



# JITE (Journal of Informatics and Telecommunication Engineering)

Available online <http://ojs.uma.ac.id/index.php/jite> DOI: 10.31289/jite.v7i1.9767

Received: 12 June 2023

Accepted: 28 June 2023

Published: 28 July 2023

## Model for Estimating Waste Generation in Pekanbaru Using Backpropagation Algorithm

Farahdina Risky Ramadani<sup>1)</sup>, Inggih Permana<sup>2)</sup>, M. Afdal<sup>3)</sup>, Siti Monalisa<sup>4)</sup>

1) 2) 3) 4) Prodi Sistem Informasi, Fakultas Sains dan Teknologi, UIN Sultan Syarif Kasim Riau, Indonesia

\*Corresponding Email: [farahdinarr97@gmail.com](mailto:farahdinarr97@gmail.com)

### Abstrak

Timbulan sampah di Kota Pekanbaru belum dapat dikelola secara maksimal. Berdasarkan data tahun 2020, sampah yang sampai ke Tempat Pembuangan Akhir (TPA) tidak mencapai 50%. Untuk mengatasi masalah tersebut, penelitian ini bertujuan membuat model estimasi yang dapat memperkirakan jumlah timbulan sampah yang dihasilkan setiap tahunnya. Sehingga dapat membantu pihak berwenang untuk menerapkan berbagai kebijakan untuk pengendalian timbulan sampah. Model estimasi dibuat menggunakan algoritma backpropagation. Atribut-atribut yang digunakan adalah atribut-atribut yang terkait dengan populasi penduduk dan timbulan sampah. Berdasarkan hasil percobaan yang dilakukan menggunakan RapidMiner, model arsitektur jaringan terbaik adalah model 6-6-1 yaitu enam node pada input layer, enam node pada hidden layer, dan satu node pada output layer. Enam node pada input layer mengacu pada jumlah atribut yang digunakan. Fungsi aktivasi yang digunakan adalah sigmoid biner. Nilai RMSE yang dihasilkan dari model terbaik adalah sangat rendah, yaitu 0,0181. Sehingga dapat disimpulkan bahwa model ini dapat digunakan untuk mengestimasi timbulan sampah yang di Kota Pekanbaru.

**Kata Kunci:** Timbulan Sampah, Estimasi, Backpropagation, Pekanbaru

### Abstract

Waste generation in Pekanbaru City cannot be managed optimally. Based on 2020 data, less than 50% of the waste that reaches the Final Disposal Site (TPA) reaches. To overcome this problem, this study aims to create an estimation model that can estimate the amount of waste generated each year. So that it can help the authorities to implement various policies to control waste generation. The estimation model is created using the backpropagation algorithm. The attributes used are those related to population and waste generation. Based on the results of experiments conducted using RapidMiner, the best network architecture model is the 6-6-1 model, namely six nodes in the input layer, six nodes in the hidden layer, and one node in the output layer. The six nodes in the input layer refer to the number of attributes used. The activation function used is binary sigmoid. The RMSE value generated from the best model is very low, namely 0.0181. So it can be concluded that this model can be used to estimate the generation of solid waste in Pekanbaru City.

**Keywords:** Waste Generation, Estimation, Backpropagation, Pekanbaru

**How to Cite:** Ramadani, F. R., Permana, I., Afdal, M., Monalisa, S. (2023). Model for Estimating Waste Generation in Pekanbaru Using Backpropagation Algorithm. *JITE (Journal Of Informatics And Telecommunication Engineering)*. 7 (1): 317-327

## I. PENDAHULUAN

Timbulan sampah adalah banyaknya sampah yang dihasilkan dari sumber sampah di wilayah tertentu dalam satuan volume dan berat per satuan waktu (Husen dkk., 2021). Seperti yang dinyatakan oleh Damanhuri (dalam Adityaputra, 2018), rata-rata timbulan sampah biasanya akan berbeda pada setiap daerah (Adityaputra, 2018). Beberapa faktor yang dapat mempengaruhi jumlah timbulan sampah, diantaranya adalah jumlah penduduk, pendapatan, ukuran rumah tangga, jenis tempat tinggal, kelompok usia, pekerjaan, konsumsi listrik, dan Produk Domestik Bruto (PDB) (Sun & Chungpaibulpatana, 2017). Selain itu, tingkat sampah kota tahunan per kapita juga sangat berkorelasi dengan kondisi ekonomi masing-masing wilayah (Kulisz & Kujawska, 2020). Jumlah penduduk telah ditetapkan sebagai faktor utama yang berkontribusi terhadap timbulnya sampah. Selain itu, persentase warga yang bekerja dan mengaggur juga

berpengaruh terhadap pembentukan timbulan sampah. Ketika tingkat pendapatan masyarakat tinggi, sampah kering (anorganik) yang dihasilkan lebih banyak dibandingkan dengan sampah basah (organik) (Ayeleru dkk., 2021). Akan tetapi, jika masyarakat mengaggur, timbulan sampah yang dihasilkan akan berkurang drastis dikarenakan daya beli yang sedikit lebih rendah (Elshaboury dkk., 2021). Selain itu, beberapa penelitian menunjukkan bahwa ada hubungan yang menghubungkan jumlah rumah tangga dan jumlah produksi sampah (Ayeleru dkk., 2021).

Bagi penduduk perkotaan, timbulan sampah dapat menimbulkan berbagai masalah secara langsung maupun tidak langsung, terutama di sekitar lokasi penumpukan sampah. Dampak langsung dari pengelolaan sampah yang tidak baik diantaranya adalah penyakit menular, penyakit kulit, gangguan pernafasan, dan sebagainya. Sedangkan dampak tidak langsung diantaranya adalah banjir yang terjadi karena tersumbatnya aliran air (Audina dkk., 2018). Menurut Mukono (dalam Istiqomah, 2018), pengelolaan sampah yang tidak baik dapat berdampak pada tiga hal, yaitu: (1) aspek kesehatan (seperti penyakit tikus, cacing, dan jamur); (2) aspek lingkungan (seperti terganggunya estetika dan kenyamanan lingkungan); dan (3) aspek masyarakat (seperti pengelolaan sampah yang tidak baik dapat menjadi indikasi status sosial ekonomi masyarakat dan kondisi lingkungan yang tidak menarik sehingga membuat wisatawan enggan untuk berkunjung) (Istiqomah, 2018).

Kota Pekanbaru adalah ibu kota dan kota terbesar di Provinsi Riau dengan jumlah penduduk sekitar 1,1 juta jiwa pada tahun 2022 (Badan Pusat Statistik Kota Pekanbaru, 2022). Saat ini Kota Pekanbaru memiliki permasalahan sampah yang belum terselesaikan dengan optimal. Pada tahun 2020, produksi sampah kota di Kota Pekanbaru mencapai 1.052,16 ton perhari, atau setara dengan 384.039 ton pertahun, namun sampah yang sampai ke Tempat Pembuangan Akhir (TPA) selama lima tahun terakhir rata-rata belum mencapai setengahnya (46,72%) (Afriyanni dkk., 2022). Situasi ini semakin diperkuat oleh temuan Riset Kesehatan Dasar Provinsi Riau Tahun 2018, yang menunjukkan bahwa hanya 25% sampah yang diangkut, sedangkan mayoritas (64%) dibakar, dibuang ke kali/selokan (4%) dan bahkan dibuang sembarangan (Afriyanni dkk., 2022). Kemudian pada tahun 2021 jumlah sampah yang dihasilkan di Kota Pekanbaru diperkirakan mencapai angka 400.462 ton pertahun (Kominfo, 2021). Sampah tersebut berasal dari sampah rumah tangga, institusi pendidikan, perkantoran, kawasan industri, dan pusat perbelanjaan. Pertambahan penduduk yang begitu pesat akan menyebabkan jumlah sampah yang semakin banyak dan akan sangat mempengaruhi kualitas kesehatan lingkungan perkotaan dan permukiman (Priandila dkk., 2022).

Untuk memastikan pengelolaan sampah yang baik dan akurat, tentunya diperlukan estimasi jumlah timbulan sampah setiap tahunnya. Hasil dari estimasi ini dapat digunakan oleh berbagai pihak berwenang untuk mengambil berbagai kebijakan dalam mengatasi permasalahan sampah di masa mendatang, contohnya penyediaan Tempat Pembuangan Sementara (TPS), petugas, kendaraan pengangkut, anggaran biaya hingga persiapan TPA baru.

Salah satu teknik pemodelan estimasi yang bisa digunakan adalah machine learning. Penelitian ini menggunakan salah satu algoritma dari teknik machine learning yaitu backpropagation untuk membuat model yang dapat mengestimasi jumlah timbulan sampah. Backpropagation adalah jenis supervised learning yang menggunakan pola penyesuaian bobot untuk mencapai nilai kesalahan minimum antara keluaran hasil estimasi dan keluaran yang nyata (Pranata dkk., 2018). Backpropagation melatih jaringan untuk mencapai keseimbangan antara kemampuan jaringan dalam mengenali pola yang digunakan selama training (Pranata dkk., 2021). Algoritma backpropagation merupakan algoritma iteratif yang mudah dan sederhana dan bekerja dengan baik bahkan dengan data yang kompleks (Rohayani & Umam, 2022).

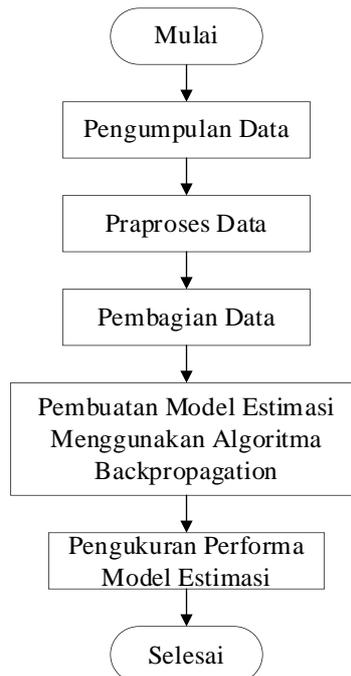
Penelitian ini menggunakan algoritma backpropagation karena hasil dari penelitian sebelumnya yang dilakukan oleh Oguz-Ekim (2021) yang juga membahas prediksi timbulan sampah menunjukkan bahwa backpropagation memiliki performa yang lebih baik dibandingkan dengan Support Vector Regression (SVR). Namun penelitian tersebut tidak menggunakan atribut jumlah penduduk, penduduk usia 15-59 tahun, jumlah rumah tangga, jumlah bekerja, jumlah pengangguran, dan jumlah wisatawan (Oguz-Ekim, Pinar, 2021). Sedangkan menurut Sun dan Chungpaibulpatana (2017), atribut jumlah penduduk, penduduk usia 15-59 tahun, jumlah rumah tangga, dan jumlah wisatawan sangat mempengaruhi timbulan sampah (Sun & Chungpaibulpatana, 2017). Kemudian menurut Ayeleru, dkk. (2021) persentase warga yang bekerja dan mengaggur berkontribusi terhadap timbulan sampah. Namun penelitian tersebut tidak menggunakan atribut penduduk usia 15-59 tahun dan jumlah wisatawan. Kemudian hasilnya menunjukkan bahwa metode backpropagation lebih baik daripada metode Support Vector Machine (SVM) (Ayeleru dkk., 2021). Begitu juga dengan Purnamaswari, dkk. (2022) dalam penelitiannya menemukan bahwa metode backpropagation memiliki performa yang lebih baik dibandingkan dengan metode SVM. Namun penelitiannya tersebut tidak menggunakan atribut mengenai populasi penduduk (Purnamaswari dkk., 2022). Kemudian pada penelitian

Hoque (2020) menyatakan bahwa dalam mengestimasi area TPA menggunakan metode neural network memperoleh hasil yang optimal, dimana hasil estimasi dari model tersebut tidak jauh berbeda dari data aktual (Hoque & Rahman, 2020).

Paper ini dibagi menjadi 4 bagian. Bab pertama merupakan pendahuluan yang membahas tentang latar belakang masalah dan penelitian terkait. Bab kedua adalah metodologi penelitian, yang menjelaskan tentang tahapan penelitian dan metode yang digunakan dalam penelitian ini. Bab ketiga adalah hasil dan pembahasan dari percobaan yang telah dilakukan. Bab terakhir merupakan kesimpulan dari penelitian ini.

## II. METODE PENELITIAN

Penelitian ini dilakukan dengan melalui beberapa tahapan penelitian. Adapun tahapan-tahapan penelitian dapat terlihat pada Gambar 1.



Gambar 1. Metodologi Penelitian

### A. Pengumpulan Data

Dalam penelitian ini, data yang digunakan adalah data sekunder. Data diperoleh dari dua sumber. Sumber data pertama berasal Dinas Lingkungan Hidup (DLH) dan Kebersihan Kota Pekanbaru untuk data timbulan sampah di Kota Pekanbaru. Sumber data kedua berasal dari Badan Pusat Statistik (BPS) untuk data populasi penduduk.

Atribut yang digunakan untuk proses estimasi merujuk pada penelitian Sun & Chungpaibulpatana (2017) dan Ayeleru dkk., (2021). Untuk lebih jelasnya dapat dilihat pada Tabel 1.

Tabel 1. Atribut yang Digunakan

Atribut	Deskripsi	Satuan	Sumber
Jumlah timbulan sampah	Sampah kota yang dikumpulkan biasanya terdiri dari bahan rumah tangga dan komersial, tidak termasuk sampah berbahaya dan industri.	Ton/tahun	DLH
Jumlah penduduk	Jumlah orang yang terdaftar tinggal di Kota Pekanbaru.	Kapita	BPS
Jumlah penduduk berusia 15-59 tahun	Jumlah orang yang terdaftar di Kota Pekanbaru berusia 15 hingga 59 tahun.	Kapita	BPS
Jumlah rumah tangga	Jumlah total rumah tangga yang terdaftar di Kota Pekanbaru.	-	BPS
Bekerja	Jumlah orang yang memiliki pekerjaan dan penghasilan	Kapita	BPS
Pengangguran	Jumlah orang yang tidak memiliki pekerjaan.	Kapita	BPS
Jumlah Wisatawan	Jumlah turis mancanegara di Kota Pekanbaru.	Kapita	BPS

## B. *Praproses Data*

Adapun langkah-langkah dari praproses data, yaitu data *cleaning*, data *integration*, dan normalisasi data. Proses data *cleaning* yang dilakukan adalah mengisi data yang hilang (*missing value*) dengan nilai rata-rata. Proses data *integration* yang dilakukan adalah menggabungkan data yang berasal dari DLH dan BPS. Kemudian normalisasi data dilakukan dengan menggunakan metode *minmax normalization* dengan nilai minimal adalah 0 dan nilai maksimal adalah 1. Adapun rumus normalisasi dapat dilihat pada Rumus ( 1 ) (Natasya dkk., 2021).

$$\text{Normalisasi} = \frac{0,8(x - \min x)}{\max x - \min x} + 0,1 \quad (1)$$

Keterangan:

$x$  = data,

$\max x$  = nilai maksimum,

$\min x$  = nilai minimum.

## C. *Pembagian Data*

Pembagian data latih dan data uji menggunakan *K-Fold Cross Validation* dengan nilai K adalah 10. Metode ini digabung karena metode ini bisa mengevaluasi kinerja proses dari suatu metode algoritma dengan membagi secara acak sampel data dan mengelompokkan data tersebut sebanyak nilai K pada *K-Fold* (Arisandi dkk., 2022). Selain itu, metode ini bisa digunakan untuk menghilangkan bias pada data (Tempola dkk., 2018). *Tools* yang digunakan pada tahapan penelitian ini adalah RapidMiner 9.1.

## D. *Pembuatan Model Estimasi Menggunakan Algoritma Backpropagation*

Proses algoritma backpropagation memiliki arsitektur jaringan yang sangat mempengaruhi keakuratan hasil prediksi, sehingga pemilihan arsitektur jaringan yang tepat adalah suatu hal yang harus dilakukan (Indrayati Sijabat dkk., 2020). Tahapan ini menggunakan tools RapidMiner 9.1. Arsitektur jaringan yang digunakan adalah 6-4-1, 6-6-1, 6-8-1, dan 6-10-1. Parameter-parameter backpropagation yang digunakan pada penelitian ini dapat dilihat pada Tabel 2.

**Tabel 2.** Nilai Parameter-Parameter *Backpropagation*

No	Parameter	Nilai
1.	<i>Learning Rate</i> ( $\alpha$ )	0,01, 0,03, 0,09, 0,10, 0,30, 0,50
2.	Jumlah node dalam <i>Input Layer</i>	6
3.	Jumlah node dalam <i>Hidden Layer</i>	4, 6, 8, 10
4.	Jumlah node dalam <i>Output Layer</i>	1
5.	Fungsi Aktivasi	<i>Sigmoid Biner</i>
6.	Jumlah <i>Epoch</i>	1000
7.	<i>Error Maksimal</i>	0,01

## E. *Pengukuran Performa Model Estimasi*

Pengukuran performa model estimasi menggunakan *Root Means Square Error* (RMSE). Nilai estimasi yang dihasilkan oleh model yang didapat akan didenormalisasi.

## F. *Denormalisasi*

Denormalisasi adalah mengembalikan ukuran data yang sebelumnya telah dinormalisasi untuk mendapatkan data yang asli (Budiman, 2021). Rumus denormalisasi dapat dilihat pada Rumus ( 2 ) (Putra & Walmi, 2020).

$$\text{Denormalisasi} = \frac{(x - 0,1) (\max x - \min x)}{0,8} + \min x \quad (2)$$

Keterangan:

$x$  = hasil keluaran dari pelatihan,  
 $\max x$  = nilai maksimum,  
 $\min x$  = nilai minimum.

### III. HASIL DAN PEMBAHASAN

#### A. Hasil Pengumpulan Data

Berdasarkan hasil pengumpulan data dari tahun 2007 sampai dengan tahun 2022, terdapat dua nilai *missing value* pada data tahun 2016. Untuk lebih jelasnya dapat dilihat pada Tabel 3 dan Tabel 4.

**Tabel 3.** Hasil Pengumpulan Data dari DLH

Tahun	Timbulan Sampah (ton/tahun)
2007	256.197
2008	262.541
2009	263.716
2010	294.917
2011	308.113
2012	316.857
2013	328.182
2014	332.267
2015	341.022
2016	349.710
2017	358.422
2018	367.052
2019	377.564
2020	323.032
2021	326.721
2022	330.977

**Tabel 4.** Hasil Pengumpulan Data dari BPS

Tahun	Total Penduduk	Penduduk Usia 15-59 Tahun	Total Rumah Tangga	Bekerja	Pengangguran	Wisatawan
2007	779.899	514.108	175.859	232.729	56.404	12.055
2008	799.213	546.032	177.762	268.861	44.652	14.223
2009	802.788	530.830	188.341	284.463	38.909	14.459
2010	897.768	601.651	213.795	391.047	44.556	16.984
2011	937.939	628.799	223.388	382.185	39.348	25.227
2012	964.558	647.156	229.939	389.921	20.049	25.065
2013	999.031	669.186	237.937	412.254	29.424	25.949
2014	1.011.467	688.192	240.888	408.331	41.363	25.757
2015	1.038.118	706.768	247.234	440.873	35.547	24.399
2016	1.064.566	725.230	253.533	-	-	24.904
2017	1.091.088	743.666	259.849	467.555	45.716	29.690

2018	1.117.359	761.734	266.105	494.362	45.469	29.319
2019	1.149.359	779.584	272.296	514.200	43.865	29.060
2020	983.356	650.571	233.749	507.617	47.521	5.220
2021	994.585	657.405	236.864	492.354	44.503	73
2022	1.007.540	664.984	239.948	533.633	36.513	441

## B. Hasil Praproses Data

Data *cleaning* dilakukan pada data tahun 2016 yang terdapat *missing value* dengan mengisi nilai rata-rata seperti yang terlihat pada Tabel 5. Sedangkan data *integration* dilakukan dengan menggabungkan data yang bersumber dari DLH dan BPS berdasarkan tahun. Hasil data *integration* dapat dilihat pada

Tabel 6. Untuk data hasil normalisasi dapat dilihat pada

Tabel 7. Sedangkan nilai minimal dan maksimal dari setiap atribut dapat dilihat pada

Tabel 8.

Tabel 5. Hasil Data *Cleaning*

Tahun	Total Penduduk	Penduduk Usia 15-59 Tahun	Total Rumah Tangga	Bekerja	Pengangguran	Wisatawan
2007	779.899	514.108	175.859	232.729	56.404	12.055
2008	799.213	546.032	177.762	268.861	44.652	14.223
2009	802.788	530.830	188.341	284.463	38.909	14.459
2010	897.768	601.651	213.795	391.047	44.556	16.984
2011	937.939	628.799	223.388	382.185	39.348	25.227
2012	964.558	647.156	229.939	389.921	20.049	25.065
2013	999.031	669.186	237.937	412.254	29.424	25.949
2014	1.011.467	688.192	240.888	408.331	41.363	25.757
2015	1.038.118	706.768	247.234	440.873	35.547	24.399
2016	1.064.566	725.230	253.533	414.692	40.923	24.904
2017	109.1088	743.666	259.849	467.555	45.716	29.690
2018	1.117.359	761.734	266.105	494.362	45.469	29.319
2019	1.149.359	779.584	272.296	514.200	43.865	29.060
2020	983.356	650.571	233.749	507.617	47.521	5.220
2021	994.585	657.405	236.864	492.354	44.503	73
2022	1.007.540	664.984	239.948	533.633	36.513	441

Tabel 6. Hasil Data *Integration*

Tahun	Total Penduduk	Penduduk Usia 15-59 Tahun	Total Rumah Tangga	Bekerja	Pengangguran	Wisatawan	Timbulan Sampah (ton/tahun)
2007	779.899	514.108	175.859	232.729	56.404	12.055	256.197
2008	799.213	546.032	177.762	268.861	44.652	14.223	262.541
2009	802.788	530.830	188.341	284.463	38.909	14.459	263.716
2010	897.768	601.651	213.795	391.047	44.556	16.984	294.917
2011	937.939	628.799	223.388	382.185	39.348	25.227	308.113
2012	964.558	647.156	229.939	389.921	20.049	25.065	316.857

2013	999.031	669.186	237.937	412.254	29.424	25.949	328.182
2014	1.011.467	688.192	240.888	408.331	41.363	25.757	332.267
2015	1.038.118	706.768	247.234	440.873	35.547	24.399	341.022
2016	1.064.566	725.230	253.533	414.692	40.923	24.904	349.710
2017	1.091.088	743.666	259.849	467.555	45.716	29.690	358.422
2018	1.117.359	761.734	266.105	494.362	45.469	29.319	367.052
2019	1.149.359	779.584	272.296	514.200	43.865	29.060	377.564
2020	983.356	650.571	233.749	507.617	47.521	5.220	323.032
2021	994.585	657.405	236.864	492.354	44.503	73	326.721
2022	1.007.540	664.984	239.948	533.633	36.513	441	330.977

**Tabel 7.** Hasil Data Normalisasi

Tahun	Total Penduduk	Penduduk Usia 15-59 Tahun	Total Rumah Tangga	Bekerja	Pengangguran	Wisatawan	Timbulan Sampah (ton/tahun)
2007	0,1000	0,1000	0,1000	0,1000	0,9000	0,4237	0,1000
2008	0,1418	0,1962	0,1158	0,1961	0,6414	0,4822	0,1418
2009	0,1496	0,1504	0,2035	0,2375	0,5150	0,4886	0,1496
2010	0,3552	0,3638	0,4147	0,5209	0,6393	0,5568	0,3552
2011	0,4422	0,4456	0,4943	0,4974	0,5247	0,7794	0,4422
2012	0,4998	0,5009	0,5486	0,5179	0,1000	0,7751	0,4998
2013	0,5745	0,5673	0,6150	0,5773	0,3063	0,7989	0,5745
2014	0,6014	0,6246	0,6395	0,5669	0,5690	0,7938	0,6014
2015	0,6591	0,6806	0,6921	0,6534	0,4410	0,7571	0,6591
2016	0,7164	0,7362	0,7444	0,5838	0,5593	0,7707	0,7164
2017	0,7738	0,7918	0,7967	0,7243	0,6648	0,9000	0,7738
2018	0,8307	0,8462	0,8486	0,7956	0,6594	0,8900	0,8307
2019	0,9000	0,9000	0,9000	0,8483	0,6241	0,8830	0,9000
2020	0,5405	0,5112	0,5802	0,8308	0,7045	0,2390	0,5405
2021	0,5649	0,5318	0,6061	0,7903	0,6381	0,1000	0,5649
2022	0,5929	0,5547	0,6317	0,9000	0,4623	0,1099	0,5929

**Tabel 8.** Nilai Minimal dan Maksimal Setiap Atribut

Atribut	Minimal	Maksimal
Total Penduduk	779.899	1.149.359
Penduduk Usia 15-59 Tahun	514.108	779.584
Total Rumah Tangga	175.859	272.296
Bekerja	232.729	533.633
Pengangguran	20.049	56.404
Wisatawan	73	29.690
Timbulan Sampah (ton/tahun)	256.197	377.564

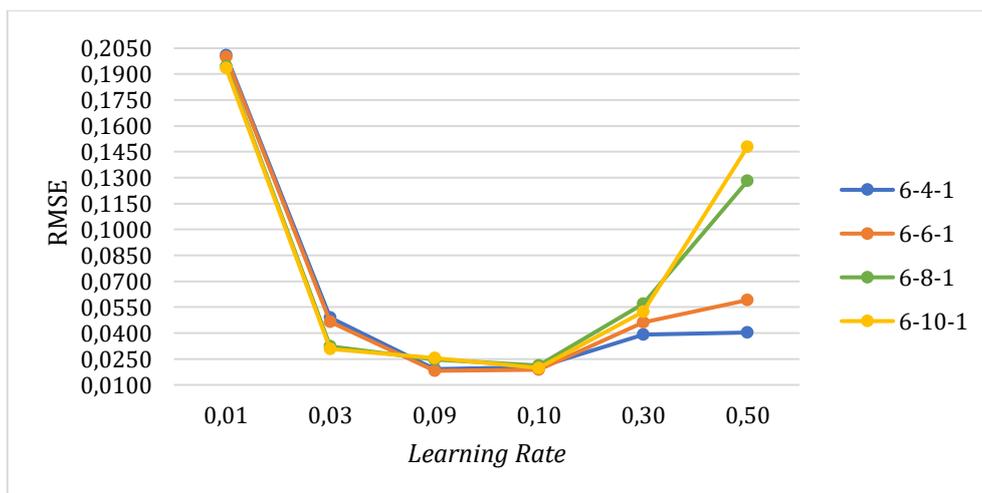
### C. Pembuatan Model Estimasi Menggunakan Algoritma Backpropagation

Berdasarkan hasil 24 kali percobaan yang dilakukan dengan mengkombinasikan beberapa *learning rate* dan arsitektur *backpropagation* didapat model estimasi terbaik dengan nilai *learning rate* 0,09 dan arsitektur 6-6-1, dengan nilai RMSE adalah 0,0181. Untuk lebih jelasnya dapat dilihat pada Tabel 9.

**Tabel 9.** Hasil Pengujian Model Arsitektur

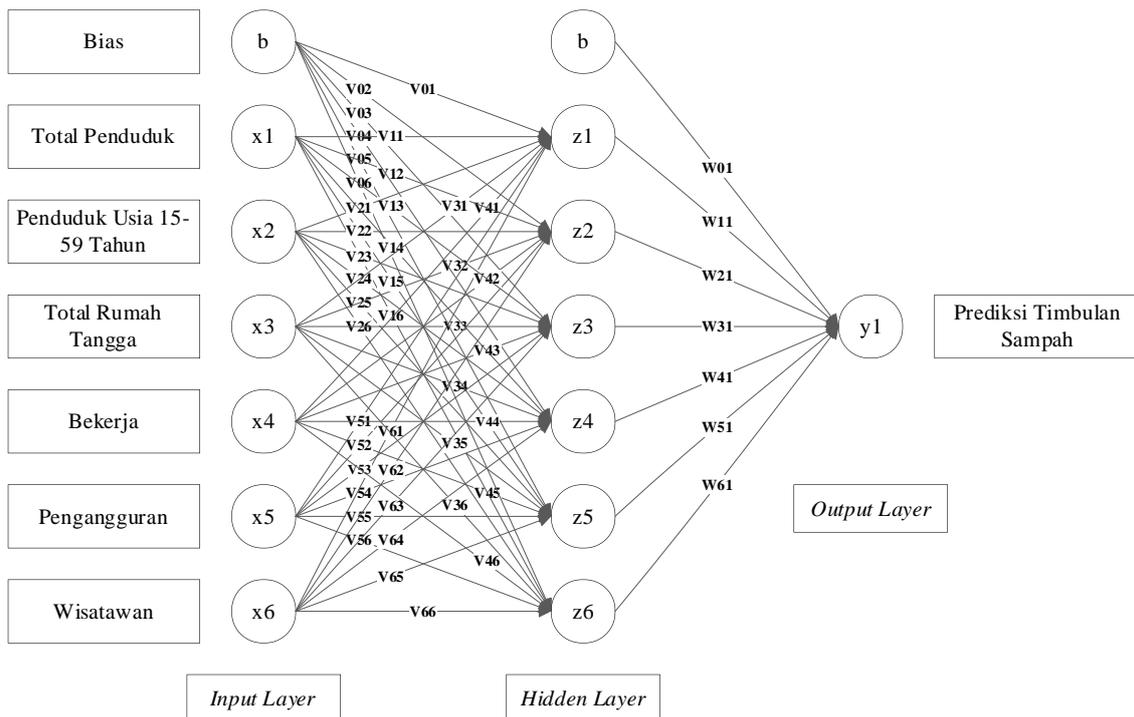
No	Learning Rate	Model Arsitektur	RMSE
1.	0,01	6-4-1	0,2009
2.		6-6-1	0,1999
3.		6-8-1	0,1945
4.		6-10-1	0,1935
5.	0,03	6-4-1	0,0490
6.		6-6-1	0,0465
7.		6-8-1	0,0324
8.		6-10-1	0,0308
9.	0,09	6-4-1	0,0192
10.		6-6-1	0,0181
11.		6-8-1	0,0245
12.		6-10-1	0,0255
13.	0,10	6-4-1	0,0203
14.		6-6-1	0,0186
15.		6-8-1	0,0213
16.		6-10-1	0,0198
17.	0,30	6-4-1	0,0393
18.		6-6-1	0,0461
19.		6-8-1	0,0569
20.		6-10-1	0,0524
21.	0,50	6-4-1	0,0402
22.		6-6-1	0,0592
23.		6-8-1	0,1282
24.		6-10-1	0,1479

Gambar 2 memperlihatkan pengaruh nilai *learning rate* terhadap performa dari model estimasi pada semua arsitektur jaringan. Pada model tersebut terlihat nilai RMSE cenderung menurun pada *learning rate* 0,09 sampai 0,10. Setelah itu nilai RMSE kembali naik, sehingga dapat disimpulkan bahwa pada kasus ini nilai *learning rate* yang terbaik yang dapat digunakan adalah rentang 0,09 sampai dengan 0,10.



**Gambar 2.** Perbandingan Seluruh Model Arsitektur

Setelah dilakukan percobaan *backpropagation* menggunakan model optimasi, selanjutnya adalah melakukan pengujian dengan model terbaik. Arsitektur dari model estimasi terbaik dapat dilihat pada Gambar 3.



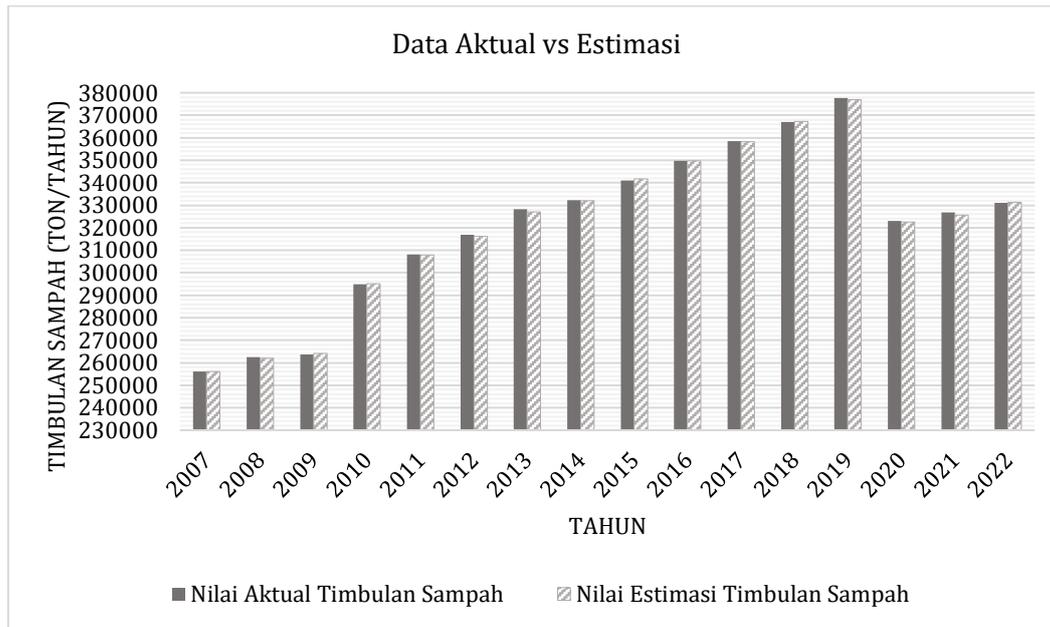
**Gambar 3.** Hasil Arsitektur *Backpropagation* dari Model Estimasi Terbaik

Sedangkan untuk bobot vektornya dapat dilihat pada Tabel 10.

**Tabel 10.** Hasil Nilai Bobot dan Bias dari Model Estimasi Terbaik

Input ke Hidden							Hidden ke Output	
V	1	2	3	4	5	6	W	1
0	-0,874	-1,106	-1,337	-0,917	-0,962	-1,067	0	-0,290
1	-0,539	0,543	0,663	-0,460	-0,036	0,482	1	-0,679
2	-0,484	0,437	0,488	-0,365	0,015	0,398	2	0,812
3	-0,469	0,388	0,498	-0,416	-0,076	0,328	3	1,068
4	-0,349	0,028	-0,005	-0,253	-0,056	0,041	4	-0,601
5	-0,103	-0,152	0,126	-0,112	-0,339	-0,190	5	-0,051
6	-0,397	-0,083	-0,264	-0,356	-0,210	-0,040	6	0,687

Simulasi hasil penerapan model estimasi yang didapat menggunakan data tahun 2007 sampai dengan tahun 2022 dapat dilihat pada Gambar 4. Pada gambar tersebut terlihat bahwa antara nilai aktual timbulan sampah dengan nilai estimasi timbulan sampah sangat mirip. Sehingga dapat disimpulkan bahwa model ini dapat digunakan.



**Gambar 4.** Simulasi Hasil Penerapan Model Estimasi

#### IV. SIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan menggunakan data dari tahun 2007 – 2022, berhasil menghasilkan model estimasi timbulan sampah dengan performa yang sangat baik. Hasil uji coba yang dilakukan dengan software RapidMiner, performa terbaik terdapat pada arsitektur 6-6-1 dengan 6 node pada input layer yang merupakan atribut untuk melakukan estimasi, 6 node pada hidden layer, dan 1 node pada output layer. Nilai RMSE dari model estimasi yang dihasilkan sangat rendah, yaitu 0,0181 pada learning rate 0,09 dengan menggunakan fungsi aktivasi sigmoid biner. Semakin kecil nilai RMSE yang dihasilkan, maka semakin baik pula hasil estimasi yang diperoleh.

#### DAFTAR PUSTAKA

- Adityaputra, A. T. (2018). *Perencanaan Pengelolaan Sampah di Permukiman Desa Gunungpring Muntilan* [Undergraduate]. Universitas Islam Indonesia.
- Afriyanni, A., Hayati, K., Kusumaningrum, N. R., & Amri, K. (2022). Kinerja Pengelolaan Persampahan di Kota Pekanbaru. *Inovasi Pembangunan: Jurnal Kelitbangan*, 10(01), Article 01. <https://doi.org/10.35450/jip.v10i01.281>
- Arisandi, R. R. R., Warsito, B., & Hakim, A. R. (2022). Aplikasi Naive Bayes Classifier (NBC) pada Klasifikasi Status Gizi Balita Stunting dengan Pengujian K-Fold Cross Validation. *Jurnal Gaussian*, 11(1), Article 1.
- Audina, M., Anwar, S., & Antomi, Y. (2018). *Prediksi dan Analisis Tempat Pembuangan Akhir (TPA) Sampah di Kota Padang*. 1–9. <http://repository.unp.ac.id/17341/>
- Ayeleru, O. O., Fajimi, L. I., Oboirien, B. O., & Olubambi, P. A. (2021). Forecasting Municipal Solid Waste Quantity Using Artificial Neural Network and Supported Vector Machine Techniques: A Case Study of Johannesburg, South Africa. *Journal of Cleaner Production*, 289, 125671. <https://doi.org/10.1016/j.jclepro.2020.125671>
- Badan Pusat Statistik Kota Pekanbaru. (2022). *Kota Pekanbaru Dalam Angka* (Badan Pusat Statistik Kota Pekanbaru, Ed.). BPS Kota Pekanbaru. <https://pekanbarukota.bps.go.id/publication/2022/02/25/06fe10f9f07b52694cd0bf5d/kota-pekanbaru-dalam-angka-2022.html>
- Budiman, A. (2021). *Prediksi Produksi Kelapa Sawit Menggunakan Metode Algoritma Genetika Backpropagation*. Universitas Islam Negeri Sultan Syarif Kasim Riau.
- Elshaboury, N., Mohammed Abdelkader, E., Al-Sakkaf, A., & Alfalah, G. (2021). Predictive Analysis of Municipal Solid Waste Generation Using an Optimized Neural Network Model. *Processes*, 9(11), Article 11. <https://doi.org/10.3390/pr9112045>

- Hoque, Md. M., & Rahman, M. T. U. (2020). Landfill area estimation based on solid waste collection prediction using ANN model and final waste disposal options. *Journal of Cleaner Production*, 256, 120387. <https://doi.org/10.1016/j.jclepro.2020.120387>
- Husen, V. B., Halim, R., & Perdana, S. M. (2021). Gambaran Pengelolaan Bank Sampah Dream Dalam Mengurangi Timbulan Sampah Anorganik di Perumahan BCL 5 Kota Jambi. *Electronic Journal Scientific of Environmental Health And Disease*, 2(1), Article 1. <https://doi.org/10.22437/esehad.v2i1.13751>
- Indrayati Sijabat, P., Yuhandri, Y., Widi Nurcahyo, G., & Sindar, A. (2020). Algoritma Backpropagation Prediksi Harga Komoditi terhadap Karakteristik Konsumen Produk Kopi Lokal Nasional. *Digital Zone: Jurnal Teknologi Informasi dan Komunikasi*, 11(1), 96–107. <https://doi.org/10.31849/digitalzone.v11i1.3880>
- Istiqomah, D. N. (2018). *Faktor—Faktor yang Mempengaruhi Timbulan Sampah di Tempat Penampungan Sementara (TPS) Kota Madiun.pdf* [Undergraduate]. Stikes Bhakti Husada Mulia Madiun.
- Kominfo. (2021, Juli 21). *Secara Nasional, Pengelolaan Sampah di Pekanbaru 5,32 Persen*. Pekanbaru.go.id. <https://www.pekanbaru.go.id/p/news/secara-nasional-pengelolaan-sampah-di-pekanbaru-532-persen>
- Kulisz, M., & Kujawska, J. (2020). Prediction of Municipal Waste Generation in Poland Using Neural Network Modeling. *Sustainability*, 12(23), Article 23. <https://doi.org/10.3390/su122310088>
- Natasya, Musdalifah, S., & Andri. (2021). Prediksi Harga Beras Di Tingkat Perdagangan Besar Indonesia Menggunakan Algoritma Backpropagation. *Jurnal Ilmiah Matematika dan Terapan*, 18(2), 148–159. <https://doi.org/10.22487/2540766x.2021.v18.i2.15688>
- Oguz-Ekim, Pinar. (2021). Machine Learning Approaches for Municipal Solid Waste Generation Forecasting. *Environmental Engineering Science*, 38(6), 489–499. <https://doi.org/10.1089/ees.2020.0232>
- Pranata, R. E., Gunawan, I., & Sumarno. (2021). Algoritma Backpropagation Dalam Melakukan Estimasi Penjualan Beras Pada CV Hariara Pematangsiantar. *Journal of Computer System and Informatics*, 2(2), 210–221.
- Pranata, R. E., Sinaga, S. P., & Wanto, A. (2018). Estimasi Wisatawan Mancanegara yang Datang ke Sumatera Utara Menggunakan Jaringan Saraf. *semanTIK*, 4(1), 97–102.
- Priandila, N., Sariapura, D., & Simanjuntak, M. (2022). Penerapan Metode Backpropagation untuk Memprediksi Jumlah Sampah. *Agustus*, 6(3), 906–918.
- Purnamaswari, A. A. A., Putra, I. K. G. D., & Putra, I. M. S. (2022). Komparasi Metode Neural Network Backpropagation dan Support Vector Machines dalam Prediksi Volume Sampah TPA Suwung. *Jurnal Ilmiah Teknologi dan Komputer*, 3(1).
- Putra, H., & Walmi, N. U. (2020). Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation. *Jurnal Nasional Teknologi dan Sistem Informasi*, 6(2), Article 2. <https://doi.org/10.25077/TEKNOSI.v6i2.2020.100-107>
- Rohayani, H., & Umam, M. C. (2022). Prediksi Penentuan Program Studi Berdasarkan Nilai Siswa dengan Algoritma Backpropagation. *Journal of Information System Research (JOSH)*, 3(4), Article 4. <https://doi.org/10.47065/josh.v3i4.1935>
- Sun, N., & Chungpaibulpatana, S. (2017). Development of an Appropriate Model for Forecasting Municipal Solid Waste Generation in Bangkok. *Energy Procedia*, 138, 907–912. <https://doi.org/10.1016/j.egypro.2017.10.134>
- Tempola, F., Muhammad, M., & Khairan, A. (2018). Perbandingan Klasifikasi Antara KNN dan Naive Bayes pada Penentuan Status Gunung Berapi dengan K-Fold Cross Validation. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 5(5), Article 5. <https://doi.org/10.25126/jtiik.201855983>
- Widodo, A. P., Suhartono, S., Sarwoko, E. A., & Firdaus, Z. (2017). Akurasi Model Prediksi Metode Backpropagation Menggunakan Kombinasi Hidden Neuron Dengan Alpha. *Matematika*, 20(2), 79–84.