



***Economy Circular* Pengelolaan Sampah Organik Pasar di Peternakan Sapi dari Hulu hingga Hilir (Studi Kasus di Kelompok Tani Sumber Makmur, Gunung Tembak Kota Balikpapan)**

Noneng Dewi Z.¹⁾, Reno Pratiwi²⁾, Ika Bayu K.¹⁾, Sekar Inggar R.¹⁾, Galuh Boyo M.¹⁾, Evi Oktavia¹⁾

¹⁾Fakultas Teknik Sipil dan Perencanaan/ Program Studi Teknik Lingkungan, Universitas Balikpapan

²⁾Fakultas Teknik Sipil dan Perencanaan/ Program Studi Teknik Sipil, Universitas Balikpapan

E-mail: noneng_dwi@uniba-bpn.ac.id

ABSTRAK

Pengelolaan sampah organik pasar di Kota Balikpapan menjadi sebuah hal yang penting dilakukan untuk mengurangi beban TPA Manggar. Timbulan sampah organik khususnya sampah organik pasar yang terus bertambah seiring dengan lajunya pertumbuhan penduduk Kota Balikpapan sebagai kota penyangga IKN dapat meningkatkan resiko pencemaran dan keselamatan lingkungan. Sampah organik pasar dapat dimanfaatkan menjadi alternatif pakan ternak sapi dan kambing dan hal tersebut telah dilakukan oleh Kelompok Tani Sumber Makmur Gunung Tembak Kota Balikpapan. Selain memanfaatkan sampah organik pasar sebagai pakan ternak sapi dan kambing, Kelompok Tani Sumber Makmur juga telah mengelola kotoran sapi baik berupa padat dan cair menjadi pupuk organik padat dan pupuk organik cair. Dengan demikian telah terjadi rangkaian *Economy circular* yang dapat menjadi alternatif dalam mengatasi permasalahan sampah organik pasar di Kota Balikpapan sekaligus peningkatan nilai ekonomi. Metode dalam penelitian ini menggunakan metode deskriptif-kualitatif dengan model *design action research* atau penelitian tindakan dengan mengamati langsung untuk mendapatkan informasi dari objek kajian. Terbagi 4 bagian dari pembahasan penelitian ini yaitu Sistem Pemanfaatan Sampah Organik Pasar sebagai Pakan Ternak Sapi dan Kambing, system pemanfaatan kotoran padat sapi, system pemanfaatan kotoran cair sapi, potensi pengelolaan peternakan sapi dan kambing berbasis *economy circular*. Hasil pengamatan di Kelompok Tani Sumber Makmur Gunung Tembak Kota Balikpapan menunjukkan bahwa telah terjadi kegiatan pengelolaan peternakan yang menerapkan *economy circular* dari hulu hingga hilir.

Kata Kunci: sampah organik pasar, peternakan, pakan ternak, *economy circular*, pupuk kotoran.

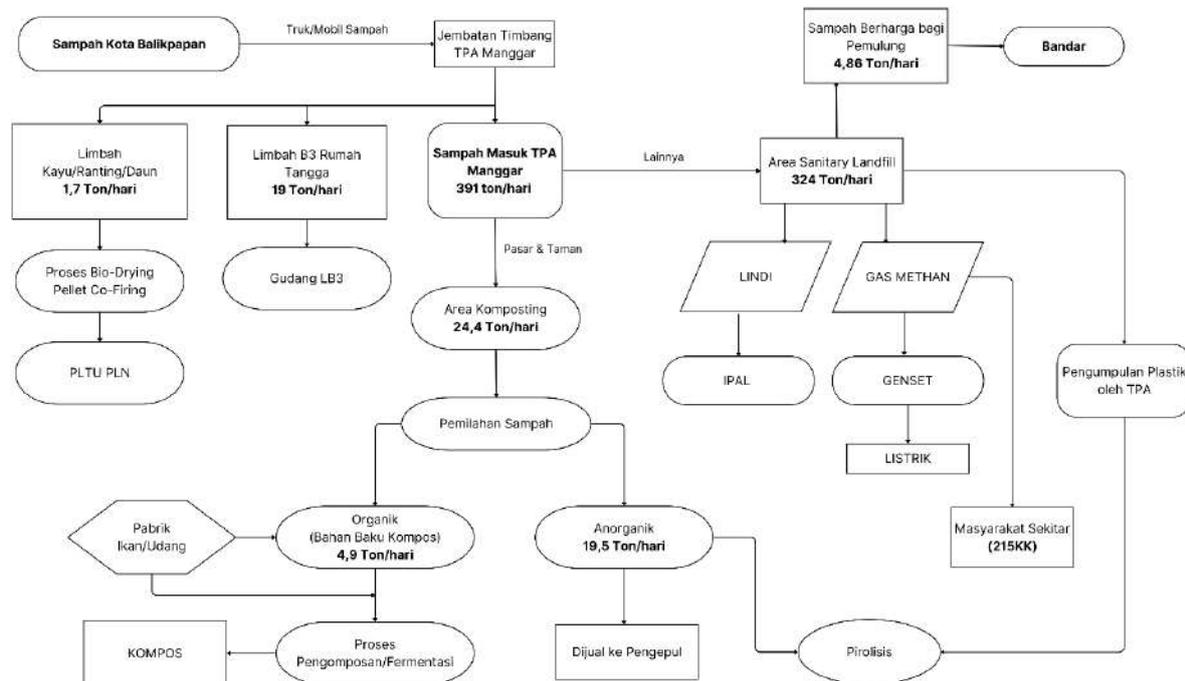
ABSTRACT

Management of market organic waste in Balikpapan City is an important thing to do to reduce the burden on Manggar TPA. Organic waste, especially market organic waste, which continues to increase along with the rapid growth of the population in Balikpapan City as a buffer city for the IKN can increase the risk of environmental pollution and safety. Market organic waste can be used as an alternative feed for cattle and goats and this has been done by the Sumber Makmur Farmer Group, Gunung Tembak, Balikpapan City. In addition to utilizing market organic waste as cattle and goat feed, the Sumber Makmur Farmer Group has also managed cow manure in the form of solid and liquid into solid organic fertilizer and liquid organic fertilizer. Thus there has been a series of Economy circular which can be an alternative in overcoming the problem of market organic waste in the Balikpapan city as well as increasing economic value. The method in this study uses a descriptive-qualitative method with a design action research model or action research by observing directly to obtain information from the object of study. Discussion of this research is divided into 4 parts such us System for Utilizing Market Organic Waste as Cattle and Goat Feed, the system for utilizing solid cow manure, the system for utilizing liquid cow manure, the potential for managing cattle and goat farms based on an economy circular. The results of observations at the Sumber Makmur Farmer Group, Gunung Tembak, Balikpapan City, show that there have been livestock management activities that apply an economy circular from upstream to downstream.

Keyword: market organic waste, farming, animal feed, economic circular, manure

1. Pendahuluan

Sumber sampah di Kota Balikpapan berasal dari permukiman (domestik) dan non-domestik, dari data DLH Kota Balikpapan dalam kajian Master Plan TPA Manggar, pada Tahun 2021 timbulan sampah dari sumber permukiman sebesar 0,72kg/orang/hari sedangkan timbulan sampah non-permukiman sebesar 0,26 kg/orang/hari, sehingga total timbulan sampah Kota Balikpapan sebesar 0,98 kg/orang/hari dengan jumlah populasi sebanyak 709.663 jiwa (BPS Kota Balikpapan, 2021). Efisiensi pengumpulan sampah sebesar 56,2% atau sekitar 391 ton/hari sampah yang masuk ke dalam TPA Manggar, sedangkan untuk sampah yang tidak terkelola sebesar 183,33 ton/hari atau 26,4%, kemudian dari program pengurangan sampah (Program 3R) persentase sampah yang terkelola sebesar 17,5% dan sisanya 0,2% dijadikan kompos pakan ternak. Sektor permukiman sebagai penghasil terbesar yang setara dengan 70,30% dari sampah yang dihasilkan dan sisanya adalah sampah non-permukiman mencakup 29,7% dengan rincian 2,86% berasal dari perkantoran/institusi, 8,77% sampah berasal dari pusat perniagaan, fasilitas public sebesar 4,57%, kawasan sebesar 3,01%, pasar (tradisional) sebesar 6,44%, dan sumber lainnya sebesar 4,05%. Kondisi saat ini, seluruh sampah baik domestik dan non-domestik langsung di bawa dan diproses di TPA Manggar Kota Balikpapan, seperti yang diketahui bahwa mayoritas sampah domestik merupakan jenis sampah yang mudah membusuk (sampah organik), maka timbul bau busuk akibat dari proses pembusukan sampah organik, begitu pula air lindi yang dapat menimbulkan penyakit, dan mencemari air tanah dan lingkungan sekitar. Hal ini dapat semakin berat dan menambah beban di TPA Manggar sendiri karena saat ini Kota Balikpapan merupakan kota penyangga Ibu Kota Negara (IKN) yang baru, sehingga akan berdampak pada peningkatan jumlah penduduk yang cukup signifikan dan berpengaruh pada semakin tingginya angka timbulan sampah Kota Balikpapan. Berikut merupakan gambaran terkait neraca sampah yang masuk ke TPA Manggar Kota Balikpapan yang dapat dilihat sebagai berikut (DLH Kota Balikpapan, 2022).



Gambar 1. Neraca Sampah di TPA Manggar Tahun 2022

Dari neraca sampah yang masuk ke TPA Manggar sebesar 391 ton/hari, Sebagian besar atau setara dengan 324 ton/hari masuk ke area *Sanitary Landfill* dimana sampah yang masih memiliki nilai jual diambil oleh pemulung yang kemudian disetorkan ke bandar-bandar. Selanjutnya, dari total seluruh sampah, jenis sampah berupa kayu/ranting/daun diolah lebih lanjut melalui proses *bio-drying* dan *pellet co-firing*, sementara untuk jenis sampah yang masuk ke dalam limbah B3 rumah tangga disimpan sementara di Gudang Limbah B3. Nilai tonase sampah yang besar juga dari sampah pasar dan taman sebesar 24,4 ton/hari yang diolah lebih lanjut melalui proses *composting* yang menghasilkan pupuk kompos. Selanjutnya baik lindi dan gas metan yang terbentuk diproses lebih lanjut pada unit pengolahan masing-masing. Untuk gas metan sendiri saat ini telah dimanfaatkan oleh masyarakat di sekitar TPA Manggar dan Sebagian gas metan dimanfaatkan untuk pembangkit listrik. Untuk jenis sampah anorganik, selain di ambil oleh pemulung

namun, juga dikumpulkan oleh pihak TPA dan diproses lebih lanjut menggunakan pirolisis (DLH Kota Balikpapan, 2022).

Seperti yang diketahui sampai saat ini untuk pakan ternak terutama sapi dan kambing menggunakan rumput segar. Dalam memperoleh rumput segar dibutuhkan tenaga dan waktu, sehingga proses pemberian pakan dengan rumput segar dirasa tidak efektif serta ada beberapa kendala lain. Ketersediaan rumput segar semakin lama semakin berkurang dikarenakan pembukaan lahan oleh pembangunan dan kepadatan penduduk yang semakin bertambah serta sangat dipengaruhi oleh musim, khususnya di musim kemarau. Beberapa upaya untuk penyediaan bahan pakan baik dari impor maupun lokal telah dilakukan, namun biaya pakan tetap menjadi permasalahan utama (Outline business case untuk pengelolaan sampah Manggar, (diunduh dari https://web.balikipapan.go.id/uploaded/PS_Executive_Summary.pdf)

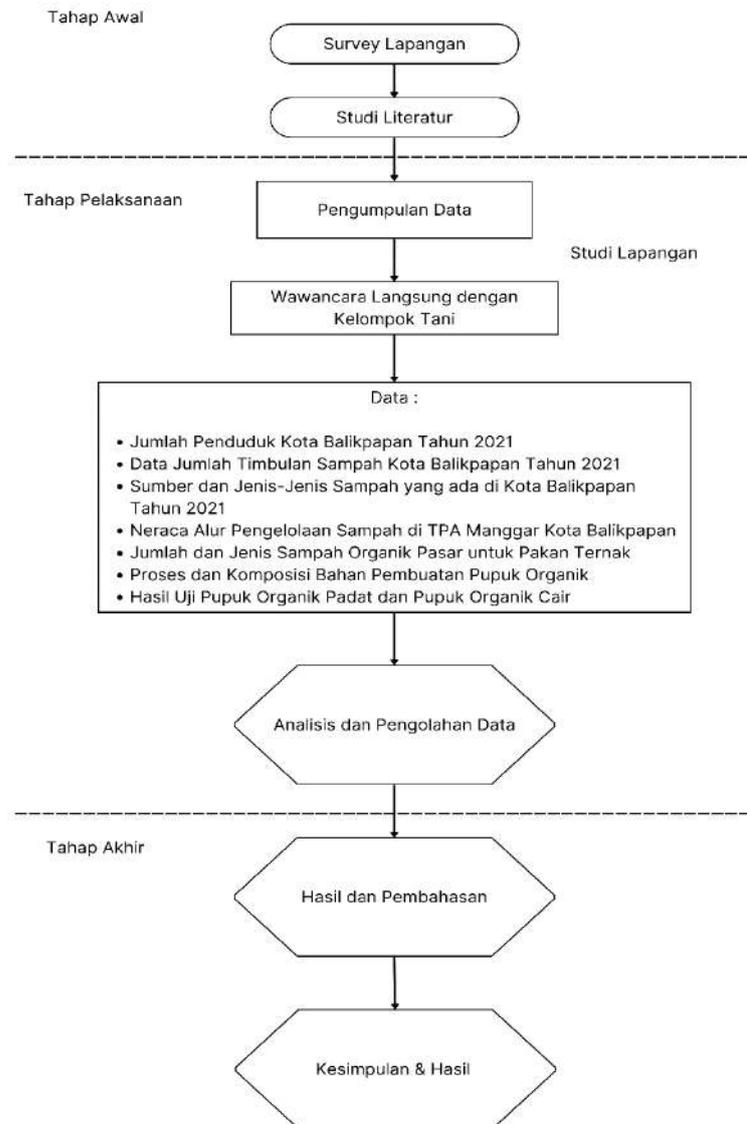
Adapun permasalahan selain sumber pakan ialah dari kotoran sapi dan kambing sendiri yang dapat meningkatkan efek gas rumah kaca karena terbebasnya gas metan dari kotoran ke atmosfer (Chadwick et al., 2011). Di samping itu, umumnya peternakan sangat identik dengan bau serta dapat meningkatkan vector penyakit. Pada dasarnya kotoran sapi dapat dimanfaatkan sebagai pupuk organik, kotoran yang dihasilkan dari satu ekor sapi setiap harinya berkisar antara 8 – 10 kg atau setiap tahunnya menghasilkan 2,6 – 3,6 ton yang nilai tersebut setara dengan 1,5 – 2 ton pupuk organik (Ratriyanto et al., 2019).

Pada dasarnya sampah organik dapat diolah menjadi produk yang lebih bermanfaat seperti halnya kompos, sumber bahan bakar gas alami, dan pakan ternak. Pemanfaatan sampah organik dari pasar untuk pakan ternak, selain dapat mengurangi timbulan sampah organik juga dapat memenuhi kebutuhan gizi yang diperlukan oleh ternak, khususnya dalam ini sapi dan kambing. Pemanfaatan sampah organik dari pasar dapat diberikan secara langsung kepada hewan ternak. Selain itu baik kotoran padat dan cairnya dapat digunakan sebagai pupuk organik (pupuk kandang dan pupuk cair).

Adapun tujuan penelitian kali ini ialah penerapan pola *economy circular* dalam sistem pengelolaan ternak dengan cara pemberian pakan ternak sapi dan kambing yang dikombinasikan dengan pemberian sampah organik pasar dan fermentasi rumput kering serta pemanfaatan kotoran padat dan cair menjadi pupuk organik di Kelompok Tani Sumber Makmur Gunung Tembak Kota Balikpapan. *Economy circular* sebuah istilah untuk kegiatan yang ditujukan pada penghematan energi, produksi hijau yang regeneratif, dan kegiatan konsumsi (Murray et al., 2017). Tidak seperti model tradisional dari pengembangan ekonomi, *economy circular* ini adalah model yang terbaik dalam rangka penghematan sumber daya dan material serta dalam pertumbuhan ekonomi yang berkelanjutan (Nikolaienko, 2019).

2. Metode Penelitian

Dalam penelitian ini menggunakan metode Kualitatif – Deskriptif dengan model *design action research* (penelitian Tindakan). Penelitian Tindakan adalah penelitian yang bertujuan mengembangkan keterampilan baru atau pendekatan baru untuk memecahkan masalah di dunia kerja (Masyhuri dan Zainuddin, 2008). Berdasarkan teori tersebut maka penulis merumuskan desain kajian lapangan yang merupakan kegiatan pemantauan secara langsung oleh pelaku penelitian untuk mendapatkan informasi terkait kajian yang diamati dengan konsep pelaku sebagai bagian yang terlibat secara aktif terhadap objek yang diamati. Penelitian ini dilakukan dengan wawancara dan studi lapangan. Adapun alur serta tahapan penelitian ini dapat dilihat pada **Gambar 2**. Alur Metodologi Penelitian



Gambar 2. Alur Metodologi Penelitian

A. Tahapan Awal

Pada tahapan awal dilakukan survey lapangan yang berlokasi di Kelompok Tani Sumber Makmur Gunung Tembak, Kota Balikpapan. Pada tahapan ini dilakukan survey lapangan dengan mengamati keadaan lapangan, seperti kondisi kandang sapi dan kambing, pola pemberian pakan pada ternak sapi dan kambing tersebut, pola pengelolaan kotoran sapi baik padat maupun cair baik dari pengumpulan, pengolahan, pengemasan, hingga pemasaran setelah menjadi pupuk organik padat maupun cair.

B. Tahapan Pengumpulan Data

Pada tahapan ini dilakukan dengan wawancara langsung dengan pengelola Kelompok Tani Sumber Makmur Gunung Tembak, Kota Balikpapan. Data yang diperoleh berupa data jumlah penduduk Kota Balikpapan Tahun 2021, jumlah timbulan sampah Tahun 2021 di Kota Balikpapan termasuk jenis sampah dari sumber permukiman dan non-permukiman serta neraca alur sampah di TPA Manggar Kota Balikpapan, jenis dan banyaknya sampah organik yang dijadikan pakan ternak dan data terkait jumlah kotoran sapi baik padat maupun cair serta proses pengolahan yang dilakukan hingga kotoran menjadi pupuk organik.

3. Hasil dan Pembahasan

A. Sistem Pemanfaatan Sampah Organik Pasar sebagai Pakan Ternak Sapi dan Kambing

Berdasarkan pengamatan di lapangan dan hasil wawancara terhadap peternak, bahwa proses pemberian pakan dilakukan dengan membagi menjadi 2 kali pemberian pakan dalam 1 hari, yaitu pada siang hari dan

malam hari, sedangkan pagi hari tidak diberi pakan agar memberi waktu hewan ternak mencerna makanan lebih sempurna. Pada siang hari, pakan yang diberikan adalah berupa sampah organik pasar yang telah dikumpulkan dan dipilah dari sampah anorganik (plastik) yang masih terbawa dalam sampah organik pasar, sedangkan malam harinya hewan ternak diberi pakan rumput kering yang telah difermentasi. Pemberian pakan menggunakan sampah organik, menghemat kebutuhan pakan yang dibutuhkan sehari-hari. Pengalaman peternak Kelompok Tani Sumber Makmur ini, penggunaan rumput lebih dapat diperpanjang waktunya karena adanya penambahan dengan menggunakan pakan sampah pasar, misalnya yang biasa dalam 1 hari dapat memberi pakan sapi dan kambing dengan 1 *pick up* rumput, maka penggunaan 1 *pick up* rumput ini dapat diperpanjang menjadi beberapa hari dengan adanya tambahan pakan berupa sampah organik.

Jumlah sampah organik pasar yang diberikan ke hewan ternak setiap harinya sebanyak 1 *pick up* atau setara dengan 1 ton (namun jumlah ini berfluktuatif tergantung pada jumlah sampah yang dikumpulkan). Adapun jenis sampah organik yang dapat dijadikan pakan ternak antara lain berupa sisa sayuran, kulit pisang, dan sisa buah, namun berdasarkan pengalaman peternak bahwa kulit bawang dan cabai tidak dikonsumsi oleh sapi. Kondisi sampah organik yang dimanfaatkan sebagai bahan pakan ternak merupakan sampah yang baru diperoleh dari sumber.



Gambar 3. Pakan Ternak dari Sampah Organik Pasar

Dalam pembuatan pakan ternak yang difermentasi perlu dilakukan pembuatan bahan cair terlebih dahulu yang berisikan molase, Mikroba EM₄, dan air dengan rasio (1 drum 200 L) = 20:1:179. Rumput yang telah dikeringkan kemudian ditambahkan 5L bahan cair fermentasi dengan 10 kg dedak kemudian dicampur rata dan ditutup dengan terpal agar terjadi proses secara anaerobik, proses ini membutuhkan waktu selama 2 minggu. Selain makanan padat, diberikan juga ampas tahu yang diambil dari Industri pembuatan Tahu/Tempe di daerah Sombor Kota Balikpapan sebagai tambahan nutrisi bagi hewan ternak dalam bentuk cair.

B. Sistem Pemanfaatan Kotoran Padat Sapi

Untuk menerapkan konsep *Economy Circular*, Kelompok Tani Sumber Makmur mengolah kotoran sapi menjadi pupuk kandang dan diperjualbelikan ke industri tambang dan perkebunan sawit. Di Industri Pertambangan, pupuk kandang kotoran sapi digunakan sebagai pupuk tanaman dalam kegiatan reklamasi lahan sedangkan di Perkebunan Sawit digunakan sebagai pupuk organik pada tanaman sawit. Tiap harinya, 1 ekor sapi dapat menghasilkan 10 kg kotoran padat (*faeces*). Kotoran padat tersebut dikumpulkan ke dalam ruangan bersekat untuk proses pengeringan secara alami (diangin-anginkan) dan terlindung dari air hujan. Ruang tersebut berkapasitas 10 – 12 Ton kotoran padat. Untuk membuat pupuk kandang organik maka, kotoran padat dicampurkan dengan dolomit sebanyak 20 Kg dan 200 L mikroba rumen sapi dengan waktu proses selama 1 bulan. Selama waktu proses berlangsung, dilakukan pengadukan agar proses pembuatan pupuk kandang berjalan sempurna dan mengurangi panas yang dihasilkan dari proses pembuatan tersebut. Sebelum proses pengemasan dan pendistribusian, pupuk kandang dihaluskan terlebih dahulu dengan mesin pencacah lalu dikemas ke dalam karung 25 kg. Banyaknya jumlah pupuk kandang yang dihasilkan disesuaikan dengan banyaknya jumlah permintaan dari konsumen.



Gambar 4. Proses Pembuatan Pupuk Kandang

Dari hasil pengujian kandungan pupuk organik padat, diperoleh nilai C/N sesuai standar baku mutu pupuk organik padat adalah ≤ 25 , yaitu 10,5. C/N merupakan indikator yang menunjukkan tingkat kematangan dari bahan kompos. Dari nilai ratio C/N kompos tersebut menunjukkan bahwa bahan organik sudah terdekomposisi dan hampir menjadi kompos secara sempurna (Ismayana et al., n.d, 2012) Nilai pH pada pupuk organik sudah dalam pH ideal dekomposisi anaerobik antara 6 – 8 pada nilai derajat tersebut mikroba dapat mendekomposisi bahan organik (Andriany et al., 2018). Hasil pengujian pupuk organik padat dapat dilihat pada tabel 1.

Tabel 1. Hasil Pengujian Pupuk Organik Padat

Parameter	Nilai	Satuan	Metode
Kadar Air	73,47	%	SNI 7763:2018 butir 6.3
pH	7,43		SNI 7763:2018 butir 6.4
C-Organik	34,85	%	SNI 7763:2018 butir 6.5
N-Total	3,32	%	IKM PO.07
Phosphate (P)	3,75	%	SNI 7763:2018 butir 6.7 dan 6.7.4.2.2
Potassium (K)	0,59	%	SNI 7763:2018 butir 6.7 dan 6.7.4.2.1
Magnesium	0,58	%	
Fe	0,27	%	
Cu	0,001	%	IKM PO.10
Zn	0,05	%	
Mn	0,47	%	
C/N	10,5		

C. Sistem Pemanfaatan Kotoran Cair Sapi

Selain kotoran padat yang dimanfaatkan sebagai pupuk kandang, adapun kotoran cair (urine) dari hewan ternak yang dimanfaatkan sebagai pupuk cair organik. Kandang sapi telah didesain sedemikian rupa agar saluran tidak tercampur dengan limpasan air hujan. Dari 15 ekor sapi didapatkan 200 Liter urine sapi tiap harinya. Urine sapi masuk ke dalam saluran pengumpul dan masuk ke kolam penampungan yang kemudian dipompa ke dalam 2 (dua) tandon yang masing-masing berkapasitas 1100L. selanjutnya dari tandon, urine sapi dialirkan ke dalam masing-masing drum berukuran 200 L. untuk dijadikan pupuk cair ditambahkan bahan campuran untuk meningkatkan nutrisi berupa Empon-Empon, Pisang, Sabut Kelapa, dan Nanas dengan masing-masing sebanyak 5-10% untuk 200 L urine sapi dengan waktu proses selama 1 bulan, yang selanjutnya dikemas ke dalam jerigen 25 L. Pupuk cair organik ini pula didistribusikan ke Industri Pertambangan dan Perkebunan Sawit.



Gambar 5. Proses Pembuatan Pupuk Cair

Penggunaan pupuk organik lebih cepat dalam penyerapan dalam tanah. Berdasarkan baku mutu yang digunakan yaitu Keputusan Menteri Pertanian RI No. 261 Tahun 2019, pH pupuk yang diperbolehkan adalah 4-9. Maka nilai pH dari pupuk organik cair sudah memenuhi baku mutu yang ditetapkan. pH yang tinggi disebabkan oleh penguraian protein di dalam bahan organik. Sedangkan pH yang terendah akan menyebabkan sebagian mikroba mati dan mengganggu proses pengomposan. Dari hasil kandungan nutrisi pupuk organik cair yang diujikan di laboratorium menunjukkan nilai Nitrogen (N), Phospat (P), dan Potassium (K) masih terlalu rendah dibandingkan dengan baku mutu yaitu berkisar 2 – 6%. Kandungan yang terlalu rendah dapat disebabkan oleh proses pengomposan terlalu cepat atau bahan tambahan yang digunakan sedikit. (Sari et al., 2022)

Tabel 2. Hasil Pengujian Pupuk Organik Cair

Parameter	Nilai	Satuan	Metode
pH	8,49		SNI 7763:2018 butir 6.4
C-Organik	4,56	%	IKM PO.06
N-Total	0,199	%	IKM PO.07
Phosphate (P)	0,004	%	SNI 7763:2018 butir 6.7 dan 6.7.4.2.2
Potassium (K)	1,56	%	SNI 7763:2018 butir 6.7 dan 6.7.4.2.1
Magnesium	0,02	%	
Fe	0,005	%	
Cu	0	%	IKM PO.10
Zn	0,001	%	
Mn	0,01	%	
C/N	10,5		

D. Potensi Pengelolaan Peternakan Sapi dan Kambing Berbasis Ekonomi Sirkular

Pengelolaan sampah organik di lingkungan pasar dari limbah sayuran dan buah-buahan dapat dimanfaatkan sebagai pakan ternak. Begitu pula pada industri kedelai yang menghasilkan limbah yang berasal dari ampas tahu dan kulit ari yang masih memiliki nilai nutrisi bagi ternak. Pemanfaatan tersebut dapat mengurangi sampah yang masuk ke TPA. Kotoran yang dihasilkan oleh ternak juga dapat dimanfaatkan dalam pembuatan pupuk organik padat dan cair. Kotoran tersebut dimanfaatkan oleh petani, pemilik perkebunan untuk meningkatkan hasil pertanian, serta pupuk ini telah dimanfaatkan oleh industri pertambangan dalam kegiatan reklamasi lahan. Hasil pertanian yang menggunakan pupuk organik, meningkatkan produksi pertanian secara kuantitas dan kualitas, begitu pula dalam kegiatan reklamasi lahan pada industri pertambangan agar mengurangi pencemaran lingkungan, dan meningkatkan kualitas lahan secara berkelanjutan dan di bawah ini adalah alur *Economy Circular* yang terjadi mulai dari pasar penghasil sampah organik hingga pemanfaatan pupuk organik dari kotoran hewan ternak sapi dan kambing.

dicampur rata dan ditutup dengan terpal agar terjadi proses secara anaerobik, proses ini membutuhkan waktu selama 2 minggu. Selain makanan padat, diberikan juga ampas tahu yang diambil dari Industri pembuatan Tahu/Tempe di daerah Sumber Kota Balikpapan sebagai tambahan nutrisi bagi hewan ternak dalam bentuk cair.

B. Sistem Pemanfaatan Kotoran Padat Sapi

Untuk menerapkan konsep *Economy Circular*, Kelompok Tani Sumber Makmur mengolah kotoran sapi menjadi pupuk kandang dan diperjualbelikan ke industri tambang dan perkebunan sawit. Di Industri Pertambangan, pupuk kandang kotoran sapi digunakan sebagai pupuk tanaman dalam kegiatan reklamasi lahan sedangkan di Perkebunan Sawit digunakan sebagai pupuk organik pada tanaman sawit. Tiap harinya, 1 ekor sapi dapat menghasilkan 10 kg kotoran padat (*faeces*). Kotoran padat tersebut dikumpulkan ke dalam ruangan bersekat untuk proses pengeringan secara alami (diangin-anginkan) dan terlindung dari air hujan. Ruangan tersebut berkapasitas 10 – 12 Ton kotoran padat. Untuk membuat pupuk kandang organik maka, kotoran padat dicampurkan dengan dolomit sebanyak 20 Kg dan 200 L mikroba rumen sapi dengan waktu proses selama 1 bulan. Selama waktu proses berlangsung, dilakukan pengadukan agar proses pembuatan pupuk kandang berjalan sempurna dan mengurangi panas yang dihasilkan dari proses pembuatan tersebut. Sebelum proses pengemasan dan pendistribusian, pupuk kandang dihaluskan terlebih dahulu dengan mesin pencacah lalu dikemas ke dalam karung 25 kg. Banyaknya jumlah pupuk kandang yang dihasilkan disesuaikan dengan banyaknya jumlah permintaan dari konsumen.



Gambar 8. Proses Pembuatan Pupuk Kandang

Dari hasil pengujian kandungan pupuk organik padat, diperoleh nilai C/N sesuai standar baku mutu pupuk organik padat adalah ≤ 25 , yaitu 10,5. C/N merupakan indikator yang menunjukkan tingkat kematangan dari bahan kompos. Dari nilai ratio C/N kompos tersebut menunjukkan bahwa bahan organik sudah terdekomposisi dan hampir menjadi kompos secara sempurna (Ismayana et al., n.d, 2012) Nilai pH pada pupuk organik sudah dalam pH ideal dekomposisi anaerobik antara 6 – 8 pada nilai derajat tersebut mikroba dapat mendekomposisi bahan organik (Andriany et al., 2018). Hasil pengujian pupuk organik padat dapat dilihat pada tabel 1.

Tabel 1. Hasil Pengujian Pupuk Organik Padat

Parameter	Nilai	Satuan	Metode
Kadar Air	73,47	%	SNI 7763:2018 butir 6.3
pH	7,43		SNI 7763:2018 butir 6.4
C-Organik	34,85	%	SNI 7763:2018 butir 6.5
N-Total	3,32	%	IKM PO.07
Phosphate (P)	3,75	%	SNI 7763:2018 butir 6.7 dan 6.7.4.2.2
Potassium (K)	0,59	%	SNI 7763:2018 butir 6.7 dan 6.7.4.2.1
Magnesium	0,58	%	
Fe	0,27	%	
Cu	0,001	%	IKM PO.10
Zn	0,05	%	
Mn	0,47	%	
C/N	10,5		

C. Sistem Pemanfaatan Kotoran Cair Sapi

Selain kotoran padat yang dimanfaatkan sebagai pupuk kandang, adapun kotoran cair (urine) dari hewan ternak yang dimanfaatkan sebagai pupuk cair organik. Kandang sapi telah didesain sedemikian rupa agar saluran tidak tercampur dengan limpasan air hujan. Dari 15 ekor sapi didapatkan 200 Liter urine sapi tiap harinya. Urine sapi masuk ke dalam saluran pengumpul dan masuk ke kolam penampungan yang kemudian dipompa ke dalam 2 (dua) tandon yang masing-masing berkapasitas 1100L. selanjutnya dari tandon, urine sapi dialirkan ke dalam masing-masing drum berukuran 200 L. untuk dijadikan pupuk cair ditambahkan bahan campuran untuk meningkatkan nutrisi berupa Empon-Empon, Pisang, Sabut Kelapa, dan Nanas dengan masing-masing sebanyak 5-10% untuk 200 L urine sapi dengan waktu proses selama 1 bulan, yang selanjutnya dikemas ke dalam jerigen 25 L. Pupuk cair organik ini pula didistribusikan ke Industri Pertambangan dan Perkebunan Sawit.



Gambar 9. Proses Pembuatan Pupuk Cair

Penggunaan pupuk organik lebih cepat dalam penyerapan dalam tanah. Berdasarkan baku mutu yang digunakan yaitu Keputusan Menteri Pertanian RI No. 261 Tahun 2019, pH pupuk yang diperbolehkan adalah 4-9. Maka nilai pH dari pupuk organik cair sudah memenuhi baku mutu yang ditetapkan. pH yang tinggi disebabkan oleh penguraian protein di dalam bahan organik. Sedangkan pH yang terendah akan menyebabkan sebagian mikroba mati dan mengganggu proses pengomposan. Dari hasil kandungan nutrisi pupuk organik cair yang diujikan di laboratorium menunjukkan nilai Nitrogen (N), Phospat (P), dan Potassium (K) masih terlalu rendah dibandingkan dengan baku mutu yaitu berkisar 2 – 6%. Kandungan yang terlalu rendah dapat disebabkan oleh proses pengomposan terlalu cepat atau bahan tambahan yang digunakan sedikit. (Sari et al., 2022)

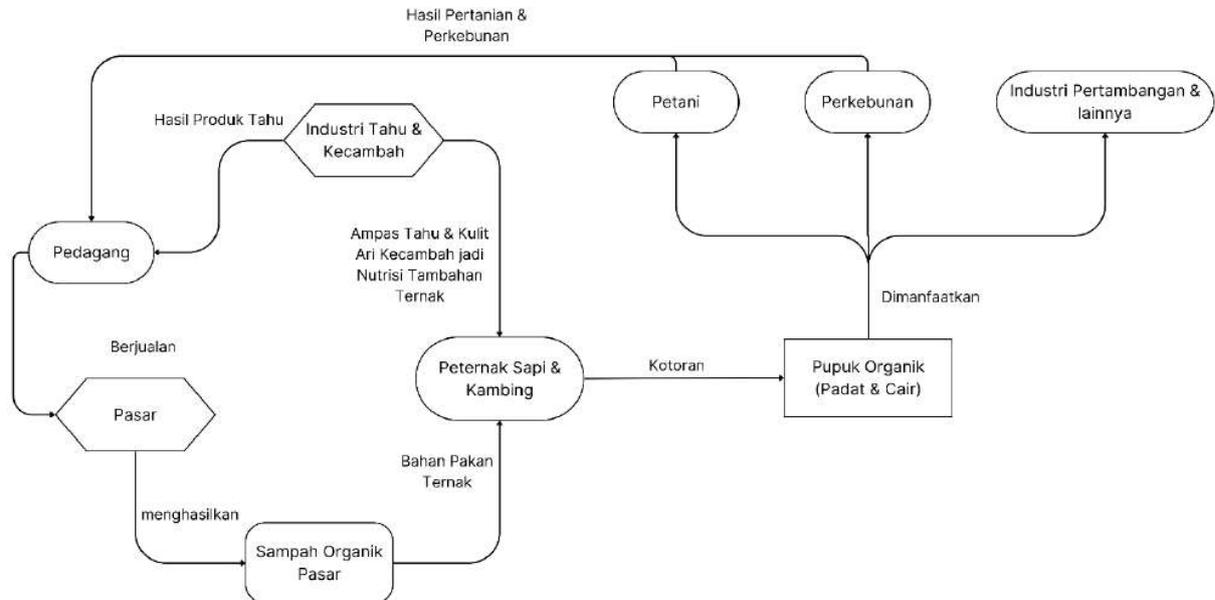
Tabel 2. Hasil Pengujian Pupuk Organik Cair

Parameter	Nilai	Satuan	Metode
pH	8,49		SNI 7763:2018 butir 6.4
C-Organik	4,56	%	IKM PO.06
N-Total	0,199	%	IKM PO.07
Phosphate (P)	0,004	%	SNI 7763:2018 butir 6.7 dan 6.7.4.2.2
Potassium (K)	1,56	%	SNI 7763:2018 butir 6.7 dan 6.7.4.2.1
Magnesium	0,02	%	
Fe	0,005	%	
Cu	0	%	IKM PO.10
Zn	0,001	%	
Mn	0,01	%	
C/N	10,5		

D. Potensi Pengelolaan Peternakan Sapi dan Kambing Berbasis Ekonomi Sirkular

Pengelolaan sampah organik di lingkungan pasar dari limbah sayuran dan buah-buahan dapat dimanfaatkan sebagai pakan ternak. Begitu pula pada industri kedelai yang menghasilkan limbah yang berasal dari ampas tahu dan kulit ari yang masih memiliki nilai nutrisi bagi ternak. Pemanfaatan tersebut dapat mengurangi sampah yang masuk ke TPA. Kotoran yang dihasilkan oleh ternak juga dapat dimanfaatkan dalam pembuatan pupuk organik padat dan cair. Kotoran tersebut dimanfaatkan oleh petani,

pemilik perkebunan untuk meningkatkan hasil pertanian, serta pupuk ini telah dimanfaatkan oleh industri pertambangan dalam kegiatan reklamasi lahan. Hasil pertanian yang menggunakan pupuk organik, meningkatkan produksi pertanian secara kuantitas dan kualitas, begitu pula dalam kegiatan reklamasi lahan pada industri pertambangan agar mengurangi pencemaran lingkungan, dan meningkatkan kualitas lahan secara berkelanjutan dan di bawah ini adalah alur *Economy Circular* yang terjadi mulai dari pasar penghasil sampah organik hingga pemanfaatan pupuk organik dari kotoran hewan ternak sapi dan kambing.



Gambar 10. *Economy Circular*

4. Kesimpulan

Penerapan *economy circular* pada dasarnya adalah penggunaan sumber daya secara maksimal dan menghasilkan limbah secara minimal. Pada studi kasus Kelompok Tani Sumber Makmur, *economy circular* telah diterapkan dari hulu ke hilir, mulai dari penggunaan alternatif pakan ternak sapi dan kambing berupa sampah organik pasar, hingga pengelolaan kotoran sapi menjadi pupuk organik baik berupa kotoran padatannya menjadi pupuk kandang, dan urine sapi menjadi pupuk organik cair yang selanjutnya akan dipasarkan. Keuntungan yang diperoleh oleh peternak tidak hanya keuntungan dari penjualan hewan ternak berupa sapi dan kambing saja, namun dapat juga diperoleh dari penjualan pupuk organik tersebut. Diharapkan penerapan *economy circular* seperti ini dapat diterapkan lebih luas bagi kelompok tani lainnya dan membutuhkan kolaborasi dari berbagai sektor untuk penelitian lebih mendalam.

5. Pengakuan

Terimakasih kami sampaikan kepada Bapak Wahyu Setiawan sebagai pengelola Kelompok Tani Sumber Makmur Gunung Tembak Kota Balikpapan, atas keterlibatan beliau dalam penyajian data, berbagi pengalaman, dan dukungan lainnya hingga penelitian dan penulisan jurnal ilmiah ini dapat diselesaikan. Terimakasih juga kami sampaikan kepada mahasiswa Teknik Lingkungan Universitas Balikpapan yang telah berpartisipasi mengikuti kegiatan ini sebagai bentuk pembelajaran lapangan.

6. Daftar Pustaka

- Andriany, A., Fahrudin, F., & Abdullah, A. (2018). Pengaruh Jenis Bioaktivator Terhadap Laju Dekomposisi Seresah Daun Jati *Tectona grandis* L.f., di Wilayah Kampus UNHAS Tamalanrea. *BIOMA: JURNAL BIOLOGI MAKASSAR*, 3(2). <https://doi.org/10.20956/bioma.v3i2.5820>
- Chadwick, D., Sommer, S., Thorman, R., Fanguero, D., Cardenas, L., Amon, B., & Misselbrook, T. (2011). Manure management: Implications for greenhouse gas emissions. *Animal Feed Science and Technology*, 166–167, 514–531. <https://doi.org/10.1016/j.anifeedsci.2011.04.036>

DLH Kota Balikpapan. (2022). Kajian Review Master Plan AMDAL TPA Manggar (Kajian Teknis Pembuangan Air Imbah) Kota Balikpapan.

Ismayana, A., Indrasti, N. S., Maddu, A., & Fredy, A. (2012). *Faktor Rasio C/N Awal dan Laju Aerasi Pada Proses Co-Composting Bagasse dan Blotong*.

Masyhuri, Zainuddin. (2008). *Metodologi dan Penelitian Pendekatan Praktis dan Aplikatif*. Bandung: Refika Editama.

Murray, A., Skene, K., & Haynes, K. (2017). The Circular Economy: An Interdisciplinary Exploration of the Concept and Application in a Global Context. *Journal of Business Ethics*, 140(3), 369–380. <https://doi.org/10.1007/s10551-015-2693-2>

Nikolaienko, A. (2019). Resource efficiency strategies based on the circular economy. *European Journal of Management Issues*, 27(3–4), 90–98. <https://doi.org/10.15421/191910>

Ratriyanto, A., Widyawati, S. D., P.S. Suprayogi, W., Prastowo, S., & Widias, N. (2019). Pembuatan Pupuk Organik dari Kotoran Ternak untuk Meningkatkan Produksi Pertanian. *SEMAR (Jurnal Ilmu Pengetahuan, Teknologi, dan Seni bagi Masyarakat)*, 8(1). <https://doi.org/10.20961/semar.v8i1.40204>

Sari, D. A. P., Taniwiryono, D., Andreina, R., Nursetyowati, P., & Irawan, D. S. (2022). Pembuatan Pupuk Organik Cair dari Hasil Pengolahan Sampah Organik Rumah Tangga dengan Bantuan Larva Black Soldier Fly (BSF). *Agro Bali : Agricultural Journal*, 5(1), 102–112. <https://doi.org/10.37637/ab.v5i1.848>

Outline business case untuk pengelolaan sampah Manggar, diunduh dari https://web.balikpapan.go.id/uploaded/PS_Executive_Summary.pdf. diunduh pada 28 Mei 2023.



Pemanfaatan Kayu Gelam (*Melaleuca cajuputi* Powell) sebagai Struktur Perkuatan Jalan

Muhammad Afief Ma'ruf¹⁾, Rusdiansyah¹⁾, Rusliansyah¹⁾

¹⁾Program Studi Teknik Sipil, Fakultas Teknik, Universitas Lambung Mangkurat

E-mail: afief.maruf@ulm.ac.id

ABSTRAK

Kayu gelam yang termasuk dalam genus *Melaleuca* dari famili *Myrtaceae* merupakan tumbuhan yang tumbuh secara alami di lahan gambut Kalimantan Selatan, Kalimantan Tengah, dan daerah lainnya. Kayu gelam oleh Departemen Kehutanan digolongkan dalam kelas kuat II dan kelas awet kayu III. Salah satu bentuk pemanfaatan kayu gelam di dunia konstruksi adalah sebagai struktur perkuatan jalan. Penelitian ini mengidentifikasi bentuk penggunaan kayu gelam sebagai struktur perkuatan jalan dan besar volume kayu gelam yang digunakan. Metode penelitian adalah pengamatan lapangan serta studi literatur mengenai pemanfaatan kayu gelam sebagai struktur perkuatan jalan. Kayu gelam yang dimanfaatkan untuk struktur perkuatan jalan umumnya digunakan pada perkuatan urugan jalan, pondasi dinding penahan tanah, dan pondasi siring timbunan dengan diameter 8-10 cm dan panjang 3,5-4 m. Penggunaan kayu gelam baik sebagai pondasi maupun sebagai dinding penahan tanah dikarenakan penggunaan kayu gelam tersebut terbukti mampu memperkuat daya dukung maupun tahanan geser tanah. Total volume penggunaan kayu gelam sebagai pondasi jalan di Kota Banjarmasin selama tahun 2022 mencapai 678.606 m³. Jumlah ini menunjukkan bahwa pemanfaatan kayu gelam dalam pekerjaan jalan masih sangat dibutuhkan terutama di Kalimantan Selatan dan sekitarnya yang memiliki struktur tanah lunak dan tanah rawa.

Kata Kunci: kayu gelam, *Melaleuca cajuputi* Powell, perkuatan jalan, pondasi jalan, dinding penahan tanah

ABSTRACT

Gelam wood, which belongs to the genus Melaleuca of the Myrtaceae family, is a plant that grows naturally on the peatlands of South Kalimantan, Central Kalimantan and other areas. Gelam wood is classified by the Ministry of Forestry in strong class II and wood durable class III. One form of utilization of gelam wood in the world of construction is as a road reinforcement structure. This study identified the form of use of gelam wood as a road reinforcement structure and the volume of gelam wood used. The research method is field observation and literature study regarding the use of gelam wood as a road strengthening structure. Gelam wood used for road reinforcement structures is generally used for road embankment reinforcement, retaining wall foundations, and embankment siring foundations with a diameter of 8-10 cm and a length of 3,5-4 m. The use of gelam wood both as a foundation and as a retaining wall is because the use of gelam wood has proven to be able to strengthen the bearing capacity and shear resistance of the soil. The total volume of using gelam wood as a road foundation in the City of Banjarmasin during 2022 reaches 678.606 m³. This number shows that the use of gelam wood in road works is still very much needed, especially in South Kalimantan and its surroundings which have soft soil structures and swampy soil.

Keyword: *gelam wood, Melaleuca cajuputi Powell, road reinforcement, road foundation, retaining wall*

1. Pendahuluan

Kayu gelam yang termasuk dalam genus *Melaleuca* dari famili *Myrtaceae* merupakan tumbuhan yang tumbuh secara alami di lahan gambut Kalimantan Selatan, Kalimantan Tengah, dan daerah lainnya. Dalam

hal ini, menurut Balai Penelitian, Pengembangan Lingkungan Hidup, dan Kehutanan Kota Banjarbaru tahun 2020, spesies yang umumnya dipasarkan sebagai kayu gelam di Pulau Kalimantan adalah *Melaleuca cajuputi* Powell. Kayu gelam seperti yang terlihat pada Gambar 1 mampu tumbuh hingga setinggi mencapai 40 m dan diameter batang mencapai 35 cm. Kayu gelam memiliki karakteristik yang khas yaitu salah satunya mampu beradaptasi dalam lingkungan ekosistem yang berbeda-beda maupun beradaptasi terhadap perubahan lingkungan yang terjadi, sehingga sangat cocok digunakan sebagai bahan konstruksi untuk reklamasi ataupun pembangunan wilayah. Selain dimanfaatkan dalam bentuk kayu batangan (kayu bulat berdiameter kecil), gelam juga dapat dimanfaatkan dalam bentuk kayu gergajian (Arifin dkk., 2014).

Banyaknya pemanfaatan kayu gelam dikarenakan jumlah populasi kayu gelam yang melimpah dan cukup mudah didapatkan di lahan rawa gambut Kalimantan Selatan dan daerah lainnya (Supriyati dkk., 2015). Selain itu ketersediaannya yang masih mencukupi di pasaran untuk saat ini membuatnya sangat cocok dimanfaatkan di Kota Banjarmasin. Hal ini terutama terlihat dari banyaknya dan mudahnya pedagang kayu gelam ditemui di Kota Banjarmasin dan sekitarnya, seperti terlihat pada Gambar 2. Di Kota Banjarmasin sendiri, kayu gelam yang digunakan sebagai besar berasal Kalimantan sendiri, yaitu dari Kabupaten Barito Kuala, Kabupaten Margasari, dan juga dari Kalimantan Tengah, yaitu Kabupaten Kapuas (Ma'ruf dkk., 2023).

Penelitian kali ini mencoba memberikan informasi lebih detail mengenai pemanfaatan kayu gelam sebagai struktur perkuatan jalan di Kalimantan Selatan dan sekitarnya. Hal ini diperlukan untuk memberikan informasi lebih detail mengenai apa saja bentuk pemanfaatan kayu gelam sebagai struktur perkuatan jalan serta berapa banyak sebenarnya volume kayu gelam yang digunakan untuk tujuan tersebut. Informasi ini nantinya akan dapat mendukung penyusunan rencana pemanfaatan kayu gelam untuk masa yang akan datang mengingat saat ini kayu gelam mulai menurun ketersediaannya.



Gambar 1 Kayu Gelam (*Melaleuca cajuputi* Powell)



Gambar 2. Pedagang kayu gelam di Kota Banjarmasin

2. Metode Penelitian

Lingkup wilayah penelitian adalah Kalimantan Selatan dan sekitarnya, khususnya Kota Banjarmasin dan Kabupaten Banjar yang dominan memiliki struktur tanah lunak dan tanah rawa. Penelitian ini mengidentifikasi bentuk penggunaan kayu gelam sebagai pondasi jalan dan besar volume kayu gelam yang digunakan. Objek penelitian adalah pekerjaan-pekerjaan konstruksi jalan yang menggunakan kayu gelam sebagai struktur perkuatan. Metode penelitian adalah pengamatan lapangan serta studi literatur mengenai pemanfaatan kayu gelam sebagai struktur perkuatan jalan.

3. Hasil dan Pembahasan

Pada umumnya daerah Banjarmasin dan sekitarnya mempunyai struktur lapisan tanah yang berkategori sangat lunak, karena sebagian daratannya digenangi oleh air atau dipengaruhi oleh pasang surut air sungai. dengan kedalaman tanah keras Kota Banjarmasin yang berada pada kedalaman 28–42,4 m (Ma'ruf dkk., 2019). Dalam hal ini maka penggunaan pondasi yang cocok untuk bangunan sederhana adalah jenis pondasi mengapung dengan bahan pondasi yang dapat menyesuaikan dengan kondisi karakteristik fisik maupun kimia dari tanah lunak tersebut. Dalam hal ini kayu gelam adalah salah satu bahan pondasi yang paling cocok karena mampu beradaptasi dengan kondisi sekitar (Mohamad dkk., 2014).

Kayu gelam (*Melaleuca cajuputi Powell*) yang banyak dimanfaatkan untuk bahan konstruksi di Kalimantan Selatan sendiri oleh Departemen Kehutanan (2003) digolongkan dalam kelas kuat II dan kelas awet kayu III. Komposisi kimia kayu gelam sendiri terdiri dari pentosan, selulosa, lignin, dan sedikit material substraktif, dengan berat jenis umumnya rata-rata sebesar 0,85. Kekuatan kayu gelam sendiri akan meningkat jika digunakan dalam area rawa yang selalu terendam, ataupun jika tidak terkena sinar matahari secara langsung. Hingga saat ini pemanfaatan kayu gelam masih sangat luas dilakukan di Kalimantan Selatan, khususnya Kota Banjarmasin dan sekitarnya, karena tipikal jenis tanah di wilayah tersebut yaitu tanah rawa pasang surut yang mana sangat cocok untuk penggunaan kayu gelam sebagai konstruksi pondasi, terutama struktur pondasi. Dari penelitian terkait, diperoleh informasi bahwa untuk daerah Kalimantan Selatan, kayu gelam yang berukuran kecil dengan diameter 2 cm hingga 3 cm umumnya digunakan untuk perancah konstruksi, kandang ternak, ataupun tiang penanda tanaman. Sedangkan kayu gelam dengan diameter hingga 10 cm dan lebih besar digunakan sebagai tiang ataupun pondasi bangunan untuk pembangunan rumah panggung yg membutuhkan pasak ke tiang panggung untuk menahan erosi tanah, dan sebagai bahan konstruksi yaitu untuk balok dan papan kayu, serta untuk pembuatan peti kayu

dalam pengepakan di ekspedisi pengiriman barang, sedang kayu-kayu sisa dimanfaatkan untuk kayu bakar (Arifin dkk., 2014).

Khusus untuk pekerjaan jalan, Penelitian yang dilakukan pada proyek pembangunan jalan alternatif makam Syech Muhammad Arsyad Al-Banjari di Kabupaten Banjar pada menunjukkan bahwa umumnya kayu gelam digunakan sebagai pondasi jalan yang berada di lahan rawa atau tanah lunak. Kayu gelam yang digunakan sebagai pondasi jalan pada proyek ini berdiameter 8-10 cm dengan panjang 3,5 m hingga 4 m. Pondasi kayu gelam dipancangkan dengan jarak 40-50 cm antar pondasi dengan bantuan excavator, seperti terlihat pada Gambar 4 dan 5. Ukuran kayu gelam yang digunakan pada pondasi jalan tersebut bersesuaian dengan penelitian lain yang menyatakan bahwa ukuran yang disyaratkan sebagai pondasi adalah diameter kayu antara 8 cm hingga 15 cm dan panjang tiang kayu antara 3,5 m hingga 6 m (Rusdiansyah, 2020; Yusgian & Ma'ruf, 2021). Berdasarkan data dari Dinas Pekerjaan Umum dan Penataan Ruang Kota Banjarmasin selama tahun 2022, jumlah kayu gelam yang digunakan sebagai pondasi jalan mencapai 678.606 m³, seperti dapat dilihat pada data yang ditampilkan pada Tabel 1.

Penggunaan pondasi kayu gelam bertujuan untuk meningkatkan daya dukung tanah dasar, karena lahan asli lokasi proyek adalah rawa gambut. Kemampuan kayu gelam untuk meningkatkan daya dukung tersebut telah dibuktikan oleh penelitian terkait dalam skala laboratorium yang menyatakan bahwa penggunaan cerucuk kayu gelam mampu meningkatkan daya dukung pondasi di atas tanah gambut (Dewi dkk., 2020). Selain penelitian skala laboratorium, penelitian terkait juga melakukan pengujian *loading test* lapangan untuk melihat kekuatan batas (ultimit) daya dukung tiang tunggal pondasi kayu gelam. Penelitian dilakukan di lokasi yang merupakan tanah lunak yang memiliki kadar air cukup tinggi dan didominasi tanah gambut dengan menggunakan sampel tiang pondasi kayu gelam berdiameter 12 cm dan 14 cm dengan panjang 3,5 m. Beban yang diaplikasikan menggunakan beban mati dari material bata *press* dengan pemberian beban secara bertahap hingga penurunan tiang mencapai 10% dari ukuran diameter tiang. Hasil penelitian menunjukkan nilai kapasitas daya dukung ultimit kayu gelam dengan rentang antara 567,75 kg hingga 729,25 kg untuk diameter 12 cm dan 14 cm dengan panjang 3,5 m (Khaliq, 2014). Penelitian lainnya mengenai daya dukung kayu gelam pada pekerjaan pondasi jalan *rigid* menyatakan bahwa dengan menggunakan cerucuk kayu gelam dengan panjang 3,5 m didapatkan daya dukung tiang tunggal sebesar 0,38 ton (Yusgian & Ma'ruf, 2021). Hasil penelitian tersebut menunjukkan bahwa pondasi kayu gelam merupakan bahan yang tepat untuk tanah lunak karena mampu menyalurkan beban melalui lekatan selimut tiangnya dengan tanah.



Gambar 4. Kayu gelam dalam pekerjaan jalan



Gambar 4. Pemancangan pondasi kayu gelam

Tabel 1. Jumlah penggunaan kayu gelam sebagai pondasi jalan di Kota Banjarmasin tahun 2022

No	Nama Ruas	Panjang Jalan (m)	Volume kayu (m ³)
1	Pelebaran Jalan (Jl. Banua Anyar Gg. Veteran)	280	105,60
2	Pelebaran Jalan (Jl. Basirih Dalam)	827	207,93
3	Pelebaran Jalan (Jl. Gandapura)	622	156,39
4	Pelebaran Jalan (Jl. Tatah Belayung)	390	98,06
5	Pembangunan Jalan Jl. Basirih Dalam - Jl. Handil Palung	220	110,63
Total Volume			678,606

(Sumber: Dinas Pekerjaan Umum dan Penataan Ruang Kota Banjarmasin, 2022)

Selain dimanfaatkan untuk memikul beban vertikal atau aksial seperti pada pondasi bangunan, kayu gelam juga dimanfaatkan sebagai perkuatan tanah dalam menahan kelongsoran tanah akibat gaya lateral atau pergerakan horizontal dari lapisan tanah. Pada proyek pembangunan jalan alternatif makam Syech Muhammad Arsyad Al-Banjari di Kabupaten Banjar, kayu gelam juga dimanfaatkan sebagai dinding siring atau turap untuk menahan timbunan oprit jembatan penghubung, seperti terlihat pada Gambar 5. Penggunaan kayu gelam sebagai dinding siring atau turap ini bersesuaian dengan penelitian mengenai penanggulangan longsoran pada timbunan jalan dengan menggunakan dinding turap kayu gelam yang menyatakan bahwa pengaruh perkuatan dinding turap kayu gelam meningkatkan stabilitas tanah dan mengurangi terjadinya longsoran (Gazali, 2019). Penelitian ini juga bersesuaian dengan penelitian lainnya yang menggunakan cerucuk kayu untuk meningkatkan kekuatan geser tanah lunak yang mana pemakaian cerucuk kayu dapat meningkatkan kekuatan geser tanah. Dalam hal ini hasil penelitian menunjukkan bahwa semakin panjang cerucuk kayu yang digunakan, maka kekuatan atau ahanan geser tanah semakin meningkat (Rusdiansyah, 2016).



Gambar 5. Dinding kayu gelam pada oprit jembatan

Kemampuan kayu gelam untuk menahan gaya lateral atau gerakan tanah horizontal berkaitan erat dengan kuat lentur dari kayu gelam itu sendiri. Penelitian kuat lentur kayu dengan metode berdasarkan SNI 03-3959-1995 dan ASTM D-198 yang membandingkan kekuatan lentur kayu gelam dan kayu sengon menunjukkan hasil bahwa kekuatan lentur rata-rata kayu gelam adalah sebesar 100,13 MPa dan lebih tinggi dibandingkan kekuatan lentur rata-rata kayu sengon yang sebesar 82,62 Mpa (Basyaruddin dkk., 2019).

Berdasarkan beberapa hasil penelitian tersebut, maka dapat disimpulkan bahwa kayu gelam yang dimanfaatkan untuk struktur perkuatan jalan umumnya digunakan pada perkuatan urugan jalan, pondasi dinding penahan tanah, dan pondasi siring timbunan. Penggunaan kayu gelam baik sebagai pondasi maupun sebagai dinding penahan tanah dikarenakan penggunaan kayu gelam tersebut terbukti mampu memperkuat daya dukung maupun tahanan geser tanah. Jumlah penggunaan kayu gelam sebagai pondasi jalan yang mencapai 678.606 m³ selama tahun 2022 menunjukkan bahwa pemanfaatan kayu gelam dalam pekerjaan jalan masih sangat dibutuhkan terutama di Kalimantan Selatan dan sekitarnya yang memiliki struktur tanah lunak dan tanah rawa.

4. Kesimpulan

Hasil penelitian tentang bentuk penggunaan kayu gelam sebagai struktur perkuatan jalan dan besar volume kayu gelam memperoleh beberapa kesimpulan sebagai berikut:

1. Kayu gelam yang dimanfaatkan untuk struktur perkuatan jalan umumnya digunakan pada perkuatan urugan jalan, pondasi dinding penahan tanah, dan pondasi siring timbunan dengan diameter 8-10 cm dan panjang 3,5-4 m.
2. Penggunaan kayu gelam baik sebagai pondasi maupun sebagai dinding penahan tanah dikarenakan penggunaan kayu gelam tersebut terbukti mampu memperkuat daya dukung maupun tahanan geser tanah.
3. Total volume penggunaan kayu gelam sebagai pondasi jalan di Kota Banjarmasin selama tahun 2022 mencapai 678.606 m³.
4. Jumlah ini menunjukkan bahwa pemanfaatan kayu gelam dalam pekerjaan jalan masih sangat dibutuhkan terutama di Kalimantan Selatan dan sekitarnya yang memiliki struktur tanah lunak dan tanah rawa.

5. Pengakuan

Ucapan terima kasih diberikan kepada Muhammad Baihaki dan Sofie Wulan Andini yang telah membantu melaksanakan pengamatan pada proyek pembangunan jalan alternatif makam Syech Muhammad Arsyad Al-Banjari di Kabupaten Banjar. Ucapan terima kasih juga diberikan kepada Dinas Pekerjaan Umum dan Penataan Ruang Kota Banjarmasin dan Fakultas Teknik Universitas Lambung Mangkurat serta seluruh pihak yang telah mendukung terlaksananya penelitian ini.

6. Daftar Pustaka

Arifin, Y. F., Hamidah, S., & Arifin, Y. F. (2014). The Analysis of Management and Timber Trade System of Gelam (*Melaleuca cajuputi*) From Peat Swamp Forest in South Kalimantan. *Journal of Wetlands Environmental Management*, 2(2), 79–83. <https://doi.org/10.20527/jwem.v2i2.40>

Balai Penelitian, Pengembangan Lingkungan Hidup, dan Kehutanan Kota Banjarbaru. (2020). *Komoditas Paludikultur di Kalimantan*. Penerbit IPB Press.

Basyaruddin, B., Suryaningsih, A., & Awali, J. (2019). Potensi Pemanfaatan Kayu Gelam dan Kayu Sengon Dalam Dunia Konstruksi Berdasarkan Uji Kuat Lentur. *Rekayasa Sipil*, 13(3), 193–198. <https://doi.org/10.21776/ub.rekayasasipil.2019.013.03.6>

Departemen Kehutanan. (2003). *Budidaya Kayu Putih (Melaleuca cajuputi) (silviculture of kayu putih)*. Departemen Kehutanan, Jakarta.

Dewi, R., Hastuti, Y., Sutejo, Y., Iqbal, M. M., & Arfan, M. (2020). Peat soil improvement method using woven bamboo and Cerucuk. *International Journal on Advanced Science, Engineering, and Information Technology*, 10(4), 1617–1623. <https://doi.org/10.18517/ijaseit.10.4.4199>

Dinas Pekerjaan Umum dan Penataan Ruang Kota Banjarmasin (2022). *Sistem Informasi Manajemen Bangunan Gedung*. (Tidak dipublikasikan).

Gazali, A. (2019). Analisis Penanggulangan Longsor pada Tepi Timbunan Jalan Menggunakan Perkuatan Dinding Turap Galam di Daerah Rawa Kabupaten Barito Kuala. *Seminar Nasional Tahunan VI Program Studi Magister Teknik Sipil ULM*, 119–128. <http://s2tekniksipil.ulm.ac.id/wp-content/uploads/2020/02/14.-Akhmad-Gazali.pdf>

Khalik, A. (2014). Penentuan Beban Batas Tiang Galam dengan Loading Test. *Jurnal Poros Teknik*, 6(1), 8–21. <https://ejurnal.poliban.ac.id/index.php/porosteknik/article/view/143/132>

Ma'ruf, M. A., Rusliansyah, Fitriati, U., & Rachman, A. A. (2019). Digital Mapping of Hard Soil Depth in Banjarmasin City. *International Journal of Engineering and Technology*, 11(5), 316–320. <https://doi.org/10.7763/ijet.2019.v11.1168>

Ma'ruf, M. A., Arifin, Y. F., Asyari, M., & Rusdiansyah. (2023). Utilization Pattern and Potential of Gelam Wood (*Melaleuca Cajuputi Powell*) as a Foundation Structure. *International Journal of GEOMATE*, 25(107), 25–32. <https://doi.org/10.21660/2023.107.3657>

Mohamad, M., Razak, S. B. A., Salim, J. M., & Ismail, S. (2014). Histological observation of Gelam (*Melaleuca cajuputi Powell*) in different ecosystems of Terengganu. *AIP Conference Proceedings*, 1669(26), 1–8. <https://doi.org/10.1063/1.4919208>

Rusdiansyah (2016). Asumsi Sistem Cerucuk Sebagai Alternatif Solusi Dalam Penanganan Kelongsoran Lereng Jalan Diatas Tanah Lunak. *Infoteknik*, 250–278.

Rusdiansyah (2020). *Peningkatan Tahahan Geser Tanah Kohesif dengan Menggunakan Metode Cerucuk*, Mangu Makmur Tanjung Lestari. Bandung, Indonesia.

Supriyati, W., Prayitno, T. A., Sumardi, S., & Marsoem, S. N. (2015). Kearifan Lokal Penggunaan Kayu Gelam dalam Tanah Rawa Gambut di Kalimantan Tengah (Local Wisdom of Utilization of Gelam Wood on Peat swamp Land of Central Kalimantan). *Jurnal Manusia dan Lingkungan*, 22(1), 94. <https://doi.org/10.22146/jml.18729>

Yusgian, Y., & Ma'ruf, M. A. (2021). Analisa Daya Dukung Cerucuk Galam pada Perkerasan Rigid di Ruas Jalan Tatah Bangkal. *Info-Teknik*, 22(2), 249–260. <https://ppjp.ulm.ac.id/journal/index.php/infoteknik/article/view/13783>



Penerapan Model *Random Forest* untuk Prediksi Penyebaran Porositas pada Lapangan 'X'

Nugraha Septiawisal Putra¹⁾, Abdul Gafar Karim¹⁾

¹⁾Program Studi S1 Teknik Perminyakan, Sekolah Tinggi Teknologi Migas Balikpapan

E-mail: nugrahaseptiawisa199@gmail.com

ABSTRAK

Kegiatan karakterisasi reservoir memiliki peran yang penting untuk dapat mengidentifikasi sifat-sifat batuan dan fluida, serta dapat mengestimasi besar cadangan hidrokarbon di bawah permukaan. Estimasi metode tradisional memiliki akurasi yang rendah, sangat memakan waktu, dan galat yang lebih besar selama memprediksi porositas dan permeabilitas reservoir menggunakan data *well logging* serta pengukuran *sample core* yang cukup memakan biaya. Dalam penelitian ini, metode *machine learning Random Forest* diterapkan sebagai solusi yang cepat dan hemat biaya untuk mengestimasi parameter reservoir dari data *well logging*. Enam model telah dikembangkan pada kondisi yang berbeda (jumlah fitur dan transformasi data) yang dibagi menjadi 85% training data dan 15% test data. Penentuan *hyperparameters* merupakan hal yang penting dikarenakan akan sangat berpengaruh ke performa pada setiap model. Hasil *Exploratory Data Analysis* menunjukkan bahwa fitur-fitur yang dapat digunakan sebagai input data untuk memprediksi nilai porositas *core* adalah fitur GR (-0.54), RHOB (-0.51), LLS (-0.44), LLD (-0.4), dan CXO (0.32). Sehingga dilanjutkan ke dalam proses pelatihan model dan ditemukan bahwa model B dengan fitur tiga teratas (GR, RHOB, dan LLS) tanpa transformasi data mendapatkan hasil yang optimal dengan mendapatkan nilai R^2 sebesar 0.8 dan RMSE sebesar 0.034 dengan menggunakan *hyperparameter* $n_estimators = 19$ dan $random_state = 42$. Penelitian dilanjutkan dengan melakukan pelatihan model ulang dengan menggunakan seluruh data *well logging* untuk dapat mengembangkan model prediksi porositas. Prediksi porositas *core* berhasil dilakukan hingga 1.393 data pada baris kosong yang terdapat pada kolom porositas *core*.

Kata Kunci: karakterisasi reservoir, *machine learning*, *random forest*, prediksi porositas, *well logging*

ABSTRACT

Reservoir characterization activities have an important role in identifying rock and fluid properties and estimating the amount of subsurface hydrocarbon reserves. Traditional estimation methods have low accuracy, are very time-consuming, and have larger errors while predicting reservoir porosity and permeability using well-logging data and sample core measurements which are quite costly. This study applied the Random Forest machine learning method as a fast, cost-effective solution for estimating reservoir parameters from well-logging data. Six models have been developed under different conditions (number of features and data transformation,) which are divided into 85% training data and 15% test data. The determination of hyperparameters is important because it will greatly affect the performance of each model. Exploratory data analysis results show that features that can be used as input data to predict core porosity values are GR (-0.54), RHOB (-0.51), LLS (-0.44), LLD (-0.4), and CXO (0.32) features.). So it was continued into the model training process, and it was found that model B with the top three features (GR, RHOB, and LLS) without data transformation got optimal results by getting an R^2 value of 0.8 and an RMSE of 0.034 using the hyperparameter $n_estimators=19$ and $random_state=42$. The research was continued by conducting re-model training using all well-logging data to be able to develop a porosity prediction model. Core porosity prediction was successfully carried out for up to 1393 data in empty rows contained in the core porosity column.

Keywords: reservoir characterization, machine learning, random forest, porosity prediction, well logging

1. Pendahuluan

Kegiatan karakterisasi reservoir memiliki peran yang penting untuk dapat mengidentifikasi sifat-sifat batuan dan fluida, serta dapat mengestimasi besar cadangan hidrokarbon di bawah permukaan. Karakterisasi reservoir merupakan suatu kegiatan yang sangat kompleks mengingat banyak reservoir yang memiliki heterogenitas tinggi yang terbentuk secara alami. Dua di antara karakteristik yang terdapat pada reservoir adalah porositas dan permeabilitas yang merupakan karakteristik utama dalam proses karakterisasi reservoir. Interpretasi *well logging* banyak diterapkan untuk dapat mengestimasi nilai porositas dan permeabilitas pada kedalaman yang bervariasi dikarenakan biaya yang minimal dibandingkan proses *sample core* (Helle & Bhatt, 2002; Lim & Kim, 2004, sebagaimana dikutip dalam Abdel Azim & Aljehani, 2022). Sebaliknya, proses *sample core* merupakan sumber informasi yang terpercaya dikarenakan *sample core* dapat langsung diambil dari sumur bor. Hal ini menyebabkan sumur-sumur yang dilakukan *core data analysis* dapat dijadikan sebagai acuan untuk mengetahui kualitas dari hasil interpretasi dan perhitungan petrofisika untuk sumur-sumur lain yang akan dibor di sekitar pemboran acuan (Oetomo dkk., 2019).

Menurut Yao dkk., 2010; Félix & Muñoz, 2005 sebagaimana dikutip dalam Chen dkk., 2021 menjelaskan bahwa hasil estimasi metode tradisional memiliki akurasi yang rendah, sangat memakan waktu, dan kesalahan yang lebih besar selama memprediksi porositas dan permeabilitas reservoir menggunakan data *well logging*. Serta pengukuran laboratorium *sample core* merupakan kegiatan yang cukup memakan biaya dan terbatas (Chen dkk., 2021). Sehingga untuk mengatasi hal tersebut, terdapat solusi alternatif dengan menggunakan perhitungan regresi untuk melakukan prediksi penyebaran porositas di Lapangan 'X'. Metode *machine learning* dapat diaplikasikan sebagai solusi yang cepat dan hemat biaya untuk mengestimasi parameter reservoir dari hubungan gabungan yang kompleks hingga pengukuran tidak langsung, dalam hal ini diwakili oleh *well log* (Huang dkk., 1997; Helle & Bhatt, 2002; Hamada dkk., 2020 sebagaimana dikutip dalam Andersen dkk., 2022).

Sehingga, dalam penelitian ini bertujuan untuk menentukan variabel yang dapat digunakan untuk proses model *training*, mendapatkan model yang optimal berdasarkan nilai R^2 dan RMSE pada masing-masing model, serta melakukan prediksi penyebaran porositas dengan menggunakan metode *machine learning* dengan algoritma *Random Forest*. Model *Random Forest* telah berhasil didemonstrasikan pada penelitian sebelumnya untuk memprediksi *variable oil recovery* dan analisis sensitivitas dari parameter *Low Salinity Water Injection* (Hidayat & Astsauri, 2021), dan untuk meramalkan kumulatif produksi minyak, performa CO₂-WAG dalam kondisi parameter injeksi yang bervariasi (Li dkk., 2022). Data yang tersedia dalam penelitian ini terdiri dari data petrofisika dan data *core* yang diambil dari lima sumur yang berbeda pada Lapangan 'X'. Kemudian masing-masing model dikembangkan dengan menggunakan variabel yang relevan, dan mencari model yang memiliki kemampuan prediksi yang baik. Membagi data petrofisika menjadi 85% data *training* dari lima sumur berbeda yang diacak untuk mengembangkan model *machine learning*. Setelah model berhasil dikembangkan, 15% data *testing* digunakan untuk menguji model, dan membandingkannya dengan data porositas *core* yang sebenarnya kemudian dilanjutkan dengan melakukan prediksi pada data yang *missing* di variabel porositas dengan menggunakan model yang telah di kembangkan sebelumnya.

2. Metode Penelitian

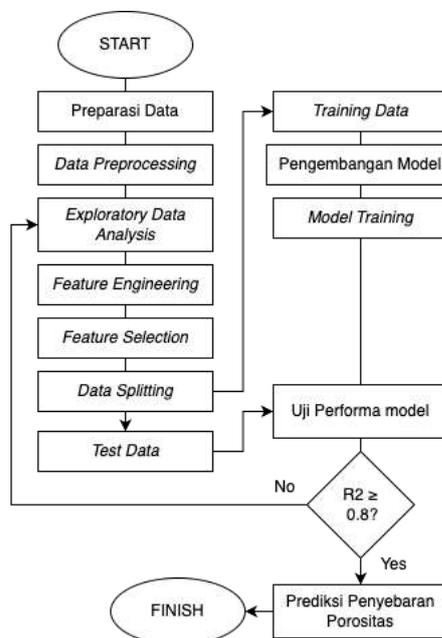
Pada bagian ini, akan menjelaskan rincian dasar teori mengenai metode kuantitatif yang digunakan. Pada bagian ini terdiri dari preparasi data, *data preprocessing*, *exploratory data analysis* (EDA), *feature engineering*, pemilihan fitur, pengembangan model *Random Forest*, *model evaluation metrics* yang digunakan untuk menguji model pada *test data*.

A. Diagram Alir

Diagram alir yang digunakan pada penelitian ini (dapat diilustrasikan sebagai Gambar 1) diterapkan untuk mempersiapkan model *Random Forest* yang dapat digunakan untuk memprediksi porositas *core* berdasarkan data *well logging*.

1. Data dipersiapkan untuk dapat digunakan dalam penelitian ini, berupa data petrofisika sebagai *independent variable* dan data *core* sebagai *dependent variable* (*target variable*).
2. Ketika data telah dipersiapkan, maka perlu untuk melakukan data *preprocessing* terlebih dahulu dengan melihat apakah data terdapat *missing values*, *noisy data*, menghapus *outliers* atau

- transformasi variabel. Serta mengambil keputusan apakah data perlu untuk dibersihkan (*cleaning*) atau ditransformasi.
- Setelah data dibersihkan atau ditransformasi, dapat dilanjutkan ke proses *exploratory data analysis* (EDA) yang bertujuan untuk dapat untuk menggali informasi berupa pola, anomali, uji hipotesis, yang dapat dilakukan secara grafis dan statistik.
 - Feature engineering* dilakukan untuk mendapatkan bentuk distribusi data yang normal, mengatasi *outliers*, dan proses *encoding* untuk data *categorical* agar dapat digunakan pada proses regresi.
 - Setelah *exploratory data analysis* (EDA) dan *feature engineering* dilakukan, maka dapat menentukan fitur yang tepat untuk digunakan untuk proses *training* model nantinya (dapat dilihat dari nilai korelasi masing-masing fitur terhadap *target variable*).
 - Melanjutkan ke dalam proses data *splitting* yang bertujuan untuk membagi data-data untuk digunakan sebagai *training data* dan sebagai *unseen data* (*test data*).
 - Mengembangkan model *random forest* dengan mencari parameter-parameter yang sesuai, dan dilakukan proses *training model* terhadap data-data yang telah digunakan sebagai *input*.
 - Ketika proses pengembangan model telah berhasil, maka hasil *training* yang telah dilakukan pada model diuji performa tersebut dan mengamati nilai R^2 yang didapatkan. Jika nilai R^2 yang didapatkan tidak lebih dari 0,8, maka kembali ke proses *exploratory data analysis* (EDA) dan melakukan *hyperparameter tuning*.
 - Ketika model terbaik telah didapatkan, dan mendapatkan nilai $R^2 \geq 0,8$, maka dapat dilanjutkan ke proses prediksi keseluruhan baris yang kosong pada kolom variabel porositas dengan menggunakan model yang telah didapatkan sebelumnya.



Gambar 1. Diagram alir penelitian

B. *Random Forest*

Random forest merupakan pendekatan *ensemble machine learning* yang diusulkan oleh Breiman (2001), yang memiliki kelebihan dalam proses interpretasi, kenyamanan, dan komputasi dengan kecepatan yang tinggi. *Random forest* dibangun secara *independen* oleh beberapa *decision trees* (Wang dkk., 2022). *Decision Trees* merupakan sebuah algoritma *machine learning* yang sering digunakan dalam tugas klasifikasi dan regresi. *Decision trees* seperti pohon yang dimana setiap *internal node* mempresentasikan fitur/variable, setiap cabang mewakili keputusan atau hasil berdasarkan nilai fitur yang digunakan, dan setiap *leaf node* mewakili keputusan akhir atau hasil yang diprediksi.

Random forest standar dibangun dengan menggunakan *Bootstrap Aggregating* atau *Bagging*. Algoritma ini secara acak memilih sampel dari data mentah sehingga proses *train* dari setiap *regressor*

dasar dalam *ensambel* yang tidak bergantung pada yang lain. Alur spesifik dalam konstruksi random forest adalah sebagai berikut: Pertama, pada setiap *node decision trees*, *variable predictor* diambil sampelnya secara acak, Kemudian, algoritma dapat menemukan minimal *residual sum of squares* (RSS) untuk regresi. Selanjutnya, data dibagi menjadi subset “*in-bag*” untuk *training*, dan subset “*out-of-bag* (OOB)” untuk *testing*. Terakhir *decision trees* digabungkan melalui rata-rata regresi untuk membentuk hasil prediksi akhir (Makariou dkk., 2021)

C. Model Evaluation Metrics

Dalam penelitian ini, dua *model evaluation metrics* digunakan untuk dapat melihat performa model dalam memprediksi nilai porositas *core*. *Model evaluation metrics* yang digunakan antara lain *coefficient of determination* (R^2), dan *root mean squared error* (RMSE). Komponen R^2 menunjukkan akurasi prediksi dari metode yang diusulkan, sedangkan komponen RMSE menunjukkan nilai standar deviasi antara nilai prediksi dan nilai aktualnya.

$$R^2 = \frac{\sum_{i=1}^n (y_{pred} - y_{mean})^2}{\sum_{i=1}^n (y_{actual} - y_{mean})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{pred} - y_{actual})^2} \quad (2)$$

D. Preparasi Data

Pengumpulan data petrofisika dan data *core* pada setiap sumur ditabulasi menjadi satu dataset primer yang terdiri dari data *input* dan *output*. Data petrofisika (*well log*) yang dijadikan sebagai *variable input* dan data porositas *core* dijadikan sebagai variabel *output*. Untuk lebih detail mengenai data *input* dan data *output*, dapat dilihat pada Tabel 1.

Tabel 1. Urutan data *input* dan *output*

No.	Variabel	Kategori	Jenis Variabel
1	WELLNAME	Data Petrofisika	<i>Independent Variables</i>
2	DEPTH	Data Petrofisika	<i>Independent Variables</i>
3	CALI	Data Petrofisika	<i>Independent Variables</i>
4	CXO	Data Petrofisika	<i>Independent Variables</i>
5	SP	Data Petrofisika	<i>Independent Variables</i>
6	DT	Data Petrofisika	<i>Independent Variables</i>
7	GR	Data Petrofisika	<i>Independent Variables</i>
8	LLD	Data Petrofisika	<i>Independent Variables</i>
9	LLS	Data Petrofisika	<i>Independent Variables</i>
10	MLL	Data Petrofisika	<i>Independent Variables</i>
11	NPHI	Data Petrofisika	<i>Independent Variables</i>
12	PEF	Data Petrofisika	<i>Independent Variables</i>
13	RHOB	Data Petrofisika	<i>Independent Variables</i>
14	PHI_CORE	Data Core	<i>Dependent Variables</i>
15	PERM_CORE	Data Core	<i>Dependent Variables</i>

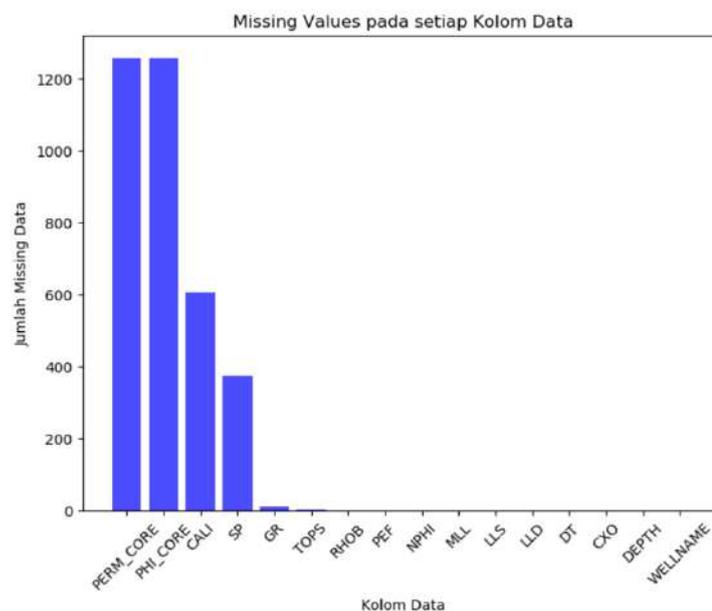
E. Data Preprocessing

Data preprocessing sangat penting dilakukan sebelum penggunaan *machine learning*. *Data preprocessing* merupakan konsep mengubah data mentah menjadi kumpulan data yang bersih. Dataset

diproses untuk memeriksa apakah terdapat nilai yang hilang (*missing values*), data yang berisik (*noisy data*), dan ketidakkonsistenan lainnya sebelum dilakukan pemodelan *machine learning* (Singh dkk. 2021). *Data preprocessing* terbagi menjadi *data cleaning*, *data integration*, *data transformation* dan *data reduction*. Menurut Yan-li & Jia (2012), Teknik-teknik yang dapat digunakan dalam proses data *preprocessing* adalah sebagai berikut:

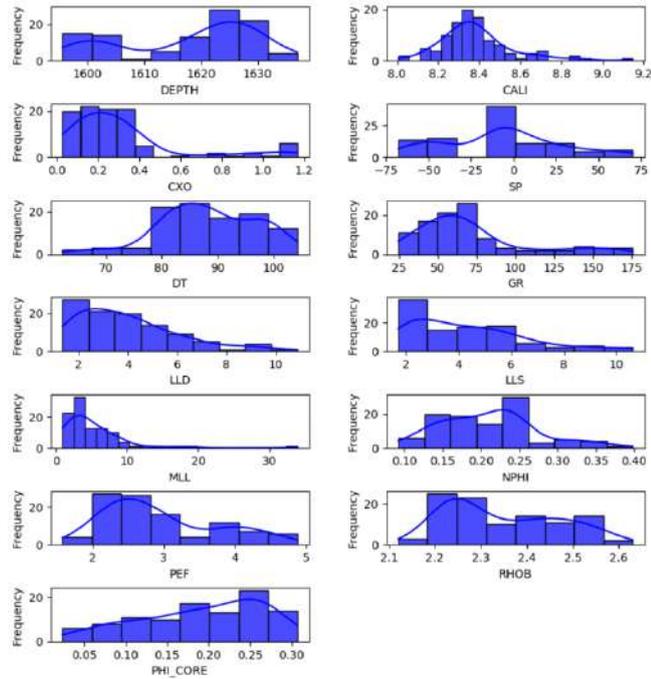
1. *Data Cleaning*: Dengan mengisi *null-data*, menghaluskan data *noise*, mengidentifikasi dan menghapus data yang diisolasi, dan menyelesaikan ketidakkonsistenan untuk mencapai tujuan utama (*data bersih*).
2. *Data Integration*: Simpan data dari beberapa sumber ke dalam penyimpanan data yang konsisten, sumber data ini dapat mencakup beberapa database, data cube, atau file biasa.
3. *Data Transformation*: Data mentah diubah atau dimodifikasi menjadi skala yang sesuai untuk dianalisis dan pemodelan *machine learning*. Dapat dilakukan dengan metode *normalization* atau *standardization*, *log transformation*, dan *categorical variables encoding*.
4. *Data Reduction*: Sekumpulan data asli berisi informasi yang berulang, tidak relevan, atau berisik, atau saat bekerja dengan data dimensi tinggi yang dapat menyebabkan adanya tantangan komputasi pada algoritma tertentu.

Dalam penelitian ini, dilakukan pengumpulan *data missing* guna untuk dapat menggunakan data yang bersih sebagai *input* model *training* nantinya. Ditemukan 6 kolom dengan nilai *missing values* yang bervariasi (dapat dilihat pada Gambar 2) kemudian dilakukan proses pembersihan data dengan menyisakan data sebesar 109 data.



Gambar 2. Jumlah data yang hilang (*missing values*)

Sebelum data diproses untuk pemodelan, butuh untuk dilakukan identifikasi penyebaran data pada masing-masing variabel dengan menggunakan alat visualisasi bernama histogram. Didapatkan enam variabel yang memiliki *right-skewed distribution* dengan nilai *skewness* lebih dari 0,75 (*skew limit*) yaitu MLL, CXO, GR, CALI, LLD, dan LLS (dapat dilihat pada Gambar 3). Sehingga dalam penelitian ini, akan dilakukan pengembangan model pada kondisi data yang tidak ditransform dan data yang ditransform penyebarannya.

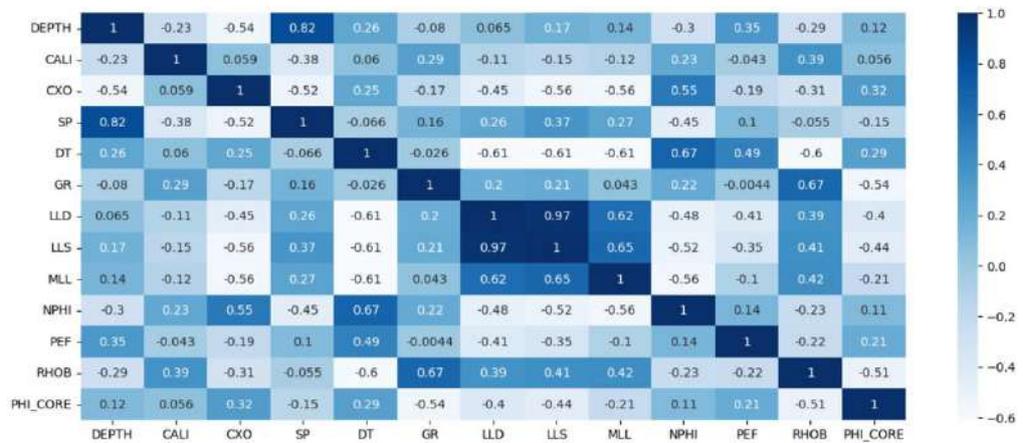


Gambar 3. Distribusi data pada masing-masing variabel

3. Hasil dan Pembahasan

A. Hasil *Exploratory Data Analysis* (EDA)

Exploratory data analysis (EDA) dilakukan untuk melihat korelasi masing-masing parameter *input* terhadap parameter *output*. *Pearson correlation coefficient* dihitung berdasarkan keseluruhan data-data yang diambil dari masing-masing sumur. Pada Gambar 4 dapat dilihat bahwa dilakukannya perhitungan nilai *pearson correlation coefficient* pada variable porositas *core* terhadap variabel lainnya (tidak termasuk permeabilitas *core*). Dapat dilihat bahwa tidak ada data variabel petrofisika yang memiliki nilai korelasi yang tinggi terhadap variabel porositas *core*. Namun terdapat fitur yang masih berpotensi untuk digunakan sebagai variabel *input* seperti variabel GR (-0.54), RHOB (-0.51), LLS (-0.44), LLD (-0.4), dan CXO (0.32).



Gambar 4. Nilai *Pearson correlation coefficient* masing-masing variabel

B. Pengembangan Model

Dalam penelitian ini, model *Random Forest* dikembangkan dengan menggunakan data petrofisika dengan jumlah *potential input feature* tertentu dan menerapkan kondisi dengan dan tanpa *variable transform* untuk melihat performa *random forest* pada setiap kondisi. Sehingga, menghasilkan enam model dengan kondisi yang berbeda. Penentuan *hyperparameter model* merupakan kegiatan yang penting sebelum melakukan *model training*. Dalam bahasa pemrograman *python*, *hyperparameter random forest* yang umum digunakan antara lain adalah: *n_estimators*, *max_depth*, *min_sample_split*,

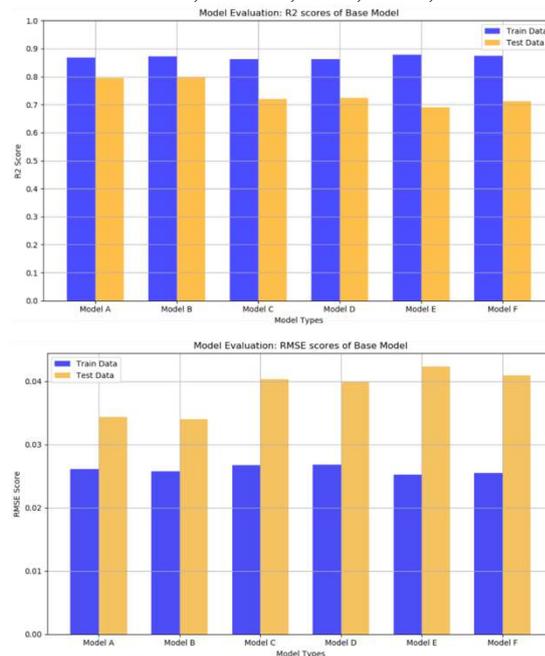
max_features, dan *random_state*. Dalam penelitian ini dilakukan pemodelan *random forest* dengan menggunakan *hyperparameter* yang dapat dilihat pada Tabel 2.

Tabel 2. Detail model yang digunakan pada kondisi berbeda

<i>Inisial Model</i>	<i>Features & Transform</i>	<i>Hyperparameters</i>	
		<i>n_estimators</i>	<i>random_state</i>
A	3 Variable + Log Transform	19	42
B	3 Variable + No Transform	17	42
C	4 Variable + Log Transform	15	42
D	4 Variable + No Transform	13	42
E	5 Variable + Log Transform	13	42
F	5 Variable + No Transform	13	42

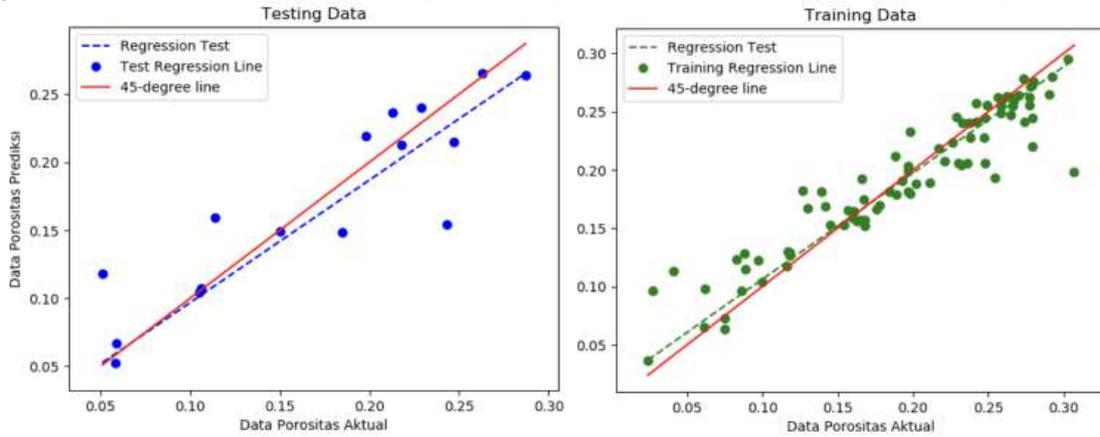
Dalam kegiatan *model training*, penilaian performa *random forest* dilakukan pada dua data set yang berbeda (*Training Data* dan *Test Data*). Pertama, tiga fitur digunakan untuk melatih model dengan dan tanpa *variable transform*. Berdasarkan fitur GR, RHOB, dan LLS didapatkan nilai R^2 sebesar 0,7959 dan RMSE sebesar 0,0344 (dengan *log transform*) pada *test data* dan nilai R^2 sebesar 0,8 dan RMSE sebesar 0,034 (tanpa *log transform*) pada *test data*. Selanjutnya dilakukan penambahan fitur kedua (yaitu LLD) dan menunjukkan bahwa dengan adanya penambahan fitur ini, tidak memberikan peningkatan terhadap model yang digunakan, dengan mendapatkan nilai R^2 sebesar 0,72 dan RMSE sebesar 0,0403 (dengan *log transform*) pada *test data* dan nilai R^2 sebesar 0,725 dan RMSE sebesar 0,0399 (tanpa *log transform*) pada *test data*. Kemudian dilanjutkan dengan menambahkan fitur ketiga (yaitu CXO) dan mengalami hal yang serupa dengan kondisi sebelumnya (tidak adanya peningkatan model), dengan nilai R^2 sebesar 0,691 dan RMSE sebesar 0,0423 (dengan *log transform*) pada *test data* dan nilai R^2 sebesar 0,712 dan RMSE sebesar 0,0409 (tanpa *log transform*) pada *test data*. Hasil pengembangan model pada kondisi yang berbeda dapat dilihat pada Gambar 5.

Tercatat bahwa Model A menggunakan fitur GR, RHOB, dan LLS dengan *log transform*, Model B menggunakan fitur GR, RHOB, dan LLS tanpa *log transform*, Model C menggunakan fitur GR, RHOB, LLS, dan LLD dengan *log transform*, Model D menggunakan fitur GR, RHOB, LLS, dan LLD tanpa *log transform*, Model E menggunakan fitur GR, RHOB, LLS, LLD, dan CXO dengan *log transform*, Model F menggunakan fitur GR, RHOB, LLS, LLD, dan CXO tanpa *log transform*.



Gambar 5. Performa model *random forest* pada kondisi yang berbeda

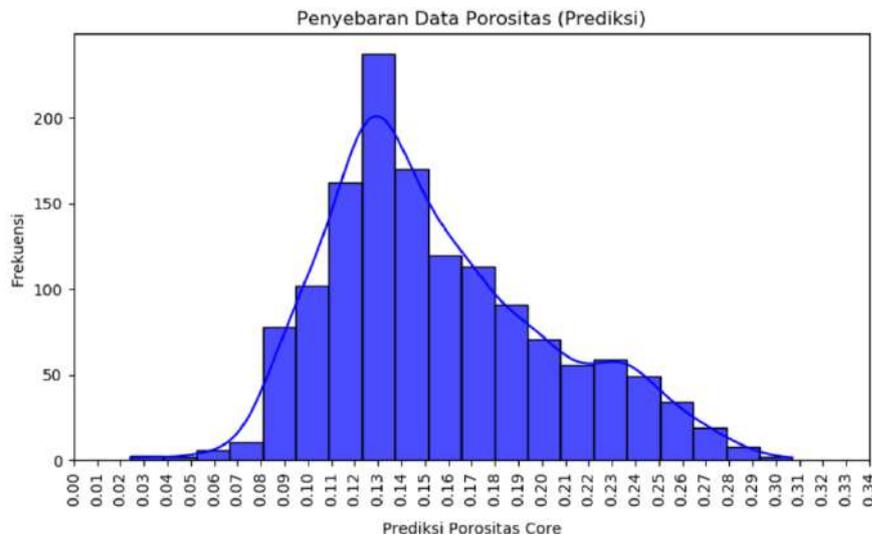
Sehingga berdasarkan pengujian enam model pada kondisi yang berbeda, dapat dikatakan bahwa model B merupakan model terbaik untuk digunakan dalam memprediksi penyebaran porositas *core* dengan mendapatkan nilai R^2 sebesar 0,8 dan RMSE sebesar 0,034. Pada Gambar 6 dapat dilihat bahwa sebagian besar nilai prediksi menggunakan model B tidak jauh dari garis linear sempurna dan memiliki kinerja yang baik dibandingkan dengan model *random forest* yang lainnya, sehingga model *Random Forest* dengan $n_estimators = 19$ dan $random_state = 42$ dapat menjadi *hyperparameter* yang tepat untuk memprediksi penyebaran porositas *core* berdasarkan data *well logging*. Hal ini juga disebabkan oleh tiga fitur (GR, RHOB, dan LLS) yang memiliki korelasi tertinggi terhadap *variable target* (porositas *core*) dibandingkan dengan fitur yang lainnya. Pada kasus ini terdapat catatan bahwa dengan adanya *log transformation* dianggap kurang relevan selama proses model training.



Gambar 6. Performa model B dalam memprediksi porositas *core*

C. Prediksi Nilai Porositas

Berdasarkan performa prediksi didapatkan oleh model B, penelitian dilanjutkan dengan melakukan pelatihan model ulang dengan menggunakan seluruh data *well logging* untuk dapat mengembangkan model prediksi porositas. Dengan *hyperparameter* dan fitur yang telah didapatkan sebelumnya digunakan kembali untuk dapat memprediksi/generate secara regresi nilai porositas *core* yang kosong pada setiap sumur. Hasil prediksi data porositas *core* dapat divisualisasikan pada Gambar 7.



Gambar 7. Penyebaran data porositas (prediksi)

Sehingga berdasarkan hasil yang didapatkan oleh model yang digunakan untuk memprediksi penyebaran data porositas pada setiap sumur (total 1.393 data yang diprediksi), dapat dilihat bahwa frekuensi tertinggi didapatkan pada data porositas yang memiliki nilai di antara 0,12 hingga 0,14 dengan nilai *skewness* sebesar 0,439 yang mana data porositas yang diprediksi hampir simetris. Data

porositas core yang diprediksi dapat ditabulasi secara statistik deskriptif yang dapat dilihat pada Tabel 3.

Tabel 3. Statistik deskriptif dari variable PHI_CORE

	<i>PHI_CORE</i>
Jumlah	1393
<i>Mean</i>	0.155593
<i>Std</i>	0.047848
<i>Min</i>	0.024
25%	0.121824
50%	0.144824
75%	0.185353
Max	0.307

4. Kesimpulan

Penelitian ini menyajikan analisis *machine learning* untuk memprediksi data porositas berdasarkan data *well logging*. Pengembangan model *Random Forest* dilakukan dengan menyiapkan enam model dengan kondisi yang berbeda (jumlah fitur yang digunakan dan data yang ditransformasi) untuk dapat melihat performa masing-masing model. Model dengan performa terbaik akan digunakan untuk proses pelatihan model ulang dengan menggunakan seluruh data *well logging*, dan akhirnya berhasil dilakukan prediksi penyebaran data porositas *core* untuk baris yang kosong pada kolom porositas *core* dengan menggunakan fitur dan *hyperparameter* model yang optimal. Pada penelitian ini dapat disimpulkan:

- Fitur terbaik yang dapat digunakan untuk memprediksi data porositas *core* adalah: log sinar-gamma (GR), log densitas (RHOB), dan log resistivitas dangkal (LLS). Hal ini didasarkan pada nilai *pearson correlation coefficient* yang didapatkan serta menghasilkan performa terbaik pada *test data* dan penambahan fitur lainnya tidak dapat meningkatkan performa model *random forest* yang digunakan.
- Didapatkan model *random forest* dengan performa terbaik untuk memprediksi nilai porositas dengan nilai R^2 sebesar 0,8 dan RMSE sebesar 0,034. Model tersebut adalah model B dengan *hyperparameter* $n_estimator = 19$, dan $random_state = 42$ dan berdasarkan pengujian model bahwa penambahan proses *variable transformation* tidak dapat meningkatkan performa model *random forest*.
- Berhasil melakukan prediksi penyebaran porositas *core* pada baris kosong dalam kolom porositas *core* sebanyak 1.393 data dengan menggunakan fitur terbaik dan model terbaik yang telah didapatkan sebelumnya.

5. Daftar Pustaka

- Andersen, P. Ø., Skjeldal, M., & Augustsson, C. (2022). Machine Learning Based Prediction of Porosity and Water Saturation from Varg Field Reservoir Well Logs. In *SPE EuropeEC - Europe Energy Conference featured at the 83rd EAGE Annual Conference & Exhibition* (p. D041S010R005). <https://doi.org/10.2118/209659-MS>
- Abdel Azim, R., & Aljehani, A. (2022). Neural Network Model for Permeability Prediction from Reservoir Well Logs. *Processes*, 10(12). <https://doi.org/10.3390/pr10122587>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chen, L., Lin, W., Chen, P., Jiang, S., Liu, L., & Hu, H. (2021). Porosity Prediction from Well Logs Using Back Propagation Neural Network Optimized by Genetic Algorithm in One Heterogeneous Oil Reservoirs of Ordos Basin, China. *Journal of Earth Science*, 32(4), 828–838. <https://doi.org/10.1007/s12583-020-1396-5>
- Hidayat, F., & Astsauri, T. M. S. (2022). Applied random forest for parameter sensitivity of low salinity water Injection (LSWI) implementation on carbonate reservoir. *Alexandria Engineering Journal*, 61(3), 2408–2417. <https://doi.org/10.1016/j.aej.2021.06.096>

-
- Makariou, D., Barrieu, P., & Chen, Y. (2021). A random forest based approach for predicting spreads in the primary catastrophe bond market. *Insurance: Mathematics and Economics*, *101*, 140–162. <https://doi.org/10.1016/j.insmatheco.2021.07.003>
- Li, H., Gong, C., Liu, S., Xu, J., & Imani, G. (2022). Machine Learning-Assisted Prediction of Oil Production and CO₂ Storage Effect in CO₂-Water-Alternating-Gas Injection (CO₂-WAG). *Applied Sciences (Switzerland)*, *12*(21). <https://doi.org/10.3390/app122110958>
- Oetomo, M. A., Harmoko, U., & Yuliyanto, G. (2019). Reservoir characterization by petrophysical analysis and core data validation, a case study of the “x” field prospect zone. *Journal of Physics: Conference Series*, *1217*(1), 0–8. <https://doi.org/10.1088/1742-6596/1217/1/012015>
- Singh, P., Singh, N., Singh, K. K., & Singh, A. (2021). Diagnosing of disease using machine learning. In K. K. Singh, M. Elhoseny, A. Singh, & A. A. B. T.-M. L. and the I. of M. T. in H. Elngar (Eds.), *Machine Learning and the Internet of Medical Things in Healthcare* (pp. 89–111). Academic Press. <https://doi.org/10.1016/B978-0-12-821229-5.00003-3>
- Wang, M., Feng, D., Li, D., & Wang, J. (2022). Reservoir Parameter Prediction Based on the Neural Random Forest Model. *Frontiers in Earth Science*, *10*(May), 1–12. <https://doi.org/10.3389/feart.2022.888933>
- Yan-li, Z., & Jia, Z. (2012). Research on Data Preprocessing in Credit Card Consuming Behavior Mining. *Energy Procedia*, *17*, 638–643. <https://doi.org/10.1016/j.egypro.2012.02.147>



Peran Arsitek dalam Pelestarian Objek Diduga Cagar Budaya Wilayah Samarinda, Kalimantan Timur

Mulyani¹⁾, Nur Asriatul Kholifah¹⁾, Anisah Azizah¹⁾, Amelia Dwi Nur Azizah¹⁾, Afriza Rizki Antaresti¹⁾, Nabeela Amalia Putri¹⁾, Vinie Tamama¹⁾, Saddam Gumilang Syarif¹⁾

¹⁾ Program Studi Arsitektur, Fakultas Teknik, Universitas Mulawarman

E-mail: amldwnrzzh@gmail.com

ABSTRAK

Indonesia memiliki beragam budaya dalam setiap daerah, keberagaman ini menciptakan berbagai sejarah serta bentuk atau ciri khas dari sebuah daerah tersebut. Salah satu daerah yang memiliki berbagai macam cerita terdahulu adalah Samarinda tepatnya berada di Samarinda Seberang dengan terbentuknya atau terbangunnya sebuah bangunan yang memiliki filosofi maupun cerita nya masing-masing. Semakin berkembangnya pembangunan-pembangunan pada wilayah Samarinda membuat bangunan-bangunan terdahulu semakin tidak diperhatikan. Namun, hal ini ditindaklanjuti oleh pemerintah wilayah Samarinda untuk melakukan pelestarian terhadap sejarah yang telah terjadi di masa lampau. Penelitian ini bertujuan untuk 1) Menentukan objek bangunan bersejarah yang di duga belum menjadi cagar budaya, 2) Mengetahui sejarah terbangunnya sebuah bangunan pada wilayah tersebut, 3) Menentukan upaya pelestarian yang akan digunakan pada bangunan. Penelitian ini merupakan pengembangan dalam pelestarian sebuah bangunan bersejarah yang akan mengacu pada pola pikir untuk melakukan upaya-upaya pelestarian bangunan sejarah. Kesimpulan dari perencanaan ini adalah 1) Penentuan Objek bersejarah serta fungsi disesuaikan dengan sejarah terdahulu, 2) Awal mula sejarah bangunan ini diketahui melalui sejarah seseorang melalui salah satu alat transportasi, 3) Bangunan bersejarah membutuhkan beberapa upaya pelestarian yaitu dengan melakukan rekonstruksi yang merupakan upaya dengan memperbaiki kerusakan-kerusakan yang telah terjadi tanpa merubah bentuk asli sebuah bangunan.

Kata Kunci: sejarah, bangunan, cagar budaya, pelestarian

ABSTRACT

Indonesia has a variety of cultures in each region, this diversity creates various histories and forms or characteristics of a region. One area that has various kinds of previous stories is Samarinda, precisely in Samarinda Seberang, with the formation or construction of a building that has its own philosophy and story. The increasing development of developments in the Samarinda area means that previous buildings are increasingly ignored. However, this was followed up by the Samarinda regional government to preserve the history that occurred in the past. This research aims to 1) Determine historical building objects that are thought not to be cultural heritage, 2) Find out the history of the construction of a building in that area, 3) Determine the preservation efforts that will be used on the building. This research is a development in the preservation of a historic building which will refer to the mindset for making efforts to preserve historical buildings. The conclusions of this planning are 1) Determining historical objects and functions adapted to previous history, 2) The beginning of the history of this building is known through the history of a person through one means of transportation, 3) Historic buildings require several preservation efforts, namely by carrying out reconstruction which is an effort with repair damage that has occurred without changing the original shape of a building.

Keyword: history, building, cultural heritage, preservation

1. Pendahuluan

Indonesia merupakan negara yang kaya akan budayanya, bahkan setiap daerah yang ada di Indonesia memiliki ciri khasnya masing-masing. Dari sinilah terdapat berbagai jenis peninggalan bersejarah yang diwariskan oleh nenek moyang kita berupa tulisan, bangunan, benda-benda, karya seni, dan masih banyak lagi. Dalam UURI No. 11 Tahun 2010, Cagar Budaya adalah warisan budaya bersifat kebendaan berupa Benda Cagar Budaya, Bangunan Cagar Budaya, Struktur Cagar Budaya,

Situs Cagar Budaya, dan Kawasan Cagar Budaya di darat dan/atau di air yang perlu dilestarikan keberadaannya karena memiliki nilai penting bagi sejarah, ilmu pengetahuan, pendidikan, agama, dan/atau kebudayaan melalui proses penetapan. Dengan mendaftarkan peninggalan bersejarah menjadi cagar

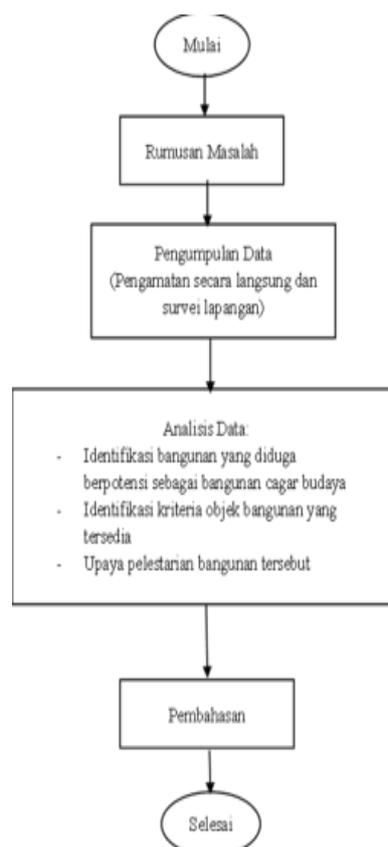
budaya, maka akan memperpanjang usia peninggalan karena berada di bawah pengawasan pemerintah yang pastinya memelihara, merawat, serta mempertahankan keberadaan situs sejarah dan budaya yang ada di Indonesia.

Di Samarinda sendiri tidak banyak jumlah cagar budaya yang ditetapkan oleh pemerintah. Kepala Disdikbud Samarinda Asli Nuryadin menjelaskan ada beberapa objek dan lokasi yang berpotensi diusulkan ke Kementerian Pendidikan Kebudayaan Riset dan Teknologi (Kemendikbudristek) melalui aplikasi Dapobud (Data Pokok Kebudayaan/Sistem Pendataan Kebudayaan Terpadu) pada 2019–2022. “Sebanyak 40 objek diduga cagar budaya (ODCB) didaftarkan pada aplikasi Dapobud. Hasil identifikasi dan verifikasi tim ahli cagar budaya (TACB) Samarinda merekomendasikan sembilan cagar budaya, yang kemudian ditetapkan wali kota”. Angka ini terbilang kecil karena cagar budaya yang ditetapkan bahkan tidak sampai setengah dari jumlah objek yang diajukan. Padahal cagar budaya sendiri berguna bagi pemahaman dan pengembangan sejarah, ilmu pengetahuan, serta kebudayaan bagi generasi selanjutnya. Hal ini mendorong kami untuk melakukan pencarian terhadap objek-objek bersejarah di Samarinda untuk diajukan menjadi cagar budaya.

2. Metode Penelitian

Metode penelitian yang digunakan yakni menggunakan metode kualitatif. Metode ini dilakukan dengan cara observasi, survey lokasi secara langsung, serta studi literatur. jenis metode penelitian ini dipilih dikarenakan memudahkan untuk memperoleh analisis informasi lokasi serta keadaan sekitar dari lokasi disekitarnya.

A. Diagram Alir



Gambar 1. Bagan Penelitian

3. Hasil dan Pembahasan

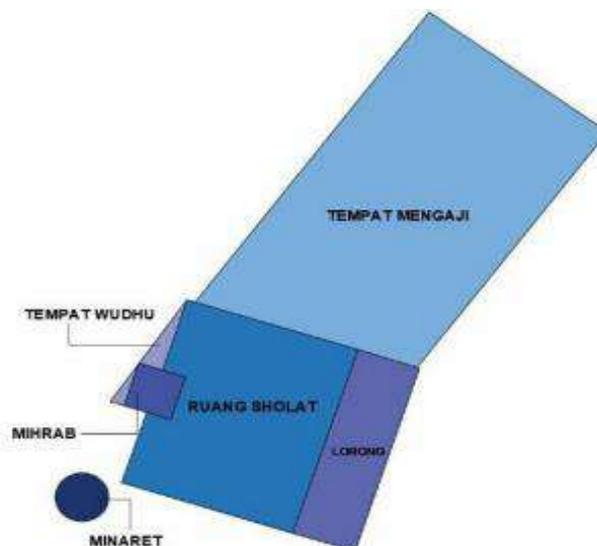
Seperti yang telah diketahui, Masjid Shiratal Mustaqiem merupakan masjid tertua yang ada di Samarinda. Masjid ini dibangun pada tahun 1881 dan sudah tercantum sebagai salah satu cagar budaya yang ada di Samarinda. Namun ternyata ada tempat beribadah umat muslim yang lebih tua dari Masjid Shiratal Mustaqiem yaitu Langgar Al Washilah. Langgar ini telah didirikan oleh Habib Sayyid Abdurrahman bin Muhammad Assegaf sejak tahun 1837, yang berarti sekarang langgar ini telah berusia sekitar 186 tahun. Meskipun usianya jauh lebih tua dari Masjid Shiratal Mustaqiem namun langgar ini belum termasuk ke dalam cagar budaya yang ada di Samarinda. Lokasi langgar ini tak jauh dari Masjid Shiratal Mustaqiem yaitu berjarak sekitar 600 meter.

Langgar ini dulunya dimanfaatkan sebagai tempat beribadah saja namun seiring berjalannya waktu terdapat penambahan fungsi ruang pada bangunan ini. Tempat mengaji ditambahkan pada area belakang langgar sebagai tempat anak-anak sekitar belajar mengaji. Bangunan ini berorientasi ke arah barat daya dengan ukuran lahan 420 m² dan luas bangunan langgar 42 m². Dengan luas tersebut langgar ini dapat menampung kurang lebih 300 jamaah. Denah pada langgar ini cukup sederhana karena pada saat itu pembangunan langgar ini memang ditujukan sebagai tempat beribadah warga sekitar saja. Langgar Al Washilah ini terdiri dari ruang beribadah untuk jamaah, mihrab untuk imam, tempat mengaji di bagian belakang, tempat wudhu, dan juga terdapat sebuah minaret di bagian depan bangunan.

A. Sejarah

Pada tahun 1880, Habib Sayyid Abdurrahman bin Muhammad Assegaf datang ke kawasan Samarinda Seberang untuk berdagang serta menyebarkan ajaran agama islam. Pada saat itu, kawasan Samarinda seberang masih dipenuhi dengan kegiatan seperti judi baik sabung ayam maupun judi dadu serta banyaknya peredaran minuman keras. Hal ini menimbulkan keresahan warga, oleh sebab itu dibangunlah sebuah tempat beribadah guna mengembalikan citra Samarinda Seberang sebagai syiar Islam. Selain itu, dibangunnya langgar ini juga untuk memenuhi kebutuhan tempat beribadah karena banyaknya pendatang yang datang untuk berdagang. Dulunya langgar ini tidak dibangun di atas tanah, melainkan dibangun di atas

rakit yang mengambang di sungai Mahakam. Setelah 25 tahun berada di atas air, akhirnya langgar Al Washilah dipindahkan ke daratan karena semakin meningkatnya jumlah jamaah yang beribadah di langgar ini. Langgar ini dinaikkan ke daratan tanpa menggunakan tiang pancang. Langgar Al Washilah juga menjadi salah satu awal mula berdirinya Masjid Shiratal Mustaqiem.



Gambar 2. Denah Langgar Al Washilah

B. Identifikasi Kriteria Objek

1) Eksterior

Atap pada langgar Al Washilah berbentuk limasan yang terdiri dari dua susun. Atap dua susun ini melambangkan dua kalimat syahadat yang diyakini oleh umat Islam sebagai tanda kepercayaan kepada Allah SWT. Material yang digunakan pada bagian penutup atap langgar adalah atap sirap kayu. Atap seperti ini banyak ditemui pada tempat beribadah kuno yang ada di Indonesia seperti pada Masjid Agung Demak.



Gambar 2. Atap Langgar Al Washilah



Gambar 3. Masjid Agung Demak

Selanjutnya, terdapat sebuah minaret pada langgar Al Washilah ini yang bermaterial kayu dengan penutup atap sama seperti pada bangunan utama yaitu atap kayu sirap. Berbeda dari minaret biasanya yang berbentuk lingkaran, minaret langgar Al Washilah berbentuk persegi yang semakin ke atas diagonal minaret semakin kecil. Minaret dengan bentuk serupa dapat ditemukan pada Masjid Layur, Semarang.



Gambar 4. Minaret Langgar Al Washilah



Gambar 5. Masjid Layur Semarang

Dinding langgar bermaterial kayu yang didominasi oleh warna hijau dan putih. Di dalam Islam kedua warna tersebut melambangkan kebaikan. Warna hijau dan putih juga diterapkan pada kebanyakan masjid yang ada di Indonesia sehingga menjadi ciri khas hingga sekarang.



Gambar 6. Dinding Langgar Al Washilah



Gambar 7. Dinding Masjid di Indonesia

Di sekeliling teras bangunan langgar terdapat pagar kecil yang mengadopsi gaya Belanda dengan material kayu. Warna yang digunakan masih sama seperti warna dinding pada bangunan. Pagar seperti ini juga bisa ditemukan pada Rumah Dahor yang ada di Balikpapan.



Gambar 8. Pagar Langgar Al-Washilah



Gambar 9. Rumah Dahor Balikpapan

2). Interior

Pola ruang yang sederhana merupakan salah satu ciri khas bangunan kuno seperti pada langgar ini. Dimana bentuk ruangan ini hanya persegi dengan sedikit sisi bangunan menjorok ke arah luar sebagai mihrab atau tempat imam memimpin sholat. Penggunaan pola ruang yang sederhana dipilih karena fokus untuk menyelesaikan permasalahan yang ada di sekitar yaitu kurangnya tempat ibadah yang memadai, sehingga pada saat itu langgar dibuat hanya untuk tempat beribadah saja. Namun kini sudah ada penambahan-penambahan pada bangunan seperti adanya tempat mengaji anak pada area belakang langgar. Penerapan pola ruang sederhana ini juga dapat ditemukan di tempat beribadah lainnya seperti yang ada pada Masjid Hidayatullah, Jakarta.



Gambar 10. Pola Ruang Langgar Al Washilah



Gambar 11. Masjid Hidayatullah Jakarta



Gambar 12. Kayu Ulin Langgar Al Washilah



Gambar 13. Masjid Kayu Tuatunu Palangkaraya

Interior bangunan didominasi dengan material kayu ulin yang digunakan untuk dinding dan lantai. Pemilihan jenis kayu ulin sangat tepat dengan posisi bangunan yang berada di tepi sungai Mahakam, hal ini karena kayu ulin memiliki sifat tahan dari kelembaban dan juga anti rayap. Warna dari kayunya sendiri juga tetap mempertahankan warna asli kayu, hanya saja dilapisi dengan pernis kayu agar tahan lama dan meminimalisir terjadinya kerusakan. Penggunaan kayu ini sama dengan interior yang ada pada Masjid Kayu Tuatunu, Palangkaraya.

3). Fasilitas

Dari bagian samping kanan bangunan, terdapat tempat wudhu wanita dan pria yang bisa langsung diakses melalui area depan bangunan. Selanjutnya ada tempat mengaji yang diperuntukkan pada anak-anak di daerah sekitar langgar. Tempat mengaji ini merupakan salah satu penambahan untuk menambah fungsi dari bangunan. Masuk ke area beribadah, di dalamnya disediakan beberapa fasilitas yang bisa digunakan oleh jamaah diantaranya ada AC ditambah lagi dengan beberapa kipas angin, lampu gantung yang berada di tengah-tengah ruang beribadah, lukisan kaligrafi yang selalu ada di tempat ibadah umat muslim pada umumnya, selain itu ada juga lemari kaca yang didalamnya disediakan beberapa alat sholat dan juga Al-Quran untuk dipinjam oleh jamaah, lalu ada ambal tentunya untuk alas sholat, ada juga gordena pemisah antara jamaah laki-laki dan jamaah perempuan, dan terakhir ada jam pendulum yang secara tidak langsung menjelaskan bahwa langgar ini sudah berusia tua.



Gambar 14. Teras Langgar Al Washilah

4). Pemetaan kondisi objek

Dalam pelestarian arsitektur, pemetaan kondisi fisik ini diperlukan untuk mengidentifikasi bagian mana saja yang perlu dilakukan perbaikan atau langkah-langkah pelestarian selanjutnya. Pada bagian eksterior Langgar Al Washilah ini terdapat kerusakan pada bagian dinding minaret yang bagian kayunya sudah kusam, sedangkan pada bagian atapnya ada beberapa bagian yang rapuh dan lembab. Selain bagian eksterior, identifikasi objek fisik juga dilakukan di dalam langgar. Pada gambar ini terlihat terdapat kerusakan pada bagian plafon di dalam langgar yang sudah lapuk dan terdapat kebocoran di beberapa titik. Lalu pada bagian keramik kamar mandi juga terdapat kerusakan berlumut, dan juga kotor.

C. Upaya Pelestarian

Rekonstruksi bertujuan untuk mengembalikan sebuah Bangunan Cagar Budaya atau warisan budaya lainnya sesuai dengan aslinya dengan menggunakan bahan penyusun mula-mula atau baru. Merekonstruksi bagian atap dengan mengganti material yang mengalami kerusakan. Selain itu ada upaya Konservasi, yaitu tindakan untuk mencegah kerusakan dan memperpanjang usia suatu bangunan tua, yang dimana proses konservasi itu sendiri tidak boleh menyebabkan kerusakan pada bangunan tadi serta menghancurkan atau menghilangkan bukti sejarah. Karena sedari awal pun bangunan ini tidak pernah berubah bentuk dan masih mempertahankan keaslian bangunannya

hingga sekarang.

4. Kesimpulan

Langgar Al Washilah dibangun jauh sebelum masuknya gaya arsitektur islam, oleh karena itu Langgar Al Washilah banyak mengadopsi haya arsitektur Melayu, Arab, bahkan Belanda. Langgar Al Washilah merupakan bangunan bersejarah dan layak masuk dalam dalam kategori bangunan cagar budaya, karena bangunan ini memiliki kriteria bangunan cagar budaya yaitu usianya sudah lebih dari 50 tahun, memiliki arti khusus bagi Sejarah, ilmu pengetahuan, Pendidikan agama, dan kebudayaan. Namun dengan usia langgar yang sudah tua ini, banyak material yang telah mengalami kerusakan. Hal ini dapat ditindak lanjuti dengan melakukan rekonstruksi, yaitu mengembalikan kondisi bangunan sesuai aslinya. Rekonstruksi bertujuan mengembalikan sebuah bangunan cagar budaya atau warisan budaya sesuai dengan aslinya dengan menggunakan bahan penyusun yang baru. Rekonstruksi ini dapat dilakukan pada bagian atap langgar dengan mengganti material yang mengalami kerusakan. Selain itu juga melakukan konservasi, yaitu mencegah kerusakan pada bangunan langgar tersebut. Tindakan ini dilakukan untuk mencegah kerusakan dan memperpanjang usia suatu bangunan tua, yang dimana proses konservasi itu sendiri tidak boleh menyebabkan kerusakan pada bangunan atau menghancurkan dan menghilangkan bukti sejarahnya. Karena sedari awal bangunan ini tidak pernah berubah dan masih mempertahankan keaslian bangunannya hingga saat ini.

5. Daftar Pustaka

- Dacanal, C., Luz, S. do N., Turco, S. H. N., & Vasconcelos, O. C. M. (2018). Diagnosis and recommendations for the bioclimatic design of grape packing houses in hot and dry climate. *Engenharia Agricola*, 38(1), 1–6.
- Jovanović, D., Milovanov, S., Ruskovski, I., Govedarica, M., Sladić, D., Radulović, A., & Pajić, V. (2020). Building virtual 3D city model for smart cities applications: A case study on campus area of the university of novi sad. *ISPRS International Journal of Geo-Information*, 9(8).
- Kellert, S. R. (2005). *Building to life: designing and understanding the human-nature connection*. Island Press.
- Lim, C., Kim, K. J., & Maglio, P. P. (2018). Smart cities with big data: Reference models, challenges, and considerations. *Cities*, 82(August 2017), 86–99.
- Mansuri, L., Udejaja, C., Trillo, C., Kwasi, G., Patel, D., Jha, K., Makore, C. B., & Gupta, S. (2019). Scientometric analysis and mapping of digital technologies used in cultural heritage field. *Association of Researchers in Construction Management, ARCOM 2019 - Proceedings of the 35th Annual Conference*, September, 255–264.
- Premier, A. (2019). Solar shading devices integrating smart materials: an overview of projects, prototypes and products for advanced façade design. *Architectural Science Review*, 62(6), 455–465.
- Utomo, P. K., Sari, D. P., & S. Saptaningtyas, R. (2021). (Re)Interpretasi Arsitektur Tropis: Kajian Teoretis tentang Determinasi Arsitektur Vernakular dan Regionalisme. *SADE: Jurnal Arsitektur, Planologi Dan Teknik Sipil*, 1(2), 63–68. <https://doi.org/10.29303/sade.v1i2.16>



Performa Kluster *Hadoop MapReduce* pada *Private Cloud Computing* untuk Komputasi *Skyline Query*

Annisa Octavyanti Hakim¹⁾, Heri Wijayanto¹⁾, I Gde Putu Wirarama¹⁾

¹⁾Program Studi Teknik Informatika, Fakultas Teknik, Universitas Mataram

E-mail: annisaoctavya@gmail.com

ABSTRAK

Untuk mengoptimalkan pemrosesan data besar dengan *Hadoop*, komputasi awan menyediakan infrastruktur yang mudah digunakan, menggabungkan layanan *private cloud* dengan *Infrastructure as a Service (IaaS)*. Dalam penelitian ini, terdapat proses karakterisasi dan penilaian kinerja eksekusi data besar pada instan kluster virtual *Hadoop MapReduce* yang dibangun di *private cloud* Universitas Mataram. Dengan algoritma *Skyline Query*, kluster diuji dengan variasi data, mesin, dan ukuran blok *HDFS* pada 3 jenis data sintesis: *anti-correlated*, *correlated*, dan *independent*. Parameter waktu eksekusi digunakan untuk membandingkan hasil dengan kluster *Hadoop* pada infrastruktur fisik. Hasil pengujian kluster *private cloud* menunjukkan peningkatan waktu komputasi saat data meningkat dari 1,5 juta menjadi 12 juta pada 4 mesin: data *anti-correlated* (168%), *correlated* (194%), dan *independent* (126%). Tren serupa terjadi pada kluster *Hadoop* fisik. Pada skenario lainnya, kluster *private cloud* menunjukkan kinerja yang lebih baik dengan penambahan mesin hingga 7, sementara kluster *Hadoop* fisik mengalami *overhead communication* antar-node ketika mesin diskalakan menjadi 7 mesin. Pemrosesan data 12 juta dengan ukuran blok *HDFS* 512 MB dan 7 mesin merupakan *block size* paling optimal karena menghasilkan waktu eksekusi terpendek. Berdasarkan uji statistik t menggunakan rata-rata waktu komputasi, disimpulkan bahwa kluster *Hadoop* di *private cloud* dengan spesifikasi *Intel(R) Xeon (R) E3-1225 v5 @ 3,30 GHz RAM 16 GB* lebih unggul dalam mengeksekusi aplikasi *Skyline* dibandingkan kluster *Hadoop* fisik dengan spesifikasi *Intel Core i5 CPU @ 3,00GHz RAM 4GB*.

Kata Kunci: *Hadoop MapReduce*, *cloud computing*, *private cloud*, *IaaS*, *skyline query* terdistribusi, *MR-BNL*

ABSTRACT

To optimize significant data processing through *Hadoop*, cloud computing offers user-friendly infrastructure by combining *private cloud* services and *Infrastructure as a Service (IaaS)*. In this research, the characterization and evaluation of large data execution on virtual *Hadoop MapReduce* clusters within Mataram University's *private cloud*. Using the *Skyline Query* algorithm, the cluster is tested with variations in data, machines, and *HDFS* block sizes on three synthetic data types: *anti-correlated*, *correlated*, and *independent*. Execution time parameters are used to compare results with *Hadoop* clusters on physical infrastructure. Test outcomes of the *private cloud* cluster exhibit increased completion time as data scales from 1,5 million to 12 million on four machines: *anti-correlation* data (168%), *correlation* data (194%), and *independent* data (126%). A parallel performance trend is observed in the physical *Hadoop* cluster. In a separate scenario, the *private cloud* cluster demonstrates superior performance with the addition of up to 7 machines, while the physical *Hadoop* cluster encounters communication overhead with 7 machines. Processing 12 million data using an *HDFS* block size of 512 MB and 7 machines produces the shortest execution time. Based on *t*-statistical tests concerning average processing time, the conclusion is that the *Hadoop* cluster within the *private cloud*, featuring *Intel(R) Xeon (R) E3-1225 v5 @ 3,30 GHz and 16 GB RAM*, surpasses *Skyline* application execution compared to a physical *Hadoop* cluster with specifications of *Intel Core i5 CPU @ 3,00 GHz and 4 GB RAM*.

Keyword: *Hadoop MapReduce*, *cloud computing*, *private cloud*, *IaaS*, *distributed skyline query*, *MR-BNL*

1. Pendahuluan

Teknologi internet mengalami perkembangan yang sangat pesat sejak kemunculannya pada tahun 1960-an (Nuriadin dkk., 2021). Pengguna internet yang terus meningkat bersamaan dengan layanan aplikasi yang semakin beragam menjadi pemicu konsumsi data yang terus bertambah tanpa henti. Data dalam jumlah besar tanpa mekanisme pengelolaan yang baik hanya akan menjadi objek pasif yang tidak dapat dimanfaatkan lagi. Oleh karena itu, dibutuhkan suatu arsitektur yang mumpuni untuk mengelola data besar (Subagya dkk., 2021).

Salah satu *framework big data* yang paling populer saat ini adalah *Hadoop*. *Hadoop* merupakan sebuah arsitektur yang menggunakan konsep paralel terdistribusi untuk mengolah data bervolume besar menggunakan model pemrograman *MapReduce* melalui sekumpulan komputer yang terhubung satu sama lain melalui jaringan (klaster) (Ryanto, 2017). *MapReduce* membagi data menjadi banyak pecahan yang mana tiap pecahan akan diproses di tiap *node* pada sebuah klaster.

Pada saat ini, mengelola data besar menggunakan *Hadoop* memiliki tantangan tersendiri dalam hal penyediaan, pengaturan, dan perawatan infrastruktur skala besar. Diperlukan biaya investasi awal dalam hal infrastruktur, operasional, pakar TI dan pemeliharaan berkelanjutan yang tentunya tidak sedikit. Hal ini membuat implementasi *Hadoop* dengan *physical machine* terbatas dilakukan. Untuk menyelesaikan tantangan ini, *cloud computing* menawarkan konsep pengolahan sumber daya komputasi melalui jaringan internet (*cloud*) dengan biaya sebesar yang digunakan pengguna saja. Ini dapat membantu pengguna untuk lebih berfokus dalam pekerjaannya dibandingkan mengkhawatirkan masalah ketersediaan infrastruktur, sumber daya, dan pakar TI.

Pada *cloud computing*, terdapat beberapa model penyebaran, salah satunya yakni *private cloud*. Layanan ini banyak digunakan oleh pengguna seperti perusahaan dan universitas yang menginginkan *control* eksklusif. *Private cloud* memberikan kontrol penuh kepada penggunanya dengan memberikan akses khusus ke jaringan dan infrastruktur yang dapat dikostumisasi. Implementasi *private cloud* dengan *Infrastructure as a Service (IaaS)* akan disediakan dalam bentuk *virtual instance* atau infrastruktur virtual yang bisa diminta (*request*) sesuai kebutuhan internal. Infrastruktur virtual ini bekerja seperti mesin dengan komponen penyimpanan, RAM, *disk space*, sistem operasi, *network*, dan kekuatan pemrosesan *CPU* (Subramanian & Gouda, 2015). *IaaS* dengan *virtual machine* dapat dikelola secara fleksibel dan secara teknis dapat menggantikan *server* fisik, sumber daya pusat data, *network tools*, dan komponen fisik lainnya (Prabowo dkk., 2015).

Keunggulan *private cloud* ini dapat dimanfaatkan untuk mengatasi keterbatasan penyediaan mesin fisik dengan spesifikasi yang ideal untuk komputasi *big data* berskala kompleks pada laboratorium Prodi Teknik Informatika, Universitas Mataram. Saat ini, Laboratorium 2, Prodi Teknik informatika memiliki PC sejumlah 21 buah dengan spesifikasi *Processor Intel(R) Core (TM) i5-9500 CPU @ 3,00GHz*, RAM 4,00 GB (3,78 GB *usable*) dan memori SSD 500 GB. Berdasarkan (Azizah & Saptono, 2020), spesifikasi tersebut merupakan spesifikasi *minimum* untuk komputasi *Hadoop*. Sehingga untuk komputasi *Hadoop* yang lebih baik, teknologi virtualisasi dengan *private cloud* akan sangat baik diimplementasikan.

Fokus penelitian ini terletak pada unjuk kerja klaster *virtual* pada *private cloud* yang ada di *server* Universitas Mataram dalam menyelesaikan komputasi *Hadoop MapReduce*. Ekosistem *Hadoop* yang dibangun, akan digunakan untuk mengeksekusi sejumlah data berukuran besar dengan beberapa skenario pengujian salah satunya algoritma *Skyline Query* guna menilai kinerja klaster *Hadoop*. *Skyline Query* merupakan metode pencarian sekumpulan objek penting yang memiliki kriteria lebih baik dari pada objek lainnya dalam himpunan data. Algoritma ini dipilih karena merupakan algoritma yang memiliki kompleksitas yang sangat bergantung pada jumlah dimensi dan besar *dataset* yang digunakan (Wibawa dkk., 2018). Sebagai bahan perbandingan, *requirement* serupa juga akan dijalankan pada mesin fisik. Kedua implementasi ini akan dibandingkan kinerjanya dalam hal waktu kecepatan eksekusi atau *running time* saat menjalankan komputasi.

2. Metode Penelitian

A. Klaster Hadoop

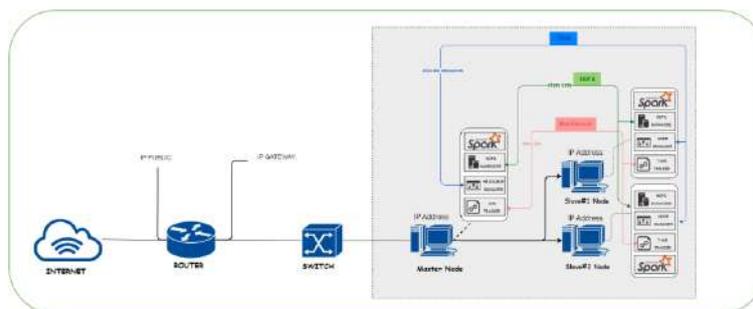
Pada penelitian ini, Klaster *Hadoop* dibangun di atas layanan *Infrastructure as a Service* pada *Private Cloud* menggunakan *server* Laboratorium 2, Laboratorium Komunikasi Data dan Sistem

Tertanam yang diletakan di UPT PUSTIK Universitas Mataram. Kluster yang akan diluncurkan berbentuk *instance virtual* atau *virtual machine* sebanyak 1 buah *node* sebagai inisialisasi awal. Setiap *node* akan dilakukan instalasi *Linux Ubuntu 22.04.1 LTS* sebagai basis sistem operasi Kluster *Hadoop*.

Distribusi *Kluster Hadoop* berbentuk mesin virtual akan dibuat menggunakan komputer *server* PUSTIK Universitas Mataram dengan spesifikasi:

1. *Processor* : *Intel(R) Xeon (R) E3-1225 v5, 4 Core, CPU @3,30 GHz*
2. *RAM* : 16 GB
3. *Memori* : *HDD, 1TB*

Sebagai bahan perbandingan, dilakukan konfigurasi *Hadoop* dengan *requirement* yang serupa pada kluster virtual menggunakan komputer fisik pada Laboratorium 2, Laboratorium Komunikasi Data dan Sistem Tertanam Prodi Teknik Informatika. Kluster komputer ini akan diberikan perlakuan yang sama dengan *kluster virtual*. Arsitektur Kluster *Hadoop* yang akan dibangun ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur Kluster *Hadoop*

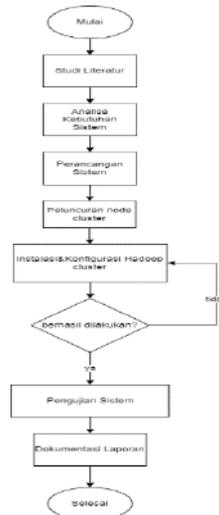
B. Data

Pada penelitian ini, data yang digunakan adalah data sintetis. Data sintetis mengacu pada data artifisial yang dibuat (*generate*) dengan suatu *tools* menggunakan suatu algoritma untuk melakukan pengujian tertentu. Dalam distribusi data, penulis menggunakan berbagai jenis data sintetis yakni *correlated*, *uncorrelated*, dan *independent* dengan masing-masing berukuran 1 GB. Ketiga distribusi data yang dimaksud seperti berikut (Börzsönyi dkk., 2001):

1. *Independent*: semua nilai atribut dibuat secara *independent* menggunakan sebuah distribusi *uniform*.
2. *Correlated*: mengacu pada data yang memiliki korelasi atau terhubung satu sama lainnya. Data ini merepresentasikan lingkungan di satu titik yang tidak hanya baik pada satu dimensi, namun juga dimensi lainnya
3. *Uncorrelated*: data yang tidak saling berhubungan satu sama lain. Dalam artian, data yang dimiliki hanya baik pada satu dimensi saja, tidak pada dimensi lainnya.

C. Alur Penelitian

Subbab ini berisi langkah-langkah yang akan dilakukan peneliti dalam menyelesaikan pokok permasalahan yang diangkat pada penelitian ini. Diagram alir penelitian dapat dilihat pada Gambar 2.



Gambar 2 Diagram alir penelitian

D. Pengujian Sistem

Dalam penelitian ini, dikarenakan fokus penelitian terletak pada pengujian performa Kluster *Hadoop* menggunakan layanan IaaS *Private Cloud*, maka rancangan skenario pengujian perlu disusun. Pengujian akan dilakukan menggunakan beberapa kasus seperti pada Tabel 1.

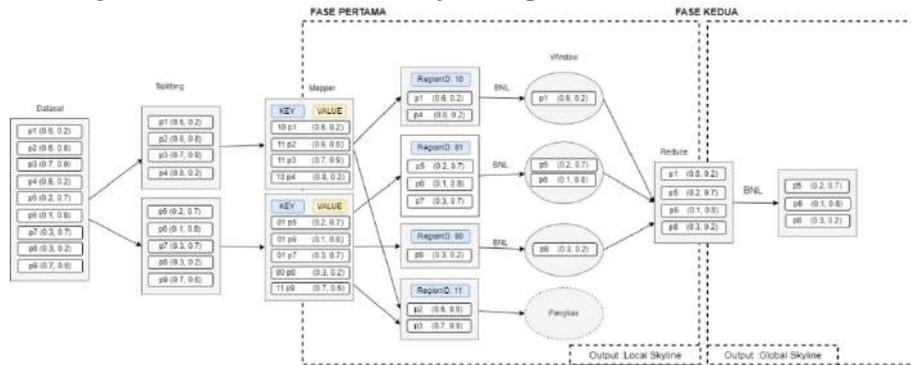
Tabel 1. Rancangan pengujian performa *kluster*

<i>Case</i>	<i>Step Pengujian</i>	<i>Expected Result</i>
Komputasi <i>Skyline</i> dengan <i>MR-BNL</i>	1. <i>Input data</i>	Sistem mampu menghasilkan <i>local</i> dan <i>global skyline</i>
	2. <i>Splitting data</i> sama rata sebesar 2^d pada mesin <i>mapper</i>	
	3. Berikan <i>flag d-bit</i>	
	4. <i>Scanning local skyline</i> dengan <i>MR-BNL</i>	
	5. <i>Local skyline</i> digabungkan menggunakan <i>flag</i>	
	6. <i>Reducing</i> dengan <i>MR-BNL</i>	
	7. <i>Global skyline</i> dihasilkan	
Modifikasi ukuran file	1. Dari total ukuran <i>dataset</i> yang dimiliki, eksekusi dilakukan secara berkala dengan ukuran <i>file</i> pertama sekitar 100 MB atau jumlah data 1,5 juta.	Kecepatan <i>excecution time</i> Kecepatan waktu eksekusi semakin melambat seiring penambahan ukuran <i>file</i>
	2. Ukuran <i>file</i> akan terus ditambah hingga data berukuran sekitar 1 GB dengan pecahan 200 MB (2,5 juta), 400 MB (5 juta), 800 MB (10 juta) hingga 1 GB (12 juta).	
Variasi jumlah <i>node</i>	1. <i>Hadoop MapReduce</i> dijalankan dengan 1 <i>node</i> pada sebuah ukuran <i>file</i> .	Kecepatan <i>excecution time Hadoop MapReduce</i> meningkat seiring penambahan <i>node</i> .
	2. <i>Node</i> kemudian ditambah mulai dari 2 hingga 7 <i>node</i> .	
Variasi ukuran <i>block HDFS</i>	1. <i>Blocksize HDFS</i> dengan blok lebih kecil dari <i>default</i> (128 MB) yakni 64 MB	Terjadi peningkatan eksekusi <i>write time</i> seiring penambahan ukuran <i>block HDFS</i> .
	2. Penambahan ukuran <i>block</i> menjadi 128 MB dan 256 MB, 512 MB	

Pengujian dilakukan untuk menilai performa kluster virtual terhadap suatu keadaan tertentu. Untuk memberikan perbandingan kinerja yang jelas dan realistis, kluster virtual akan dibandingkan dengan kluster fisik dalam *running jobs* dan diberikan skenario pengujian yang sama. Setiap pengujian akan diulang 3 kali dan hasilnya akan dirata-ratakan, kemudian direpresentasikan dalam plot grafik.

Sesuai Tabel 1, dalam menilai respon kluster, perlu disiapkan beberapa skenario pengujian yang dilakukan secara bertahap. Setiap pengujian yang dilakukan menggunakan algoritma MR-BNL dengan kluster yang diinisialisasikan untuk mencari *Skyline* pada data berukuran besar. Pada *Skyline Block*

Nested Loop (BNL) proses *MapReduce* untuk menghasilkan *local skyline* dan *global skyline* terdiri atas dua fase. Fase pertama adalah distribusi partisi data ke *mapper* dan fase kedua adalah komputasi *local skyline* pada setiap partisi dengan BNL sehingga menghasilkan *global skyline*. Komputasi *Skyline* menggunakan algoritma MR-BNL akan ditunjukkan pada Gambar 3.



Gambar 3. *Skyline* dengan MR-BNL

3. Hasil dan Pembahasan

Bagian ini menyajikan temuan yang didapatkan setelah menjalankan setiap percobaan. Ditampilkan hasil performa kluster *Hadoop MapReduce* setelah menjalankan komputasi *Skyline* MR-BNL dengan beragam kondisi di atas *private cloud* dan di atas komputer fisik. Kluster diuji dengan beragam variasi kondisi seperti perubahan ukuran file, perbedaan jumlah mesin hingga variasi ukuran blok data HDFS. Penulis telah menggunakan tiga jenis input data sintetik dan menggunakan parameter konfigurasi yang sama untuk perbandingan yang realistis. Untuk setiap skenario pengujian, waktu *running jobs* ditulis menggunakan format detik berdasarkan tiga kali percobaan pengujian. Grafik untuk setiap skenario pada kluster fisik maupun kluster virtual *private cloud* di-plot untuk memvisualisasikan performa komputasi.

Tabel 2. Spesifikasi Kluster

Kluster Hadoop Private Cloud					Kluster Hadoop Fisik				
Hostname	Spesifikasi				Hostname	Spesifikasi			
	Processor	Core(s)	RAM	SSD		Processor	Core(s)	RAM	SSD
Master	Intel(R) Xeon (R) E3-1225 v5 @ 3.30 GHz	2	2.7 GB	35 GB	Master	Intel Core i5 CPU @ 3.00GHz	4	2.7 GB	80 GB
Slave1	Intel(R) Xeon (R) E3-1225 v5 @ 3.30 GHz	1	2 GB	25 GB	Slave1	Intel Core i5 CPU @ 3.00GHz	3	2 GB	50 GB
Slave2	Intel(R) Xeon (R) E3-1225 v5 @ 3.30 GHz	1	2 GB	25 GB	Slave2	Intel Core i5 CPU @ 3.00GHz	3	2 GB	50 GB
Slave3	Intel(R) Xeon (R) E3-1225 v5 @ 3.30 GHz	1	2 GB	25 GB	Slave3	Intel Core i5 CPU @ 3.00GHz	3	2 GB	50 GB
Slave4	Intel(R) Xeon (R) E3-1225 v5 @ 3.30 GHz	1	2 GB	25 GB	Slave4	Intel Core i5 CPU @ 3.00GHz	3	2 GB	50 GB
Slave5	Intel(R) Xeon (R) E3-1225 v5 @ 3.30 GHz	1	2 GB	25 GB	Slave5	Intel Core i5 CPU @ 3.00GHz	3	2 GB	50 GB
Slave6	Intel(R) Xeon (R) E3-1225 v5 @ 3.30 GHz	1	2 GB	25 GB	Slave6	Intel Core i5 CPU @ 3.00GHz	3	2 GB	50 GB

A. Hasil Pengujian dan Analisis Hasil Kluster Virtual *Hadoop Private Cloud*

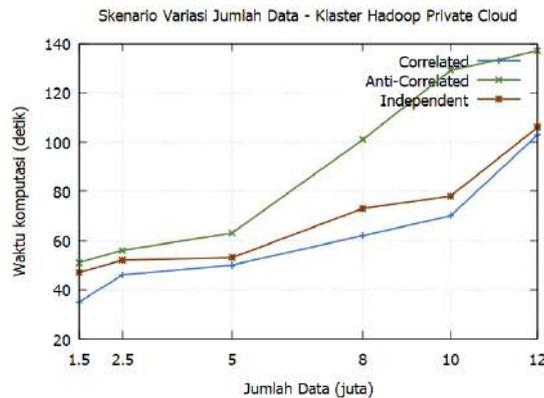
1. Skenario Variasi Jumlah Data atau Ukuran File

Menjalankan beragam variasi ukuran data dengan 4 mesin tidak membutuhkan waktu yang lama. Mesin membutuhkan waktu rata-rata yang berbeda untuk setiap jenis dan ukuran *dataset*. Dari ketiga *dataset*, data sintesis *anti-correlated* cenderung memberikan waktu komputasi yang lebih tinggi dibanding yang lainnya. Hal ini disebabkan data *anti-correlated* menghasilkan lebih banyak titik *skyline* dibandingkan kedua *dataset* lainnya, sehingga waktu pencarian *skyline global* menghasilkan waktu yang lebih lama. Hal ini dapat dilihat pada Tabel 3.

Tabel 3. Hasil komputasi skenario 1 - Kluster *Hadoop Private Cloud*

Jumlah Data (Juta)	Jenis <i>Dataset</i>		
	<i>Correlated</i>	<i>Anticorrelated</i>	<i>Independent</i>
1.5	35	51	47
2.5	46	56	52
5	50	63	53
8	62	101	73
10	70	129	78
12	103	137	106

Berdasarkan Gambar 4, secara garis besar ketiga *dataset* menunjukkan peningkatan waktu komputasi seiring dengan penambahan volume data. Penambahan volume data mengakibatkan semakin banyak kandidat *skyline* yang harus di bandingkan satu persatu untuk mencari *skyline global* menggunakan algoritma *Block Nested Loops*, sehingga *execution time* semakin lama. Urutan data yang menghasilkan titik *skyline* paling banyak terletak pada data *anti-correlated* diikuti oleh data *independent* kemudian data *correlated*. Hal ini menyebabkan data *anti-correlated* membutuhkan waktu komputasi paling lama dibanding kedua data lainnya. Sementara, data *correlated* menjadi data dengan komputasi tercepat karena hasil akhir *skyline global* yang sedikit.



Gambar 4. Hasil komputasi skenario 1 – Kluster *Hadoop Private Cloud*

2. Skenario Variasi Jumlah Mesin

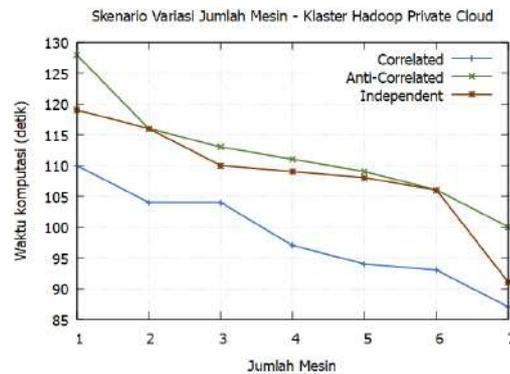
Skenario pengujian ini menampilkan tingkat signifikansi perubahan kinerja kluster secara parsial dari waktu eksekusi sebelum dan sesudah mengalami perubahan jumlah *node*. Pada skenario ini ditetapkan variabel terikat yakni jumlah data berukuran 12 juta, sementara variabel bebas yakni jumlah mesin virtual dari 1 mesin hingga 7 mesin. Pemilihan jumlah data ini dilakukan setelah mengamati peningkatan kinerja kluster pada ketiga *dataset* di skenario sebelumnya. Tabel 4 menunjukkan jumlah mesin memberi peningkatan kinerja yang secara umum cukup signifikan dalam mengeksekusi ketiga jenis *dataset* ketika kluster ditingkatkan dari 1 mesin hingga 7 mesin.

Tabel 4. Hasil Komputasi Skenario 2 - Kluster *Hadoop Private Cloud*

Jumlah Mesin	Jenis <i>Dataset</i>		
	<i>Correlated</i>	<i>Anticorrelated</i>	<i>Independent</i>
1	110	128	119
2	104	116	116
3	104	113	110
4	97	111	109
5	94	109	108
6	93	106	106
7	87	100	91

Pada Gambar 5, tampak bahwa waktu menyelesaikan komputasi *Hadoop MapReduce* pada aplikasi *skyline* secara umum berkurang secara konstan seiring jumlah mesin virtual yang diskalakan. Penggunaan lebih banyak mesin akan mempercepat kinerja komputasi paralel dalam memproses aplikasi *Skyline MR-BNL*. Hal ini disebabkan efisiensi pembagian tugas ke dalam bagian-bagian yang lebih kecil pada beberapa prosesor memungkinkan keseluruhan proses komputasi diselesaikan dengan lebih cepat. Efisiensi komputasi paralel pada Gambar 5 menunjukkan percepatan yang ideal, yang mana peningkatan kecepatan komputasi terjadi seiring dengan penambahan jumlah prosesor yang digunakan secara paralel. Pada ketiga jenis *dataset* yang diujikan, data *anti-correlated* membutuhkan waktu yang paling lama, kemudian menyusul *dataset*

independent dengan perbandingan waktu komputasi sedikit lebih cepat, namun tidak jauh berbeda. Sementara data *correlated* mampu diselesaikan dengan jauh lebih cepat oleh kluster dibanding kedua *dataset* lainnya.



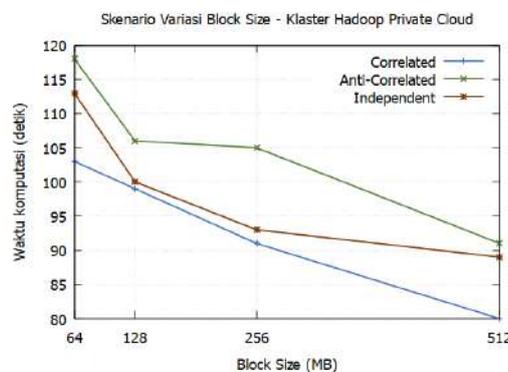
Gambar 5. Hasil komputasi skenario 2 - Kluster *Hadoop Private Cloud*

3. Skenario Ukuran Blok HDFS

Gambar 6 menunjukkan bahwa *block size* dapat mempengaruhi performa kecepatan *Hadoop MapReduce* dalam mengeksekusi aplikasi *Skyline MR-BNL* untuk setiap percobaan menggunakan file 1,06 GB pada *block size* yang bervariasi. Pada skenario ketiga, ketiga *dataset* dengan jumlah data 12 juta atau 1,06 GB akan dipotong menjadi beberapa *block* sesuai *block size* 64 MB, 128 MB, 256 MB dan 512 MB. Gambaran potongan *block* tersebut dapat dilihat pada Gambar 7. Dari gambar tersebut, dapat terlihat bahwa file berukuran 1,06 GB dengan *block default* (128 MB) dipotong menjadi 9 *block* dengan replikasi 3 yang akan tersimpan pada setiap *node*.

Tabel 5. Hasil Komputasi Skenario 3 - Kluster *Hadoop Private Cloud*

Ukuran <i>Block</i>	Jenis <i>Dataset</i>		
	<i>Correlated</i>	<i>Anticorrelated</i>	<i>Independent</i>
64 MB	103	118	113
128 MB	99	106	100
256 MB	91	105	93
512 MB	80	91	89



Gambar 6. Hasil Komputasi Skenario 3 - Kluster *Hadoop Private Cloud*

Jumlah *block* pada ukuran file 1,06 GB dengan *block size* 64 MB menghasilkan 17 *block*, lebih banyak dibandingkan pada *block size* 256 MB dan 512 MB yang masing-masing menghasilkan 5 *block* dan 3 *block*. Jumlah *block* yang semakin sedikit akan mengurangi ukuran *metadata* dari *namenode* sehingga mempercepat proses kerja dari *namenode*. Selain itu, jumlah *block* pada *HDFS Hadoop* menentukan jumlah *task* yang harus dikerjakan oleh *MapReduce*. Jumlah *block* yang sedikit dapat diartikan dengan jumlah *task* yang sedikit pula. Jumlah *task* yang sedikit dapat memudahkan

scheduler task MapReduce dalam menjadwalkan *task* yang diberikan sehingga mengurangi kerja *scheduler task MapReduce*. Jumlah *task* yang sedikit juga dapat mengurangi waktu komunikasi permintaan *task* antara *scheduler task MapReduce* dengan *Resource Manager* serta *Resource Manager* dengan *Node Manager*. Hal ini tentunya akan berdampak pada kecepatan komputasi *Hadoop MapReduce* yang dijalankan.

Gambar 6, secara garis besar memperlihatkan bahwa penambahan *block size* pada ketiga jenis *dataset* dapat mempercepat proses *MapReduce* pada *Hadoop*. Ketika menggunakan *block size* 64 MB dengan 17 potongan *block*, komputasi *Hadoop MapReduce* berjalan paling lambat dibanding menggunakan *block size* 128 MB, 256 MB dan 512 MB. Sementara itu, waktu komputasi tercepat ditunjukkan ketika *block size* 512 MB dengan jumlah *block* yang dihasilkan hanya 3 *block*.

Perlu diketahui bahwa pada *Hadoop*, tidak ada aturan dalam memilih *block size* HDFS, itu semua tergantung pada ukuran file yang akan dieksekusi. Maka dari itu, untuk memaksimalkan throughput, perlu disesuaikan ukuran *block* dengan input data. Jika data yang akan diolah adalah kumpulan data berukuran besar yang tidak bisa diolah menggunakan single machine, disarankan untuk menggunakan *block size* berukuran 128 MB atau 256 MB atau 512 MB. Dan jika datanya berukuran lebih kecil, maka menggunakan *block size* yang lebih kecil lagi adalah pilihan yang lebih baik.

Jika sebelumnya telah dijelaskan bahwa memperkecil *block size* akan memperlambat kinerja *name node* dan *MapReduce*, maka pada kasus tertentu memperbesar *block size* juga akan menyebabkan efisiensi paralelisme berkurang dikarenakan sedikitnya *splitting* data. Hal ini menyebabkan banyaknya mesin *mapper* yang kurang dimanfaatkan untuk komputasi. Ketika menggunakan *block size* berukuran besar, potongan *block* akan semakin kecil, dengan begitu *block* akan disebarkan pada mesin *mapper* sesuai jumlah *block*. Menjalankan komputasi dengan mesin *mapper* yang lebih sedikit pada beberapa kasus contohnya (Basuki dkk., 2015) akan menyebabkan komputasi melambat. Hal ini disebabkan karena ukuran potongan *block* yang harus diproses menghasilkan *block* terlalu besar dan membebani suatu node dalam mengolahnya.

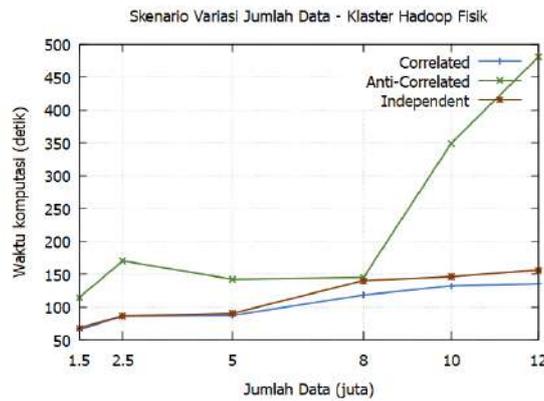
B. Hasil Pengujian dan Analisis Hasil Kluster Hadoop Fisik

1. Skenario Variasi Jumlah Data atau Ukuran File

Menjalankan komputasi *skyline MR-BNL* menggunakan kluster fisik menunjukkan bahwa perlu waktu yang lebih banyak untuk menghasilkan titik *skyline* untuk ukuran data 10 GB dan 12 GB. Menggunakan 4 *node slave*, hasil pengujian 3 jenis data sintetik menunjukkan pengaruh jumlah data terhadap waktu komputasi *Hadoop MapReduce*. Pada Tabel 6 tercantum hasil komputasi *skyline* menggunakan tiga jenis data sintetis dan dikonseptualisasikan dalam Gambar 7.

Tabel 6. Hasil Komputasi Skenario 1 – Kluster *Hadoop* Fisik

Jumlah Data (Juta)	Jenis Dataset		
	<i>Correlated</i>	<i>Anticorrelated</i>	<i>Independent</i>
1.5	65	114	68
2.5	86	170	86
5	87	142	90
8	118	145	140
10	132	349	146
12	135	481	156



Gambar 7. Hasil komputasi skenario 1 – Kluster *Hadoop* Fisik

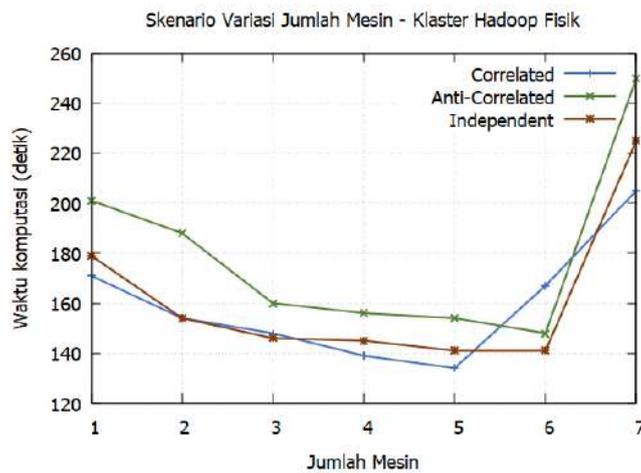
Gambar 7 menggambarkan pengaruh penambahan jumlah data yang secara garis besar mampu menurunkan kinerja kluster seiring penambahan jumlah data. Sesuai dengan jumlah titik *skyline* yang dihasilkan pada ketiga *dataset*, data *anti-correlated* dengan titik *skyline* paling banyak tentunya membutuhkan waktu komputasi paling tinggi dibanding data lainnya. Sementara data *independent* dan *correlated* membutuhkan waktu yang tidak jauh berbeda untuk memproses data. Pada data *anti-correlated*, waktu pencarian *skyline* meningkat sebesar 48% saat data dinaikkan dari 1.5 juta menjadi 2.5 juta. Namun, menambah jumlah data menjadi 5 juta dan 8 juta menyebabkan penurunan dalam waktu pencarian *skyline* sebesar 14%. Ini bisa saja disebabkan karena dampak dari *network bottleneck*, terutama komputasi *Hadoop* yang sangat dipengaruhi oleh kelancaran jaringan. Sementara saat data ditambah menjadi 10 juta dan 12 juta, waktu pencarian *skyline* meningkat kembali hingga 231%.

2. Skenario Vairiasi Jumlah Mesin

Grafik *execution time* dari komputasi *skyline query* dengan variasi jumlah data, menjadi patokan dalam menentukan jumlah data yang akan diproses pada skenario selanjutnya. Skenario pengujian ini menampilkan tingkat signifikansi perubahan kinerja *kluster* secara parsial dari waktu eksekusi sebelum dan sesudah mengalami perubahan jumlah *node*. Pada kluster *Hadoop* fisik, variabel terikat dan bebas ditetapkan sama seperti pengujian variasi jumlah mesin pada kluster *Hadoop Private Cloud*. Tabel 7 menunjukkan jumlah mesin memberikan pengaruh yang besar pada waktu eksekusi data berjumlah 12 juta.

Tabel 7. Hasil komputasi skenario 2 - Kluster *Hadoop* Fisik

Jumlah Mesin	Jenis Dataset		
	<i>Correlated</i>	<i>Anticorrelated</i>	<i>Independent</i>
1	171	201	179
2	154	188	154
3	148	160	146
4	139	156	145
5	134	154	141
6	167	148	141
7	205	250	225



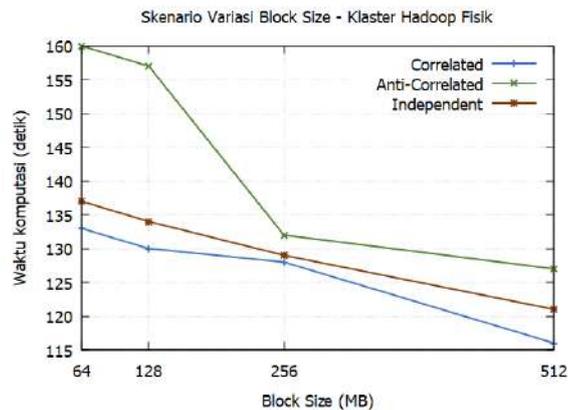
Gambar 8. Hasil komputasi skenario 2 - Kluster *Hadoop* Fisik

Menjalankan ketiga data sintesis di atas kluster fisik memberikan hasil yang berbeda. Umumnya peningkatan jumlah mesin akan mempercepat jalannya program. Namun, menjalankan banyak mesin dalam satu waktu rentan dengan kondisi *overhead* yang menyebabkan naiknya waktu komputasi. Pada Gambar 8, kluster berjalan secara optimal untuk seluruh jenis *dataset* hingga 5 *node*. Namun, ketika mesin ditambah menjadi 6 mesin, respon berbeda didapati dari masing-masing jenis *dataset*. Secara garis besar, kluster menunjukkan kinerja yang tidak optimal ketika menjalankan ketiga *dataset* menggunakan 7 *node*. Adanya peningkatan waktu komputasi ini diduga dipicu oleh kompleksitas pada proses distribusi data, sinkronisasi antar *node* dan komunikasi antar *daemon Hadoop* ketika jumlah mesin ditambah serta *network bottleneck*. *Overhead* menyebabkan waktu komputasi menjadi berlebih dan kluster bekerja tidak optimal. Terjadi peningkatan rata-rata waktu komputasi sebesar 50.3% pada ketiga *dataset*. Waktu komputasi berlebih karena overhead antar node juga terjadi pada penelitian (Made dkk., 2023; Achahbar & Abid, 2014). Pada (Achahbar & Abid, 2014), *overhead* terjadi ketika mengolah data berukuran 100 MB, 1 GB, 10 GB dan 100 GB menggunakan 7 mesin dan 8 mesin untuk *TestDFSIO- Read Performance*. Selain itu, kondisi *overhead* juga terjadi pada 8 node virtual *VMware ESXi* yang diduga disebabkan memori berlebih, tingkat latensi yang tinggi, dan kekurangan sumber daya ketika melakukan *Terasort 30 GB*. Menurut (Ivanov dkk., 2014), *overhead* pada mesin virtual terjadi berkisar pada 2-10% tergantung jenis aplikasinya. Namun, ada juga kasus yang mana kluster *Hadoop* yang divirtualisasikan memiliki komputasi yang lebih baik dari kluster *Hadoop* fisik karena sumber daya yang lebih baik. Salah satu kasusnya ialah penelitian ini. Kluster *Hadoop* virtual dibangun dengan spesifikasi sumber daya mesin yang lebih baik dibandingkan dengan kluster *Hadoop* fisik, sehingga memiliki kinerja yang lebih baik. Spesifikasi kedua kluster dapat dilihat pada Tabel 1.

3. Skenario Variasi Ukuran Blok HDFS

Tabel 8. Hasil komputasi skenario 3 - Kluster *Hadoop* Fisik

Ukuran Block	Jenis Dataset		
	Correlated	Anticorrelated	Independent
64 MB	133	160	137
128 MB	130	157	134
256 MB	128	132	129
512 MB	116	127	121

Gambar 9. Hasil komputasi skenario 3 - Kluster *Hadoop* Fisik

Grafik pada Gambar 8, memperlihatkan bahwa waktu eksekusi aplikasi *Skyline MR-BNL* pada file berukuran 1,06 GB seiring penambahan besar *block size* mengalami penurunan pada ketiga *dataset*, termasuk data *anti-correlated* yang menurun sebesar 20,6% dari 160 detik pada *block* 64 MB menjadi 127 detik pada *block* 512 MB. Penurunan waktu eksekusi juga dialami pada data *correlated* sebesar 12,7% dari 133 detik pada 64 MB menjadi 116 detik pada 512 MB. Penurunan waktu eksekusi *Hadoop MapReduce* pada ketiga *dataset* yang diujikan menunjukkan bahwa besar *block size* mempengaruhi proses komputasi dan semakin besar ukuran *block HDFS*, maka semakin rendah waktu eksekusi *Hadoop MapReduce* yang diperlukan.

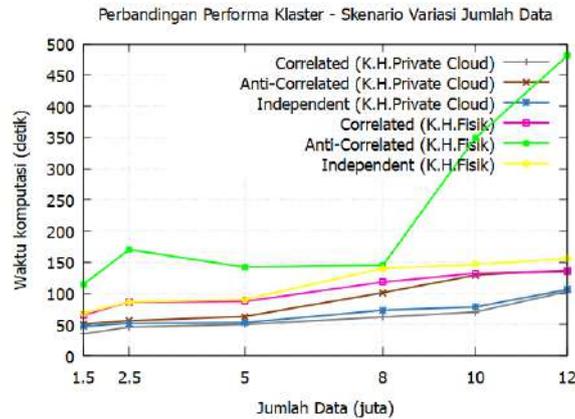
C. Perbandingan Performa Kluster Hadoop Private Cloud dan Kluster Hadoop Fisik

Secara garis besar, performa dari kedua kluster tergantung pada spesifikasi mesin, ukuran data komputasi, jenis *dataset*, jumlah mesin yang terlibat serta besar ukuran *block HDFS*. Untuk mengukur perbedaan yang signifikan antara kinerja kluster *Hadoop MapReduce* dengan mesin fisik (tanpa virtualisasi) dan tervirtualisasi *private cloud*, digunakan uji statistik t atau t-test. Jenis t-test yang digunakan ialah *paired sample t-test*. Uji statistik akan menunjukkan apakah rata-rata waktu komputasi *Hadoop MapReduce* akan mengalami perubahan yang bermakna ketika kluster divirtualisasikan dengan *private cloud*. Pada uji statistik ini, ditetapkan signifikansi (α) sebesar 5%. Kemudian, dalam mempermudah perhitungan *t-test* digunakan program Microsoft Excel.

Dalam skenario variasi jumlah data 1,5 juta pada ketiga data sintesis, kluster *private cloud* memproses data *anti-correlated* (55%), *independent* (31%) dan *correlated* (46%) lebih cepat dibandingkan kluster *Hadoop* fisik. Selanjutnya, kinerja kluster meningkat signifikan saat jumlah data pada semua jenis *dataset* ditambah menjadi 2,5 juta, 5 juta, 8 juta, 10 juta dan 12 juta. Dalam hal ini, kluster *Hadoop private cloud* masih jauh lebih cepat daripada kluster *Hadoop* fisik. Secara keseluruhan, kluster fisik mengeksekusi jenis data *anti-correlated*, *independent* dan *correlated* dengan rentang waktu masing-masing 114-481 detik, 68-156 detik dan 65-135 detik. Sementara kluster *Hadoop private cloud* hanya membutuhkan masing-masing 51-137 detik, 47-106 detik dan 35-103 detik pada jenis data yang sama untuk menyelesaikan aplikasi *Skyline* yang dijalankan.

Tabel 9. Perbandingan waktu komputasi pada skenario 1

Jumlah Data (Juta)	Klaster <i>Hadoop Private Cloud</i>				Klaster <i>Hadoop Fisik</i>	
	<i>Correlated</i>	<i>Anticorrelated</i>	<i>Correlated</i>	<i>Anticorrelated</i>	<i>Correlated</i>	<i>Anticorrelated</i>
1.5	35	51	47	65	114	68
2.5	46	56	52	86	170	86
5	50	63	53	87	142	90
8	62	101	73	118	145	140
10	70	129	78	132	349	146
12	103	137	106	135	481	156



Gambar 10. Perbandingan waktu komputasi pada skenario 1

Pada skenario perubahan ukuran atau jumlah data menggunakan 4 mesin, sebelum melakukan t-test, terlebih dahulu dirumuskan hipotesis nol (H_0) dan hipotesis alternatif (H_1). Hipotesis tersebut adalah:

H_0 = Rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan jumlah data sebelum divirtualisasi (menggunakan mesin fisik) = Rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan jumlah data setelah divirtualisasi dengan *private cloud*.

H_1 = Rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan jumlah data sebelum divirtualisasi (menggunakan mesin fisik) \neq Rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan jumlah data setelah divirtualisasi dengan *private cloud*.

Anti-Correlated - Dengan Klaster Mesin Fisik		Anti-Correlated - Dengan Klaster Virtualisasi Private Cloud	
Mean	257.4		87.2
Variance	22954.3		1369.2
Observations	5		5
Pearson Correlation	0.84354303		
Hypothesized Mean Difference	0		
t Stat	2.934802739		
P(T<=t) one-tail	0.031302081		
t Critical one-tail	2.33846786		
P(T<=t) two-tail	0.041604562		
t Critical two-tail	2.776445105		
Independent - Dengan Klaster Mesin Fisik		Independent - Dengan Klaster Virtualisasi Private Cloud	
Mean	125.8		72.4
Variance	3983.8		438.1
Observations	5		5
Pearson Correlation	0.305291369		
Hypothesized Mean Difference	0		
t Stat	7.231736882		
P(T<=t) one-tail	0.00102188		
t Critical one-tail	2.33846786		
P(T<=t) two-tail	0.00204376		
t Critical two-tail	2.776445105		
Correlated - Dengan Klaster Mesin Fisik		Correlated - Dengan Klaster Virtualisasi Private Cloud	
Mean	111.6		86.2
Variance	556.3		514.2
Observations	5		5
Pearson Correlation	0.84661179		
Hypothesized Mean Difference	0		
t Stat	7.860362148		
P(T<=t) one-tail	0.000707757		
t Critical one-tail	2.33846786		
P(T<=t) two-tail	0.001415514		
t Critical two-tail	2.776445105		

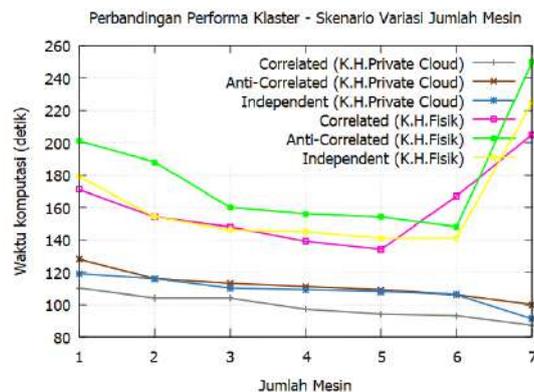
Gambar 11. Hasil Uji-t pada skenario 1

Berdasarkan hasil uji statistik pada Gambar 11, dihasilkan t hitung atau t stat (2,93) > t tabel atau *t critical two tail* (2,77) pada data *anti-correlated*, t hitung atau t stat (7,13) > t tabel atau *t critical two tail* (2,77) pada data *correlated* dan t hitung atau t stat (7,86) > t tabel atau *t critical two tail* (2,77) pada data *independent*. Hal ini berarti H_0 ditolak dan H_1 diterima. Sehingga dapat ditarik kesimpulan bahwa rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan jumlah data sebelum divirtualisasi (menggunakan mesin fisik) tidak sama dengan rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan jumlah data setelah divirtualisasi dengan *private cloud* atau

dengan kata lain, pada skenario perubahan jumlah data, *Hadoop MapReduce* menunjukkan performa yang jauh lebih baik saat divirtualisasi dengan *private cloud*, dibandingkan menggunakan kluster fisik.

Tabel 10. Perbandingan waktu komputasi pada skenario 2

Jumlah Mesin	Kluster <i>Hadoop Private Cloud</i>				Kluster <i>Hadoop Fisik</i>	
	<i>Correlated</i>	<i>Anticorrelated</i>	<i>Correlated</i>	<i>Anticorrelated</i>	<i>Correlated</i>	<i>Anticorrelated</i>
1	110	128	119	171	201	179
2	104	116	116	154	188	154
3	104	113	110	148	160	146
4	97	111	109	139	156	145
5	94	109	108	134	154	141
6	93	106	106	167	148	141
7	87	100	91	205	250	225



Gambar 12. Perbandingan performa kluster – skenario 2

Pada skenario kedua yakni variasi jumlah mesin, kluster *Hadoop* tervirtualisasi *private cloud* memiliki kinerja yang lebih baik bila dibandingkan dengan kluster fisik. Saat mengeksekusi aplikasi *Skyline MR-BNL* pada data *anti-correlated*, *correlated*, dan *independent* menggunakan 1 mesin, waktu komputasi dengan kluster *Hadoop private cloud* unggul dibanding kluster *Hadoop* fisik (Gambar 12) masing-masing sebesar 36%, 35%, dan 36%. Selanjutnya, seiring jumlah mesin yang diskalakan dari 2 mesin hingga 7 mesin, performa komputasi secara konstan meningkat, sehingga mencapai kondisi yang ideal. Sementara pada kluster *Hadoop* fisik, penambahan mesin memberikan respon yang berbeda pada ketiga dataset. Dataset *anti-correlated* dan *independent* mencapai kondisi ideal ketika mesin berjumlah 6, sehingga ketika mesin ditambah menjadi 7 mesin, terjadi *OC (Overhead Communication)*. *OC* terjadi ketika kluster memiliki kompleksitas pada proses distribusi data, sinkronisasi antar *node* dan komunikasi antar *daemon Hadoop*. Sedikit berbeda dari kedua dataset lainnya, dataset *correlated* mencapai kondisi ideal ketika mesin berjumlah 5. Kondisi *OC* juga didapati ketika mesin diskalakan menjadi 6 mesin dan 7 mesin.

	Anti-Correlated - Dengan Kluster Mesin Fisik	Anti-Correlated - Dengan Kluster Virtualisasi Private Cloud
Mean	176	109.1666667
Variance	1508.8	31.76666667
Observations	6	6
Pearson Correlation	-0.549952051	
Hypothesized Mean Difference	0	
df	5	
t Stat	3.878752663	
P(T<=t) one-tail	0.0058283	
t Critical one-tail	2.015048373	
P(T<=t) two-tail	0.0116566	
t Critical two-tail	2.570581836	
	Independent - Dengan Kluster Mesin Fisik	Independent - Dengan Kluster Virtualisasi Private Cloud
Mean	158.6666667	106.6666667
Variance	1078.666667	70.26666667
Observations	6	6
Pearson Correlation	-0.848989556	
Hypothesized Mean Difference	0	
df	5	
t Stat	3.168141336	
P(T<=t) one-tail	0.012433372	
t Critical one-tail	2.015048373	
P(T<=t) two-tail	0.024866745	
t Critical two-tail	2.570581836	
	Correlated - Dengan Kluster Mesin Fisik	Correlated - Dengan Kluster Virtualisasi Private Cloud
Mean	157.8333333	96.5
Variance	668.5666667	44.3
Observations	6	6
Pearson Correlation	-0.618835736	
Hypothesized Mean Difference	0	
df	5	
t Stat	4.937396094	
P(T<=t) one-tail	0.002165907	
t Critical one-tail	2.015048373	
P(T<=t) two-tail	0.004331815	
t Critical two-tail	2.570581836	

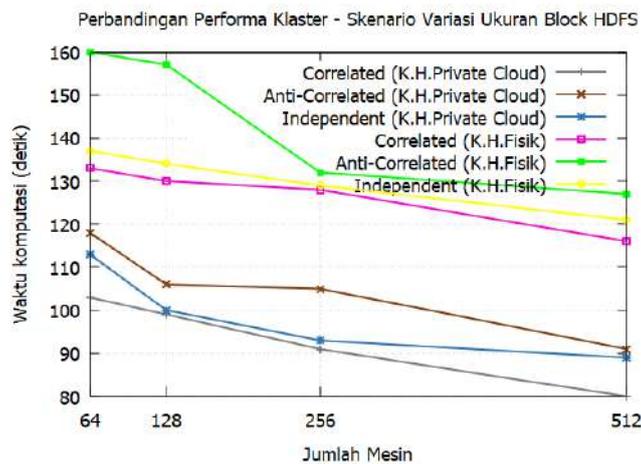
Gambar 13. Hasil Uji-t pada skenario 2

Pada Gambar 13, dikarenakan t hitung (9,11) > t tabel (2,77) pada data *anti-correlated*, t hitung (8,02) > t tabel (2,77) pada data *correlated* dan t hitung (43,8) > t tabel (2,77) pada data *independent*, maka H₁ diterima. Sehingga disimpulkan bahwa ketika menjalankan skenario 1, terdapat perbedaan antara rata-rata waktu komputasi sebelum kluster di virtualisasikan dan sesudah divirtualisasikan dengan Private Cloud. Hal ini juga menunjukkan ketika menskalakan jumlah mesin, kluster *Hadoop* yang divirtualisasikan dengan *private cloud* bekerja lebih baik menggunakan komputer fisik (tidak divirtualisasikan).

Pada skenario penambahan ukuran *block size HDFS* (Gambar 14), kedua kluster menunjukkan *trend* kinerja yang sama. Kedua kluster sama-sama menunjukkan peningkatan waktu komputasi *Hadoop MapReduce* ketika jumlah *block* yang akan dieksekusi berkurang. Dalam hal ini, secara keseluruhan, kluster *private cloud* menyelesaikan komputasi lebih cepat dibandingkan kluster *Hadoop* fisik. Misalnya, menggunakan *block size* 64 MB pada ketiga dataset berukuran 1,06 GB akan menghasilkan potongan *block* sebanyak 17 *block*. Waktu komputasi yang diperlukan oleh kluster *private cloud* pada data *anti-correlated*, *independent* dan *correlated* lebih rendah dibanding kluster *Hadoop* fisik dengan persentase masing-masing sebesar 26%, 18%, dan 23%. Kemudian, saat *block size* diperbesar menjadi 128 MB, 256 MB dan 512 MB sehingga potongan *block* menjadi lebih sedikit, kinerja kluster menurun secara signifikan pada semua jenis dataset.

Tabel 11. Perbandingan waktu komputasi pada skenario 3

Block Size	Kluster Hadoop Private Cloud			Kluster Hadoop Fisik		
	Correlated	Anticorrelated	Independent	Correlated	Anticorrelated	Independent
64 MB	103	118	113	133	160	137
128 MB	99	106	100	130	157	134
256 MB	91	105	93	128	132	129
512 MB	80	91	89	116	127	121



Gambar 14. Perbandingan performa kluster – skenario 3

	Anti-Correlated - Dengan Kluster Mesin Fisik	Anti-Correlated - Dengan Kluster Virtualisasi Private Cloud
Mean	138.6666667	100.6666667
Variance	258.3333333	70.3333333
Observations	3	3
Pearson Correlation	0.67386737	
Hypothesized Mean Difference	0	
df	2	
t Stat	5.428571429	
P(T<=t) one-tail	0.016149255	
t Critical one-tail	2.91998558	
P(T<=t) two-tail	0.03229851	
t Critical two-tail	4.30265273	
	Independent - Dengan Kluster Mesin Fisik	Independent - Dengan Kluster Virtualisasi Private Cloud
Mean	128	94
Variance	43	31
Observations	3	3
Pearson Correlation	0.958634312	
Hypothesized Mean Difference	0	
df	2	
t Stat	29.44486373	
P(T<=t) one-tail	0.000575705	
t Critical one-tail	2.91998558	
P(T<=t) two-tail	0.001151411	
t Critical two-tail	4.30265273	
	Correlated - Dengan Kluster Mesin Fisik	Correlated - Dengan Kluster Virtualisasi Private Cloud
Mean	124.6666667	90
Variance	57.3333333	91
Observations	3	3
Pearson Correlation	0.955267051	
Hypothesized Mean Difference	0	
df	2	
t Stat	18.67895141	
P(T<=t) one-tail	0.00142693	
t Critical one-tail	2.91998558	
P(T<=t) two-tail	0.002853861	
t Critical two-tail	4.30265273	

Gambar 15. Hasil Uji-t pada skenario 3

Pada skenario 3, dirumuskan hipotesis uji t yakni $H_0 =$ Rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan *block size* HDFS sebelum divirtualisasi (menggunakan mesin fisik) = Rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan *block size* HDFS setelah divirtualisasi dengan *private cloud*. Sementara $H_1 =$ Rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan *block size* HDFS sebelum divirtualisasi (menggunakan mesin fisik) \neq Rata-rata waktu komputasi *Hadoop MapReduce* dalam merespon perubahan *block size* HDFS setelah divirtualisasi dengan *private cloud*. Sehingga berdasarkan Gambar 15 yang mana t hitung (5,42) > t tabel (4,30) pada data anti-correlated, t hitung (18,67) > t tabel (4,30) pada data correlated dan t hitung (29,44) > t tabel (4,30) pada data independent, kluster *Hadoop* yang divirtualisasikan dengan *private cloud* kembali unggul dibandingkan kluster *Hadoop* fisik pada ketiga dataset ketika memproses beragam ukuran *block* HDFS untuk data berukuran 1,06 GB.

Berdasarkan hasil uji statistik t pada Gambar 11, Gambar 13, Gambar 15, dapat dibuktikan bahwa dalam menjalankan keseluruhan pengujian mulai dari perubahan ukuran file, perubahan jumlah mesin dan modifikasi *block size* HDFS, dengan spesifikasi tertentu, kluster *Hadoop private cloud* yang dibangun bekerja lebih baik dalam menjalankan komputasi *Hadoop MapReduce*, dibandingkan kluster mesin fisik (tanpa virtualisasi).

4. Kesimpulan

- Untuk mengimplementasikan kluster *Hadoop MapReduce* di atas *private cloud computing*, dilakukan proses instalasi dan konfigurasi lingkungan tempat *daemon Hadoop* dijalankan serta parameter konfigurasi untuk *daemon Hadoop*. *Daemon Hadoop* yang dimaksud adalah *name node*, *data node*, *secondary name node*, *resource manager*, dan *node manager*.
- Penambahan volume data yang dieksekusi dari 1,5 juta hingga 12 juta akan menyebabkan kenaikan waktu komputasi dan penurunan kinerja kluster.
- Penambahan jumlah mesin dari 1 mesin menjadi 7 mesin meningkatkan kinerja kluster *Hadoop private cloud*, sementara bagi kluster *Hadoop* fisik menyebabkan overhead.
- *Block Size* menentukan jumlah potongan *block* yang akan dieksekusi dan mempengaruhi kecepatan komputasi *Hadoop MapReduce*.
- Pada seluruh skenario pengujian performa yang peneliti lakukan, kluster *Hadoop* yang divirtualisasikan di atas *Private Cloud* dengan spesifikasi mesin Intel(R) Xeon (R) E3-1225 v5 @ 3,30 GHz RAM 16 GB, bekerja jauh lebih baik dalam mengeksekusi aplikasi *Skyline* dibandingkan kluster *Hadoop* yang dibangun pada mesin fisik dengan spesifikasi mesin Intel Core i5 CPU @ 3,00GHz RAM 4 GB. Hal ini dibuktikan dari hasil perbandingan rata-rata waktu komputasi kedua kluster dengan *paired t-test* yang mana pada skenario perubahan jumlah data dihasilkan bahwa t hitung (2,93) > t tabel (2,77) pada data *anti-correlated*, t hitung (7,13) > t tabel (2,77) pada data *correlated* dan t hitung (7,86) > t tabel (2,77) pada data *independent*. Pada skenario perubahan jumlah mesin dihasilkan t hitung (9,11) > t tabel (2,77) pada data *anti-correlated*, t hitung (8,02) > t tabel (2,77) pada data *correlated* dan t hitung (43,8) > t tabel (2,77) pada data *independent*. Sementara skenario modifikasi ukuran *block size* HDFS dihasilkan t hitung (5,42) > t tabel (4,30) pada data *anti-correlated*, t hitung (18,67) > t tabel (4,30) pada data *correlated* dan t hitung (29,44) > t tabel (4,30) pada data *independent*.

5. Daftar Pustaka

- Achahbar, O., & Abid, M. R. (2014). The impact of virtualization on high performance computing clustering in the cloud. *International Journal of Distributed Systems and Technologies*, 6(4), 65–81. <https://doi.org/10.4018/IJDST.2015100104>
- Azizah, N., & Saptono, H. (2020). Uji Performa Dan Perbandingan Rdbms Mysql Dan Hive-Hadoop. *Jurnal Informatika Terpadu*, 6(1), 20–28. <https://journal.nurulfikri.ac.id/index.php/JIT>
- Basuki, K., Palit, H. N., & Dewi, L. P. (2015). Implementasi Hadoop: Studi Kasus Pengolahan Data Peminjaman Perpustakaan Universitas Kristen Petra. *Jurnal Infra*, 3, 7. <http://publication.petra.ac.id/index.php/teknik-informatika/article/view/3135>
- Börzsönyi, S., Kossmann, D., & Stocker, K. (2001). The skyline operator. *Proceedings - International Conference on Data Engineering*, 421–430. <https://doi.org/10.1109/icde.2001.914855>
- Ivanov, T., Zicari, R. V., Izberovic, S., & Tolle, K. (2014). *Performance Evaluation of Virtualized Hadoop Clusters*. <http://arxiv.org/abs/1411.3811>
- Made, I., Putra, S. W., Wijayanto, H., & Zafrullah, A. (2023). *Komputasi Paralel untuk Perhitungan Relasi Dominasi Menggunakan Skyline Query pada Lokasi Wisata di Pulau Lombok* [Universitas Mataram]. <http://eprints.unram.ac.id/39679/>
- Nuriadin, A., Dyan Nofia Harumike, Y., Tana Sanggamu, D., Studi Ilmu Komunikasi, P., & Islam Blitar, U. (2021). Sejarah Perkembangan Dan Implikasi Internet Pada Media Massa Dan Kehidupan Masyarakat. *SELASAR KPI: Referensi Media Komunikasi Dan Dakwah*, 1(1). <https://ejournal.iainu-kebumen.ac.id/index.php/selasar/index>
- Prabowo, W. S., Muslim, M. H., & Iryanto, S. B. (2015). Pusat Data Privat Virtual Pemerintah Berbasis Komputasi Awan (Studi Empiris Pada Lembaga Ilmu Pengetahuan Indonesia). *Jurnal Penelitian dan Pengembangan Komunikasi, dan Informatika*, 6(2), 1–12.
- Ryanto, A. M. (2017). *Analisis Kinerja Framework Big Data Pada Kluster Tervirtualisasi: Hadoop Mapreduce Dan Apache Spark* [Universitas Hasanuddin]. <http://digilib.unhas.ac.id/>

- Subagya, N., Wijajarto, A., & Almaarif, A. (2021). Implementasi Dan Analisis Hadoop Element Availability Berdasarkan Daemon Log Monitoring Hadoop Element Availability Implementation and Analysis Based on Daemon Log Monitoring. *E-Proceeding of Engineering*, 8(5), 9223–9234. <https://openlibrary.telkomuniversity.ac.id/pustaka/170581/implementasi-dan-analisis-hadoop-element-availability-berdasarkan-daemon-log-monitoring-menggunakan-log4j-logging.html>
- Subramanian, S. K., & Gouda, K. C. (2015). A Study on The Different Aspects of Virtual Private Cloud. *International Journal of Applied Engineering Research*, 10(86), 343–347. <https://www.ripublication.com/Volume/ijaerv10n86.htm>
- Wibawa, I. P. A. P., Giriantari, I. D., & Sudarma, M. (2018). Komputasi Paralel Menggunakan Model Message Passing Pada SIM RS (Sistem Informasi Manajemen Rumah Sakit). *Majalah Ilmiah Teknologi Elektro*, 17(3), 439. <https://doi.org/10.24843/mite.2018.v17i03.p20>