

**PREDIKSI ENDAPAN *ASPHALTENE* MENGGUNAKAN
MACHINE LEARNING DENGAN METODE *BAYESIAN*
*NETWORK***

TUGAS AKHIR

Diajukan guna melengkapi syarat dalam mencapai gelar serjana teknik

Oleh

IRFAN DINO

NPM 163210109



**PROGRAM STUDI TEKNIK PERMINYAKAN
UNIVERSITAS ISLAM RIAU
PEKANBARU**

2021

HALAMAN PENGESAHAN

Tugas akhir ini disusun oleh :

Nama : Irfan Dino

NPM : 163210109

Program Studi : Teknik Perminyakan

Judul Skripsi : Prediksi endapan *asphaltene* menggunakan *machine learning* dengan metode *Bayesian network*.

Telah berhasil dipertahankan dihadapan Dewan Penguji dan diterima sebagai salah satu syarat guna memperoleh gelar Sarjana Teknik pada Program Studi Teknik Perminyakan, Fakultas Teknik, Universitas Islam Riau

DEWAN PENGUJI

Pembimbing : Fiki Hidayat, S.T., M.Eng. (.....)

Penguji : Dike Fitriansyah Putra, S.T., M.Sc., MBA. (.....)

Penguji : Muhammad Aryon, S.T., M.T. (.....)

Diterapkan di : Pekanbaru

Tanggal : 14 September 2021

Disahkan Oleh:

KETUA PROGRAM STUDI

TEKNIK PERMINYAKAN


(Novia Rita, S.T., M.T.)

PERNYATAAN KEASLIAN TUGAS AKHIR

Dengan ini saya menyatakan bahwa tugas akhir ini merupakan karya saya sendiri dan semua sumber yang tercantum di dalamnya baik yang dikutip maupun dirujuk telah saya nyatakan dengan benar sesuai ketentuan. Jika didapat unsur penipuan atau pemalsuan data maka saya bersedia dicabut gelar yang telah saya peroleh.

Pekanbaru, 14 September 2021



Irfan Dino

NPM 163210109



KATA PENGANTAR

Rasa syukur saya sampaikan kepada Allah Subhannahu wa Ta'ala karena atas Rahmat dan Karunia ilmu yang ia berikan, saya dapat menyelesaikan tugas akhir ini. Penulisan tugas akhir ini merupakan salah satu syarat untuk memperoleh gelar Sarjana Teknik, Program Studi Teknik Perminyakan, Universitas Islam Riau. Banyak pihak yang telah ikut berkontribusi dalam membantu dan menolong saya untuk menyelesaikan tugas akhir ini serta memperoleh ilmu pengetahuan selama perkuliahan. Oleh karena itu saya ingin mengucapkan terima kasih kepada:

1. Kedua orang tua saya yaitu, bapak Pahmiuddin Nasution dan Ibu Nurani, serta keluarga besar yang telah memberikan doa serta dukungan penuh kepada saya baik moral maupun material.
2. Bapak Fiki Hidayat, S.T., M.Eng., selaku dosen pembimbing yang telah meluangkan waktu dan pikirannya dalam memberikan arahan dan masukan selama proses pembuatan tugas akhir saya.
3. Bapak Ali Musnal, S.T., M.T., selaku Pembimbing Akademik yang memberikan nasihat dalam menjalani perkuliahan di Teknik Perminyakan.
4. Ibu Novia Rita, S.T, M.T., selaku Ketua Prodi dan Bapak Tomi Erfando, S.T., M.T., selaku Sekertaris Prodi serta Dosen lainnya yang telah banyak membantu terkait perkuliahan, ilmu pengetahuan, dan hal lainnya yang tidak dapat saya sebutkan satu per satu.
5. Seluruh teman-teman saya, yaitu Karin Della, teman-teman mahasiswa Pangkalan Kerinci, teman-teman kelas A angkatan 2016, serta teman-teman Teknik Perminyakan UIR lainnya.

Teriring doa saya, semoga Allah memberikan Kesehatan, kedamaian hati, dan dibalaskan segala kebaikan seluruh pihak yang telah membantu. Semoga skripsi ini membawa manfaat bagi pengembangan ilmu pengetahuan.

Pekanbaru, 14 September 2021



Irfan Dino

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGESAHAN.....	ii
PERNYATAAN KEASLIAN TUGAS AKHIR.....	iii
KATA PENGANTAR.....	iv
DAFTAR ISI.....	v
DAFTAR GAMBAR.....	vii
DAFTAR TABEL	viii
ABSTRAK	xii
<i>ABSTRACT</i>	xiii
BAB I PENDAHULUAN	1
1.1 LATAR BELAKANG	1
1.2 TUJUAN PENELITIAN.....	3
1.3 MANFAAT PENELITIAN.....	3
1.4 BATASAN MASLAH.....	4
BAB II TINJAUAN PUSTAKA	5
2.1 ENDAPAN <i>ASPHALTENE</i>	5
2.2 ALGORITMA <i>BAYESIAN NETWORK</i>	6
2.3 <i>PYTHON LANGUAGE</i>	11
2.4 <i>JUPYTER NOTEBOOK</i>	11
2.5 <i>PGMPY</i>	11
BAB III METODOLOGI PENELITIAN.....	12
3.1 LOKASI PENELITIAN.....	12
3.2 <i>FLOWCHART</i>	13
3.3 JENIS PENELITIAN	14
3.3.1. Alat.....	14
3.3.2. Bahan	14
3.4 METODE PENELITIAN.....	14
3.4.1. Pengumpulan Data	14
3.4.2. Praproses Data.....	15
3.4.3. Pembagian Data	15
3.4.4. Membangun Model BN	16

3.4.5.	Pengujian dan Analisa.....	16
3.5	JADWAL KEGIATAN PENELITIAN	17
BAB IV	HASIL DAN PEMBAHASAN.....	18
4.1	DATA	18
4.2	STRUKTUR GRAFIK.....	19
4.3	<i>PARAMETER LEARNING</i>	20
4.3.1	Hubungan Data Tekanan.....	21
4.3.2	Hubungan Data Temperatur.....	22
4.3.3	Hubungan Data <i>Light Component</i>	23
4.3.4	Hubungan Data <i>Intermediate Component</i>	23
4.3.5	Hubungan Data <i>Heavy Component</i>	24
4.4	PENGUJIAN MODEL	24
4.4.1	Hasil Pengujian 10% Data	25
4.4.2	Hasil Pengujian 15% Data	28
4.4.3	Hasil Pengujian 20% Data	28
4.4.4	Hasil Pengujian 25% Data	29
4.4.5	Hasil Pengujian 30% Data	29
4.5	ANALISIS HASIL.....	30
BAB V	KESIMPULAN DAN SARAN.....	33
5.1	KESIMPULAN.....	33
5.2	SARAN.....	33
	DAFTAR PUSTAKA.....	34
	LAMPIRAN.....	38

DAFTAR GAMBAR

Gambar 2. 1 Bayesian (belief) network (Weber, 2016)	8
Gambar 3. 2 Data.....	12
Gambar 3. 3 Diagram alir	13
Gambar 4. 1 Data set setelah melalui praproses data.	18
Gambar 4. 2 Struktur grafik model BN	19
Gambar 4. 3 Hubungan tekanan terhadap endapan asphaltene	21
Gambar 4. 4 Hubungan temperatur terhadap endapan asphaltene	22
Gambar 4. 5 Hubungan light component terhadap endapan asphaltene.....	23
Gambar 4. 6 Hubungan intermediate component terhadap endapan asphaltene.	23
Gambar 4. 7 Hubungan heavy component terhadap endapan asphaltene	24
Gambar 4. 8 Hasil pengujian dari 10% tes poin.....	25
Gambar 4. 9 Hasil pengujian dari 15% tes poin.....	28
Gambar 4. 10 Hasil pengujian dari 20% tes poin.....	28
Gambar 4. 11 Hasil pengujian dari 25% tes poin.....	29
Gambar 4. 12 Hasil pengujian dari 30% tes poin.....	29
Gambar 4. 13 Akumulasi performa model.....	31

DAFTAR TABEL

Tabel 4. 1 Distribusi prior probability variabel API	20
Tabel 4. 2 Distribusi conditional probability variabel Tekanan	21
Tabel 4. 3 Hasil inferensi probabilitas atribut tes $x=0$	26
Tabel 4. 4 Hasil inferensi probabilitas atribut tes $x=1$	26
Tabel 4. 5 Hasil inferensi probabilitas atribut tes $x=2$	27
Tabel 4. 6 Tabel performa model bayesian network	30



DAFTAR LAMPIRAN

Lampiran I. Dataset.....	38
Lampiran II. Distrbusi Data	39
Lampiran III. Hasil Pemodelan	40
Lampiran IV. Link GitHub	42



Dokumen ini adalah Arsip Milik :
Perpustakaan Universitas Islam Riau

DAFTAR SINGKATAN

AI	Artificial Intelligent
AOP	<i>Asphatene Onset Pressure</i>
BN	Bayesian Network
BDeu Score	Bayesian Dirichlet Equivalent Uniform Score
CPD	Conditional Probability Distribution
DAG	Direct Acyclic Graph
HC	Hill Climbing
NB	Naïve Bayes
PGM	Probabilistic Graphical Model
RF	Random Forest



DAFTAR SIMBOL

$^{\circ}\text{F}$	Fahrenheit
p	Probabilitas
$\%wt$	Weight percent



Dokumen ini adalah Arsip Milik :
Perpustakaan Universitas Islam Riau

PREDIKSI ENDAPAN *ASPHALTENE* MENGGUNAKAN *MACHINE LEARNING* DENGAN METODE *BAYESIAN NETWORK*

IRFAN DINO

163210109

ABSTRAK

Endapan *asphaltene* adalah salah satu penyebab permasalahan produksi terjadi, karena endapan *asphaltene* mampu merubah karakteristik formasi dan menyebabkan *plugging* pada *surface facilities*. Dalam mengatasi masalah tersebut dibutuhkan perhitungan untuk mengetahui nilai variabel yang mempengaruhi presipitasi dari *asphaltene* dan besar nilai dari endapan *asphaltene* yang terbentuk. Prediksi dilakukan dengan metode *Artificial intelligent* dengan machine learning menggunakan metode klasifikasi *Bayesian Network*. Metode *Bayesian network* adalah *probabilistic graphical model* (PGM) yang memiliki struktur direct acyclic graph (DAG) yang menunjukkan hubungan peluang satu arah pada tiap variabel, setiap variabel digambarkan sebagai node dan hubungan sebab akibat dari tiap variabel dihubungkan dengan tanda panah atau disebut *arc* atau *edge*.

Dalam membangun *Bayesian Network*, struktur dibangun dengan mempertimbangkan pendekatan statistik yang disebut *conditional probability*. Pengaplikasian *Bayesian Network* dilakukan dengan menggunakan *Python* sebagai bahasa pemrograman dengan menggunakan *Jupyter Notebook* sebagai *open source* untuk mengolah serta memproses kode dan data serta menggunakan *pgmpy* sebagai *library* dalam pembuatan model. Model akan dibentuk pertama kali dengan menentukan struktur grafik berdasarkan *structure learning* dengan menggunakan algoritma *hill climbing* dengan menggunakan *scoring method* *BDeu score*, kemudian model *Bayesian network* akan dibangun sesuai dengan srstruktur yang telah ditentukan dengan menggunakan data training dengan bobot berbeda-beda, lalu melakukan *parameter learning* menggunakan *Bayesian parameter estimation* berdasarkan pendekatan probabilitas dari data berdasarkan struktur grafik.

Kemudian model *Bayesian network* yang telah dibangun akan diuji kemampuannya dalam memprediksi endapan *asphaltene* dengan melakukan inferensi menggunakan metode *variable elimination*, bobot dari data pengujian yang digunakan berbeda-beda yaitu dengan bobot sebesar 10%,15%,20%,25%, dan 30% dari total keseluruhan nilai atribut dari dataset dan dipilih secara acak. Kemampuan model yang dibangun untuk memprediksikan endapan *asphaltene* kemudian diukur performanya dengan *matric threshold accuracy*, Adapun nilai akurasi yang diperoleh dari tiap pengujian bervariasi dengan nilai rata-rata akurasi sebesar 64%.

Kata Kunci : Endapan *Asphaltene*, *Probabilistic Graphical Model*, *Bayesian Network*, *Parameter Learning*, Inferensi.

**PREDICTION OF ASPHALTENE DEPOSIT USING MACHINE LEARNING
WITH BAYESIAN NETWORK METHOD**

IRFAN DINO

163210109

ABSTRACT

Asphaltene deposits are one of the causes of production problems because asphaltene deposits are able to change the characteristics of formations and cause plugging on surface facilities. In solving the problem, it takes calculation to know the value of variables that affect the precipitation of asphaltene with the value of asphaltene precipitation formed. Prediction is made by an Artificial intelligent method with machine learning using the Bayesian Network classification method. The Bayesian network method is a probabilistic graphical model (PGM) that has a direct acyclic graph (DAG) structure that shows a one-way opportunity relationship on each variable, each variable is described as a node and the causality of each variable is associated with an arrow or called an arc or edge.

In building the Bayesian Network, structures are built taking into a statistical approach called conditional probability. Bayesian Network application using Python as a programming language and using Jupyter Notebook as an open-source to process code and data, and also use pgmpy as a python library in making some model. The model will be created first by determining the structure of the graph based on structure learning by using the hill-climbing algorithm by using BDeu score as the scoring method, then the Bayesian network model will be built according to the structure that has been determined by using training data with different weights, then doing learning parameters using Bayesian estimation parameters based on probability approach from data based on graph structure.

Then the Bayesian network model that has been built will be tested for its ability to predict asphaltene deposits by inference using the variable elimination method, the weight of the test data used varies by weight by 10%,15%,20%,25%, and 30% of the total attribute value of the dataset and selected randomly. The ability of the model built to predict asphaltene deposits is then measured performance with matric threshold accuracy, while the accuracy value obtained from each test varies with an average accuracy value of 64%.

Keywords: *Asphaltene Precipitate, Probabilistic Graphical Model, Bayesian Network, Parameter Learning, Inference.*

BAB I PENDAHULUAN

1.1 LATAR BELAKANG

Minyak mentah merupakan kumpulan dari beberapa fraksi yang terkandung seperti *wax*, *asphaltene*, aromatik hidrokarbon, resin, dan saturasi. Fraksi yang terkandung dalam minyak ini dapat menyebabkan masalah pada formasi ataupun fasilitas produksi. *Asphaltene* merupakan fraksi berat didalam minyak (Subramanian, Simon, & Sjöblom, 2016) dan memiliki sifat yang kompleks karena *asphaltene* tidak dapat menguap pada segala nilai temperatur dan *asphaltene* tidak memiliki *dew point* (Leontaritis & President, 2007). Perubahan tekanan dan temperature akan mengakibatkan resin pada permukaan *asphaltene* akan terlepas dan menyebabkan ketidak stabilan *asphaltene*, sehingga membentuk endapan yang dapat mengakibatkan peningkatan biaya produksi. Endapan *asphaltene* ini dapat menyebabkan turunnya nilai porositas dan permeabilitas, perubahan wettabilitas, dan menurunkan *sweep efficiency* pada formasi dan juga pada fasilitas endapan *asphaltene* dapat merusak pipa karena *plugging* yang terjadi di dalam pipa (Kamari, Safiri, & Mohammadi, 2015). Karena itu dibutuhkan perhitungan untuk memprediksi nilai dari endapan *asphaltene* agar masalah tersebut dapat diatasi dengan baik.

Banyak penelitian yang sudah dilakukan untuk mengetahui sifat dari *asphaltene*, baik dengan percobaan di laboratorium, perhitungan skala, menggunakan simulator, ataupun dengan machine learning. Darabi (2016) melakukan penelitian untuk melihat dampak dari variasi temperature terhadap dinamika dari *asphaltene*, menggunakan simulator CMG GEM, UTCOMP, dan UTCHEM untuk mengetahui perubahan *asphaltene* terhadap presipitasi, flokulasi, dan deposisi dari *asphaltene*. Penelitian yang dilakukan Zanganeh (2018) melalui visual dan modelling study dari proses injeksi gas berbahan CH₄, CO₂, dan N₂. Penelitian dilakukan dengan memasukkan sampel minyak sintetik kedalam *set-up tools*, kemudian sample minyak diuji dengan tekanan dan temperature yang berbeda, hasil yang diperoleh kemudian diolah kembali menggunakan simulator CMG Winprop, untuk dibuat model real dari sifat serta dinamika dari *asphaltene*.

Ahmadi, (2012) melakukan studi dengan menggunakan *artificial neural network* (ANN) yang disupport dengan *particle swarm object* (PSO). Model yang dibuat merupakan *back propagation network* yang telah dilakukan pendekatan Levenberg-Marquardt menggunakan parameter tekanan dan temperatur, yang di masukkan kedalam metode PSO sebagai algoritma optimasi *neural network* untuk memprediksi endapan *asphaltene*.

Menurut Mehryar Mohri (2013) ada lima tugas utama dari machine learning yaitu *classification, regression, ranking, clustering, dan dimensional reduction*. Salah satu metode klasifikasi adalah *Bayesian Network*. Klasifikasi *Bayesian Network* merupakan pengembangan model sederhana dari Naive Bayes (NB) (Minsky, 1961) perbedaannya adalah pada Naïve bayes merupakan korelasi antar nilai data suatu variabel, sedangkan pada *Bayesian Network* merupakan variabel input yang dapat saling berkaitan. *Bayesian Network* dapat digunakan untuk prediksi menggunakan pendekatan probabilitas (Mihaljevič, Bielza, & Larrañaga, 2019). Proses dari probabilitas sebuah data dikenal sebagai *probabilistic reasoning*. Data diolah dengan menyebarkan informasi baru melalui jaringan dikenal dengan metode *belief propagation* (Yu, Moharil, & Blair, 2020). Kelebihan dari *Bayesian Network* adalah lebih mudah dipahami dalam proses pengolahan data dan dapat digunakan untuk berbagai jenis kasus diberbagai bidang. Di dunia perminyakan *Bayesian Network* digunakan sebagai pendukung keputusan keuangan, optimasi *history matching*, dan memprediksi kumulatif produksi (Khaz'ali, Farahani, & Ahmadabadi, 2011).

Kinerja yang lebih baik telah ditunjukkan oleh *Bayesian Network* dibandingkan *neural network, support vector machine, decision trees* dan sebagainya pada klasifikasi tingkat lanjut seperti data mining, pemantauan kesalahan, bioinformatika dan sebagainya. *Bayesian Network* dapat menunjukkan hubungan sebab akibat dalam bentuk yang lebih mudah dipahami. (Mittal & Kassim, 2007). Bhattacharya (2018) melakukan pemodelan menggunakan aplikasi algoritma *machine learning Bayesian Network* (BN) dan *Random Forest* (RF) untuk memprediksi rekahan dan fasies menggunakan parameter data log dari Appalachian basin di Amerika Utara. Peneliti melakukan prediksi dengan

menggunakan 10 data logging yang diolah kedalam mesin algoritma, hasilnya pada prediksi fasies BN menghasilkan prediksi dengan tingkat akurasi 75% sedangkan RF menghasilkan akurasi yang lebih tinggi yaitu sekitar 81,9%, dan pada prediksi rekahan BN menghasilkan prediksi dengan akurasi sekitar 75,2% dan sekitar 71,2% untuk formasi Clinton dan Copper ridge, sedangkan RF menghasilkan prediksi dengan tingkat akurasi sekitar 80,5% untuk formasi yang sama. Dari hasil persentase memang RF menunjukkan lebih unggul dari pada BN, namun BN dapat mengungkapkan konsep hubungan sebab akibat yang rinci dari hubungan data petrofisik dengan hasil prediksi (fasies dan rekahan) sedangkan RF tidak. Dan RF juga memerlukan waktu komputasi yang lebih lama dari BN, Hal tersebut menunjukkan bahwa BN lebih efisien digunakan dalam memprediksi suatu masalah.

Penelitian ini dilakukan untuk memprediksi nilai dari endapan *asphaltene* dengan menghitung probabilitas dari hubungan setiap parameter terhadap terbentuknya endapan *asphaltene*, parameter yang digunakan adalah komposisi pelarut serta tekanan dengan *Bayesian Network* seperti yang dilakukan oleh Sayyad Amin (2010), namun menggunakan *Jupyter notebook* dan menambahkan parameter temperatur sebagai parameter yang dianggap dapat mempengaruhi terbentuknya endapan *asphaltene*. Tujuannya adalah untuk mendapatkan informasi dari sampel yang digunakan dan hubungannya terhadap parameter yang diuji, agar dapat mencegah serta meminimalisir kerusakan yang terjadi pada formasi maupun fasilitas produksi yang ditimbulkan oleh endapan *asphaltene*.

1.2 TUJUAN PENELITIAN

Adapun tujuan dari penelitian Tugas Akhir kali ini adalah:

1. Untuk mengetahui hubungan komposisi minyak, variasi nilai tekanan, dan nilai temperatur terhadap terbentuknya endapan *asphaltene*.
2. Untuk memprediksi nilai dari endapan *asphaltene*.

1.3 MANFAAT PENELITIAN

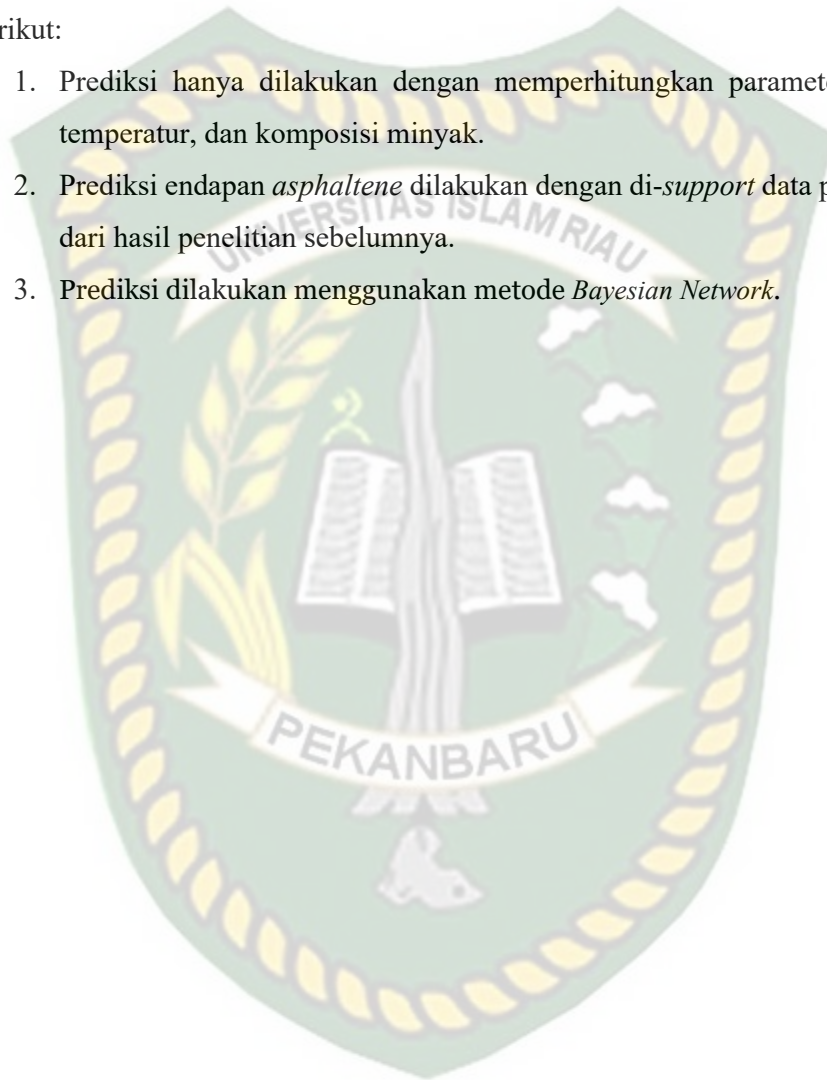
Penelitian Tugas Akhir kali ini diharapkan dapat dimanfaatkan sebagai alternatif metode yang dapat dilakukan dalam memprediksi dan mengetahui sifat

dari endapan *asphaltene* sehingga dapat meminimalisir masalah yang ditimbulkan baik didalam formasi ataupun difasilitas produksi.

1.4 BATASAN MASLAH

Agar penelitian ini dapat menghasilkan nilai yang lebih terarah dan sesuai dengan tujuan, maka penelitian dibatasi pembahasan mengenai beberapa hal berikut:

1. Prediksi hanya dilakukan dengan memperhitungkan parameter tekanan, temperatur, dan komposisi minyak.
2. Prediksi endapan *asphaltene* dilakukan dengan di-*support* data pengalaman dari hasil penelitian sebelumnya.
3. Prediksi dilakukan menggunakan metode *Bayesian Network*.



BAB II TINJAUAN PUSTAKA

Bersyukur kepada ALLAH SWT dengan mengucapkan “Alhamdulillah” kita telah diberikan kesempatan untuk menjalani hidup dengan segala rahmat, taufik, serta hidayahNya. Begitu besar kasih sayang ALLAH SWT kepada kita yang telah memberikan akal dan pikiran untuk digunakan, salah satunya yang kita telah rasakan pada saat ini adalah kemajuan teknologi yang mempermudah setiap pekerjaan kita, yang merupakan hasil perkembangan pikiran yang merupakan anugerah yang diberikan ALLAH SWT. Salah satu perkembangan teknologi berupa komputer dan menerapkan kecerdasan buatan atau lebih dikenal dengan *Artificial Intelligent*.

Kecerdasan buatan ini (AI) sangat berguna dalam mempermudah segala urusan manusia pada saat ini. Seperti yang telah dijelaskan pada Al-qur'an didalam surah alam nasyrah ayat 5-6:

“*Karena sesungguhnya sesudah kesulitan ada kemudahan. Sesungguhnya sesudah kesulitan itu ada kemudahan.*” (QS. Al – Insyirah(94): ayat 5-6).

Dengan perkembangan teknologi saat ini maka sangatlah mungkin untuk mendapatkan berbagai kemudahan dari penggunaan teknologi secara baik dan benar. Oleh karena itu penerapan *Machine learning* berbasis algoritma *Bayesian network* dibutuhkan untuk mempermudah pengelolaan data dalam membuat model prediksi terhadap suatu masalah. Dengan penelitian ini diharapkan mampu memberikan solusi agar dapat mengetahui perilaku minyak terhadap terbentuknya endapan *asphaltene*.

2.1 ENDAPAN ASPHALTENE

Asphaltenes adalah fraksi minyak terberat dan paling terpolarisasi dalam hal kelarutannya. sesuai dengan standar ASTM D6560 dan IP 143 partikel *asphaltene* mewakili fraksi yang tidak dapat larut seperti n-heptana dari minyak. *Asphaltene* dapat larut di dalam pelarut aromatik seperti *toluene* dan *xylene* (Vargas et al., 2014). Perubahan termodinamika, seperti temperatur, tekanan, dan komposisi minyak, menyebabkan penyusutan lapisan resin yang mengakibatkan partikel

asphaltene saling bersentuhan, menyebabkan ketidak stabilan larutan dan endapan mampu keluar dari *crude oil*. (Na'imi, 2014)

Resin merupakan pecahan dari minyak *desasphalted* yang teradsorpsi pada permukaan aktif dari materi seperti silika, alumina, atau *Fuller's earth*, dan hanya bisa diserap pelarut seperti *pyridine* atau campuran metanol dan toluene. Resin dan *asphaltene* memiliki sifat *heterocompounds* dengan substitusi alifatik dan membentuk fraksi polar dari minyak mentah. Resin memiliki kecenderungan yang kuat untuk diasosiasikan dengan *asphaltene* dan menentukan kelarutan dalam minyak. (Buenrostro, 2004)

Penambahan molekul dapat merubah komposisi dari minyak mentah yang dapat menyebabkan endapan *asphaltene*, penambahan molekul yang berbeda dari *asphaltene* dan resin baik dalam struktur, ukuran, mengakibatkan parameter kelarutan berubah dari kondisi kesetimbangan yang terdapat pada bagian nonpolar dari minyak mentah. Contohnya penambahan cairan alkana (C5, C6, dan C7) sering ditambahkan kedalam minyak mentah untuk mengurangi viskositas dari minyak berat (Hammami, 2007).

Volume molar parsial dari sebuah molekul seperti metana berubah secara nyata bila dibandingkan dengan pentana karena tekanan yang menurun secara isothermal. Perubahan volume yang minim dapat juga dilihat pada C7-C12. Dapat dibayangkan fraksi yang lebih berat seperti resin dan *asphaltene* juga akan menunjukkan penurunan volume molar parsial relative namun kecil akibat pengaruh dari penurunan tekanan.

2.2 ALGORITMA BAYESIAN NETWORK

Bayesian Network adalah sebuah representasi tingkat tinggi dari distribusi variable yang digunakan untuk membangun model dari suatu masalah. Metode ini digunakan dalam berbagai aplikasi *artificial intelligent* (AI) dan menawarkan penyelesaian masalah secara probabilitas (Mittal & Kassim, 2007). *Bayesian Network* merupakan *probabilistic graphical model* (PGM) sederhana yang dibangun dari teori *probabilistic* dan teori graf, untuk struktur graf *Bayesian network* disebut juga sebagai *direct acyclic graph* (DAG) yaitu graf yang berarah

dan tidak mengandung siklus (Suryana, Suryani, Paulus, & Rosadi, 2018). Aplikasi *Bayesian Network* telah sering digunakan diberbagai bidang seperti ekonomi, ilmu sosial, biologi, dan informasi medis (Choi, 2015). Dengan menggunakan teori probabilitas, Bayesian dapat mendeskripsikan ketidakpastian didalam parameter sebuah model atau dalam pemilihan model itu sendiri (Bidhop, 2004). Bentuk dari teorema Bayesian adalah:

$$p(w|D) = \frac{p(w|D)p(w)}{p(D)} \quad (2.1)$$

Untuk dapat mengevaluasi ketidak pastian hubungan (w) dan data observasi (D), maka dibuat bentuk dari *posterior* probabilitas $p(w|D)$ yang disebut *likelihood function*. Berdasarkan rumus (2.1) perhitungan dapat didefinisikan menjadi:

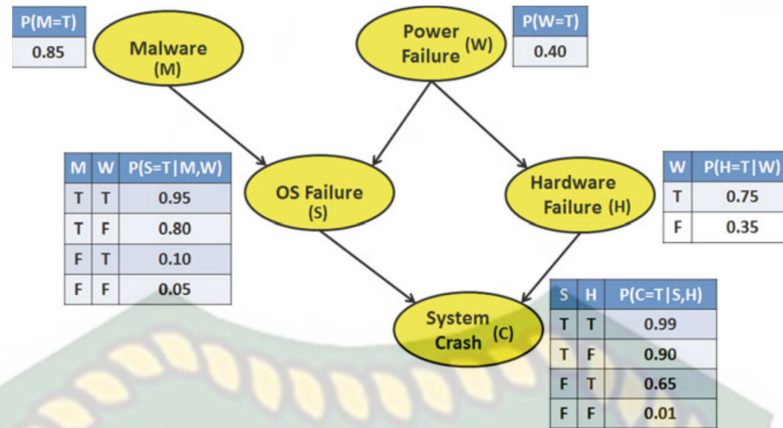
$$posterior \propto likelihood \times prior \quad (2.2)$$

Rumus (2.1) penyebutnya dapat diekspresikan dalam Bayesian pada distribusi *prior* dan fungsi *likelihood*:

$$p(D) = \int p(D|w)p(w)dw \quad (2.3)$$

Didalam pola perhitungan Bayesian, fungsi dari probabilitas $p(D|w)$ memiliki peran penting. didalam Bayesian hanya ada satu kumpulan data D (yang benar-benar diamati) dan melalui distribusi perobabilitas (w) dapat mengekspresikan ketidakpastian dari suatu parameter.

Jaringan bayes (BN) adalah model dari grafik probabilitas yang dimana node mewakili variabel kontinu atau diskrit dan busur sebagai tanda koneksi kausal atau sebab akibat antar variabel. BN dapat secara langsung menangkap informasi probabilistik dari data dengan menggunakan struktur grafis (Weber, 2016). Seperti contoh sederhana dari hubungan sebab akibat lima variabel berikut:



Gambar 2.1 Bayesian (belief) network (Weber, 2016)

Gambar 2.1 diatas menjelaskan bahwa *Power failure* (W), *malware* (M), *OS Failure* (S), *system failure* (C), dan *hardware failure* (H). hubungan kausal pada variabel tersebut diartikan: kegagalan daya dan *malware* menyebabkan kegagalan *OS*; kegagalan daya dapat menyebabkan kegagalan *hardware*; kegagalan *OS* dan *Hardware* dapat menyebabkan kegagalan *system*. Seperti pada Gambar 2.1, BN berbentuk seperti grafik yang terdiri dari node (simpul) yang menunjukkan variabel beserta nilai probabilitasnya dan arc (busur) sebagai penunjuk hubungan antar simpul (Windarti & Suradi, 2019).

Untuk kondisi distribusi pada Gambar 2.1 aturan dapat dijelaskan kedalam rumus probabilitas *Bayesian Network* sebagai:

$$p(C, H, M, S, W) = p(C|H, S)p(S|M, W)p(H|W)p(M)p(W) \quad (2.4)$$

Sehingga rumus umum untuk *Bayesian Network* dapat ditulis dengan:

$$p(x_1, \dots, x_n) = \prod_{i=1}^n p(x_i | pa(x_i)) \quad (2.5)$$

Berikut merupakan contoh dalam perhitungan dengan menggunakan metode *Bayesian Network*. Nilai probabilitas terjadinya *OS Failure* (S) bila diketahui *Power failure* (W) terjadi:

$$p(S|W) = p(S|M, W)p(M) + p(S|\sim M, W)p(\sim M)$$

$$p(S|W) = 0,95 * 0,85 + 0,1 * 0,15 = 0,8225$$

Penelitian yang dilakukan Spalburg (2004) menggunakan implementasi Bayesian berdasarkan algoritma Markov Chain Monte Carlo untuk mengurangi nilai evaluasi dari logging, akibat dari perbedaan litologi menghasilkan perbedaan interpretasi dan model. Peneliti menggabungkan data geologi, geofisika, dan produksi kedalam algoritma Monte Chain Monte Carlo sebagai bentuk modifikasi dari distribusi probabilitas untuk evaluasi parameter dan model, serta mempercepat analisa dari pengurangan ketidakpastian dari evaluasi data log. Hasil yang diperoleh menunjukkan bahwa metode Bayesian sukses diterapkan untuk evaluasi log dan memungkinkan ahli petrofisika untuk mengurangi ketidakpastian informasi yang diperoleh dari alat logging.

Rajaieyamchee (2010) melakukan penelitian untuk mencari informasi dalam menentukan penempatan sumur horizontal karena mempertimbangkan beberapa tujuan, seperti biaya pemboran, konfigurasi lubang sumur dan produksi dimasa depan. Untuk membuat keputusan tersebut metode yang digunakan adalah *Bayesian Disicion Network* atau dikenal dengan diagram pengaruh, untuk menganalisa, membatasi, dan mendukung keputusan operasional. Peneliti melakukan analisa dengan menggunakan parameter yaitu data sensor dan data model dari *subsurface*. Kemudian memfokuskan kepada dua diagram pengaruh, yaitu *multiple-attribute utility influence diagram* (MAUID) dan *multiple objective influence diagram* (MOID) sebagai pendekatan yang potensial. Hasil dari Analisa yang dilakukan menunjukkan MAUID sebagai alat yang layak untuk mendukung keputusan dalam menentukan penempatan sumur horizontal.

Zerifat (2011) menggunakan metode Bayesian sebagai alat untuk melakukan screening EOR. Peneliti menggunakan berbagai parameter seperti data simulasi reservoir, aliran fluida pada media berpori, percobaan laboratorium, dan pengalaman skala lapangan yang ada, yang diekstraksi dan kemudian digabungkan dengan *screeening table* yang ada sehingga menjadi suatu nilai terpadu, yang dapat menentukan teknik EOR yang tepat, untuk digunakan sebagai informasi lebih lanjut untuk penilaian berdasarkan kriteria ekonomi dan lingkungan. Peneliti menggunakan dua tabel untuk diimplementasikan kedalam model jaringan, data pertama dihasilkan dari data tabel dan data kedua merupakan laporan dari proses

EOR yang telah berhasil diseluruh dunia. Hasil penelitian yang dilakukan menunjukkan banyaknya data tersedia ternyata sangat menentukan keakuratan dan kurangnya data yang memadai mengakibatkan salah prediksi. Jaringan diuji dengan 10% dari data yang dihapus dari kumpulan data. Hasilnya relatif dapat diterima terhadap jumlah data yang digunakan untuk pengujian.

Kemudian Fanailoo (2016) menjelaskan mengenai penggunaan *Bayesian Networks* dengan model MARV. dimana model MARV ini merupakan metodologi penilaian resiko yang memanfaatkan data sensor, model berbasis fisika, dan data statistik dari kegagalan yang terjadi pada masa lampau, Metode dengan model MARV ini menjadi metode yang bisa mengatasi batasan data yang tidak lengkap ataupun tidak tepat tetapi menawarkan prediksi yang akurat mengenai kegagalan yang akan terjadi. Sebelum adanya *Bayesian Network* ini, terdapat beberapa teknik untuk menganalisis resiko. teknik-teknik ini mempunyai kelebihan dan kekurangan masing-masing yaitu FMECA (Failure Modes and Effects Criticality Analysis), HAZOP (Hazard Operations) and HAZID (Hazard Identification), Fault Tree Analysis (FTA), Namun *Bayesian Network* adalah salah satu teknik yang mampu menggabungkan banyak keunggulan dari metode-metode sebelumnya.

Pada penelitian yang dilakukan Sayyad Amin et al. (2010) untuk mempelajari efek perbedaan dari parameter pada endapan *asphaltene*, peneliti melakukan pemodelan dengan menggunakan *software Netica* yang merupakan sebuah *artificial intelligence modeling tool* berbasis *Bayesian Belief Network* (BBN). dalam model ini rasio pengencer, tekanan, dan berat molekul berperan sebagai *parent node* dan persen berat *asphaltene* berperan sebagai *child node*, 80% data (560 data) telah diseleksi secara acak untuk digunakan pada model BBN. Sisanya 20% data digunakan untuk uji coba kedalam model prediksi. Rata-rata nilai error relative kecil (4.5%) yang mengindikasikan validitas dan kecocokan performa model. Dari hasil yang ditemukan dengan model BBN telah mampu mempertimbangkan efek perbedaan dilution ratio pada endapan *asphaltene* dan pada perbandingan untuk n-hexane dan n-heptane, grafik menjelaskan hasil yang lebih baik diantara data percobaan dan prediksi model BBN yang dibandingkan dengan prediksi dari *scaling model*.

2.3 *PYTHON LANGUAGE*

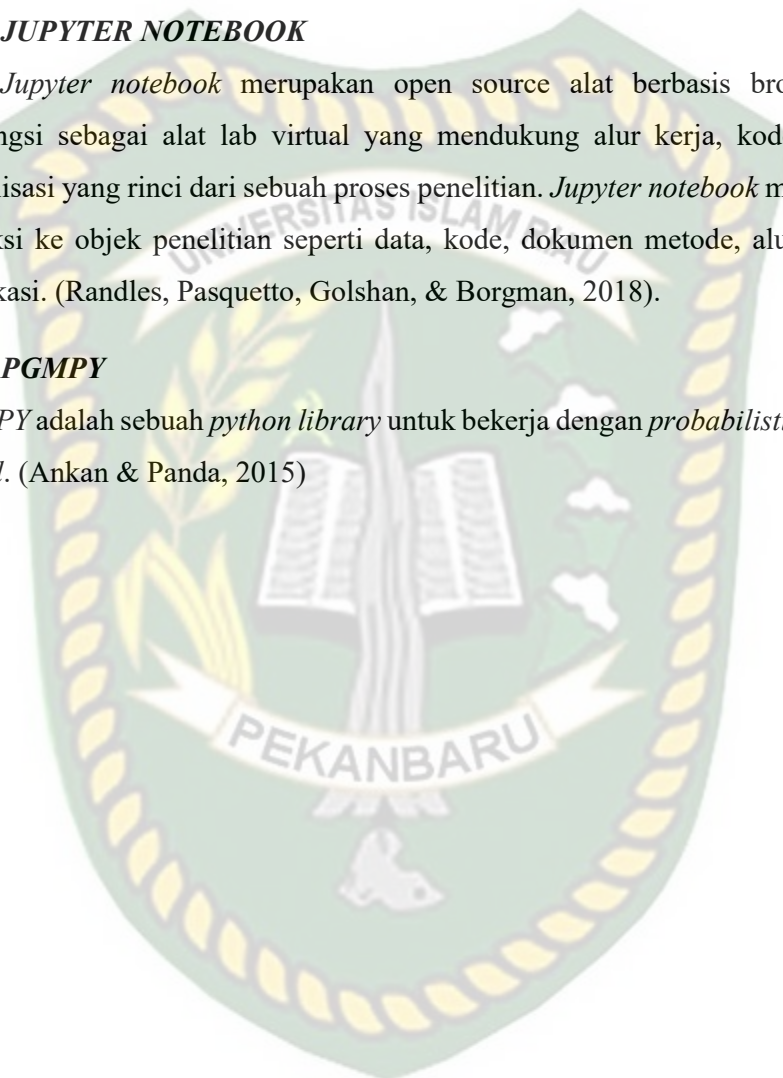
Python merupakan Bahasa pemrograman berorientasi pada interpretasi, objek orientasi, dan interaktif. *Python* memiliki syntax yang sangat sederhana namun merupakan Bahasa pemrograman yang kuat dan bertujuan umum, dirancang oleh Guido van Rossum pada tahun 1990. (Sanner, 1999)

2.4 *JUPYTER NOTEBOOK*

Jupyter notebook merupakan open source alat berbasis browser yang berfungsi sebagai alat lab virtual yang mendukung alur kerja, kode, data dan visualisasi yang rinci dari sebuah proses penelitian. *Jupyter notebook* menyediakan koneksi ke objek penelitian seperti data, kode, dokumen metode, alur kerja dan publikasi. (Randles, Pasquetto, Golshan, & Borgman, 2018).

2.5 *PGMPY*

PGMPY adalah sebuah *python library* untuk bekerja dengan *probabilistic graphical model*. (Ankan & Panda, 2015)



BAB III METODOLOGI PENELITIAN

3.1 LOKASI PENELITIAN

Pada penelitian kali ini dilakukan di laboratorium komputer Teknik Perminyakan Universitas Islam Riau. Adapun data yang digunakan berasal dari data yang dikumpulkan dari berbagai jurnal penelitian mengenai endapan *asphaltene* kemudian digabungkan menjadi satu himpunan table data yang padu yang digunakan sebagai data set dan akan diolah kedalam model *Bayesian Network* yang akan dibuat. Berikut merupakan data set yang akan diproses untuk dibangun model *Bayesian Network*-nya:

```
In [4]: print(data_set)
```

	API	Tekanan	Temperatur	H2S*	N2*	CO2*	C1*	C2*	C3*	\
0	19.00	1014.7	212.0	34.08	28.013	44.01	16.043	30.07	44.097	
1	19.00	2014.7	212.0	34.08	28.013	44.01	16.043	30.07	44.097	
2	19.00	3034.7	212.0	34.08	28.013	44.01	16.043	30.07	44.097	
3	19.00	4014.7	212.0	34.08	28.013	44.01	16.043	30.07	44.097	
4	24.00	514.7	218.0	34.08	28.013	44.01	16.043	30.07	44.097	
..
177	41.38	2014.7	158.5	34.08	28.013	44.01	16.043	30.07	44.097	
178	41.38	2214.7	158.5	34.08	28.013	44.01	16.043	30.07	44.097	
179	41.38	2414.7	158.5	34.08	28.013	44.01	16.043	30.07	44.097	
180	41.38	2614.7	158.5	34.08	28.013	44.01	16.043	30.07	44.097	
181	41.38	2814.7	158.5	34.08	28.013	44.01	16.043	30.07	44.097	

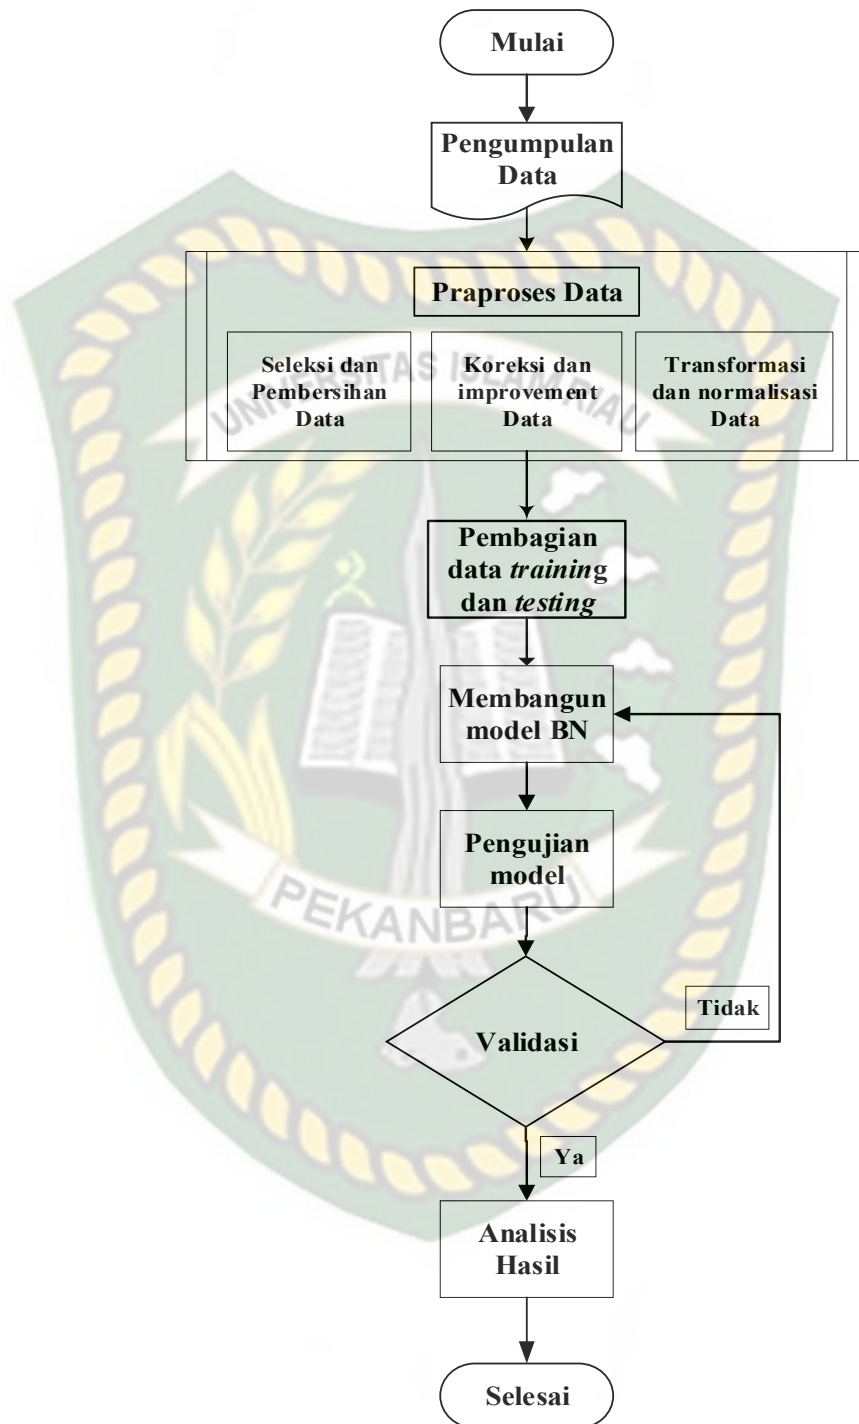
	i-C4*	...	C6	C7	C7+	C30+	C33+	SG	Average MW Oil	\
0	58.124	...	1.62	2.73	47.96	12.46	10.45	0.9594	203.8	
1	58.124	...	1.62	2.73	47.96	12.46	10.45	0.9594	203.8	
2	58.124	...	1.62	2.73	47.96	12.46	10.45	0.9594	203.8	
3	58.124	...	1.62	2.73	47.96	12.46	10.45	0.9594	203.8	
4	58.124	...	3.16	4.71	66.86	12.35	9.91	0.9020	202.4	
..
177	58.124	...	2.58	16.20	69.65	0.16	NaN	0.8308	193.5	
178	58.124	...	2.58	16.20	69.65	0.16	NaN	0.8308	193.5	
179	58.124	...	2.58	16.20	69.65	0.16	NaN	0.8308	193.5	
180	58.124	...	2.58	16.20	69.65	0.16	NaN	0.8308	193.5	
181	58.124	...	2.58	16.20	69.65	0.16	NaN	0.8308	193.5	

	Asp. Precipitation	References	Tab
0	0.403000	burke1990	tabel 5
1	1.037000	burke1990	tabel 6
2	0.742000	burke1990	tabel 7
3	0.402000	burke1990	tabel 8
4	0.200000	burke1990	tabel 6
..
177	0.001707	TA dinda asmara2014	fig. 4.6
178	0.001426	TA dinda asmara2014	fig. 4.6
179	0.001108	TA dinda asmara2014	fig. 4.6
180	0.000754	TA dinda asmara2014	fig. 4.6
181	0.000365	TA dinda asmara2014	fig. 4.6

[182 rows x 38 columns]

Gambar 3. 1 Data

3.2 FLOWCHART



Gambar 3. 2 Diagram alir

3.3 JENIS PENELITIAN

Penelitian ini dilakukan dengan metode komputasi dengan membuat program, dengan menggunakan Bahasa *Python* lewat komputer untuk membuat model berdasarkan algoritma *Bayesian network*. Dengan metode ini peneliti dapat membuat model yang diinginkan. Adapun alat dan bahan yang digunakan selama penelitian dilakukan adalah sebagai berikut:

3.3.1. Alat

- a. Personal komputer dengan spesifikasi:
- b. Prosesor Core 3 (atau diatasnya)
- c. Minimal memory 1 GB
- d. Hardisk minimal 8 GB

3.3.2. Bahan

1. *Python* versi 3.8
2. Jaringan internet aktif
3. Data lapangan yang akan diteliti, seperti:
 - a. Data tekanan
 - b. Data Temperatur
 - c. Komposisi dari sampel yang akan diuji.

3.4 METODE PENELITIAN

Adapun metode yang dilakukan selama penelitian adalah sebagai berikut:

3.4.1. Pengumpulan Data

Pengumpulan data berupa komposisi fluida, tekanan, dan temperatur yang diperoleh dari berbagai sumber jurnal penelitian sebelumnya yang terkait dengan endapan *asphaltene* guna diproses untuk membangun sebuah model *Bayesian Network*. Secara umum dataset yang dihimpun merupakan data yang telah dikumpulkan dari berbagai jurnal ilmiah terkait eksperimen dan simulasi yang melakukan pengamatan pada sifat fluida minyak terhadap perubahan termodinamika yang menyebabkan terbentuknya endapan *asphaltene*. Kriteria data yang dikumpulkan merupakan data pada pengamatan termodinamika saja, tanpa memasukkan data pada sampel yang dititrasi *solvent*.

3.4.2. Praproses Data

Setelah dataset terkumpul, data tersebut perlu dilakukan *treatment* terlebih dahulu agar mempermudah memahami data, meningkatkan kualitas data, dan meningkatkan efisiensi dan kemudahan dalam memproses data. Adapun tiga jenis praproses data yang akan dilakukan yaitu:

1. Seleksi dan Pembersihan Data

Proses seleksi dan pembersihan data merupakan proses dalam memilih atribut agar mendapatkan data yang berkualitas, sehingga dapat menghasilkan model prediktif yang baik. Adapun hal yang dilakukan pada proses ini adalah meliputi pemilihan atribut data kolom yang tidak memiliki satu nilai, variasi nilai yang sedikit, memiliki nilai data yang sedikit, dan menyeleksi kolom yang memiliki duplikasi data. Kemudian melakukan evaluasi data *outlier* dan melakukan evaluasi data yang hilang pada kolom.

2. Koreksi dan *Improvement* Data

Merupakan proses memeriksa dan memperbaiki data apabila terdapat nilai yang inkonsisten dan kesalahan pada data.

3. Transformasi dan Normalisasi Data

Merupakan proses mengubah data yang belum memiliki entitas jelas kedalam bentuk data yang valid dan serta mengurangi jarak yang terlalu jauh antar data. Adapun transformasi data yang dilakukan adalah mengelompokkan fraksi minyak kedalam empat kategori yaitu “*non-HC gas*” yang merupakan gabungan dari data %mole dari H₂S, N₂, dan CO₂. Untuk kategori “*Light*” merupakan gabungan dari %mole dari fraksi C1 hingga C3, “*Intermediate*” merupakan gabungan dari fraksi i-C4 hingga C6, dan “*Heavy*” merupakan fraksi C7+.

3.4.3. Pembagian Data

Merupakan proses membagi data menjadi dua bagian yaitu data *training* dan data *testing* dengan bobot berbeda-beda. Data *training* merupakan data yang akan digunakan dalam melatih model yang akan dibangun, sedangkan data *testing* merupakan data yang akan digunakan sebagai nilai input untuk menguji kemampuan model dalam memprediksi berdasarkan model yang telah dilatih.

3.4.4. Membangun Model BN

Dalam membangun sebuah model *Bayesian Network* menggunakan *pgmpy*, Langkah-langkah yang akan dilakukan sebagai berikut:

1. Struktur Grafik

Pada penelitian kali ini pembentukan struktur grafik *Bayesian Network* dilakukan dengan cara melakukan *structure learning* dengan pendekatan *scoring*, yaitu metode pencarian dalam membangun dan mengevaluasi model berdasarkan nilai skor. Adapun metode *scoring* yang dilakukan adalah dengan algoritma *Hill climbing* (HC). Adapun yang dilakukan algoritma HC adalah memberikan penilaian terhadap parameter input dan menentukan keterhubungan dari masing-masing parameter, adapun metode *scoring* yang dipakai adalah *BDeu score*.

2. Membangun Model

Model *Bayesian Network* dibangun berdasarkan struktur grafik yang telah ditentukan. Proses ini dilakukan dengan membuat kode perintah kedalam sistem, sehingga sistem akan memproses perintah yang diberikan untuk membangun sebuah model *Bayesian network*. Perintah yang diberikan terkait dengan hubungan *Child node* dan *Parent node* sesuai struktur grafik yang telah dibangun.

3. Melakukan *Parameter Learning*

Setelah model untuk endapan *asphaltene* terbentuk, selanjutnya adalah melakukan perhitungan parameter untuk mendapatkan *prior probability* dan *conditional probability distribution* (CPD), yaitu tabel yang merepresentasikan nilai probabilitas dari varabel, pada perhitungan *parameter learning* metode yang digunakan adalah *Bayesian parameter estimation*.

3.4.5. Pengujian dan Analisa

Prediksi dilakukan untuk menguji model yang telah dibangun dengan memasukkan data baru kedalam sistem untuk mengetahui nilai dari endapan *asphaltene* melalui perhitungan oleh sistem berdasarkan model algoritma *Bayesian Network* yang telah dibangun. Kemudian melakukan pengujian tingkat akurasi dari hasil prediksi yang dibandingkan dengan data aslinya, digunakan sebagai pengukur performa dari model yang telah dibangun. Untuk menguji model klasifikasi yang

dihasilkan model dilakukan dengan *threshold matrix* untuk mengukur kesalahan prediksi. *Threshold matrix* didesain untuk meringkas fraksi, rasio, atau laju ketika kelas yang diprediksi tidak cocok dengan kelas yang diharapkan dalam kumpulan data yang tidak dapat diakses (Brownlee, 2020). Untuk *matrix threshold* yang paling sering digunakan adalah akurasi klasifikasi:

$$\text{Accuracy} = \frac{\text{Correct Predictions}}{\text{Total Prediction}} \quad (3.1)$$

3.5 JADWAL KEGIATAN PENELITIAN

Kegiatan	Waktu Pelaksanaan (per Minggu)											
	April				Mei				Juni			
	1	2	3	4	5	6	7	8	9	10	11	12
Studi Literatur	■	■	■	■	■	■						
Pembuatan Proposal Penelitian				■	■	■						
Pengumpulan dan Pengolahan Data					■	■	■	■				
Pembuatan Model								■	■	■		
Analisis & Pembuatan Laporan Hasil Akhir									■	■	■	■

BAB IV HASIL DAN PEMBAHASAN

Pada bab ini akan dijelaskan hasil dan pembahasan yang diperoleh dari penelitian yang berjudul “Prediksi Endapan *Asphaltene* Menggunakan *Machine Learning* Dengan Metode *Bayesian Network*”. Bab ini akan menjelaskan hasil dari proses perancangan model *Bayesian Network* yang digunakan sebagai model untuk melakukan prediksi endapan *asphaltene*, tahapan pengujian yang akan dilakukan, serta hasil yang didapat dari tiap pengujian model.

4.1 DATA

Dalam pembuatan sebuah model *machine learning* data merupakan faktor yang sangat penting oleh karena itu dibutuhkan data dengan kualitas baik agar dapat menghasilkan model prediksi yang menghasilkan output yang baik pula. Adapun data yang akan digunakan telah melalui beberapa tahapan praproses data, sehingga data yang awalnya terkumpul sebanyak 34 variabel dengan jumlah atribut tiap variabel sebesar 182 nilai data, menjadi 8 variabel dengan 145 atribut data. Adapun variabel dari data yang akan dimasukkan kedalam sistem guna membangun model prediksi algoritma *Bayesian network* adalah tekanan (Psia), temperatur (°F), endapan asphaltene (wt%), serta % mole komponen minyak yaitu non-HC gas, light, intermediate, heavy. Berikut merupakan sebagian dari data set yang akan digunakan yang akan ditampilkan pada gambar dibawah ini:

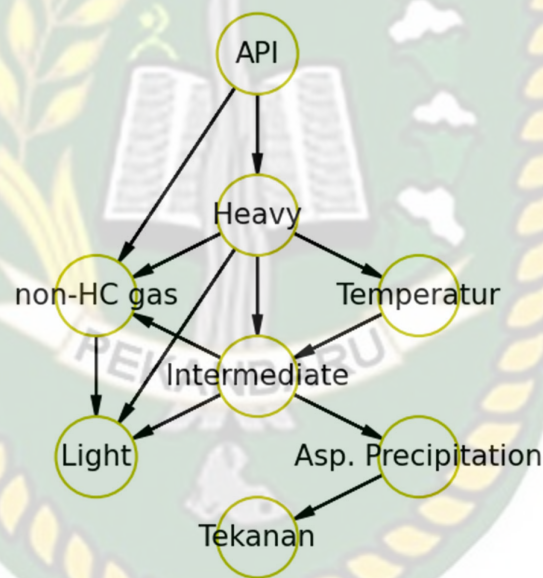
	Tekanan	Temperatur	non-HC gas	Light	Intermediate	Heavy	API	Asp. Precipitation
6	3000	240	8	30	18	55	30	0.0
7	4000	240	10	50	12	35	36	0.0
8	3000	150	13	50	12	35	38	0.6
9	2000	120	13	50	12	35	38	0.6
16	0	210	4	40	16	55	20	1.0
...
177	2000	150	0	30	8	70	42	0.0
178	2000	150	0	30	8	70	42	0.0
179	2000	150	0	30	8	70	42	0.0
180	3000	150	0	30	8	70	42	0.0
181	3000	150	0	30	8	70	42	0.0

145 rows × 8 columns

Gambar 4. 1 Data set setelah melalui praproses data.

4.2 STRUKTUR GRAFIK

Pembuatan model diawali dengan membangun struktur grafik untuk model prediksi endapan *asphaltene*. Pembangunan struktur grafik dilakukan dengan cara melakukan metode *scoring* yaitu sebuah metode penilaian pada tiap-tiap variabel kemudian berdasarkan penilaian tersebut sistem akan menyimpulkan hubungan keterkaitan pada masing-masing variabel. Proses penilaian tersebut dilakukan dengan menggunakan algoritma *hill climbing* sebagai kelas heuristik untuk pencarian DAG dengan mempelajari struktur jaringan data dan mengestimasi penemuan model dengan skor yang optimal. Dalam melakukan *structure learning* data, algoritma *hill climbing* di-support dengan metode penilaian BDeu score sebagai metode skor untuk mengukur seberapa baik model mampu menggambarkan kumpulan data yang diberikan.



Gambar 4. 2 Struktur grafik model BN

Dapat dilihat hubungan struktur dari model prediksi *asphaltene* yang direkomendasikan oleh sistem berdasarkan pembelajaran yang dilakukan tentang hubungan keterkaitan data input dengan melakukan penilaian data menggunakan algoritma *hill climbing* dan metode penilaian BDeu score bahwa variabel “API gravity” merupakan *parent node* yang memiliki *child node* variabel “Heavy” dan “non-HC gas”, untuk variabel “Heavy” merupakan *parent node* dari tiga variabel

yaitu variabel “non-HC gas”, “intermediate”, dan “Temperatur”, sedangkan variabel “non-HC gas” memiliki satu *child node* yaitu “Light” dan temperatur memiliki *child node* “Intermediate”, variabel “inter mediate memiliki tiga *child node* “non-HC gas”, “Light”, dan “Asp. Precipitation”, kemudian parameter “Asp. Precipitation” memiliki *child node* variabel “Tekanan”. Untuk keseluruhan struktur model yang disarankan sistem memiliki nilai skor sebesar -993,42922958.

4.3 **PARAMETER LEARNING**

Setelah struktur dari model dibangun dilakukan perhitungan dari tiap *node* untuk menghasilkan nilai probabilitas dari tiap variabel. Pada perhitungan *parameter learning* dilakukan dengan menggunakan metode *Bayesian parameter estimation*, yaitu perhitungan yang dilakukan dengan data *training* yang telah diinput dan melakukan perhitungan probabilitas berdasarkan hubungan yang telah ditentukan pada struktur model dalam menentukan nilai CPD (*Conditional Probability Distribution*) dan *Prior Probability Distribution*. Berikut merupakan salah satu hasil dari perhitungan *parameter learning* dari salah satu variabel input dengan data *training* sebesar 130 (90% dataset) atribut:

Tabel 4. 1 Distribusi prior probability variabel API

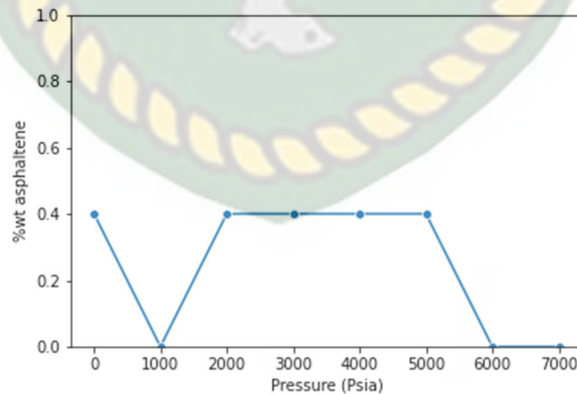
API (20)	0,108333
API (30)	0,012037
API (32)	0,0416667
API (34)	0,537963
API (36)	0,012037
API (38)	0,108333
API (40)	0,0416667
API (42)	0,137963

Tabel 4. 2 Distribusi *conditional probability* variabel Tekanan

Asp. Precipitation	Asp. Precipitation (0,0)	Asp. Precipitation (0,2)	Asp. Precipitation (0,4)	Asp. Precipitation (0,6)	Asp. Precipitation (0,8)	Asp. Precipitation (1,0)
Tekanan (0)	0,02358	0,00658	0,06357	0,15211	0,18929	0,28804
Tekanan (1000)	0,25845	0,32237	0,02261	0,07982	0,53214	0,28804
Tekanan (2000)	0,2371	0,06974	0,24787	0,29669	0,18929	0,02717
Tekanan (3000)	0,15169	0,00658	0,18643	0,15211	0,01786	0,28804
Tekanan (4000)	0,08763	0,06974	0,32978	0,2244	0,01786	0,02717
Tekanan (5000)	0,02358	0,38553	0,14548	0,00753	0,01786	0,02717
Tekanan (6000)	0,15169	0,13289	0,00213	0,00753	0,01786	0,02717
Tekanan (7000)	0,06628	0,00658	0,00213	0,07982	0,01786	0,02717

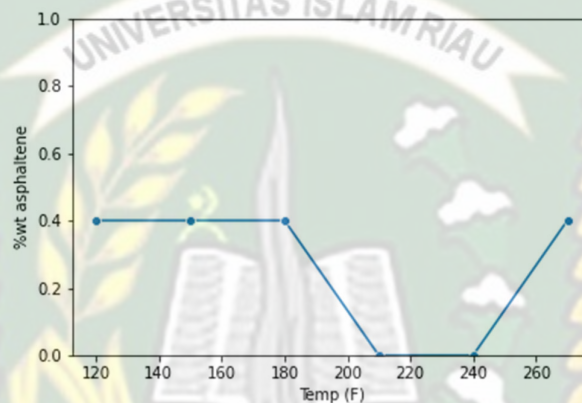
Berikut merupakan hasil perhitungan *parameter learning* terhadap pengaruh variasi nilai data pada tiap variabel terhadap terbentuknya endapan *asphaltene*:

4.3.1 Hubungan Data Tekanan

**Gambar 4. 3** Hubungan tekanan terhadap endapan *asphaltene*

Dari Gambar 4.3 dapat dilihat hubungan dari penurunan nilai tekanan terhadap endapan *asphaltene* dari model yang telah dibangun, Hasil yang diperoleh menunjukkan bahwa endapan *asphaltene* mulai terbentuk pada tekanan 6000 Psia pada posisi ini sering disebut sebagai *upper AOP* dan nilai maksimum dari endapan yang diperoleh sebesar 0,4 persen pada tekanan 5000 hingga 2000 Psia, pada tekanan 2000 proses presipitasi akan berhenti dan pada posisi ini sering juga disebut dengan posisi *lower AOP*.

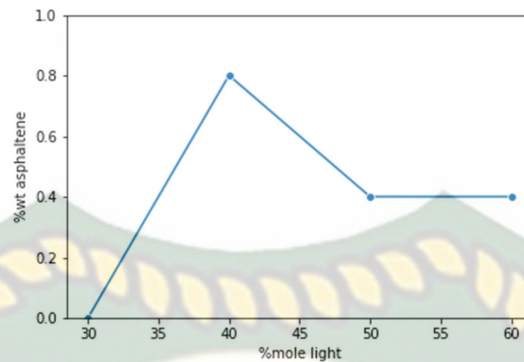
4.3.2 Hubungan Data Temperatur



Gambar 4. 4 Hubungan temperatur terhadap endapan *asphaltene*

Dapat dilihat bahwa pengaruh dari peningkatan nilai temperatur terhadap terbentuknya nilai endapan *asphaltene* berdasarkan Gambar 4.4, nilai endapan *asphaltene* terbentuk pada temperatur 120 °F sebesar 0,4 persen dan mulai menurun pada temperatur 180 °F.

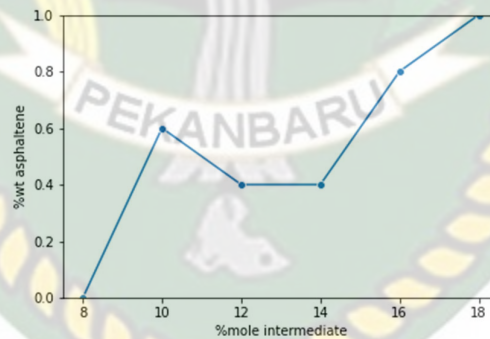
4.3.3 Hubungan Data *Light Component*



Gambar 4.5 Hubungan *light component* terhadap endapan *asphaltene*

Dari Gambar 4.5 berdasarkan perhitungan model, dapat dilihat bahwa nilai endapan *asphaltene* akan terbentuk pada minyak dengan *light component* diatas 30 persen dan dapat dilihat pada gambar bahwa nilai endapan maksimal berada pada nilai *%mole light component* sebesar 40 persen dengan nilai endapan *asphaltene* yaitu 0,8 persen.

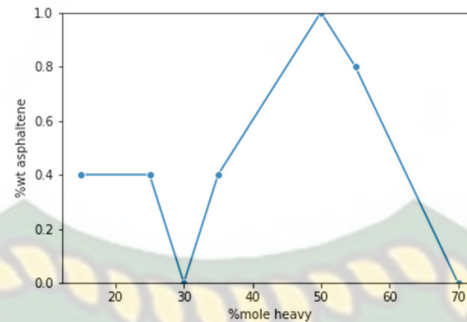
4.3.4 Hubungan Data *Intermediate Component*



Gambar 4.6 Hubungan *intermediate component* terhadap endapan *asphaltene*

Berdasarkan Gambar 4.6 nilai endapan *asphaltene* akan meningkat sesuai dengan banyaknya jumlah *intermediate component*, dapat dilihat pada Gambar 4.6 bahwa endapan *asphaltene* terendah berada pada minyak dengan *intermediate component* sebesar 8 persen dengan nilai endapan *asphaltene* sebesar 0.0 persen, dan nilai tertinggi berada pada *intermediate component* sebesar 18 persen dengan nilai endapan sebesar 1.0 persen.

4.3.5 Hubungan Data *Heavy Component*



Gambar 4. 7 Hubungan *heavy component* terhadap endapan *asphaltene*

Dari Gambar 4.7 dapat dilihat bahwa nilai endapan asphaltene akan terbentuk pada *%mole heavy component* sebesar 10 persen dengan nilai endapan sebesar 0,4 persen dan akan meningkat secara maksimal pada minyak dengan *%mole heavy component* diatas 35 persen dengan nilai endapan maksimum pada *%mole heavy component* sebesar 50 persen dengan nilai endapan sebesar 1.0 persen.

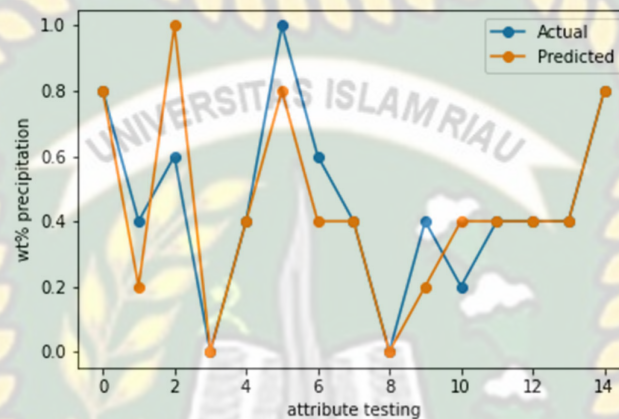
4.4 PENGUJIAN MODEL

Selanjutnya melakukan inferensi dengan menggunakan *variable elimination*, dimana hasil yang didapat dengan menggunakan *variable elimination* mendekati peluang yang sebenarnya. Pada penelitian kali ini, *variable elimiation* digunakan untuk mengevaluasi hasil yang diperoleh pada struktur model yang dibangun dan menghitung *parameter learning*.

Data yang digunakan diambil dari seluruh jurnal mengenai endapan asphaltene, data uji yang digunakan adalah data tes yang telah dibagi sebelumnya yang merupakan sebagian nilai dataset yang tidak digunakan dalam *training* model. Nilai prediksi dilakukan dengan memperhitungkan probabilitas 7 variabel sebagai sampel, kemudian hasil prediksi akan dibandingkan dengan hasil asli dari data test. Agar pengujian optimal, maka data pengujian diambil secara acak dari dataset. Pengujian dilakukan untuk melihat seberapa akurat sistem yang telah dibangun dapat memprediksi endapan *asphaltene* dengan benar.

Pada penelitian kali ini, pengujian dilakukan dengan cara memperhitungkan probabilitas dari 7 variabel yang merupakan faktor yang mempengaruhi nilai endapan asphaltene, seperti tekanan, temperatur, *non-HC gas*, *light*, *intermediate*, *heavy*, dan *API gravity*. Berikut merupakan hasil pengujian menggunakan sistem yang telah dibangun:

4.4.1 Hasil Pengujian 10% Data



Gambar 4. 8 Hasil pengujian dari 10% tes poin

Dari model yang telah dibangun dari 90% (130 atribut) data *training model* dari 8 variabel model kemudian diuji dengan 7 variabel dengan 15 atribut tiap variabel untuk memprediksikan hasil dari endapan *asphaltene*, sumbu “x” merupakan urutan atribut dari 15 data uji yang dibandingkan hasil aktual, sedangkan sumbu “y” merupakan nilai dari prediksi endapan *asphaltene*. dari model yang telah dibangun dengan melatih 130 atribut dari dataset didapatkan hasil tingkat akurasi dari model dalam memperkirakan nilai endapan *asphaltene* yaitu sebesar 60%.

Dari grafik line pada Gambar 4. 8 dapat dilihat bahwa garis berwarna kuning menunjukkan nilai prediksi endapan *asphaltene* dari model dan garis biru sebagai nilai asli dari kelas target dari data uji, terlihat bahwa di beberapa poin nilai prediksi dapat menunjukkan nilai yang sama dengan data asli, terdapat 9 poin nilai prediksi yang benar sesuai dengan nilai asli dari kelas target data uji, dan terdapat 6 nilai yang tidak sesuai dengan kelas target. Untuk nilai probabilitas yang dihasilkan dari

data tes pertama pada Gambar 4. 8, pada sumbu $x=0$ data yang dimasukkan untuk memprediksi nilai dari endapan asphaltene yaitu nilai tekanan 1000 psi, temperatur 180 °F, %mole non-HC gas, light component, intermediate component, heavy component secara berurutan adalah 4%, 30%,14%,55% dan API gravity sebesar 20° adalah sebagai berikut:

Tabel 4. 3 Hasil inferensi probabilitas atribut tes $x=0$

Asp. Precipitation	Phi (Asp. Precipitation)
Asp. Precipitation (0,0)	0,1820
Asp. Precipitation (0,2)	0,2270
Asp. Precipitation (0,4)	0,0858
Asp. Precipitation (0,6)	0,1056
Asp. Precipitation (0,8)	0,3748
Asp. Precipitation (1,0)	0,0247

Dapat dilihat dari Tabel 4. 8 yang merupakan hasil inferensi sistem terhadap probabilitas atribut tes pertama pada sumbu $x=0$ di Gambar 4. 8, dari hasil model untuk tes poin pertama sistem menunjukkan probabilitas tertinggi sebesar 0,3748 pada kelas terget Asp. Precipitation (0.8), dari hasil inferensi probabilitas tersebut sistem memilih bahwa dari variabel uji yang dimasukkan nilai dari wt% asphaltene precipitation sebesar 0.8. Dari hasil inferensi tersebut model mampu memprediksikan nilai endapan asphaltene dengan benar sesuai dengan data asli dari kelas targetnya sesuai yang ditampilkan pada grafik di Gambar 4. 8 bahwa nilai prediksi dan aktual berada di titik yang sama saling berhimpitan.

Untuk atribut tes ke-2 pada sumbu $x=1$ pada Gambar 4. 8 dengan nilai tes tekanan 1000 psi, temperatur 180 °F, %mole non-HC gas, light component, intermediate component, heavy component secara berurutan adalah 13%, 60%,12%,25% dan API gravity sebesar 34° nilai inferensi probabilitas yang dihasilkan sistem adalah sebagai berikut:

Tabel 4. 4 Hasil inferensi probabilitas atribut tes $x=1$

Asp. Precipitation	Phi (Asp. Precipitation)
Asp. Precipitation (0,0)	0,3688
Asp. Precipitation (0,2)	0,3842

Asp. Precipitation (0,4)	0,1040
Asp. Precipitation (0,6)	0,0670
Asp. Precipitation (0,8)	0,0712
Asp. Precipitation (1,0)	0,0047

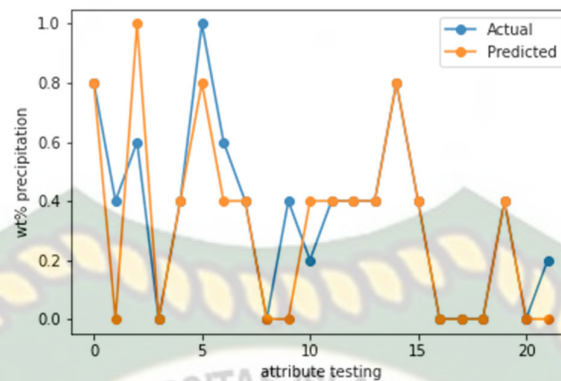
Dari Tabel 4. 4 dapat dilihat hasil dari inferensi probabilitas nilai atribut tes ke-2 menunjukkan bahwa sistem menampilkan nilai probabilitas dari prediksi endapan *asphaltene* dengan cukup yakin, dari nilai data tes yang telah dimasukkan kedalam sistem menunjukkan probabilitas tertinggi dengan nilai densitas 0,3842 pada nilai *%wt asphaltene precipitation* sama dengan 0,2 dan jika dilihat dari data asli untuk data tes yang diinput memiliki kelas target yang berbeda. dengan hasil inferensi probabilitas tersebut model belum mampu memprediksi endapan *asphaltene* dengan benar yaitu *wt% asphaltene precipitation* = 0,4 sehingga terjadi *under estimate* pada nilai prediksi endapan *asphaltene* yang dihasilkan.

Tabel 4. 5 Hasil inferensi probabilitas atribut tes x=2

Asp. Precipitation	Phi (Asp. Precipitation)
Asp. Precipitation (0,0)	0,1645
Asp. Precipitation (0,2)	0,0071
Asp. Precipitation (0,4)	0,2022
Asp. Precipitation (0,6)	0,0201
Asp. Precipitation (0,8)	0,0194
Asp. Precipitation (1,0)	0,5876

Dari Tabel 4. 5 merupakan hasil dari inferensi probabilitas dari atribut data tes x=2 pada Gambar 4. 8 dengan input data tes tekanan 3000 psi, temperatur 150 °F, *%mole non-HC gas, light component, intermediate component, heavy component* secara berurutan adalah 4%, 40%, 18%, 50% dan *API gravity* sebesar 20° dari Tabel 4. 5 kita dapat melihat bahwa nilai probabilitas dengan densitas tertinggi adalah 0.5867 yaitu pada kelas target Asp. Precipitation = 1,0 dari hasil probabilitas tersebut sistem tidak mampu memprediksi bahwa endapan akan terjadi sebesar 0.6% dengan benar, nilai prediksi menjadi *over estimate* terhadap data aktualnya.

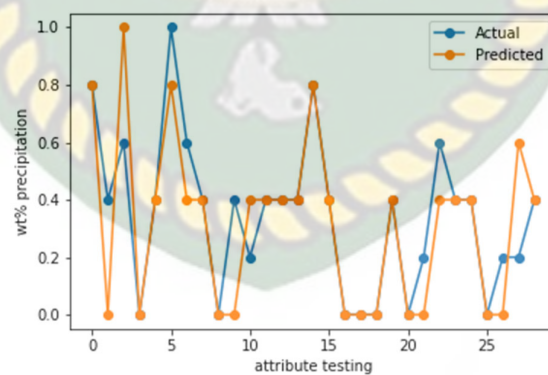
4.4.2 Hasil Pengujian 15% Data



Gambar 4. 9 Hasil pengujian dari 15% tes poin

Dari Gambar 4. 9 diatas dapat dilihat bahwa hasil dari prediksi model yang telah dibangun dengan melatih 85% dataset secara acak dan hasil prediksi yang diperoleh dengan menguji model dengan 22 atribut sesuai yang ditampilkan pada grafik diatas dapat dilihat bahwa terdapat 15 nilai prediksi yang benar sesuai dengan nilai aktual dari kelas target data uji yang dimasukkan dan terdapat 7 nilai prediksi yang salah. Dari model yang telah diuji dengan 15% data uji, model dapat memprediksi nilai endapan *asphaltene* dengan tingkat akurasi sebesar 68%.

4.4.3 Hasil Pengujian 20% Data

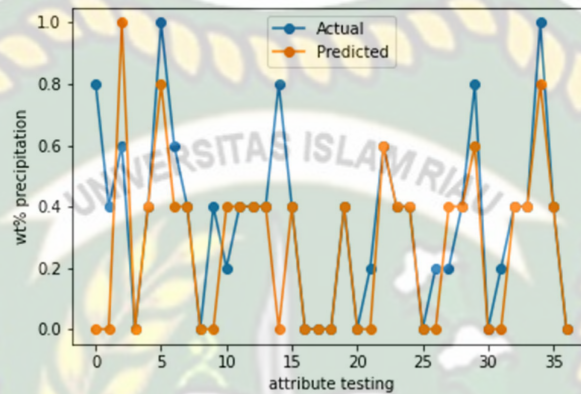


Gambar 4. 10 Hasil pengujian dari 20% tes poin

Gambar 4. 10 menunjukkan bahwa hasil dari prediksi model yang telah dibangun dengan melatih 80% dataset secara acak, lalu melakukan prediksi dari model yang telah dibangun menunjukkan bahwa hasil prediksi yang diperoleh

sesuai yang ditampilkan grafik pada Gambar 4. 10 menunjukkan bahwa terdapat 20 nilai prediksi yang benar dan terdapat 9 nilai prediksi yang salah. Dari model yang diuji dengan 20% data, model dapat menghasilkan prediksi dengan tingkat akurasi sebesar 69%.

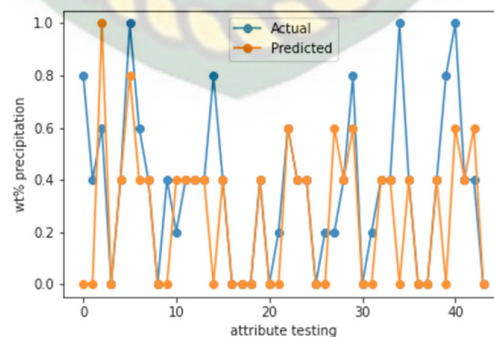
4.4.4 Hasil Pengujian 25% Data



Gambar 4. 11 Hasil pengujian dari 25% tes poin

Pada Gambar 4. 11 diatas menunjukkan hasil dari prediksi model yang telah dibangun dengan melatih 75% (109 atribut) dataset yang dipilih secara acak, kemudian hasil prediksi yang diperoleh sesuai yang ditampilkan pada grafik diatas adalah 23 nilai prediksi benar dan terdapat 14 nilai salah. Dari model yang diuji dengan 25% data, model dapat menghasilkan prediksi dengan tingkat akurasi sebesar 62%.

4.4.5 Hasil Pengujian 30% Data



Gambar 4. 12 Hasil pengujian dari 30% tes poin

Dari Gambar 4. 12 dapat dilihat bahwa hasil dari prediksi model yang telah dibangun dengan melatih 70% dataset yang dipilih secara acak, kemudian hasil prediksi yang diperoleh sesuai yang ditampilkan pada grafik diatas dapat dilihat bahwa terdapat 27 nilai prediksi sesuai dengan nilai aktual dan terdapat 17 yang tidak sesuai dengan nilai aktual dari kelas terget endapan *asphaltene* data uji. Dari model yang diuji dengan 30% data, model dapat menghasilkan prediksi dengan tingkat akurasi 61%.

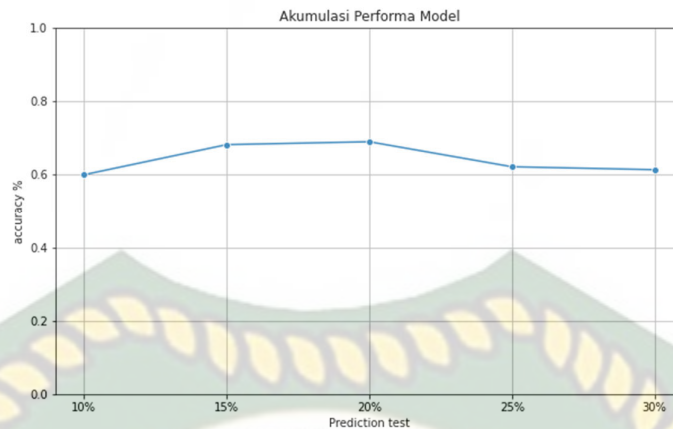
4.5 ANALISIS HASIL

Berikut merupakan akumulasi nilai akurasi dari total seluruh bobot pengujian model *Bayesian network*:

Tabel 4. 6 Tabel performa model *bayesian network*

Training Point (%)	Total atribut training data	Total atribut testing data	Prediksi benar	Prediksi salah	Akurasi (%)
90	130	15	9	6	60
85	123	22	15	7	68
80	116	29	20	9	69
75	108	37	23	14	62
70	101	44	27	17	61
Rata-rata					64

Dari data tersebut performa dari model *Bayesian network* yang telah dilatih dan diuji dapat divisualisasikan kedalam grafik sebagai berikut:

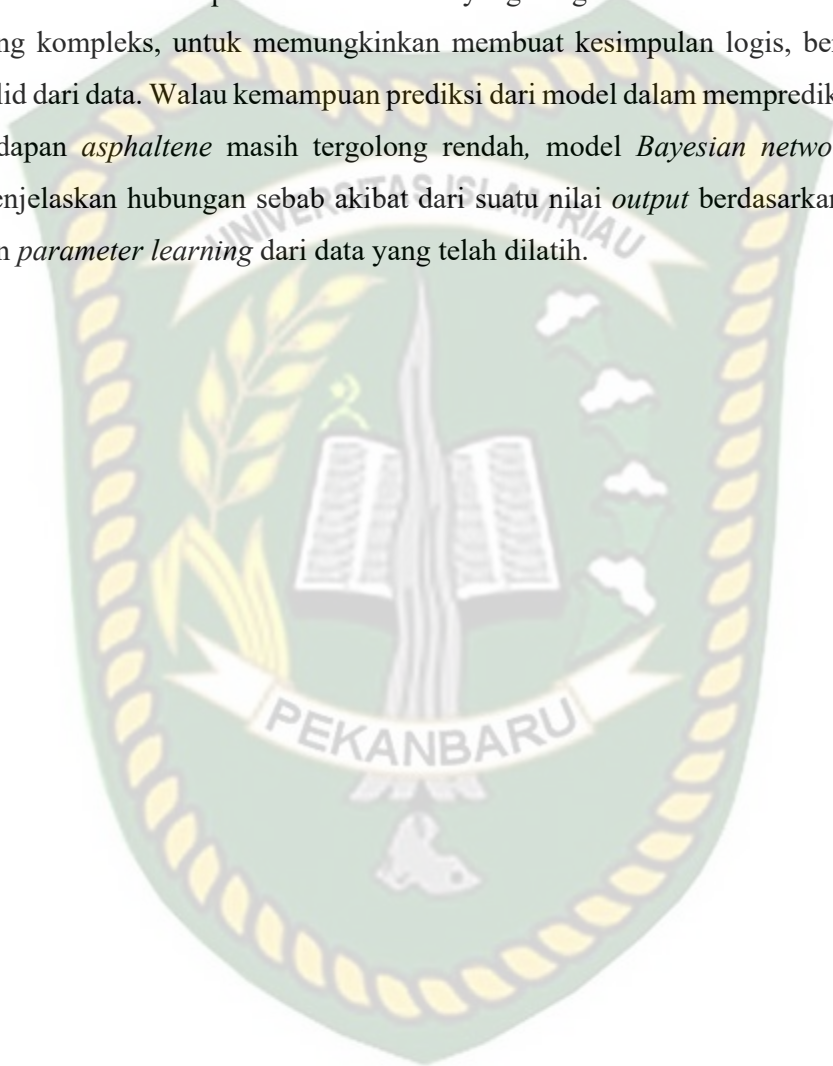


Gambar 4. 13 Akumulasi performa model

Dari Gambar 4. 13 dapat dilihat distribusi nilai akurasi dari tiap-tiap bobot pengujian dari seluruh bobot nilai pengujian, model hasil dari inferensi yang paling baik dihasilkan oleh pelatihan model menggunakan 80% data atau dengan sebanyak 116 atribut data pada tiap variabel input, dengan model yang dihasilkan memiliki nilai akurasi 69% dan pemodelan yang memiliki hasil inferensi paling kecil akurasinya adalah dengan pelatihan data sebanyak 90% data dengan akurasi model sebesar 60%. Jika dilihat dari seluruh nilai akurasi model dengan rata-rata sebesar 64%.

Adapun rendahnya hasil nilai akurasi model *Bayesian network* yang dibangun adalah karena jumlah data yang kecil menyebabkan distribusi data yang sedikit dan tidak seimbang menjadi faktor utama dalam kegagalan dari model *Bayesian network*, sehingga menghasilkan nilai akurasi prediksi endapan *asphaltene* menjadi rendah. Adapun Chang (2010) menjelaskan bahwa performa dari metode *Bayesian network* sangat bergantung pada jumlah dataset yang dilatih dan kualitas *prior* yang digunakan, sehingga metode ini menghadapi kendala praktis karena ketersediaan jumlah data yang tergolong kecil. Sehingga metode *Bayesian network* yang dibangun dari dataset yang digunakan belum dapat direkomendasikan sebagai salah satu jalan keluar dalam memprediksikan nilai endapan *asphaltene* karena performa yang diperoleh masih tergolong rendah.

Namun keunggulan dari metode *Bayesian network* yang telah dilakukan pada penelitian kali ini, sesuai dengan yang disampaikan oleh Mittal & Kassim (2007) bahwa pemodelan berdasarkan grafis mampu memberikan cara dalam menangani dua masalah utama yaitu probabilitas dan kompleksitas. *Graphical model* menyediakan cara intuitif dimana user dan mesin dapat berkerjasama dalam memodelkan sekumpulan variabel acak yang sangat interaktif serta struktur data yang kompleks, untuk memungkinkan membuat kesimpulan logis, berguna, dan valid dari data. Walau kemampuan prediksi dari model dalam memprediksikan nilai endapan *asphaltene* masih tergolong rendah, model *Bayesian network* mampu menjelaskan hubungan sebab akibat dari suatu nilai *output* berdasarkan *structure* dan *parameter learning* dari data yang telah dilatih.



BAB V KESIMPULAN DAN SARAN

5.1 KESIMPULAN

Adapun kesimpulan yang diperoleh dari penelitian ini adalah:

1. Berdasarkan pemodelan dengan metode *Bayesian network* didapati bahwa hubungan dari pengaruh parameter tekanan, temperatur, serta komposisi yang diperoleh dengan melakukan *parameter learning* adalah endapan akan terbentuk ketika penurunan tekanan telah mencapai 6000 Psia, pada hubungan peningkatan nilai temperatur dengan endapan *asphaltene* diketahui bahwa endapan *asphaltene* akan terbentuk pada temperatur 120 °F, hubungan *%mole light component* terhadap terbentuknya endapan *asphaltene* adalah bahwa endapan *asphaltene* akan terbentuk pada minyak yang memiliki *%mole light component* diatas 30 persen, hubungan *intermediate component* berdasarkan model diperoleh bahwa endapan akan terjadi pada minyak yang memiliki *%mole intermediate component* diatas 8 persen, dan hubungan *%mole heavy component* terhadap terbentuknya *asphaltene* didapati bahwa endapan *asphaltene* akan terbentuk pada minyak dengan *%mole heavy component* sebesar 10 persen.
2. Prediksi yang dilakukan dengan lima kali pengujian dengan bobot data yang berbeda-beda dan acak, menghasilkan bahwa model *Bayesian network* yang dibangun dapat memprediksikan nilai endapan *asphaltene*, hasil yang diperoleh berdasarkan dataset yang digunakan mendapatkan nilai akurasi rata-rata sebesar 64%.

5.2 SARAN

Berdasarkan pembahasan yang telah dijabarkan sebelumnya, diharapkan untuk peneliti selanjutnya melakukan prediksi terhadap endapan *asphaltene* dengan metode *machine learning* lainnya.

DAFTAR PUSTAKA

- Ahmadi, M. A., & Shadizadeh, S. R. (2012). New approach for prediction of asphaltene precipitation due to natural depletion by using evolutionary algorithm concept. *Fuel*, *102*, 716–723.
<https://doi.org/10.1016/j.fuel.2012.05.050>
- Ankan, A., & Panda, A. (2015). pgmpy: Probabilistic Graphical Models using Python. In *Proceedings of the 14th Python in Science Conference*.
<https://doi.org/10.25080/majora-7b98e3ed-001>
- Bhattacharya, S., & Mishra, S. (2018). Applications of machine learning for facies and fracture prediction using Bayesian Network Theory and Random Forest: Case studies from the Appalachian basin, USA. *Journal of Petroleum Science and Engineering*, *170*, 1005–1017.
<https://doi.org/10.1016/j.petrol.2018.06.075>
- Bidhop, christopher m. (2004). PATTERN RECOGNATION AND MACHINE LEARNING. In *Oxidation Communications* (Vol. 27).
- Brownlee, J. (2020). Imbalanced Classification with Python. *Machine Learning Mastery*, 463.
- Buenrostro-Gonzalez, E., Lira-Galeana, C., Gil-Villegas, A., & Wu, J. (2004). Asphaltene precipitation in crude oils: Theory and experiments. *AIChE Journal*, *50*(10), 2552–2570. <https://doi.org/10.1002/aic.10243>
- Chang, R. (2010). Advanced Algorithms of Bayesian Network Learning and Probabilistic Inference from Inconsistent Prior Knowledge and Sparse Data with Applications in Computational Biology and Computer Vision. In *Bayesian Network*. *IntechOpen*.
- Choi, T. (2015). Bayesian networks with examples in R. In *Biometrics* (Vol. 71).
<https://doi.org/10.1111/biom.12369>
- Darabi, H., Abouie, A., & Sepehrnoori, K. (2016). Effect of temperature

variations on asphaltene dynamics in oil reservoirs. *Society of Petroleum Engineers - SPE Western Regional Meeting*. <https://doi.org/10.2118/180481-ms>

- Fanailoo, P., & Clemens, J. (2016). Application of Bayesian networks for estimating risk in Shale operations. *SPE/AAPG/SEG Unconventional Resources Technology Conference 2016*, 1776–1782. <https://doi.org/10.15530/urtec-2016-2459399>
- Hammami, A., & Ratulowski, J. (2007). Precipitation and Deposition of Asphaltenes in Production Systems: A Flow Assurance Overview. *Asphaltenes, Heavy Oils, and Petroleomics*, 617–660. https://doi.org/10.1007/0-387-68903-6_23
- Kamari, A., Safiri, A., & Mohammadi, A. H. (2015). Compositional Model for Estimating Asphaltene Precipitation Conditions in Live Reservoir Oil Systems. *Journal of Dispersion Science and Technology*, 36(3), 301–309. <https://doi.org/10.1080/01932691.2014.896220>
- Khaz'ali, A. R., Farahani, F. J., & Ahmadabadi, M. N. (2011). Bayesian network - A new probabilistic method for petroleum reservoir production prediction and history matching. *Petroleum Science and Technology*, 29(7), 745–757. <https://doi.org/10.1080/10916460903468393>
- Leontaritis, K. J., & President, P. D. (2007). The Asphaltene and Wax Deposition Envelopes. *Fuel Science and Technology International*, 14((1-2)), 13–39.
- Mehryar Mohri, Rostamizadeh, A., & Talwalkar, A. (2013). Foundations of Machine Learning second edition. In *Вестник Казнму*.
- Mihaljevič, B., Bielza, C., & Larrañaga, P. (2019). bnclassify: Learning Bayesian network classifiers. *R Journal*, 10(2), 455–468. <https://doi.org/10.32614/RJ-2018-073>
- Minsky, M. (1961). Steps Toward Artificial Intelligence. *Proceedings of the IRE*, 49(1), 8–30. <https://doi.org/10.1109/JRPROC.1961.287775>

- Mittal, A., & Kassim, A. (2007). Bayesian network technologies: Applications and graphical models. In *Bayesian Network Technologies: Applications and Graphical Models*. <https://doi.org/10.4018/978-1-59904-141-4>
- Na'imi, S. R., Gholami, A., & Asoodeh, M. (2014). Prediction of Crude Oil Asphaltene Precipitation Using Support Vector Regression. *Journal of Dispersion Science and Technology*, 35(4), 518–523. <https://doi.org/10.1080/01932691.2013.798585>
- Rajaieyamchee, M. A., Bratvold, R. B., & Badreddine, A. (2010). *Bayesian Decision Networks for Optimal Placement of Horizontal Wells*. <https://doi.org/10.2118/129984-ms>
- Randles, B. M., Pasquetto, I. V., Golshan, M. S., & Borgman, C. L. (2018). Using the jupyter notebook as a tool for open science: An empirical study. *ArXiv*, 17–18.
- Sanner, M. F. (1999). Python: A programming language for software integration and development. *Journal of Molecular Graphics and Modelling*, 17(1), 57–61.
- Sayyad Amin, J., Alamdari, A., Mehranbod, N., Ayatollahi, S., & Nikooee, E. (2010). Prediction of asphaltene precipitation: Learning from data at different conditions. *Energy and Fuels*, 24(7), 4046–4053. <https://doi.org/10.1021/ef100106r>
- Spalburg, M. R. (2004). Bayesian uncertainty reduction for log evaluation. *11th ADIPEC: Abu Dhabi International Petroleum Exhibition and Conference - Conference Proceedings*, 249–259. <https://doi.org/10.2118/88685-ms>
- Subramanian, S., Simon, S., & Sjöblom, J. (2016). Asphaltene Precipitation Models: A Review. *Journal of Dispersion Science and Technology*, 37(7), 1027–1049. <https://doi.org/10.1080/01932691.2015.1065418>
- Suryana, I., Suryani, M., Paulus, E., & Rosadi, R. (2018). Metode Bayesian Network Untuk Menentukan. *Euclid*, 5(2), 45–60.

- Vargas, F. M., Garcia-Bermudes, M., Boggara, M., Punnapala, S., Abutaqiya, M., Mathew, N., ... Al Asafen, H. (2014). On the development of an enhanced method to predict asphaltene precipitation. *Proceedings of the Annual Offshore Technology Conference*, 3, 2301–2319.
<https://doi.org/10.4043/25294-ms>
- Weber, P. (2016). *Volume 2 Benefits of Bayesian* (Vol. 2).
- Windarti, M., & Suradi, A. (2019). Perbandingan Kinerja 6 Algoritme Klasifikasi Data Mining untuk Prediksi Masa Studi Mahasiswa. *Telematika*, 12(1), 14.
<https://doi.org/10.35671/telematika.v12i1.778>
- Yu, H., Moharil, J., & Blair, R. H. (2020). Bayesnetbp: An R package for probabilistic reasoning in Bayesian networks. *Journal of Statistical Software*, 94(3), 1–31. <https://doi.org/10.18637/jss.v094.i03>
- Zanganeh, P., Dashti, H., & Ayatollahi, S. (2018). Comparing the effects of CH₄, CO₂, and N₂ injection on asphaltene precipitation and deposition at reservoir condition: A visual and modeling study. *Fuel*, 217(April 2017), 633–641.
<https://doi.org/10.1016/j.fuel.2018.01.005>
- Zerfat, M. M., Ayatollahi, S., Mehranbod, N., & Barzegari, D. (2011). Bayesian network analysis as a tool for efficient EOR screening. *Society of Petroleum Engineers - SPE Enhanced Oil Recovery Conference 2011, EORC 2011*, 1, 111–126. <https://doi.org/10.2118/143282->