



Klasifikasi jamur menggunakan algoritma naïve bayes

Regiolina Hayami^{*1}, Soni², Irzi Gunawan³

Email: ¹regiolinahayami@umri.ac.id, ²soni@umri.ac.id, ³170401094@student.umri.ac.id

¹²³Teknik Informatika, Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

Diterima: 25 April 2022 | Direvisi: 31 Mei 2022 | Disetujui: 31 Mei 2022

©2022 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Jamur merupakan tanaman dari kingdom fungi dengan tubuh berdaging dan dapat dapat dimakan, meski demikian terdapat beberapa spesies jamur yang tidak dapat dimakan dan memiliki ciri khas tersendiri. Banyaknya orang yang mengkomsumsi jamur tanpa tahu apakah jamur yang dikomsumsi aman untuk dimakan atau beracun mengakibatkan banyak insiden keracunan jamur bahkan hingga meninggal. Salah satu jenis edukasi yang dapat dilakukan adalah dengan membuat sebuah alat dalam bentuk perangkat lunak untuk mengklasifikasikan jenis jamur menjadi bisa dimakan atau beracun. Salah satu jenis klasifikasi menggunakan algoritma kecerdasan buatan adalah algoritma Naïve Bayes yang mengasumsikan setiap nilai atribut yang mempengaruhi nilai kelas bersifat independen dari nilai atribut yang mempengaruhi nilai kelas lainnya. Data yang digunakan diperoleh berupa dataset berisi kriteria jamur dari UCI Machine Learning Repository yang telah dilabelkan kedalam edible dan poisonous dengan total data sebanyak 8124 data. Dataset yang digunakan akan dibagi menjadi dua masing-masing untuk data train dan data test dengan porsi 80% banding 20% dan 90% banding 10%. Klasifikasi dilakukan sebanyak empat kali dengan pembagian dua kali menggunakan categorical naïve bayes dan dua kali menggunakan multinomial naïve bayes untuk setiap porsi dataset sehingga dihasilkan 4(empat) model klasifikasi. Berdasarkan hasil evaluasi dan confusion matrix dapat dilihat bahwa model dengan naïve bayes *categorical* adalah yang terbaik dengan jarak performa yang cukup besar dimana model Categorical1 dan Categorical2 mendapatkan akurasi 100% dengan 1 kesalahan prediksi kelas 0 pada model Categorical 2. Sementara itu, pada model Multinomial1 dan Multinomial2 diperoleh nilai akurasi sebesar 84% dan 85%.

Kata kunci: klasifikasi, naïve bayes, categorical dan multinomial

Mushroom classification using naïve bayes algorithm

Abstract

Mushrooms are plants from the fungi kingdom with fleshy bodies and can be eaten, although there are several species of mushrooms that are not edible and have their own characteristics. The number of people who consume mushrooms without knowing whether the mushrooms they eat are safe to eat or poisonous, resulting in many incidents of mushroom poisoning and even death. One type of education that can be done is to create a tool in the form of software to classify types of mushrooms as edible or poisonous. One type of classification using an artificial intelligence algorithm is the Naïve Bayes algorithm which assumes that each attribute value that affects the class value is independent of the attribute value that affects the other class values. The data used is obtained in the form of a dataset containing mushroom criteria from the UCI Machine Learning Repository which has been labeled as edible and poisonous with a total data of 8124 data. The dataset used will be divided into two, respectively, for train data and test data with a portion of 80% vs 20% and 90% vs 10%. Classification was carried out four times by dividing twice using categorical naïve Bayes and twice using multinomial naïve Bayes for each portion of the dataset so that 4 (four) classification models were produced. Based on the results of the evaluation and confusion matrix, it can be seen that the model with naïve Bayes categorical is the best with a large enough performance distance where the Categorical1 and

Categorical2 models get 100% accuracy with 1 class 0 prediction error in the Categorical 2 model. Meanwhile, in the Multinomial1 and Multinomial2 obtained accuracy values of 84% and 85%..

Keywords: *classification, nave Bayes, categorical and multinomial*

1. PENDAHULUAN

Jamur adalah tanaman dari kingdom fungi dengan tubuh berdaging dan dapat dapat dimakan, meski demikian terdapat beberapa spesies jamur yang tidak dapat dimakan dan memiliki ciri khas tersendiri [1]–[3]. Jamur banyak dikonsumsi selain karena kandungan nutrisi serta nilai obatnya juga karena kandungan vitamin dan cita rasanya yang khas [4], [5]. Namun demikian, umumnya orang tidak tahu bahwa ada perbedaan besar antara jamur yang bisa dimakan dan yang beracun sehingga banyak orang mengalami keracunan bahkan meninggal karena konsumsi jamur [2], [6]. Banyaknya orang yang mengonsumsi jamur tanpa tahu apakah jamur yang dikonsumsi aman untuk dimakan atau beracun mengakibatkan banyak insiden keracunan jamur bahkan hingga meninggal. Dalam meta-analisis 2005 dari 28.018 kasus keracunan jamur di seluruh dunia selama periode 1951 hingga 2002, ditemukan peningkatan yang signifikan dalam frekuensi keracunan jamur yang dilaporkan dari waktu ke waktu. Analisis retrospektif dari 93 kasus keracunan jamur di Portugal selama periode pelaporan tahun 1990 hingga 2008 mengaitkan 63,4% kasus dengan jamur yang mengandung amatoxin, dengan 11,8% di antaranya mengakibatkan kematian [7]. Pada tahun 2015, penyelidik Tiongkok melaporkan 7 kasus rhabdomyolysis tertunda dengan 1 kematian dalam sebuah keluarga (rentang usia 18-58 tahun) yang telah mengonsumsi 1 kali jamur *Russula subnigricans* yang dimasak dan dipanen dari hutan Provinsi Guizhou di Cina selatan. Dua puluh jam kemudian, semua 7 anggota keluarga dirawat di rumah sakit karena mual, muntah, diare, pusing, kelelahan, dan kelemahan otot. Lima pasien datang dengan mialgia di kaki bagian atas [8]. Banyaknya kasus keracunan jamur sehingga dibutuhkan edukasi dan pengelompokan jenis jamur yang dapat dimakan dan beracun sehingga diharapkan dapat meningkatkan pengetahuan masyarakat mengenai jamur. Salah satu jenis edukasi adalah dengan membuat sebuah alat dalam bentuk perangkat lunak untuk mengklasifikasikan jenis jamur menjadi bisa dimakan atau beracun.

Machine Learning merupakan cabang ilmu dari *Artificial Intelligence* [9] yang telah membuat kemajuan signifikan pada bidang teknologi di berbagai industri [10]. *Machine Learning* belajar dan dilatih melalui sekumpulan data historis dalam jumlah besar untuk mendapatkan pola dan korelasi pada data bertujuan untuk mengurangi intervensi manusia, menghemat waktu, dan memaksimalkan sumber daya komputasi sekaligus meningkatkan keselamatan [9]–[11].

Model *Machine Learning* bisa bersifat prediktif atau deskriptif bergantung pada penelitian, dimana model prediktif bertujuan untuk memberikan prediksi berdasarkan data dan model deskriptif bertujuan untuk mendapatkan informasi dari data dan menjelaskan apa yang telah terjadi. Untuk tahap pengujian, sebagian dari data yang belum digunakan pada tahap pelatihan digunakan untuk evaluasi kinerja [9]. Model *Machine Learning* sangat dipengaruhi oleh features [9], [12]. Model *Machine Learning* terbagi menjadi tiga bagian, model yang diawasi atau *supervised*, tidak diawasi atau *unsupervised*, dan gabungan atau *semi-supervised* [11], [12].

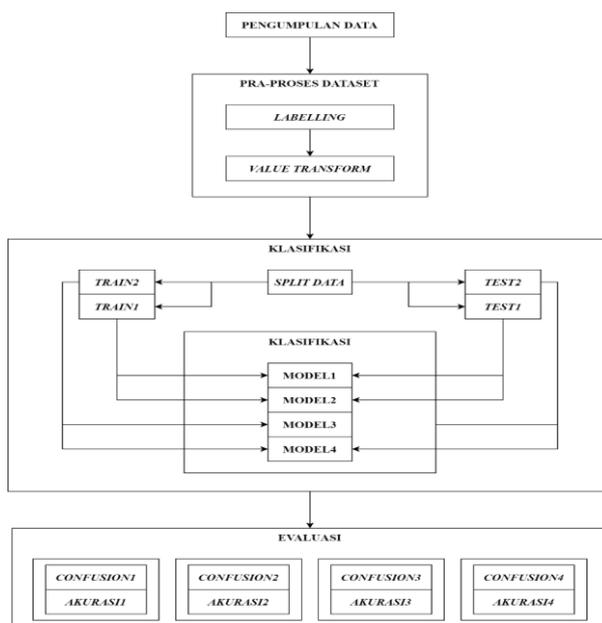
Salah satu jenis klasifikasi menggunakan algoritma kecerdasan buatan adalah algoritma Naïve Bayes. Naïve bayes adalah algoritma klasifikasi yang populer pada penerapan machine learning [13] merupakan jaringan bayesian sederhana yang mengasumsikan setiap nilai atribut yang mempengaruhi nilai kelas bersifat independen dari nilai atribut yang mempengaruhi nilai kelas lainnya [14]. Naïve bayes adalah algoritma yang dikembangkan berdasarkan teorema bayes yang mengasumsikan setiap atribut sebagai independen sendiri dan berbeda dengan atribut lainnya [3], [15], [16].

Penelitian menggunakan naïve bayes sebelumnya telah dilakukan untuk klasifikasi gambar promosi dengan pengenalan karakter optik, hasil penelitian mereka menunjukkan performa naïve bayes yang lebih unggul dengan akurasi 94,31% dibandingkan 2 algoritma pembandingnya yaitu random forest sebesar 86,79% dan K-nearest neighbor sebesar 90,56% [17]. Penelitian lainnya menggunakan algoritma naïve bayes pada klasifikasi teks mendapatkan nilai akurasi sebesar 80,5%, presisi sebesar 80,7% dan *recall* sebesar 80,3% dengan catatan waktu selama 0,42s [18].

Oleh karena itu penelitian ini akan menggunakan algoritma naïve bayes untuk klasifikasi jamur dengan perbandingan hasil berdasarkan penelitian yang dilakukan oleh (Wibowo et al., 2018). Evaluasi pada penelitian ini menggunakan confusion matrix untuk mendapatkan nilai akurasi, sedangkan pelatihan menggunakan teknik split validation.

2. METODE PENELITIAN

Adapun alur penelitian yang direncanakan dalam penelitian ini seperti pada ilustrasi berikut:



Gambar 1. Alur Penelitian

Pengumpulan data adalah tahap awal dalam penelitian ini, data yang digunakan diperoleh berupa dataset berisi kriteria jamur dari UCI *Machine Learning Repository* yang telah dilabelkan kedalam edible dan poisonous dengan total data sebanyak 8124 data. Berikut merupakan gambar contoh dataset yang digunakan:

```
p, x, s, n, t, p, f, c, n, k, e, e, s, s, w, w, p, w, o, p, k, s, u
e, x, s, y, t, a, f, c, b, k, e, c, s, s, w, w, p, w, o, p, n, n, g
e, b, s, w, t, l, f, c, b, n, e, c, s, s, w, w, p, w, o, p, n, n, m
p, x, y, w, t, p, f, c, n, n, e, e, s, s, w, w, p, w, o, p, k, s, u
e, x, s, g, f, n, f, w, b, k, t, e, s, s, w, w, p, w, o, e, n, a, g
e, x, y, y, t, a, f, c, b, n, e, c, s, s, w, w, p, w, o, p, k, n, g
e, b, s, w, t, a, f, c, b, g, e, c, s, s, w, w, p, w, o, p, k, n, m
e, b, y, w, t, l, f, c, b, n, e, c, s, s, w, w, p, w, o, p, n, s, m
p, x, y, w, t, p, f, c, n, p, e, e, s, s, w, w, p, w, o, p, k, v, g
e, b, s, y, t, a, f, c, b, g, e, c, s, s, w, w, p, w, o, p, k, s, m
```

Gambar 2 Alur Contoh Dataset

Pra-proses dataset adalah tahap untuk mengolah data yang akan digunakan untuk tahap produksi. Pra-proses terbagi menjadi dua yaitu labelling dan value transform. *Labelling* bertujuan untuk memberikan label atau nama atribut ke dataset, dimana data yang didapat masih belum memiliki label. Label dataset diambil dari keterangan dataset yang disediakan oleh penyedia dataset. *Value Transform* bertujuan merubah nilai dari data atau atribut pada dataset dari huruf menjadi angka. Hal ini diperlukan karena nilai atribut atau data yang digunakan oleh naïve bayes berupa integer atau float.

Klasifikasi merupakan proses pengolahan dataset dengan naïve bayes, dataset yang digunakan akan dibagi menjadi dua masing-masing untuk data train dan data test dengan porsi 80 banding 20 dan 90 banding 10. Klasifikasi dilakukan sebanyak empat kali dengan pembagian dua kali menggunakan categorical naïve bayes dan dua kali menggunakan multinomial naïve bayes untuk setiap porsi dataset sehingga akan menghasilkan empat model klasifikasi. Empat model klasifikasi yang dihasilkan akan dievaluasi yang kemudian akan dibandingkan untuk mendapatkan hasil terbaik. Klasifikasi berfungsi sebagai validasi untuk menilai model Klasifikasi Jamur dengan naïve bayes yang dirancang pada penelitian ini, penilaian kerja dari model ditentukan berdasarkan nilai akurasi. Nilai akurasi dihitung berdasarkan nilai *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN). Ada beberapa nilai yang biasa digunakan untuk mengukur performa dari model *Machine Learning* dengan *output* dua kelas, diantaranya akurasi, f1-score, presisi, sensitifitas (*recall*). Nilai akurasi untuk menghitung kedekatan

hasil prediksi model dengan nilai sebenarnya, *f1-score* merepresentasikan nilai kombinasi dari presisi dan *recall*, presisi untuk mengukur ketepatan model mengklasifikasikan data dan seberapa dekat perbedaan nilai saat dilakukan pengulangan, *recall* untuk mengukur seberapa besar dokumen terklasifikasikan kepada kelas yang diobservasi. Nilai dari akurasi, *f1-score*, presisi, dan *recall* bisa dihitung dengan persamaan berikut:

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

$$F1 - score = \frac{Precision*Recall}{Precision+Recall} \quad (4)$$

3. HASIL DAN PEMBAHASAN

Data yang didapat masih berupa data abstrak sehingga diperlukan pra-proses agar data mudah dimengerti dan dibaca. Pra-proses dilakukan berdasarkan panduan dataset yang didapatkan dari penyedia yang sama dengan file terpisah. Tahapan pra-proses yang dilakukan terdiri dari *Labelling* dan *Value Transform*.

3.1. Labelling

Labelling adalah tahapan memberikan label, nama atribut, atau nama fitur ke dataset berdasarkan panduan yang didapatkan. Tabel di bawah menunjukkan nama atribut beserta nilai dan keterangan nilainya dalam bahasa inggris. Adapun kategori jamur dibedakan menjadi 2 yaitu e untuk edible dan p untuk poisonous. Nama atribut seperti tabel di atas dimasukkan kedalam dataset sehingga dapat diketahuinama dari masing-masing atribut pada tabel dataset. Dataset yang telah diberi nama atribut seperti pada gambar di bawah:

category	cap- shape	cap- surface	cap- color	bruise	odor	gill- attachment	gill- spacing	gill- size	gill- color	...	stalk- surface- below- ring	stalk- color- above- ring	stalk- color- below- ring	veil- type	veil- color	ring- number	ring- type	spore- print- color	population	habitat
p	x	s	n	t	p	f	c	n	k	...	s	w	w	p	w	o	p	k	s	u
e	x	s	y	t	a	f	c	b	k	...	s	w	w	p	w	o	p	n	n	g
e	b	s	w	t	l	f	c	b	n	...	s	w	w	p	w	o	p	n	n	m
p	x	y	w	t	p	f	c	n	n	...	s	w	w	p	w	o	p	k	s	u
e	x	s	g	f	n	f	w	b	k	...	s	w	w	p	w	o	e	n	a	g
...
e	k	s	n	f	n	a	c	b	y	...	s	o	o	p	o	o	p	b	c	l
e	x	s	n	f	n	a	c	b	y	...	s	o	o	p	n	o	p	b	v	l
e	f	s	n	f	n	a	c	b	n	...	s	o	o	p	o	o	p	b	c	l
p	k	y	n	f	y	f	c	n	b	...	k	w	w	p	w	o	e	w	v	l
e	x	s	n	f	n	a	c	b	y	...	s	o	o	p	o	o	p	o	c	l

Gambar 3 Contoh Dataset yang Telah diberi Nama Atribut

3.2. Value Transform

Value transform adalah merubah nilai dari dataset yang berupa *alphabet* menjadi bentuk angka karena naïve bayes hanya menerima data dalam bentuk angka. Aturan transformasi nilai dataset yaitu a = 1, b =2, c = 3, dan seterusnya terkecuali nilai pada kategori yang akan menjadi e = 0 dan p = 1. Adapun nilai missing akan dirubah menjadi 0. Hasil dari penerapan *value transform* seperti yang ditunjukkan pada gambar di bawah:

category	cap- shape	cap- surface	cap- color	bruise	odor	gill- attachment	gill- spacing	gill- size	gill- color	...	stalk- surface- below- ring	stalk- color- above- ring	stalk- color- below- ring	veil- type	veil- color	ring- number	ring- type	spore- print- color	population	habitat
1	24	19	14	20	16	6	3	14	11	...	19	23	23	16	23	15	16	11	19	21
0	24	19	25	20	1	6	3	2	11	...	19	23	23	16	23	15	16	14	14	7
0	2	19	23	20	12	6	3	2	14	...	19	23	23	16	23	15	16	14	14	13
1	24	25	23	20	16	6	3	14	14	...	19	23	23	16	23	15	16	11	19	21
0	24	19	7	6	14	6	23	2	11	...	19	23	23	16	23	15	5	14	1	7
...
0	11	19	14	6	14	1	3	2	25	...	19	15	15	16	15	15	16	2	3	12
0	24	19	14	6	14	1	3	2	25	...	19	15	15	16	14	15	16	2	22	12
0	6	19	14	6	14	1	3	2	14	...	19	15	15	16	15	15	16	2	3	12
1	11	25	14	6	25	6	3	14	2	...	11	23	23	16	23	15	5	23	22	12
0	24	19	14	6	14	1	3	2	25	...	19	15	15	16	15	15	16	15	3	12

Gambar 4 Contoh Hasil Value Transform pada Dataset

3.3. Klasifikasi

Sebelum masuk ke klasifikasi, dataset dipisah terlebih dahulu menjadi fitur dengan nama indikator dan target atau kategori. Kemudian dataset dibagi menggunakan teknik *split validation* menjadi data training yang akan digunakan untuk melatih model atau sebagai referensi model dan data *testing* untuk menguji performa model yang dibuat. Dataset dibagi menjadi 2 porsi yaitu train1 dan test1 dengan porsi 90% dan 10%, train2 dan test2 dengan porsi 80% dan 20%. Setelah dataset dibagi menjadi data train dan data test kemudian dilanjutkan dengan membuat model klasifikasi menggunakan *naïve bayes categorical* dan *naïve bayes multinomial* dari Library Sklearn. Setelah data train dimasukkan ke model *naïve bayes* kemudian model diberikan data test untuk diprediksi, hasil prediksi nantinya akan digunakan pada tahap evaluasi untuk menilai performa model yang telah dibuat.

Hasil model klasifikasi menjadi 4 model dengan cat1 untuk *categorical* dengan data train1 dan test1, cat2 untuk *categorical* dengan data train2 dan test2, mul1 untuk *multinomial* dengan data train1 dan test1, dan mul2 untuk *multinomial* dengan data train2 dan test2.

3.4 Evaluasi

Evaluasi merupakan tahap akhir untuk mengukur performa model klasifikasi yang telah dibuat dengan membandingkan hasil prediksi ke nilai aktual. Nilai yang digunakan untuk mengukur performa model pada penelitian ini adalah nilai akurasi. Untuk mengetahui jumlah perbedaan prediksi salah dan prediksi benar digunakan *confusion matrix*. Tabel dibawah ini memaparkan hasil *confusion matrix* dari 4 model klasifikasi yang dibangun:

Tabel 1. Confusion Metric Model Klasifikasi

No.	Nama Model Klasifikasi	Hasil Confussion Metric	Keterangan	Nilai Akurasi								
1.	Categorical 1 (cat1)	<table border="1"> <tr><td colspan="2">PREDIKSI</td></tr> <tr><td>0</td><td>1</td></tr> <tr><td>AKTUAL 0</td><td>399 0</td></tr> <tr><td>1</td><td>0 414</td></tr> </table>	PREDIKSI		0	1	AKTUAL 0	399 0	1	0 414	tidak ada kesalahan prediksi dari total 399 kelas 0 dan 414 kelas 1.	100%
PREDIKSI												
0	1											
AKTUAL 0	399 0											
1	0 414											
2.	Categorical 2 (cat2)	<table border="1"> <tr><td colspan="2">PREDIKSI</td></tr> <tr><td>0</td><td>1</td></tr> <tr><td>AKTUAL 0</td><td>837 1</td></tr> <tr><td>1</td><td>0 787</td></tr> </table>	PREDIKSI		0	1	AKTUAL 0	837 1	1	0 787	1 kesalahan prediksi pada kelas 0 dari total 838 kelas 0 dan nihil salah prediksi pada kelas 1 dari total 787 kelas 1.	100%
PREDIKSI												
0	1											
AKTUAL 0	837 1											
1	0 787											
3.	Multinomial 1 (mul1)	<table border="1"> <tr><td colspan="2">PREDIKSI</td></tr> <tr><td>0</td><td>1</td></tr> <tr><td>AKTUAL 0</td><td>368 31</td></tr> <tr><td>1</td><td>101 313</td></tr> </table>	PREDIKSI		0	1	AKTUAL 0	368 31	1	101 313	31 kesalahan prediksi kelan 0 dari total 399 kelas 0 dan 101 kesalahan prediksi pada kelas 1 dari total 414 kelas 1	84%
PREDIKSI												
0	1											
AKTUAL 0	368 31											
1	101 313											

4. Multinomial 2 (mul2)	PREDIKSI			51 kesalahan prediksi pada kelas 0 dari total 838 kelas 0 dan 189 kesalahan prediksi dari total 787 kelas 1.	85%
		0	1		
	AKTUAL	0	787		
		1	189	598	

Berdasarkan hasil evaluasi dan confusion matrix dari 4 model yang ada dapat dilihat bahwa model dengan naïve bayes *categorical* adalah yang terbaik dengan jarak performa yang cukup besar dimana model cat1 dan cat2 mendapatkan akurasi 100% sedangkan model mul1 dan mul2 hanya sebesar 84% dan 85%. Berdasarkan hasil yang didapat maka pada penelitian ini model cat1 menjadi yang terbaik, sementara keempat model dapat digunakan sebagai klasifikasi jamur seperti pada tujuan penelitian ini.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan dan hasil yang didapat maka dapat diambil kesimpulan bahwa algoritma naïve bayes telah berhasil digunakan untuk mengklasifikasikan jamur dengan menggunakan model *categorical* dan *multinomial* dengan menggunakan metode *split validation*. Berdasarkan hasil evaluasi dan *confusion matrix* dari 4 model yang ada dapat dilihat bahwa model dengan naïve bayes *categorical* adalah yang terbaik dengan jarak performa yang cukup besar dimana model *Categorical1* dan *Categorical2* mendapatkan akurasi 100% dengan 1 kesalahan prediksi kelas 0 pada model *Categorical 2*.

Adapun saran untuk penelitian berikutnya adalah menggunakan algoritma yang berbeda, dataset yang berbeda, atau teknik yang berbeda untuk klasifikasi jamur, terutama disarankan untuk menggunakan dataset berupa gambar untuk pengenalan atau klasifikasi jenis jamur.

DAFTAR PUSTAKA

- [1] N. Chitayae and A. Sunyoto, "Performance Comparison of Mushroom Types Classification Using K-Nearest Neighbor Method and Decision Tree Method," in *2020 3rd International Conference on Information and Communications Technology (ICOIACT)*, 2020, pp. 308–313.
- [2] S. Ismail, A. R. Zainal, and A. Mustapha, "Behavioural features for mushroom classification," in *2018 IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, 2018, pp. 412–415.
- [3] A. Wibowo, Y. Rahayu, A. Riyanto, and T. Hidayatulloh, "Classification algorithm for edible mushroom identification," in *2018 International Conference on Information and Communications Technology (ICOIACT)*, 2018, pp. 250–253.
- [4] R. W. Mwangi, J. M. Macharia, I. N. Wagara, and R. L. Bence, "The antioxidant potential of different edible and medicinal mushrooms," *Biomed. Pharmacother.*, vol. 147, p. 112621, 2022.
- [5] P. Nowakowski, R. Markiewicz-Żukowska, J. Bielecka, K. Mielcarek, M. Grabia, and K. Socha, "Treasures from the forest: Evaluation of mushroom extracts as anti-cancer agents," *Biomed. Pharmacother.*, vol. 143, p. 112106, 2021.
- [6] N. Zahan, M. Z. Hasan, M. A. Malek, and S. S. Reya, "A Deep Learning-Based Approach for Edible, Inedible and Poisonous Mushroom Classification," in *2021 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD)*, 2021, pp. 440–444.
- [7] J. H. Diaz, "Amatoxin-containing mushroom poisonings: species, toxidromes, treatments, and outcomes," *Wilderness Environ. Med.*, vol. 29, no. 1, pp. 111–118, 2018.
- [8] J. H. Diaz, "Nephrotoxic Mushroom Poisoning: Global Epidemiology, Clinical Manifestations, and Management," *Wilderness Environ. Med.*, vol. 32, no. 4, pp. 537–544, 2021.
- [9] A. Oikonomidis, C. Catal, and A. Kassahun, "Deep learning for crop yield prediction: a systematic literature review," *New Zeal. J. Crop Hortic. Sci.*, pp. 1–26, 2022.
- [10] Y. Xu, Y. Zhou, P. Sekula, and L. Ding, "Machine learning in construction: From shallow to deep learning," *Dev. Built Environ.*, vol. 6, p. 100045, 2021.
- [11] M. Bibi *et al.*, "Class association and attribute relevancy based imputation algorithm to reduce twitter data for optimal sentiment analysis," *IEEE Access*, vol. 7, pp. 136535–136544, 2019.
- [12] A. Rasool, R. Tao, M. Kamyab, and S. Hayat, "GAWA—A feature selection method for hybrid sentiment classification," *IEEE Access*, vol. 8, pp. 191850–191861, 2020.
- [13] W. M. Shaban, A. H. Rabie, A. I. Saleh, and M. A. Abo-Elsoud, "Accurate detection of COVID-19 patients based on distance biased Naïve Bayes (DBNB) classification strategy," *Pattern Recognit.*, vol. 119, p. 108110, 2021.
- [14] K. Orphanou, A. Dagliati, L. Sacchi, A. Stassopoulou, E. Keravnou, and R. Bellazzi, "Incorporating repeating temporal association rules in naïve bayes classifiers for coronary heart disease diagnosis," *J. Biomed. Inform.*, vol. 81, pp. 74–82, 2018.
- [15] W. A. van Eeden *et al.*, "Predicting the 9-year course of mood and anxiety disorders with automated machine learning: A comparison between auto-sklearn, naïve Bayes classifier, and traditional logistic regression," *Psychiatry Res.*, vol. 299, p. 113823, 2021.
- [16] J. O. Onah, M. Abdullahi, I. H. Hassan, and A. Al-Ghusham, "Genetic Algorithm based feature selection and Naïve Bayes for anomaly detection in fog computing environment," *Mach. Learn. with Appl.*, vol. 6, p. 100156, 2021.
- [17] P. Phoenix, R. Sudaryono, and D. Suhartono, "Classifying promotion images using optical character recognition and Naïve Bayes classifier," *Procedia Comput. Sci.*, vol. 179, pp. 498–506, 2021.
- [18] F. A. Wenando, R. Hayami, and A. J. Anggrawan, "ANALISIS SENTIMEN PADA PEMERINTAHAN TERPILIH PADA PILPRES 2019 DITWITTER MENGGUNAKAN ALGORITME NAÏVEBAYES," *JURTEKSI (Jurnal Teknol. dan Sist. Informasi)*, vol. 7, no. 1, pp. 101–106, 2020.