

PREDIKSI LAJU PENETRASI PENGEBORAN MENGGUNAKAN JARINGAN SARAF TIRUAN

Raka Sudira Wardana¹, Bastian Andoni², Fadhil Rhisnanda³

^{1,3}Program Studi Teknik Perminyakan, Universitas Pertamina

²PT. Pertamina Internasional EP

E-mail: rakawardana@gmail.com

ABSTRACT

Various efforts have been made to reduce drilling costs in the oil and gas upstream industry. One of it is by maximizing drilling Rate Of Penetration (ROP), the speed at which a drill bit breaks the formation underneath it to deepen the borehole. High ROP resulted in shorter drilling times can reduce drilling costs. This is the ideal condition that is expected in every drilling process. However, many factors such as environmental factors (rock formations, wellbore size, drilling mud), drilling parameters (weight on bits, rotational speed, flow rate, hydraulics, etc.) and the characteristics of the bits determine the ROP. Among all, drilling parameters is the only one that can be customized to generate the highest ROP during the drilling process. Choosing drilling parameters to generate the highest ROP in the various environmental condition is not a trivial thing. Moreover, the correlation among these parameters is not linear, and some other factors also affect ROP. Some empirical ROP models that can be used requires parameters that are not always available in the operation field. This study proposes an Artificial Neural Network (ANN) to predict ROP. Using formation type and drilling parameters data as the input, the model produces a great degree of accuracy (R-square at least 0.8). It shows that ANN can become a better alternative to find the optimum drilling parameter to achieve the highest ROP.

Keywords: Rate of penetration, Drilling parameter, Artificial Neural Network

ABSTRAK

Berbagai upaya dilakukan untuk mengurangi biaya pengeboran pada industri upstream minyak dan gas. Salah satunya dengan melakukan optimasi laju penetrasi pengeboran atau Rate Of Penetration (ROP), kecepatan mata bor memecah formasi di bawahnya untuk memperdalam lubang sumur. ROP yang tinggi dapat menghasilkan waktu pengeboran yang lebih singkat sehingga dapat mengurangi biaya pengeboran. Ini adalah kondisi ideal yang diharapkan dalam setiap proses pengeboran. Namun, banyak faktor seperti faktor lingkungan (formasi batuan, ukuran lubang sumur, lumpur pengeboran), parameter pengeboran (beban pada mata bor, kecepatan putar, laju alir, hidrolika, dll) dan karakteristik dari mata bor yang menentukan ROP. Di antara semua faktor tersebut, parameter pengeboran adalah satu-satunya faktor yang dapat dikustomisasi untuk menghasilkan ROP tertinggi selama proses pengeboran. Memilih parameter pengeboran untuk menghasilkan ROP tertinggi dalam berbagai kondisi lingkungan bukanlah hal yang mudah. Selain itu, korelasi antara parameter-parameter tersebut tidak linier, dan ada beberapa faktor lain yang juga mempengaruhi ROP. Beberapa model empiris ROP yang dapat digunakan memerlukan parameter yang tidak selalu tersedia di lapangan operasi. Penelitian ini menggunakan Jaringan Saraf Tiruan (JST) untuk memprediksi ROP. Menggunakan data tipe formasi dan parameter pengeboran sebagai input, model ini menghasilkan tingkat akurasi yang besar (R-square sekurang-kurangnya 0,8). Ini menunjukkan bahwa JST dapat menjadi alternatif yang lebih baik untuk menemukan parameter pengeboran yang optimal untuk mencapai ROP tertinggi.

Kata kunci: Laju penetrasi, Parameter pengeboran, Jaringan Saraf Tiruan

1. PENDAHULUAN

Harga minyak dunia turun secara tajam di akhir tahun 2013. Penurunan harga minyak dunia tersebut menyebabkan berkurangnya pendapatan industri *upstream* minyak dan gas secara drastis sehingga banyak proyek pengeboran dan produksi yang dibatalkan serta banyak karyawan yang meninggalkan industri ini. Terlebih lagi, biaya yang diperlukan dalam industri ini terus meningkat sejalan dengan meningkatnya kesulitan dalam memproduksi minyak dan gas bumi. Dalam dekade terakhir, pengeluaran modal naik 400% sementara produksi hanya meningkat 15% [1]. Untuk itu berbagai macam upaya untuk mengurangi biaya operasional pengeboran terus dilakukan oleh pelaku industri minyak dan gas.

Salah satu cara untuk menurunkan biaya pengeboran ialah dengan meningkatkan laju penetrasi pengeboran. Laju penetrasi pengeboran atau *Rate Of Penetration* (ROP) dapat diartikan sebagai kecepatan mata bor memecah formasi di bawahnya untuk memperdalam lubang sumur. ROP sangat mempengaruhi waktu operasi pengeboran karena ROP berhubungan langsung dengan *rotating time*. Dalam waktu operasi pengeboran, *rotating time* dapat memakan waktu hingga 30% dari total waktu operasi pengeboran. Dengan meningkatkan ROP maka proses pengeboran akan lebih cepat sehingga biaya yang dikeluarkan untuk menyewa peralatan pengeboran maupun *rig* pengeboran bisa berkurang.

ROP sangat dipengaruhi oleh banyak faktor seperti seperti faktor lingkungan (formasi batuan, ukuran lubang sumur, lumpur pengeboran), parameter pengeboran (beban pada mata bor, kecepatan putar, laju alir, hidrolika, dll) dan karakteristik dari mata bor yang digunakan. Parameter pengeboran dan mata bor merupakan parameter yang bisa dikontrol. Parameter pengeboran bisa diganti-ganti pada saat proses pengeboran berlangsung namun memiliki batasan minimum dan maksimum sesuai alat yang digunakan, desain sumur dan program pengeboran.

Parameter pengeboran dipilih oleh *driller* untuk menghasilkan ROP yang paling maksimum. Namun pemilihan parameter pengeboran yang optimum tidaklah mudah. Pada prakteknya di lapangan, *driller* akan mencatat parameter pengeboran yang digunakan dan ROP yang dihasilkan. Hal ini dilakukan melalui *trial and error*. Dari data tersebut kemudian *driller* menganalisis kecenderungan yang terjadi. Namun kemampuan yang baik dalam memprediksi ROP hanya dapat dicapai dengan memiliki banyak pengalaman pengeboran yang pada formasi yang sama dan memiliki faktor *human error yang tinggi*. Oleh karena itu, diperlukan metode yang dapat membantu *driller* untuk memahami dan menganalisis ROP serta menentukan ROP berdasarkan parameter pengeboran yang digunakan.

Artificial Neural Network atau Jaringan Saraf Tiruan (JST) adalah salah satu metode yang dapat membantu menemukan hubungan antara parameter input dan

parameter output tanpa menghasilkan korelasi. Tujuan dari penelitian ini adalah untuk menghasilkan model JST yang dapat memprediksi laju penetrasi pengeboran. Menggunakan parameter pengeboran (beban pada mata bor, kecepatan putar, torsi, laju alir dan hidrolika pengeboran), mata bor dan formasi batuan sebagai parameter input, Jaringan Saraf Tiruan dapat digunakan untuk memprediksi laju penetrasi pengeboran.

2. DASAR TEORI

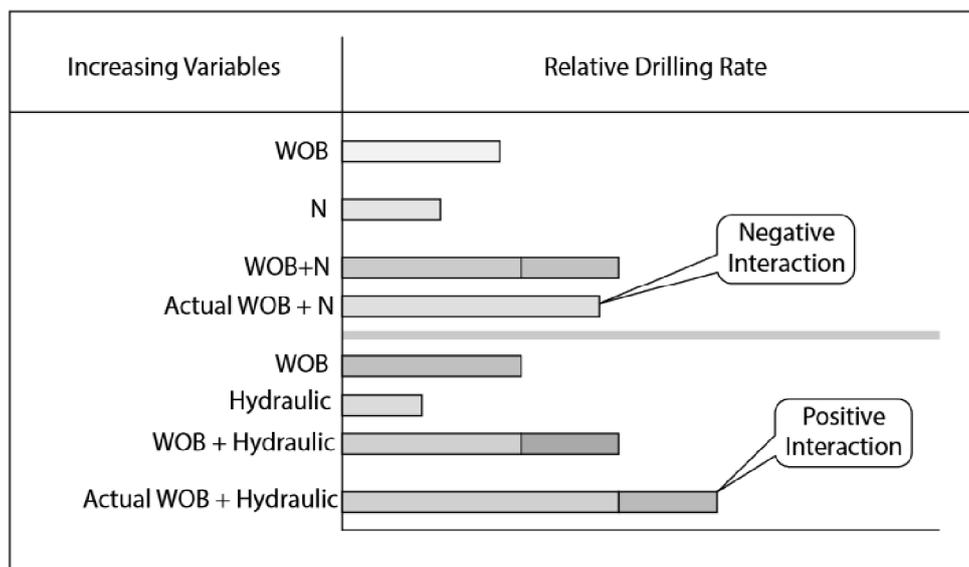
2.1 Laju Penetrasi Pengeboran

Laju penetrasi pengeboran atau *rate of penetration* (ROP) diukur melalui perubahan relatif dari posisi blok dalam suatu rentang waktu [2]. Terdapat banyak faktor yang mempengaruhi ROP bahkan mungkin ada beberapa faktor yang belum dikenali hingga saat ini. Faktor-faktor yang mempengaruhi ROP dapat dikelompokkan ke dalam dua kelompok yaitu faktor lingkungan dan faktor yang dapat dikendalikan (tabel 1).

Tabel 1. Faktor yang Mempengaruhi ROP [2]

Faktor Lingkungan	Faktor yang dapat dikendalikan
Kedalaman	<i>Bit Wear State</i>
Properti Formasi	Desain Mata Bor
Tipe Lumpur	Beban pada Mata Bor
Densitas Lumpur	Kecepatan Putar
Properti lain lumpur	Laju Alir
Tekanan Lumpur <i>Overbalance</i>	Hidrolika Mata Bor
Tekanan Lumpur Dasar Sumur	Ukuran <i>nozzle</i> Mata Bor
Ukuran Mata Bor	Geometri Motor/turbin

Tidak semua faktor yang dapat dikendalikan bisa dirubah saat proses pengeboran dilakukan. Desain mata bor, ukuran mata bor dan geometri motor harus ditentukan di awal pengeboran dan tidak akan diganti selama proses pengeboran dilakukan. Selama proses pengeboran dilakukan, *driller* hanya akan mengubah parameter pengeboran seperti beban pada mata bor, kecepatan putar dan laju alir untuk mendapatkan ROP yang maksimum.



Gambar 1. Interaksi Positif dan Negatif [2]

Namun hubungan antara masing – masing parameter pengeboran dengan ROP sulit untuk ditentukan. Gambar 1 menunjukkan efek interaksi parameter pengeboran pada ROP. Interaksi tersebut ada ketika nilai dua atau lebih variabel ditingkatkan dan tidak menghasilkan efek additif jika dibandingkan dengan efek individu.

Selain itu, belum adanya persamaan pasti yang menghubungkan faktor-faktor tersebut membuat ROP semakin kompleks untuk diprediksi. Beberapa pendekatan empiris (model ROP) dilakukan untuk memprediksi ROP berdasarkan faktor yang ada. Beberapa model ROP di antaranya ada *Maurer’s Method*, *Galle and Woods’ Method*, *Bingham Model*, *Bourgoyne and Young’s Model*, *Warren’s Model*, *Modified Warren’s Model*, *Pessier and Fear Method*, dan *Osgouei Model*. Dari model ROP tersebut, *Bourgoyne and Young’s Model* adalah salah satu model yang paling sering digunakan untuk mengestimasi ROP.

Bourgoyne and Young’s Model [3] merupakan model yang digunakan untuk mengestimasi nilai ROP yang dibuat dari analisis regresi berganda dengan data pengeboran asli yang diambil dalam interval pendek. Model ini merupakan fungsi dari beberapa variabel seperti kekuatan formasi, kompaksi formasi, perbedaan tekanan sepanjang lubang sumur, diameter mata bor, beban pada mata bor, kecepatan putar, *bit wear*, dan hidrolika mata bor. Persamaan dibawah berikut merupakan model ROP yang dibuat oleh *Bourgoyne* dan *Young* [3]:

$$\frac{d}{dt}(ROP) = e^{(a_1 + \sum_{j=2}^8 a_j x_j)} \tag{1}$$

$$x_1 = 1.0 \tag{2}$$

$$x_2 = 10,000 - TVD \quad (3)$$

$$x_3 = TVD^{0.69}(g_P - 9.0) \quad (4)$$

$$x_4 = TVD(g_P - \rho_{ec}) \quad (5)$$

$$x_5 = \ln \left\{ \frac{\left(\frac{WOB}{d_b} - \left(\frac{WOB}{d_b} \right)_t \right)}{4.0 - \left(\frac{WOB}{d_b} \right)_t} \right\} \quad (6)$$

$$x_6 = \ln \left\{ \frac{N}{100} \right\} \quad (7)$$

$$x_7 = -h \quad (8)$$

$$x_8 = \ln \left\{ \frac{\rho_m Q}{350 \mu d_n} \right\} \quad (9)$$

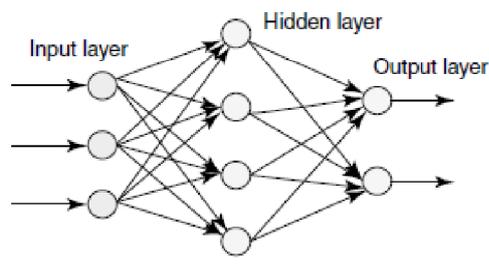
$$\frac{d}{dt}(ROP) = e^{\left[a_1 + a_2(10000 - TVD) + a_3 TVD^{0.69}(g_P - 9.0) + a_4 TVD(g_P - \rho_{ec}) + a_5 \ln \left\{ \frac{\left(\frac{WOB}{d_b} - \left(\frac{WOB}{d_b} \right)_t \right)}{4.0 - \left(\frac{WOB}{d_b} \right)_t} \right\} + a_6 \ln \left\{ \frac{N}{100} \right\} + a_7(-h) + a_8 \ln \left\{ \frac{\rho_m Q}{350 \mu d_n} \right\} \right]} \quad (10)$$

Dari persamaan tersebut terlihat bahwa banyak sekali parameter yang diperlukan, sedangkan banyak dari parameter tersebut yang belum tentu tersedia di lapangan. Sebuah penelitian oleh M. Bataee, S. Irawan dan M. Kamyab menemukan bahwa model ini cukup cocok dengan data sumur aktual dengan kesalahan dan deviasi ROP yang lebih rendah dibanding model Bingham dan Warren, namun tetap memiliki nilai R yang cukup jauh dari 1 yaitu 40.46% [4].

2.2 Artificial Neural Network (JARINGAN SARAF TIRUAN)

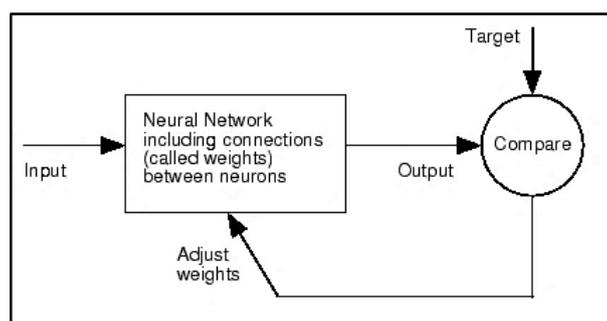
Artificial Neural Network atau Jaringan Saraf Tiruan (JST) adalah model matematika yang memiliki kemampuan untuk belajar, melatih dan membuat kesimpulan berdasarkan data yang disajikan. Model matematika ini meniru sistem saraf biologis otak manusia, karenanya disebut JST.

JST terdiri dari lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan keluaran (*output layer*) seperti yang terlihat pada gambar 2. Lapisan *input* adalah parameter utama yang mempengaruhi nilai lapisan keluaran. Lapisan tersembunyi (*hidden layer*) adalah lapisan tidak terlihat dia antaranya.



Gambar 2. Jaringan Saraf Tiruan [5]

Gambar 3 menunjukkan penjelasan sederhana cara kerja JST. JST memiliki kemampuan untuk belajar dan berlatih, untuk mencocokkan antara *output* dan target. Dalam model matematika yang disederhanakan dari neuron, efek dari sinapsis direpresentasikan dengan *connection weights* yang memodulasi efek dari sinyal input terkait, dan karakteristik nonlinear yang ditunjukkan oleh neuron direpresentasikan oleh fungsi transfer [6]. Dengan menyesuaikan perubahan *weights* dan *bias* berdasarkan algoritma pembelajaran, JST dapat belajar beradaptasi dengan target.

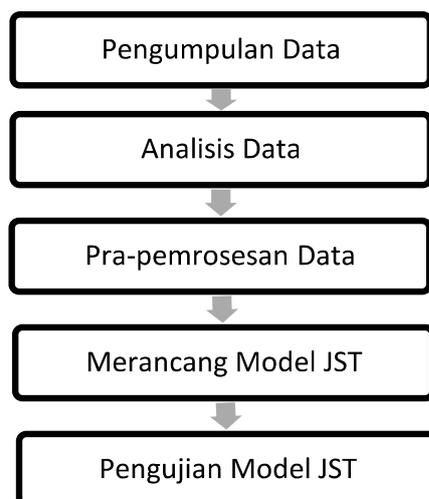


Gambar 3. Neural Networks Typical Connections [6]

Keberhasilan Model JST dapat dinilai dengan membandingkan hasil prediksi dan data aktual atau target. Nilai yang lebih dekat antara data prediksi dan data aktual menunjukkan kinerja yang baik dari Model JST.

3. METODOLOGI DAN PEMBAHASAN

Gambar 4 menunjukkan metodologi penelitian yang dilakukan. Metodologi penelitian terdiri dari pengumpulan data, analisis data, pra-pemrosesan data, perancangan model JST dan pengujian model.



Gambar 4. Metodologi Penelitian

Langkah pertama dari penelitian ini adalah pengumpulan data. Data dikumpulkan dari lapangan X. Sumur di lapangan X dibor dengan trajektori vertikal. Ukuran lubang sumur dari paling besar ke kecil yaitu 24", 17.5", 12.25", 8.5" dan 6". Data dikumpulkan dari 6 sumur yang dibor. Keenam sumur yang dibor ini memiliki karakteristik formasi yang identik sehingga valid untuk dilakukan pemodelan. Data drilling parameter yang diambil hanya dari 12 ¼" *hole section*. Hal ini dilakukan karena interval ini merupakan bagian lubang sumur yang paling panjang untuk dibor (sekitar 2100 m), selain itu pada interval ini tidak terdapat zona produksi minyak maupun zona tekanan abnormal, sehingga tidak perlu dilakukan pengendalian laju penetrasi. Pada bagian lubang lainnya, perlu dilakukan pengendalian laju penetrasi (ROP) karena pada interval 8.5" terdapat zona tekanan abnormal sedangkan pada interval 6" terdapat zona produksi. Laju penetrasi yang terlalu tinggi dapat menyebabkan kualitas lubang pada zona produksi menjadi kurang baik.

Lembar parameter pengeboran, laporan informasi mata bor yang digunakan dan data formasi dikumpulkan dari masing-masing sumur. 9285 dataset yang terkumpul dibagi menjadi 3; data *training*, data *validation* dan data *testing*.

Langkah selanjutnya adalah menganalisis dan memilih data yang akan digunakan sebagai *input* dari model JST. Dalam menghasilkan Model JST untuk prediksi ROP, penentuan parameter yang akan dijadikan input perlu dilakukan. Berdasarkan data yang tersedia di lapangan dan faktor yang berpengaruh terhadap ROP (tabel 1) maka data yang digunakan sebagai *input* parameter yaitu:

1. Jenis formasi
2. Kedalaman
3. Beban pada mata bor atau *Weight on Bit* (WOB)

4. Kecepatan Alir (*flow rate*)
5. Tekanan *Standpipe*
6. Kecepatan putar atau rotating speed (RPM)
7. Torsi
8. Densitas lumpur pengeboran

Semua sumur menggunakan jenis dan ukuran mata bor yang sama yaitu *Polycrystalline Diamond Compact (PDC) bit*. Oleh karena itu data mata bor tidak dimasukkan sebagai *input* di JST. Data yang digunakan sebagai *output* model JST hanya 1 yaitu ROP. Tabel 2 menunjukkan distribusi statistik dari data yang digunakan.

Tabel 2. Distribusi Statistik Data

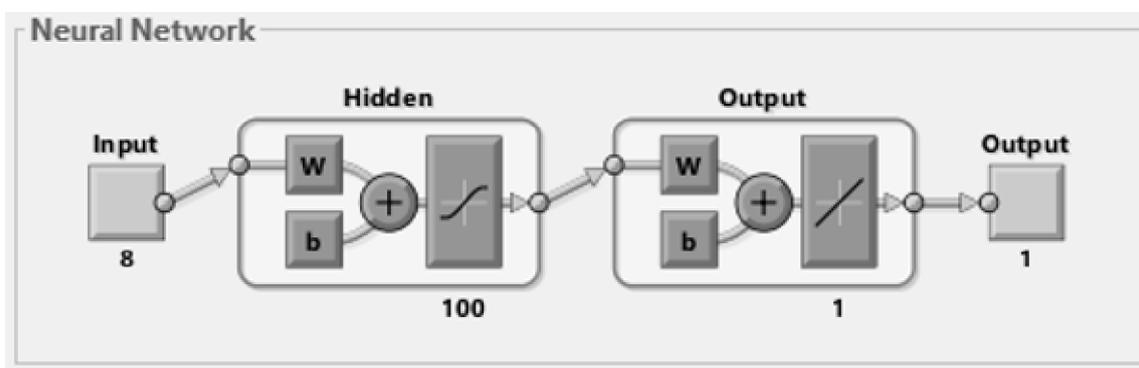
	Kode Formasi	Kedalaman	Beban pada mata bor	Laju Alir	Tekanan <i>Standpipe</i>
	[<i>dimensionless</i>]	[meter]	[ton]	[gpm]	[psi]
Nilai Maksimum	10	2595	160	1741.3	4416
Nilai Minimum	1	428	0	0	547
Jarak	9	2167	160	1741.3	3869
Median	5	1447	11	782.2	3409
	Kecepatan Putar	Torsi	Densitas Fluida	Laju Penetrasi	
	[rpm]	[lb ft]	[ppg]	[meter / jam]	
Nilai Maksimum	13851	19822	12.049	309.1	
Nilai Minimum	57	0	8.25	3.1	
Jarak	13794	19822	3.799	306	
Median	151	9194	11	78.3	

Kemudian data memasuki tahap pra-pemrosesan. Pra-pemrosesan data adalah proses mentransformasikan data menjadi kompatibel untuk JST. Dalam tahap pra-pemrosesan data dilakukan normalisasi nilai numerik. Normalisasi nilai numerik atau normalisasi data diperlukan karena JST memiliki rentang nilai operasi yang terbatas. Dan tidak semua dataset memiliki rentang yang sama. Dalam pra-pemrosesan data, data ditransformasikan menjadi rentang -1 hingga 1. Nilai maksimum ditransformasikan menjadi satu dan nilai minimum ditransformasikan menjadi -1. Selain itu pada tahap ini data – data anomali dibuang.

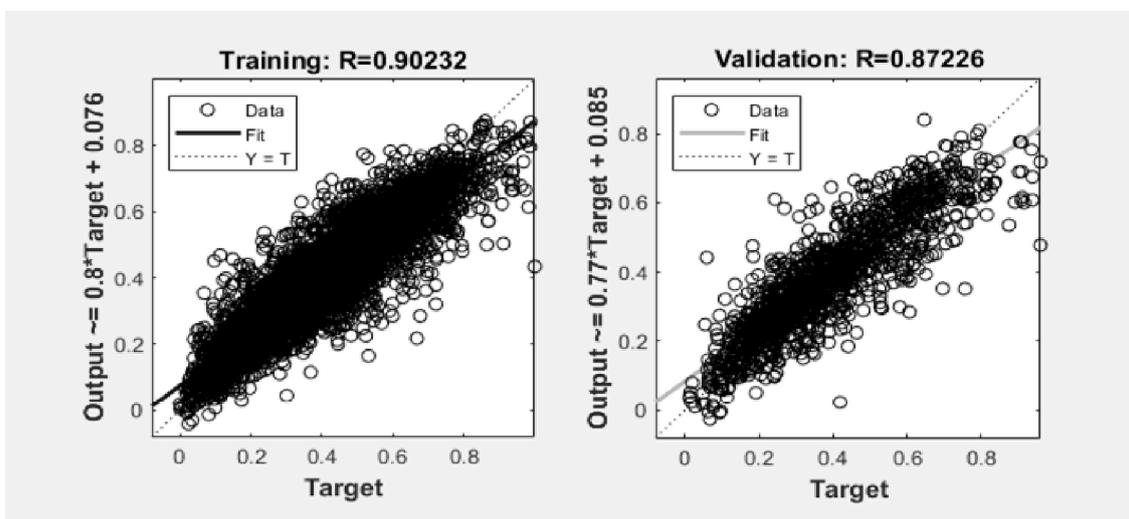
Setelah semua data melalui tahap pra-pemrosesan, langkah selanjutnya adalah mendesain model JST. Model JST didesain dengan 1 *hidden layer*. Jumlah neuron yang digunakan di hidden layer ditentukan dengan proses iterasi dan *trial and error*.

Kemudian *network wight* pada model akan disesuaikan pada proses *training*. Training dilakukan dengan menggunakan algoritma Levenberg-Marquardt. Selanjutnya *parameter tuning* dilakukan menggunakan data *validation*. Model JST yang dipilih adalah model yang menghasilkan korelasi (nilai-R) yang mendekati 1. Kedua hal tersebut menunjukkan bahwa model JST memiliki kinerja yang baik.

Optimasi model dilakukan dengan menggunakan beberapa variasi jumlah neuron di *hidden layer*. Berdasarkan optimasi tersebut maka didapatkan model paling baik menggunakan 100 neuron pada hidden layer (gambar 5). Model tersebut menghasilkan korelasi (nilai-R) 0.9 untuk data *training* dan 0.877 untuk data *validation* (gambar 6).



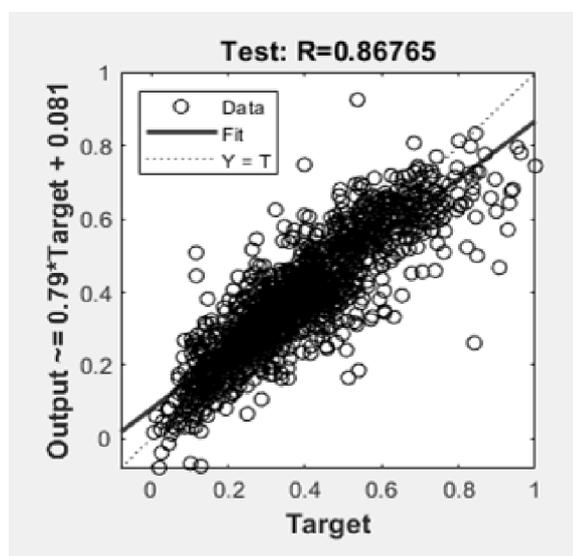
Gambar 5. JST Model



Gambar 6. Nilai R data *training* dan *validation*

Setelah model JST dihasilkan, model JST diuji dengan menggunakan data *testing*. Data *testing* tersebut tidak pernah dikenali oleh model JST sebelumnya. Hasil prediksi dari model JST dibandingkan dengan ROP sebenarnya di lapangan. Dari

perbandingan tersebut didapatkan nilai korelasi (nilai-R) sebesar 0.86 (gambar 7). Dari hasil ini menunjukkan bahwa model JST yang dibuat menunjukkan kemampuan yang baik dalam melakukan prediksi data ROP.



Gambar 7. Nilai R data *testing*

4. KESIMPULAN DAN SARAN

Model JST berhasil dibuat dan divalidasi dengan memprediksi laju penetrasi. Model JST yang dirancang dan dihasilkan dari data lapangan X menunjukkan hasil yang baik dalam memprediksi laju penetrasi. JST terbukti bisa menjadi metode untuk membantu *driller* memprediksi ROP dari parameter pengeboran yang digunakan di lapangan. Dengan prediksi tersebut *driller* bisa melakukan optimasi pemilihan parameter pengeboran untuk mendapatkan ROP yang maksimum dan menurunkan biaya pengeboran.

Beberapa rekomendasi untuk penelitian lebih lanjut yaitu model JST dapat dibuat dengan berbagai data sumur dari lapangan lain. Hal ini dilakukan sehingga model JST tersebut dapat digunakan tidak terbatas hanya untuk satu lapangan. Selain itu penelitian ini bisa dilanjutkan ke penelitian tentang optimasi parameter pengeboran menggunakan data hasil prediksi ROP menggunakan JST. Hal ini memungkinkan *driller* untuk melakukan penyesuaian parameter pengeboran dan mendapatkan ROP yang maksimal sesuai kondisi saat pengeboran.

5. UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada Universitas Pertamina dan PT. Pertamina Internasional EP yang telah memberi dukungan yang membantu pelaksanaan penelitian dan atau penulisan artikel ini.

DAFTAR PUSTAKA

- [1] S. Rassenfoss dan A. Henni, "Low Oil Prices Make Innovation a Priority," *Journal of Petroleum Technology*, vol. 67, no. 02, pp. 56-61, 2015.
- [2] M. E. Hossain dan A. A. Al-Majed, *Fundamentals of Sustainable Drilling Engineering*, Beverly: Scrivener Publishing, 2015.
- [3] A. Bourgoyne dan F. Young, "A Multiple Regression Approach to Optimal Drilling and Abnormal Pressure Detection," *Society of Petroleum Engineers Journal*, vol. 14, no. 04, pp. 371-384, 1974.
- [4] M. Bataee, S. Irawan dan M. Kamyab, "Artificial Neural Network Model for Prediction of Drilling Rate of Penetration and Optimization of Parameters," *Journal of the Japan Petroleum Institute*, vol. 56, no. 2, pp. 65-70, 2014.
- [5] A. Abraham, "Artificial Neural Networks," dalam *Handbook of Measuring System Design*, Oklahoma, John Wiley & Sons, 2005, pp. 901-908.
- [6] H. Demuth dan M. Beale, "Neural Network Toolbox For Use With MATLAB", The MathWorks, 2002.