Jurnal Elektronika dan Teknik Informatika Terapan
Volume 4, Nomor 3, September 2026
E-ISSN : 2988-0874, P-ISSN : 2988-0866, Hal. 495-507
DOI: https://doi.org/10.59061/jentik.v4i3.1622
Tersedia: https://e-journal.poltek-kampar.ac.id/index.php/JENTIK

Konfigurasi *Backpropagation Neural Network* Ringan untuk Klasifikasi Kesuburan Tanah Berbasis Nilai NPK: Analisis *Hyperparameter* dan Uji Derau Simulasi

Marzuarman[1*], Agustiawan[2], Mus Ali Alsabah[3], Azizul[4], M. Afridon[5], Jefri Lianda[6], Fandy Octafiandri[7], Cindy Witra Nuansa[8]
[1-8]Jurusan Teknik Elektro, Politeknik Negeri Bengkalis, Indonesia
**Penulis Korespondensi: marzuarman@polbeng.ac.id*

Abstract*. Soil fertility classification from nitrogen (N), phosphorus (P), and potassium (K) values can be embedded in low-cost devices, but the architecture and hyperparameters of a Backpropagation Neural Network (BPNN) are often chosen by trial and error, and the effect of sensor uncertainty is rarely examined. This study aims to find a lightweight BPNN configuration and evaluate it under simulated sensor noise. A dataset of 200 soil samples from Bengkalis Island and Sungai Pakning, labeled into three fertility classes, was used. Hidden-layer size, learning rate, and number of epochs were explored by grid search with 5-fold stratified cross-validation repeated three times, and Gaussian noise of 0–20% of each feature's range was added to the test data. Networks with at least two hidden neurons reached 100.00% accuracy without noise, whereas one hidden neuron reached 94.50%. Within 25 epochs, accuracy rose from 32.00% at a learning rate of 0.0001 to 100.00% at 0.1. The lightweight 3–2–3 configuration (17 parameters) matched the 3–12–8–3 reference (179 parameters) at every noise level, with 95.87% versus 95.57% accuracy at 10% noise, and trained about 30 times faster. A two-neuron BPNN is therefore sufficient for this dataset. The findings are limited to simulated noise and 200 samples, so validation with real RS485 sensor readings is required.*

Keywords*: Backpropagation Neural Network; Lightweight Configuration; Noise Testing; NPK Sensor; Soil Fertility.*

Abstrak. Klasifikasi kesuburan tanah berdasarkan nilai nitrogen (N), fosfor (P), dan kalium (K) dapat ditanamkan pada perangkat berbiaya rendah, tetapi arsitektur dan *hyperparameter Backpropagation Neural Network* (BPNN) sering ditentukan secara coba-coba, dan pengaruh ketidakpastian sensor jarang dikaji. Penelitian ini bertujuan menemukan konfigurasi BPNN yang ringan dan mengevaluasinya pada derau sensor simulasi. Dataset terdiri atas 200 sampel tanah dari Pulau Bengkalis dan Sungai Pakning dengan tiga kelas kesuburan. Ukuran lapisan tersembunyi, *learning rate*, dan jumlah *epoch* dieksplorasi dengan *grid search* dan validasi silang berstrata 5-lipat yang diulang tiga kali, dan derau Gaussian sebesar 0–20% dari rentang tiap fitur ditambahkan pada data uji. Jaringan dengan minimal dua *neuron* tersembunyi mencapai akurasi 100,00% tanpa derau, sedangkan satu neuron hanya 94,50%. Dalam 25 *epoch*, akurasi naik dari 32,00% pada *learning rate* 0,0001 menjadi 100,00% pada 0,1. Konfigurasi ringan 3–2–3 (17 parameter) setara dengan acuan 3–12–8–3 (179 parameter) di semua tingkat derau, dengan akurasi 95,87% berbanding 95,57% pada derau 10%, dan dilatih sekitar 30 kali lebih cepat. Dengan demikian BPNN dua *neuron* sudah cukup untuk dataset ini. Temuan terbatas pada derau simulasi dan 200 sampel sehingga validasi dengan bacaan sensor RS485 yang sebenarnya masih diperlukan.

Kata Kunci: *Backpropagation Neural Network*; Kesuburan Tanah; Konfigurasi Ringan; Sensor NPK; Uji Derau.

1. LATAR BELAKANG

Kesuburan tanah merupakan salah satu faktor penentu produktivitas pertanian (Sujatha & Jaidhar, 2021), dan unsur hara makro nitrogen (N), fosfor (P), dan kalium (K) menjadi indikator utama dalam menilai ketersediaan hara bagi tanaman (Saleem et al., 2023; Yahaya et al., 2023). Analisis tanah di laboratorium memberikan hasil yang akurat, tetapi memerlukan waktu dan biaya sehingga kurang praktis untuk pemantauan lahan secara cepat.

Sensor NPK berbiaya rendah dengan antarmuka RS485 memungkinkan pengukuran kandungan N, P, dan K secara langsung, dan keluarannya dapat dikombinasikan dengan

Naskah Masuk: 29 Juli 2026; Revisi: 18 Agustus 2026; Diterima: 27 September 2026; Terbit: 30 September 2026

metode pembelajaran mesin untuk mengklasifikasikan tingkat kesuburan tanah (Islam et al., 2023; Sujatha et al., 2023; Sujatha & Jaidhar, 2021). Di antara berbagai metode tersebut, Backpropagation Neural Network (BPNN) (Rumelhart et al., 1986) banyak dipilih karena strukturnya sederhana dan mampu memodelkan hubungan nonlinear antarvariabel masukan.

Kinerja BPNN, bagaimanapun, sensitif terhadap pemilihan *hyperparameter*. Jumlah *neuron* lapisan tersembunyi yang terlalu sedikit dapat menyebabkan *underfitting*, sedangkan jumlah yang berlebihan meningkatkan risiko *overfitting*, terutama pada dataset berukuran kecil (Goodfellow et al., 2016). *Learning rate* yang terlalu besar dapat membuat pelatihan tidak konvergen, sedangkan nilai yang terlalu kecil membuat pelatihan lambat; jumlah *epoch* yang tidak sesuai juga dapat menghentikan pelatihan terlalu dini atau terlalu lama. Pencarian hyperparameter yang sistematis terbukti lebih andal dibandingkan penentuan manual (Bergstra & Bengio, 2012).

Pada sebagian penelitian terkait, arsitektur jaringan ditetapkan tanpa analisis sensitivitas terhadap *hyperparameter* (Ainurohman et al., 2026; Sujatha & Jaidhar, 2024). Selain itu, bacaan sensor NPK berbiaya rendah dipengaruhi oleh sifat tanah dan lokasi pengukuran, tetapi pengaruh ketidakpastian ini terhadap kinerja klasifikasi jarang diuji dan pengaruhnya terhadap klasifikasi belum menjadi fokus utama pada studi sensor tersebut (Sulaeman et al., 2024). Pada dataset kecil dengan tiga fitur, konfigurasi yang dipilih tanpa evaluasi yang tepat dapat tampak baik pada satu pembagian data tetapi tidak stabil pada pembagian lainnya, sehingga diperlukan kajian sistematis yang melaporkan pengaruh masing-masing *hyperparameter* secara terukur.

Kontribusi penelitian ini adalah: (1) analisis sensitivitas BPNN terhadap jumlah neuron lapisan tersembunyi, *learning rate*, dan jumlah *epoch* pada klasifikasi kesuburan tanah berbasis nilai N, P, dan K; (2) pengujian pada derau simulasi untuk menilai kinerja model terhadap ketidakpastian bacaan sensor; dan (3) penentuan konfigurasi BPNN yang ringan, yaitu 17 parameter, dengan kinerja setara konfigurasi acuan yang jauh lebih besar.

2. KAJIAN TEORITIS

Kesuburan Tanah dan Unsur Hara N, P, K

Kesuburan tanah menggambarkan kemampuan tanah menyediakan unsur hara dalam jumlah dan keseimbangan yang cukup bagi pertumbuhan tanaman. Di antara unsur hara makro, nitrogen (N), fosfor (P), dan kalium (K) dibutuhkan dalam jumlah besar sehingga paling sering dijadikan indikator dasar. Nitrogen berperan dalam pertumbuhan vegetatif dan pembentukan klorofil, fosfor mendukung perkembangan akar serta transfer energi dalam tanaman, sedangkan

kalium berperan dalam pengaturan air dan ketahanan tanaman terhadap cekaman (Saleem et al., 2023; Yahaya et al., 2023). Karena ketiga unsur ini saling berkaitan, tingkat kesuburan tanah lebih tepat dinilai dari kombinasi nilai N, P, dan K daripada dari satu unsur saja. Penentuan kelas kesuburan umumnya mengacu pada kriteria aturan kategorisasi N, P, dan K yang digunakan pada dataset penelitian.

Sensor NPK dan Pengukuran Hara Tanah

Analisis hara tanah secara laboratorium memberikan hasil yang akurat, tetapi memerlukan waktu, bahan kimia, dan tenaga terlatih. Sensor NPK dengan antarmuka RS485 menjadi alternatif karena dapat ditancapkan langsung ke tanah dan membaca nilai N, P, dan K secara digital melalui mikrokontroler atau komputer papan tunggal. Hasil pengukuran sensor berbiaya rendah dipengaruhi oleh sifat tanah dan lokasi pengukuran sehingga perlu dikalibrasi terhadap alat atau metode acuan (Sulaeman et al., 2024). Pada penelitian ini, nilai N, P, dan K pada dataset diperoleh dari alat ukur YY-1104 yang juga berfungsi sebagai kalibrator sensor NPK.

Klasifikasi dan Jaringan Saraf Tiruan

Klasifikasi adalah proses menetapkan suatu data ke salah satu kelas berdasarkan nilai fitur-fiturnya, dan modelnya dipelajari dari data berlabel (Hastie et al., 2009). Jaringan saraf tiruan (JST) merupakan model pembelajaran mesin yang terinspirasi dari cara kerja sistem saraf biologis. Jaringan ini tersusun atas *neuron-neuron* yang dikelompokkan dalam lapisan masukan, lapisan tersembunyi, dan lapisan keluaran, dengan setiap koneksi memiliki bobot yang diatur selama pelatihan (Haykin, 2009). Kemampuan lapisan tersembunyi dengan fungsi aktivasi nonlinear membuat JST dapat memodelkan hubungan kompleks antara fitur dan kelas (LeCun et al., 2015).

Backpropagation Neural Network

Backpropagation Neural Network (BPNN) adalah JST umpan maju (*feedforward*) yang dilatih dengan algoritme propagasi balik galat (Rumelhart et al., 1986). Pelatihan berlangsung dalam dua fase yang berulang. Pada fase maju, data masukan dihitung melalui seluruh lapisan hingga menghasilkan keluaran, lalu keluaran tersebut dibandingkan dengan label sebenarnya untuk memperoleh galat. Pada fase mundur, galat dipropagasikan dari lapisan keluaran ke lapisan sebelumnya menggunakan aturan rantai untuk menghitung gradien galat terhadap setiap bobot, kemudian bobot diperbarui ke arah yang mengurangi galat (Goodfellow et al., 2016).

Hyperparameter pada BPNN

Hyperparameter adalah pengaturan yang ditetapkan sebelum pelatihan dan sangat memengaruhi kinerja BPNN. Jumlah *neuron* dan lapisan tersembunyi menentukan kapasitas model: jaringan yang terlalu kecil mengalami *underfitting*, sedangkan yang terlalu besar rentan *overfitting* pada data terbatas (Goodfellow et al., 2016). *Learning rat*e mengatur besar langkah pembaruan bobot, sehingga nilai yang terlalu besar membuat pelatihan tidak konvergen dan nilai yang terlalu kecil membuatnya lambat. Jumlah *epoch* menentukan berapa kali data latih dipelajari, dengan risiko belum optimal bila terlalu sedikit dan *overfitting* bila berlebihan. Karena ketiganya saling berinteraksi, pencarian sistematis seperti *grid search* lebih andal daripada penentuan manual (Bergstra & Bengio, 2012).

Validasi Silang dan Metrik Evaluasi

Pada dataset kecil, satu kali pembagian data latih dan uji menghasilkan estimasi kinerja yang tidak stabil. Validasi silang k-lipat mengatasinya dengan menggunakan setiap bagian data secara bergiliran sebagai data uji (Kohavi, 1995). Kinerja klasifikasi diukur dengan akurasi, *precision*, *recall*, dan F1-*score* yang dirata-ratakan secara makro agar setiap kelas berbobot sama (Sokolova & Lapalme, 2009).

3. METODE PENELITIAN

Alur Penelitian

Penelitian dilakukan melalui tujuh tahap seperti pada Gambar 1: pengambilan sampel tanah, pengukuran nilai N, P, K dan pelabelan kelas, pra-pemrosesan data, pembagian data dengan validasi silang, pencarian *hyperparameter* dengan *grid search*, uji derau simulasi, serta evaluasi dan pemilihan konfigurasi optimal.

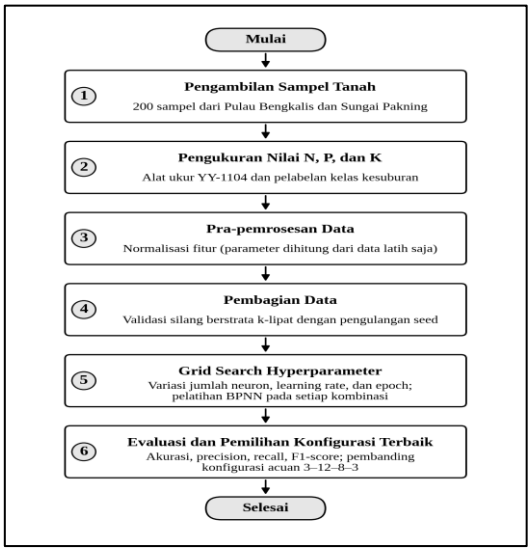

Gambar 1. Diagram alir penelitian.

Dataset dan Pelabelan Kelas

Dataset terdiri atas 200 sampel tanah yang diambil dari Pulau Bengkalis dan Sungai Pakning. Sampel diambil dan dikumpulkan terlebih dahulu, kemudian nilai N, P, dan K setiap sampel diukur satu per satu menggunakan alat ukur YY-1104 yang juga digunakan sebagai kalibrator sensor NPK RS485. Setiap data memuat wilayah, koordinat lokasi, kedalaman pengambilan, nilai N, P, K (mg/kg), dan label kelas kesuburan. Dataset tidak memuat informasi jenis tanah dan variabel tersebut tidak digunakan dalam pemodelan.

Label kelas kesuburan terdiri atas tiga kelas, yaitu Tidak Subur (64 sampel), Sedang (72 sampel), dan Sangat Subur (64 sampel), yang ditentukan berdasarkan aturan kategorisasi N, P, dan K yang telah ditetapkan pada dataset penelitian. Karena label diturunkan dari nilai N, P, dan K melalui kriteria tersebut, tugas klasifikasi pada penelitian ini pada dasarnya adalah mempelajari kriteria pelabelan dari data, sehingga model dievaluasi pada data yang tidak digunakan dalam pelatihan dan pada data uji yang diberi derau simulasi.

Pra-pemrosesan Data

Ketiga fitur (N, P, K) dinormalisasi dengan metode *min–max* agar berada pada skala yang sebanding. Parameter normalisasi dihitung hanya dari data latih pada setiap lipatan validasi silang, kemudian diterapkan pada data uji, untuk mencegah kebocoran informasi dari data uji ke proses pelatihan.

Backpropagation Neural Network

BPNN yang digunakan memiliki 3 neuron masukan (N, P, K), satu atau dua lapisan tersembunyi dengan jumlah *neuron* yang divariasikan, dan 3 *neuron* keluaran sesuai jumlah kelas. Keluaran neuron j pada lapisan l dihitung dengan:

$$a_j^{(l)} = f(\sum_{i=1}^{n} w_{(ji)}^{(l)}\, a_i^{(l-1)} + b_j^{(l)}) \quad \text{.....(i)}$$

Dengan $a_j^{(l)}$ keluaran *neuron* j pada lapisan l, $w_{ji}^{(l)}$ bobot dari *neuron* i pada lapisan l−1 ke *neuron* j pada lapisan l, $a_i^{(l-1)}$ keluaran *neuron* i pada lapisan l−1, n jumlah *neuron* pada lapisan l−1, $b_j^{(l)}$ bias *neuron* j, dan f fungsi aktivasi, yaitu logistik (sigmoid) pada lapisan tersembunyi dan *softmax* pada lapisan keluaran. Galat keluaran dihitung dengan fungsi *cross-entropy*:

$$E = \frac{1}{2}\sum_{k=1}^{K}(t_k - y_k)^2 \quad \text{.....(ii)}$$

Dengan t_k target satu-panas (*one-hot*), y_k keluaran *softmax neuron* ke-k, dan K jumlah kelas (K = 3). Bobot diperbarui melalui propagasi balik galat dengan aturan dasar:

$$w_{ji}^{(l)} \leftarrow w_{ji}^{(l)} - \eta \frac{\partial E}{\partial x_{ji}^{(l)}} \quad \text{.....(iii)}$$

Dengan η adalah *learning rate*. Penelitian ini menggunakan optimizer Adam (Kingma & Ba, 2015), yang menyesuaikan langkah pembaruan setiap bobot menggunakan estimasi momen pertama dan kedua gradien dengan η sebagai *learning rate* awal. BPNN diimplementasikan menggunakan kelas MLPClassifier pada pustaka *scikit-learn* versi 1.7.1 (Pedregosa et al., 2011) dengan ukuran *mini-batch* 32. Pelatihan berjalan tepat sebanyak jumlah *epoch* yang ditentukan tanpa *early stopping*.

Rancangan Eksperimen

Ruang pencarian *hyperparameter* disajikan pada Tabel 1 dan seluruhnya berjumlah 96 kombinasi yang dievaluasi dengan *grid search*. Setiap kombinasi dievaluasi menggunakan validasi silang berstrata 5-lipat (Kohavi, 1995) yang diulang tiga kali dengan pembagian data acak berbeda, sehingga setiap konfigurasi dilatih 15 kali dan hasilnya dilaporkan sebagai rata-rata dan simpangan baku. Sebagai konfigurasi acuan digunakan arsitektur 3–12–8–3 yang dilatih ulang dengan *learning rate* 0,01 dan 500 *epoch* pada protokol yang sama agar perbandingan adil.

Tabel 1. Ruang pencarian hyperparameter.

Hyperparameter	Nilai yang diuji
Arsitektur satu lapisan tersembunyi	3–1–3, 3–2–3, 3–3–3, 3–4–3, 3–8–3
Arsitektur dua lapisan tersembunyi	3–4–2–3
Learning rate (η)	0,0001; 0,001; 0,01; 0,1
Jumlah *epoch*	10; 25; 50; 100
Tingkat derau uji	0%; 2%; 5%; 10%; 20% dari rentang fitur
Parameter tetap	Aktivasi logistik (tersembunyi), *softmax* (keluaran), optimizer Adam, *mini-batch* 32, normalisasi *min–max*, loss *cross-entropy*

Uji Derau Simulasi

Untuk meniru ketidakpastian bacaan sensor NPK RS485, data uji diberi derau Gaussian dengan rata-rata nol dan simpangan baku sebesar 0%, 2%, 5%, 10%, dan 20% dari rentang masing-masing fitur pada data latih. Derau ditambahkan setelah pembagian data dan hanya pada data uji, sedangkan data latih tetap bersih, dan nilai negatif dipotong menjadi nol. Pada setiap lipatan, pemberian derau diulang lima kali dan akurasinya dirata-ratakan. Derau ini merupakan simulasi dan bukan hasil pengukuran galat sensor yang sebenarnya.

Pemilihan Konfigurasi Optimal

Skor setiap konfigurasi adalah akurasi rata-rata pada seluruh tingkat derau. Konfigurasi optimal dipilih sebagai konfigurasi dengan jumlah parameter paling sedikit (kemudian jumlah

epoch paling sedikit) di antara konfigurasi yang skornya berada dalam 1 poin persentase dari skor terbaik. Jumlah parameter dihitung dari seluruh bobot dan bias jaringan.

Metrik Evaluasi

Kinerja klasifikasi diukur dengan akurasi, yaitu jumlah prediksi benar dibagi jumlah seluruh data, serta F1-*score* yang dirata-ratakan secara makro agar setiap kelas berbobot sama. Selain itu dicatat jumlah parameter dan waktu latih rata-rata per pelatihan sebagai indikator beban komputasi, yang diukur pada Raspberry Pi 4 dengan RAM 8GB tanpa pemrosesan paralel.

4. HASIL DAN PEMBAHASAN

Pengaruh Jumlah Neuron Lapisan Tersembunyi

Tabel 2 menunjukkan kinerja enam arsitektur pada *learning rate* 0,1 dan 25 epoch. Arsitektur dengan satu *neuron* tersembunyi (3–1–3) hanya mencapai akurasi 94,50 ± 2,54%, sedangkan semua arsitektur dengan dua *neuron* atau lebih, termasuk yang berlapis dua (3–4–2–3), mencapai 100,00 ± 0,00% tanpa derau. Pada derau 5%, 3–1–3 turun menjadi 93,37%, sementara arsitektur lainnya bertahan pada 99,23–99,37%. Hasil ini menunjukkan bahwa satu *neuron* belum cukup untuk memisahkan tiga kelas (*underfitting*), dan batas kapasitas minimum berada pada dua *neuron*. Menambah *neuron* di atas dua tidak meningkatkan akurasi, tetapi menambah jumlah parameter dari 17 menjadi 59 pada 3–8–3, dan lapisan tersembunyi kedua tidak memberi keuntungan tambahan.

Tabel 2. Pengaruh arsitektur terhadap kinerja klasifikasi ($\eta = 0{,}1$; 25 epoch).

Arsitektur	Parameter	Akurasi bersih (%) ± SD	Akurasi derau 5% (%)	F1-score makro	Waktu latih (s)
3–1–3	10	94,50 ± 2,54	93,37	0,945	0,02
3–2–3	17	100,00 ± 0,00	99,37	1,000	0,02
3–3–3	24	100,00 ± 0,00	99,27	1,000	0,03
3–4–3	31	100,00 ± 0,00	99,33	1,000	0,02
3–8–3	59	100,00 ± 0,00	99,33	1,000	0,03
3–4–2–3	35	100,00 ± 0,00	99,23	1,000	0,03

Pengaruh *Learning Rate*

Tabel 3 dan Gambar 2 menunjukkan pengaruh *learning rate* pada arsitektur 3–2–3 dengan 25 *epoch*. Akurasi pada learning rate 0,0001 hanya 32,00 ± 1,04%, mendekati tebakan acak (kelas terbesar hanya 36% dari data), dan 37,50 ± 5,75% pada 0,001. Pada 0,01 akurasi naik menjadi 75,50 ± 4,93%, dan pada 0,1 mencapai 100,00 ± 0,00%. Gambar 2 memperlihatkan bahwa pada 0,0001 dan 0,001 *loss* hampir tidak turun dari nilai awal dalam 25 *epoch*, sedangkan pada 0,1 loss turun hingga sekitar 0,05. Perbedaan ini sebagian besar disebabkan oleh jumlah pembaruan bobot yang terbatas pada *learning rate* kecil, bukan oleh

ketidakmampuan model. Berdasarkan hasil *grid* lengkap, *learning rate* 0,01 dengan 100 *epoch* juga mencapai 100,00% pada beberapa arsitektur, sehingga *learning rate* dan jumlah *epoch* saling menggantikan: *learning rate* yang lebih kecil memerlukan *epoch* yang lebih banyak.

Tabel 3. Pengaruh learning rate terhadap kinerja klasifikasi (arsitektur 3–2–3; 25 *epoch*).

Learning rate	Akurasi bersih (%) ± SD	Akurasi derau 5% (%)	F1-score makro
0,0001	32,00 ± 1,04	32,00	0,162
0,001	37,50 ± 5,75	37,33	0,200
0,01	75,50 ± 4,93	75,70	0,733
0,1	100,00 ± 0,00	99,37	1,000

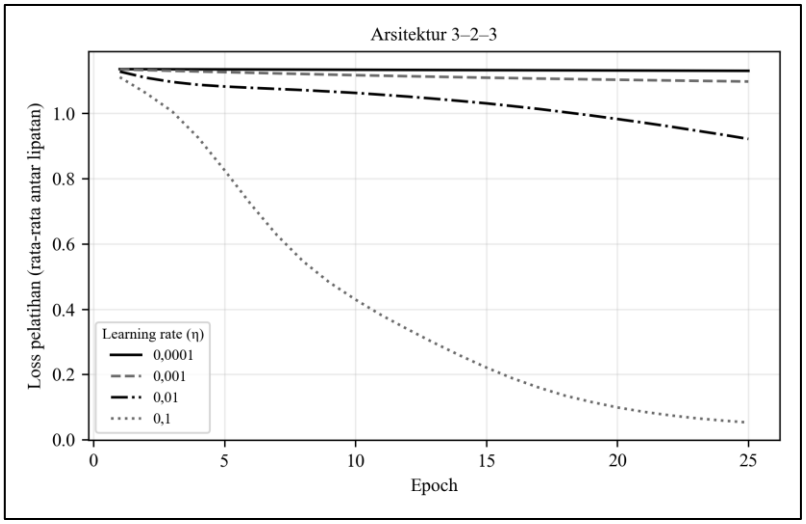

Gambar 2. Kurva *loss* pelatihan pada arsitektur 3–2–3 untuk empat nilai *learning rate* (25 *epoch*).

Pengaruh Jumlah Epoch

Tabel 4 menunjukkan bahwa pada arsitektur 3–2–3 dan *learning rate* 0,1, akurasi pada 10 *epoch* adalah 96,00 ± 3,51%, kemudian mencapai 100,00 ± 0,00% pada 25 *epoch* dan tidak berubah pada 50 maupun 100 *epoch*. Akurasi pada derau 5% juga stabil di 99,27–99,37% untuk 25–100 *epoch*, sehingga tidak tampak penurunan akibat pelatihan berlebih. Penambahan *epoch* di atas 25 hanya menambah waktu latih, dari 0,02 s menjadi 0,09 s.

Tabel 4. Pengaruh jumlah *epoch* terhadap kinerja klasifikasi (arsitektur 3–2–3; $\eta = 0{,}1$).

Jumlah epoch	Akurasi bersih (%) ± SD	Akurasi derau 5% (%)	F1-score makro	Waktu latih (s)
10	96,00 ± 3,51	95,17	0,960	0,01
25	100,00 ± 0,00	99,37	1,000	0,02
50	100,00 ± 0,00	99,30	1,000	0,05
100	100,00 ± 0,00	99,27	1,000	0,09

Ketahanan terhadap Derau Simulasi

Tabel 5 dan Gambar 3 menunjukkan akurasi menurun seiring naiknya tingkat derau. Untuk 3–2–3, akurasi turun dari 100,00% tanpa derau menjadi 99,93% (2%), 99,37% (5%),

95,87% (10%), dan 84,70% (20%). Arsitektur dengan dua *neuron* atau lebih menunjukkan kurva yang hampir menumpuk, dengan selisih antararsitektur tidak lebih dari sekitar 0,5 poin persentase pada setiap tingkat derau, lebih kecil dari simpangan bakunya (0,26–2,45). Hanya 3–1–3 yang konsisten lebih rendah di semua tingkat derau (80,33% pada derau 20%). Dengan demikian tidak ada bukti bahwa arsitektur yang lebih besar lebih tahan derau. Hal ini diduga karena label ditentukan oleh nilai N, P, dan K yang bersih, sehingga kesalahan akibat derau terutama berasal dari sampel yang bergeser melewati batas kelas, dan itu berlaku bagi semua model yang kapasitasnya sudah cukup.

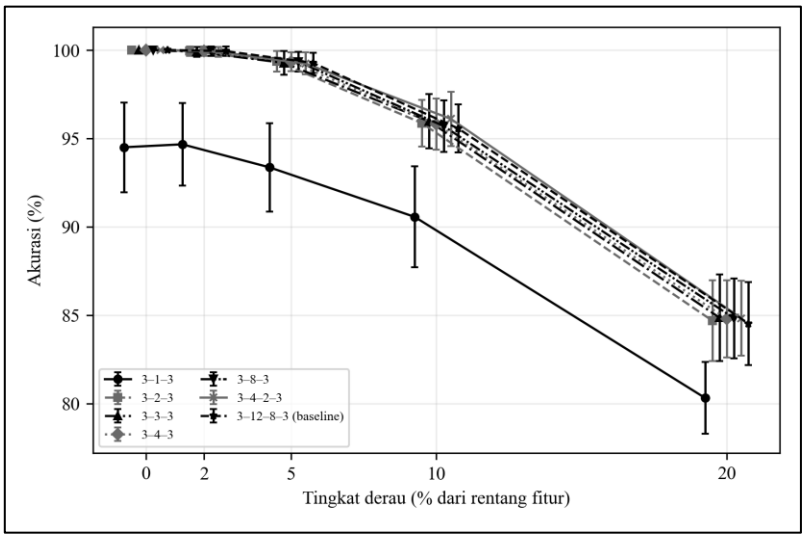

Gambar 3. Akurasi terhadap tingkat derau simulasi untuk setiap arsitektur (rata-rata ± simpangan baku; titik digeser sedikit agar tidak menumpuk).

Tabel 5. Akurasi (%) ± SD pada berbagai tingkat derau simulasi (η = 0,1; 25 epoch).

Arsitektur	Tanpa derau	Derau 2%	Derau 5%	Derau 10%	Derau 20%
3–1–3	94,50 ± 2,54	94,67 ± 2,34	93,37 ± 2,50	90,57 ± 2,86	80,33 ± 2,03
3–2–3	100,00 ± 0,00	99,93 ± 0,26	99,37 ± 0,58	95,87 ± 1,32	84,70 ± 2,29
3–3–3	100,00 ± 0,00	99,90 ± 0,28	99,27 ± 0,68	95,97 ± 1,54	84,87 ± 2,45
3–4–3	100,00 ± 0,00	99,93 ± 0,26	99,33 ± 0,52	95,80 ± 1,45	84,80 ± 2,19
3–8–3	100,00 ± 0,00	99,93 ± 0,26	99,33 ± 0,56	95,70 ± 1,46	84,83 ± 2,26
3–4–2–3	100,00 ± 0,00	99,90 ± 0,28	99,23 ± 0,62	96,10 ± 1,53	84,83 ± 2,12
3–12–8–3 (baseline)	100,00 ± 0,00	99,93 ± 0,26	99,27 ± 0,56	95,57 ± 1,36	84,53 ± 2,36

Konfigurasi Optimal dan Perbandingan dengan Konfigurasi Acuan

Skor terbaik, yaitu 96,01%, dicapai oleh 3–4–2–3 dengan 35 parameter, sedangkan 3–2–3 mencapai 95,97% hanya dengan 17 parameter. Karena selisihnya masih dalam toleransi 1 poin persentase, konfigurasi optimal yang dipilih adalah arsitektur 3–2–3 dengan learning rate

0,1 dan 25 epoch. Tabel 6 membandingkannya dengan konfigurasi acuan 3–12–8–3. Akurasi kedua konfigurasi setara pada semua tingkat derau, misalnya 99,37% berbanding 99,27% pada derau 5% dan 95,87% berbanding 95,57% pada derau 10%, dengan selisih paling besar 0,30 poin persentase dan berada dalam simpangan baku. Konfigurasi optimal hanya memiliki 17 parameter (sekitar sepersepuluh dari 179 parameter acuan) dan waktu latihnya 0,02 s dibandingkan 0,62 s, kira-kira 30 kali lebih cepat. Percepatan ini berasal dari model yang lebih kecil dan *epoch* yang lebih sedikit (25 berbanding 500).

Tabel 6. Perbandingan konfigurasi acuan dan konfigurasi optimal.

Parameter	Acuan	Optimal (ringan)
Arsitektur	3–12–8–3	3–2–3
Learning rate (η)	0,01	0,1
Jumlah *epoch*	500	25
Jumlah parameter	179	17
Akurasi tanpa derau (%)	100,00 ± 0,00	100,00 ± 0,00
Akurasi derau 2% (%)	99,93 ± 0,26	99,93 ± 0,26
Akurasi derau 5% (%)	99,27 ± 0,56	99,37 ± 0,58
Akurasi derau 10% (%)	95,57 ± 1,36	95,87 ± 1,32
Akurasi derau 20% (%)	84,53 ± 2,36	84,70 ± 2,29
Waktu latih (s)	0,62	0,02

Gambar 4 menunjukkan *confusion matrix* 3–2–3 pada derau 10%: 191 dari 200 sampel terklasifikasi benar. Seluruh sembilan kesalahan terjadi antar kelas bersebelahan (Tidak Subur dan Sedang sebanyak 6, Sedang dan Sangat Subur sebanyak 3), dan tidak ada sampel Tidak Subur yang diprediksi Sangat Subur atau sebaliknya. Pola ini sesuai dengan sifat kesalahan akibat derau yang menggeser sampel hanya ke batas kelas terdekat.

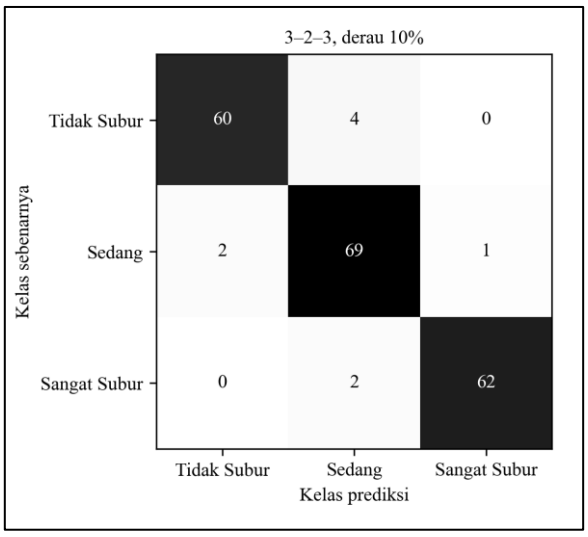

Gambar 4. *Confusion matrix* arsitektur 3–2–3 pada derau 10%.

Pembahasan dan Keterbatasan

Secara keseluruhan, hasil menunjukkan bahwa untuk dataset ini BPNN yang sangat kecil sudah cukup: dua neuron tersembunyi adalah batas kapasitas, *learning rate* dan *epoch*

dapat dipertukarkan, dan arsitektur yang lebih besar tidak memberi keuntungan akurasi maupun ketahanan derau. Ukuran yang kecil relevan bagi implementasi pada perangkat dengan sumber daya terbatas (Samanta & Saha, 2026). Penelitian ini memiliki beberapa keterbatasan. Pertama, label kelas diturunkan dari aturan kategorisasi N, P, dan K yang telah ditetapkan pada dataset penelitian, sehingga akurasi 100% menunjukkan kemampuan model mereproduksi kriteria pelabelan, bukan kemampuan menilai kesuburan tanah di luar kriteria tersebut. Kedua, derau pada pengujian merupakan simulasi dan belum mewakili galat sebenarnya antara sensor NPK RS485 dan alat acuan YY-1104. Ketiga, dataset terbatas pada 200 sampel dari dua wilayah. Keempat, konfigurasi optimal dipilih dari hasil validasi silang yang sama dengan yang dilaporkan, sehingga estimasi kinerjanya cenderung sedikit optimistis. Kelima, nilai N, P, dan K sampel dapat berubah selama penyimpanan sebelum diukur. Keenam, fungsi aktivasi, optimizer, dan ukuran *mini-batch* tidak divariasikan.

5. KESIMPULAN DAN SARAN

Penelitian ini menganalisis pengaruh jumlah neuron lapisan tersembunyi, *learning rate*, dan jumlah *epoch* terhadap kinerja BPNN pada klasifikasi kesuburan tanah berbasis nilai N, P, dan K, serta mengujinya pada derau simulasi. Hasilnya menunjukkan bahwa (1) dua *neuron* tersembunyi sudah cukup, karena satu *neuron* hanya mencapai 94,50% sedangkan dua *neuron* atau lebih mencapai 100,00% tanpa derau; (2) *learning rate* dan jumlah *epoch* saling terkait, dan pada 25 epoch *learning rate* 0,1 diperlukan untuk mencapai 100,00%; dan (3) konfigurasi 3–2–3 dengan 17 parameter setara dengan konfigurasi acuan 3–12–8–3 (179 parameter) di semua tingkat derau dengan waktu latih sekitar 30 kali lebih cepat. Penelitian selanjutnya disarankan menguji konfigurasi ini dengan bacaan sensor RS485 yang sebenarnya, memperluas dataset ke lebih banyak wilayah dan jenis tanah, serta mengevaluasi dengan *nested cross-validation*.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada DPPM Kemdiktisaintek melalui skema Penelitian Dosen Pemula (PDP) tahun 2026 dengan nomor kontrak 184/C3/DT.05.00/PL-BARU/2026, serta kepada Politeknik Negeri Bengkalis atas dukungan yang diberikan.

DAFTAR REFERENSI

Ainurohman, Y. C., Fiolana, F. A., & others. (2026). Perancangan Sensor NPK Menggunakan JST Sebagai Pengambil Keputusan. *ALINIER: Journal of Artificial Intelligence \& Applications*, *7*(1), 1–12. https://doi.org/https://doi.org/10.36040/alinier.v7i1.16149

Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, *13*, 281–305.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.

Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson.

Islam, M. R., Oliullah, K., Kabir, M. M., Alom, M., & Mridha, M. F. (2023). Machine learning enabled IoT system for soil nutrients monitoring and crop recommendation. *Journal of Agriculture and Food Research*, *14*, 100880. https://doi.org/10.1016/j.jafr.2023.100880

Kingma, D. P., & Ba, J. (2015). Adam: A Method for Stochastic Optimization. *3rd International Conference on Learning Representations (ICLR 2015)*.

Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *Proceedings of the 14th International Joint Conference on Artificial Intelligence*, *2*, 1137–1143.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*, 436–444.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., & Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, *12*, 2825–2830.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, *323*, 533–536. https://doi.org/10.1038/323533a0

Saleem, S., Mushtaq, N. U., Rasool, A., Shah, W. H., Tahir, I., & Rehman, R. U. (2023). Plant nutrition and soil fertility: Physiological and molecular avenues for crop improvement. In *Sustainable Plant Nutrition: Molecular Interventions and Advancements for Crop Improvement* (pp. 23–49). Academic Press. https://doi.org/10.1016/B978-0-443-18675-2.00009-2

Samanta, R., & Saha, B. (2026). Affordable precision agriculture: A deployment-oriented review of low-cost, low-power Edge AI and TinyML for resource-constrained farming systems. *ArXiv Preprint ArXiv:2603.15085*.

Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing \& Management*, *45*(4), 427–437.

Sujatha, M., & Jaidhar, C. D. (2021). Classification of soil fertility using machine learning-based classifier. *International Conference on Secure Cyber Computing and Communications (ICSCCC 2021)*, 138–143. https://doi.org/10.1109/ICSCCC51823.2021.9478169

Sujatha, M., & Jaidhar, C. D. (2024). Machine learning-based approaches to enhance the soil fertility---A review. *Expert Systems with Applications*, *240*, 122557.

Sujatha, M., Jaidhar, C. D., & Lingappa, M. (2023). 1D convolutional neural networks-based soil fertility classification and fertilizer prescription. *Ecological Informatics*, *78*,

102295.

Sulaeman, Y., Sutanto, E., Kasno, A., Sunandar, N., & Purwaningrahayu, R. D. (2024). Developing and testing a portable soil nutrient detector in irrigated and rainfed paddy soils from Java, Indonesia. *Computers*, *13*(8), 209. https://doi.org/10.3390/computers13080209

Yahaya, S. M., Mahmud, A. A., Abdullahi, M., & Haruna, A. (2023). Recent advances in the chemistry of nitrogen, phosphorus and potassium as fertilizers in soil: A review. *Pedosphere*, *33*(3), 385–406. https://doi.org/10.1016/j.pedsph.2022.07.012