

# Implementasi *Multilayer Perceptron Artificial Neural Network* untuk Prediksi Konsumsi Energi Listrik PT PLN (Persero) UP3 Salatiga

Roni Saputra<sup>1)</sup>, Said Sunardiyo<sup>2)</sup>, Anan Nugroho<sup>3)</sup>, dan Subiyanto<sup>4)</sup>

<sup>1,2,3,4)</sup>Program Studi Pendidikan Teknik Elektro, Fakultas Teknik, Universitas Negeri Semarang

<sup>1,2,3,4)</sup>Kampus UNNES, Sekaran, Kec. Gunungpati, Kota Semarang, Jawa Tengah, Indonesia, 50229

e-mail: roni\_saputra@students.unnes.ac.id<sup>1)</sup>, saidelektro@mail.unnes.ac.id<sup>2)</sup>, anannugroho@mail.unnes.ac.id<sup>3)</sup>, subiyanto@mail.unnes.ac.id<sup>4)</sup>

## ABSTRACT

*Electricity is energy that flows through cable networks and has become an important part of the progress of human civilization in various fields. The high demand for electrical energy for consumers requires providers of electrical energy to provide a reliable but economical supply of electrical energy. Therefore, strategies and methods are needed to adjust the supply and demand of electrical energy. This can be achieved by carrying out proper and appropriate operational planning. One of the important steps in planning the operation of an electric power system is predicting the demand for electrical energy. However, in the existing research there are still deficiencies in the form of a high error rate. The purpose of this study was to determine the implementation of the multilayer perceptron artificial neural network to predict electricity in 2022-2026 at PT PLN (Persero) UP3 Salatiga. The study used time series data on electricity consumption for the previous 5 years. Based on the research that has been done, the best network variation is TRAINING 4 hidden layer with 20 hidden layer nodes, this network model at the training stage produces output with MAD of 2,624,072 kWh and MAPE of 2.79%, and at the stage testing produced an output with MAD of 3,728,386 kWh and MAPE of 3.24%.*

**Keywords:** *Multilayer perceptron artificial neural network, Forecasting, Electricity consumption.*

## ABSTRAK

Listrik merupakan energi yang mengalir melalui jaringan kabel serta sudah menjadi bagian yang penting dalam kemajuan peradaban manusia di berbagai bidang. Tingginya kebutuhan energi listrik pada konsumen mengharuskan penyedia energi listrik menyediakan suplai energi listrik yang handal tetapi tetap ekonomis. Oleh karena itu, diperlukan strategi dan metode untuk penyesuaian antara *supply* dan *demand* energi listrik. Hal tersebut dapat dicapai dengan melakukan perencanaan operasi yang baik dan tepat, salah satu langkah perencanaan operasi sistem tenaga listrik yang penting yaitu prediksi kebutuhan energi listrik. Namun dalam penelitian yang ada masih terdapat kekurangan berupa tingkat kesalahan yang masih cukup tinggi. Tujuan dari penelitian ini adalah untuk mengetahui implementasi *multilayer perceptron artificial neural network* untuk melakukan prediksi listrik pada tahun 2022-2026 pada PT PLN (Persero) UP3 Salatiga. Penelitian menggunakan data *time series* konsumsi energi listrik 5 tahun sebelumnya. Berdasarkan penelitian yang telah dilakukan didapatkan variasi jaringan terbaik yaitu TRAINING 4 *hidden layer* dengan 20 *node hidden layer*, model jaringan ini pada tahap *training* menghasilkan *output* dengan nilai MAD sebesar 2,624,072 kWh dan MAPE sebesar 2.79%, serta pada tahap *testing* menghasilkan *output* dengan nilai MAD sebesar 3,728,386 kWh dan MAPE sebesar 3.24%.

**Kata kunci:** *Multilayer perceptron artificial neural network, Prediksi, Konsumsi energi listrik.*

## I. PENDAHULUAN

Energi memiliki peran vital dalam kehidupan saat ini dalam mencapai tujuan ekonomi, sosial, dan lingkungan dalam mewujudkan pembangunan berkelanjutan serta mendukung kegiatan ekonomi nasional maupun internasional [1]. Penggunaan energi listrik senantiasa terus mengalami peningkatan, berdasarkan data statistik ketenagalistrikan bahwa jumlah pelanggan listrik PLN tahun 2021 mencapai 82.543.980 naik sebanyak 3.543.947 pelanggan atau 4,49% dari tahun sebelumnya, dengan penjualan energi listrik PLN pada tahun 2021 mencapai 257.634.252.888,85 GWh dengan komposisi penjualan sektor rumah tangga 115.369.696.749,41 GWh, sektor industri 80.904.456.814,42 GWh, sektor komersial atau usaha 44.440.872.419,49 GWh, sektor sosial 8.666.303.696,93 GWh, sektor gedung kantor pemerintah 4.707.936.982,56 GWh, dan sektor penerangan jalan umum 3.544.986.226,04 GWh [2].

Ketidakpastian besarnya konsumsi listrik di masa depan serta tidak dilakukannya perencanaan terlebih dapat menimbulkan masalah ketika *supply* dan *demand* energi listrik tidak sebanding [3]. Ketika *supply* energi listrik yang dihasilkan dari pembangkit terlalu besar dibanding dengan permintaan energi maka akan terjadi pemborosan energi yang mengakibatkan kerugian pihak penyedia energi listrik. Sedangkan jika energi listrik yang dihasilkan pembangkit lebih kecil dibanding permintaan energi maka akan berdampak terjadinya pemadaman listrik secara bergilir yang mengakibatkan kerugian bagi pihak konsumen [4]. Oleh sebab itu, perlu dilakukan prediksi (*forecasting*) untuk memperkirakan kebutuhan energi listrik sebagai upayaantisipasi hal yang tidak diinginkan di masa depan [5].

Prediksi dibedakan dalam tiga kelompok berdasarkan jangka waktunya yaitu prediksi jangka pendek, prediksi jangka menengah, dan prediksi jangka panjang [6]. Perkembangan teknologi yang semakin canggih memberikan alternatif metode prediksi dengan

memanfaatkan kecerdasan buatan (*artificial intelligence*). Salah satu kecerdasan buatan yang dapat diaplikasikan dalam proses prakiraan adalah *Artificial Neural Network* (ANN) atau Jaringan Syaraf Tiruan (JST) [7]. JST merupakan suatu sistem cerdas yang dapat memproses data dan informasi yang diberikan dengan prinsip kerjanya menirukan jaringan syaraf manusia. ANN mampu melakukan pengenalan dari pola yang diberikan berdasarkan variabel atau parameter yang digunakan. Kemudian data tersebut akan diolah dan dipelajari oleh ANN [8].

*Multilayer perceptron* merupakan salah satu model ANN. *Multilayer perceptron* yang tersusun dari neuron-neuron yang dihubungkan oleh bobot-bobot penghubung neuron tersebut dan tersusun pada beberapa layer yaitu terdiri dari 1 *input layer*, 1 atau lebih *hidden layer*, dan 1 *output layer* [9]. *Multilayer perceptron* ini dapat digunakan secara efektif dalam melakukan prediksi dan cocok untuk digunakan dalam mengolah data *time series* [10]. Algoritma pembelajaran yang sering digunakan pada *multilayer perceptron* yaitu algoritma *backpropagation*, karena algoritma ini akan memperbarui bobot agar dapat meminimalisir *error* [11].

Prediksi konsumsi energi listrik dilakukan pada cakupan wilayah kerja PT PLN (Persero) UP3 Salatiga yang meliputi wilayah kerja ULP Salatiga Kota, ULP Ungaran, dan ULP Ambarawa. Konsumsi energi listrik pada wilayah tersebut cukup fluktuatif dan cenderung terus meningkat dari tahun ke tahun. Pada tahun 2021 konsumsi energi listrik mencapai 1.313.592.239 KWh meningkat 69.237.066 KWh atau 5,56% dari tahun sebelumnya, dengan jumlah pelanggan yang juga terus meningkat dan mencapai 428,176 pelanggan pada tahun 2021.

Berdasarkan uraian diatas, peneliti tertarik untuk melakukan penelitian dengan judul "Implementasi *Multilayer Perceptron Artificial Neural Network* Untuk Prediksi Konsumsi Energi Listrik PT PLN (Persero) UP3 Salatiga". Penelitian ini dilakukan untuk memprediksi konsumsi energi listrik pada wilayah kerja PT PLN (Persero) UP3 Salatiga pada tahun 2022-2026 (5 tahun), jangka waktu ini dipilih agar hasil penelitian dapat dijadikan salah satu acuan dalam menyusun perencanaan energi masa depan. Prediksi untuk 5 tahun kedepan ini termasuk dalam kategori prediksi jangka panjang karena lebih dari 2 tahun [12]. Dalam penelitian ini menggunakan *Multilayer Perceptron Artificial Neural Network* dengan *toolbox neural network* pada *software* Matlab.

## II. TINJAUAN PUSTAKA

Meninjau dari penelitian yang telah dilakukan oleh Dudek (2020) pada penelitiannya yang berjudul "*Multilayer Perceptron for Short-Term Load Forecasting: from Global to Local Approach*". Penelitian ini dilakukan untuk mengetahui penggunaan JST *multilayer perceptron* dalam kajian prediksi beban

listrik jangka pendek, variabel data input berjumlah 24 dari siklus beban listrik 24 jam dalam sehari. Hasil penelitian ini menunjukkan bahwa arsitektur JST yang digunakan yaitu terdiri dari *input layer* 24 neuron, 1 *hidden layer* dengan *node hidden layer* berjumlah 2-4 dapat memberikan hasil prediksi yang sangat baik dengan nilai *Mean Absolut Percentage Error* (MAPE) sebesar 1,45 – 2,99 [13].

Meninjau dari penelitian yang telah dilakukan oleh Madhiarasan dan Mohamed (2021) pada penelitiannya yang berjudul "*Different Forecasting Horizons Based Performance Analysis of Electricity Load Forecasting Using Multilayer Perceptron Neural Network*" penelitian ini menyajikan penggunaan jaringan syaraf tiruan *multilayer perceptron* untuk peramalan beban listrik. Jumlah *hidden layer* dan *node hidden layer* didapatkan berdasarkan investigasi kinerja jaringan yang diusulkan. Hasil analisis kinerja model yang diusulkan didapatkan *Mean Square Error* (MSE) sebesar  $1.1506 \times 10^{-05}$  pada Dataset 1 dan MSE  $4.0142 \times 10^{-7}$  pada Dataset 2 dengan 17 *node hidden layer* berdasarkan model jaringan yang diusulkan [14].

Penelitian ini akan mengkombinasikan arsitektur ANN yaitu jumlah *hidden layer*, jumlah *node hidden layer*, dan fungsi pelatihan ANN berdasarkan referensi dari penelitian terdahulu untuk mendapatkan arsitektur ANN dengan nilai *error* terkecil. Arsitektur ANN yang akan digunakan dalam penelitian ini yaitu jumlah *hidden layer* yang akan digunakan adalah 1, 2, 3, 4, dan 5. Jumlah *node hidden layer* yang akan digunakan adalah 2, 3, 4, 5, 10, 15, 20, 25. Fungsi pelatihan yang akan digunakan adalah TRAINGDM dan TRAINGDA.

### A. Forecasting

*Forecasting* atau adalah suatu seni atau ilmu dalam meramalkan kejadian yang akan datang di masa depan dengan memperhatikan data atau informasi yang relevan, baik data atau informasi masa lalu maupun data atau informasi saat ini. prediksi menjadi sebuah metode statistik yang memiliki peranan penting dalam pengambilan keputusan berdasarkan hasil prediksi yang didapat dalam mempersiapkan langkah-langkah yang harus dilakukan pada masa mendatang dan mengantisipasi hal-hal yang tidak diinginkan. Prediksi akan memberikan gambaran kondisi yang belum pasti pada masa mendatang dan dapat dijadikan acuan dan memperkecil kesalahan [15].


### B. Artificial Neural Network

*Artificial Neural Network* (ANN) merupakan model aritmatika yang meniru fitur fungsional jaringan syaraf biologis. ANN berisi neuron buatan yang saling terkait dan memproses. Sebagai aturan umum ANN adalah sistem adaptif yang menyesuaikan strukturnya berdasarkan informasi eksternal atau internal yang berjalan melalui jaringan selama proses pembelajaran. ANN dapat digunakan untuk memodelkan hubungan yang rumit antara *input* dan *output* atau untuk

mengungkap pola dalam data. ANN dapat diterapkan secara efektif di bidang prediksi, pengenalan karakter tulisan tangan, evaluasi harga, dan lainnya. Lapisan ANN terdiri dari tiga penyusun yaitu lapisan *input* (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan *output* (*output layer*) [16].

### C. Multilayer Perceptron

*Multilayer perceptron* merupakan model ANN *feed-forward* yang tersusun dari sejumlah neuron yang dihubungkan oleh bobot-bobot penghubung [17]. *Multilayer perceptron* dapat digunakan untuk mengolah data *time series* dan dapat digunakan untuk prediksi dengan akurasi yang sangat baik dengan nilai *error* <10% dari beberapa penelitian sebelumnya. Arsitektur JST multilayer perceptron ditunjukkan pada Gambar 1.



Gambar. 1. Arsitektur ANN *Multilayer Perceptron* Dengan 2 *Hidden Layer*

### D. Algoritma Backpropagation

*Backpropagation* merupakan salah satu metode dalam pembelajaran ANN *multilayer perceptron* dengan perhitungan serta propagasi balik dari error yang didapatkan sehingga akan diperoleh hasil bobot yang sesuai dengan pola data yang ada [18]. Algoritma pembelajaran *backpropagation* dipilih dan digunakan dalam penelitian ini karena berdasarkan studi literatur penelitian-penelitian sebelumnya tentang prediksi yang menggunakan algoritma pembelajaran *backpropagation* menunjukkan akurasi yang sangat baik dengan nilai *error* yang kecil <10%.

#### 1. Fungsi Aktivasi Algoritma *Backpropagation*

Fungsi aktivasi yang digunakan memiliki beberapa ketentuan yang harus dipenuhi yaitu: terdiferensial dengan mudah, kontinu, dan merupakan fungsi tidak turun. Adapun beberapa fungsi aktivasi yang memenuhi persyaratan tersebut yakni fungsi aktivasi sigmoid biner, fungsi aktivasi sigmoid bipolar, dan fungsi aktivasi identitas.

#### 2. Pelatihan algoritma *backpropagation*

Pelatihan algoritma *backpropagation* dilakukan dalam 3 fase. Fase yang pertama yaitu fase maju, fase kedua yaitu fase mundur, dan fase ketiga yaitu memodifikasi bobot dengan tujuan dapat menurunkan tingkat kesalahan yang terjadi. Langkah-langkah yang dilakukan pada proses training standar (TRAINGD) ANN *backpropagation* sebagai berikut [19].

Langkah 1. Inisialisasi bobot.

Langkah 2. Tetapkan maksimum epoch, target error, dan learning rate ( $\alpha$ )

Langkah 3. Kerjakan langkah-langkah berikut selama Epoch < Max Epoch

#### Fase I: Propagasi Maju

a) Tiap unit input ( $X_i, i = 1, 2, 3, \dots, n$ ) menerima sinyal  $X_i$  dan meneruskan sinyal tersebut ke hidden layer

b) Tiap unit pada hidden layer ( $Z_j, j = 1, 2, 3, \dots, p$ ) menjumlahkan sinyal-sinyal input terbobot:

$$z\_in_j(p) = b1_j(p) + \sum_{i=1}^n x_i(p)v_{ij}(p) \quad (1)$$

$$z_j(p) = f(z\_in_j(p)) = \frac{1}{1+e^{-z\_in_j(p)}} \quad (2)$$

c) Tiap unit output ( $Y_k, k = 1, 2, 3, \dots, m$ ) menjumlahkan sinyal-sinyal input terbobot.

$$y\_in_k(p) = b2_k + \sum_{i=1}^p z_i(p)w_{jk}(p) \quad (3)$$

Gunakan fungsi aktivasi untuk menghitung sinyal outputnya:

$$y_k(p) = f(y\_in_k(p)) = \frac{1}{1+e^{-y\_in_k(p)}} \quad (4)$$

#### Fase II: Propagasi mundur

d) Tiap unit *output* ( $Y_k, k = 1, 2, 3, \dots, m$ ) menerima target pola yang berhubungan dengan pola *input* pembelajaran, hitung informasi *error*nya:

$$\delta_k(p) = y_k(p)[1 - y_k(p)] e_k(p) \quad (5)$$

$$e_k(p) = y_{tk}(p) - y_k(p) \quad (6)$$

Kemudian hitung koreksi bobot:

$$\Delta w_{jk}(p) = \alpha \delta_k(p) z_j(p) \quad (7)$$

e) Tiap unit *hidden layer* ( $z_j, j = 1, 2, 3, \dots, p$ ) menjumlahkan delta *input*nya (dari unit-unit yang ada di atasnya):

$$\delta_j(p) = z_j(p) [1 - z_j(p)] \sum_{k=1}^m \delta_k(p) w_{jk}(p) \quad (8)$$

Kemudian hitung koreksi bobot:

$$\Delta v_{ij}(p) = \alpha \delta_j(p) x_j(p) \quad (9)$$

#### Fase III: Perubahan Bobot

f) Tiap unit *output* ( $Y_k, k = 1, 2, 3, \dots, m$ ) memperbaiki bobotnya ( $j = 0, 1, 2, \dots, p$ ):

$$w_{jk}(p+1) = w_{jk}(p) + \Delta w_{jk}(p) \quad (10)$$

g) Tiap-tiap unit *hidden layer* ( $z_j, j = 1, 2, 3, \dots, p$ ) memperbaiki bobotnya ( $i = 0, 1, 2, \dots, n$ ):

$$v_{ij}(p+1) = v_{ij}(p) + \Delta v_{ij}(p) \quad (11)$$

#### 1. Fungsi Pelatihan TRAINGDM

Perubahan persamaan untuk pelatihan menggunakan fungsi pelatian TRAINGDM pada matlab sebagai berikut:

Perubahan bobot pada persamaan (8), berubah menjadi:

$$\Delta w_{jk} = \alpha \varphi 2_{jk} \quad (12)$$

Untuk epoch = 1 dan

$$\Delta w_{jk} = mc * \Delta w_{jk}(\text{epoch sebelumnya}) + (1 - mc) * \alpha \varphi 2_{jk} \quad (13)$$

Untuk epoch > 1

Perubahan bobot pada persamaan (9), berubah menjadi:

$$\Delta v_{jk} = \Delta v_{jk} + \alpha \phi 1_{ij} \quad (14)$$

Untuk epoch = 1, dan

$$\Delta v_{jk} = mc * \Delta v_{jk}(\text{epoch sebelumnya}) + (1 - mc) * \alpha \phi 1_{ij} \quad (15)$$

## 2. Fungsi Pelatihan TRAINGDA

Setelah bobot-bobot baru diperoleh berdasarkan persamaan (10) dan (11), cari kinerja jaringan syaraf dengan bobot-bobot baru tersebut (*perf2*). Kemudian bandingkan dengan kinerja jaringan dengan bobot sebelumnya (*perf*). Apabila  $\text{perf2}/\text{perf} > \text{max\_perf\_inc}$ , maka:

$$\alpha = \alpha * \text{ir\_dec} \quad (16)$$

Namun, jika  $\text{perf2}/\text{perf} < \text{max\_perf\_inc}$ , maka:

$$\alpha = \alpha * \text{ir\_inc} \quad (17)$$


Untuk  $\text{perf2}/\text{perf} \leq \text{max\_perf\_inc}$ , maka bobot baru diterima sebagai bobot sekarang.

## E. Software Matlab

Matlab atau *Matrix Laboratory* merupakan bahasa pemrograman yang dikembangkan oleh The Mathwork Inc. Matlab menjadi bahasa pemrograman komputer generasi keempat yang banyak digunakan untuk menyelesaikan berbagai masalah dengan melibatkan proses komputasi dalam berbagai bidang. *Software Matlab* memiliki kotak kakas (*toolbox*) yang bisa diaplikasikan dalam melakukan aplikasi-aplikasi khusus, seperti sistem kontrol, pengolahan sinyal, jaringan syaraf tiruan, logika fuzzy, optimalisasi, pengolahan citra digital, simulasi, serta teknologi lainnya. Dalam penelitian ini akan menggunakan *software Matlab*. *Software Matlab* dipilih dan digunakan dalam penelitian ini karena memiliki *toolbox neural network*. *Toolbox* tersebut dapat digunakan untuk melakukan prediksi dengan JST sehingga akan membantu dan memudahkan dalam penelitian ini.

## F. PT PLN (Persero) UP3 Salatiga

PT PLN (Persero) UP3 Salatiga merupakan adalah sebuah Badan Usaha Milik Negara (BUMN) penyedia jasa ketenaga listrikan yang berkedudukan di Jl. Diponegoro No. 19, Salatiga, Kec. Sidorejo, Kota Salatiga, 50711. Wilayah kerja PT PLN (Persero) UP3 Salatiga meliputi enam Pemerintahan Daerah Tingkat II yaitu Kab. Grobogan, Kab. Boyolali, Kab. Semarang, Kota Semarang, Kab. Temanggung, Kota Salatiga. Dalam menyediakan jasa ketenagalistrikan PT. PLN (Persero) UP3 Salatiga dibantu tiga ULP (Unit Layanan Pelangan) yaitu: ULP Salatiga Kota, ULP Ungaran, ULP Ambarawa.



Gambar 2. Wilayah Kerja PT PLN (Persero) UP3 Salatiga

PT PLN (Persero) UP3 Salatiga pada tahun 2021 telah memiliki jumlah konsumen hingga 428,176, dengan peningkatan jumlah pelanggan rata-rata setiap tahunnya sebanyak 14,583 pelanggan atau 3.7%. PLN ini mampu mensuplai energi listrik ke konsumen hingga 300 MVA. Total konsumsi energi listrik tahun 2017 hingga 2021 mencapai 6,304,298,572 KWh, dengan peningkatan konsumsi energi listrik pelanggan rata-rata setiap tahunnya sebesar 53,507,778 KWh atau 4,3%.

## III. METODE PENELITIAN

### A. Objek Penelitian

Data yang digunakan pada penelitian ini merupakan data konsumsi energi listrik cakupan wilayah kerja PT PLN (Persero) UP3 Salatiga Variabel yang akan digunakan yaitu variabel bebas (X1 s.d. X12) adalah konsumsi energi listrik pada bulan Januari 2017 sampai bulan Desember 2017, variabel terikat (Y) adalah konsumsi energi listrik pada bulan Januari 2018. Lalu akan membentuk pola seterusnya dengan mengurangi satu bulan awal dan menambah satu bulan terakhir. Pola data penelitian ini dapat dipahami pada Tabel 1.

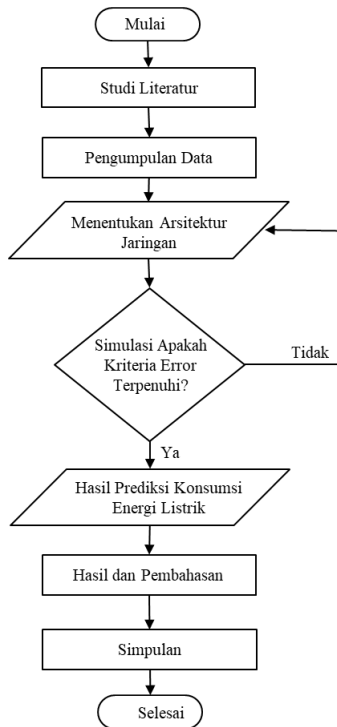
Tabel 1. Pola Data Prediksi Konsumsi Energi Listrik

| Data Input                    | Data Target        |
|-------------------------------|--------------------|
| Data input bulan ke-1 - ke-12 | Target bulan ke-13 |
| Data input bulan ke-2 - ke-13 | Target bulan ke-14 |
| -                             | -                  |
| Data input bulan ke-n - ke-n  | Target bulan ke-n  |

### B. Desain Penelitian

Desain penelitian ini direpresentasikan dalam bentuk diagram alir yang ditunjukkan pada Gambar 3.





Gambar 3. Diagram Alir Penelitian.

### C. Pengumpulan Data

Teknik pengumpulan data merupakan teknik atau cara yang digunakan peneliti dalam mendapatkan data untuk penelitian. Adapun teknik pengumpulan data yang digunakan dalam penelitian ini yaitu studi literatur, wawancara, dan dokumentasi.

### D. Analisis Data

Model JST yang akan dibangun akan diolah dalam lima langkah yaitu pengumpulan data, pra-pemrosesan data, membangun jaringan, training, dan menguji kinerja model [20]. Perangkat lunak atau *software* yang digunakan yaitu Matlab R2021a yang dilengkapi dengan *Toolbox Neural Network* untuk melakukan prediksi konsumsi energi listrik.

#### 1. Pra-pemrosesan Data

##### a. Normalisasi data

Data penelitian yang yang didapatkan memiliki rentang yang tidak terbatas sehingga data yang diperoleh harus dilakukan normalisasi menjadi data yang memiliki rentang yang terbatas dengan rentang 0 sampai 1. Sebab dalam penelitian ini akan menggunakan JST multilayer perceptron dengan fungsi sigmoid biner yang memiliki range 0 sampai 1. Normalisasi data dapat dilakukan menggunakan persamaan 18 [21].

$$y = \frac{x - \min}{\max - \min} (0,8) + 0,1 \quad (18)$$

Keterangan:

- y : nilai data hasil normalisasi
- x : nilai data awal (sebelum normalisasi)
- min : nilai data terkecil
- max : nilai data terbesar


#### b. Pola data

Gambaran pola data dalam penelitian dijelaskan pada Tabel 3.2. Berdasarkan pola data yang dijelaskan pada Tabel 3.2. untuk susunan pola data proses training jaringan akan membentuk matriks 12 x 30 dengan matriks target 1 x 30. Sedangkan data untuk testing jaringan akan membentuk matriks 12 x 6 dengan matriks target 1 x 6.

### 2. Membangun Jaringan

#### a. Arsitektur Jaringan

*Input layer* penelitian ini terdiri dari 12 neuron *input* yang dibentuk berdasarkan siklus 12 bulan, untuk perubahan pada tiap pola dengan mengurangi satu bulan lama lalu menambah satu bulan baru. Jumlah *hidden layer* dan *node hidden layer* merupakan parameter yang akan diujikan dan jumlahnya akan diubah-ubah, dengan jumlah hidden layer yaitu 1, 2, 3, 4, dan 5. Jumlah *node* pada *hidden layer* 2, 3, 4, 5, 10, 15, 20, dan 25. Lapisan *output* terdiri 1 neuron yang menjadi target 1 bulan dari setiap pola. Gambaran umum dari arsitektur jaringan ditampilkan pada Gambar 4.



Gambar 4. Arsitektur Jaringan.

#### b. Fungsi Pelatihan

Fungsi pelatihan yang digunakan dalam penelitian ini yaitu:

##### a) TRAINGDM

TRAINGDM (*Gradient Descent dengan Momentum/GDM*) merupakan pelatihan jaringan yang memperbarui nilai bobot dan bias berdasarkan turunan gradien dengan momentum.

##### b) TRAINGDA

TRAINGDA (*Gradient Descent dengan Adaptive Learning Rate/GDA*) merupakan fungsi pelatihan jaringan yang memperbarui nilai bobot dan bias berdasarkan turunan gradien dengan pembelajaran yang bersifat adaptif.

### 3. Training

Tahap *training* dilakukan untuk mendapatkan bobot baru berdasarkan parameter JST yang telah ditentukan,

bobot baru tersebut selanjutnya akan diujikan pada tahap testing.

#### 4. Menguji Kinerja Model

##### a. Testing

Tahap *testing* dilakukan ketika tahap *training* JST sudah selesai serta memiliki hasil *output* jaringan yang memenuhi kriteria. Selama proses *training*, JST akan memperoleh bobot baru. Bobot baru tersebut akan diuji menggunakan data konsumsi energi listrik PT PLN (Persero) UP3 Salatiga bulan Juli 2020 – Desember 2021 untuk mengetahui apakah bobot baru tersebut dapat menghasilkan output sesuai target ataukah belum.

##### b. Menghitung nilai error

Tahap ini dilakukan untuk mengetahui nilai *error* dari hasil prediksi pada tahap *training* dan *testing*. Evaluasi error yang akan dilakukan dalam penelitian ini dengan MAD, MAPE, dan MSE [22].

##### a) MAD

MAD (*Mean Absolute Deviation*) merupakan rata-rata kesalahan absolut (mutlak) hasil prediksi tanpa memperhatikan lebih besar atau lebih kecil hasil prediksi tersebut terhadap kenyataannya, sehingga MAD dapat diartikan rata-rata dari nilai absolut simpangan. Secara matematis MAD dirumuskan seperti pada persamaan 19.

$$MAD = \frac{\sum_{t=1}^n |X_t - F_t|}{n} \quad (19)$$

Keterangan:

$X_t$  = data aktual pada periode (t) tertentu

$F_t$  = nilai peramalan pada periode (t) tertentu

$n$  = jumlah data

##### b) MSE

MSE (*Mean Squared Error*) merupakan cara untuk mengevaluasi hasil prediksi pada tahap *training* dengan mengkuadratkan kesalahan. Dalam penelitian ini nilai MSE setiap jaringan akan diketahui secara otomatis dari tahap *training* dengan klik *performance*. Sedangkan secara matematis MSE dirumuskan seperti pada persamaan 20.

$$MSE = \frac{\sum_{t=1}^n (X_t - F_t)^2}{n} \quad (20)$$

Keterangan  $X_t$ ,  $F_t$ , dan  $n$  sama dengan persamaan 19

##### c) MAPE

MAPE (*Mean Absolute Percentage Error*) merupakan ukuran kesalahan relatif yang menyatakan persentase kesalahan hasil prediksi terhadap nilai aktual selama periode tertentu. Secara matematis MSE dirumuskan seperti pada persamaan 21.

$$MAPE = \left( \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - F_t}{X_t} \right| \right) \times 100\% \quad (21)$$

Keterangan  $X_t$ ,  $F_t$ , dan  $n$  sama dengan persamaan 19

Persentase nilai MAPE menunjukkan kemampuan prediksi seperti yang ditunjukkan pada Tabel 2.

Tabel 2. Kriteria Nilai MAPE Pada Prediksi

| No. | Nilai MAPE | Akurasi Prediksi |
|-----|------------|------------------|
| 1.  | <10%       | Sangat Baik      |
| 2.  | 10-20%     | Baik             |
| 3.  | 20-50%     | Cukup            |
| 4.  | >50%       | Buruk            |

##### c. Prediksi konsumsi energi listrik

Tahap prediksi konsumsi energi listrik dilakukan setelah proses *training* dan *testing* telah selesai, serta hasil *testing* diperoleh *output* yang mendekati target. Hasil yang diperoleh tersebut menunjukkan jika nilai bobot baru sudah sesuai dengan data deret waktu sesuai susunan pola yang diberikan selama proses *training*. Lalu bobot baru tersebut selanjutnya akan digunakan dalam melakukan prediksi konsumsi energi listrik PT PLN (Persero) UP3 Salatiga tahun 2022 – 2026. Adapun data yang digunakan untuk proses prediksi ini menggunakan susunan yang sama seperti data pengujian. Untuk memprediksi satu bulan berikutnya dapat dengan menghilangkan satu pola lama lalu menambah satu pola baru yang tersusun berdasarkan data hasil prediksi.

##### d. Denormalisasi data

Data yang *output* yang diperoleh dari hasil *training*, *testing*, dan prediksi jaringan merupakan data normalisasi yaitu data dengan range yang terbatas dengan range 0 sampai 1 sesuai dengan jenis data yang digunakan sebagai input. Sehingga data tersebut harus didenormalisasi untuk mengetahui nilai asli dari data *output* yang didapatkan. Denormalisasi data dapat dilakukan menggunakan persamaan 3.2 [21].

$$y' = \frac{x' - 0,1}{0,8} (max - min) + min \quad (22)$$

Keterangan:

$y'$  : nilai data hasil denormalisasi

$x'$  : nilai data sebelum denormalisasi

min : nilai data terkecil

max : nilai data terbesar

## IV. ANALISA KUALITAS JARINGAN

### A. Analisa Hasil Drive Test Di Area Purwokerto

Pengambilan data *drive test* dilakukan dengan *drive test* menggunakan metode *moving* atau bergerak. Hasil pengambilan data kualitas sinyal berdasarkan parameter 4G LTE pada provider H3I di daerah yang telah ditentukan yaitu RSRP (*Reference Signal Received Power*) dan SINR (*Signal to Interference and Noise Ratio*).


### B. Analisa Hasil RSRP dan SINR Bulan Desember 2019

Untuk nilai RSRP jaringan 4G di daerah Purwokerto pada bulan Desember 2019 dapat dikatakan memiliki kuat sinyal yang baik.

Tabel 3. Jumlah Titik Nilai RSRP Bulan Desember 2019

| Warna | Nilai RSRP (dBm) | Jumlah Titik |
|-------|------------------|--------------|
| ●     | -80 to 0         | 810          |
| ●     | -95 to -80       | 3539         |
| ●     | -100 to -95      | 786          |
| ●     | -105 to -100     | 390          |
| ●     | -140 to -105     | 106          |
|       | Total            | 5631         |

Pada tabel 3 menunjukkan hasil kualitas jaringan di daerah purwokerto Untuk *range* -80 sampai 0 adalah 810 titik, untuk *range* -95 sampai -80 adalah 3539 titik, untuk *range* -100 sampai -95 adalah 786 titik, untuk *range* -105 sampai -100 adalah 390 titik dan *range* -140 sampai -105 adalah 106 titik. Berikut tampilan hasil kualitas jaringan pada *Map Info*:



Gambar 2. Hasil Peta *Thematic* Nilai RSRP Pada Bulan Desember 2019

Tabel 4. Jumlah Titik Nilai SINR Bulan Desember 2019

| Warna | Nilai SINR (dB) | Jumlah Titik |
|-------|-----------------|--------------|
| ●     | -20 to 0        | 588          |
| ●     | 0 to 6          | 869          |
| ●     | 6 to 8          | 313          |
| ●     | 8 to 12         | 595          |
| ●     | 12 to 30        | 1378         |
|       | Total           | 3743         |

Pada tabel 4 menunjukkan hasil kualitas sinyal. Untuk *range* -20 sampai 0 adalah 588 titik, *range* 0 sampai 6 adalah 869 titik, *range* 6 sampai 8 adalah 313 titik, *range* 8 sampai 12 adalah 595 titik dan *range* 12 sampai 30 adalah 1378 titik.


### C. Analisa Hasil RSRP dan SINR Bulan Maret 2020

Untuk nilai RSRP jaringan 4G di daerah Purwokerto pada bulan Maret 2020 dapat dikatakan memiliki kuat sinyal yang baik,

Tabel 5. Jumlah Titik Nilai RSRP Bulan Maret 2020

| Warna | Nilai RSRP (dBm) | Jumlah Titik        |                  | Persentase          |                  |
|-------|------------------|---------------------|------------------|---------------------|------------------|
|       |                  | Bulan Desember 2019 | Bulan Maret 2020 | Bulan Desember 2019 | Bulan Maret 2020 |
| ●     | -80 to 0         | 810                 | 1403             | 14.38%              | 30.71%           |
| ●     | -95 to -80       | 3539                | 2337             | 62.85%              | 51.15%           |
| ●     | -100 to -95      | 786                 | 481              | 13.96%              | 10.53%           |
| ●     | -105 to -100     | 390                 | 221              | 6.93%               | 4.84%            |
| ●     | -140 to -105     | 106                 | 127              | 1.88%               | 2.78%            |
|       | Total            | 3763                | 5631             | 100%                | 100%             |
|       | ≥-95 dBm         | 2152                | 4349             | 77.23%              | 81.86%           |

Pada tabel 5 menunjukkan hasil parameter RSRP. Untuk *range* -80 sampai 0 adalah 1403 titik, *range* -95 sampai -80 adalah 2337 titik, *range* -100 sampai -95 adalah 481 titik, *range* -105 sampai -100 adalah 221 titik dan *range* -140 sampai -105 adalah 127 titik dan jumlah total nilai RSRP adalah 4569 titik.



Gambar 3 Hasil Peta *Thematic* Nilai RSRP Pada Bulan Maret 2020

Pada gambar 3 menampilkan hasil kualitas sinyal jaringan 4G dengan kategori warna yang telah ditentukan oleh provider H3I dengan tabel *range* parameter RSRP.

Tabel 6. Jumlah Titik Nilai SINR Bulan Maret 2020

| Warna | Nilai SINR (dB) | Jumlah Titik |
|-------|-----------------|--------------|
| ●     | -20 to 0        | 591          |
| ●     | 0 to 6          | 632          |
| ●     | 6 to 8          | 242          |
| ●     | 8 to 12         | 531          |
| ●     | 12 to 30        | 1706         |
|       | Total           | 3702         |

Pada tabel 6 menunjukkan kuat sinyal baik hingga buruk. Untuk *range* -20 sampai 0 adalah 591 titik, *range* 0 sampai 6 adalah 632 titik, *range* 6 sampai 8 adalah 242 titik, *range* 8 sampai 12 adalah 531 titik dan *range* 12 sampai 30 adalah 1706 titik.

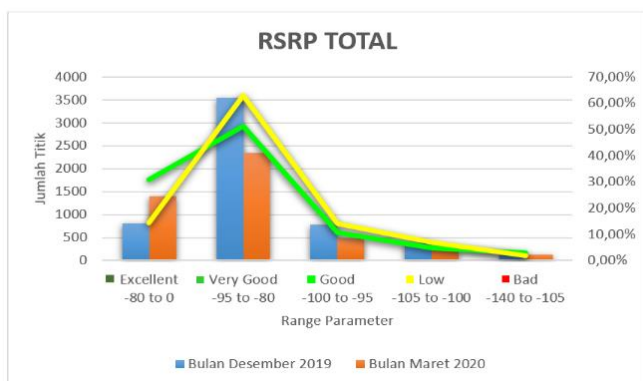
## V. ANALISA RSRP TOTAL

Pada hasil analisa secara menyeluruh pengukuran nilai RSRP bulan Desember 2019 dan Maret 2020 di daerah Purwokerto mengalami kenaikan kualitas jaringan, berikut hasil perbandingannya:

Tabel 7. Hasil Persentase Nilai RSRP Pada Bulan Desember 2019 dan Bulan Maret 2020

| Warna | Nilai RSRP (dBm) | Jumlah Titik |
|-------|------------------|--------------|
| ●     | -80 to 0         | 1403         |
| ●     | -95 to -80       | 2337         |
| ●     | -100 to -95      | 481          |
| ●     | -105 to -100     | 221          |
| ●     | -140 to -105     | 127          |
| Total |                  | 4569         |

Pada tabel 7 menunjukkan bahwa nilai parameter RSRP pada bulan Maret 2020 mengalami kenaikan kualitas jaringan dengan hasil persentase 11.63% untuk nilai RSRP  $\geq -95$  dBm. Berikut grafik RSRP total:



Gambar 4. Grafik Total Nilai RSRP Bulan Desember 2019 dan Maret 2020 di Purwokerto


## VI. ANALISA SINR TOTAL

Pada hasil analisa secara menyeluruh pengukuran nilai SINR bulan Desember 2019 dan Maret 2020 di daerah Purwokerto sudah mengalami kenaikan kualitas jaringan, berikut hasil perbandingannya:

Tabel 8. Hasil Persentase Nilai SINR Pada Bulan Desember 2019 dan Bulan Maret 2020

| Warna | Nilai SINR (dB) | Jumlah Titik        |                  | Persentase          |                  |
|-------|-----------------|---------------------|------------------|---------------------|------------------|
|       |                 | Bulan Desember 2019 | Bulan Maret 2020 | Bulan Desember 2019 | Bulan Maret 2020 |
| ●     | -20 to 0        | 588                 | 591              | 15.71%              | 15.96%           |
| ●     | 0 to 6          | 869                 | 632              | 23.22%              | 17.07%           |
| ●     | 6 to 8          | 313                 | 242              | 8.36%               | 6.54%            |
| ●     | 8 to 12         | 595                 | 531              | 15.90%              | 14.34%           |
| ●     | 12 to 30        | 1378                | 1706             | 36.82%              | 46.08%           |
| Total |                 | 3743                | 3702             | 100%                | 100%             |
|       | $\geq 12$ dB    | 1378                | 1706             | 36.82%              | 46.08%           |

Pada tabel 8 menunjukkan hasil pengukuran kualitas jaringan parameter SINR bulan Maret 2020 mengalami kenaikan kualitas jaringan dengan hasil persentase 46.08% untuk nilai SINR  $\geq 12$  dB. Berikut grafik total SINR:



Gambar 5. Grafik Total Nilai SINR Bulan Desember 2019 dan Maret 2020 di Purwokerto

## VII. KESIMPULAN

Dari hasil penelitian serta pembahasan mengenai implementasi *multilayer perceptron artificial neural network* untuk prediksi konsumsi energi listrik PT PLN (Persero) UP3 Salatiga, dapat disimpulkan sebagai berikut:

1. Pemodelan *multilayer perceptron artificial neural network* terbaik untuk prediksi konsumsi energi listrik PT PLN (Persero) UP3 Salatiga tahun 2022-2026 yaitu TRAIINGDA 4 *hidden layer* dengan 20 *node hidden layer*, model jaringan ini pada tahap *training* menghasilkan *output* dengan nilai MAD sebesar 2,624,072 kWh dan MAPE sebesar 2.79%. serta pada tahap *testing* menghasilkan *output* dengan nilai MAD sebesar 3,728,386 kWh dan MAPE sebesar 3.24%. Variasi jaringan ini dapat menghasilkan *output* dengan MAD dan MAPE terkecil tahap *testing*, sehingga jaringan tersebut yang kemudian digunakan untuk proses prediksi konsumsi energi listrik pada PT PLN (Persero) UP3 Salatiga.
2. Hasil prediksi konsumsi energi listrik di PT PLN (Persero) UP3 Salatiga menggunakan *multilayer perceptron artificial neural network* dengan model jaringan TRAIINGDA 4 *hidden layer* dengan 20 *node hidden layer*, konsumsi energi listrik pada wilayah kerja tersebut selama 5 tahun kedepan cukup fluktuatif pada tahun 2022 sebesar 1,278,867,573 kWh, tahun 2023 sebesar 1,274,074,800 kWh, tahun 2024 sebesar 1,272,107,991 kWh, tahun 2025 sebesar 1,272,151,388 kWh, dan tahun 2026 sebesar 1,273,323,104 kWh. Total konsumsi energi listrik 5 tahun kedepan mencapai 6,370,524,854 kWh dan rata-rata per tahun sebesar 1,274,104,970 kWh.



## DAFTAR PUSTAKA

- [1] [1]Alkuma, Yulian Mara, Hermawan, dan Hadiyanto, "Pengembangan Potensi Energi Alternatif Dengan Pemanafaatan Limbah Cair Kelapa Sawit Sebagai Sumber Energi Baru Terbarukan Di Kabupaten Kotawaringin Timur," *Jurnal Ilmu Lingkungan*, vol. 14, no. 2, 96-102, 2016.
- [2] ESDM, "Statistik ketenagalistrikan 2020," *Sekretariat Direktorat Jenderal Ketenagalistrikan*, Jakarta. 2021.
- [3] Rajagukguk, Agus Sofyan F., IMarthinus Pakiding, dan Meita Rumbayan, "Kajian Perencanaan Kebutuhan dan Pemenuhan Energi Listrik di Kota Manado," *Jurnal Teknik Elektro dan Komputer*, vol. 4, no. 3, 1-11, 2015.
- [4] Triwulan, Yayu, Nasrun Hariyanto, dan Sabat Anwari, "Peramalan Beban Puncak Listrik Jangka Pendek Menggunakan Metode Jaringan Syaraf Tiruan," *Jurnal Reka Elkomika*, vol. 1, no. 4, 339-350, 2013.
- [5] Saragih, Irfan Christian, Dedy Hartama, dan Anjar Wanto, "Prediksi Perkembangan Jumlah Pelanggan Listrik Menurut Pelanggan Area Menggunakan Algoritma Backpropagation," *Building of Informatics, Technology and Science (BITS)*, vol. 2, no. 1, 48-54, 2020.
- [6] Pratama, Ricky Ardian dan Lilik Anifah, "Peramalan Beban Listrik Jangka Panjang Provinsi D.I. Yogyakarta Menggunakan *Neural Network Backpropagation*," *Jurnal Teknik Elektro*, vol. 5, no. 3, 37 – 47, 2016.
- [7] Sakinah, Nabilla Putri, Imam Cholissodin, dan Agus Wahyu Widodo, "Prediksi Jumlah Permintaan Koran Menggunakan Metode Jaringan Syaraf Tiruan *Backpropagation*," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 7, 2612-2618, 2018.
- [8] Simangunsong, Fitri Ruth Diani Br. dan Surya Darma Nasution, "Aplikasi Jaringan Syaraf Tiruan Untuk Memprediksi Jumlah Pasien Rawat Inap Dengan Metode *Back Propagation* (Studi Kasus : RSU. Tere Margareth)," *Jurnal Riset Komputer (JURIKOM)*, vol. 2, no. 6, 43-47, 2015.
- [9] Irfan, Muhammad, Bakhtiar Alldino Ardi Sumbodo, dan Ika Candradewi, "Sistem Klasifikasi Kendaraan Berbasis Pengolahan Citra Digital dengan Metode *Multi-layer Perceptron*," *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, vol. 7, no. 2, 139-148, 2017.
- [10] Hadimarta, Tommy Ferdian, Rani Rotul Muhima, dan Muchammad Kurniawan, "Implementasi Multilayer Perceptron Pada Jaringan Syaraf Tiruan Untuk Memprediksi Nilai Valuta Asing," *INTEGER: Journal of Information Technology*, vol. 5, no. 1, 56-63, 2020.
- [11] Saritas, Mucahid Mustafa dan Ali Yasar, "*Performance Analysis of ANN and Naive Bayes Classification Algorithm for Data Classification*," *International Journal of Intelligent Systems and Applications in Engineering*, vol. 7, no. 2, 88-91, 2019.
- [12] Aulia, Romy, "Penerapan Metode *Backpropagation* Untuk Memprediksi Jumlah Kunjungan Wisatawan Berdasarkan Tingkat Hunian Hotel," *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, vol. 4, no. 2, 1-8, 2018.
- [13] Dudek, Grzegorz, "*Multilayer Perceptron For Short-Term Load Forecasting: From Global To Local Approach*," *Neural Computing and Applications*, vol. 32, no. 8, 3695-3707, 2020.
- [14] Madhiarasan, Manogaran dan Mohamed Louzazni, "*Different forecasting horizons based performance analysis of electricity load forecasting using multilayer perceptron neural network*," *Forecasting*, vol. 3, no. 4, 804-838, 2021.
- [15] Hartati, "Penggunaan Metode Arima Dalam Meramal Pergerakan Inflasi," *Jurnal Matematika, Saint, dan Teknologi*, vol. 18, no. 1, 1-10, 2017.
- [16] Nurhayati, "Jaringan Saraf Tiruan Backpropagation Untuk Menentukan Tingkat Pencemaran Air," *E-JURNAL JUSITI: Jurnal Sistem Informasi dan Teknologi Informasi*, vol. 4, no. 2, 124-131, 2015.
- [17] Sinaga, Dewantara, "Jaringan Saraf Tiruan Infeksi Mata dengan Menggunakan Metode Berarsitektur *Multi Layer Perceptron*," *Jurnal Majalah Ilmiah Informasi dan Teknologi Ilmiah (INTI)*, vol. 7, no. 2, 189-192, 2020.
- [18] Simbolon, Imelda Asih Rohani, Fikri Yatussa'ada, dan Anjar Wanto, "Penerapan Algoritma *Backpropagation* dalam Memprediksi Persentase Penduduk Buta Huruf di Indonesia," *Jurnal Informatika UPGRI*, vol. 4, no. 2, 163-169, 2018.
- [19] Kusumadewi, Sri, "Membangun Jaringan Syaraf Tiruan Menggunakan Matlab & Excel Link," Yogyakarta: Graha Ilmu, 2004.
- [20] Rodrigues, Filipe, Carlos Cardeira, dan J.M.F.Calado, "*The Daily And Hourly Energy Consumption And Load Forecasting Using Artificial Neural Network Method: A Case Study Using A Set Of 93 Households In Portugal*," *Energy Procedia*, vol. 6, no. 2, 220-229, 2014.
- [21] Rachman, Adi Sukarno, Imam Cholissodin, dan M. Ali Fauzi, "Peramalan Produksi Gula Menggunakan Metode Jaringan Syaraf Tiruan *Backpropagation* Pada PG Candi Baru Sidoarjo," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 4, 1683-1689, 2018.
- [22] Astuti, Yuli, Berliana Novianti, Tonny Hidayat, dan Dina Maulina, "Penerapan Metode *Single Moving Average* untuk Peramalan Penjualan Mainan Anak," *Seminar Nasional Sistem Informasi dan Teknologi Informasi*, 253-261, 2019.