

Klasifikasi Garam dengan naive bayes dan backpropagation neural network

Desi Puji Lestari

*a Matematika, Universitas Negeri Semarang, Pati, 59153, Indonesia
desipujilestari@students.unnes.ac.id

*Correspondent Author

Received: 3 agustus 2021

Revised: 21 Januari 2022

Accepted: 10 Februari 2022

KATAKUNCI

Naive Bayes Backpropagation
Neural Network
Accuracy
MSE

KEYWORDS

Naive Bayes Backpropagation
Neural Network
Accuracy
MSE

ABSTRAK

Tujuan penelitian ini adalah untuk memperoleh hasil klasifikasi dan peramalan produksi dua tahun yang akan datang dari daerah penghasil garam tertinggi di Indonesia dengan menggunakan Naive Bayes dan Backpropagation Neural Network. Data yang digunakan dalam penelitian ini adalah data jumlah produksi garam di Indonesia pada tahun 2011 sampai dengan tahun 2019 dengan jumlah data 685 dari 38 daerah kota/kabupaten penghasil garam di Indonesia. Data tersebut akan dikelompokkan menjadi data latih dan data uji dengan perbandingan data 65% untuk data latih dan 35% untuk data uji. Hasil yang didapat dari proses klasifikasi Naive Bayes dan peramalan Backpropagation terdapat 10 kota/kabupaten penghasil garam tertinggi di Indonesia yakni Kabupaten Rembang 2020 sebesar 146750 ton, Kabupaten Pati 2020 sebesar 306500 ton, Kabupaten Demak 2020 sebesar 128455 ton, Kabupaten Cirebon 2020 sebesar 251144 ton, Kabupaten Indramayu 2020 sebesar 241074 ton, Kabupaten Sampang 2020 sebesar 363450 ton, Kabupaten Pamekasan 2020 sebesar 130925 ton, Kabupaten Sumenep 2020 sebesar 391785 ton, dan Kota Surabaya 2020 sebesar 128549 ton, Kabupaten Bima 2020 sebesar 127173 ton. Dengan menggunakan Naive Bayes didapatkan nilai accuracy sebesar 96,92% untuk peramalan Backpropagation sebesar 80,52% dengan MSE sebesar $8.6975e+09$.

Salt Classification with naive bayes and backpropagation neural network

The purpose of this study was to obtain the results of the classification and forecasting of production in the next two years from the highest salt producing areas in Indonesia using Naive Bayes and Backpropagation Neural Networks. The data used in this study is data on the amount of salt production in Indonesia from 2011 to 2019 with a total of 685 data from 38 salt-producing cities/districts in Indonesia. The data will be grouped into training data and test data with a comparison of 65% data for training data and 35% for test data. The results obtained from the Naive Bayes classification process and Backpropagation forecasting are the 10 highest salt-producing cities/districts in Indonesia, namely Rembang Regency 2020 at 146750 tons, Pati Regency 2020 at 306500 tons, Demak Regency 2020 at 128455 tons, Cirebon Regency 2020 at 251144 tons, Indramayu Regency 2020 is 241074 tons, Sampang Regency 2020 is 363450 tons, Pamekasan Regency 2020 is 130925 tons, Sumenep Regency 2020 is 391785 tons, and Surabaya City 2020 is 128549 tons, Bima Regency

2020 is 127173 tons. By using Naive Bayes, the accuracy value is 96.92% for Backpropagation forecasting of 80.52% with MSE of $8.6975e+09$.

This is an open-access article under the [CC-BY-SA](#) license.



Pendahuluan

Bertambahnya penduduk di Indonesia mempengaruhi peningkatan konsumsi garam dari tahun ke

Proses pengklasifikasian ini bertujuan untuk mengetahui potensi masing-masing daerah penghasil garam terbanyak dan daerah paling sedikit menghasilkan garam yang ditentukan berdasarkan klas produksi garam rendah dan tinggi. Sehingga untuk daerah penghasil garam terbanyak dapat dimaksimalkan hasil produksinya, sehingga dapat membantu Indonesia mengurangi nilai import garam per tahunnya. Sedangkan untuk daerah yang paling sedikit memproduksi garam di Indonesia dapat diperbaiki dan ditingkatkan produksi garamnya dengan memperhatikan faktor-faktor yang mempengaruhi rendahnya tingkat produksi garam di daerah tersebut. Setelah dilakukan proses klasifikasi data, akan didapatkan hasil berupa daerah-daerah produksi garam dengan tingkat rendah dan tinggi, dari hasil produksi daerah garam tertinggi tersebut nantinya akan dilakukan proses peramalan produksi garam untuk daerah-daerah penghasil garam tertinggi. Dengan adanya prediksi hasil tersebut diharapkan produksi garam di Indonesia pada daerah-daerah penghasil tertinggi dapat dimaksimalkan produksinya baik untuk garam PUGAR maupun Non PUGAR.

K-Means Clustering merupakan algoritma tanpa pengawasan dan algoritma pengelompokan yang efektif dan fleksibel terhadap algoritma lainnya. K-Means Clustering juga merupakan salah satu metode pengelompokan data non hierarki yang mempartisi data kedalam dua atau lebih kelompok [3]. Untuk data yang memiliki karakteristik yang sama dimasukkan kedalam satu kelompok yang sama, sedangkan data yang memiliki karakteristik berbeda akan dikelompokkan kedalam kelompok lain. Dalam penelitian ini Metode K-Means Clustering digunakan untuk pembagian data training dan data testing, karena dengan menggunakan metode tersebut penyebaran data cluster dapat seimbang [4]. Setelah didapatkan pengelompokan daerah-daerah produksi garam rendah dan tinggi selanjutnya dilakukan klasifikasi data dengan menggunakan algoritma Naive Bayes Classifier [5].

Setelah didapatkan dataset tersebut akan diolah lebih lanjut dengan menggunakan data mining klasifikasi yakni dengan menggunakan algoritma Naive Bayes Classifier [6]–[8]. Naive Bayes merupakan metode pengklasifikasian probabilistik sederhana. Metode ini akan

menghitung sekumpulan probabilitas dengan menjumlahkan frekuensi dan kombinasi nilai dari dataset yang diberikan. Metode naive bayes menganggap semua atribut pada setiap kategori tidak memiliki ketergantungan satu sama lain (independen) [9]. Algoritma Naive Bayes lebih unggul dibanding algoritma lain yang lebih kompleks. Algoritma ini menggunakan keseluruhan atribut pada dataset untuk dibandingkan satu dengan yang lainnya tanpa terdapat ketergantungan antar atributnya sehingga algoritma Naive Bayes dapat memperoleh hasil klasifikasi yang akurat [10][11]-[13].

Dari data KKP nilai import garam di Indonesia relatif tinggi dan bahkan Indonesia belum mampu memenuhi jumlah konsumsi garamnya sendiri, padahal wilayah produksi garam di Indonesia relatif luas dan sangat berpotensi memproduksi garam dalam jumlah yang tinggi, dengan adanya klasifikasi menggunakan algoritma naive bayes classifier untuk daerah-daerah penghasil garam dengan jumlah yang tinggi dapat dilakukan prediksi dengan menggunakan backpropagation neural network untuk mendapatkan hasil peramalan produksi garam daerah-daerah penghasil garam di Indonesia dengan hasil klasifikasi dan peramalan produksi garam di Indonesia, diharapkan dari hasil tersebut jumlah produksi garam di Indonesia dapat dimaksimalkan dan mengurangi nilai import garam nasional.

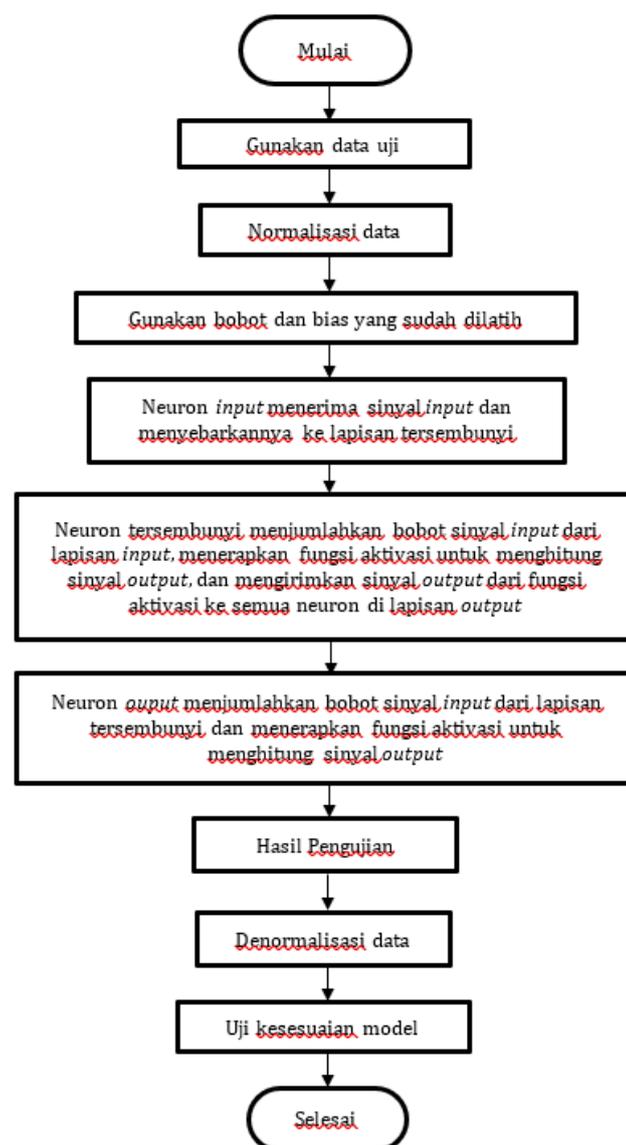
Metode

Tahap ini dimaksudkan untuk memperjelas permasalahan sehingga mempermudah pembahasan selanjutnya. Masalah yang diangkat dalam penulisan skripsi ini adalah bagaimana mengimplementasikan jaringan syaraf tiruan dan data mining klasifikasi dengan menggunakan algoritma naive bayes classifier untuk klasifikasi daerah-daerah penghasil garam di Indonesia dengan tingkat produksi rendah dan tinggi. Serta peramalan dengan menggunakan backpropagation neural network dari hasil klasifikasi daerah-daerah produksi garam tinggi akan dilakukan peramalan tingkat produksi garam pada daerah-daerah penghasil gram dengan menggunakan program Matlab, sehingga dengan adanya klasifikasi dan peramalan tersebut daerah-daerah dengan tingkat produksi garam tinggi dapat dimaksimalkan hasil produksinya sehingga dapat mengurangi tingkat import garam nasional.

Pengumpulan data yang didapatkan melalui situs data.go.id dan KKP (Kementerian Kelautan dan Perikanan) ini selanjutnya akan dimasukkan ke dalam tabel dengan bantuan MS.Excel data ini dipisahkan dalam beberapa kolom yakni nama kabupaten/kota, param garam yang meliputi garam PUGAR dan non PUGAR, produksi garam dari tahun 2011-2019 serta produktivitas garam pada masing-masing kabupaten/kota.

Processing Data

Preprocessing data merupakan suatu proses pengelompokan data dengan algoritma k-means clustering, hasil pembagian data ini berupa data yang dikelompokkan ke dalam 3 cluster yakni produksi garam tinggi dan rendah. Selanjutnya hasil pengelompokan produksi garam yang dihasilkan dari proses algoritma k-means akan dilakukan klasifikasi dengan menggunakan algoritma naive bayes proses klasifikasi data menggunakan rapidminer 5.3 dan rapidminer studio.



Gambar 1. Flowchart Pelangujin Jaringan Backpropagation Neural Network

Setelah dilakukan proses klasifikasi data maka akan didapatkan data dengan 2 cluster/kelompok yakni rendah dan tinggi hasil klasifikasi tersebut akan dijadikan bahan untuk melakukan peramalan dengan menggunakan jaringan syaraf tiruan backpropagation neural network dengan menggunakan aplikasi matlab [11].

Langkah ini merupakan langkah terakhir dari penelitian. Penarikan kesimpulan didasarkan pada studi pustaka dan pembahasan permasalahan. Simpulan yang diperoleh merupakan hasil analisis dari penelitian. Simpulan yang diambil dari penelitian ini adalah bagaimanakah implementasi algoritma naive bayes untuk klasifikasi daerah-daerah produksi garam di Indonesia. Sejauh mana tingkat akurasi yang dihasilkan dari olah data algoritma naive bayes dan setelah dilakukan klasifikasi daerah-daerah produksi garam dilakukan peramalan daerah-daerah penghasil garam tertinggi di Indonesia, bagaimana tingkat akurasinya dan berapa jumlah produksi garam yang dihasilkan dari daerah-daerah tersebut sehingga diharapkan mampu mengurangi nilai import garam di Indonesia.

Hasil dan Pembahasan

1. Pengambilan Data

Pada penelitian ini digunakan data produksi garam dari tahun 2011 sampai dengan tahun 2019 yang memiliki 6 atribut serta 684 record dengan 1 kelas atribut data ini diperoleh dari website resmi KKP dan data.go.id. Untuk mengetahui hasil akurasi dari algoritma Naive Bayes dalam menentukan klasifikasi produksi garam tertinggi di Indonesia digunakan aplikasi Rapidminer studio, Rapidminer 5.3 dan matlab. Untuk membuat klasifikasi tersebut diperlukan data-data terkait produksi garam di Indonesia, data-data tersebut digunakan untuk melakukan pengujian pada sistem rapidminer 5.3. sebagai output nya merupakan hasil klasifikasi dan akurasi dari produksi garam tertinggi di Indonesia.

Table.1 AKURASI DATA

	<i>True Tinggi</i>	<i>True Rendah</i>	<i>Class Precision</i>
Pred. Tinggi	89	9	90,4%
Pred. Rendah	0	586	100%
Class recall	100%	98,4%	

Pada Tabel 1 terlihat bahwa hasil prediksi klasifikasi produksi garam tertinggi berjumlah 89 record sedangkan klasifikasi produksi garam rendah adalah 595 record data. Pada baris recall/perkiraan data yang diidentifikasi benar pada kelas tertinggi bernilai 100% sedangkan recall pada kelas terendah bernilai 98,4%. Pada kolom precision/perhitungan prediksi tinggi bernilai 90,4% dan pada prediksi rendah bernilai 100%

2. Backpropagation Neural Network

Prosedur awal peramalan produksi garam dengan menggunakan backpropagation neural network adalah penentuan input dan target. Penentuan input backpropagation ini didapatkan

datanya dari proses Naive Bayes yang dibahas sebelumnya sedangkan target produksi garam didapatkan dengan bantuan ms.excel dengan menggunakan formula tren =TREND(E2:E10;C2:C10;H2:H10;TRUE) dengan memperhatikan jumlah produksi pada tahun-tahun sebelumnya.

Pembagian data dilakukan dengan membagi data menjadi dua, yaitu pertama untuk data latih (training) yang digunakan pada tahap pelatihan jaringan dan yang kedua untuk data uji (testing) yang digunakan pada tahap pengujian. Penetapan pembagian data dilakukan dengan trial and error pada masing-masing komposisi pembagian data. Penentuan parameter untuk pembagian data dapat dilihat pada Tabel 2., sedangkan untuk hasil komposisi pembagian data terbaik diperoleh berdasarkan pelatihan jaringan pada masing-masing parameter dengan MSE dan MAPE pengujian terkecil yang dapat dilihat pada Tabel 3.

Table.2 PENENTUAN PARAMETER PELATIHAN UNTUK PEMBAGIAN DATA

Neuron tersembunyi	: 5
Maksimum epoch	: 2000
Target error	: 0,001
Mu	: 0,001
Epoch show	: 1000

Table.3 HASIL PELATIHAN PEMBAGIAN DATA

Komposisi Pembagian Data	Epoch	Perf	Pelatihan			Pengujian		
			MSE	MAPE (%)	R	MSE	MAPE (%)	R
65% data latih dan 35% data uji	227	0,725	1.8488e+08	4.8774	0,9963	1.7720e+10	28.2130	0.7121
55% data latih dan 45% data uji	2000	0,108	1.3567e+09	8.4308	0,9434	9.6827e+10	42.7233	0.2625
50% data latih dan 50% data uji	2000	0,00539	8,2566e+08	9,9489	0,9720	2,7318e+10	41,0613	0,4357

Tabel 3 menunjukkan bahwa MSE dan MAPE terkecil untuk pelatihan diperoleh pada komposisi pembagian data 65% untuk data latih dan 35% untuk data uji, dan MSE dan MAPE terkecil untuk pengujian diperoleh pada komposisi pembagian data 65% untuk data latih dan 35% untuk data uji. Model terbaik dipilih berdasarkan MSE dan MAPE terkecil pada tahap pengujian, sehingga komposisi pembagian data yang akan digunakan untuk membangun jaringan BPNN untuk peramalan penjualan semen, yaitu 65% untuk data latih dan 35% untuk data uji, sehingga dari 89 data yang digunakan terdapat 50 data untuk data latih dan 39 data

untuk data uji.

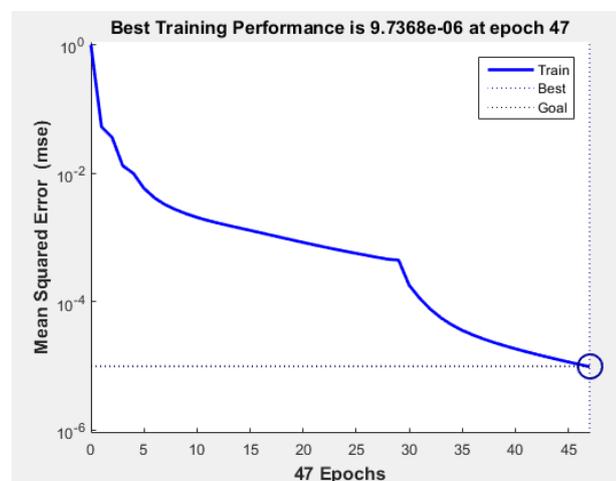
Parameter yang dipilih berdasarkan pada algoritma pelatihan yang digunakan. Parameter yang digunakan pada algoritma pelatihan Levenberg-Marquardt dapat dilihat pada Tabel 4.9.2, sedangkan parameter yang digunakan pada algoritma pelatihan gradient descent dan adaptive learning rate dapat dilihat pada Tabel 4.

Table.4 PARAMETER PELATIHAN UNTUK LEVENBERG-MARQUARDT

Maksimum epoch	: 2000
Target error	: 0,001
Inisialisasi Mu	: 0,001, 0,002, 0,003, 0,004, 0,005, 0,006, 0,007, 0,01, 0,02, 0,03, 0,04, 0,05, 0,06, 0,07, 0,1, 0,2, 0,3, 0,4, 0,5, 0,6, 0,7, 1, 2, 3
Epoch show	: 1000

Table.5 PELATIHAN GRADIENT DESCENT DENGAN MOMENTUM DAN ADAPTIVE LEARNING

Maksimum epoch	: 2000
Target error	: 0,001
Learning rate (LR)	: 0,01, 0,02, 0,03, 0,1, 0,2, 0,3
Momentum	: 0,1, 0,2, 0,8, 0,9
Epoch show	: 1000



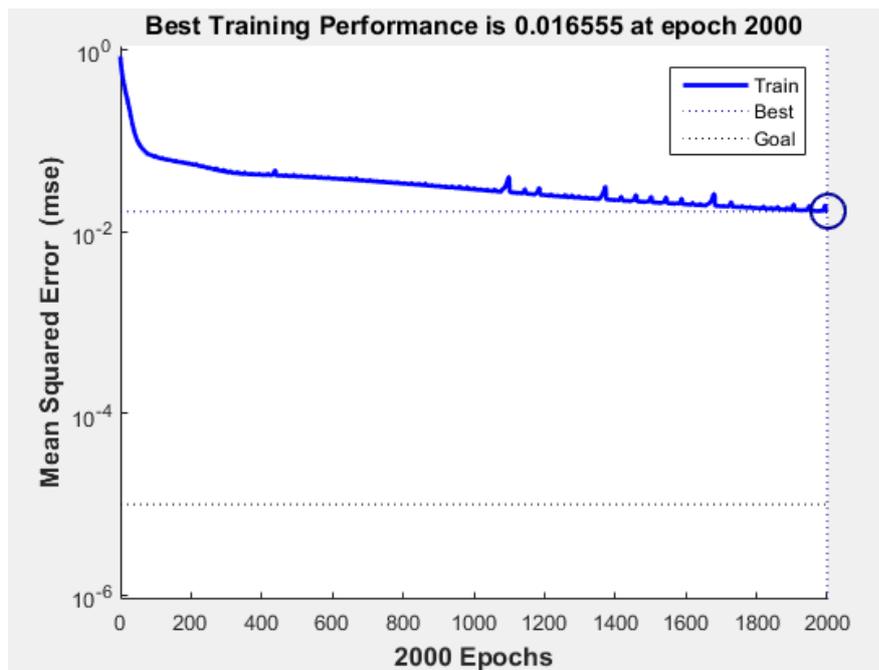
Gambar 2. Proses Pelatihan BPNN dengan Algoritma Pelatihan Levenberg-Marquardt dengan Arsitektur Jaringan 3-20-1

Hasil pelatihan BPNN dengan algoritma pelatihan Levenberg-Marquardt diperoleh model BPNN terbaik dengan algoritma pelatihan Levenberg-Marquardt pada arsitektur jaringan 3-20-1 dengan $\mu = 0,003$ pada fungsi aktivasi tansig. Model BPNN 3-20-1 memperoleh hasil pada epoch ke 47 yang memberikan nilai MSE dan MAPE pengujian masing-masing sebesar $8.0255e+09$ dan 24.4157%. Iterasi berhenti pada epoch ke 47 meskipun target error yang diinginkan (Goal = 0,001) belum tercapai. Model ini pada epoch ke 47 telah mencapai konvergen dengan performance = $8,94e-06$. Proses pelatihan pada setiap epoch ditunjukkan pada Gambar 2.

Data selengkapnya untuk hasil pelatihan BPNN dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* terlampir pada Lampiran 8. Diperoleh

model BPNN terbaik dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* pada arsitektur jaringan 3-5-1 dengan Momentum = 0,2 dan LR = 0,03 pada fungsi aktivasi tansig. Model BPNN 3-5-1 memperoleh hasil pada *epoch* ke 2000 yang memberikan nilai MSE dan MAPE pengujian masing-masing sebesar 8.6975e+09 dan 20.4829%.

Iterasi berhenti pada *epoch* ke 2000 meskipun target *error* yang diinginkan (Goal = 0,001) belum tercapai. Model ini pada *epoch* ke 2000 telah mencapai konvergen dengan *performance* = 0,0166. Proses pelatihan pada setiap *epoch* ditunjukkan pada Gambar 3.



Gambar 3. Proses Pelatihan BPNN dengan Algoritma Pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dengan Arsitektur Jaringan 3-5-1

Proses peramalan menggunakan model terbaik yang diperoleh dari pelatihan data pada data latih dan data uji. Pemilihan model terbaik dilakukan dengan membandingkan nilai MSE dan MAPE masing-masing model. Model yang pertama, yaitu model terbaik pada pelatihan algoritma pelatihan Levenberg-Marquardt dan model yang kedua yaitu algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate*. Keakuratan hasil pengujian dengan kedua model dapat dilihat pada Tabel 6.

Table.6 PELATIHAN ALGORITMA PELATIHAN LEVENBERG-MARQUARDT DAN MODEL YANG KEDUA

Model	Pelatihan		Pengujian	
	MSE	MAPE (%)	MSE	MAPE (%)
Levenberg-Marquardt (3-5-1)	2.2802e+05	0.1729	8.7255e+09	24.4157
<i>gradient descent</i> dengan momentum dan <i>adaptive learning rate</i> (3-5-1)	4.2233e+08	4.3358	8.6975e+09	20.4829

Model terbaik didapatkan dengan membandingkan MSE dan MAPE pada pengujian. Model terbaik adalah model dengan MSE dan MAPE terkecil pada pengujian dengan jaringan paling sederhana. Pada Tabel 4.12 didapatkan MSE dan MAPE terkecil adalah model pelatihan gradient descent dengan momentum dan adaptive learning rate (3-5-1) dengan MSE dan MAPE pengujian $8.6975e+09$ dan 20.4829%.

Jadi, hasil peramalan produksi garam menggunakan BPNN pada Kabupaten Rembang tahun 2020 adalah 146750 ton. Peramalan produksi garam untuk Kabupaten Pati tahun 2020 adalah dengan cara yang sama seperti peramalan pada Kabupaten Rembang tahun 2020, dengan menambahkan data jumlah produksi garam Kabupaten Pati sebagai input-nya. Perhitungan peramalan secara manual untuk Kabupaten Pati 2020 sampai dengan Kabupaten Bima 2020 terlampir pada Lampiran 12 dan perhitungan peramalan produksi garam untuk Rembang tahun 2020 sampai dengan Kabupaten Bima 2020 menggunakan bantuan software Matlab R2015b. Hasil peramalan produksi garam untuk beberapa daerah penghasil garam tertinggi di Indonesia menggunakan BPNN dapat dilihat pada tabel 7 berikut.

Table.7 HASIL PERAMALAN PRODUKSI GARAM TERTINGGI DI INDONESIA MENGGUNAKAN BPNN

<i>Waktu</i>	<i>Normalisasi Hasil Peramalan</i>	<i>Denormalisasi Hasil Peramalan</i>	<i>Hasil Peramalan Produksi Garam (dalam Ton)</i>
Rembang 2020	0,3142	146750,71	146750
Pati 2020	0,8250	306500,21	306500
Demak 2020	0,2557	128455,20	128455
Cirebon 2020	0,6480	251144,57	251144
Indamayu 2020	0,6158	241074,22	241074
Sampang 2020	1,0071	363450,85	363450
Pamekasan 2020	0,2636	130925,87	130925
Sumenep 2020	1,0977	391785,43	391785
Surabaya 2020	0,2560	128549,02	128549
Bima 2020	0,2516	127172,95	127173

Pada target pelatihan BPPN menunjukkan bahwa titik-titik mendekati garis diagonalnya dan koefisien korelasi bernilai 0,98872 (mendekati 1) menunjukkan hasil yang baik untuk kecocokan output jaringan dengan target, sehingga dapat disimpulkan bahwa model BPNN pada arsitektur jaringan 3-5-1 dengan fungsi aktivasi yang digunakan adalah tansig dapat digunakan untuk meramalkan produksi garam.

Berdasarkan Tabel 7 hasil pelatihan dan pengujian algoritma model gradient descent dengan momentum dan adaptive learning rate (3-5-1) dengan aktivasi tansig didapatkan MSE pengujian sebesar $8.6975e+09$ dan MAPE pengujian sebesar 20.4829% dengan tingkat akurasi pengujian yang baik yakni sebesar 80,52%. Hal ini sejalan dengan Susanti, dkk (2013) yang menyatakan bahwa hasil error yang kecil pada saat pelatihan jaringan belum tentu menghasilkan error yang kecil pada saat peramalan, sehingga untuk menentukan apakah suatu peramalan baik atau tidak, maka tidak hanya mengandalkan nilai error pada pelatihan jaringan saja yang kecil tetapi nilai error pada peramalan juga harus kecil. Oleh karena itu, diperoleh

bahwa model BPNN (3-5-1) adalah model yang optimal untuk peramalan produksi garam di Indonesia.

Simpulan

Model Naive Bayes Classifier untuk klasifikasi produksi garam di Indonesia adalah model yang dibangun dengan tiga operator yakni operator apply model, performance dan operator algoritma Naive Bayes, serta pengelompokan data menggunakan algoritma K-means Clustering. Hasil klasifikasi data produksi garam tertinggi dan terendah menggunakan algoritma Naive Bayes menghasilkan 89 record data untuk produksi garam tertinggi dan 595 record garam terendah. Hasil klasifikasi produksi garam tertinggi dihasilkan oleh 10 Kota/Kabupaten yakni Rembang, Pati, Demak, Cirebon, Indramayu, Sampang, Pamekasan, Sumenep, Surabaya dan Bima. Nilai accuracy yang dihasilkan dari klasifikasi menggunakan algoritma Naive Bayes adalah sebesar 98.68% dengan nilai precision sebesar 100.00% dan nilai recall data sebesar 98.49%. Model terbaik untuk peramalan produksi garam tertinggi di Indonesia adalah model BPNN (3-5-1) dengan tingkat akurasi sebesar 80,52% merupakan peramalan baik dengan MSE sebesar $8.6975e+09$. Hasil peramalan daerah produksi garam tertinggi di Indonesia menggunakan model BPNN (3-5-1) dari 10 Kota/Kabupaten di Indonesia yakni Kabupaten Rembang 2020 sebesar 146750 ton, Kabupaten Pati 2020 sebesar 306500 ton, Kabupaten Demak 2020 sebesar 128455 ton, Kabupaten Cirebon 2020 sebesar 251144 ton, Kabupaten Indramayu 2020 sebesar 241074 ton, Kabupaten Sampang 2020 sebesar 363450 ton, Kabupaten Pamekasan 2020 sebesar 130925 ton, Kabupaten Sumenep 2020 sebesar 391785 ton, dan Kota Surabaya 2020 sebesar 128549 ton, Kabupaten Bima 2020 sebesar 127173 ton.

Daftar Pustaka

- [1] L. T. Garam, "DI KECAMATAN JUWANA KABUPATEN PATI," 2013.
- [2] D. A. Sega Neli Riyanti, I. K. Satriawan, and C. A. Bayu Sadyasmara, "Analisis Pemasaran Garam Kusamba Di Kecamatan Dawan, Kabupaten Klungkung," *J. Rekayasa Dan Manaj. Agroindustri*, vol. 7, no. 2, p. 169, 2019, doi: 10.24843/jrma.2019.v07.i02.p01.
- [3] H. M. Nawawi, J. J. Purnama, and A. B. Hikmah, "Komparasi Algoritma Neural Network Dan Naive Bayes Untuk Memprediksi Penyakit Jantung," *J. Pilar Nusa Mandiri*, vol. 15, no. 2, pp. 189–194, 2019.
- [4] G. Abdillah *et al.*, "Penerapan Data Mining Pemakaian Air Pelanggan Untuk Menentukan Klasifikasi Potensi Pemakaian Air Pelanggan Baru Di Pdam Tirta Raharja Menggunakan Algoritma K-Means," *Sentika 2016*, vol. 2016, no. Sentika, pp. 18–19, 2016.
- [5] A. M. Zamani, B. Amaliah, and A. Munif, "Implementasi Algoritma Genetika pada Struktur Backpropagation Neural Network untuk Klasifikasi Kanker Payudara," *J. Tek. ITS*, vol. 1, no. 1, pp. A222–A227, 2012.
- [6] F. Y. Marianto, T. Tarno, and I. M. Di Asih, "Perbandingan Metode Naive Bayes Dan Bayesian Regularization Neural Network (BRNN) Untuk Klasifikasi Sinyal Palsu Pada

- Indikator Stochastic Oscillator (Studi Kasus: Saham PT Bank Rakyat Indonesia (Persero) Tbk Periode Januari 2017–Agustus 2019),” *J. Gaussian*, vol. 9, no. 1, pp. 16–25, 2020.
- [7] H. Hartatik, A. Syafrianto, and W. Widayani, “Perbandingan klasifikasi pencemaran air sungai dengan metode backpropagation dan naïve bayes,” *Data Manaj. dan Teknol. Inf.*, vol. 18, no. 4, pp. 67–71, 2018.
- [8] H. Dhika, “Kajian Komparasi Penerapan Algoritma C4. 5, Naïve Bayes, Dan Neural Network Dalam Pemilihan Mitra Kerja Penyedia Jasa Transportasi: Studi Kasus Cv. Viradi Global Pratama,” *SNIT 2015*, vol. 1, no. 1, pp. 197–201, 2015.
- [9] R. N. Devita *et al.*, “PERBANDINGAN KINERJA METODE NAIVE BAYES DAN K-NEAREST NEIGHBOR UNTUK KLASIFIKASI ARTIKEL BERBAHASA INDONESIA PERFORMANCE COMPARISON OF NAIVE BAYES AND K-NEAREST NEIGHBOR,” vol. 5, no. 4, pp. 427–434, 2018, doi: 10.25126/jtiik.201854773.
- [10] N. Chamidah, M. M. Santoni, and N. Matondang, “The Effect of Oversampling on the Classification of Hypertension with the Naïve Bayes Algorithm, Decision Tree, and Artificial Neural Network (ANN),” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 4, no. 4, pp. 635–641, 2020.
- [11] A. Mukminin and D. Riana, “Komparasi Algoritma C4. 5, Naïve Bayes Dan Neural Network Untuk Klasifikasi Tanah,” *J. Inform.*, vol. 4, no. 1, 2017.
- [12] I. N. Purnama, “Perbandingan Klasifikasi Website Secara Otomatis Menggunakan Metode Multilayer Perceptron dan Naive Bayes,” *J. Sist. Komput. dan Inform.*, vol. 2, no. 2, pp. 155–161, 2021.
- [13] T. Arifin and D. Ariesta, “Prediksi Penyakit Ginjal Kronis Menggunakan Algoritma Naive Bayes Classifier Berbasis Particle Swarm Optimization,” *J. Tekno Insentif*, vol. 13, no. 1, pp. 26–30, 2019.