



Research Articles

Optimalisasi Aktivitas Antibakteri Formulasi Hidrogel Kitosan Berbasis Jaringan Saraf *Multilayer Perceptron* dalam Bioteknologi Lingkungan

Multilayer Perceptron Neural Network Enabled Discovery of Optimal Antibacterial Chitosan Composite Hydrogel Formulations for Environmental Biotechnology

Halil Akhyar¹, Ariyan Zubaidi¹, Fitri Bimantoro¹, M. Zaenuddin Hamidi¹,
Ramadian Ridho Illahi^{2*}, Hendrawan², Susi Rahayu²

¹Program Studi Teknik Informatika, Fakultas Teknik, Universitas Mataram

²Program Studi Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Mataram

*corresponding author, email : ramadian@unram.ac.id

Manuscript received: 25-07-2025. Accepted: 28-09-2025

ABSTRAK

Pengembangan biomaterial antibakteri yang berkelanjutan sangat penting untuk kemajuan bioteknologi lingkungan dan meningkatkan pengendalian patogen. Komposit hidrogel berbasis kitin menunjukkan aktivitas antimikroba alami. Namun, penentuan formulasi optimal masih menjadi tantangan akibat interaksi nonlinier antara kitin, PVA, gelatin, dan honey (madu). Studi ini memperkenalkan jaringan saraf tiruan Multilayer Perceptron (MLP) sebagai kerangka kerja prediktif dan optimasi cerdas untuk menentukan komposisi hidrogel paling efektif terhadap *Pseudomonas aeruginosa*. Model MLP dilatih menggunakan dataset sekunder dan dievaluasi melalui R^2 , MSE, RMSE, dan MAE untuk menilai akurasi prediksi dan kinerja generalisasi. Model mencapai R^2 sebesar 0.991 pada tahap pelatihan dan 0.914 pada tahap pengujian, menunjukkan kemampuan yang baik dalam menangkap hubungan variabel yang kompleks. Kemudian, optimasi berbasis grid mengidentifikasi formulasi optimal yang terdiri dari 0.06 g/mL kitosan, 0.05 g/mL PVA, 0.00 g/mL gelatin, dan 0.01 g/mL honey (madu), menghasilkan zona inhibisi maksimum sebesar 30.66 mm. Selain itu, validasi eksternal menunjukkan bahwa model MLP menghasilkan bias rata-rata sebesar 4.80%, melampaui Response Surface Methodology dan mengonfirmasi kemampuannya yang superior dalam pemodelan nonlinier. Hasil ini menunjukkan potensi jaringan saraf MLP sebagai salah satu algoritma pemodelan untuk mempercepat penemuan dan optimasi hidrogel antibakteri ramah lingkungan dalam aplikasi bioteknologi lingkungan.

Kata kunci : Prediksi Antibakteri, Optimasi Formulasi, *Pseudomonas aeruginosa*

ABSTRACT

The development of sustainable antibacterial biomaterials is essential for advancing environmental biotechnology and improving pathogen control. Chitosan-based composite hydrogels exhibit inherent antimicrobial activity; however, identifying optimal formulations remains challenging due to nonlinear interactions among chitosan, PVA, gelatin, and honey. This study introduces a Multilayer Perceptron (MLP) neural network as an intelligent

predictive and optimization framework for determining the most effective hydrogel composition against *Pseudomonas aeruginosa*. The MLP model was trained using secondary datasets and evaluated through R^2 , MSE, RMSE, and MAE to assess predictive accuracy and generalization performance. The model achieved an R^2 of 0.991 for training and 0.914 for testing, indicating strong capability in capturing complex variable relationships. Grid-based optimization then revealed an optimal formulation comprising 0.06 g/mL chitosan, 0.05 g/mL PVA, 0.00 g/mL gelatin, and 0.01 g/mL honey, producing a maximum inhibition zone of 30.66 mm. Moreover, an external validation illustrated that the MLP model produced a mean bias of 4.80%, outperforming Response Surface Methodology and confirming its superior capacity for nonlinear modeling. These results highlight the potential of MLP neural networks as an efficient algorithm for accelerating the discovery and optimization of eco-friendly antibacterial hydrogels within environmental biotechnology applications.

Keywords: Antibacterial Prediction, Formulation Optimization, *Pseudomonas aeruginosa*

PENDAHULUAN

Pemanfaatan biomaterial berbasis biopolimer semakin berkembang seiring meningkatnya kebutuhan terhadap bahan yang ramah lingkungan, biokompatibel, dan memiliki aktivitas antibakteri tinggi. Salah satu sumber material biopolimer yaitu kitosan, merupakan biopolimer alami hasil deasetilasi kitin, yang dapat digunakan sebagai penyembuh luka, antimikroba, selain itu kitosan telah terbukti memiliki sifat biokompatibel, biodegradable, serta tidak beracun, sehingga kitosan sering digunakan pada pengaplikasian industri dan biomedis, selain itu kitosan juga telah terbukti dapat menghambat pertumbuhan bakteri seperti, *Staphylococcus aureus* dan *Pseudomonas aeruginosa* (Adiana & Syafiar, 2014; Damayanti et al., 2016; Ketabchi et al., 2017; Lahooti et al., 2016). Salah satu tantangan dalam pengembangan material tersebut adalah bagaimana memperoleh komposisi optimal agar dapat menghasilkan fungsionalitas yang tinggi dan dapat menghemat waktu serta biaya penelitian. Dalam mencapai hal tersebut, diperlukan pendekatan ilmiah yang tidak hanya mengandalkan percobaan pada laboratorium saja, tetapi juga mampu menganalisis hubungan kompleks antarvariabel komposisi yang memengaruhi kinerja material.

Penelitian (Lahooti et al., 2016), telah melakukan prediksi dan optimasi aktivitas antibakteri film hidrogel menggunakan pendekatan statistik *Response Surface Methodology* (RSM) berbasis *Central Composite Design* (CCD) untuk memprediksi dan menentukan kombinasi optimal yang menghasilkan zona hambat maksimal terhadap bakteri uji. Namun, meskipun RSM telah banyak digunakan untuk mengoptimasi berbagai parameter formulasi, metode ini memiliki keterbatasan dalam menangani hubungan non-linear yang kompleks serta pada data yang tidak presisi (Khamparia et al., 2020). Oleh karena itu, diperlukan pendekatan alternatif yang mampu memodelkan hubungan non-linear dengan lebih baik. Dalam mengatasi permasalahan tersebut digunakan pendekatan dengan menggunakan *Artificial Neural Network* (ANN), yang merupakan algoritma pembelajaran mesin yang terinspirasi dari cara kerja jaringan saraf biologis (Choi et al., 2020). ANN digunakan karena kemampuannya dalam memodelkan sistem nonlinear dan melakukan prediksi yang akurat berdasarkan pola pada data (Dananjaya et al., 2022).

Penelitian ini bertujuan untuk membangun model *Artificial Neural Network* (ANN) berbasis *Multilayer Perceptron* (MLP) serta melakukan pelatihan model menggunakan dataset dari penelitian Lahooti et al. (2016). Model ANN yang telah dilatih digunakan untuk memprediksi output berupa zona hambat antibakteri terhadap *Pseudomonas aeruginosa*.

Selanjutnya, dilakukan proses *Grid Search*, yaitu suatu metode eksplorasi untuk mencari parameter optimal (Fajri & Primajaya, 2023). Pendekatan tersebut digunakan untuk menentukan kombinasi komposisi bahan yang menghasilkan nilai zona hambat maksimal, serta membandingkan hasil prediksi optimasi yang diperoleh dari ANN terhadap hasil yang dilaporkan melalui metode RSM. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan metode prediktif yang efisien dan akurat dalam bidang formulasi material antibakteri.

METODE PENELITIAN

Metode yang digunakan dalam penelitian ini terdiri atas dua tahapan utama, yaitu pembangunan dan pelatihan model *Artificial Neural Network* (ANN) berbasis *Multilayer Perceptron* (MLP) untuk memprediksi aktivitas antibakteri terhadap *P. aeruginosa*, serta optimasi variabel input menggunakan model terlatih untuk menentukan kombinasi bahan yang menghasilkan zona hambat optimal. Dataset yang digunakan merupakan data sekunder dari penelitian (Lahooti et al., 2016), yang terdiri atas empat variabel input berupa konsentrasi kitosan (X_1), *Polyvinyl Alcohol*/PVA (X_2), Gelatin (X_3), dan *honey* (madu) (X_4), serta dua variabel output berupa diameter zona hambat terhadap *P. aeruginosa* dan *Staphylococcus aureus*. Analisis dalam penelitian ini difokuskan pada *P. aeruginosa* karena bakteri tersebut merupakan objek utama kajian aktivitas antibakteri.

Pembangunan dan Pelatihan Model ANN

Proses pelatihan model dilakukan setelah data dianalisis secara deskriptif sebagai gambaran awal pola hubungan antara variabel *input* dan *output*, termasuk identifikasi rentang nilai dan kecenderungan non-linearitas sistem. Tahap pra-pemrosesan (*preprocessing*) data meliputi pemilihan fitur dan target, dimana variabel *input* ($X_1 - X_4$) digunakan sebagai fitur dan zona hambat (Y) sebagai target. Seluruh variabel kemudian dinormalisasi menggunakan metode *Standard Scaler* agar nilai memiliki *mean* (rata-rata) 0 dan varian 1 (Ishak et al., 2025). Metode normalisasi ini bertujuan untuk menjaga kestabilan pelatihan dan mempercepat konvergensi model. Dataset selanjutnya dibagi menjadi 80% data *training* dan 20% data *testing*.

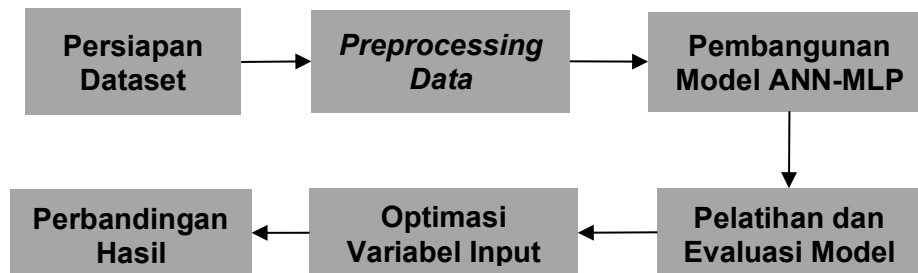
Model ANN dibangun menggunakan arsitektur *Multilayer Perceptron* (MLP) dengan empat *neuron* pada lapisan *input*, diikuti dua lapisan tersembunyi (*hidden layer*), masing-masing terdiri dari 12 dan 8 *neuron* dengan fungsi aktivasi *Rectified Linear Unit* (ReLU). Lapisan *output* terdiri atas satu *neuron* dengan fungsi aktivasi linear, karena target penelitian berupa nilai kontinu (diameter zona hambat dalam mm). Model dikompilasi menggunakan *optimizer Adam* (*Adaptive Moment Estimation*) dengan fungsi *loss* berupa *Mean Squared Error* (MSE). Proses pelatihan dilakukan selama 200 *epochs* dengan *batch size* sebesar 4. Kinerja model dievaluasi menggunakan metrik *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi (R^2) pada data latih dan uji untuk memastikan kemampuan generalisasi model sebelum digunakan dalam tahap optimasi.

Optimasi Variabel Input

Tahap optimasi variabel *input* dilakukan untuk menentukan kombinasi konsentrasi bahan ($X_1 - X_4$) yang menghasilkan nilai zona hambat maksimum. Optimasi dilakukan menggunakan model ANN-MLP terlatih melalui pendekatan *grid-based optimization (Grid-Search)*. Rentang nilai variabel ditetapkan sesuai data Lahooti et al. (2016), yaitu Kitosan (0.02–0.06 g/mL), PVA (0.01–0.05 g/mL), Gelatin (0.00–0.04 g/mL), dan Honey (madu) (0.00–0.04 g/mL). Seluruh kombinasi nilai *input* yang terbentuk kemudian dinormalisasi menggunakan parameter dari *Standard Scaler* dari tahap pelatihan, diprediksi menggunakan model ANN terlatih, dan dikembalikan ke skala asli (mm) melalui proses *inverse transform*. Kombinasi nilai *input* dengan prediksi zona hambat terbesar diidentifikasi sebagai kondisi optimum. Hasil optimasi yang diperoleh dibandingkan dengan hasil penelitian Lahooti et al. (2016) yang menggunakan metode *Response Surface Methodology (RSM)*. Perbandingan dilakukan untuk mengevaluasi kemampuan pendekatan ANN dalam merepresentasikan hubungan non-linear dan menghasilkan prediksi yang sebanding atau lebih baik daripada metode statistik konvensional. Tingkat kesesuaian prediksi terhadap nilai eksperimental dihitung menggunakan persentase (%Bias) seperti pada persamaan:

$$\%Bias = \left[\frac{PV - EV}{PV} \right] \times 100 \tag{1}$$

dengan PV merupakan nilai prediksi (*predicted value*) dan EV nilai eksperimental (*experimental value*). Nilai %Bias yang rendah menunjukkan kesesuaian yang wajar antara hasil prediksi dan data eksperimen. Secara umum, alur metode penelitian ini ditunjukkan pada diagram alir berikut.



Gambar 1. Diagram alir metode penelitian berbasis ANN-MLP

HASIL DAN PEMBAHASAN


Analisis Data Awal dan Pola Hubungan Variabel

Analisis awal terhadap dataset yang digunakan dalam pemodelan terdiri atas 30 data eksperimen dari penelitian (Lahooti et al., 2016), mencakup empat variabel komposisi bahan berupa Kitosan (X_1), PVA (X_2), Gelatin (X_3), dan Honey (X_4) terhadap respon antibakteri yang direpresentasikan melalui nilai diameter zona hambat *Pseudomonas aeruginosa* (Y). Ringkasan nilai variabel *input* dan *output* ditampilkan pada Tabel 1 berikut.

Tabel 1. Analisis statistik dataset

Variabel	Rentang (min-maks)	Rata-rata	Satuan
Kitosan (X_1)	0.02 – 0.06	0.040	g/mL
PVA (X_2)	0.01 – 0.05	0.030	g/mL
Gelatin (X_3)	0.00 – 0.04	0.020	g/mL
Honey (X_4)	0.00 – 0.04	0.020	g/mL
Zona Hambat (Y)	14.50 – 27.67	21.77	mm

Berdasarkan analisis statistik deskriptif (Tabel 1), rentang nilai variabel *input* menunjukkan variasi yang cukup luas sehingga memungkinkan model ANN untuk mempelajari pola hubungan antarvariabel secara efektif. Secara umum, peningkatan konsentrasi kitosan berkolerasi positif dengan peningkatan zona hambat, sejalan dengan literatur bahwa muatan positif gugus amina pada kitosan mampu mengganggu permeabilitas membran sel bakteri (Magani et al., 2020). Senyawa penyusun lainnya seperti PVA dilaporkan dapat meningkatkan kekuatan dan plastisitas film hidrogel pada kadar tertentu (Aprilianti et al., 2020), yang berpotensi mendukung stabilitas formulasi. Gelatin dan *honey* (madu) juga diketahui memiliki aktivitas antimikroba berspektrum luas, yaitu sebagai antibakteri, anti jamur, anti virus, dan antioksidan (Suwito et al., 2024), meskipun kontribusinya bergantung pada interaksi antarvariabel. Dengan demikian, efektivitas antibakteri tidak hanya dipengaruhi oleh masing-masing komponen secara individual, melainkan ditentukan oleh interaksi kompleks dan non-linear antarvariabel, sehingga pendekatan berbasis ANN dinilai tepat digunakan dalam penelitian ini. Hubungan antarvariabel divisualisasikan melalui *heatmap* korelasi antarvariabel pada Gambar 2 berikut.




Gambar 2. Heatmap korelasi antar variabel *input* dan *output*

Hasil analisis korelasi (Gambar 2) memperlihatkan hubungan antarvariabel *input* (Kitosan, PVA, Gelatin, dan Honey/Madu) terhadap *output* berupa zona hambat *Pseudomonas*

aeruginosa. Nilai korelasi PVA ($r = 0.58$) dan kitosan ($r = 0.47$) memiliki hubungan positif yang cukup kuat terhadap diameter zona hambat, menunjukkan peningkatan konsentrasi kedua bahan ini cenderung meningkatkan aktivitas antibakteri. Sebaliknya, Gelatin ($r = 0.03$) menunjukkan korelasi sangat lemah, mengindikasikan kontribusinya terhadap zona hambat bakteri relatif kecil. Sementara Honey ($r = 0.20$) memberikan korelasi positif lemah, namun tetap berpotensi meningkatkan aktivitas antibakteri melalui sifat antimikroba alami yang dimilikinya (Suwito et al., 2024).

Analisis Pelatihan Model ANN-MLP

Model *Artificial Neural Network* (ANN) berbasis *Multilayer Perceptron* dilatih menggunakan dataset dari penelitian (Lahooti et al., 2016). Setelah proses pelatihan selesai, dilakukan analisis bentuk kurva *loss train* untuk menilai kemampuan model dalam menangkap pola data secara progresif selama proses iterasi. Perubahan nilai *loss* terhadap jumlah *epochs* disajikan dalam grafik berikut (Gambar 3) yang digunakan untuk mengamati kestabilan proses pelatihan.



Gambar 3. Plot *train loss function*

Gambar 3 menunjukkan kurva *training history* dari model *Artificial Neural Network* (ANN) berbasis *Multilayer Perceptron* (MLP) selama proses pelatihan sebanyak 200 *epochs*. Sumbu horizontal (x) merepresentasikan jumlah *epochs*, sedangkan sumbu vertikal (y) menunjukkan nilai *Mean Squared Error* (MSE) sebagai fungsi *loss* yang digunakan untuk mengukur selisih antara nilai prediksi terhadap nilai aktual selama pelatihan. Grafik memperlihatkan nilai *loss* mengalami penurunan yang stabil tanpa mengalami fluktuasi besar hingga mendekati angka nol pada *epochs* 200. Pola ini menunjukkan bahwa model telah berhasil mempelajari pola hubungan antarvariabel input dan output secara optimal tanpa mengalami fluktuasi atau ketidakstabilan pelatihan. Nilai *loss* akhir yang sangat kecil mengindikasikan tingkat kesalahan prediksi terhadap data pelatihan berada pada batas minimal. Dengan demikian, model ANN-MLP dapat dikategorikan terlatih secara optimal.

Analisis Kinerja Model ANN-MLP

Analisis kinerja model dievaluasi dengan membandingkan nilai aktual dan nilai prediksi menggunakan sejumlah metrik statistik sebagaimana disajikan pada Tabel 2. Hasil menunjukkan bahwa model ANN-MLP memiliki kemampuan pemodelan yang sangat baik.

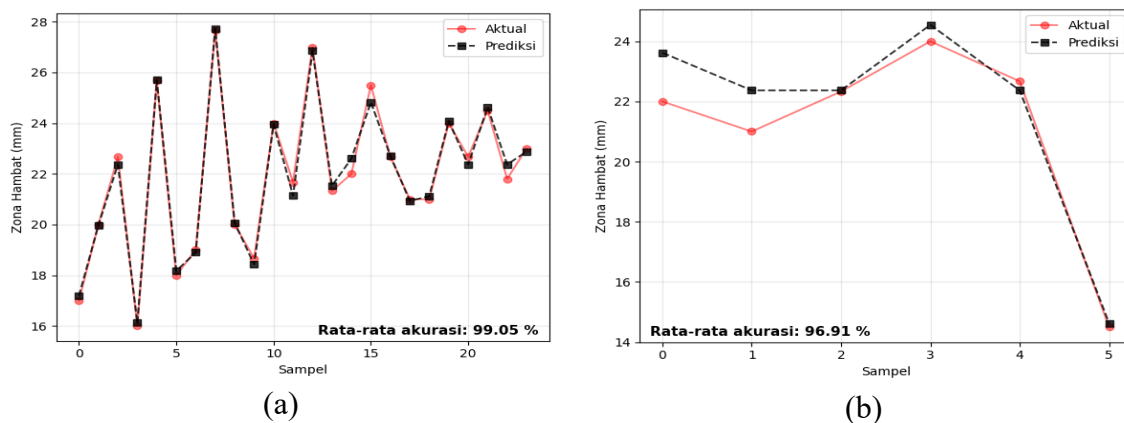
Tabel 2. Metrik evaluasi model ANN-MLP

Metrik	Train	Test
R ²	0.991	0.914
MAE	0.207	0.667
MSE	0.079	0.818
RMSE	0.281	0.904

Nilai koefisien determinasi (R²) sebesar 0.991 pada data pelatihan menunjukkan bahwa model mampu menjelaskan sekitar 99.1% variabilitas data terhadap nilai aktual, mengindikasikan tingkat kecocokan yang sangat tinggi. Sementara itu, nilai R² pada data pengujian sebesar 0.914 mengonfirmasi kemampuan generalisasi model yang baik (akurasi prediksi 91.4%) pada data yang tidak digunakan dalam proses pelatihan. Hal ini menunjukkan bahwa model ANN-MLP tidak hanya mampu melakukan pembelajaran efektif terhadap data pelatihan, tetapi juga adaptif ketika diterapkan pada data baru. Nilai MAE dan RMSE pada data pelatihan relatif rendah (0.207 dan 0.281), yang menandakan bahwa kesalahan prediksi rata-rata berada pada tingkat minimal dan model menghasilkan prediksi yang konsisten. Meskipun terjadi sedikit peningkatan kesalahan pada data pengujian (MAE = 0.667 dan RMSE = 0.904), perbedaan ini masih berada dalam rentang yang dapat diterima. Kondisi ini menunjukkan bahwa model tidak mengalami *overfitting* secara signifikan dan tetap stabil saat diuji data baru. Secara keseluruhan, evaluasi terhadap kinerja metrik menunjukkan bahwa model ANN-MLP mampu merepresentasikan hubungan non-linear antarvariabel input dan output dengan akurasi prediktif yang sangat baik. Dengan demikian, model ini dinilai layak digunakan untuk proses optimasi formulasi antibakteri pada tahap selanjutnya.

Perbandingan Nilai Aktual dan Prediksi

Perbandingan antara nilai aktual dan prediksi pada data pelatihan dan pengujian disajikan dalam bentuk grafik (Gambar 4) berikut.



Gambar 4. (a) Perbandingan aktual dan prediksi data pelatihan (b) Perbandingan aktual dan prediksi data pengujian

Gambar 4 memperlihatkan bahwa garis prediksi (hitam) hampir berhimpit dengan garis nilai aktual (merah), baik pada data pelatihan maupun data pengujian, walaupun ada sedikit perbedaan yang tidak terlalu jauh pada data pengujian. Akurasi prediksi mencapai 99.05% pada data latih dan 96.91% pada data uji. Hasil ini mengonfirmasi stabilitas ANN-MLP dalam

merepresentasikan fenomena eksperimental, sekaligus memperkuat perannya sebagai alat prediksi alternatif dalam optimasi formulasi antibakteri.

Optimasi Variabel Input

Hasil optimasi variabel *input* menggunakan metode *grid-based optimization (Grid Search)* menunjukkan bahwa kombinasi variabel (Tabel 3) menghasilkan zona hambat prediksi sebesar 30.66 mm.

Tabel 3. Hasil prediksi komposisi optimum

Variabel	Nilai Optimum	Satuan
Kitosan	0.060	g/mL
PVA	0.050	g/mL
Gelatin	0.000	g/mL
Honey	0.010	g/mL
Zona Hambat (prediksi)	30.66	mm

Hasil prediksi komposisi optimum (Tabel 3) menunjukkan bahwa peningkatan konsentrasi kitosan dan PVA secara bersamaan berkontribusi signifikan terhadap efektivitas antibakteri. Sementara itu, gelatin pada kondisi optimum justru bernilai nol, yang mengindikasikan bahwa keberadaan gelatin dalam konsentrasi tinggi tidak diperlukan atau bahkan dapat mengurangi efektivitas terhadap zona hambat. Selain itu, penambahan madu (*honey*) dalam jumlah kecil memiliki peran tambahan terhadap peningkatan aktivitas antibakteri, karena sifat antimikroba alami yang dimilikinya. Secara keseluruhan, hasil optimasi ini menunjukkan bahwa pendekatan ANN-MLP berbasis *Grid-based optimization (Grid Search)* mampu melakukan eksplorasi ruang kombinasi dengan sangat luas dan efektif, sehingga diperoleh kondisi optimum.

Perbandingan ANN dengan RSM

Uji validasi eksternal untuk memastikan kemampuan generalisasi model *Artificial Neural Network (ANN)* dilakukan menggunakan lima data komposisi optimum yang diambil dari penelitian (Lahooti et al., 2016). Data ini tidak digunakan saat pelatihan, sehingga dapat menggambarkan kinerja prediktif ANN secara nyata terhadap data baru yang belum pernah diberikan pada model. Pada kedua tabel dibawah ini memperlihatkan perbandingan antara nilai aktual hasil eksperimen Lahooti et al. (2016) dengan pendekatan RSM dan nilai prediksi ANN yang dihasilkan dari model terlatih.

Tabel 4. Prediksi vs Aktual dengan RSM*)

Sampel	Komposisi				Zona Hambat		%Bias
	Kitosan	PVA	Gelatin	Honey	Prediksi	Aktual	
A	0.03	0.05	0.01	0.02	30.65	28	8.646
B	0.04	0.05	0.01	0.02	31.56	29	8.111
C	0.05	0.05	0.01	0.02	30.3	27	10.891
D	0.06	0.05	0.01	0.01	29.3	27	7.850
E	0.06	0.05	0.01	0.02	30.98	30	3.163

Sumber: *) (Lahooti et al., 2016)

Hasil perbandingan (Tabel 4 dan Tabel 5) menunjukkan bahwa metode RSM menghasilkan rata-rata %Bias sebesar 7.73%, sedangkan model ANN menghasilkan rata-rata %Bias sebesar 4.80%. Nilai bias yang lebih rendah pada ANN menunjukkan akurasi prediktif yang lebih tinggi. Pada sampel optimum (Sampel E), ANN memberikan prediksi sebesar 28.15 mm terhadap nilai eksperimental 30 mm (bias 6.57%), sedangkan RSM menunjukkan bias sebesar 3.16%. Hal ini menegaskan bahwa ANN unggul dalam akurasi prediksi secara keseluruhan, meskipun pada titik tunggal tertentu RSM mampu menghasilkan prediksi lebih mendekati. Secara umum, hasil validasi eksternal membuktikan bahwa ANN-MLP memiliki kemampuan generalisasi yang baik dan lebih mampu mengatasi kompleksitas hubungan non-linear antarvariabel dibandingkan pendekatan statistik konvensional seperti RSM. Dengan demikian, model ANN-MLP dapat direkomendasikan sebagai alternatif metode optimasi formulasi antibakteri berbasis material komposit.

Tabel 5. Prediksi vs Aktual dengan ANN

Sampel	Komposisi				Zona Hambat		%Bias
	Kitosan	PVA	Gelatin	Honey	Prediksi	Aktual	
A	0.03	0.05	0.01	0.02	27.50	28	1.818
B	0.04	0.05	0.01	0.02	29.15	29	0.514
C	0.05	0.05	0.01	0.02	29.05	27	7.056
D	0.06	0.05	0.01	0.01	29.37	27	8.069
E	0.06	0.05	0.01	0.02	28.15	30	6.571

Secara keseluruhan, hasil validasi eksternal membuktikan bahwa model ANN-MLP yang dikembangkan tidak hanya memiliki performa tinggi pada data pelatihan dan pengujian internal, tetapi juga menunjukkan konsistensi yang baik terhadap data eksternal (data baru). Hal ini menegaskan bahwa pendekatan ANN mampu menangkap hubungan non-linear yang kompleks antara variabel input (kitosan, pva, gelatin, dan honey/madu) dengan respon zona hambat antibakteri (*P. aeruginosa*), lebih baik dibandingkan model statistik seperti RSM. Dengan demikian, hasil dari prediksi pada data eksternal ini memperkuat model ANN memiliki kapasitas generalisasi yang baik, serta dapat digunakan sebagai alat prediksi alternatif yang efektif dalam optimasi formulasi antibakteri.

KESIMPULAN

Pendekatan pemodelan menggunakan *Artificial Neural Network* (ANN) berbasis *Multilayer Perceptron* (MLP) terbukti efektif dalam memprediksi dan mengoptimasi aktivitas antibakteri formulasi hidrogel komposit berbasis kitosan. Model menunjukkan kemampuan generalisasi yang sangat baik dengan nilai R^2 sebesar 0.991 pada data latih dan 0.914 pada data uji. Kombinasi optimum yang dihasilkan, yaitu kitosan 0.060 g/mL, PVA 0.050 g/mL, gelatin 0.000 g/mL, dan madu 0.010 g/mL, menghasilkan prediksi zona hambat terhadap *P. aeruginosa* sebesar 30.66 mm. Perbandingan dengan metode RSM menunjukkan bahwa ANN memiliki kinerja prediktif yang lebih tinggi secara keseluruhan dengan nilai rata-rata sebesar 4.80% lebih rendah dari RSM sebesar 7.73%. Dengan demikian, seluruh tujuan penelitian telah tercapai, yaitu membangun model ANN-MLP yang akurat, menentukan komposisi optimum, serta menunjukkan perbandingan pendekatan RSM dengan ANN.

Ucapan Terimakasih.

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan dukungan dan bantuan selama pelaksanaan penelitian. Penelitian ini didukung oleh pendanaan dari sumber Penerimaan Negara Bukan Pajak (PNBP) Universitas Mataram skema dosen pemula tahun 2025 No : 3223/UN18.L1/PP/2025.

DAFTAR PUSTAKA

- Adiana, I. D., & Syafiar, L. (2014). PENGGUNAAN KITOSAN SEBAGAI BIOMATERIAL DI KEDOKTERAN GIGI (USE OF CHITOSAN AS A BIOMATERIAL IN DENTISTRY). In *dentika Dental Journal* (Vol. 18, Issue 2).
- Aprilianti, N., Hajrah, H., & Sastyarina, Y. (2020). Optimasi Polivinilalkohol (PVA) Sebagai Basis Sediaan Gel Antijerawat. *Proceeding of Mulawarman Pharmaceuticals Conferences*, 11, 17–21. <https://doi.org/10.25026/mpc.v11i1.387>
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Campbell, J. P. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science and Technology*, 9(2). <https://doi.org/10.1167/tvst.9.2.14>
- Damayanti, W., Rochima, E., & Hasan, Z. (2016). Aplikasi Kitosan sebagai Antibakteri pada Filet Patin selama Penyimpanan Suhu Rendah. *JPHPI* 2016, 19(3), 321–328. <https://doi.org/10.17844/jphpi.2016.19.3.321>
- Dananjaya, R. H., Sutrisno, S., & Fitriady, S. (2022). PENERAPAN ARTIFICIAL NEURAL NETWORK (ANN) DALAM MEMPREDIKSI KAPASITAS DUKUNG FONDASI TIANG. *Matriks Teknik Sipil*, 10(4), 419. <https://doi.org/10.20961/mateksi.v10i4.65034>
- Fajri, M., & Primajaya, A. (2023). Komparasi Teknik Hyperparameter Optimization pada SVM untuk Permasalahan Klasifikasi dengan Menggunakan Grid Search dan Random Search. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 7, Issue 1). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Ishak, R., Nurmawanti, & Amiruddin. (2025). Optimasi K-Means pada Clustering Penyakit Ibu Hamil Menggunakan Random Forest. *Jambura Journal of Electrical and Electronics Engineering*, 7(1), 41–47.
- Ketabchi, N., Naghibzadeh, M., Adabi, M., Esnaashari, S. S., & Faridi-Majidi, R. (2017). Preparation and optimization of chitosan/polyethylene oxide nanofiber diameter using artificial neural networks. *Neural Computing and Applications*, 28(11), 3131–3143. <https://doi.org/10.1007/s00521-016-2212-0>
- Khamparia, A., Pandey, B., Pandey, D. K., Gupta, D., Khanna, A., & de Albuquerque, V. H. C. (2020). Comparison of RSM, ANN and Fuzzy Logic for extraction of Oleonolic Acid from *Ocimum sanctum*. *Computers in Industry*, 117. <https://doi.org/10.1016/j.compind.2020.103200>
- Lahooti, B., Khorram, M., Karimi, G., Mohammadi, A., & Emami, A. (2016). Modeling and optimization of antibacterial activity of the chitosan-based hydrogel films using central composite design. *Journal of Biomedical Materials Research - Part A*, 104(10), 2544–2553. <https://doi.org/10.1002/jbm.a.35799>

- Magani, A. K., Tallei, T. E., & Kolondam, B. J. (2020). Uji Antibakteri Nanopartikel Kitosan terhadap Pertumbuhan Bakteri *Staphylococcus aureus* dan *Escherichia coli*. *Jurnal Bios Logos*, 10(1), 7–12.
- Suwito, W., Andriani, A., Amelia, I., Rohmayanti, T., Haris, H., & Karimy, M. F. (2024). Aktivitas Madu sebagai Antibakteri *Staphylococcus aureus* dan *Escherichia Coli* O157:H7. *Jurnal Sain Veteriner*, 42(1), 82. <https://doi.org/10.22146/jsv.90498>