

# Prediksi Kuat Tekan Kolom Beton Persegi dengan Perkuatan FRP Menggunakan *Machine Learning*

ANANG KRISTIANTO<sup>1\*</sup>, YOSAFAT AJI PRANATA<sup>1</sup>,  
NOVIE THERESIA Br. PASARIBU<sup>2</sup>, JASEN ALFATAMA<sup>2</sup>

<sup>1</sup>Program Studi Teknik Sipil, Universitas Kristen Maranatha, Bandung, Indonesia  
<sup>2</sup>Program Studi Teknik Elektro, Universitas Kristen Maranatha, Bandung, Indonesia  
Email: [anang.kristianto@eng.maranatha.edu](mailto:anang.kristianto@eng.maranatha.edu)<sup>1</sup>, [yosafat.ap@eng.maranatha.edu](mailto:yosafat.ap@eng.maranatha.edu)<sup>1</sup>,  
[novie.theresia@eng.maranatha.edu](mailto:novie.theresia@eng.maranatha.edu)<sup>2</sup>

## ABSTRAK

*Analisis secara teoritis kuat tekan kolom beton persegi dengan perkuatan FRP masih mengandalkan pendekatan seperti yang digunakan untuk kolom lingkaran dengan modifikasi. Sesuai dengan kemajuan teknologi saat ini pendekatan menggunakan machine learning diharapkan dapat memberikan perspektif berbeda sekaligus hasil yang lebih akurat. Tujuan dari penelitian ini adalah menggunakan beberapa teknik machine learning untuk memprediksi kuat tekan aksial kolom persegi yang diperkuat dengan FRP dengan berbagai radius kelengkungan pada sudutnya dan membandingkan metode machine learning dengan pendekatan analitik dan mekanik yang sudah ada. Tiga algoritma digunakan dalam pendekatan machine learning: Jaringan Syaraf Tiruan (JST), Categorical Boost (CatBoost), dan M5-Tree. Ensemble Machine Learning membuat kinerja yang lebih baik dibandingkan dengan tiga model individual JST, CatBoost, dan M5-Tree dengan nilai R-squared sebesar 0,9557. Penggunaan machine learning untuk memprediksi dibandingkan dengan beberapa usulan teori tegangan terkekang, memberikan hasil yang paling mendekati dengan nilai R-squared sebesar 0,8276.*

**Kata kunci:** tegangan, kolom beton, FRP, prediksi, pembelajaran mesin

## ABSTRACT

*Theoretically analyzing the compressive strength of square concrete columns with FRP reinforcement still relies on the approach as used for circular columns with modifications. In accordance with current technological advances, machine learning approaches are expected to provide a different perspective as well as more accurate results. The objective of this research is to use several machine learning techniques to predict the axial compressive strength of square columns reinforced with FRP with various radii of curvature at the corners and compare the machine learning methods with existing analytical and mechanical approaches. Three algorithms were used in the machine learning approach: Artificial Neural Network (ANN), Categorical Boost (CatBoost), and M5-Tree. The machine learning ensemble performed better than the three individual models JST, CatBoost, and M5-Tree with an R-squared value of 0.9557. The use of machine learning to predict, compared to some proposed confined stress theories, gave the closest results with an R-squared value of 0.8276.*

**Keywords:** stress, concrete column, FRP, prediction, machine learning

## 1. PENDAHULUAN

Kolom beton bertulang (RC) yang diperkuat dengan menggunakan *Fiber Reinforced Polymer (FRP)* telah banyak digunakan untuk meningkatkan kapasitas aksial kolom. Untuk mensimulasikan perilaku kolom beton yang dikekang dengan FRP, sejumlah penelitian dan model kekuatan telah banyak diusulkan [11][21]. Sebagian besar model yang saat ini digunakan didasarkan pada penelitian Richart dkk. [16], dimana model ini menggunakan pendekatan penampang melingkar yang memberikan tekanan pengekangan yang merata, dengan memperhitungkan diameter penampang serta kekuatan dan ketebalan lembaran *Fiber Reinforced Polymer (FRP)*.

Apabila dibandingkan dengan kolom melingkar, model untuk kolom persegi panjang yang dikekang FRP jauh lebih sedikit [11][21]. Kolom dengan penampang persegi yang terkekang FRP mengalami tekanan pengekangan yang tidak seragam di sepanjang sisi perimeternya. Hal ini menjadi kesulitan tersendiri dalam menganalisis distribusi tekanan dengan menggunakan solusi mekanika. Secara umum untuk menganalisis tegangan yang terjadi digunakan pendekatan dari teori kolom berpenampang melingkar yang diekuivalenkan dengan memberikan faktor bentuk selain ekuivalen diameter ke panjang sisi.

Beberapa pendekatan telah dilakukan untuk memodelkan perilaku kolom persegi dengan perkuatan FRP, termasuk pendekatan mekanik di mana lembaran FRP dimodelkan seperti balok yang bertumpu pada tanah elastis, yang mensimulasikan interaksi FRP dengan inti beton yang ditahannya. Campione dkk. [6] melakukan pendekatan secara mekanis pada kolom persegi dengan sudut melingkar yang diperkuat dengan FRP dengan memodelkan lembaran FRP sebagai elemen balok yang berinteraksi dengan inti beton kolom. Model balok ini dihubungkan melalui pegas yang didistribusikan sepanjang arah radial dan melingkar dengan inti beton yang kaku. Dalam studi ini, pendekatan mekanis diusulkan dengan menggunakan persamaan konstruktif yang merupakan fungsi dari pegas melingkar dan radial.

Pendekatan dengan model elemen hingga dengan bantuan perangkat lunak telah dilakukan oleh Karam dan Tabbara, 2005, yang menganalisis pengaruh jari-jari kelengkungan sudut kolom persegi terhadap pada distribusi tegangan. Penelitian ini juga mengkonfirmasi secara numerik bahwa tegangan pengekangan di sepanjang tepi lurus sangat kecil dibandingkan dengan tegangan di sudut.

Pendekatan secara analitis matematis dilakukan oleh Pham dan Hadi [15], dimana pada penelitian ini, tegangan tarik yang terjadi pada lembaran FRP diturunkan dari model cangkang tipis. Penelitian ini memberikan informasi bahwa faktor efisiensi regangan, yang dihitung sebagai rasio antara tegangan ultimate FRP pada kolom dan tegangan FRP pada kondisi uji tarik murni, merupakan fungsi dari  $r/b$  (radius kelengkungan/lebar sisi kolom) dan rasio kekakuan pengekangan.

Dengan banyaknya data hasil penelitian eksperimental yang telah dilakukan, dewasa ini mulai digunakan pendekatan modern dengan memanfaatkan model *machine learning* untuk memprediksi besarnya tegangan dan regangan ultimit kolom beton dengan perkuatan FRP. Pendekatan *machine learning* tidak memerlukan asumsi hubungan fungsional antara berbagai variabel yang ditentukan, seperti yang dilakukan pada pendekatan analitis dan mekanis. Oreta dkk. [14] menggunakan pendekatan jaringan syaraf tiruan untuk memprediksi besarnya kapasitas tegangan dan regangan pada kolom melingkar yang diperkuat dengan FRP. Pendekatan JST pada penelitian ini memberikan perbedaan nilai tegangan dan regangan yang diprediksi sebesar 1% hingga 3% dari nilai eksperimen. Oreta juga menyarankan untuk menambah jumlah data eksperimen sebagai bagian dari proses "*training*" JST untuk

mendapatkan hasil prediksi yang lebih akurat. Penelitian lain untuk kolom melingkar dilakukan oleh Naderpour dkk. [13], Jalal dan Ramezaniapour [9].


Studi dalam artikel imiah ini melakukan analisis dengan pendekatan pembelajaran mesin untuk memprediksi kekuatan tekan aksial kolom persegi yang diperkuat dengan FRP. Analisis dilakukan dengan memperhitungkan berbagai jari-jari kelengkungan sudut dan melakukan perbandingan hasil prediksi pendekatan pembelajaran mesin dengan metode analitis dan mekanis yang telah ada.

## 2. METODOLOGI

Pada penelitian ini, akan dirancang dan direalisasikan prediksi nilai kuat tekan kolom beton persegi yang dilapisi material FRP dengan menggunakan ensemble machine learning. 3 Model algoritma kecerdasan buatan digunakan dalam memprediksi nilai kuat tekan beton yang dilapisi material FRP. Algoritma yang akan digunakan adalah *Artificial Neural Network* (ANN) atau Jaringan Saraf Tiruan (JST), *Categorical Boost* (CatBoost), dan *M5-Tree*.

### 2.1 Jaringan Saraf Tiruan

Jaringan syaraf tiruan (JST) adalah model matematika yang terinspirasi oleh organisasi dan fungsi neuron biologis. JST terdiri dari lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan output (*output layer*), seperti yang ditunjukkan pada **Gambar 1**. Jaringan syaraf tiruan *feedforward multilayer perceptron* digunakan dalam penelitian ini, dan terdiri dari beberapa lapisan, yang masing-masing memiliki beberapa neuron. Setiap neuron pada suatu lapisan terhubung dengan neuron pada lapisan berikutnya menggunakan fungsi bobot.



**Gambar 1.** Arsitektur jaringan syaraf tiruan

Proses kerja JST dimulai dengan memberikan data input ke input layer, kemudian data tersebut melewati *hidden layer*, yang melakukan pemrosesan dan transformasi, dan akhirnya menghasilkan output melalui *output layer*. Kemudian dengan metode *Back Propagation*, JST memperbarui bobot dan bias pada setiap neuron berdasarkan kesalahan prediksi pada output untuk meningkatkan kemampuannya dalam membuat prediksi yang lebih akurat. Setiap neuron pada lapisan tersembunyi dan lapisan keluaran melakukan komputasi dengan menggabungkan input dari neuron sebelumnya menggunakan bobot dan bias, dan menerapkan fungsi aktivasi [18].

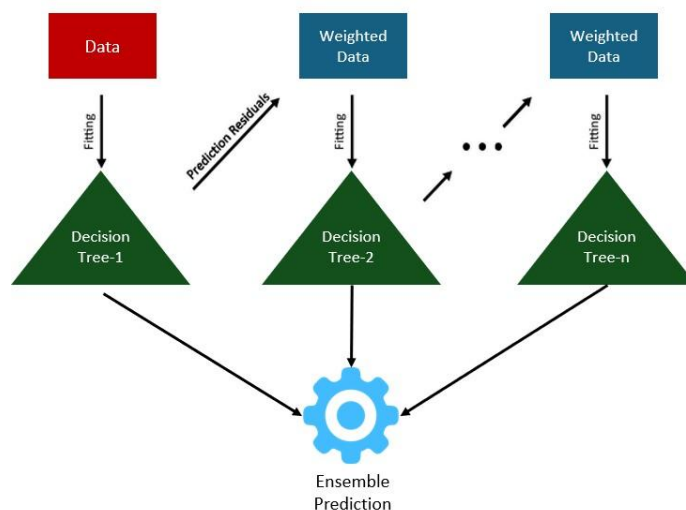
Neuron dalam JST adalah unit pemrosesan dasar yang menerima input, mengalikan bobot dengan input, menjumlahkan hasilnya, dan meneruskannya melalui fungsi aktivasi. Setiap neuron memiliki bobot yang merepresentasikan kekuatan koneksi antara neuron tersebut dengan neuron di lapisan sebelumnya. Neuron juga dapat memiliki bias yang membantu dalam penyesuaian dan pembelajaran [18].

Fungsi aktivasi dalam JST digunakan untuk memperkenalkan non-linearitas pada output neuron atau input ke neuron berikutnya dalam jaringan. Fungsi aktivasi ini memberikan

jaringan syaraf kekuatan untuk mempelajari hubungan non-linier dalam data [18]. Salah satu fungsi aktivasi yang umum digunakan dalam JST adalah *Rectified Linear Unit* (ReLU). Fungsi ReLU adalah fungsi aktivasi non-linear yang sederhana dan efisien. Fungsi ini mengubah input positif menjadi nilai yang sama dan mengabaikan input negatif (nilai nol). Fungsi ReLU sangat populer dalam jaringan saraf pembelajaran mendalam karena fungsi ini mengatasi masalah gradien lenyap yang sering terjadi pada fungsi sigmoid.

## 2.2 CatBoost

CatBoost adalah algoritme peningkatan gradien yang menggunakan pendekatan ensambel untuk membangun model prediksi yang kuat. *Gradient Boosting* secara bertahap meningkatkan model dengan menambahkan prediksi berbasis pohon secara berurutan [3]. Salah satu fitur dari CatBoost adalah kemampuannya untuk menangani variabel kategori secara langsung tanpa perlu melakukan proses pengkodean terlebih dahulu. Algoritmanya secara otomatis menangani variabel kategori dan menghasilkan fitur numerik yang relevan untuk setiap kategori [3]. CatBoost membuat model prediksi sederhana, seperti pohon keputusan yang terdiri dari beberapa cabang dan simpul (**Gambar 2**). Model ini dibuat berdasarkan data pelatihan awal. Setelah membuat model prediksi awal, model ini digunakan untuk memprediksi nilai target berdasarkan data validasi. Hasil prediksi awal ini akan memiliki kesalahan, terutama pada data yang tidak seimbang atau memiliki nilai yang hilang.




**Gambar 2. Diagram prinsip kerja Catboost**

CatBoost menghitung gradien kesalahan untuk setiap prediksi. Gradien ini memberikan informasi tentang seberapa jauh setiap prediksi dari nilai target yang sebenarnya. Pada iterasi berikutnya, CatBoost menambahkan model prediksi baru yang akan mengoreksi kesalahan prediksi dari iterasi sebelumnya. Model baru ini dapat berupa pohon keputusan tambahan atau kombinasi dari beberapa pohon.

## 2.3 M5-Tree

Algoritma *M5-Tree* diperkenalkan oleh Quinlan pada tahun 1992. Model ini dibentuk berdasarkan pohon keputusan biner yang di dalamnya terdapat fungsi regresi linier pada simpul terminal (*leaf*) yang mengatur variabel independen dan dependen [1]. *M5-Tree* adalah salah satu algoritma pengindeksan untuk pemrosesan data. Algoritma pengindeksan adalah teknik untuk mengorganisasikan data ke dalam struktur yang efisien sehingga dapat diakses dengan cepat dan mudah.

*M5-Tree* menggunakan teknik induksi aturan untuk membangun pohon keputusan. Pada tahap pembangunan pohon keputusan, *M5-Tree* akan memilih variabel terbaik untuk melakukan pemisahan berdasarkan penilaian kualitas pemisahan. Penilaian ini didasarkan pada *information gain*, yaitu pengurangan entropi yang dihasilkan dari pemisahan variabel. Entropi adalah ukuran ketidakpastian dalam kumpulan data, dan pengurangan entropi mengukur seberapa besar ketidakpastian yang dihilangkan ketika data dipecah berdasarkan variabel yang dipilih [1]. Setelah variabel dipilih, *M5-Tree* akan membagi data ke dalam *subset* berdasarkan nilai dari variabel tersebut. *M5-Tree* kemudian akan membuat aturan untuk setiap *subset*. Jika ada *subset* yang tidak dapat dijelaskan oleh aturan yang telah dibuat, *M5-Tree* akan membuat *subtree* baru untuk subset tersebut. Pembuatan *subtree* dilakukan dengan cara yang sama, yaitu dengan memilih variabel terbaik dan membagi subset tersebut ke dalam subsubset yang lebih kecil. Proses ini diulang hingga tidak ada lagi subset yang tidak dapat dijelaskan oleh aturan yang telah dibangun atau batas kedalaman pohon telah tercapai. Contoh pohon keputusan dapat dilihat pada **Gambar 3**. *M5-Tree* menggunakan teknik regresi linier untuk memberikan hasil prediksi.



**Gambar 3. Contoh pohon keputusan M5-Tree**

Persamaan garis regresi dapat digunakan untuk memprediksi nilai variabel dependen berdasarkan nilai variabel independen yang diberikan. Persamaan garis regresi dapat digunakan untuk memprediksi nilai variabel dependen berdasarkan nilai variabel independen yang diberikan. Dalam regresi linier, hubungan linier antara variabel independen dan variabel dependen diwakili oleh persamaan garis lurus yang dikenal sebagai "garis regresi". Persamaan garis regresi dapat digunakan untuk memprediksi nilai variabel dependen berdasarkan nilai variabel independen yang diberikan.

## 2.4 Ensemble Machine Learning

*Ensemble machine learning* menggabungkan prediksi dari anggota *ensemble* untuk menghasilkan prediksi akhir. Dalam *ensemble*, setiap anggota model dapat menjadi model yang relatif lemah secara individual, tetapi ketika digabungkan, mereka dapat menghasilkan model yang lebih kuat dan lebih akurat secara keseluruhan [5]. *Ensemble machine learning* menggabungkan prediksi dari anggota ensemble untuk menghasilkan prediksi akhir. Proses agregasi dapat dilakukan dengan berbagai metode, seperti *voting* (mengambil prediksi mayoritas), *average prediction* (mengambil prediksi rata-rata), *stacking* (menggunakan model *meta-learner* untuk menggabungkan prediksi), atau *weighted averaging* (menggabungkan prediksi dengan bobot tertentu) [5]. Prediksi rata-rata adalah salah satu metode sederhana yang digunakan dalam pembelajaran mesin *ensemble* untuk menghasilkan prediksi akhir. Metode ini melibatkan penggabungan prediksi dari semua anggota *ensemble* dengan mengambil rata-rata dari prediksi-prediksi tersebut [5].

Pembelajaran dalam *machine learning* ada 3 jenis, yaitu: *Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning*. Pada *supervised learning*, algoritma diberikan data

training yang sudah memiliki label atau jawaban yang benar. Tujuan utamanya adalah untuk mempelajari hubungan antara input dan output yang diinginkan sehingga dapat melakukan prediksi yang akurat pada data baru.

Ada beberapa jenis masalah yang dapat diselesaikan dalam *supervised learning*, tergantung dari jenis output atau variabel yang akan diprediksi. Beberapa jenis permasalahan *supervised learning* antara lain Klasifikasi, Regresi, dan Klasifikasi Multikelas. Masalah regresi adalah jenis masalah di mana variabel target yang akan diprediksi adalah nilai kontinu. Tujuan dari regresi adalah untuk mempelajari hubungan antara variabel input (fitur) dan variabel output (nilai kontinu) untuk membuat prediksi yang akurat pada data baru. Dalam regresi, variabel target (output) yang akan diprediksi bersifat kontinu, seperti harga rumah, temperatur, pendapatan, atau jumlah penjualan. Tujuan utamanya adalah untuk membangun sebuah model yang dapat mempelajari pola dan hubungan antara variabel input dan variabel target, sehingga dapat memprediksi nilai target yang tepat untuk data baru.

Dalam regresi, ada beberapa metrik evaluasi yang umum digunakan untuk mengukur kinerja model regresi seperti *Root Mean Squared Error* (RMSE) dan *R-squared* ( $R^2$ ). RMSE adalah metrik evaluasi yang menghitung akar kuadrat dari perbedaan kuadrat rata-rata antara nilai yang diprediksi dan nilai sebenarnya. RMSE memberikan gambaran tentang "kesalahan rata-rata" yang dibuat oleh model dalam memprediksi data. *R-squared* memberikan informasi tentang seberapa baik model menjelaskan variasi dalam data. Persamaan yang digunakan dalam menghitung RMSE dan *R-squared* dapat dilihat pada **Persamaan 1** dan **Persamaan 2**.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (2)$$

Dengan:  $\hat{y}_i$  = prediksi model;  $y_i$  = hasil eksperimen; and  $n$  = total jumlah data uji.

## 2.5 Data Uji

Sebelum mengumpulkan data spesimen uji untuk pembelajaran *machine learning*, jumlah spesimen yang diperlukan untuk database yang sesuai harus dipilah. Data dapat dilihat pada **Tabel 1** dan **Tabel 2**. Data yang digunakan merupakan sejumlah hasil uji eksperimental pada kolom beton persegi atau persegi yang diperkuat FRP yang dilaporkan oleh beberapa peneliti.

Dataset yang diperoleh berjumlah 190 data yang meliputi: dimensi terpendek kolom ( $b$ ), dimensi terpanjang kolom ( $h$ ), jari-jari sudut beton ( $r$ ), kuat tekan beton tanpa sambungan ( $f_{co}$ ), jenis FRP: Carbon FRP (CRFP), Aramid FRP (ARFP), Glass FRP (GFRP), jumlah lapisan FRP, tebal lembaran FRP ( $t$ ), kuat tarik FRP ( $f_f$ ), regangan ultimit FRP ( $\epsilon_{fu}$ ), modulus elastisitas FRP ( $E_f$ ), kuat tekan beton terkekang setelah dibungkus dengan bahan FRP ( $f_{cc}$ ).

**Tabel 1. Hasil Pengujian Benda Uji Kolom Persegi dengan Perkuatan FRP**

No.	Referensi	Spesimen	Jenis FRP	Ukuran $h$ [mm] x $h$ [mm]	$r$ [mm]	$f_c'$ [MPa]
1	Rochette and Labossière (2000)[16]	17	C, A	152 x 152 152 x 203	5; 25; 38	35,8 – 43,9
2	Shehata et al. (2002)[18]	4	C	150 150	10	23,7 – 29,5
3	Ilki and Kumbasar (2003)[8]	6	C	250 X 250	40	32,8
4	Lam and Teng (2003)[11]	6	C	150 x 150	15; 25	24,0 – 33,7
5	Masia et al. (2004)[12]	15	C	100 X 100 125 X 125 150 X 150	25	21,3 – 24,5
6	Harajli et al. (2006)[7]	18	C	79 X 214 102 X 176 132 X 132	15	18,3
7	Rousakis et al. (2007)[18]	13	C, G	200 X 200	30	33,0 – 40,0
8	Al-Salloum (2007)[2]	8	C	150 X 150	5; 25; 38; 50	26,7 – 30,9
9	Wang and Wu (2008)[21]	48	C	150 X 150	15; 30; 45; 60	29,3 – 55,2
10	Tao et al. (2008)[20]	11	C	150 X 150	20; 35; 50	19,5 – 49,5
11	Wu and Wei (2010)[21]	30	C	150 X 150 150 X 188 150 X 225 150 X 260 150 X 300	30	35,3
12	Wang et al. (2012)[22]	14	C	204 X 305 305 X 305	20; 30	25,5

**Tabel 2. Statistik Karakteristik Benda Uji**

	$b$ [mm]	$h$ [mm]	$r$ [mm]	$f_{co}'$ [MPa]	Jumlah lapisan	Data karakteristik FRP				$f_{cc}'$ [MPa]
						$t$ [mm]	$f_r$ [MPa]	$\epsilon_{fu}$ [%]	$E_r$ [GPa]	
Minimum	79	100	5	18,3	1	0,12	230	1,25	14	17,2
Maximum	305	305	60	55,2	12	1,2	4.519	2,8	257	90,9
Mean	158,69	182,94	28,93	33,46	2,33	0,22	3.486,46	1,77	201,09	47,58
Median	150	150	30	33,0	2	0,17	3.788	1,84	229	45,65
Sum	30.151	34.759	5.496	6.357,7	442	42,12	662.427	336.31	38.207	9.040,3
Count	190	190	190	190	190	190	190	190	190	190

## 2.6 Persiapan Data

Prosedur persiapan data meliputi proses pra-pemrosesan data dan *Train-Test Split*. *Scaling* atau penskalaan adalah prosedur pra-pemrosesan data yang dilakukan melibatkan konversi semua variabel. Proses ini melakukan perhitungan skala nilai yang awalnya berbeda ke skala nilai antara 0 dan 1. Tujuan dari penskalaan adalah untuk mencegah variabel dengan rentang nilai yang lebih besar mendominasi. Dominasi variabel dengan rentang nilai yang lebih besar cenderung memberikan kontribusi yang lebih besar pada bobot yang terbentuk dalam model, karena sedangkan variabel dengan rentang nilai yang lebih kecil akan diabaikan. Oleh karena itu, penskalaan dilakukan agar kontribusi setiap variabel dalam pemodelan menjadi proporsional.

Setelah melakukan penskalaan terhadap seluruh data, data dibagi menjadi data pelatihan, validasi, dan pengujian. Seluruh data dibagi menjadi data pelatihan dan pengujian, dengan komposisi 80% data pelatihan dan 20% data pengujian. Setelah itu, 10% dari data pelatihan diambil sebagai data validasi. Dengan demikian, data pelatihan terdiri dari 136 dari 190 data, data validasi terdiri dari 16, dan data uji terdiri dari 38. Pada tahap pelatihan, data pelatihan dan validasi akan digunakan untuk merancang model pelatihan JST, CatBoost, dan *M5-Tree*. Eksperimen dilakukan untuk mencari parameter yang tepat pada setiap model pelatihan untuk mendapatkan model pelatihan terbaik pada model JST, CatBoost, dan *M5-Tree* yang diukur berdasarkan metrik pada data validasi. Data uji akan digunakan dalam model *ensemble* dan diuji pada *ensemble*. Setelah itu, hasilnya akan ditentukan dengan menggunakan metrik *Root Mean Squared Error* (RMSE) dan *R-squared* untuk membandingkan performa dari model ANN-*Tree* tunggal, model CatBoost, dan *Ensemble*.

### 3. HASIL DAN PEMBAHASAN

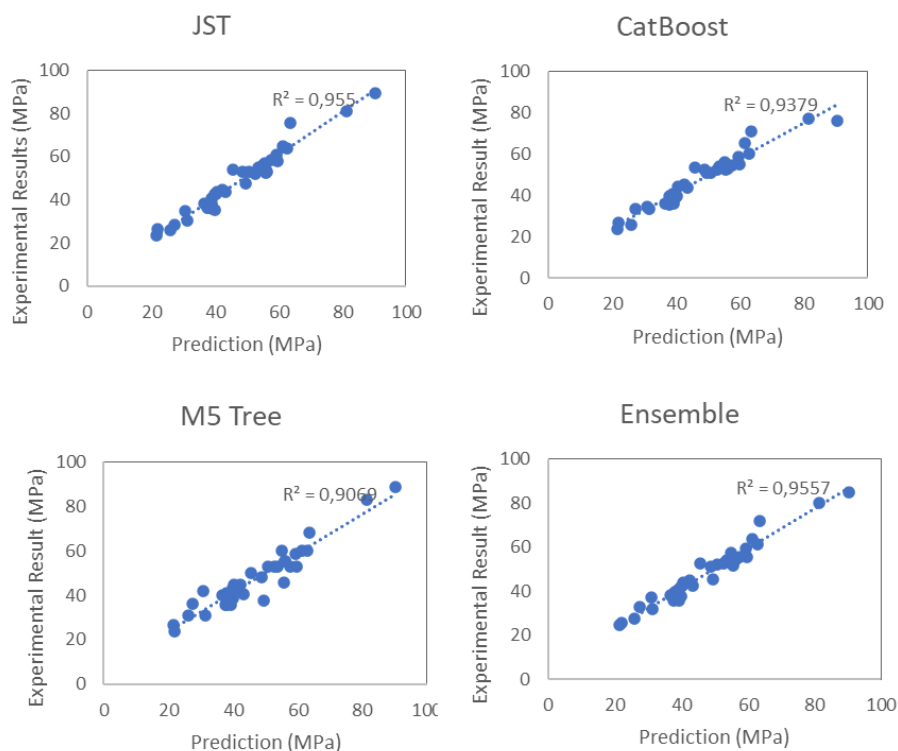
#### 3.1 Prediksi Kuat Tekan

*Ensemble machine learning* memberikan pendekatan dengan menggabungkan beberapa model *machine learning* dengan tujuan untuk meningkatkan performa dan stabilitas prediksi. Dalam *ensemble*, setiap anggota model dapat menjadi model yang relatif lemah secara individual, tetapi ketika digabungkan, mereka dapat menghasilkan model yang lebih kuat dan lebih akurat secara keseluruhan. **Gambar 4** menunjukkan grafik yang membandingkan hasil eksperimen dan prediksi menggunakan pembelajaran mesin. Berdasarkan **Gambar 4**, hasil prediksi dari masing-masing model dan model *ensemble* cukup mendekati nilai eksperimennya. Model ensemble memberikan performa yang cukup baik dengan metrik RMSE 3,207 dan *R-squared* 0,9557.

Perbandingan antara hasil eksperimental dan prediksi *machine learning* diberikan pada **Gambar 5**. Sejumlah usulan model tegangan pengekang beton dengan FRP dari peneliti yang telah ada digunakan untuk tujuan perbandingan dengan hasil prediksi. Verifikasi akan dilakukan pada 3 model yang sudah ada (Lam dan Teng 2003b [11]; Wu 2012 [21]; Pham dan Hadi 2014 [13]). Pemilihan model-model ini didasarkan pada jumlah kutipan yang cukup besar dan kesesuaiannya dengan basis data. **Gambar 5** memperlihatkan bahwa hasil prediksi memberikan nilai *R-squared* yang lebih baik (0,8276) bila dibandingkan dengan usulan dari beberapa peneliti, meskipun masih terdapat beberapa nilai prediksi yang cukup jauh dari nilai sebenarnya.

#### 3.2 Pengaruh Radius Kelengkungan Sudut Kolom

Sesuai dengan hasil prediksi dengan *machine learning*, terdapat pengaruh radius kelengkungan ( $r$ ) terhadap peningkatan kapasitas kuat tekan kolom dengan perkuatan FRP. Pham dan Hadi [15] melaporkan bahwa faktor efisiensi regangan yang dihitung sebagai rasio antara tegangan *ultimate* FRP pada kolom dengan tegangan FRP pada kondisi uji tarik murni merupakan fungsi kekakuan pengekangan dan rasio jari kelengkungan sudut ( $r$ ) dan lebar sisi kolom ( $b$ ). Efek dari penambahan jari-jari kelengkungan yang diberikan pada kolom persegi dapat dilihat pengaruhnya dengan menggunakan hasil *machine learning*. Untuk hal itu dalam penelitian ini dilakukan studi sederhana dalam bentuk analisis besarnya tegangan beton terkekang ( $f'_{cc}$ ) pada kolom persegi yang diberi jari-jari kelengkungan dengan sudut 10 mm sampai 50 mm. Kolom yang digunakan memiliki dimensi berikut:  $b = 150$  mm;  $h = 150$  mm; mutu beton  $f_{co} = 25$  MPa; ketebalan FRP  $t = 0,13$  mm; jumlah lapisan digunakan 1 lembar. Karakteristik FRP: kuat tarik = 3.500 MPa dan Modulus Elastisitas  $E_f = 230.000$  MPa. Hubungan berbagai  $r/b$  dan peningkatan yang dihasilkan dalam bentuk perbandingan antara beton terkekang FRP dan beton tanpa kekangan ( $f'_{cc}/f_{co}$ ) dari hasil prediksi dapat dilihat secara grafis pada **Gambar 5** dengan tanda segitiga.



**Gambar 4. Perbandingan kuat tekan setiap model prediksi dan *ensemble***

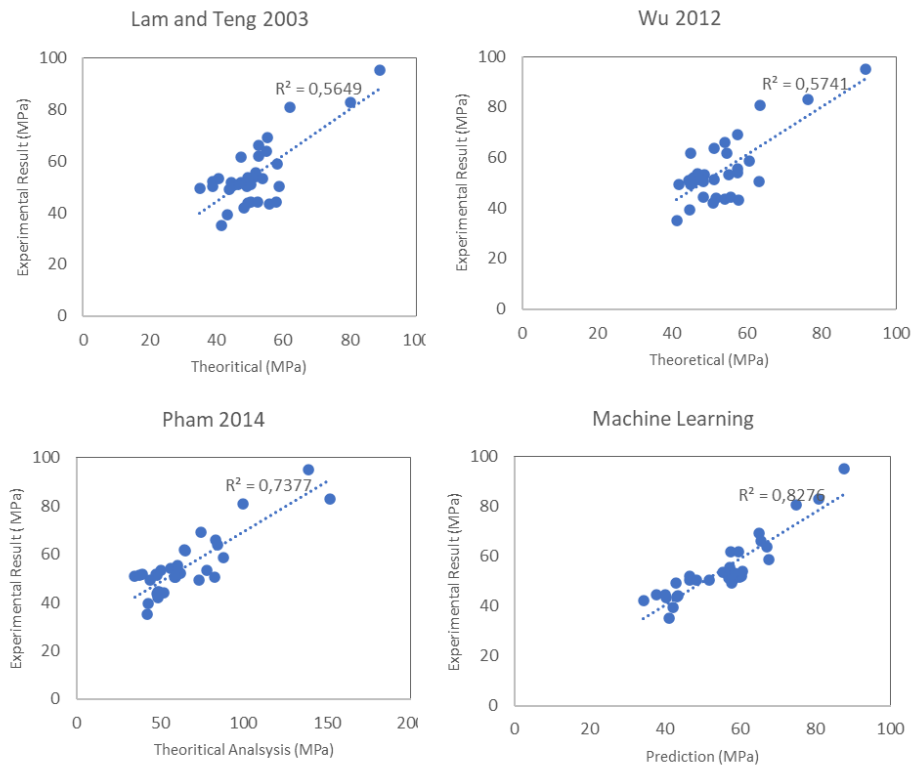
Untuk memberikan perbandingan dengan hasil eksperimen dan standar desain, grafik pada **Gambar 5** juga menyajikan perbandingan dengan hasil eksperimen dari beberapa penelitian yang menggunakan spesimen kolom persegi dengan jari-jari kelengkungan pada sudut-sudut kolom dan menggunakan 1 lembar FRP.

Menurut hasil prediksi, terdapat indikasi bahwa kuat tekan akan meningkat seiring dengan bertambah besar radius kelengkungan sudut yang diberikan. Data eksperimen dari investigasi penelitian lain juga menunjukkan tren yang sama. Hal ini menunjukkan bahwa peningkatan jari-jari kelengkungan akan menyebabkan dimensi kolom memiliki bentuk mendekati penampang melingkar, yang pada gilirannya akan meningkatkan keseragaman tegangan lateral yang bekerja pada FRP di sisi kolom.


Pada radius kelengkungan yang kecil terjadi konsentrasi tegangan pada sudut-sudut kolom karena tidak meratanya efek kekangan pada penampang persegi. Kondisi ini akan menghasilkan kegagalan yang lebih awal karena tegangan telah mencapai batas kapasitas FRP.

SNI 8971:2021 Panduan Perancangan Dan Pelaksanaan Sistem Lembaran Serat Berpolimer Terlekat Eksternal Untuk Perkuatan Struktur Beton [4] memberi batasan jari-jari kelengkungan minimum yang diperlukan pada sudut kolom persegi harus lebih besar dari 15 mm.

Pada **Gambar 6** terlihat ketika diberikan  $r$  kurang dari 15mm ( $r/b < 0,1$ ), hasil prediksi dalam kasus ini tidak akurat karena tidak ada data eksperimen yang digunakan dalam pelatihan *machine learning* yang memiliki radius kelengkungan rendah dari 15 mm.



**Gambar 5. Perbandingan hasil usulan teori dan prediksi dengan *machine learning***



**Gambar 6. Korelasi  $r/b$  terhadap peningkatan kuat tekan**

#### 4. KESIMPULAN

Berdasarkan model individual JST, CatBoost, dan *M5-Tree*, kinerja model berikut berturut-turut adalah JST ( $R\text{-squared}=0,9550$ ); CatBoost ( $R\text{-squared}=0,939$ ); dan *M5-Tree* ( $R\text{-squared}=0,9069$ ). *Ensemble Machine Learning* membuat kinerja yang lebih baik dibandingkan dengan tiga model individual ANN, CatBoost, dan *M5-Tree* dengan nilai  $R\text{-squared}$  sebesar 0,9557. Penggunaan *machine learning* untuk memprediksi hasil kuat tekan beton dengan perkuatan FRP dibandingkan dengan beberapa usulan teori tegangan terkekang, memberikan hasil yang paling mendekati dengan nilai  $R\text{-squared}$  sebesar 0,8276. Prediksi dengan *machine learning* dapat memberikan gambaran korelasi antara peningkatan radius sudut kelengkungan dengan peningkatan tegangan terkekang.

## UCAPAN TERIMA KASIH

Ucapan terima kasih untuk fasilitas dan anggaran yang diberikan dalam program hibah internal tahun anggaran 2023.

## DAFTAR PUSTAKA

- [1] A., Alipour, J., Yarahmadi, & M., Mahdavi. (2014). "Comparative Study of M5 Model Tree and Artificial Neural Network in Estimating Reference Evapotranspiration Using MODIS Products," *Journal of Climatology (Cairo)*, 2014(1), pp. 1–11. <https://doi.org/10.1155/2014/839205>
- [2] Y. A., Al-Salloum, (2007). "Influence of edge sharpness on the strength of square concrete columns confined with FRP composite laminates", *Composites Part B: Engineering*, 38(5–6), pp. 640–650. <https://doi.org/10.1016/j.compositesb.2006.06.019>
- [3] A. V., Dorogush, V., Ershov, & A., Gulin. (2018), "CatBoost: gradient boosting with categorical features support," pp. 1–7. <https://doi.org/10.48550/arXiv.1810.11363>
- [4] Badan Standardisasi Nasional, (2021). "SNI 8971:2021 tentang Panduan Perancangan Dan Pelaksanaan Sistem Lembaran Serat Berpolimer Terlekat Eksternal Untuk Perkuatan Struktur Beton", Badan Standardisasi Nasional, Jakarta.
- [5] B., Kim, D. E., Lee, G., Hu, Y., Natarajan, S., Preethaa, & A. P., Rathinakumar, (2022). "Ensemble Machine Learning-Based Approach for Predicting of FRP–Concrete Interfacial Bonding", *Mathematics*, 10(2), pp. 231. <https://doi.org/10.3390/math10020231>
- [6] G., Campione, N., Miraglia, & M., Papia, (2004). "Strength and strain enhancements of concrete columns confined with FRP sheets", *Struct. Eng.Mech*, 18(6), pp. 769–790. <https://doi.org/10.12989/sem.2004.18.6.769>
- [7] M. H., Harajli, E., Hantouche, & K., Soudki, (2006). "Stress-strain model for fiber-reinforced polymer jacketed concrete columns", *Structural Journal*, 103(5), pp. 672–682. <https://doi.org/10.14359/16919>
- [8] A., Ilki, & N., Kumbasar, (2003). "Compressive behaviour of carbon fibre composite jacketed concrete with circular and non-circular cross-sections", *Journal of Earthquake Engineering*, 7(3), pp. 381–406. <https://doi.org/10.1080/13632460309350455>
- [9] M., Jalal, & A. A., Ramezaniapour, (2012). "Strength enhancement modeling of concrete cylinders confined with CFRP composites using artificial neural networks", *Composites Part B: Engineering*, 43(8), pp. 2990–3000. <https://doi.org/10.1016/j.compositesb.2012.05.044>
- [10] G., Karam, & M., Tabbara. (2005). "Confinement effectiveness in rectangular concrete columns with fiber reinforced polymer wraps", *Journal of Composites for Construction*, 9(5), pp. 388–396. [https://doi.org/10.1061/\(ASCE\)1090-0268\(2005\)9:5\(388\)](https://doi.org/10.1061/(ASCE)1090-0268(2005)9:5(388))
- [11] L., Lam, & J. G., Teng, (2003). "Design-oriented stress-strain model for FRP-confined concrete in rectangular columns", *Journal of Reinforced Plastics and Composites*, 22(13), pp. 1149–1186. [https://doi.org/10.1016/S0950-0618\(03\)00045-X](https://doi.org/10.1016/S0950-0618(03)00045-X)
- [12] M. J., Masia, T. N., Gale, & N. G., Shrive, (2004). "Size effects in axially loaded square-section concrete prisms strengthened using carbon fibre reinforced polymer wrapping", *Canadian Journal of Civil Engineering*, 31(1), pp. 1–13. <https://doi.org/10.1139/l03-064>
- [13] H., Naderpour, A., Kheyroddin, & G. G., Amiri, (2010). "Prediction of FRP-confined compressive strength of concrete using artificial neural networks", *Composite Structures*, 92(12), pp. 2817–2829. <https://doi.org/10.1016/j.compstruct.2010.04.008>
- [14] A. W. C., Oreta, & K., Kawashima, (2003). "Neural Network Modeling of Confined Compressive Strength and Strain of Circular Concrete Columns", *Journal of Structural Engineering*, 129(4), pp. 554–561. [https://doi.org/10.1061/\(ASCE\)0733-9445\(2003\)129:4\(55](https://doi.org/10.1061/(ASCE)0733-9445(2003)129:4(55)

- [15] T. M., Pham, & M. N. S., Hadi, (2014). "Stress prediction model for FRP confined rectangular concrete columns with rounded corners", *Journal of Composites for Construction*, 18(1). [https://doi.org/10.1061/\(ASCE\)CC.1943-5614.000040](https://doi.org/10.1061/(ASCE)CC.1943-5614.000040)
- [16] F. E., Richart, A., Brandtzaeg, & R. L., Brown, (1928). "A study of the failure of concrete under combined compressive stresses", Bulletin No. 185, 26(12), Engineering Experiment Station, University of Illinois, Urbana.
- [17] P., Rochette, & P., Labossière, (2000). "Axial testing of rectangular column models confined with composites", *Journal of Composites for Construction*, 4(3), pp. 129–136. [https://doi.org/10.1061/\(ASCE\)1090-0268\(2000\)4:3\(129\)](https://doi.org/10.1061/(ASCE)1090-0268(2000)4:3(129))
- [18] T. C., Rousakis, A. I., Karabinis, & P. D., Kiousis, (2007). "FRP-confined concrete embers: Axial compression experiments and plasticity modelling", *Engineering Structures*, 29(7), pp. 1343–1353. <https://doi.org/10.1016/j.engstruct.2006.08.006>
- [19] I. A. E. M., Shehata, L. A. V., Carneiro, and L. C. D., Shehata, (2002). "Strength of short concrete columns confined with CFRP sheets", *Materials and Structures*, 35(1), pp. 50–58.
- [20] Z., Tao, Q., Yu, & Y. Z., Zhong, (2008). "Compressive behaviour of CFRP-confined rectangular concrete columns", *Magazine of Concrete Research*, 60(10), pp. 735–745. <https://doi.org/10.1680/mac.2007.00115>
- [21] L. M., Wang, & Y. F., Wu. (2008). "Effect of corner radius on the performance of CFRP-confined square concrete columns: Test", *Engineering Structures*, 30(2), pp. 493–505. <https://doi.org/10.1016/j.engstruct.2007.04.016>
- [22] Z. Y., Wang, D. Y., Wang, S. T., Smith, & D. G., Lu, (2012). "CFRP-Confined square RC columns. I: Experimental investigation", *Journal of Composites for Construction*, 16(2), pp. 150–160. [https://doi.org/10.1061/\(ASCE\)CC.1943-5614.0000245](https://doi.org/10.1061/(ASCE)CC.1943-5614.0000245)
- [23] E., Alpaydin, (2014). "Introduction to Machine Learning Second Edition", The MIT Press, Cambridge, Massachusetts, London, England.