

# Prediksi Sifat Mekanik Aluminium Berdasarkan Unsur Kimia Paduan Menggunakan Model *Machine Learning*

Prima Fierza Saputra<sup>1</sup>, Desmarita Leni<sup>2</sup>, Femi Earnestly<sup>3</sup>

<sup>1,2,3</sup> Jurusan Teknik Mesin, Fakultas Teknik, Universitas Muhammadiyah Sumatera Barat

\*Email: Prima.fierza@gmail.com

## **Abstract**

*This study designs and compares optimal machine learning models for predicting the mechanical properties of alloyed aluminum with code 1050 (A91050) based on the percentage composition of chemical elements using the software RapidMiner with decision tree and Random Forest algorithms. The aim is to develop a data-driven predictive model with high accuracy to minimize the need for physical testing on aluminum with various compositional variations. The machine learning modeling in this study involves nine input variables, comprising chemical elements such as Al, Mg, Zn, Ti, Cu, Mn, Cr, Fe, Si, and two output or target variables, YS and TS (yield strength and tensile strength). Additionally, a Heatmap correlation is employed to observe the correlations between the chemical elements and the mechanical properties of the alloyed aluminum. The comparison of these algorithms reveals that Random Forest (RF) outperforms other algorithms in predicting YS with a Mean Absolute Error (MAE) of 7.157, Root Mean Square Error (RMSE) of 11.248, and a coefficient of determination (SC) of 0.977. On the other hand, Random Forest (RF) also exhibits better performance in predicting TS with an MAE of 29.296, RMSE of 42.382, and SC value of 0.443.*

**Keywords:** Algorithm, Aluminium, Machine learning, Rapidminer, Tensile strength, Yield strength

## **Abstrak**

*Studi ini merancang dan membandingkan model machine learning optimal untuk memprediksi sifat mekanik aluminium paduan dengan kode 1050 (A91050) berdasarkan komposisi persentase unsur kimia aluminium menggunakan software rapidminer dengan algoritma decision tree dan Random Forest. Tujuannya adalah untuk mengembangkan model prediksi berbasis data yang memiliki akurasi tinggi dalam upaya meminimalisir pengujian fisik pada aluminium dengan berbagai jenis komposisinya. Pemodelan machine learning dalam studi ini memiliki sembilan variabel input yang terdiri dari unsur kimia aluminium seperti Al, Mg, Zn, Ti, Cu, Mn, Cr, Fe, Si, dan dua variabel output atau target yang terdiri dari YS dan TS. Selain itu, Heatmap correlation digunakan untuk mengamati korelasi antara unsur-unsur kimia dan sifat mekanik aluminium paduan. Perbandingan dari algoritma-algoritma ini menunjukkan bahwa Random Forest (RF) memiliki performa lebih baik daripada algoritma lain dalam memprediksi YS dengan MAE sebesar 7,157, RMSE sebesar 11,248, dan nilai SC sebesar 0,977. Di sisi lain, Random Forest (RF) juga memiliki performa lebih baik dalam memprediksi TS dengan MAE sebesar 29,296, RMSE sebesar 42,382, dan nilai SC sebesar 0,443.*

**Kata kunci:** Algoritma, Aluminium, Machine learning, Rapidminer, Tensile strength, Yield strength

## **1. Pendahuluan**

Aluminium merupakan salah satu material yang paling sering digunakan dalam berbagai industri karena memiliki berbagai keunggulan seperti ringan, tahan korosi, dan mudah diolah. Pengolahan aluminium dilakukan dengan pengecoran dan terbagi menjadi 2 yaitu aluminium murni dan aluminium paduan. Perbedaanannya terletak pada konsentrasi aluminiumnya misal aluminium murni bisa

memiliki kandungan aluminium sampai dengan 90% dan dipadu dengan material lain untuk menambah kekuatan mekaniknya. Sedangkan pada aluminium paduan komposisi logam paduan bisa jadi besar pada aluminium itu sendiri. Salah satu faktor yang mempengaruhi sifat mekanik dari aluminium adalah komposisi kimia, kekuatan mekanik pada aluminium dapat ditingkatkan dengan penambahan unsur paduan seperti Cu, Mg, Zn, Mn, V, Fe, Si dan Ni.

Terdapat beberapa jenis pengujian mekanis untuk menentukan sifat mekanik aluminium, diantaranya meliputi pengujian tarik (*tensile test*), pengujian kekerasan (*hardness test*), pengujian impak (*impact test*) dan pengujian mekanik lanjut meliputi pengujian fatik (*fatigue test*), pengujian mulur (*creep test*), pengujian fraktur (*fracture test*), dan pengujian keausan (*wear test*). Tujuan uji mekanis pada material adalah untuk mengukur sifat-sifat mekanis dari material tersebut, seperti kekuatan, kekakuan, ketahanan, dan elastisitas. Dengan menguji sifat mekanis dari material, kita dapat menentukan apakah material tersebut cocok atau tidak digunakan dalam aplikasi tertentu. Misalnya, jika material diuji dan ditemukan tidak cukup kuat, maka material tersebut tidak dapat digunakan dalam aplikasi yang membutuhkan kekuatan tinggi. Uji mekanis juga dapat digunakan untuk membandingkan sifat mekanis dari beberapa jenis material yang berbeda, sehingga dapat membantu dalam memilih material yang paling cocok untuk aplikasi tertentu sesuai dengan manfaat dan kegunaannya. Pengujian mekanis ini tentunya memakan banyak biaya dan waktu sehingga mengurangi keefisienan dalam proses manufaktur.

Dalam perkembangan yang pesat dari kecerdasan buatan (AI), khususnya *Machine Learning*, banyak penelitian yang memanfaatkan data untuk mengurangi pengujian secara fisik dan meningkatkan efisiensi dan efektivitas dalam berbagai bidang. Salah satu cara yang digunakan untuk mengolah data dan menganalisis informasi dari berbagai sumber adalah melalui *platform analytics* seperti *RapidMiner*, Weka, SAS, *Alteryx*, KNIME, dan Python. Dengan *platform analytics* tersebut, para peneliti dapat memproses data besar dan menghasilkan informasi yang lebih akurat, serta memprediksi kemungkinan hasil berbagai situasi dan masalah. Hal ini membuka peluang baru untuk inovasi dan kemajuan dalam bidang-bidang seperti manufaktur, kesehatan, keuangan, dan lain-lain. Penelitian oleh Stefanus pada tahun 2021 menunjukkan bahwa proses rekayasa sangat membutuhkan peran komputasi untuk memperoleh akurasi dan kehandalan yang tinggi. Kompetisi yang ketat di dunia industri menuntut siklus desain yang pendek yang didasarkan pada simulasi numerik untuk mengurangi pengujian prototipe secara fisik dan dapat memprediksi proses pengujian dengan data yang telah dihasilkan dari pengujian sebelumnya. Komputasi *engineering* juga diterapkan pada ilmu material, dan ada beberapa referensi yang menyebutkan penggunaan teknologi berbasis kecerdasan buatan di bidang pengolahan dan

rekayasa logam. David dalam penelitiannya tentang Prediksi kurva tegangan-regang bilinear paduan aluminium menggunakan kecerdasan buatan dan big data juga menerapkan komputasi *engineering*.

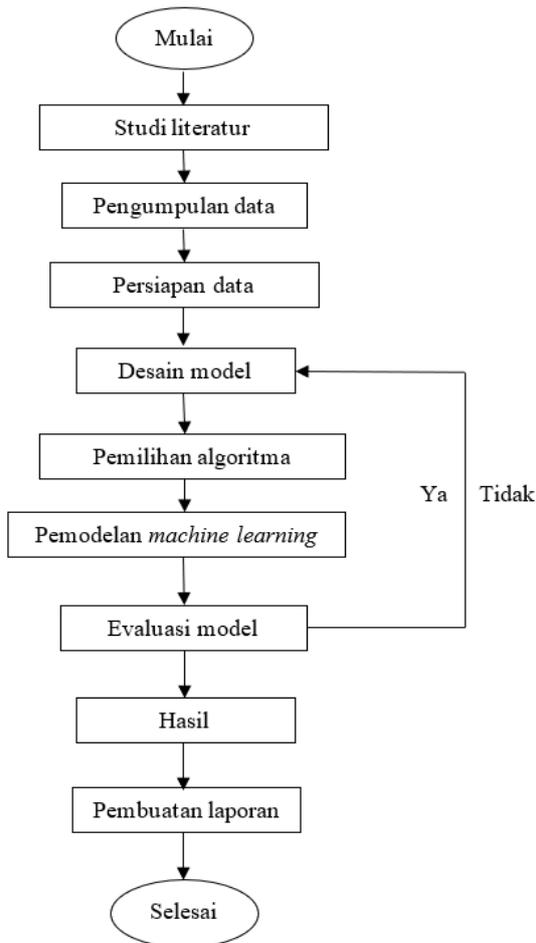
Dalam penelitian dengan judul “Perbandingan Algoritma *Machine Learning* Untuk Prediksi Sifat Mekanik Pada Baja Paduan Rendah” meneliti tentang prediksi sifat mekanik baja paduan rendah menggunakan *Machine Learning*[1]. Studi ini membandingkan tiga algoritma, yaitu pohon keputusan (*Decision tree/DT*), hutan acak (*random forest/RF*), dan jaringan saraf tiruan (*artificial neural network/ANN*), di mana algoritma ANN memiliki performa yang lebih baik dengan menghasilkan nilai RMSE sebesar 6,187 dengan pengaturan parameter siklus pelatihan 30.000, tingkat pembelajaran 0.007, momentum 0.9, dan ukuran lapisan tersembunyi sebanyak 9.

Pada penelitian dengan judul “*Prediction of Physical and Mechanical Properties for Metallic Materials Selection Using Big Data and Artificial Neural Networks*”, hasil studi menunjukkan sebuah jaringan saraf tiruan (ANN) dibangun dengan ribuan perceptron, topologi dan koneksi ANN telah dioptimalkan untuk mempercepat pelatihan dan kapasitas prediktif ANN. Setelah pelatihan yang sesuai, sistem mampu membuat prediksi tentang densitas material dan modulus *Young* dengan kepercayaan rata-rata lebih dari 99% dan 98%, masing-masing[2].

Tujuan Penelitian ini adalah merancang sebuah pemodelan dengan *Machine Learning* menggunakan aplikasi *Rapidminer* dengan tujuan mengembangkan model prediksi berbasis data yang memiliki akurasi tinggi dalam upaya meminimalisir pengujian fisik pada aluminium dengan berbagai jenis komposisinya. Pada penelitian ini dibatasi hanya untuk menghitung nilai Sifat mekanik (*yield strength* dan *tensile strength*) pada aluminium paduan dengan kode 1050 (A91050). Dalam penelitian ini algoritma yang digunakan adalah *Random forest* dan *Decision tree*.

## 2. Methodologi

Penelitian ini menggunakan metode Prediksi Sifat Mekanik Aluminium Berdasarkan Unsur Kimia Paduan Menggunakan Model *Machine Learning*. Tujuannya adalah untuk mengidentifikasi pola, hubungan, dan anomali dalam data serta mendapatkan wawasan yang berharga sebelum melakukan analisis lebih lanjut.



Gambar 1. Diagram alir penelitian

Data penelitian ini diambil pada periode April 2023 dari website *makeitfrom.com*. *makeitfrom.com* adalah sebuah database kurasi properti material teknik yang menekankan kemudahan perbandingan. Situs ini bukanlah sekedar kumpulan data mentah, melainkan setiap bahan yang terdaftar di dalamnya adalah bahan generik yang diakui secara internasional. Data yang ada berasal dari standar yang telah diterbitkan, literatur akademik, dan dokumentasi dari pemasok bahan.

Data yang tersedia seperti sifat mekanik material, komposisi kimia, korosi, perlakuan panas, sifat termal dan masih banyak lagi, namun pada penelitian ini data yang diambil adalah data komposisi kimia aluminium, nilai uji tarik aluminium (TS) dan kekuatan luluh aluminium (YS). Data komposisi kimia aluminium yang diambil pada penelitian ini adalah presentase kadar Aluminium (Al), Manganese (Mg), Zinc (Zn), Titanium (Ti), Copper (Cu), Manganese (Mn), Chromium (Cr), Ferrum (Fe), Silicium (Si) yang dapat dilihat pada tabel 1. Pada penelitian ini menggunakan dataset *Aluminium Alloy*

AA1000 dengan kode AL 1050 dan 1060 yang berjumlah 237 data dengan 9 data input serta 2 data output atau target.

Tabel 1.  
Statistik dataset aluminium

Keterangan	Tipe data	Min	Max	Mean
Mg (%)	Input	0,03	0,05	0,039
Zn (%)	Input	0,05	0,05	0,05
Ti (%)	Input	0,03	0,03	0,03
Cu (%)	Input	0,05	0,05	0,05
Mn (%)	Input	0,03	0,05	0,03842
Cr (%)	Input	0,05	0,05	0,05
Fe (%)	Input	0,35	0,4	0,3725
Si (%)	Input	0,25	0,25	0,25
Al (%)	Input	99,5	99,6	99,555
YS (Mpa)	Output	17	120	73,4
TS (Mpa)	Output	67	140	101,45

Pada penelitian ini digunakan algoritma *Decision tree* dan *Random forest* menggunakan perbandingan rasio data training dan data testing sebesar 60:40, 70:30 dan 80:20. Kemudian performa model yang dilatih dievaluasi dengan menghitung *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Correlation Coefficient* (R), dari nilai aktual dan nilai prediksi dari data uji.

### 3. Hasil dan Pembahasan

Pemodelan dilakukan menggunakan perangkat lunak *RapidMiner*. Pemodelan ini melibatkan 9 variabel input yang mencakup unsur kimia paduan, serta 2 variabel output, yaitu YS dan TS. Selanjutnya analisis data dilakukan dengan menggunakan *heatmap correlation* yang terdapat pada gambar 2. *Heatmap correlation* adalah sebuah visualisasi grafik yang digunakan untuk menampilkan tingkat korelasi antara dua set data atau variabel. Dalam *heatmap correlation*, setiap sel pada matriks dipresentasikan dengan warna yang menunjukkan tingkat korelasi antara variabel-variabel tersebut. Visualisasi *heatmap correlation* menunjukkan bahwa unsur Mg memiliki korelasi positif tertinggi dengan YS, yakni sebesar 0,620. Kemudian, unsur Ti memiliki korelasi sebesar 0,600, dan unsur Zn sebesar 0,371. Hal ini menandakan bahwa semakin tinggi kadar Mg dalam komposisi kimia paduan aluminium maka, dapat meningkatkan kekuatan *yield strength* (YS). Terkait dengan kekuatan *tensile strength* (TS), unsur Mg memiliki korelasi paling kuat, yaitu 0,879. Pada urutan kedua, unsur Ti memiliki korelasi positif sebesar 0,752, diikuti oleh unsur Cr sebesar 0,688, dan unsur Zn sebesar 0,450. Hal ini

menandakan bahwa semakin tinggi kadar Mg dalam komposisi kimia paduan aluminium maka, dapat meningkatkan kekuatan *Tensile strength* (TS).

Attributes	Mg	Zn	Ti	Cu	Mn	Cr	Fe	Si	Al	Yield st...	Tensile ..
Mg	1	0.208	0.827	-0.100	0.157	0.596	-0.326	-0.174	-0.877	0.620	0.879
Zn	0.208	1	0.041	0.782	0.237	0.420	0.237	0.054	-0.434	0.371	0.450
Ti	0.827	0.041	1	-0.330	0.123	0.305	-0.460	-0.181	-0.688	0.600	0.752
Cu	-0.100	0.782	-0.330	1	0.197	0.260	0.366	0.125	-0.169	0.668	0.976
Mn	0.157	0.237	0.123	0.197	1	0.269	0.096	0.143	-0.465	0.221	0.396
Cr	0.596	0.420	0.305	0.260	0.269	1	-0.033	0.067	-0.661	0.261	0.688
Fe	-0.326	0.237	-0.460	0.366	0.096	-0.033	1	0.803	-0.049	-0.174	-0.237
Si	-0.174	0.054	-0.181	0.125	0.143	0.067	0.803	1	-0.182	-0.158	-0.155
Al	-0.877	-0.434	-0.688	-0.169	-0.465	-0.661	-0.049	-0.182	1	-0.593	-0.887
Yield strength (Mpa)	0.620	0.371	0.600	0.668	0.221	0.261	-0.174	-0.158	-0.593	1	0.639
Tensile strength (Mpa)	0.879	0.450	0.752	0.976	0.396	0.688	-0.237	-0.155	-0.887	0.639	1

Gambar 2. Heatmap correlation

### 3.1 Pemodelan Machine Learning

Untuk memprediksi kekuatan tarik dan kekuatan luluh material aluminium secara akurat, dilakukan variasi pengaturan parameter berupa *maximal depth* untuk algoritma *decision tree* serta *maximal depth* dan *number of trees* untuk algoritma *random forest*. Informasi tentang variasi parameter pada setiap algoritma dapat dilihat pada Tabel 2, tabel tersebut mencakup dua kolom utama, yaitu kolom pertama yang berisi nama algoritma (DT dan RF), kolom kedua yang berisi nama parameter yang akan diberikan, dan kolom ketiga yang berisi pengaturan parameter pada masing-masing algoritma.

**Tabel 2.**  
Pengaturan parameter untuk mencari algoritma terbaik

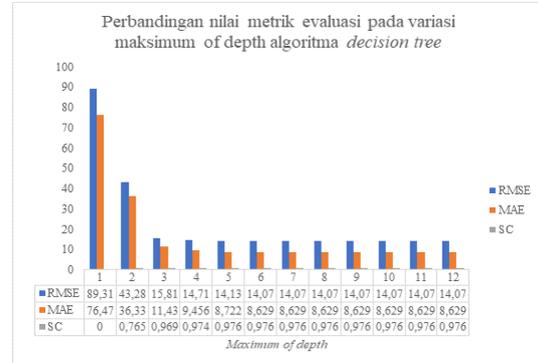
No	Algoritma	Nama Pramer	Pengaturan parameter
1.	<i>Decision tree</i>	<i>Criterion</i>	<i>Least square</i>
		<i>Maxima l depth</i>	1,2,3,4,5,6,7,8,9 ,10,11,12
		<i>Ratio</i>	60:40, 70:30, 80:20
2.	<i>Random forest</i>	<i>Number of trees</i>	20,40,60,80,100,120 ,140,160,180,200
		<i>Criterion</i>	<i>Least square</i>
		<i>n</i>	
		<i>Maxima l depth</i>	1,2,3,4,5,6,7,8,9 ,10,11,12
		<i>Ratio</i>	60:40, 70:30, 80:20

Hasil pencarian parameter terbaik ditentukan dengan nilai RMSE dan MAE terkecil dengan nilai SC tertinggi. Berikut adalah hasilnya:

#### a. *Decision tree*

Berdasarkan hasil pemodelan *Machine Learning* didapatkan nilai maksimum of depth sebesar 6 dengan nilai RMSE 14,074, nilai MAE 8,629 dan nilai SC 0,976. Hal ini dikarenakan

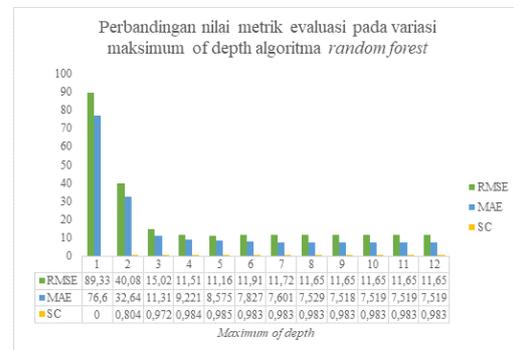
setelah kenaikan nilai maksimum of depth lebih dari 6, tidak ada kenaikan nilai RMSE, MAE dan penurunan nilai SC. Dengan begitu dalam pengujian algoritma *Decision tree* selanjutnya diambil nilai *maximum of depth* sebesar 6.



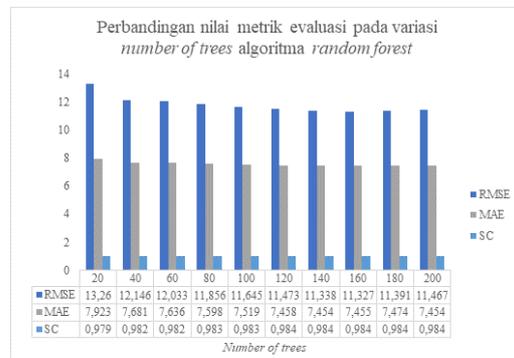
Gambar 3. Grafik perbandingan hasil uji variasi nilai maksimum of depth algoritma *Decision tree*

#### b. *Random forest*

Berdasarkan hasil pemodelan *Machine Learning* didapatkan nilai maksimum of depth sebesar 10 dan *number of trees* sebesar 160 dengan nilai RMSE 11,327, nilai MAE 7,455 dan nilai SC 0,984. Dengan begitu dalam pengujian algoritma *Random forest* selanjutnya diambil nilai *maximum of depth* sebesar 10 dan nilai *number of trees* sebesar 160.



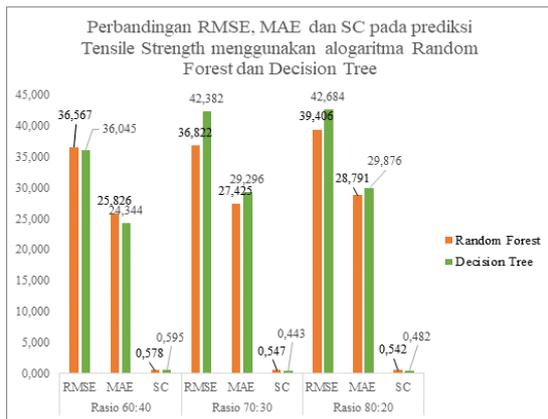
Gambar 4. Grafik perbandingan hasil uji variasi nilai maksimum of depth algoritma *random forest*



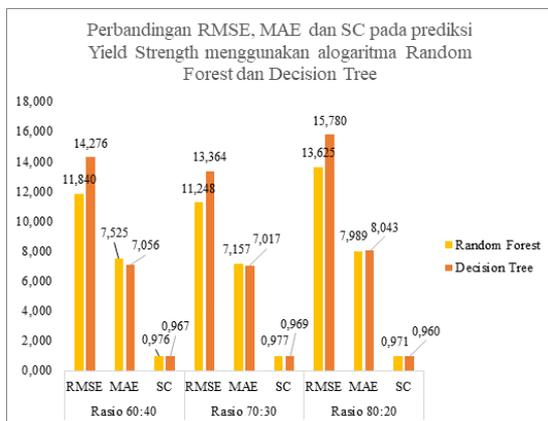
Gambar 5. Grafik perbandingan hasil uji variasi nilai number of trees algoritma *random forest*

### 3.2 Cross Validation

*Cross Validation* merupakan salah satu teknik dalam melakukan validasi model yang melibatkan pembagian data menjadi beberapa subset atau *fold*[3]. Pada setiap iterasinya, satu *fold* digunakan sebagai data validasi, sementara *fold* yang lain menjadi data latih. Dalam penelitian ini, digunakan *Cross Validation* dengan *K-fold* 5, yang berarti data dibagi menjadi 5 subset yang berbeda dan dilakukan 5 iterasi. Setiap iterasi menggunakan subset secara bergantian sebagai data uji dan subset lainnya sebagai data latih. Performa model dihitung menggunakan metrik evaluasi seperti MAE, RMSE, dan R-squared. Setelah 5 iterasi, performa model pada setiap *fold* diambil rata-ratanya untuk memperoleh performa model yang konsisten dan stabil. Metode *K-fold Cross Validation* ini memungkinkan pengujian validitas model prediksi dengan lebih akurat dan reliabel karena memperhitungkan variasi data pada setiap *fold*.



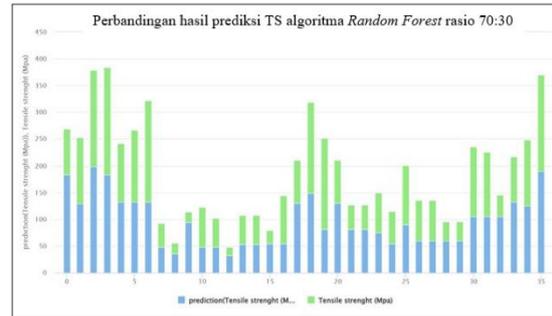
Gambar 6. Perbandingan performa algoritma *Random forest* dan *Decision tree* pada prediksi TS



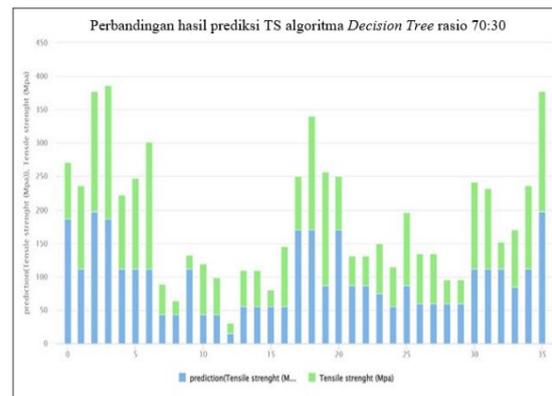
Gambar 7. Perbandingan performa algoritma *Random forest* dan *Decision tree* pada prediksi YS

### 3.3 Evaluasi model

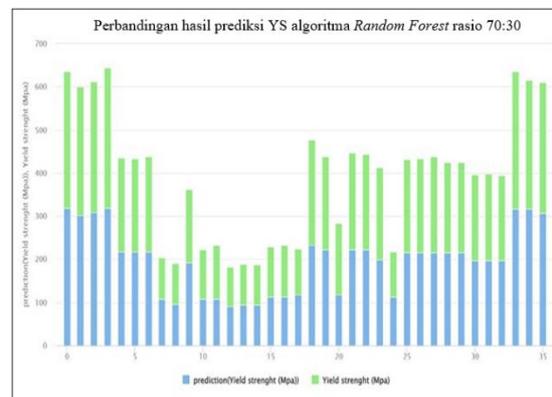
Evaluasi model bertujuan untuk menilai sejauh mana kualitas model yang dihasilkan dalam melakukan prediksi. Berdasarkan hasil pemodelan dengan membandingkan dua algoritma, ditemukan bahwa algoritma *Random forest* dengan perbandingan 70:30 menunjukkan performa yang lebih baik dalam memprediksi nilai *yield strength* dan *tensile strength* dibandingkan dengan algoritma *Decision tree*.



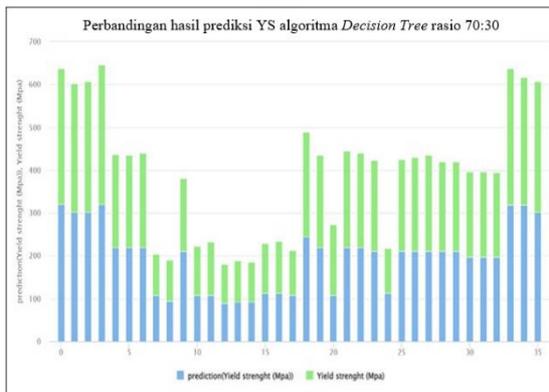
Gambar 8. Grafik perbandingan data prediksi nilai *tensile strength* dengan data aktual menggunakan algoritma *Random forest* rasio 70:30



Gambar 9. Grafik perbandingan data prediksi nilai *tensile strength* dengan data aktual menggunakan algoritma *Decision tree* rasio 70:30



Gambar 10. Grafik perbandingan data prediksi nilai *yield strength* dengan data aktual menggunakan algoritma *Random forest* rasio 70:30



Gambar 11. Grafik perbandingan data prediksi nilai *yield strength* dengan data aktual menggunakan algoritma *Decision tree* rasio 70:30

#### 4. Simpulan

Dari penelitian yang telah dilakukan mengenai prediksi sifat mekanik aluminium berdasarkan unsur kimia paduan menggunakan model *Machine Learning* dapat disimpulkan sebagai berikut:

1. *Heatmap correlation* mampu memberikan informasi hubungan korelasi antara unsur kimia paduan aluminium dengan sifat mekanik aluminium seperti *Yield strength* (YS) dan *Tensile strength* (TS).
2. Hasil prediksi nilai *yield strength* terbesar diperoleh dari hasil pengujian model algoritma *Random forest* dengan parameter *maximum of depth* sebesar 10, *number of trees* sebesar 160 dan rasio perbandingan sebesar 70:30. Diikuti dengan nilai RMSE sebesar 11,248, MAE sebesar 7,157 dan SC sebesar 0,977.

3. Hasil prediksi nilai *tensile strength* terbesar diperoleh dari hasil pengujian model algoritma *Random forest* dengan parameter *maximum of depth* sebesar 10, *number of trees* sebesar 160 dan rasio perbandingan sebesar 70:30. Diikuti dengan nilai RMSE sebesar 42,382, MAE sebesar 29,296 dan SC sebesar 0,443.

#### Daftar Pustaka

- [1] A. Desmarita leni, Yuda perdana kusuma, Ruzita sumiati, Muchlisinalahuddin, "Perbandingan Alogaritma Machine Learning Untuk Prediksi Sifat Mekanik Pada Baja Paduan Rendah," *J. Rekayasa Mater. Manufaktur dan Energi*, vol. 2, no. 2, pp. 131–139, 2019.
- [2] D. Merayo, A. Rodriguez-Prieto, and A. M. Camacho, "Prediction of Physical and Mechanical Properties for Metallic Materials Selection Using Big Data and Artificial Neural Networks," *IEEE Access*, vol. 8, pp. 13444–13456, 2020, doi: 10.1109/ACCESS.2020.2965769.
- [3] A. I. Kusumarini, P. A. Hogantara, M. Fadhlurohman, and S. K. . M. K. Nurul Chamidah, "Perbandingan Algoritma Random Forest, Naive Bayes, Dan Decision Tree Dengan Oversampling Untuk Klasifikasi Bakteri E.Coli," *Pros. Semin. Nas. Mhs. Bid. Ilmu Komput. dan Apl.*, vol. 2, no. 1, pp. 792–799, 2021.