

## PREDICTION OF DEPTH OF NITRIDE LAYER IN IRON DURING GAS NITRIDING USING NEURAL NETWORK

Jan Setiawan<sup>1) 2)</sup>

<sup>1</sup> Electrical Engineering, Pamulang University

<sup>2</sup>Research Center for Advanced Materials, National Research and Innovation Agency

<sup>1</sup>Jl.Raya Puspittek, Buaran, Tangerang Selatan, 15310

<sup>2</sup>Science Techno Park Building 224, Tangerang Selatan, 15310

E-mail: jansetiawan.lecturer@gmail.com<sup>1) 2)</sup>

### ABSTRACT

*Surface engineering of materials can add economic value to the material. Gas nitriding in iron is a typical thermochemical surface engineering process at eutectoid temperatures, where nitrogen diffuses to the surface to form nitride layers in the form of gamma phase and epsilon phase. In this study, a computational approach will be taken to predict the formation of the nitriding layer. In the prediction, a backpropagation neural network is used with input parameters of temperature, nitriding potential and time with an output of nitriding layer depth. This prediction does not distinguish the phase formed in the nitriding layer. The best results were obtained in the model of single hidden layer with 5 neurons and two hidden layers with the formation starting with 6 neurons followed by 5 neurons. The mean square error of the training data for the single hidden layer is 0.0027. While for two hidden layers the value is higher at 0.0032. The results obtained for the absolute mean error and root mean square values for the single hidden layer model are 0.6117 and 0.9670. For the two hidden layers model, the absolute error and root mean square values are 0.5894 and 1.0472. It can be seen from the correlation coefficient that both models can only predict well at depths of more than 10  $\mu\text{m}$ .*

**Keywords:** Gas Nitriding, Eutectoid Temperature, Diffusion, Backpropagation, Neural Network.

### 1. PENDAHULUAN

Proses nitridasi gas dipatenkan pada tahun 1913 dan 1921. Pemanfaatan proses nitridasi untuk rekayasa permukaan telah digunakan di sektor industri sejak tahun 1920 dengan tujuan untuk meningkatkan daya tahan komponen terhadap keausan, kelelahan, dan korosi (Zhou dkk, 2023; Huang dkk, 2023). Proses ini dilakukan pada temperatur yang berkisar antara 550 hingga 580 °C, memanfaatkan tungku dalam atmosfer amonia yang terdisosiasi. Teknik ini menawarkan manfaat untuk mencapai keseragaman temperatur di seluruh volume dan laju pemanasan yang cepat. Nitridasi gas adalah proses termokimia yang umum digunakan untuk memodifikasi permukaan benda kerja pada temperatur eutectoid. Selama proses ini, nitrogen ditransfer dari sumber seperti gas amonia ke permukaan benda kerja, menghasilkan pembentukan dua fase: fase gamma ( $\gamma'$ -Fe<sub>4</sub>N) dan fase epsilon ( $\varepsilon$ -Fe<sub>3</sub>N) (Funch dkk, 2022; Korecka dkk, 2023). Nitridasi biasanya dilakukan di bawah temperatur eutektoid Fe-N, yaitu sekitar 590 °C. Dilakukan pada temperatur tersebut agar tidak ada perubahan fasa selama proses nitridasi berlangsung. Selama proses nitridasi akan terjadi (Berladir dkk, 2023; Caballero, 2021), interaksi antara media nitridasi dan permukaan material besi, untuk menghasilkan nitrogen reaktif. Nitrogen akan berdifusi di area ini, di mana nitrogen bereaksi dengan elemen paduan apa pun yang mungkin ada. Pembentukan presipitat nitrida yang sangat halus dalam reaksi ini akan menyebabkan pengerasan.

Reaksi utama yang terlibat dalam nitridasi gas adalah dekomposisi katalitik amonia, yang menghasilkan pembentukan unsur nitrogen. Reaksi yang terjadi satu molekul amonia akan terdekomposisi menjadi satu molekul nitrogen dan 3/2 gas hidrogen (Caballero, 2021). Parameter utama yang mengatur proses ini adalah waktu, temperatur, dan laju pemisahan gas. Namun, memantau konsentrasi nitrogen secara akurat dalam teknik ini menimbulkan tantangan yang signifikan. Melakukan estimasi dan replikasi struktur lapisan nitrida dan keseluruhan proses secara inheren memberikan tantangan. Prosedur nitridasi gas yang disempurnakan dilakukan dengan menggunakan campuran gas amonia dan aditif gas. Perbedaan utama dengan nitridasi gas konvensional selama proses nitridasi berlangsung proses difusinya tidak dapat diatur oleh tingkat disosiasi. Parameter yang digunakan adalah potensial nitridasi dari atmosfer tungku. Potensi nitridasi didefinisikan sebagai hasil bagi tekanan parsial amonia dan hidrogen. Manfaat dari penggunaan teknik ini adalah tercapainya permukaan nitrida yang seragam pada bentuk yang rumit. Pada temperatur tinggi akan mempercepat proses nitridasi (Setiawan, Riyanto & Banawa, 2021). Namun, penting untuk dicatat bahwa tantangan yang melekat pada proses nitridasi gas, seperti kebutuhan untuk secara selektif melindungi daerah tertentu untuk mencegah nitridasi, tetapi ada dan tidak dapat dielakkan.

Untuk mendapatkan lapisan nitrida yang memiliki komposisi dan kedalaman yang akurat pada permukaan material, diperlukan lingkungan yang berlimpah dengan

nitrogen yang akan meresap sepenuhnya ke dalam permukaan material. Pengendalian yang tepat terhadap komposisi media, temperatur, dan durasi sangat penting untuk keberhasilan pelaksanaan proses termokimia (Ramezani dkk, 2023). Pengembangan aplikasi komputer telah dikembangkan untuk membantu mensimulasikan proses termokimia. Pengembangan aplikasi ini adalah untuk mendapatkan lapisan yang sesuai dengan persyaratan yang ditentukan dan sifat fungsional yang diinginkan (Li dkk, 2023).

Dalam mengembangkan rekayasa permukaan semakin tertarik untuk menggunakan teknik *machine learning* dan *artificial intelligence* (AI). Penggunaan model dan adanya kumpulan data yang besar, teknologi ini dapat membantu dalam mendesain dan optimalisasi struktur permukaan, pelapisan, dan modifikasi. Selain itu, algoritma *machine learning* dapat digunakan untuk membuat material baru yang memiliki sifat permukaan yang dimodifikasi; sehingga memungkinkan penyelesaian proses rekayasa permukaan menjadi lebih cepat dan lebih efisien. *Backpropagation Neural Network* (BPNN) adalah model *neural network* (NN) yang biasa digunakan untuk tujuan pemecahan masalah (Rashid dkk, 2020; Kuang dkk, 2022). Model ini digunakan karena kemampuannya untuk secara efektif mengenali pola esensial dan meramalkan terjadinya fakta atau fenomena sebelum hal tersebut benar-benar terjadi. Meskipun arsitektur *backpropagation network* memiliki potensi untuk menyertakan beberapa *hidden layer* berdasarkan kebutuhan sistem, namun sebenarnya hanya terdiri dari *hidden layer* tunggal. Sebaliknya, jumlah pola input dan pola output menentukan jumlah simpul yang terhubung ke lapisan input dan lapisan output. Tujuan dari pelatihan *neural network* adalah untuk menentukan nilai pembobotan yang optimal (Yanto, Sovia, & Melati, 2020). Beberapa peneliti telah menggunakan algoritma *backpropagation*, yang berasal dari *neural network*, dalam konteks analisis karakteristik material. Sebagai contoh, dalam referensi Al-Jarrah & Al-Oqla (2022), Wang dkk (2020) dan Lai dkk (2019), menggunakan algoritma *machine learning* untuk memprediksi perilaku material.

Penelitian ini akan menggunakan *backpropagation neural network* (BPNN) untuk memprediksi ketebalan lapisan nitrida pada besi yang diproses dengan gas nitridasi. Prediksi kedalaman lapisan nitrida pada besi ini dilakukan dengan parameter input yang terdiri dari parameter proses proses seperti temperatur, potensial nitridasi dan waktu proses nitridasi.

## 2. RUANG LINGKUP

Dalam penelitian ini permasalahan mencakup:

1. Permodelan kedalaman lapisan nitrida pada pemukaan besi yang diproses dengan gas nitridasi. Data yang digunakan sebagai *input* merupakan data yang berasal dari parameter proses temperatur, potensial nitridasi dan waktu proses nitridasi.
2. Data yang digunakan sebagai *input* merupakan data yang berasal dari parameter proses temperatur, potensial nitridasi dan waktu proses nitridasi. Data pelatihan diperoleh dari eksperimen proses nitridasi pada baja. Dalam proses pemodelan dipilih dua model dengan nilai *mean square error* (MSE) yang terendah. Kemudian dibandingkan nilai sensitivitas model dalam melakukan prediksi.
3. Setelah pelatihan diimplementasikan ke model, kemudian dilakukan proses prediksi terhadap data eksperimental. Kemudian dilakukan proses analisis sensitivitas model yang terdiri dari koefisien korelasi (CC) dan linearitasnya dan komparasi nilai prediksi dari dua model yang digunakan. Diperoleh juga nilai *mean square error* (MSE) dan *root mean square error* (RMSE) dari kedua model tersebut.

## 3. BAHAN DAN METODE

Penelitian ini menggunakan dua model *hidden layer* dalam *backpropagation neural network* untuk memprediksi kedalaman lapisan nitrida pada permukaan besi selama proses nitridasi gas. Model yang digunakan adalah *hidden layer* tunggal dan dua *hidden layer* seperti yang diilustrasikan pada Gambar 1.(a) dan Gambar 1.(b) sebagai arsitektur *backpropagation neural network*. Parameter *input* yang digunakan adalah temperatur, potensial nitridasi dan waktu proses. Kedua model BPNN pada Gambar 1.(a) dan 1.(b) diimplementasikan dalam aplikasi Simbrain 3.07, dengan parameter *learning rate* yang digunakan adalah 0,25 dan momentum 0,9. Fungsi aktivasi yang digunakan adalah sigmoidal biner. Fungsi aktivasi adalah fungsi logistik, dan dapat dibedakan dengan output yang bervariasi sekitar 0 sampai 1.

Data yang digunakan untuk pelatihan dan prediksi diberikan pada Tabel 1. Total data pelatihan yang digunakan pada kedua model ini adalah 112 data. Data yang diberikan adalah temperatur proses nitridasi dalam satuan derajat Celcius, potensial nitridasi merupakan bilangan tanpa satuan, waktu atau lama proses nitridasi dalam satuan jam dan kedalaman hasil nitridasi dalam satuan mikrometer yang diukur untuk menyediakan data ini. Dari data ini, parameter temperatur, potensial nitridasi dan waktu sebagai *input* dalam model BPNN. Temperatur untuk data latihan adalah 500, 550, 600, 650, 700, 750 dan 800 °C. Untuk potensial nitridasi nilai berada pada rentang 0 sampai 1. Nilai ini menentukan seberapa besar kemungkinan terbentuknya lapisan nitrida dengan struktur yang tertentu. Semakin tinggi nilainya akan menghasilkan fase nitrida yang kaya akan nitrogen menjadi lebih tinggi lagi. Struktur dari lapisan nitida ini sebagai fungsi potensial dan temperatur disajikan dalam grafik Lehrer. Waktu proses nitridasi memiliki fenomena yang serupa, semakin lama kemungkinan terbentuk lapisan nitrida yang lebih dalam. Parameter *output* yang diinginkan adalah ketebalan lapisan nitrida

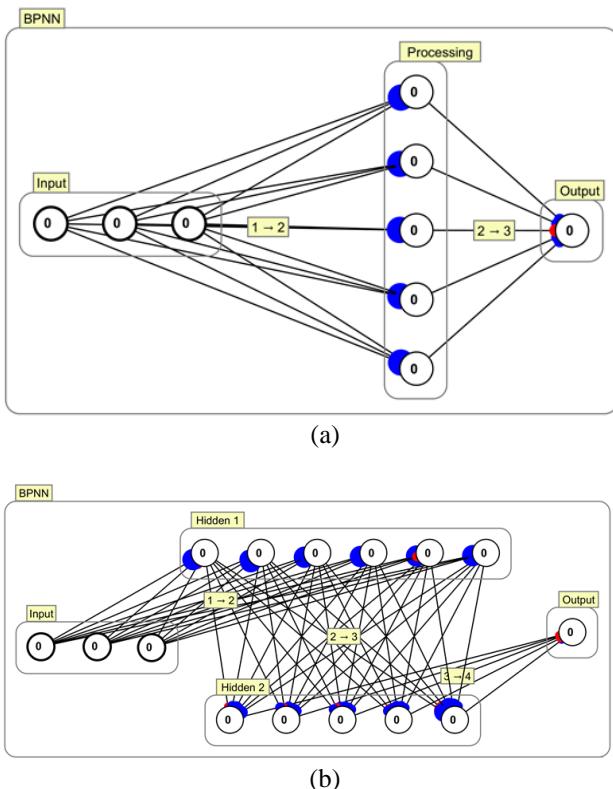


yang terbentuk pada permukaan baja murni yang telah

melalui proses nitridasi gas.

**Tabel 1. Data Eksperimental Proses Nitridasi Gas Beserta Nilai Kedalaman Lapisan Nitrida**

No	Temperatur (°C)	Potensial Nitridasi	Waktu (jam)	Kedalaman (μm)	No	Temperatur (°C)	Potensial Nitridasi	Waktu (jam)	Kedalaman (μm)
1	500	0,62	2	5,69	57	500	0,46	3	7,62
2	500	0,52	1	7,73	58	500	0,31	3	7,99
3	500	0,44	1	9,40	59	500	0,38	3	10,61
4	500	0,53	2	10,86	60	500	0,76	3	11,69
5	550	0,60	1	11,69	61	550	0,44	3	12,11
6	550	0,30	2	12,32	62	550	0,65	3	12,53
7	550	0,79	1	12,73	63	550	0,58	3	12,84
8	550	0,69	1	12,94	64	550	0,62	3	13,05
9	600	0,34	2	13,15	65	600	0,65	3	13,36
10	600	0,50	1	13,47	66	600	0,71	3	13,47
11	600	0,42	1	13,57	67	600	0,51	3	13,67
12	600	0,43	2	13,78	68	600	0,47	3	13,99
13	650	0,60	1	13,99	69	650	0,44	3	14,20
14	650	0,47	2	14,30	70	650	0,31	3	14,41
15	650	0,43	1	14,41	71	650	0,70	3	14,72
16	650	0,32	1	14,82	72	650	0,74	3	15,03
17	700	0,52	1	15,14	73	700	0,41	3	15,14
18	700	0,62	2	15,34	74	700	0,54	3	15,34
19	700	0,78	2	15,45	75	700	0,47	3	15,76
20	700	0,77	1	15,76	76	700	0,44	3	15,87
21	750	0,67	1	16,05	77	750	0,40	3	16,08
22	750	0,80	2	16,28	78	750	0,46	3	16,39
23	750	0,42	2	16,60	79	750	0,46	3	16,60
24	750	0,59	1	16,81	80	750	0,47	3	16,91
25	800	0,33	2	17,01	81	800	0,53	3	17,23
26	800	0,43	1	17,33	82	800	0,73	3	17,43
27	800	0,56	1	17,54	83	800	0,61	3	17,85
28	800	0,34	2	18,06	84	800	0,48	3	18,59
29	500	0,44	2	6,37	85	500	0,54	3	7,60
30	500	0,33	2	7,83	86	500	0,33	3	9,29
31	500	0,30	2	10,20	87	500	0,73	4	10,20
32	500	0,63	2	10,86	88	500	0,56	3	11,27
33	550	0,56	2	11,69	89	550	0,36	3	12,00
34	550	0,50	2	12,42	90	550	0,76	4	12,42
35	550	0,30	2	12,73	91	550	0,78	4	12,84
36	550	0,40	2	12,94	92	550	0,45	4	13,00
37	600	0,51	2	13,15	93	600	0,59	3	13,15
38	600	0,31	2	13,47	94	600	0,69	4	13,47
39	600	0,75	2	13,57	95	600	0,56	3	13,57
40	600	0,44	2	13,88	96	600	0,40	4	13,99
41	650	0,35	2	14,09	97	650	0,55	4	14,20
42	650	0,70	2	14,30	98	650	0,70	4	14,41
43	650	0,35	2	14,61	99	650	0,80	4	14,72
44	650	0,62	2	14,93	100	650	0,75	4	15,14
45	700	0,60	2	15,14	101	700	0,79	3	15,24
46	700	0,31	2	15,34	102	700	0,40	4	15,45
47	700	0,69	2	15,45	103	700	0,72	3	15,76
48	700	0,65	2	15,76	104	700	0,59	4	15,97
49	750	0,44	2	16,08	105	750	0,63	3	16,28
50	750	0,49	2	16,39	106	750	0,78	4	16,39
51	750	0,69	2	16,60	107	750	0,72	3	16,70
52	750	0,55	2	16,81	108	750	0,54	4	16,91
53	800	0,35	2	17,22	109	800	0,55	3	17,33
54	800	0,50	2	17,33	110	800	0,46	4	17,43
55	800	0,62	2	17,85	111	800	0,52	3	17,95
56	800	0,69	2	18,48	112	800	0,65	3	18,68



**Gambar 1. Arsitektur Backpropagation Neural Network (a) Hidden Layer Tunggal dan (b) Dua Hidden Layer Untuk Memprediksi Kedalaman Lapisan Nitrida.**

**Tabel 2. Data Eksperimental Proses Nitridasi Gas Beserta Nilai Kedalaman Lapisan Nitrida**

Koefisien Korelasi	Interpretasi
0,9 – 1	Sangat Tinggi
0,7 – 0,899	Tinggi
0,4 – 0,699	Cukup
0,2 – 0,399	Rendah
< 0,2	Sangat Rendah

**Tabel 3. Nilai sensitivitas Backpropagation Neural Network**

Model hidden layer dan Jumlah Neuron	MSE pelatihan saat 20,000 iterasi	Prediksi			
		CC < 10 µm	CC > 10 µm	MAE	RMSE
Hidden layer tunggal (5 neuron)	0,0027	0,3994	0,9775	0,6117	0,9670
Dua hidden layer (6 – 5 neuron)	0,0032	0,3948	0,9760	0,5894	1,0472

Seperti yang dapat diamati, *hidden layer* tunggal dengan 5 neuron memiliki nilai pelatihan MSE saat mencapai 20.000 iterasi sebesar 0,0027. Hasil ini lebih rendah dibandingkan dengan nilai pelatihan MSE dari dua hidden layer sebesar 0,0032 pada iterasi yang sama. Dari jumlah neuron yang diberikan pada *hidden layer* tunggal, penambahan atau pengurangan jumlah neuron menghasilkan nilai pelatihan MSE yang lebih rendah dari nilai ini. Nilai MAE dan RMSE untuk prediksi terhadap data uji sangat besar. Distribusi data prediksi dengan

#### 4. PEMBAHASAN

Sebanyak 112 data yang terdiri dari temperatur, potensial nitridasi dan waktu proses nitridasi dengan output kedalaman lapisan nitridasi disediakan sebagai data pelatihan untuk BPNN dengan *hidden layer* tunggal dan dua *hidden layer*. Proses pelatihan dilakukan hingga 20.000 iterasi. Nilai MSE dari pelatihan dan sensitivitas BPNN untuk nilai prediksi seperti MAE, RMSE dan CC menggunakan Persamaan 1 hingga 3, ditunjukkan pada Tabel 3.

Kinerja BPNN dievaluasi dengan *mean absolute error* (MAE), *root mean square error* (RMSE) dan koefisien korelasi (CC) yang diberikan oleh persamaan berikut (Zhang & Xu, 2020),

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i^{exp} - x_i^{pred}| \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^{exp} - x_i^{pred})^2} \quad (2)$$

$$CC = \frac{\sum_{i=1}^n (x_i^{exp} - \bar{x}^{exp})(x_i^{pred} - \bar{x}^{pred})}{\sqrt{\sum_{i=1}^n (x_i^{exp} - \bar{x}^{exp})^2} \sqrt{\sum_{i=1}^n (x_i^{pred} - \bar{x}^{pred})^2}} \quad (3)$$

di mana n adalah jumlah total data,  $x_i^{exp}$  adalah data eksperimen ke-i untuk kedalaman lapisan nitrida, dan nilai rata-ratanya adalah  $\bar{x}^{exp}$ . Nilai prediksi ke-i untuk kedalaman lapisan nitrida dilambangkan dengan  $x_i^{pred}$ , dan nilai rata-ratanya adalah  $\bar{x}^{pred}$ . Interpretasi untuk koefisien korelasi diberikan pada Tabel 2 (Daru dkk, 2021),

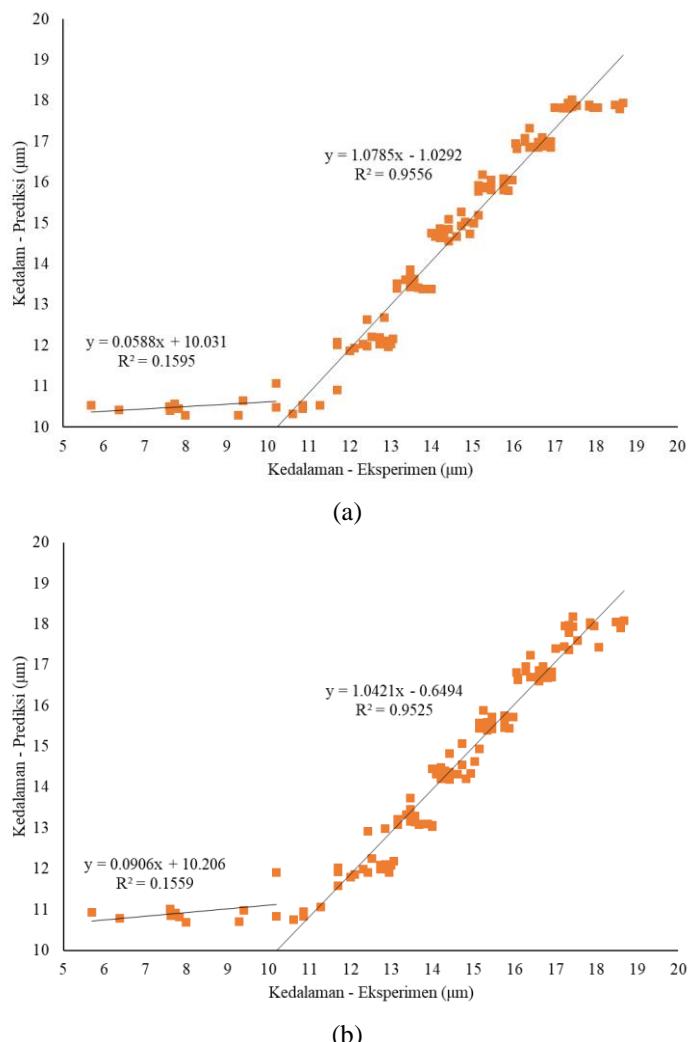
kedalaman percobaan lapisan nitrida diberikan pada Gambar 2.

Distribusi data pada Gambar 2 dapat dibagi menjadi dua bagian yang dapat didekati dengan garis lurus. Fungsi polinomial hingga orde keempat dapat digunakan jika perkiraan diberlakukan untuk keseluruhan data. Pendekatan garis lurus dapat ditentukan dengan batas pada kedalaman eksperimental lapisan nitrida sebesar 10 µm. Untuk *hidden layer* tunggal dapat dilihat pada Gambar 2.(a), koefisien korelasi pendekatannya memiliki



nilai yang sedikit lebih tinggi daripada koefisien korelasi yang diperoleh dari dua *hidden layer* seperti yang terlihat pada Gambar 2.(b). Meskipun perbedaan nilai koefisien korelasi untuk kedua model ini masih masuk dalam kategori yang sama. Kedalaman lapisan nitrida eksperimental yang nilainya kurang dari 10  $\mu\text{m}$  memiliki korelasi yang rendah dan bertolak belakang nilainya menjadi korelasi yang sangat tinggi pada kedalaman lapisan nitrida yang lebih dari 10  $\mu\text{m}$ . Berdasarkan temuan ini, dapat disimpulkan bahwa model BPNN dengan data pelatihan yang ada sangat baik dalam memprediksi nilai kedalaman lapisan nitrida lebih dari

10  $\mu\text{m}$ . Hal ini kemungkinan besar disebabkan oleh jumlah data pelatihan untuk kedalaman lapisan nitrida kurang dari 10  $\mu\text{m}$  terbatas. Koefisien korelasi yang memiliki interpretasi sangat tinggi diantara data kedalaman lapisan nitrida prediksi dan eksperimen, serta kinerja model yang stabil menunjukkan pemodelan BPNN berguna dalam memahami hubungan antara variabel *input* dan *output* (Varshini dkk, 2021). Hasil prediksi kedalaman lapisan nitrida berdasarkan nilai yang diuji pada kedua model BPNN disajikan pada Tabel 4.

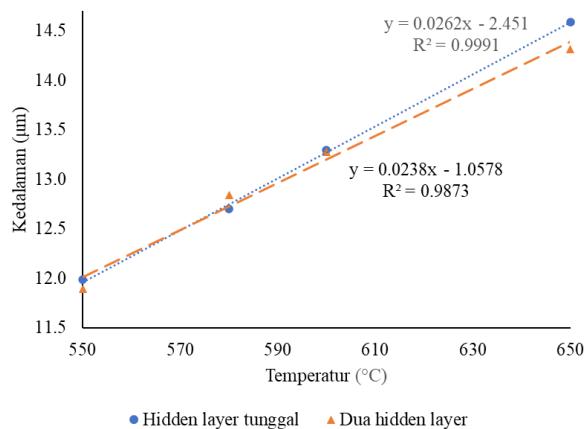


Gambar. 2. Korelasi Linear Antara Nilai Prediksi dan Eksperimen Kedalaman Lapisan Nitrida Pada Model *hidden layer* (a) Tunggal dan (b) Dua.

Tabel 4. Data Uji Proses Nitridasi Gas Beserta Nilai Kedalaman Lapisan Nitrida Hasil Prediksi

Temperatur ( $^{\circ}\text{C}$ )	Potential Nitridasi	Waktu Nitridasi (jam)	Kedalaman ( $\mu\text{m}$ )	
			Hidden layer tunggal	Dua <i>hidden layers</i>
550	0,44	2	11.98442	11.89399
580	0,34	1	12.70112	12.84013
600	0,39	1	13.29854	13.27822
650	0,39	1	14.58588	14.31623

Hasil pengujian untuk *hidden layer* tunggal dan dua *hidden layer* menunjukkan perbedaan nilai yang serupa. Dari eksperimen yang dilakukan oleh Sun dkk (2019) dengan proses nitridasi dua tahap diperoleh pada temperatur 280 °C selama 2 jam yang dilanjutkan dengan nitridasi pada temperatur 550 °C selama 6 jam diperoleh kedalaman lapisan nitrida sebesar 25 µm. Biasanya, kedalaman lapisan nitrida lebih besar pada *hidden layer* tunggal dibandingkan dengan dua *hidden layer*. Parameter temperatur proses nitridasi memiliki dampak yang signifikan dalam meningkatkan kedalaman lapisan nitrida, seperti yang terlihat dari ketiga parameter masukan. Prediksi kedalaman lapisan nitrida dari Tabel 4 disandingkan dalam Gambar 3 terlihat korelasi positif antara temperatur dan kedalaman lapisan nitrida. Melakukan percobaan dengan dua model menunjukkan korelasi yang signifikan antara temperatur proses nitridasi dan kedalaman lapisan nitrida. Selain prediksi hasil proses nitridasi dengan pendekatan BPNN merupakan pilihan yang tepat juga dalam memprediksi struktur mikro dan profil kekerasan sebagai fungsi dari proses nitridasi. Parameter proses yang dapat digunakan antara lain waktu, temperatur dan tingkat unsur paduan dalam proses nitridasi. Model BPNN dapat dikembangkan dan digunakan untuk mengkorelasikan parameter proses dan komposisi paduan untuk mendapatkan sifat yang diinginkan untuk tujuan tertentu.



**Gambar 3. Prediksi Kedalaman Lapisan Nitrida yang Diberikan Data Dari Tabel 4.**

## 5. KESIMPULAN

Investigasi ini mengungkapkan bahwa lapisan nitrida kedalaman selama nitridasi besi dapat ditentukan dengan menggunakan BPNN. Data pelatihan dan ketepatannya dalam menentukan parameter memiliki dampak yang signifikan terhadap analisis BPNN, meskipun efektivitasnya tinggi dalam menghasilkan prediksi. Kedalaman lapisan nitrida telah diprediksi dengan menggunakan tiga variabel: temperatur, potensial nitridasi, dan waktu untuk proses nitridasi besi. Nilai RMSE pelatihan model *hidden layer* tunggal adalah 0,0027, yang lebih kecil dari nilai RMSE pelatihan

model dua *hidden layer* 0,0032. Model *hidden layer* tunggal memprediksi bahwa nilai MAE dan RMSE masing-masing adalah 0,6117 dan 0,9670. Sebaliknya, model dua *hidden layer* menghasilkan prediksi nilai MAE dan RMSE masing-masing sebesar 0,5894 dan 1,0472. Nilai MAE dan RSME ini masih relatif tinggi (Kassaymeh dkk, 2021) sehingga sangat memungkinkan dilakukan modifikasi dengan melakukan hibridisasi terhadap estimator dalam BPNN untuk mengoptimalkan parameternya guna mengurangi kesalahan estimasi secara keseluruhan, yang akan meningkatkan akurasi estimasi (Kassaymeh dkk, 2022). Dari analisis korelasi terlihat bahwa terdapat hubungan yang lemah untuk kedalaman eksperimen lapisan nitrida di bawah 10 µm, dan korelasi yang kuat untuk kedalaman di atas 10 µm. Mengingat ketepatan hasil, BPNN memiliki banyak harapan untuk digunakan dalam memprediksi karakteristik kedalaman lapisan nitrida sebelum melakukan eksperimen. Kemampuan untuk memperkirakan kedalaman lapisan nitrida yang diinginkan ini diharapkan dapat mendorong desain permukaan material dengan kedalaman lapisan nitrida yang sesuai dan biaya yang lebih rendah terkait proses.

## 6. SARAN

Beberapa model matematis telah dikembangkan untuk memprediksi ketebalan lapisan nitrida yang terbentuk pada permukaan material. Secara umum prediksi ketebalan lapisan hasil rekayasa permukaan dapat didekati dengan hukum Fick I dan Fick II mengenai difusi. Pada saat ini data eksperimen sudah banyak diperoleh, pendekatan secara statistik menggunakan *machine learning* menjadi lebih diminati. Tentunya kebutuhan data pelatihan yang memadai sangat diperlukan agar dapat memprediksi pada rentang yang relatif lebar. Tentunya pengumpulan data eksperimen yang dibutuhkan memiliki tingkat kesulitan tersendiri. Pemilihan metode dan model pendekatan menjadi kunci penting untuk memperoleh nilai pendekatan yang sesuai dengan hasil perolehan dari eksperimen.

## 7. DAFTAR PUSTAKA

- Al-Jarraha, R., & Al-Oqla, F. M. (2022). A novel integrated BPNN/SNN artificial neural network for predicting the mechanical performance of green fibers for better composite manufacturing. *Composite Structures*, 289, 115475. <https://doi.org/10.1016/j.compstruct.2022.115475>
- Berladir, K., Hovorun, T., Ivanov, V., Vukelic, D., & Pavlenko, I. (2023). Diffusion Nitride Coatings for Heat-Resistant Steels. *Materials*, 16(21), 6877. <https://doi.org/10.3390/ma16216877>
- Caballero (Ed.). (2021). *Encyclopedia of Materials*. Elsevier.
- Daru, A. F., Hanif, M. B., & Widodo, E. (2021). Improving Neural Network Performance with



- Feature Selection Using Pearson Correlation Method for Diabetes Disease Detection. *JUITA: Jurnal Informatika*, 9(1), 123. <https://doi.org/10.30595/juita.v9i1.9941>
- Funch, C. V., Christiansen, T. L., & Somers, M. A. (2022). Gaseous nitriding of additively manufactured maraging steel; nitriding kinetics and microstructure evolution. *Surface and Coatings Technology*, 432, 128055. <https://doi.org/10.1016/j.surfcoat.2021.128055>
- Huang, N., Wang, Y., Zhang, Y., Liu, L., Yuan, N., & Ding, J. (2023). Multifunctional coating on magnesium alloy: Superhydrophobic, self-healing, anti-corrosion and wear-resistant. *Surface and Coatings Technology*, 463, 129539. <https://doi.org/10.1016/j.surfcoat.2023.129539>
- Kassaymeh, S., Abdullah, S., Alweshah, M., & Hammouri, A. I. (2021). A Hybrid Salp Swarm Algorithm with Artificial Neural Network Model for Predicting the Team Size Required for Software Testing Phase. In *2021 International Conference on Electrical Engineering and Informatics (ICEEI)*. <https://doi.org/10.1109/iceei52609.2021.9611128>
- Kassaymeh, S., Al-Laham, M., Al-Betar, M. A., Alweshah, M., Abdullah, S., & Makhadmeh, S. N. (2022). Backpropagation Neural Network optimization and software defect estimation modelling using a hybrid Salp Swarm optimizer-based Simulated Annealing Algorithm. *Knowledge-Based Systems*, 244, 108511. <https://doi.org/10.1016/j.knosys.2022.108511>
- Korecka, E.W., Michalski, J., & Januszewicz, B. (2023). The Stability of the Layer Nitrided in Low-Pressure Nitriding Process. *Coatings*, 13(2), 257. <https://doi.org/10.3390/coatings13020257>
- Kuang, F., Long, Z., Kuang, D., Liu, X., & Guo, R. (2022). Application of back propagation neural network to the modeling of slump and compressive strength of composite geopolymers. *Computational Materials Science*, 206, 111241. doi: <https://doi.org/10.1016/j.commatsci.2022.111241>
- Lai, C.-Y., Santos, S., & Chiesa, M. (2019). Machine learning assisted quantification of graphitic surfaces exposure to defined environments. *Applied Physics Letters*, 114(24). <https://doi.org/10.1063/1.5095704>
- Li, H., Ai, Z., Yang, L., Zhang, W., Yang, Z., Peng, H., & Leng, L. (2023). Machine learning assisted predicting and engineering specific surface area and total pore volume of biochar. *Bioresource Technology*, 369, 128417. <https://doi.org/10.1016/j.biortech.2022.128417>
- Ramezani, M., Mohd Ripin, Z., Pasang, T., & Jiang, C. P. (2023). Surface Engineering of Metals: Techniques, Characterizations and Applications. *Metals*, 13(7), 1299. <https://doi.org/10.3390/met13071299>
- Rashid, J., Nisar, M. W., Mahmood, T., Rehman, A., & Arifat, S. Y. (2020). Study of software development cost estimation techniques and models. *Mehrān University Research Journal of Engineering & Technology*, 39(2), 413-431.
- Setiawan, J., Riyanto, S., & Banawa, S. G. (2021). Characteristics of surface roughness and microhardness of nitrided pure iron. *FLYWHEEL: Jurnal Teknik Mesin Untirta*, 7(1), 7-11. doi: <http://dx.doi.org/10.36055/fwl.v0i0.10198>
- Sun, J., Mei, L., Li, Y., Lei, Y., Du, X., & Wu, Y. (2019). Two-Step Nitriding Behavior of Pure Iron with a Nanostructured Surface Layer. *Advanced Engineering Materials*, 21(10). <https://doi.org/10.1002/adem.201900359>
- Varshini, A. G. P., Anitha Kumari, K., Janani, D., & Soundariya, S. (2021). Comparative analysis of Machine learning and Deep learning algorithms for Software Effort Estimation. *Journal of Physics: Conference Series*, 1767(1), 012019. <https://doi.org/10.1088/1742-6596/1767/1/012019>
- Wang, Y., Wu, X., Li, X., Xie, Z., Liu, R., Liu, W., Zhang, Y., Xu, Y., & Liu, C. (2020). Prediction and Analysis of Tensile Properties of Austenitic Stainless Steel Using Artificial Neural Network. *Metals*, 10(2), 234. <https://doi.org/10.3390/met10020234>
- Yanto, M., Soving, R., & Melati, P. (2020). Analisis Forecasting Jumlah Kunjungan Tamu Hotel Di Kota Bukittinggi. *Sebatik*, 24(1), 8-13. Available at: <https://jurnal.wicida.ac.id/index.php/sebatik/article/view/857>
- Zhang, Y., & Xu, X. (2020). Machine learning the magnetocaloric effect in manganites from lattice parameters. *Applied Physics A*, 126(5). <https://doi.org/10.1007/s00339-020-03503-8>
- Zhou, Y., Xia, F., Xie, A., Peng, H., Wang, J., & Li, Z. (2023). A Review—Effect of Accelerating Methods on Gas Nitriding: Accelerating Mechanism, Nitriding Behavior, and Techno-Economic Analysis. *Coatings*, 13(11), 1846–1846. <https://doi.org/10.3390/coatings13111846>

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Pamulang atas dukungannya. Kegiatan ini dibiayai melalui dana hibah penelitian internal Universitas Pamulang tahun 2021/2022 dengan nomor kontrak 1174/D5/SPKP/LPPM/UNPAM/XI/2021.