

**PREDIKSI RECOVERY FACTOR INJEKSI SURFACTANT
HUFF AND PUFF MENGGUNAKAN ARTIFICIAL NEURAL
NETWORKS PADA SUMUR MINYAK DENGAN KADAR
PARAFFIN TINGGI**

TUGAS AKHIR

Diajukan guna melengkapi syarat dalam mencapai gelar Sarjana Teknik

Oleh

A HABIB AL UMAM

NPM 153210340



PROGRAM STUDI TEKNIK PERMINYAKAN

UNIVERSITAS ISLAM RIAU

PEKANBARU

2020

KATA PENGANTAR

Rasa syukur saya ucapkan kepada Allah SWT berkat rahmat dan karunia-Nya sehingga penulis bisa diberikan kesempatan untuk menyelesaikan tugas akhir ini. Penulisan tugas akhir ini merupakan syarat terakhir untuk mendapatkan gelar Sarjana Teknik, Program Studi Perminyakan, Universitas Islam Riau. Banyak pihak yang telah membantu penulis dalam bentuk pengetahuan, materil maupun moral penulis dalam penyelesaian tugas akhir ini. Oleh sebab itu penulis ingin mengucapkan terimakasih sebesar-besarnya kepada:

1. Kedua orang tua, Papa dan Almarhumah Mama yang telah memberikan dukungan moral, material, dan doa yang senantiasa mengiringi penulis,
2. Bapak Fiki Hidayat, S.T., M.Eng atau sering disapa dengan Mas Fiki selaku dosen pembimbing dalam penulisan tugas akhir ini yang telah meluangkan banyak waktu, tenaga dan pikiran sehingga tugas akhir ini bisa selesai,
3. Bapak H. Ali Musnal, S.T, M.T., selaku pembimbing akademik yang telah memberi arahan dan nasihat selama perkuliahan di Teknik Perminyakan,
4. Ketua dan Sekretaris Program Studi Perminyakan serta dosen-dosen lainnya yang belum bisa saya sebutkan satu persatu dalam tugas akhir ini, yang telah membantu dan mengajari penulis selama masa perkuliahan,
5. Laboratorium Teknik Perminyakan, khususnya laboratorium simulasi reservoir,
6. Sahabat dan yang terkasih: Fajar, Annisa, Syukri, Azril, Dini, Dani, Clara, Muspita, Putri, Daebak Class dan juga teman-teman lainnya di kampus yang tidak bisa disebutkan satu persatu.

Teriring do'a semoga Allah SWT memberi balasan atas segala kebaikan semua pihak yang telah membantu. Semoga tugas akhir ini membawa manfaat bagi pengembangan ilmu pengetahuan.

Pekanbaru, 21 September 2020

A Habib Al Umam

DAFTAR ISI

HALAMAN PENGESAHAN.....	ii
PERNYATAAN KEASLIAN TUGAS AKHIR	iii
KATA PENGANTAR.....	iv
DAFTAR ISI.....	v
DAFTAR GAMBAR.....	vi
DAFTAR TABEL	vii
DAFTAR LAMPIRAN	viii
ABSTRAK	ix
ABSTRACT	x
BAB I PENDAHULUAN.....	1
1.1 LATAR BELAKANG	1
1.2 TUJUAN PENELITIAN.....	2
1.3 MANFAAT PENELITIAN	2
1.4 BATASAN MASALAH	2
BAB II TINJAUAN PUSTAKA.....	3
BAB III METODOLOGI PENELITIAN	6
3.1 PEMODELAN SIMULASI.....	6
3.1.1 Reservoir Properties	6
3.1.2 Hydrocarbon Component.....	8
3.1.3 Pembuatan <i>Grid</i>	8
3.1.4 Inisialisasi	9
3.2 DIAGRAM ALIR PENELITIAN.....	10
3.3 ARTIFICIAL NEURAL NETWORKS	10
3.4 JENIS PENELITIAN	12
3.5 TEMPAT PENELITIAN.....	12
3.7 DATA ACUAN PENELITIAN	13
BAB IV HASIL DAN PEMBAHASAN	14
BAB V PENUTUP.....	19
5.1 KESIMPULAN	19
5.2 SARAN.....	19
DAFTAR PUSTAKA.....	20
LAMPIRAN.....	24

DAFTAR GAMBAR

Gambar 3.1 Grafik hubungan antara <i>relative permeability</i> dan <i>water saturation</i> (Rahmadina, 2018).....	7
Gambar 3.2 Model konseptual <i>radial grid</i> sumur H	9
Gambar 3.3 Diagram alir penelitian	10
Gambar 4.1 Struktur 11 <i>nodes hidden layer</i> ANN dengan aktivasi sigmoid	16
Gambar 4.2 <i>Coefficient of determination</i> (R^2) antara nilai RF Aktual dan RF Prediksi 400 data <i>training</i> dengan 11 <i>nodes hidden layer</i>	16
Gambar 4.3 <i>Coefficient of determination</i> (R^2) antara nilai RF Aktual dan RF Prediksi 100 data <i>testing</i> dengan 11 <i>nodes hidden layer</i>	17

DAFTAR TABEL

Tabel 2.1 Parameter yang mempengaruhi <i>surfactant huff n puff</i>	5
Tabel 2.2 Perkembangan penggunaan ANN terhadap RF.....	5
Tabel 3.1 Data <i>reservoir properties</i>	6
Tabel 3.2 Perbandingan IFT dan konsentrasi surfaktan	7
Tabel 3.3 <i>Hydrocarbon component</i>	8
Tabel 3.4 <i>Model properties</i>	9
Tabel 3.5 Hasil inisialisasi simulasi	9
Tabel 3.6 Waktu penelitian	13
Tabel 3.7 Data masing-masing parameter.....	13
Tabel 4.1 Nilai <i>Mean Square Error</i> (MSE) dan <i>coefficient correlation</i> (R) pada jumlah <i>nodes hidden layer</i> yang berbeda dengan menggunakan 500 data	15
Tabel 4.2 Hasil MSE, RMSE, R, R ² dan adjusted R ²	17

DAFTAR LAMPIRAN

Lampiran 1. Hasil <i>run</i> , prediksi dan perhitungan error 500 data sampel.....	24
Lampiran 2. <i>Coding</i> yang digunakan.....	37



A HABIB AL UMAM
153210340

ABSTRAK

Improved Oil Recovery (IOR) adalah pembaharuan metode *Enhanced Oil Recovery (EOR)* untuk meningkatkan perolehan minyak dan menghambat penurunan produksi secara drastis dari sumur yang memiliki minyak dengan viskositas tinggi. Salah satu metode IOR yang efektif untuk digunakan di dalam sumur ini adalah dengan menggunakan metode *surfactant soaking*, yaitu penginjeksian surfaktan sebagai *chemical* dan melakukan metode perendaman atau *huff and puff* pada suatu sumur. Dengan 7 parameter yaitu konsentrasi surfaktan, volume surfaktan, berat mol surfaktan, *soaking time*, *number of cycles*, *injection rate* dan *production rate* maka akan dilakukan penelitian untuk memprediksi nilai *recovery factor* (RF) dengan metode *artificial neural networks* (ANN). Metode ANN ini merupakan salah satu metode *deep learning* dari data input dan menghasilkan data output. Dengan menggunakan 500 data dengan rasio 80% dari hasil model perhitungan RF dari *software* CMG untuk *di-training* dan 20% dari hasil model untuk *di-testing*. Supaya mendapatkan hasil prediksi dari RF menggunakan metode ANN secara optimal maka akan dilakukan *trial and error* pada jumlah *nodes hidden layer*. Didapatlah *nodes hidden layer* yang optimal dan stabil pada *nodes* 11 dengan nilai MAE 0,293 dan MAPE 1,42%, lalu nilai MSE dan RMSE pada data *training* bernilai 0,1260; 0,3550 dan pada data *testing* 0,3485; 0,5903. Nilai analisis statistik lainnya seperti R, R^2 , *adjusted* R^2 secara berurutan yaitu 0,9742; 0,9491; 0,9489 untuk data *training* dan 0,9528; 0,9077; 0,9068 untuk data *testing*. Dapat disimpulkan pada penelitian ini bahwa penggunaan ANN dalam prediksi RF menggunakan 11 *nodes hidden layer* terbukti sangat bagus dan berhasil.

Kata Kunci: IOR, surfaktan, *huff and puff*, *paraffin*, *artificial neural networks*

A HABIB AL UMAM

153210340

ABSTRACT

Improved Oil Recovery (IOR) is a renewed Enhanced Oil Recovery (EOR) to increase oil recovery and inhibit a drastic production reduction from oil wells with high viscosity. One of IOR methods to be used in this is surfactant soaking method, which is injecting surfactants as a chemical and conducting a soaking or huff and puff on a well. Using 7 parameters, surfactant concentration, surfactant volume, surfactant mole weight, soaking time, number of cycles, injection rate and production rate, research will be carried out to predict the recovery factor (RF) value using the artificial neural networks (ANN) method. This ANN method is a deep learning method from input data and produces output data. By using 500 data with a ratio of 80% of the results of the RF calculation model from the CMG software for training and 20% of the results of the model for testing. In order to get optimal prediction results from RF using the ANN method, trial and error will be used on determining the number of hidden layer nodes. The optimal and stable hidden layer nodes are obtained at nodes 11 with value of MAE 0.293 and MAPE 1.42%, then the MSE and RMSE values in the training data are 0.1260; 0.3550 and the testing data are 0.3485; 0.5903. Other statistical analysis values such as R, R^2 , adjusted R^2 are 0.9742; 0.9491; 0.9489 for training data and 0.9528; 0.9077; 0.9068 for testing data. The conclusion from this research using ANN to predict RF using 11 nodes of hidden layer is proven successful and very good.

Keywords: IOR, surfactant, huff and puff, paraffin, artificial neural networks

BAB I PENDAHULUAN

1.1 LATAR BELAKANG

Terdapat beberapa risiko yang akan timbul saat mengalirkan fluida berfasa ganda, salah satunya adalah *paraffin/wax deposition*. Ketika adanya perubahan temperatur yang drastis hingga melewati *cloud point* minyak mentah, maka yang akan terjadi adalah pengendapan *wax* (Al-Yaari, 2013). Pengendapan ini bisa mengakibatkan penyumbatan pipa atau merusak peralatan, dan menghabiskan biaya yang besar untuk melakukan perbaikan (Bacon, Romero-Zerón, & Chong, 2010).

Penggunaan surfaktan dalam injeksi *chemical* adalah untuk menurunkan *interfacial tension* (IFT) dan dapat berfungsi juga untuk mengubah *wettability* (Sheng, 2015). Surfaktan yang sangat umum digunakan dalam EOR adalah surfaktan anionik, dikarenakan mereka memiliki tingkat adsorpsi paling rendah pada batuan sandstone yang memiliki ion negatif (Putra, Bachtazar, Musnal, & Fauzan, 2018). Zhao et al (2008) telah meneliti *chemical surfactant* yang dapat berkerja lebih baik terhadap minyak yang memiliki *paraffin* tinggi dan viskositas yang tinggi dibanding dengan *surfactant* lainnya yaitu *Internal Olefin Sulfonate* (IOS). IOS ini memiliki molekul *hydrophobic* yang bercabang yang dimana sangat berfungsi untuk memecah struktur, mencegah pembentukan kristal dan dapat membantu penurunan viskositas. (Khosravi, 2010)

Penelitian yang dilakukan oleh Subagio R. (2019) merupakan penelitian yang membahas tentang parameter-parameter yang berpengaruh terhadap injeksi *surfactant huff and puff* atau yang disebut dengan *surfactant soaking* dengan menggunakan *surfactant* IOS, parameternya yaitu permeabilitas formasi, *temperature reservoir*, konsentrasi surfaktan, *soaking time*, *number of cycle* dan volume surfaktan. Untuk memahami lebih lanjut efek dari *surfactant soaking*, maka parameter yang perlu diangkat dalam penelitian ini adalah konsentrasi surfaktan, volume surfaktan, *soaking time* dan *number of cycles* dan ditambahkan parameter seperti berat mol surfaktan, *injection rate* dan *production rate*.

Dengan mengamati parameter konsentrasi surfaktan, volume surfaktan, *soaking time* dan *number of cycles*, lalu dengan parameter tambahan berat mol surfaktan, *injection rate*, dan *production rate* terhadap RF. Maka akan dilakukan penelitian dengan menggunakan salah satu metode dari *artificial intelligence* (AI)

yang disebut *artificial neural networks* (ANN) untuk dapat mempelajari kinerja ketujuh parameter dan dapat memprediksi hasil dari RF lebih cepat dan akurat dengan melakukan *train and test*. Oleh karena itu, dalam penelitian kali ini berfokus kepada pengaplikasian ANN menggunakan *software* Matlab dalam memprediksi nilai RF yang sebelumnya telah diperhitungkan dengan menggunakan *software* Computer Modeling Group (CMG).

1.2 TUJUAN PENELITIAN

Terdapat tujuan dilakukannya penelitian adalah sebagai berikut:

Dapat memprediksi nilai RF dari injeksi *surfactant huff and puff* terhadap parameter konsentrasi surfaktan, volume surfaktan, berat mol surfaktan, *soaking time*, *number of cycles*, *injection rate*, dan *production rate* dengan menggunakan metode ANN pada sumur berkadar *paraffin* tinggi.

1.3 MANFAAT PENELITIAN

Penelitian ini diharapkan dapat dimanfaatkan sebagai informasi atau data penunjang bagi industri hulu migas dalam hal penentuan *recovery factor* (RF) untuk sumur ber-*paraffin* tinggi dengan menggunakan metode *surfactant huff and puff*. Diharapkan juga menjadi model prediksi untuk mengevaluasi kinerja *surfactant huff and puff* tanpa menggunakan simulasi reservoir yang dimana akan menghabiskan waktu yang lama.

1.4 BATASAN MASALAH

Terdapat batasan-batasan dari penelitian ini supaya lebih terarah dan tidak menyimpang dari tujuan yang diinginkan, terbagi menjadi 5 bagian:

- 1) Software yang digunakan adalah Computer Modelling Group (CMG) dan Matlab.
- 2) Menggunakan AI yaitu metode ANN BP.
- 3) Parameter yang diuji adalah konsentrasi surfaktan, volume surfaktan, berat mol surfaktan, *soaking time*, *number of cycles*, *injection rate* dan *production rate*.
- 4) Model reservoir dalam penelitian ini memiliki penyebaran karakteristik homogen.
- 5) Analisis hasil penelitian dilakukan tanpa adanya pertimbangan ekonomis.

BAB II TINJAUAN PUSTAKA

2.1 STATE OF THE ART

Wang et al. (2008) telah melakukan penelitian untuk penerapan *surfactant huff and puff* yang berfungsi untuk meningkatkan produksi minyak dengan menggabungkan metode *gel* dan *surfactant huff-puff*. Penelitian yang telah dilakukan oleh Kristanto et al. (2008) melakukan perencanaan peningkatan *recovery factor* dengan metode *surfactant soaking*. Wang dan Kristanto menyimpulkan bahwa metode *surfactant huff and puff* sangat efektif dilakukan. Metode perendaman ini dapat meningkatkan kinerja surfaktan terhadap permukaan batuan, sehingga apabila dilakukan perendaman maka surfaktan akan dapat masuk kedalam pori-pori batuan yang sangat kecil.

Romadhona et al. (2013) membahas tentang cara membuat model prediksi dan *screening criteria* untuk EOR dengan menggunakan metode *Surfactant Huff n Puff*. Penelitian tersebut memberikan gambaran terhadap 8 parameter yang dapat mempengaruhi metode tersebut, yaitu permeabilitas, porositas, saturasi minyak, ketebalan formasi, konsentrasi *surfactant*, waktu injeksi, laju injeksi dan waktu perendaman. Penelitian yang dilakukan oleh Subagio (2019) juga memberikan 6 parameter untuk dicermati yaitu permeabilitas formasi, *temperature reservoir*, konsentrasi surfaktan, *soaking time*, *number of cycle* dan volume surfaktan.

Liu et al (2017) menyebutkan bahwa panjang struktur surfaktan dapat mempengaruhi IFT. Apabila struktur hidrofilik dan hidrofobik sama panjang, maka surfaktan dapat bekerja lebih baik untuk mendapatkan IFT yang rendah, apabila terdapat perbedaan panjang struktur pada hidrofobik dan hidrofilik, maka IFT yang didapat akan semakin besar.

Untuk parameter yang mempengaruhi *huff and puff* akan diangkat dua parameter tambahan, yaitu *injection rate* dan *soaking time*. Ma et al. (2013) mengatakan bahwa *injection rate* dalam *huff and puff* sangat perlu diperhatikan, apabila uap yang diinjeksikan terlalu cepat atau terlalu tinggi, memungkinkan reservoir untuk retak dan uap akan masuk kedalam sumur atau bisa disebut *loss circulation*. Alvarez et al. (2018) menyebutkan, *soaking time* dengan menggunakan *surfactant* memungkinkan cairan menyerap untuk menembus batuan yang retak dan

dapat meningkatkan perolehan minyak dari penurunan *interfacial tension* (IFT) dan perubahan kebasahan dari batuan (*wettability*).

Carpenter (2019) menyebutkan *Artificial Intelligence* merupakan proses yang terinspirasi dari konsep penggandaan inteligensi yang dimana dilakukannya penggabungan keahlian manusia dan kemampuan komputer untuk meningkatkan solusi yang diturunkan dari sistem yang belajar tanpa menggunakan input data dari *engineer* atau geosaintis. Dari Braswell (2013), dalam dunia perminyakan ada tiga metode *artificial intelligence* yang sangat umum digunakan dalam simulasi reservoir, optimisasi produksi dan pengeboran, otomatisasi pengeboran dan kontrol proses, dan pengambilan data yaitu; *artificial neural networks* (ANN), *fuzzy logic*, dan *evolutionary algorithms*.

Penggunaan ANN dalam prediksi *recovery factor* sudah dilakukan oleh Adrian dan teman teman pada tahun 2014. Mereka membahas tentang pengembangan cara prediksi nilai RF pada sumur dengan *strong water drive reservoir*. Lalu pada tahun 2015, Nouredien dan teman teman juga membahas bagaimana penggunaan *Artificial Intelligence* yaitu ANN dalam menghitung *recovery factor*. Lalu pada tahun yang sama, Ahmadi membahas penggunaan ANN dan pengembangan ANN dengan menggunakan *Particle Swarm Optimization* dalam memprediksi *recovery factor*. Pada tahun 2017, Ahmed dan kawan-kawan membahas tentang pengaplikasian AI yaitu ANN, *Radial basis Neural Networks* (RNN), Adaptive Neuro Fuzzy Inference System (ANFIS-2) dan *Support Vector Machine* (SVM) pada *sandy reservoir* dalam memprediksi RF.

Penelitian tentang *recovery factor* menggunakan *Artificial Intelligence* yang telah dilakukan oleh (Adrian & Chukwueke, 2014; Ahmadi, 2015; Ahmed, Elkatatny, Abdulraheem, & Mahmoud, 2017; Nouredien & El-Banbi, 2015) dapat ditarik kesimpulan bahwa penggunaan AI terutama ANN dalam dunia perminyakan dapat terbilang cukup rumit untuk diterapkan, akan tetapi penggunaan AI dalam dunia perminyakan dapat memberikan hasil yang akurat.

Tabel 2.1 Parameter yang mempengaruhi *surfactant huff n puff*

Parameter	Sumber
Volume surfaktan	(Rai, Bera, & Mandal, 2015)
Konsentrasi surfaktan	(Abdullah, Emami-Meybodi, & Ertekin, 2019; Wibowo, Buntoro, & Natsir, 2007)
Berat mol surfaktan	(Abdullah et al., 2019)
<i>Soaking time</i>	(Alvarez et al., 2018; Kristanto & Bintarto, 2008)
<i>Number of cycles</i>	(Valera, Escobar, & Iturbe, 1999)
<i>Injection rate</i>	(Gholamzadeh & Chahardahcherik, 2012; Keshtkar, Sabeti, & Mohammadi, 2016)
<i>Production rate</i>	(Ali, Hassan, & Alkhider, 2015)

Tabel 2.2 Perkembangan penggunaan ANN terhadap RF

Topik	Sumber
Pengaplikasian ANN untuk prediksi RF pada <i>water-drive reservoir</i>	(Adrian & Chukwueke, 2014)
Pengaruh ANN dalam prediksi RF	(Noureldien & El-Banbi, 2015)
Prediksi RF menggunakan ANN pada <i>Surfactant-Polymer injection</i>	(Ahmadi, 2015)
Prediksi RF pada <i>sandy reservoir</i> menggunakan ANN	(Ahmed et al., 2017)

BAB III METODOLOGI PENELITIAN

3.1 PEMODELAN SIMULASI

Thermal & Advance Processes Reservoir Simulator (STARS) merupakan paket dalam CMG yang secara luas digunakan dalam industri perminyakan saat ini. Keunggulan dari simulator ini adalah dapat mendefinisikan komponen *chemical* yang tidak terdaftar dalam simulator. Dalam proses penelitian ini terdapat beberapa batasan, yaitu:

- Model ini merupakan tampilan dari reservoir yang bersifat homogen
- Model ini tidak menggunakan geomekanik
- Metode yang digunakan adalah injeksi dengan metode *huff and puff* atau *cyclic steam stimulation*.

3.1.1 Reservoir Properties

Sumur H adalah sumur yang di dalamnya terkandung minyak dengan kadar *paraffin* yang tinggi, dengan jenis batuan reservoir *sandstone* yang kompaksi batuanannya sangat erat dan mempunyai ketebalan reservoir sebesar 10 ft. Data *reservoir properties* pada Sumur H dipaparkan pada Tabel 3.1


Berdasarkan data *reservoir properties* Tabel 3.1, fluida hidrokarbon pada reservoir berada dalam keadaan *undersaturated*. Selain itu, nilai *API gravity* yang tinggi menyatakan minyak pada reservoir ini termasuk ke dalam golongan *light oil*.

Tabel 3.1 Data *reservoir properties*

No	Parameter	Nilai
1	Oil Gravity	30,8°API
2	Oil Viscosity	14,4cp
3	Water Density	62,6lb/ft ³
4	Water Viscosity	0,5cp
5	Rock Compressibility	5,8 x 10 ⁻⁶ psi ⁻¹
6	Formation Volume Factor	1,049bbl/STB
7	Reservoir Depth	1100-1200ft
8	Reservoir Temperature	136°F

No	Parameter	Nilai
9	Reservoir Pressure	532psi
10	Bubble Point Pressure	113psig
11	Oil Saturation	0,631
12	Drainage Area	350ft
13	Porosity	0,244
14	Permeability	1004mD

Sumber:(Rahmadina, 2018)



Gambar 3.1 Grafik hubungan antara *relative permeability* dan *water saturation*
(Rahmadina, 2018)

Tabel 3.2 Perbandingan IFT dan konsentrasi surfaktan

Interfacial Tension (dynes/cm)	Surfactant Concentration (wt%)
2.00E+01	0.05
2.00E+00	0.1
2.00E-01	0.3
2.00E-02	0.6
2.00E-03	2.9
1.00E-04	4.9

Sumber:(Abdullah et al., 2019)

Grafik permeabilitas relatif terhadap saturasi air pada Gambar 3.1 menunjukkan bahwa wilayah reservoir ini bersifat *water wet*. *Water wet* adalah sifat batuan yang menunjukkan bahwa adanya lapisan air yang membasahi batuan, kondisi ini sangat diinginkan untuk mempermudah pengaliran minyak secara efisien.

3.1.2 Hydrocarbon Component

Model yang digunakan dalam penelitian ini merupakan model reservoir yang memiliki kandungan *paraffin* yang tinggi. Tabel 3.3 menjelaskan besaran *mole percent* dari masing-masing komponen hidrokarbon yang digunakan dalam penelitian ini. Berdasarkan Tabel 3.3, bahwa komponen penyusun hidrokarbon yang paling tinggi berada pada komponen C₇-C₁₂ dilihat dari nilai *mole percent* sebesar 27,47%.

Tabel 3.3 *Hydrocarbon component*

No	Component	Mole Percentage
1	CO ₂	0.56 %
2	N ₂	0.00 %
3	C ₁	0.67 %
4	C ₂	0.67 %
5	C ₃	1.51 %
6	i-C ₄	0.90 %
7	n-C ₄	1.57 %
8	i-C ₅	1.56 %
9	n-C ₅	1.50 %
10	C ₆	0.35 %
11	C ₇ -C ₁₂	27.47 %
12	C ₁₃ -C ₁₈	19.15 %
13	C ₁₉ -C ₂₄	13.35 %
14	C ₂₅ -C ₃₀	9.30 %
15	C ₃₁ +	21.44 %
Total		100 %


Sumber:(Subagio, 2019)

3.1.3 Pembuatan *Grid*

Model pada studi ini menggunakan *radial grid* karena jenis *grid* ini digunakan untuk simulasi sumur tunggal, sehingga cocok untuk dilakukan simulasi dengan metode CSS atau *huff and puff*. Selain itu, *radial grid* juga digunakan untuk melihat performa sumur akibat pengaruh dari injeksi *surfactant* yang dilakukan. Tabel 3.4 menunjukkan parameter-parameter yang digunakan dalam pemodelan ini.

Tabel 3.4 *Model properties*

No	Model Properties	Nilai
1	Type grid	Radial (cylindrical)
2	Inner radius	0,28ft
3	Outer radius	600ft
4	Layer	3
5	Along Radius	30

**Gambar 3.2** Model konseptual *radial grid* sumur H


3.1.4 Inisialisasi

Berikut hasil inisialisasi berdasarkan data *reservoir properties* dan *rock properties* dari sumur H.

Tabel 3.5 Hasil inisialisasi simulasi

No	Parameter	Nilai
1	Gross Formation Volume	$6,0430 \times 10^6 \text{ bbl}$
2	Original Oil In Place	$8,6422 \times 10^5 \text{ bbl}$
3	Original Gas In Place	0
4	Formation Pore Volume	$1,3696 \times 10^6 \text{ bbl}$

3.2 DIAGRAM ALIR PENELITIAN



Gambar 3.3 Diagram alir penelitian

3.3 ARTIFICIAL NEURAL NETWORKS

ANN adalah teknik pemodelan yang sangat mampu memecahkan permasalahan tertentu. ANN memiliki kemampuan untuk belajar dari struktur *training dataset* dan dapat mengaplikasikan pada *testing dataset* dan memprediksi data output. ANN terdapat 3 struktur, (1) *input*, (2) *hidden layer*, (3) *output*. Penggunaan ANN pada *software* Matlab telah dipermudah dengan adanya *Neural Networks Tool* (NNTool). Dalam NNTool sudah terdapat pilihan-pilihan untuk pengaturan jumlah *nodes* dalam *hidden layer*, jumlah *hidden layer*, dan bentuk fungsi yang ingin digunakan untuk mempelajari *input* dan memprediksi *output*.

ANN perlu dilakukan metode *trial and error* untuk mendapatkan hasil prediksi yang akurat.

ANN yang digunakan adalah ANN *Back Propagation* (BP) dengan 1 *hidden layer* dan menggunakan *sigmoid activation function*. Berikut adalah Langkah-langkah algoritma pelatihan ANN BP:

Langkah 1 : Menginisialisasi bobot dengan cara mengambil bobot awal

Feed forward

Langkah 2 : Tiap input ($X_i, i=1,2,\dots,n$) menerima sinyal x_i dan meneruskan sinyal ke semua *nodes* pada *hidden layer*

Langkah 3 : Tiap *hidden layer* ($Z_j, j=1,2,\dots,n$) menjumlahkan sinyal-sinyal input terbobot:

$$Z_in_j = V_{oj} + \sum_{i=1}^p X_i V_{ij}$$

Gunakan fungsi aktivasi *sigmoid* untuk menghitung sinyal *output*:

$$Z_j = f(Z_in_j)$$

Dan kirimkan sinyal tersebut ke semua output

Langkah 4 : Tiap *output* ($Y_k, K=1,2,\dots,n$) menjumlahkan sinyal-sinyal input terbobot:

$$Y_in_j = W_{ok} + \sum_{i=1}^p Z_i W_{jk}$$

Gunakan fungsi aktivasi untuk menghitung sinyal *output*:

$$Y_k = f(Y_in_k)$$

Dan kirimkan sinyal tersebut ke semua *output*

Back propagation

Langkah 5 : Tiap *output* ($Y_k, K=1,2,\dots,n$) menerima target pola yang berhubungan dengan pola input, hitung *error*-nya:

$$\delta_k = (t_k - Y_k) f'(y_in_k)$$

Kemudian hitung koreksi bobot untuk memperbaiki nilai W_{jk} :

$$\Delta W_{jk} = \alpha \delta_k z_j$$

Hitung koreksi bias untuk memperbaiki nilai W_{ok} :

$$\Delta W_{ok} = \alpha \delta_k$$

Lalu kirimkan δ_k ke unit lapisan dibawahnya

Langkah 6 : Tiap *hidden layer* ($Z_j, j=1,2,\dots,n$) menjumlahkan sinyal-sinyal input terbobot:

$$\delta_{in_j} = \sum_{k=1}^m \delta_k W_{jk}$$

Kalikan dengan turunan fungsi aktivasi untuk menghitung *error*:

$$\delta_j = \delta_{in_j}(z_{in_j})$$

Kemudian hitung koreksi bobot untuk memperbaiki V_{ij} :

$$\Delta V_{jk} = \alpha \delta_j X_i$$

Hitung juga koreksi bias untuk memperbaiki V_{oj}

$$\Delta V_{oj} = \alpha \delta_j$$

Langkah 7 : Tiap *output* (Y_k , $K=1,2,\dots,n$) memperbaiki nilai bias dan bobot:

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{ij}$$

Tiap *hidden layer* (Z_j , $j=1,2,\dots,n$) memperbaiki nilai bias dan bobot:

$$v_{jk}(\text{baru}) = v_{jk}(\text{lama}) + \Delta v_{ij}$$

Langkah 8 : Pengujian berhenti

3.4 JENIS PENELITIAN

Penelitian ini menggunakan kombinasi dari simulasi reservoir dan desain eksperimen dengan menggunakan *software* simulasi CMG dan *software* analisis statistik Matlab. Parameter yang diuji dalam penelitian ini adalah konsentrasi surfaktan, volume surfaktan, berat mol surfaktan, *number of cycles*, *soaking time*, *injection rate* dan *production rate*.

3.5 TEMPAT PENELITIAN

Penelitian ini dilakukan di Laboratorium Simulasi Reservoir, Fakultas Teknik Program Studi Perminyakan, Universitas Islam Riau. Data yang digunakan merupakan data yang bersifat sekunder dan data ini didapat dari literatur yang sesuai dan terpercaya.

3.6 WAKTU PENELITIAN

Penelitian menghabiskan waktu sekiranya adalah 4 bulan, dimulai dari bulan Mei 2020 hingga bulan Agustus 2020.

Tabel 3.6 Waktu penelitian

No	Jenis Kegiatan	Mei-20				Jun-20				Jul-20				Agu-20			
		1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
1	Literature Review																
2	Pembuatan model dalam perhitungan menggunakan software CMG																
3	Pengaplikasian ke metode Artificial Neural Networks																
4	Analisis Hasil CMG dan ANN																
5	Laporan Akhir																

3.7 DATA ACUAN PENELITIAN

Penelitian ini dilakukan menggunakan 7 parameter uji, yang masing-masing memiliki *range* nilai dari minimum, medium, hingga maksimum.

Tabel 3.7 Data masing-masing parameter

Factor		Level		
		-1	0	1
Volume surfaktan, PV	X1	0.03	0.165	0.3
Konsentrasi surfaktan, %	X2	0.1	0.55	1
Berat mol surfaktan, lb/lbmole	X3	250	375	500
<i>Soaking time</i>	X4	3	16.5	30
<i>Number of cycles</i>	X5	1	2	3
<i>Injection rate</i> , bbl/d	X6	2000	2250	2500
<i>Production rate</i> , bbl/d	X7	500	750	1000

BAB IV HASIL DAN PEMBAHASAN

Dalam penelitian yang membahas tentang aplikasi dan penerapan AI untuk memprediksi nilai RF telah menyebutkan bahwa penggunaan ANN jauh lebih efektif dan lebih cepat dibandingkan AI yang lainnya. Penerapan ANN dalam penelitian ini bertujuan untuk mempercepat perhitungan nilai RF terhadap parameter-parameter injeksi *surfactant huff and puff* pada sumur minyak dengan kadar *paraffin* tinggi yang menggunakan aplikasi simulasi reservoir CMG. ANN yang diterapkan pada penelitian kali ini adalah ANN *Back Propagation* (BP).

Parameter uji pada penelitian ini adalah konsentrasi surfaktan, volume surfaktan, berat mol surfaktan, *number of cycles*, *soaking time*, *injection rate* dan *production rate* yang dimana masing-masing dapat berpengaruh dalam perubahan nilai RF. Parameter ini didapat dari sumber-sumber terpercaya yang sebelumnya telah membahas tentang metode *surfactant huff and puff*, dan juga ditambahkan parameter yang berpengaruh dalam injeksi *surfactant* maupun injeksi uap *huff and puff*.

Terdapat 2187 hasil run menggunakan CMG CMOST dengan 81 segmen yang tiap segmennya terdiri dari 27 hasil run. Hasil *run* ini lalu dilakukan pengambilan sampel secara acak dan merata untuk mendapatkan sampel data yang representatif. Sebanyak 500 sampel data diambil untuk nantinya dilakukan prediksi perhitungan nilai RF menggunakan ANN BP. Prediksi menggunakan ANN BP membutuhkan kombinasi data *training* dan *testing* dengan rasio 0,8:0,2 dengan jumlah data untuk *training* yaitu 400 dan jumlah data untuk *testing* adalah 100.

Noureldien (2015) dalam penelitiannya mengatakan bahwa, untuk mendapatkan model ANN yang bagus harus dilakukan optimisasi dengan menggunakan metode “*trial and error*” dan untuk mempermudah penentuan jumlah *hidden layer*, terdapat *rule of thumb* yang menyatakan bahwa jumlah *hidden layer* harus melebihi jumlah *input layer* dan tidak lebih dari dua kali jumlah *input layer*. Dengan menggunakan 500 dataset dan *range* jumlah *nodes hidden layer* diantara 7


hingga 14, maka akan dicari nilai MSE yang terendah pada data *training* dan *testing*.

Tabel 4.1 Nilai *Mean Square Error* (MSE) dan *coefficient correlation* (R) pada jumlah *nodes hidden layer* yang berbeda dengan menggunakan 500 data

Jumlah Nodes Hidden Layer	MSE (Training)	R (Training)	MSE (Testing)	R (Testing)
7	0.1704	0,9649	1,5264	0,8212
8	0.1771	0,9635	0,4514	0,9332
9	0.0545	0,9889	0,9248	0,8516
10	0.1343	0,9724	0,5034	0,9201
11	0.1260	0,9742	0,3485	0,9528
12	0.0641	0,9869	681,0814	0,0711
13	0.0634	0,9871	39,2681	0,2896
14	0.0901	0,9816	4,5713	0,8024


Semakin kecil nilai MSE hingga mendekati nilai 0 maka prediksi dari ANN tersebut akan semakin bagus, dan semakin besar nilai R hingga mendekati angka 1 maka korelasi antara output dan prediksi tidak jauh berbeda.

Tabel 4.1 merupakan kumpulan hasil run dari nilai MSE dan R menggunakan 7 sampai 14 *nodes hidden layer*. Didapat *nodes hidden layer* 9 dengan nilai MSE terkecil dibanding dengan nilai MSE yang lainnya dan nilai R yang lebih tinggi daripada yang lainnya di data *training*, akan tetapi saat diaplikasikan ke data *testing* didapat nilai MSE yang lumayan tinggi yaitu 0,9248 dan nilai R bernilai 0,8516. Dikarenakan kurang efektif dan tidak stabilnya penggunaan 9 *nodes*, lalu didapat jumlah *nodes* yang stabil untuk diterapkan pada *testing* yaitu 11 *nodes* dengan MSE dan R *training* bernilai 0,1260 dan 0,9742. Setelah dilakukan simulasi pada data *testing*, nilai MSE dan nilai R pada 11 *nodes hidden layer* bernilai 0,3485 dan 0,9528. Dalam Zerpa (2007) dan Janiga (2018), pemilihan nilai MSE dan RMSE yang paling kecil merupakan pemilihan model terbaik, yang dimana performa model tersebut akan semakin baik seiring kecilnya nilai *error* tersebut. Dengan nilai R yang hampir mendekati angka “1”, maka model pada penelitian ini dapat dibilang korelasi statistiknya hampir sempurna. (Helmy, Fatai, & Faisal, 2010)




Gambar 4.1 Struktur 11 nodes hidden layer ANN dengan aktifasi sigmoid

Ahmadi (2015) juga menyatakan bahwa apabila jumlah nodes hidden layer terlalu sedikit maka akan menyebabkan *underfitting*, dan apabila jumlahnya terlalu banyak akan menyebabkan *overfitting*. Dapat dilihat dalam Tabel 4.1 bahwa jumlah hidden layer 7 terjadi *underfitting* yang dimana nilai MSE terlalu tinggi pada data training yang menyebabkan tingginya nilai MSE pada data testing. Lalu kejadian *overfitting* terjadi pada nodes dengan jumlah 12 dan 13 yang dimana MSE pada data training bernilai sangat rendah yang dapat terbilang *suitable model* untuk data testing. Tetapi disaat dilakukan simulasi terhadap data testing, didapat nilai dari MSE yang terlalu tinggi atau dapat diartikan bahwa error yang terdapat pada hidden layer 12 dan 13 terlalu besar dan berjumlah banyak. Kejadian *overfitting* juga terjadi pada nodes hidden layer 9 yang dimana tingginya nilai MSE dan rendahnya nilai R pada data testing.



Gambar 4.2 Coefficient of determination (R^2) antara nilai RF Aktual dan RF Prediksi 400 data training dengan 11 nodes hidden layer



Gambar 4.3 Coefficient of determination (R^2) antara nilai RF Aktual dan RF Prediksi 100 data testing dengan 11 nodes hidden layer

Tabel 4.2 Hasil MSE, RMSE, R, R^2 dan adjusted R^2

Hidden Layer	Value, %				
11	Training				
	MSE	RMSE	R	R^2	Adj R^2
	0,1260	0,3550	0,9742	0,9490	0,9489
	Testing				
	MSE	RMSE	R	R^2	Adj R^2
	0,3485	0,5903	0,9528	0,9077	0,9068

Karena data yang digunakan merupakan data *random sampling*, maka kita akan menggunakan *adjusted R^2* . *Adjusted R^2* adalah versi R^2 yang sudah mempertimbangkan jumlah sampel data dan jumlah variabel yang digunakan. Naik turunnya nilai *adjusted R^2* akan dipengaruhi oleh penambahan pola baru yang nantinya akan memperbaiki model regresi atau tidak, apabila hasil dari model regresi lebih buruk dari estimasi maka nilainya akan turun dan begitu sebaliknya. Tabel 4.2 menunjukkan nilai dari MSE, RMSE, R, R^2 dan adjusted R^2 pada data *training* dan data *testing* untuk 11 nodes hidden layer.

Setelah ANN melakukan peramalan terhadap nilai RF, maka selanjutnya akan dilakukan perbandingan dan perhitungan terhadap *mean absolute error* (MAE) dan

mean absolute percentage error (MAPE). Yang dimana model ini dapat terbilang bagus atau berhasil apabila terhitung *error* dalam prediksi tidak melebihi 5%. Pada lampiran 1 dapat dilihat bahwa nilai MAE dan MAPE yaitu 0,293 dan 1,42%, apabila nilai MAPE dibawah 10% maka kemampuan peramalan sangat baik (Margi S & Pendawa W, 2015). Lalu pada penelitian Shafiei (2013), MAPE yang didapatkan menggunakan ANN BP untuk prediksi RF bernilai 11,48%. Hal ini membuktikan bahwa hasil prediksi model ANN BP pada penelitian ini terbilang sangat bagus dan hampir mendekati hasil dari model CMG dalam perhitungan *recovery factor*.



BAB V PENUTUP

5.1 KESIMPULAN

Dapat disimpulkan dari penelitian ini yaitu model prediksi ANN terhadap nilai RF terbukti bagus dan berhasil dengan nilai MAE 0,293 dan MAPE 1,42%. Dengan analisa terhadap 500 data sampel menggunakan 11 *nodes hidden layer* yaitu MSE dan RMSE pada data *training* bernilai 0,1260; 0,3550 dan pada data *testing* 0,3485; 0,5903. Dengan nilai R, R^2 , *adjusted R*² secara berurutan yaitu 0,9742; 0,9491; 0,9489 untuk data training dan 0,9528; 0,9077; 0,9068 untuk data testing.

5.2 SARAN

Berdasarkan kesimpulan dari penelitian yang telah dilakukan, peneliti menyarankan untuk melakukan prediksi *full data* dan optimisasi dari parameter injeksi *surfactant huff and puff* menggunakan *Artificial Intelligence* seperti *Genetic Algorithm*, *Ant Colony Optimization* atau *Particle Swarm Optimization*.

DAFTAR PUSTAKA

- Abdullah, M., Emami-Meybodi, H., & Ertekin, T. (2019). Development and Application of an Artificial Neural Network Tool for Chemical EOR Field Implementations. *Society of Petroleum Engineers Europec Featured at 81st EAGE Conference and Exhibition*, 1–23. <https://doi.org/10.2118/195492-ms>
- Adrian, O., & Chukwueke, N. (2014). Application of Neural Networks in developing an empirical oil recovery factor equation for water drive Niger Delta Reservoirs. *38th Nigeria Annual International Conference and Exhibition, NAICE 2014 - Africa's Energy Corridor: Opportunities for Oil and Gas Value Maximization Through Integration and Global Approach*, 2, 1619–1629. <https://doi.org/10.2118/172489-ms>
- Ahmadi, M. A. (2015). Developing a robust surrogate model of chemical flooding based on the artificial neural network for enhanced oil recovery implications. *Mathematical Problems in Engineering*, 2015. <https://doi.org/10.1155/2015/706897>
- Ahmed, A. A., Elkatatny, S., Abdulraheem, A., & Mahmoud, M. (2017). Application of artificial intelligence techniques in estimating oil recovery factor for water derive sandy reservoirs. *Society of Petroleum Engineers - SPE Kuwait Oil and Gas Show and Conference 2017*. <https://doi.org/10.2118/187621-ms>
- Al-Yaari, M. (2013). Paraffin wax deposition: Mitigation & removal techniques. *Society of Petroleum Engineers - Saudi Arabia Section Young Professionals Technical Symposium 2011*, (March), 35–44. <https://doi.org/10.2118/155412-ms>
- Ali, H. M. K., Hassan, M. A. A., & Alkhider, M. D. M. (2015). Optimization of cyclic steam stimulation (CSS) using (CMG) software to increase the recovery factor. *This Dissertation Is Submitted as a Partial Requirement of B.Sc. Degree (Honor) in Petroleum Engineering*, (August).
- Alvarez, J. O., Tovar, F. D., & Schechter, D. S. (2018). Improving oil recovery in the wolfcamp reservoir by soaking/flowback production schedule with surfactant additives. *SPE Reservoir Evaluation and Engineering*, 21(4),

1083–1096. <https://doi.org/10.2118/187483-PA>

Bacon, M. M., Romero-Zerón, L. B., & Chong, K. K. (2010). Determining wax type: Paraffin or naphthene? *SPE Journal*, 15(4), 969–974.

<https://doi.org/10.2118/124799-pa>

Braswell, G. (2013). Artificial Intelligence Comes of Age in Oil and Gas. *Journal of Petroleum Technology*, 65(01), 50–57. <https://doi.org/10.2118/0113-0050-jpt>

Carpenter, C. (2019). Augmented Artificial Intelligence Improves Data Analytics in Heavy-Oil Reservoirs. *Journal of Petroleum Technology*, 71(05), 68–70. <https://doi.org/10.2118/0519-0068-jpt>

Gholamzadeh, M. A., & Chahardahcherik, M. (2012). Optimization of Injection rate and Injection Time for Surfactant. *International Journal of Advancements in Research & Technology*, 1, 1–7.

Helmy, T., Fatai, A., & Faisal, K. (2010). Hybrid computational models for the characterization of oil and gas reservoirs. *Expert Systems with Applications*, 37(7), 5353–5363. <https://doi.org/10.1016/j.eswa.2010.01.021>

Janiga, D., Czarnota, R., Stopa, J., & Wojnarowski, P. (2018). Huff and puff process optimization in micro scale by coupling laboratory experiment and numerical simulation. *Fuel*, 224(January), 289–301. <https://doi.org/10.1016/j.fuel.2018.03.085>

Keshtkar, S., Sabeti, M., & Mohammadi, A. H. (2016). Numerical approach for enhanced oil recovery with surfactant flooding. *Petroleum*, 2(1), 98–107. <https://doi.org/10.1016/j.petlm.2015.11.002>

Khosravi, V. (2010). Developing surfactant to increase the production in heavy oil reservoirs. *Society of Petroleum Engineers - Trinidad and Tobago Energy Resources Conference 2010, SPE TT 2010*, 1(June), 249–256. <https://doi.org/10.2523/132575-ms>

Kristanto, D., & Bintarto, B. (2008). Perencanaan Peningkatan Perolehan Minyak Menggunakan Metode Soaking Surfactant. *Simposium Nasional Dan Kongres X*, 12–14.

Liu, Z. Y., Wang, C., Zhou, H., Wang, Y., Zhang, L., Zhang, L., & Zhao, S. (2017). Characterizing the impact of surfactant structure on interfacial

- tension: a molecular dynamics study. *Journal of Molecular Modeling*, 23(4), 1–8. <https://doi.org/10.1007/s00894-017-3285-0>
- Ma, C., Liu, Y., Lian, P., Wang, C., & Li, J. (2013). Study on steam huff and puff injection parameters of herringbone well in shallow and thin heavy oil reservoir. *Open Petroleum Engineering Journal*, 6(1), 69–75. <https://doi.org/10.2174/1874834101306010069>
- Margi S, K., & Pendawa W, S. (2015). Analisa Dan Penerapan Metode Single Exponential Smoothing Untuk Prediksi Penjualan Pada Periode Tertentu. *Prosiding SNATIF*, (1998), 259–266.
- Noureldien, D. M., & El-Banbi, A. H. (2015). Using artificial intelligence in estimating oil recovery factor. *Society of Petroleum Engineers - SPE North Africa Technical Conference and Exhibition 2015, NATC 2015*, (September), 1464–1485. <https://doi.org/10.2118/175867-ms>
- Putra, D., Bachtazar, F., Musnal, A., & Fauzan, A. (2018). Production Optimization through Surfactant stimulation in Volcaniclastic formation A . Surfactant Introduction. *ICOGET Conference.*, 46(1570427786).
- Rahmadina, S. (2018). Analisis Sensitivitas Terhadap Key Parameters pada Injeksi Surfaktan dengan Metode Huff and Puff. *Thesis*.
- Rai, S. K., Bera, A., & Mandal, A. (2015). Modeling of surfactant and surfactant–polymer flooding for enhanced oil recovery using STARS (CMG) software. *Journal of Petroleum Exploration and Production Technology*, 5(1), 1–11. <https://doi.org/10.1007/s13202-014-0112-3>
- Romadhona, M. (2013). A Study To Formulate Predictive Model and Screening Criteria For New EOR Method In Indonesia: Surfactant Huff N’Puff Injection. *Proceedings, Indonesian Petroleum Association*, (May). <https://doi.org/10.29118/ipa.0.13.se.017>
- Shafiei, A., Dusseault, M. B., Zendehboudi, S., & Chatzis, I. (2013). A new screening tool for evaluation of steamflooding performance in Naturally Fractured Carbonate Reservoirs. *Fuel*, 108, 502–514. <https://doi.org/10.1016/j.fuel.2013.01.056>
- Sheng, J. J. (2015). Status of surfactant EOR technology. *Petroleum*, 1(2), 97–105. <https://doi.org/10.1016/j.petlm.2015.07.003>

- Subagio, R. (2019). Screening Criteria Injeksi Surfactant Dengan Metode Huff and Puff pada Sumur Paraffin. *Thesis*.
- Valera, C. A., Escobar, M. A., & Iturbe, Y. J. (1999). Use of surfactants in cyclic steam injection in Bachaquero-01 reservoir. *SPE Latin American and Caribbean Petroleum Engineering Conference Proceedings, 1999-Janua*(november 1998), 1–8. <https://doi.org/10.2523/54020-ms>
- Wang, Y., Bai, B., Gao, H., He, L., & Zhao, F. (2008). Enhanced oil production through a combined application of gel treatment and surfactant huff'n'puff technology. *Proceedings - SPE International Symposium on Formation Damage Control*, 2(2005), 896–909. <https://doi.org/10.2118/112495-ms>
- Wibowo, E. B., Buntoro, A., & Natsir, M. (2007). Upaya Peningkatan Perolehan Minyak Menggunakan Metode Chemical Flooding di Lapangan Limau. *Proceeding Simposium Nasional IATMI 25 - 28 Juli 2007, UPN "Veteran" Yogyakarta*.
- Zerpa, L. E., Queipo, N. V., Pintos, S., Zulia, U., Tillerio, E., & Alter, D. (2007). Processes : ASP Pilot Project LL-03 Reservoir. *SPE International*, 1–9.
- Zhao, P., Jackson, A. C., Britton, C., Kim, D. H., Britton, L. N., Levitt, D. B., & Pope, G. A. (2008). Development of high-performance surfactants for difficult oils. *Proceedings - SPE Symposium on Improved Oil Recovery*, 2(1992), 828–836. <https://doi.org/10.2118/113432-ms>