



## Kinerja jaringan saraf berbasis backpropagation dan LVQ sebagai algoritme fingerprint RSS LoRa untuk penentuan posisi pada ruang terbuka

*Neural network performance based on backpropagation and LVQ as the LoRa RSS fingerprint algorithms for positioning in an open space*

Misbahuddin<sup>\*</sup>, Muhamad Syamsu Iqbal, Giri Wahyu Wiriasto, L. Ahmad, S. Irfan Akbar, Muhammad Irwan

*Jurusan Teknik Elektro, Fakultas Teknik, Universitas Mataram  
Jl. Majapahit No. 62 Mataram, Nusa Tenggara Barat, Indonesia 83125*

**Cara sitasi:** M. Misbahuddin, M. S. Iqbal, G. W. Wiriasto, L. Ahmad, S. I. Akbar, and M. Irwan, "Kinerja jaringan saraf berbasis backpropagation dan LVQ sebagai algoritme fingerprint RSS LoRa untuk penentuan posisi pada ruang terbuka," *Jurnal Teknologi dan Sistem Komputer*, vol. 8, no. 2, pp. 121-126, 2020. doi: [10.14710/jtsiskom.8.2.2020.121-126](https://doi.org/10.14710/jtsiskom.8.2.2020.121-126), [Online].

**Abstract – Outdoor positioning is one of the important applications in the Internet of things (IoT). The usage of GPS is unsuitable for low-power IoT devices. Alternatively, it can use the LoRa devices. This research aims to find a better method as the fingerprint algorithm for determining the outdoor position using RSS LoRa. The methods used as the fingerprint algorithm were two artificial neural network models, i.e. backpropagation (BP) with four types of training methods and learning vector quantization (LVQ) with two types of training methods. The experiment results show the performance of LVQ1 better than those of LVQ2. Besides, the LVQ1 was also better than the BP method. However, both BP and LVQ2 have a performance that is almost similar to about 70 %. Both of the artificial neural network models, BP and LVQ, can be used as a fingerprint algorithm to determine quite accurate the outdoor object position.**

**Keywords** – neural network; backpropagation; learning vector quantization; fingerprint algorithm; RSS LoRa

**Abstrak – Penentuan posisi ruang terbuka merupakan salah satu aplikasi penting pada internet of things. Penggunaan GPS tidak cocok untuk perangkat IoT yang berdaya rendah. Sebagai alternatif digunakan perangkat LoRa. Penelitian ini bertujuan untuk menemukan metode yang lebih baik sebagai algoritme fingerprint dalam menentukan posisi objek pada ruang terbuka berdasarkan RSS LoRa. Metode yang digunakan sebagai algoritme fingerprint adalah dua model jaringan saraf tiruan, yaitu backpropagation (BP) dengan empat jenis metode pelatihan dan learning vector quantization (LVQ) dengan dua metode pelatihan. Hasil eksperimen menunjukkan bahwa kinerja LVQ1 lebih baik dibanding LVQ2. Selain itu, kinerja LVQ1 juga lebih baik dibandingkan**

**BP, sedangkan metode BP dan LVQ2 memiliki tingkat keberhasilan hampir sama di sekitar 70 %. Kedua model jaringan saraf tiruan, baik BP maupun LVQ, dapat digunakan sebagai algoritme fingerprint untuk menentukan posisi objek pada ruang terbuka dengan akurasi yang cukup tinggi.**

**Kata Kunci** – jaringan saraf tiruan; propagasi balik; kuantisasi vektor pembelajaran; algoritme fingerprint; RSS LoRa

### I. PENDAHULUAN

Posisi objek merupakan salah satu informasi yang diperlukan oleh aplikasi context-awareness dalam *Internet of things* (IoT). Context-awareness didefinisikan sebagai kumpulan informasi relevan yang mengkarakterisasi kondisi atau situasi sebuah entitas yang berada pada suatu lingkungan tertentu untuk diberikan kepada pengguna [1]. Lingkungan tersebut dapat berupa ruang tertutup (*indoor*) maupun ruang terbuka (*outdoor*).

Akurasi posisi pada ruang terbuka sangat ditentukan oleh perangkat pelacak posisi yang digunakan. Penggunaan *global positioning system* (GPS) sebagai pelacak posisi yang umum digunakan dapat menunjukkan koordinat posisi dengan cukup akurat. Namun, perangkat ini mengonsumsi arus sebesar 30 – 50 mA ketika memperoleh suatu posisi yang dicapai dalam waktu sekitar 10 detik [2]. GPS dengan konsumsi energi yang cukup besar tidak cocok untuk context-awareness pada aplikasi IoT. Oleh karena itu, diperlukan cara lain dalam menentukan posisi, yaitu dengan metode *fingerprint*.

Metode *fingerprint* adalah mengukur kekuatan sinyal (*recieved strength signal*, RSS) beberapa pengirim yang diterima oleh sebuah penerima yang merepresentasikan posisi sebuah objek. Perangkat pengirim/penerima dapat menggunakan perangkat berjarak jangkau pendek (*short range*), seperti RFID/NFC [3], BLE 802.15.1 [4], dan WiFi 802.11x [5]. Perangkat lainnya adalah yang berjarak jangkau

<sup>\*</sup>) Penulis korespondensi (Misbahuddin)  
Email: misbahuddin@unram.ac.id

menengah (*medium range*), seperti WPAN 802.15.3 atau Zigbee 802.15.4 [6], [7]. Perangkat yang berjarak jangkau jauh (*long range*) yang digunakan di antaranya adalah SigFox [8], [9], LoRa [10], dan NB-IoT [11].

Aspek penting lain dari *context-awareness* pada ruang terbuka adalah cakupan luasan lingkungan yang ingin dilingkupi. Aspek ini sangat bergantung kepada pemilihan penggunaan perangkat komunikasi yang cocok untuk lingkungan IoT. Perangkat komunikasi yang paling cocok untuk tujuan tersebut adalah *Low Power Wide Area Networks* (LPWANs) seperti SigFox, LoRa, dan NB-IoT. Kombinasi penggunaan metode *fingerprint* dan perangkat komunikasi LPWANs dapat memenuhi persyaratan *context-awareness* ruang terbuka pada IoT karena memiliki cakupan yang luas dan konsumsi energi yang lebih rendah.

Algoritme yang dapat digunakan pada metode dihasilkan. Semua penelitian tentang penentuan posisi yang menggunakan metode *fingerprint* sebagaimana disebutkan sebelumnya hanya menggunakan salah satu metode yang ada saat ini. Metode yang digunakan untuk *fingerprint* adalah di antaranya kNN [8], [9], jaringan saraf tiruan [7], dan *radial basis function* (RBF) [10]. Sampai saat ini belum ada kajian yang melakukan evaluasi kinerja beberapa algoritme untuk menguji tingkat akurasi yang terbaik. Oleh karena itu, penelitian bertujuan untuk melakukan eksperimen secara nyata (*test-bed*) menggunakan perangkat LoRa untuk melakukan penentuan posisi pada ruang terbuka melalui perbandingan algoritme jaringan saraf tiruan berbasis *backpropagation* (BP) dan *learning vector quantization* (LVQ).

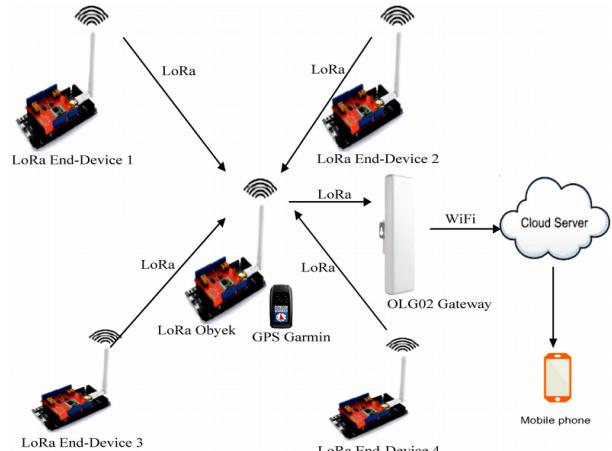
## II. METODE PENELITIAN

Penelitian ini memanfaatkan kekuatan sinyal yang diterima (*recieved signal strength indicator*, RSSI) dari perangkat LoRa sebagai representasi posisi sebuah objek. Konfigurasi jaringan LoRa *fingerprint* menggunakan empat perangkat LoRa *end-device* sebagai pengirim RSS ke LoRa objek dan satu perangkat LoRa Dragino OLGO2 sebagai *gateway* seperti ditunjukkan pada Gambar 1. Tipe perangkat LoRa yang digunakan adalah SX1278 yang bekerja pada frekuensi 433 MHz dengan bandwidth 125 KHz dan spreading factor (SF) bernilai 7.

Jaringan tersebut dipasang pada ruang terbuka sebagai lokasi eksperimen (*test-bed*) dengan luas 50 m x 150 m. Oleh karena luas jangkauan lokasi eksperimen tidak begitu luas, maka dipilih daya transmisi 14 dBm. Jenis antena yang digunakan adalah antena isotropik dengan gain antena pengirim dan penerima ( $G_t$  dan  $G_r$ ) masing-masing sebesar 1 dBi yang dipasang pada ketinggian 80 cm. Parameter jaringan LoRa tersebut diringkas pada Tabel 1.

### A. Tahapan penentuan posisi objek berbasis RSS

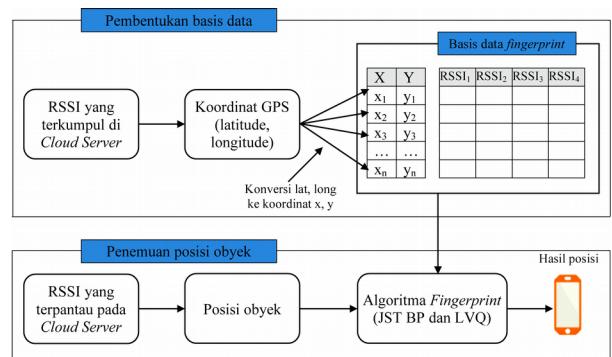
Penentuan posisi objek dilakukan melalui dua tahap, yaitu pembentukan basis data *fingerprint* dan penemuan posisi objek yang posisinya ditampilkan pada *mobile phone* sebagaimana ditunjukkan pada Gambar 2.



**Gambar 1.** Penentuan posisi menggunakan RSS LoRa

**Tabel 1.** Parameter jaringan LoRa *fingerprint*

Parameter	Nilai
Tipe perangkat LoRa	SX1278
Frekuensi	433 MHz
Bandwidth	125 KHz
Spreading factor (SF)	7
Daya transmisi	14 dBm
Gain antena ( $G_t$ dan $G_r$ )	1 dBi
Tinggi antena	80 cm



**Gambar 2.** Penemuan posisi dengan *fingerprint* LoRa

Tahap pertama, yaitu pembentukan basis data *fingerprint*, dilakukan dengan cara nilai RSSI yang diterima oleh LoRa objek secara bergantian dari empat LoRa *end-device*. Selanjutnya diteruskan melalui Lora *Gateway* Dragino OLGO2 ke server *cloud* untuk disimpan. LoRa *end-device* memiliki karakteristik pengiriman sinyal secara kontinyu dengan identitas unik sehingga LoRa objek mampu mengidentifikasi nilai masing-masing RSSI dari keempat LoRa *end-device*. Untuk mengatur agar LoRa objek dapat menerima RSSI dari keempat LoRa *end-device* secara bergantian, maka setiap LoRa *end-device* diberikan waktu tunda secara acak dalam melakukan pengiriman sinyal sebagaimana diatur pada Algoritme 1.

### Algoritme 1. Pengiriman RSSI

**Input:** waktuAkhir = 100

**Output:** RSSI

```
1: while waktuAkhir > 0 do
2:   Kirim RSSI()
3:   Tunda(interval + rand())
4:   waktuAkhir = waktuAkhir - 1
5: end while
```

Selain itu, setiap kali pengiriman nilai keempat RSSI tersebut ke server *cloud* juga diawali dengan pengiriman posisi koordinat (x, y) LoRa objek. Posisi LoRa objek diukur secara manual menggunakan GPS Garmin dengan koordinat (*latitude*, *longitude*). Koordinat ini dikonversi menjadi koordinat (x, y) menggunakan Persamaan 1 dan 2 [12].

$$x = 69,1 \times \|Lat_2 - Lat_1\| \quad (1)$$

$$y = 69,1 \times \|Lon_2 - Lon_1\| \times \cos(Lat_1 / 57,3) \quad (2)$$

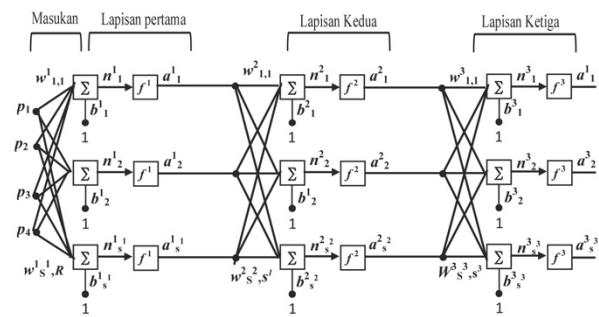
Parameter *Lat<sub>1</sub>* dan *Lon<sub>1</sub>* menyatakan koordinat (*latitude*, *longitude*) dari posisi LoRa *end-device* 1 sebagai referensi bagi posisi semua perangkat LoRa. *Lat<sub>2</sub>* dan *Lon<sub>2</sub>* menyatakan koordinat (*latitude*, *longitude*) dari posisi sesaat LoRa objek. Konstanta 69,1 dan 57,3 masing-masing digunakan untuk mengkonversi derajat *latitude* dan *longitude* ke koordinat x dan y pada jarak permukaan tanah dalam satuan mil [13].

Nilai keempat RSSI LoRa *end-device* berserta posisi koordinat (x, y) LoRa objek disimpan di server *cloud* sebagai basis data *fingerprint*. Basis data *fingerprint* tersebut digunakan untuk pelatihan algoritme jaringan saraf tiruan-*backpropagation* (JST-BP) dan jaringan saraf tiruan-*learning vector quantization* (JST-LVQ).

Tahap kedua, yaitu penemuan posisi LoRa objek, dilakukan melalui nilai RSSI yang diterima secara langsung oleh LoRa objek dari keempat LoRa *end-device*. Nilai RSSI tersebut merepresentasikan posisi sesaat LoRa objek. Prosedur penemuan posisi LoRa objek adalah masing-masing LoRa *end-device* mengirim nilai RSSI secara bergantian ke LoRa objek. Keempat nilai RSSI tersebut dijadikan sebagai nilai masukan bagi algoritme *fingerprint* dalam memprediksi posisi LoRa objek. Algoritme *fingerprint*, yaitu JST-BP atau JST-LVQ, digunakan untuk memprediksi posisi sesaat LoRa objek. Hasil prediksi tersebut ditampilkan pada perangkat *mobile phone*.

### B. Jaringan saraf tiruan *backpropagation* (JST-BP)

Jaringan saraf tiruan merupakan jaringan yang terinspirasi oleh jaringan saraf biologis manusia dan memiliki kemiripan prinsip kerja dari keduanya. Kemiripannya adalah setiap sel saraf (*neuron*) terhubung secara penuh antara satu dengan yang lainnya walaupun sel saraf tiruan sangat sederhana dibanding sel saraf biologis. Selain itu, hubungan antar sel saraf tiruan ditentukan oleh sebuah fungsi jaringan. Tujuan utama pembentukan jaringan tersebut adalah untuk menentukan



Gambar 3. Jaringan syarat tiruan multilayer [14]

hubungan dengan tepat untuk menyelesaikan persoalan rumit yang sulit dimodelkan secara matematis.

Gambar 3 menunjukkan jaringan saraf tiruan *multilayer* dengan struktur 3 lapis [14]. Lapisan pertama dan kedua disebut sebagai lapisan tersembunyi dan lapisan ketiga adalah lapisan keluaran. Lapisan tersembunyi dapat dikembangkan menjadi beberapa lapisan lagi untuk mendapatkan hasil dengan tingkat akurasi yang tinggi.

Jaringan syarat tiruan bekerja dalam dua fase, yaitu fase pelatihan dan fase pengujian atau validasi. Pelatihan dilakukan secara berulang untuk memperoleh bobot terbaik sebagai informasi tersimpan dalam rangka mengenai semua informasi yang dilatihkan. Metode pelatihan yang paling sering digunakan adalah perambatan balik (*backpropagation*). Penelitian ini menggunakan empat metode pelatihan perambatan balik, yaitu *Levenberg-Marquardt* (LM) [15], *resilient backpropagation algorithm* (RPROP) [16], *random order weight* (RO) [17], dan *quasi-Newton backpropagation* (BFGS) [18].

### C. Learning vector quantization (LVQ)

Algoritme jaringan saraf tiruan LVQ diperkenalkan oleh Linde dkk. [19] dan Gray [20] sebagai algoritme yang digunakan untuk kompresi data. Algoritme ini kemudian dikembangkan untuk pengenalan pola [21]. Prinsip utama LVQ adalah membagi ruang masukan  $R^q$  ke dalam beberapa wilayah yang berbeda yang disebut dengan wilayah keputusan (*Voronoi cell*) dan setiap wilayah ditetapkan sebagai satu vektor *codebook* (*Voronoi*).

Pengelompokan wilayah dilakukan berdasarkan wilayah sekitar vektor masukan terhadap vektor *codebook*. Ruang masukan  $x$  dikelompokkan sebagai label tetangga terdekatnya di antara vektor *codebook*. Pada proses pelatihan, batas-batas wilayah keputusan dari vektor *codebook* diatur dan disesuaikan melalui proses perulangan. Saat ini terdapat lima versi algoritme pelatihan yang telah dikembangkan, yaitu LVQ1, LVQ2, LVQ3, OLVQ1 and CLVQ (*combined LVQ*). Penelitian ini menggunakan metode pelatihan LVQ1 dan LVQ2 mengikuti algoritme dalam [22].

### III. HASIL DAN PEMBAHASAN

Pengujian kinerja jaringan saraf tiruan untuk dilatih mengetahui posisi objek pada ruang terbuka dilakukan dengan dua arsitektur, yaitu JST-BP dan JST-LVQ. Arsitektur JST-BP diuji dengan empat metode pelatihan, yaitu Levenberg-Marquardt (LM), *resilient backpropagation algorithm* (RPROP), *random order weight* (RO), dan *quasi-Newton backpropagation* (BFGS). Arsitektur JST-LVQ diuji dengan dua metode pelatihan, yaitu LVQ 1 dan LVQ 2.

#### A. Pengujian jaringan saraf tiruan – *backpropagation* (JST-BP)

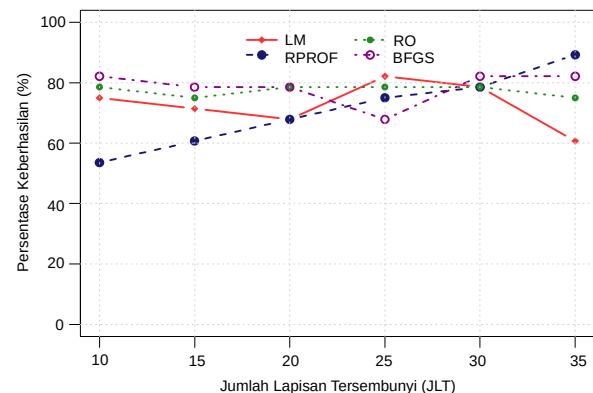
Pengujian pertama dilakukan untuk membandingkan empat metode pelatihan pada JST-BP dalam menentukan posisi objek berdasarkan metode pelatihan. Masing-masing metode diuji dengan enam variasi jumlah lapisan tersembunyi (JLT), mulai dari 10 hingga 35 dengan kenaikan jumlah 5. JLT ini dikodekan dengan JLT10, JLT15, JLT20, JLT25, JLT30, dan JLT35. Masing-masing lapisan memiliki 10 sel saraf.

Gambar 4 menunjukkan perbandingan antarmetode pelatihan JST-BP untuk masing-masing JLT. Metode pelatihan LM tidak mengalami kecenderungan naik atau turun pada tingkat keberhasilan terhadap kenaikan JLT. Namun, LM memberikan tingkat keberhasilan yang lebih baik pada JLT25 dan JLT30 pada kisaran 80 %. Metode pelatihan RPROP mengalami kenaikan tingkat keberhasilan terhadap kenaikan JLT dari sekitar 55% hingga 90 %. Metode pelatihan RO memiliki tingkat keberhasilan hampir sama untuk semua jenis JLT yang berada pada kisaran 77 %. Metode pelatihan BFGS juga memiliki tingkat keberhasilan yang hampir sama untuk semua jenis JLT pada kisaran 80 %, kecuali pada JLT25 turun pada 68 %.

Dari semua metode pelatihan JST-BP dengan jenis JLT yang dimilikinya ditemukan bahwa JLT30 memiliki kinerja yang terbaik di antara JLT yang lain. Tingkat keberhasilan berada pada capaian 80 % untuk semua metode pelatihan. Selain itu, JLT35 pada metode pelatihan RPROP merupakan kinerja terbaik yang mencapai 90 %. Hasil ini berbeda dengan [7] yang memperoleh akurasi terbaik menggunakan metode pelatihan LM sebesar 96,41 % daripada RPROP 94,52 %. Akurasi LM yang lebih baik terhadap RPROP terjadi dengan menggunakan JLT25. Secara umum, metode pelatihan RO memiliki kinerja terbaik di antara metode pelatihan lainnya. RO stabil pada tingkat keberhasilan sekitar 80 % untuk semua jenis JLT.

#### B. Pengujian jaringan saraf tiruan – *learning vector quantization* (JST-LVQ)

Pengujian JST-LVQ dilakukan dengan dua metode pelatihan yaitu JST-LVQ1 dan JST-LVQ2. Masing-masing metode pelatihan diuji untuk melihat tingkat keberhasilan dalam menentukan posisi objek berdasarkan JLT dan laju pembelajaran. Enam jenis JLT digunakan dengan jumlah mulai dari 10 sampai 35 yang



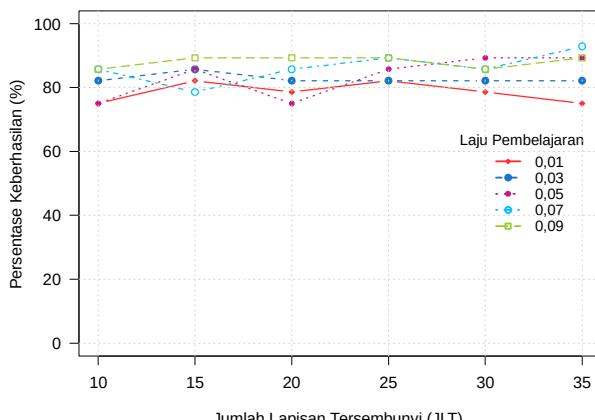
Gambar 4. Persentase keberhasilan JST-BP berdasarkan jumlah lapisan tersembunyi

dikodekan dengan JLT10, JLT15, JLT20, JLT25, JLT30, dan JLT35. Laju pembelajaran menggunakan lima variasi yang dimulai dari 0,01 hingga 0,09 dengan kenaikan 0,02.

Gambar 5 menunjukkan hasil pengujian JST-LVQ1 dengan pengujian JLT dan laju pembelajaran terhadap persentase keberhasilan dalam menentukan posisi objek. Tingkat keberhasilan tidak mengalami kecenderungan kenaikan yang signifikan terhadap kenaikan jumlah lapisan tersembunyi. Namun, terjadi kecenderungan kenaikan keberhasilan terhadap laju pembelajaran yang bermula pada 75 % hingga sekitar 90 %. Di sisi lain, tingkat keberhasilan ditinjau dari jumlah lapisan tersembunyi menunjukkan bahwa JST25 memiliki tingkat keberhasilan terbaik berkisar 82 % hingga 90 %. Sementara itu, tingkat keberhasilan ditinjau dari laju pembelajaran menunjukkan bahwa laju pembelajaran 0,09 memberikan tingkat keberhasilan terbaik berkisar 85 % hingga 90 %. Tingkat keberhasilan tertinggi berdasarkan jumlah lapisan tersembunyi dan laju pembelajaran terdapat pada JST35 dan laju pembelajaran 0,07.

Hasil pengujian pada metode pelatihan JST-LVQ2 ditunjukkan pada Gambar 6. Tingkat keberhasilan cenderung menurun terhadap kenaikan jumlah lapisan tersembunyi. Namun, terjadi kecenderungan kenaikan keberhasilan terhadap laju pembelajaran yang berkisar 55 % hingga 90 %. Selain itu, tingkat keberhasilan ditinjau dari jumlah lapisan tersembunyi menunjukkan bahwa JST15 memiliki tingkat keberhasilan terbaik yang berada pada kisaran 68 % hingga 90 %. Sementara itu, tingkat keberhasilan ditinjau dari laju pembelajaran menunjukkan bahwa laju pembelajaran tertinggi 0,05 memberikan tingkat keberhasilan terbaik berkisar 65 % hingga 80 %. Tingkat keberhasilan tertinggi yang mencapai 90 % terdapat pada JST15 dengan laju pembelajaran 0,03.

Perbandingan antara JST-LVQ1 dan JST-LVQ2 menunjukkan bahwa rata-rata tingkat keberhasilan pada metode pelatihan JST-LVQ1 lebih tinggi dibanding JST-LVQ2 yang sejalan dengan [22]. Arsitektur JST-LVQ1 memiliki rata-rata tingkat keberhasilan sekitar 80 %, sedangkan JST-LVQ2 memiliki rata-rata



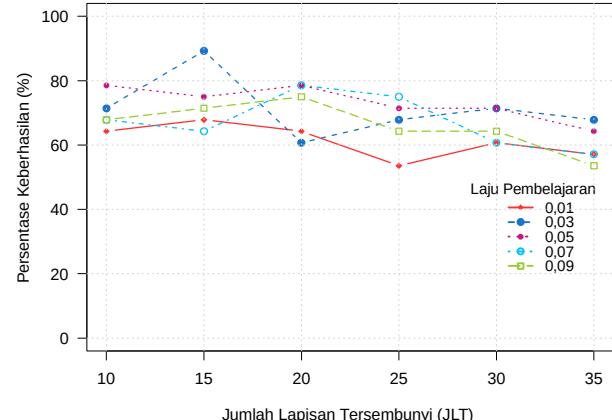
**Gambar 5.** Persentase keberhasilan JST-LVQ1 berdasarkan jumlah lapisan tersembunyi

tingkat keberhasilan sekitar 70 %. Tingkat keberhasilan JST-LVQ1 lebih tinggi dibanding JST-BP, dimana JST-LVQ1 memiliki rata-rata tingkat keberhasilan di sekitar 80 %, sedangkan JST-BP memiliki rata-rata tingkat keberhasilan di sekitar 70 %. Sementara itu, perbandingan JST-BP dan JST-LVQ2 menunjukkan bahwa keduanya memiliki tingkat keberhasilan hampir sama di sekitar 70 %.

Dari hasil tersebut di atas, metode JST-BP dan JST-LVQ dapat diterapkan dalam *fingerprint* untuk mencari posisi sebuah objek berdasarkan RSS beberapa pengirim yang diterima oleh sebuah penerima menggunakan perangkat LoRa seperti dalam [10] serta perangkat ZigBee seperti dalam [7], SigFox dalam [8], [9], dan NB-IoT dalam [11]. Dengan menggunakan luas daerah pengujian 50 m x 150 m, persentase keberhasilan tertinggi JST-BP, JST-LVQ1, dan JST-LVQ2 mencapai 90 % yang sedikit lebih rendah dari [7] sebesar 94,52 – 96,41 % menggunakan JST-BP dengan ZigBee dengan ruang uji lebih sempit. Hasil ini sebanding dengan [8] dan [9] yang menggunakan SigFox dan kNN yang masing-masing menghasilkan kesalahan lokasi 215,58 m dan 340 m. Hasil ini juga sebanding dengan [10] yang menggunakan LoRa dan RBF di ruang terbuka 340 m x 340 m dan menghasilkan kesalahan rata-rata 24,1 m.

#### IV. KESIMPULAN

Dalam jaringan saraf tiruan-*backpropagation* (JST-BP), JLT35 dengan jumlah lapisan tersembunyi 35 memiliki kinerja terbaik dengan keberhasilan 90 % pada metode pelatihan *resilient backpropagation algorithm* (RPROF). JLT30 memberikan kinerja terbaik untuk semua metode pelatihan JST-BP yang diuji dengan memiliki kinerja sekitar 80 %. Metode pelatihan *random order weight* (RO) memberikan kinerja terbaik untuk semua jenis JLT dengan tingkat keberhasilan mencapai sekitar 80 %. Dalam jaringan saraf tiruan-*learning vector quantization* (JST-LVQ), metode pelatihan LVQ1 memiliki tingkat keberhasilan lebih



**Gambar 6.** Persentase keberhasilan JST-LVQ2 berdasarkan jumlah lapisan tersembunyi

tinggi dibanding LVQ2, baik berdasarkan laju pembelajaran maupun jumlah lapisan tersembunyi.

Perbandingan antara JST-BP dan JST-LVQ2 menunjukkan bahwa keduanya memiliki kinerja yang hampir sama dengan tingkat keberhasilan di sekitar 70 %. Namun, JST-LVQ1 menunjukkan kinerja lebih baik dibanding JST-BP. Kedua metode JST-BP maupun JST-LVQ dapat digunakan sebagai algoritme *fingerprint* untuk penentuan lokasi objek dengan akurasi yang cukup baik.

#### UCAPAN TERIMA KASIH

Penelitian ini didanai Universitas Mataram melalui DIPA BLU skema penelitian peningkatan kapasitas dengan nomor kontrak 2514/UN18.L1/PP/2019.

#### DAFTAR PUSTAKA

- [1] G. D. Abowd, A. K. Dey, P. J. Brown, N. Davies, M. Smith, and P. Steggles, “Towards a better understanding of context and context-awareness,” in *International Symposium on Handheld and Ubiquitous Computing*, Karlsruhe, Germany, Sept. 1999, pp. 304–307. doi: [10.1007/3-540-48157-5\\_29](https://doi.org/10.1007/3-540-48157-5_29)
- [2] B. C. Fargas and M. N. Petersen, “GPS-free geolocation using LoRa in low-power WANs,” in *2017 Global Internet of Things Summit*, Geneva, Switzerland, Jun. 2017, pp. 1–6. doi: [10.1109/GIOTS.2017.8016251](https://doi.org/10.1109/GIOTS.2017.8016251)
- [3] A. L. A. Brian, L. Arockiam, and P. Malarchelvi, “An IoT based secured smart library system with NFC based book tracking,” *International Journal of Emerging Technology in Computer Science & Electronics*, vol. 11, no. 5, pp. 18-21, 2014.
- [4] J. Pelant *et al.*, “BLE device indoor localization based on RSS fingerprinting mapped by propagation modes,” in *2017 International Conference Radioelektronika*, Brno, Czech Republic, Apr. 2017, pp. 1–5. doi: [10.1109/RADIOELEK.2017.7937584](https://doi.org/10.1109/RADIOELEK.2017.7937584)
- [5] P. Jiang, Y. Zhang, W. Fu, H. Liu, and X. Su, “Indoor mobile localization based on Wi-Fi

- fingerprint's important access point," *International Journal of Distributed Sensor Networks*, vol. 11, no. 4, pp. 1-10, 2015. doi: [10.1155/2015/429104](https://doi.org/10.1155/2015/429104)
- [6] J. V Martí, J. Sales, R. Marin, and E. Jimenez-Ruiz, "Localization of mobile sensors and actuators for intervention in low-visibility conditions: the ZigBee fingerprinting approach," *International Journal of Distributed Sensor Networks*, vol. 8, no. 8, pp. 1-10, 2012. doi: [10.1155/2012/951213](https://doi.org/10.1155/2012/951213)
- [7] H. P. Pradityo, L. Rosyidi, Misbahuddin, and R. F. Sari, "Performance evaluation of RSS fingerprinting method to track ZigBee devices location using artificial neural networks," in *International Conference on Information and Communication Technology Convergence*, Jeju, South Korea, Oct. 2017, pp. 268-273. doi: [10.1109/ICTC.2017.8190984](https://doi.org/10.1109/ICTC.2017.8190984)
- [8] M. Aernouts, R. Berkvens, K. Van Vlaenderen, and M. Weyn, "Sigfox and LoRaWAN datasets for fingerprint localization in large urban and rural areas," *Data*, vol. 3, no. 2, pp. 1-15, 2018. doi: [10.3390/data3020013](https://doi.org/10.3390/data3020013)
- [9] T. Janssen, M. Aernouts, R. Berkvens, and M. Weyn, "Outdoor fingerprinting localization using Sigfox," in *2018 International Conference on Indoor Positioning and Indoor Navigation*, Nantes, France, Sept. 2018, pp. 1-6. doi: [10.1109/IPIN.2018.8533826](https://doi.org/10.1109/IPIN.2018.8533826)
- [10] W. Choi, Y.-S. Chang, Y. Jung, and J. Song, "Low-Power LoRa signal-based outdoor positioning using fingerprint algorithm," *International Journal of Geo-information*, vol. 7, no. 11, pp. 1-15, 2018. doi: [10.3390/ijgi7110440](https://doi.org/10.3390/ijgi7110440)
- [11] Q. Song, S. Guo, X. Liu, and Y. Yang, "CSI amplitude fingerprinting-based NB-IoT indoor localization," *IEEE Internet of Things Journal*, vol. 5, no. 3, pp. 1494-1504, 2017. doi: [10.1109/JIOT.2017.2782479](https://doi.org/10.1109/JIOT.2017.2782479)
- [12] A. Jiménez-Meza, J. Arámburo-Lizárraga, and E. de la Fuente, "Framework for estimating travel time, distance, speed, and street segment level of service (LOS), based on GPS data," *Procedia Technology*, vol. 7, pp. 61-70, 2013. doi: [10.1016/j.protcy.2013.04.008](https://doi.org/10.1016/j.protcy.2013.04.008)
- [13] M. Rosenberg, "The distance between degrees of latitude and longitude," [Online]. Available: <https://www.thoughtco.com/degree-of-latitude-and-longitude-distance-4070616>. [Accessed: 05-Jul-2019].
- [14] M. T. Hagan, H. B. Demuth, M. H. Beale, and O. De Jesus, *Neural Network Design*, 2nd ed. 2014.
- [15] H. Yu and B. M. Wilamowski, "Levenberg-marquardt training," in *Industrial Electronics Handbook* vol. 5. CRC Press, 2011, pp. 12.1-12.15.
- [16] C. Igel and M. Hüskens, "Empirical evaluation of the improved Rprop learning algorithms," *Neurocomputing*, vol. 50, pp. 105-123, 2003. doi: [10.1016/S0925-2312\(01\)00700-7](https://doi.org/10.1016/S0925-2312(01)00700-7)
- [17] G. Thimm and E. Fiesler, "High-order and multilayer perceptron initialization," *IEEE Transactions on Neural Networks*, vol. 8, no. 2, pp. 349-359, 1997. doi: [10.1109/72.557673](https://doi.org/10.1109/72.557673)
- [18] R. Setiono and L. C. K. Hui, "Use of a quasi-Newton method in a feedforward neural network construction algorithm," *IEEE Transactions on Neural Networks*, vol. 6, no. 1, pp. 273-277, 1995. doi: [10.1109/72.363426](https://doi.org/10.1109/72.363426)
- [19] Y. Linde, A. Buzo, and R. Gray, "An algorithm for vector quantizer design," *IEEE Transactions on Communications*, vol. 28, no. 1, pp. 84-95, 1980. doi: [10.1109/TCOM.1980.1094577](https://doi.org/10.1109/TCOM.1980.1094577)
- [20] R. Gray, "Vector quantization," *IEEE ASSP Magazine*, vol. 1, no. 2, pp. 4-29, 1984. doi: [10.1109/MASSP.1984.1162229](https://doi.org/10.1109/MASSP.1984.1162229)
- [21] T. Kohonen, *Self-organizing*, Third. New York: Springer-Verlag Heidelberg, 2000.
- [22] M. -T. Vakil-Baghmisheh and N. Pavetić, "Premature clustering phenomenon and new training algorithms for LVQ," *Pattern Recognition*, vol. 36, no. 8, pp. 1901-1912, 2003. doi: [10.1016/S0031-3203\(02\)00291-1](https://doi.org/10.1016/S0031-3203(02)00291-1)