguno, A. (2020) 'Pengenalan Aksara Jawa dengan Menggunakan Metode Convolutional Neural Network', *e-Proceeding of Engineering*.
- Murugan, P. (2017) 'Feed Forward and Backward Run in Deep Convolution Neural Network', *arXiv*.
- Pujoseno, J. (2018) 'IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI ALAT TULIS (Studi Kasus : Gambar alat tulis (Ballpoint, Penghapus dan Penggaris)', *Gastrointestinal Endoscopy*.
- Shafira, T. (2018) 'IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORKS UNTUK KLASIFIKASI CITRA TOMAT MENGGUNAKAN KERAS', *Journal of Materials Processing Technology*.
- Sommerville, I. (2011) *Engenharia de Software 9 ed. - Sommerville, Pearson Education*.
- Vargas, R., Mosavi, A. and Ruiz, R. (2018) 'Deep Learning: A Review', *Advances in intelligent systems and computing*. doi: 10.20944/preprints201810.0218.v1.

KLASIFIKASI KELUHAN PELANGGAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) STUDI KASUS PT TELKOM AKSES WITEL SURABAYA SELATAN

by M Rizal Yogaswara

Submission date: 12-Jul-2021 08:06PM (UTC+0700)

Submission ID: 1618700678

File name: TEKNIK_1461700046_M_RIZAL_YOGASWARA_1.pdf (7.25M)

Word count: 3805

Character count: 22119

KLASIFIKASI KELUHAN PELANGGAN MENGGUNAKAN METODE
CONVOLUTIONAL NEURAL NETWORK (CNN) STUDI KASUS PT
TELKOM AKSES WITEL SURABAYA SELATAN

ORIGINALITY REPORT

17%

SIMILARITY INDEX

14%

INTERNET SOURCES

7%

PUBLICATIONS

11%

STUDENT PAPERS
