

SEMINAR HASIL TUGAS AKHIR

Pemodelan Produksi Minyak dan Gas Bumi
Pada *Platform* “MK” di PT “X”
Menggunakan Metode *ARIMA*, *Neural
Network*, dan Hibrida *ARIMA-NN*

Windia Cinde Prameswari - 1314 105 010

Pembimbing

Dra. Destri Susilaningrum, M.Si

Dr. Suhartono, M.Sc

Sumber daya alam yang tidak dapat diperbaharui adalah sumber daya alam yang sangat sulit dihasilkan kembali setelah habis digunakan

Salah satu contoh dari sumber daya alam yang tidak dapat diperbaharui adalah minyak dan gas bumi



Campuran senyawa hidrokarbon yang tersusun dari sebagian besar karbon dan hidrogen dengan sedikit belerang, nitrogen, dan unsur-unsur lainnya.

Diduga secara tidak langsung berasal dari sisa-sisa organisme hidup

Di Indonesia cadangan minyak bumi yang tersisa sebanyak 3,7 miliar barel, konsumsi minyak dunia per harinya sebesar 1.084.000 barel. Diperkirakan akan habis 10-11 tahun mendatang

Minyak dan Gas Bumi

Banyak kandungan lain di dasar bumi yang ikut terambil melalui sumur yang dibangun, salah satunya adalah gas bumi

Hal yang penting dilakukan untuk mengambil minyak bumi adalah pengeboran sumur

Minyak bumi akan diproses dan dipisahkan hasilnya berdasarkan titik didih

Kedalaman, tekanan sumur, dan siklus hidup sumur penting diperhatikan untuk mendapatkan minyak bumi yang optimal



Hal yang harus dilakukan adalah memberikan *treatment* terhadap sumur tersebut



Dalam melakukan *treatment*, terdapat persiapan khusus sebelumnya dari perusahaan

Agar perusahaan dapat merencanakan dilakukan *treatment* pada sumur tersebut, maka perlu diketahui jumlah produksi minyak bumi untuk waktu selanjutnya

Ada saatnya sumur mulai melemah untuk menyedot kandungan minyak



Penelitian ini diharapkan dapat membantu perusahaan menganalisis jumlah produksi minyak dan gas bumi di waktu yang akan datang, sehingga dapat diketahui waktu yang tepat untuk melakukan *treatment* terhadap sumur ketika jumlah produksi minyak mulai turun

Sumur yang berada pada wilayah yang berdekatan dikelompokkan menjadi 1 *platform*

Dari beberapa *platform* yang berdekatan, minyak bumi selanjutnya dikirim ke terminal pusat

Penelitian ini menggunakan data jumlah produksi minyak dan gas bumi yang berasal dari sumur-sumur di *platform* "MK"

ARIMA

Neural Network

Hibrida ARIMA-NN

Penelitian Sebelumnya

Adnyana (2013)

Penerapan Bootstrap Pada Neural Network untuk Peramalan Produksi Minyak Mentah di Indonesia

Penelitian tersebut meramalkan produksi minyak mentah dengan membandingkan metode ARIMA, neural network, dan neural network dengan bootstrap

Hasil yang diperoleh adalah model yang paling baik menggambarkan data dan berdasarkan nilai MSE yaitu model neural network sederhana

Kusumaningrum (2012)

Peramalan Kebutuhan Bahan Bakar Premium di Depot Ampenan Dengan Metode Hibrida ARIMA – NN Untuk Optimasi Persediaan

Penelitian tersebut membandingkan antara model ARIMA – NN dengan model hibrida ARIMA – NN

Hasil yang diperoleh dari penelitian tersebut adalah model hibrida menghasilkan hasil peramalan yang lebih akurat dibandingkan model tunggal


Permasalahan dan Tujuan Penelitian

Karakteristik produksi minyak dan gas bumi pada *platform* “MK” di PT “X”


Membandingkan metode ARIMA, neural network, dan hibrida ARIMA-NN

Memodelkan jumlah produksi minyak dan gas bumi pada *platform* “MK” di PT “X”

Manfaat Penelitian



Dapat mengaplikasikan ilmu statistika terhadap kehidupan sehari-hari, khususnya dalam bidang perminyakan



Memberikan informasi mengenai jumlah produksi minyak dan gas bumi yang akan datang, sehingga perusahaan dapat membuat kebijakan baru untuk mengantisipasi ketika jumlah produksi minyak mengalami penurunan

Tinjauan Pustaka

Statistika Deskriptif

Statistika deskriptif adalah metode-metode yang berkaitan dengan pengumpulan dan penyajian suatu gugus data, sehingga memberikan informasi yang berguna (Walpole, 1995).

Time Series

Urutan observasi yang berdasarkan pada interval waktu, dengan tujuan untuk memahami dan memberikan gambaran dalam membuat suatu mekanisme, peramalan nilai masa depan dan optimalisasi sistem kontrol (Wei, 2006).

Stasioneritas $\begin{cases} \text{Mean} \\ \text{Varians} \end{cases}$

Identifikasi Model

Model	ACF	PACF
AR (p)	Dies Down	Cuts for after lag p
MA (q)	Cuts for after lag q	Dies Down
ARMA (p,q)	Dies down	Dies Down

Signifikansi Parameter

Hipotesis :

$H_0 : \beta = 0$ (parameter tidak signifikan dalam model)

$H_1 : \beta \neq 0$ (parameter signifikan dalam model)

$$t = \frac{\hat{\beta}}{SE(\hat{\beta})}$$

Uji Kesesuaian Model

$\begin{cases} \text{White Noise} \\ \text{Berdistribusi Normal} \end{cases}$

Pemilihan Model Terbaik

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (z_t - \hat{z}_t)^2}{n}}$$

ARIMA

ACF


$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (z_t - \bar{z})(z_{t+k} - \bar{z})}{\sum_{t=1}^n (z_t - \bar{z})^2}, k = 0, 1, 2, \dots$$

PACF

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}$$

Metode ini menggunakan elemen perhitungan non-linier dasar yang disebut neuron yang diorganisasikan sebagai jaringan yang saling berhubungan

Kelebihan model ini adalah dapat mengaproksimasi suatu data yang berkelas besar dengan derajat akurasi yang besar dan tidak ada asumsi tertentu



Neural Network

Lapisan Penyusun

Lapisan *input*

Lapisan tersembunyi (*hidden layer*)

Lapisan *output*

Hubungan *Input* dan *Output*

$$Z_t = w_0 + \sum_{j=1}^q w_j f(w_{0j} + \sum_{i=1}^p w_{ij} Z_{t-i}) + \varepsilon_t$$

Fungsi aktivasi

$$f(x) = \frac{1}{1 + e^{-x}}$$

Hibrida adalah kombinasi dua atau lebih sistem dalam satu fungsi. Hibrida diharapkan dapat saling melengkapi karena dalam dunia nyata jarang ditemukan kejadian *time series* yang murni linier ataupun murni non-linier

Langkah pertama adalah menentukan model ARIMA dari parameter. Selanjutnya residual dari model ARIMA dimodelkan dengan NN. Kemudian yang terakhir adalah menggabungkan kedua model yaitu model ARIMA dan model NN

Model residual ARIMA

$$e_t = y_t + \hat{L}_t$$

Gabungan Model ARIMA - NN

$$y_t = L_t + N_t$$

Sumber Data

Data harian jumlah produksi minyak dan gas bumi selama tahun 2015 yang berasal pada platform "MK" di PT "X"

Langkah Analisis

Variabel Penelitian

Mendeskripsikan data jumlah produksi minyak bumi di platform "MK"

Membagi data time series menjadi data in sample dan out sample

Memodelkan data menggunakan metode ARIMA, neural network, dan hibrida ARIMA-NN

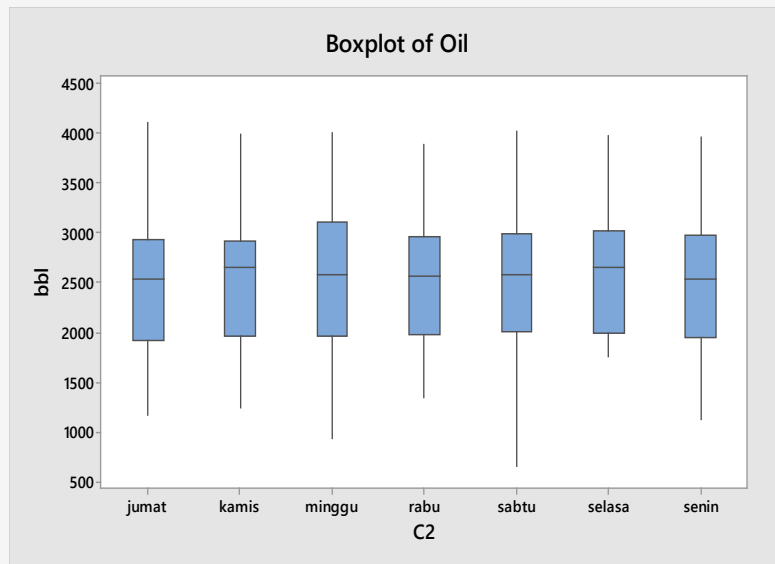
Membandingkan model ARIMA, neural network, dan hibrida ARIMA-NN berdasarkan nilai RMSE

Tanggal	Hari	Jumlah Minyak	Jumlah Gas
01/01/2015	Kamis	$Z_{1.1}$	$Z_{1.2}$
02/01/2015	Jumat	$Z_{2.1}$	$Z_{2.2}$
03/01/2015	Sabtu	$Z_{3.1}$	$Z_{3.2}$
⋮	⋮	⋮	⋮
31/12/2015	Kamis	$Z_{365.1}$	$Z_{365.2}$

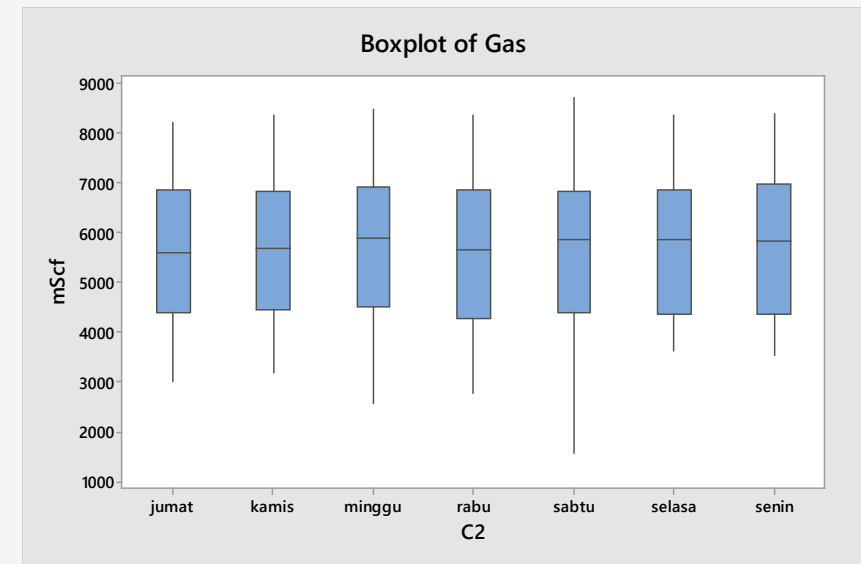
Meramalkan jumlah produksi minyak dan gas bumi di platform "MK" menggunakan model terbaik

Karakteristik Produksi Minyak dan Gas Bumi

Variabel	Minyak Bumi	Gas Bumi
Rata-rata	2555,6	5704,1
Maximum	4107,0	8718,0
Minimum	649,5	1577,0
Varians	421576,8	2197042,9
Median	2587,6	5790,0




Rata-rata jumlah produksi minyak dan gas bumi setiap hari tidak jauh berbeda selama tahun 2015




Pemodelan Produksi Minyak Bumi


ARIMA



Belum
Stasioner
dalam mean,
lagu 1
differencing



ARIMA (0,1,1)
ARIMA (0,1,2)



Sudah stasioner dalam varians

Signifikansi Parameter

Model	Parameter	Koefisien	P-Value	Keterangan
ARIMA (0,1,1)	θ_1	0,0468	0,000	Signifikan
ARIMA (0,1,2)	θ_1	0,3929	0,000	Signifikan
	θ_2	0,1853	0,000	Signifikan

Deteksi *Outlier* ARIMA (0,1,1)

White Noise	P-Value	Keterangan
Lag 6	0,1068	White Noise
Lag 12	0,5276	White Noise
Lag 18	0,1745	White Noise
Lag 24	0,1835	White Noise
Lag 30	0,2409	White Noise
Lag 36	0,2155	White Noise
Lag 42	0,3781	White Noise
Lag 48	0,5853	White Noise
Distribusi Normal	0,0221	Tidak Normal

Kesesuaian Model

Model	White Noise (P-value)				Distribusi Normal
	12	24	36	48	
ARIMA (0,1,1)	0,021	0,315	0,567	0,559	<0,010
ARIMA (0,1,2)	0,402	0,879	0,948	0,937	<0,010

Deteksi *Outlier* ARIMA (0,1,2)

White Noise	P-Value	Keterangan
Lag 6	0,6432	White Noise
Lag 12	0,8255	White Noise
Lag 18	0,9104	White Noise
Lag 24	0,9012	White Noise
Lag 30	0,9332	White Noise
Lag 36	0,9025	White Noise
Lag 42	0,8328	White Noise
Lag 48	0,924	White Noise
Distribusi Normal	0,1023	Normal

Pemilihan Model Terbaik

Out sample		In sample	
Model	RMSE	Model	RMSE
ARIMA (0,1,1)	61,48	ARIMA (0,1,1)	65,50
ARIMA (0,1,2)	48,92	ARIMA (0,1,2)	71,47

Model yang Terbentuk

$$\begin{aligned}
 Z_t = & Z_{t-1} - 0,19187a_{t-1} - 0,59695a_{t-2} + a_t - 1,436.6I_{a,t}^{107} - 1188,3I_{a,t}^{42} \\
 & - 1223,5I_{a,t}^{339} - 991,3I_{a,t}^{242} - 923,2I_{a,t}^{157} + 793,9I_{s,t}^{52} - 731,0I_{s,t}^{332} \\
 & + 1563,1I_{a,t}^{284} + 1240,8I_{a,t}^{283} + 804,1I_{s,t}^{293} - 617,3I_{a,t}^{281} - 559,3I_{a,t}^{280} \\
 & + 1370,1I_{s,t}^{318} - 516,5I_{s,t}^{280} + 568,8I_{s,t}^{307} + 426,0I_{a,t}^{62} + 298,0I_{a,t}^{300} \\
 & - 377,7I_{s,t}^{329} - 433,6I_{s,t}^{316} - 340,6I_{s,t}^{106} + 764,7I_{s,t}^{53} - 675,8I_{a,t}^{285} \\
 & + 409,4I_{a,t}^{43} + 301,4I_{a,t}^{304} - 363,7I_{s,t}^{88} + 346,6I_{s,t}^{122} - 295,1I_{a,t}^{324} \\
 & + 283,6I_{a,t}^{86} - 268,2I_{a,t}^{70} - 248,5I_{a,t}^{131} - 327,0I_{s,t}^{292} + 261,4I_{a,t}^{236} \\
 & + 208,1I_{a,t}^{223} - 671,1I_{a,t}^{318} - 284,5I_{s,t}^{317} - 344,7I_{s,t}^{331} - 253,0I_{a,t}^{177} \\
 & + 222,2I_{a,t}^{109} - 179,2I_{a,t}^{58} - 260,3I_{s,t}^{103} - 294,6I_{s,t}^{312} - 373,0I_{s,t}^{180} \\
 & + 208,8I_{s,t}^{326} + 180,8I_{s,t}^{114} - 188,6I_{s,t}^{164} - 242,3I_{s,t}^{85} - 153,7I_{a,t}^{75} \\
 & + 458,2I_{a,t}^{274} - 467,0I_{s,t}^{51} + 368,6I_{s,t}^{273} - 320,7I_{s,t}^{184} + 247,8I_{a,t}^{54} \\
 & - 199,0I_{s,t}^{141} - 294,6I_{a,t}^{319} - 694,9I_{a,t}^{64} + 327,3I_{s,t}^{64} - 131,3I_{s,t}^{161}
 \end{aligned}$$

Neural Network

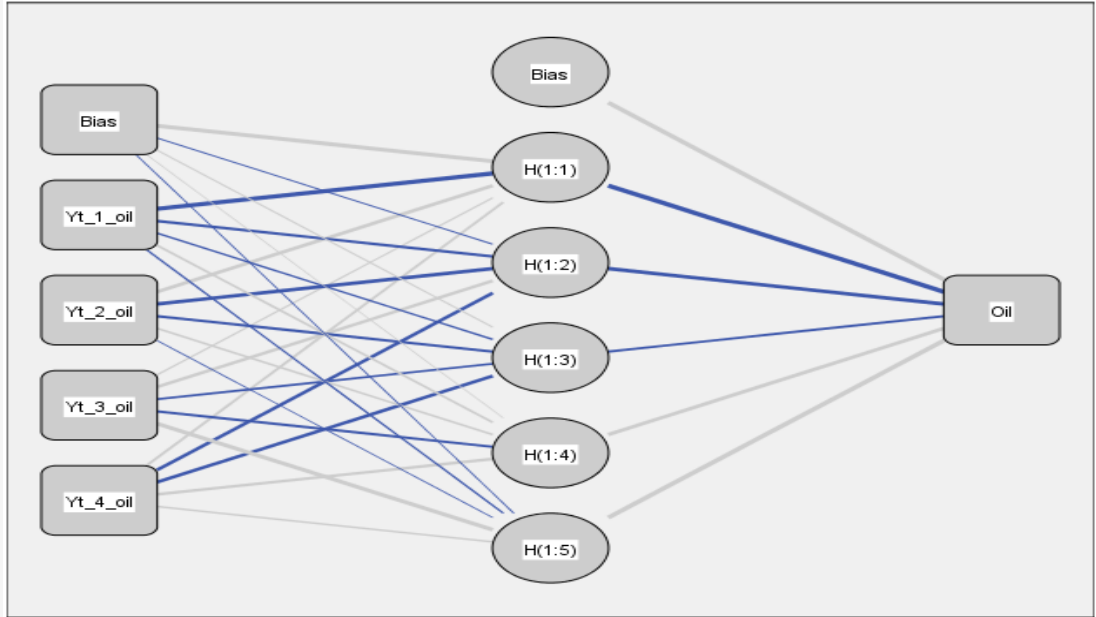
Jumlah Neuron	RMSE In sample	RMSE Out sample
1	278,4082	94,83983
2	265,4629	86,56403
3	270,5493	92,77158
4	264,4966	124,6386
5	271,8982	70,83726
6	257,217	111,2526
7	254,8293	171,2617
8	243,5046	134,5891
9	276,5005	96,2848
10	274,8766	87,45966

$$\hat{Z}_t = 0,995 - 2,266H(1,1)_t - 0,544H(1,2)_t - 0,289H(1,3)_t + 0,481H(1,4)_t + 1,356H(1,5)_t$$

$$H(1,1)_t = \frac{1}{1 + \exp - (0,802 - 1,933Z_{t-1} + 0,449Z_{t-2} + 0,116Z_{t-3} + 0,237Z_{t-4})}$$

$$H(1,2)_t = \frac{1}{1 + \exp - (-0,096 - 0,353Z_{t-1} - 0,483Z_{t-2} + 0,370Z_{t-3} - 0,378Z_{t-4})}$$

$$H(1,3)_t = \frac{1}{1 + \exp - (0,101 - 0,179Z_{t-1} - 0,311Z_{t-2} - 0,226Z_{t-3} - 0,443Z_{t-4})}$$



$$H(1,4)_t = \frac{1}{1 + \exp - (0,017 + 0,225Z_{t-1} + 0,222Z_{t-2} - 0,296Z_{t-3} + 0,359Z_{t-4})}$$

$$H(1,5)_t = \frac{1}{1 + \exp - (-0,090 - 0,137Z_{t-1} - 0,047Z_{t-2} + 0,646Z_{t-3} + 0,190Z_{t-4})}$$

Hibrida ARIMA-NN

Jumlah Neuron	RMSE In sample	RMSE Out sample
1	71,55113	47,0244
2	71,56442	46,88192
3	71,50716	47,42676
4	71,424848	47,37643
5	71,38143	47,0355
6	71,44538	47,41358
7	71,47045	46,81031
8	71,43854	47,19942
9	65,54002	51,88179
10	66,66538	46,10634

$$\hat{N}_t = -0,164 + 1,768H(1,1)_t - 0,859H(1,2)_t + 0,499H(1,3)_t - 1,198H(1,4)_t \\ + 1,697H(1,5)_t + 1,097H(1,6)_t - 0,041H(1,7)_t - 1,225H(1,8)_t \\ + 0,241H(1,9)_t - 1,525H(1,10)_t$$

$$H(1,1)_t = \frac{1}{1 + \exp(-1,724 - 2,857N_{t-1} - 1,959N_{t-2} + 2,585N_{t-3} + 3,042N_{t-4})}$$

$$H(1,2)_t = \frac{1}{1 + \exp(-0,444 - 0,245N_{t-1} - 0,150N_{t-2} + 0,443N_{t-3} + 0,205N_{t-4})}$$

$$H(1,3)_t = \frac{1}{1 + \exp(-0,431 - 0,849N_{t-1} + 0,022N_{t-2} - 0,047N_{t-3} + 1,751N_{t-4})}$$

$$H(1,4)_t = \frac{1}{1 + \exp(-0,748 + 2,096N_{t-1} + 0,416N_{t-2} + 0,222N_{t-3} + 0,528N_{t-4})}$$

$$H(1,5)_t = \frac{1}{1 + \exp(-1,660 + 1,487N_{t-1} + 1,666N_{t-2} - 0,429N_{t-3} - 1,052N_{t-4})}$$

$$H(1,6)_t = \frac{1}{1 + \exp(-0,744 - 0,612N_{t-1} - 1,514N_{t-2} + 1,686N_{t-3} - 2,368N_{t-4})}$$

$$H(1,7)_t = \frac{1}{1 + \exp(-0,207 - 0,404N_{t-1} - 0,169N_{t-2} + 0,502N_{t-3} + 0,644N_{t-4})}$$

$$H(1,8)_t = \frac{1}{1 + \exp(-0,833 - 1,236N_{t-1} - 0,893N_{t-2} + 1,016N_{t-3} + 0,617N_{t-4})}$$

$$H(1,9)_t = \frac{1}{1 + \exp(-0,207 - 0,266N_{t-1} - 0,347N_{t-2} - 0,024N_{t-3} - 0,211N_{t-4})}$$

$$H(1,10)_t = \frac{1}{1 + \exp(-1,782 - 1,321N_{t-1} + 0,078N_{t-2} + 0,479N_{t-3} - 1,192N_{t-4})}$$

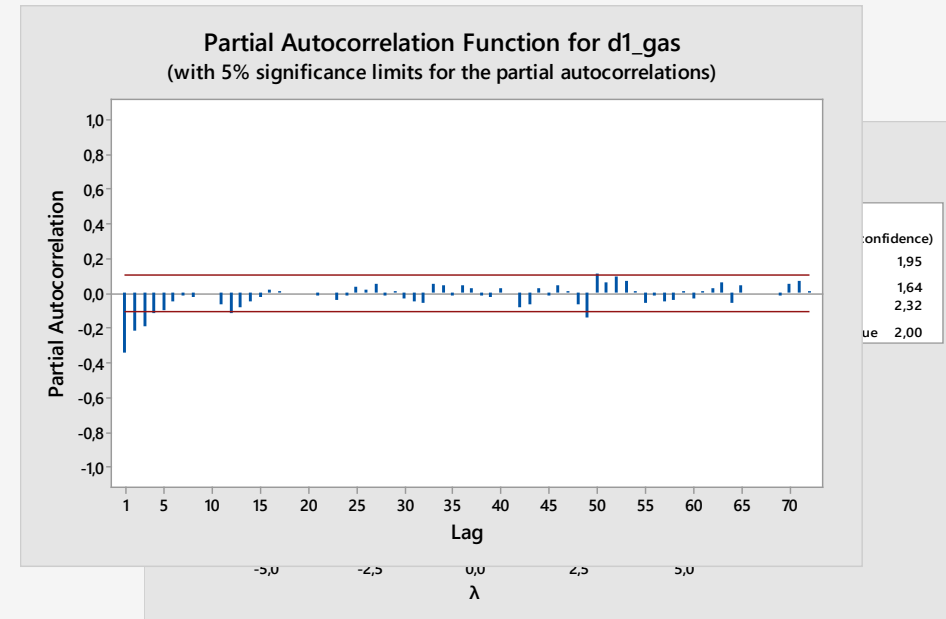

Perbandingan Metode dan Hasil Ramalan

Metode	RMSE In sample	RMSE Out sample
ARIMA	71,47089	48,91872
NN	271,8982	70,83726
Hibrida	66,66538	46,10634

Hari	Ramalan	Hari	Ramalan
01/01/2016	2005,646	08/01/2016	1960,864
02/01/2016	1961,947	09/01/2016	1960,852
03/01/2016	1961,826	10/01/2016	1960,852
04/01/2016	1960,472	11/01/2016	1960,855
05/01/2016	1960,892	12/01/2016	1960,853
06/01/2016	1960,872	13/01/2016	1960,854
07/01/2016	1960,817	14/01/2016	1960,854

Pemodelan Produksi Gas Bumi

ARIMA



Belum stasioner dalam mean, ARIMA (0,1,1)
Perlu 1 differencing ARIMA (1,1,1) Sudah stasioner dalam varians
ARIMA (2,1,1)
ARIMA (3,1,1)

Signifikansi Parameter

Model	Parameter	Estimasi	P-Value	Keterangan	
ARIMA (0,1,1)	θ_1	0,56783	<0,0001	Signifikan	
ARIMA (1,1,1)	φ_1	0,27275	0,0012	Signifikan	
	θ_1	0,76141	<0,0001	Signifikan	
ARIMA (2,1,1)	φ_1	0,28564	0,0016	Signifikan	
	φ_2	0,01870	0,7898	Tidak	
	θ_1	0,77679	<0,0001	Signifikan	
ARIMA (3,1,1)	White Noise	φ_1	0,27071	0,0137	Signifikan
	Lag 6	φ_2	0,1295	0,01254	Signifikan
	Lag 12	φ_3	0,1103	0,01160	Signifikan
	Lag 18	θ_1	0,2716	0,00177	Signifikan
	Lag 30		0,2060		Signifikan
	Lag 24		0,3521		Signifikan
	Lag 36		0,3370		Signifikan
	Lag 42		0,4001		Signifikan
	Lag 48		0,3546		Signifikan
	Distribusi Normal		0,0918		Normal

Deteksi Outlier
ARIMA (0,1,1)

Kesesuaian Model

White Noise	ARIMA (0,1,1)	ARIMA (1,1,1)
Lag 6	0,1305	0,9539
Lag 12	0,1184	0,7385
Lag 18	0,3244	0,9490
Lag 24	0,6574	0,9942
Lag 30	0,8018	0,9984
Lag 36	0,8411	0,9987
Lag 42	0,8697	0,9990
Lag 48	0,9372	0,9997
Keterangan	White Noise	White Noise
Distribusi Normal	<0,0001	<0,0001
Lag 18	0,2481	Signifikan
Lag 24	0,3573	Signifikan
Lag 30	0,1674	Signifikan
Lag 36	0,2640	Signifikan
Lag 42	0,2876	Signifikan
Lag 48	0,1421	Signifikan
Distribusi Normal	0,0940	Normal

Deteksi Outlier
ARIMA (1,1,1)

Pemilihan Model Terbaik


Model	Out Sample	In Sample
ARIMA (0,1,1)	198,2455	181,772
ARIMA (1,1,1)	195,5305	167,7969

Model yang Terbentuk

$$\begin{aligned} \hat{Z}_t = & Z_{t-1} + 0,41492Z_{t-1} + 0,41492Z_{t-2} - 0,88073a_{t-1} + a_t - 2992,3I_{a,t}^{107} \\ & - 3105,3I_{a,t}^{42} - 2804,6I_{a,t}^{339} - 1877,4I_{a,t}^{281} - 1627,3I_{a,t}^{280} - 1526,5I_{a,t}^{242} \\ & - 928,8I_{a,t}^{117} - 929,1I_{a,t}^{312} - 742,1I_{a,t}^{114} - 689,7I_{a,t}^{315} - 470,3I_{a,t}^{182} + 1346,5I_{s,t}^{274} \\ & + 1598,2I_{s,t}^{52} - 1559,1I_{s,t}^{55} + 1109,3I_{s,t}^{114} - 1321,5I_{s,t}^{32} - 1541,2I_{s,t}^{316} \\ & + 1051,2I_{s,t}^{109} - 978,7I_{s,t}^{196} + 688,4I_{s,t}^{320} - 887,2I_{s,t}^{285} - 959,9I_{s,t}^{331} + 597,1I_{s,t}^{294} \\ & + 741,9I_{s,t}^{325} + 1041,2I_{s,t}^{307} - 671,1I_{s,t}^{190} - 529,4I_{s,t}^{105} + 457,0I_{s,t}^{65} - 505,3I_{s,t}^{155} \\ & - 481,9I_{s,t}^{222} + 398,0I_{s,t}^{10} - 605,9I_{a,t}^{210} + 717,9I_{a,t}^{261} + 426,9I_{a,t}^{32} + 630,9I_{a,t}^{262} \\ & - 415,7I_{a,t}^{314} + 773,9I_{a,t}^{49} - 4659,0I_{a,t}^{157} - 615,7I_{a,t}^{166} + 799,5I_{a,t}^{300} + 646,1I_{a,t}^{304} \\ & + 433,3I_{a,t}^{115} + 471,1I_{a,t}^{301} - 747,3I_{s,t}^{159} + 515,0I_{s,t}^{185} + 391,9I_{s,t}^{333} - 400,2I_{s,t}^{188} \\ & - 628,5I_{a,t}^{61} + 454,5I_{s,t}^{59} - 464,5I_{s,t}^{310} - 353,9I_{s,t}^{171} + 382,2I_{a,t}^{275} \end{aligned}$$

Jumlah Neuron	RMSE In sample	RMSE Out sample
1	582,9493	192,7433
2	584,4298	190,8954
3	531,9169	268,2365
4	531,0319	261,5619
5	531,521	294,2941
6	525,9528	216,2174
7	525,0536	340,4683
8	528,0992	284,0333
9	524,9976	282,872
10	539,7337	197,3947

Neural Network



$$\hat{Z}_t = 0,344 + 1,743H(1,1)_t - 1,860H(1,2)_t$$

$$H(1,1)_t = \frac{1}{1 + \exp - (-0,408 + 1,137Z_{t-1} + 0,104Z_{t-2})}$$

$$H(1,2)_t = \frac{1}{1 + \exp - (0,462 - 1,083Z_{t-1} - 0,254Z_{t-2})}$$

Jumlah Neuron	RMSE In sample	RMSE Out sample
1	167,291	195,4128
2	167,114	195,4707
3	167,2037	195,4614
4	167,0955	195,6242
5	167,0705	195,7543
6	167,0881	195,6049
7	167,0786	195,5291
8	167,0291	195,746
9	167,0462	195,5653
10	167,0485	195,5989

Hibrida ARIMA-NN

$$\hat{N}_t = 1,843 - 3,152H(1,1)_t$$

$$H(1,1)_t = \frac{1}{1 + \exp - (0,525 - 1,536N_{t-1} - 0,052N_{t-2})}$$

Perbandingan Metode dan Hasil Ramalan

Metode	RMSE In sample	RMSE Out sample
ARIMA	167,7969	195,5305
NN	584,4198	190,8954
Hibrida	167,291	195,4128

Hari	Ramalan	Hari	Ramalan
01/01/2016	4307,41	08/01/2016	4395,976
02/01/2016	4330,388	09/01/2016	4399,163
03/01/2016	4352,917	10/01/2016	4401,516
04/01/2016	4366,928	11/01/2016	4403,264
05/01/2016	4378,023	12/01/2016	4404,56
06/01/2016	4385,823	13/01/2016	4405,523
07/01/2016	4391,693	14/01/2016	4406,239

Kesimpulan dan Saran

Rata-rata jumlah produksi minyak dan gas bumi setiap hari hampir sama selama tahun 2015, dan terdapat beberapa jumlah produksi yang turun drastis diduga penyebabnya adalah perbaikan sumur

Berdasarkan hasil dari perbandingan ketiga metode pada pemodelan jumlah produksi minyak dan gas bumi, disimpulkan bahwa pada pemodelan produksi minyak bumi metode hibrida ARIMA-NN paling baik. Sedangkan pada pemodelan produksi gas bumi metode yang paling baik adalah metode NN tunggal. Sehingga dapat disimpulkan bahwa metode yang lebih baik belum tentu menghasilkan model yang lebih baik juga

Pihak perusahaan tidak perlu melakukan *treatment* pada sumur di *platform* "MK" selama tanggal 1-14 Januari 2016, karena produksi minyak dan gas bumi cenderung naik perlahan

SEMINAR HASIL PROPOSAL TUGAS AKHIR

Pemodelan Produksi Minyak dan Gas Bumi
Pada *Platform* “MK” di PT “X”
Menggunakan Metode *ARIMA*, *Neural Network*, dan Hibrida *ARIMA-NN*

Windia Cinde Prameswari - 1314 105 010

Pembimbing

Dra. Destri Susilaningrum, M.Si

Dr. Suhartono, M.Sc