

**PERBANDINGAN ALGORITMA PEMBELAJARAN MESIN
MENGGUNAKAN PENCIPTAAN CIRI LENGAH DAN KAEDAH
PEMBUNGKUS BAGI MODEL PENYELENGGARAAN RAMALAN
MESIN PAM**

Nuramni Ashikin binti Anuar, Syaimak binti Abdul Shukor

Fakulti Teknologi Sains dan Maklumat, Universiti Kebangsaan Malaysia
43600 UKM Bangi, Selangor Malaysia.

P111024@ukm.edu.my, syaimak@ukm.edu.my

ABSTRAK

Mesin industri yang kompleks pada masa kini memerlukan kaedah penyelenggaraan yang mampu mengendalikan lambakan data. Kaedah Penyelenggaraan Ramalan, PdM mampu menganalisis data yang banyak dengan penggunaan algoritma Pembelajaran Mesin, ML. Kerosakan pada mesin industri menggunakan kaedah PdM untuk mengelakkan pemberhentian operasi mesin dan kos penyelenggaraan yang tinggi. Tujuan PdM adalah meramal kerosakan pada mesin sebelum ia berlaku supaya langkah penyelenggaraan dapat dijalankan. Salah satu industri yang memerlukan kaedah penyelenggaraan yang optimum adalah sistem pengepaman di mana jenis pam sering digunakan adalah pam empar. Pam empar penting untuk dipantau keadaannya supaya ia berfungsi dengan baik. Dengan menggunakan algoritma ML, data dari sensor pam empar boleh dimanfaatkan untuk mempelajari maklumat bagi meramal kerosakan. Algoritma ML dapat meramal kerosakan lebih awal pada pam empar dengan penggunaan kejuruteraan ciri. Kejuruteraan ciri melibatkan analisis siri masa iaitu penciptaan ciri lengah berjaya meramal kerosakan 10 minit lebih awal pada pam empar. Pemilihan ciri menggunakan kaedah pembungkus berjaya memilih 5 sensor dari 48 sensor diuji untuk meramal kerosakan pam empar. Overfitting pada set data latihan berjaya dilakukan hasil dari pemilihan ciri yang tepat. Algoritma ML menggunakan teknik klasifikasi pembelajaran terselia iaitu algoritma RF, DT, GB, NN dan SVM. Pembahagian data yang sesuai dilakukan bagi kajian ini adalah nisbah 60:40 dan prestasi metrik dapatan semula dan kejituuan berjaya ditingkatkan. Penalaan hiperparameter berjaya mengoptimumkan prestasi algoritma RF, DT, GB dan SVM. Penilaian prestasi algoritma dilakukan selepas pengujian dengan menilai metrik Ketepatan, Kejituuan, Dapatan Semula, Skor-F1 dan lingkungan di bawah ROC serta Matriks Kekeliruan. Prestasi algoritma dibandingkan dan algoritma yang optimum diperoleh berdasarkan analisis adalah RF dan SVM dengan dapatan semula 0.982 dan 0.985. Manakala skor kejituuan diperoleh adalah 0.974 dan 0.970. Skor F1 diperoleh tertinggi iaitu 0.978 dan memperoleh nilai lingkungan bawah ROC melebihi 0.990. Keputusan ini menunjukkan kedua-dua algoritma ini berupaya meramal kerosakan pam empar dengan baik.

Kata Kunci: Penyelenggaraan Ramalan, Pam Empar, Pembelajaran Mesin, Analisis Siri Masa, Kaedah Pembungkus, Ramalan Algoritma Optimum

I. PENGENALAN

Sistem pengepaman mempunyai mesin industri seperti pam empar yang kebanyakannya digunakan dalam industri kosmetik, pertanian, pembuatan wain, tenusu, perlombongan, petroleum, pemprosesan makanan, kimia, loji penjanaan kuasa, minuman, farmaseutikal dan pengairan air

kawasan perbandaran. Pam empar perlu berada dalam keadaan baik kerana kadar penggunaan sistem pengepaman adalah kerap dan beroperasi secara harian. Dalam industri pembuatan, 27% tenaga elektrik digunakan dalam sistem perindustrian diwakili oleh sistem pengepaman (Abelin et al. 2006). Kerosakan pada pam empar akan mengakibatkan kelumpuhan kepada proses dalam industri yang menggunakan sistem pengepaman. Justeru, kaedah pengurusan penyelenggaraan yang optimum harus dipilih bagi meramal kerosakan komponen dalam pam empar.

Kaedah pengurusan penyelenggaraan yang optimum iaitu Penyelenggaraan Ramalan, PdM menggunakan analisis ramalan untuk menentukan bila penyelenggaraan harus dilakukan berdasarkan data-data yang diperoleh seperti rekod masa lampau, rekod penyelenggaraan dan butiran operasi daripada mesin industri (Carvalho et al. 2019; Bukhsh and Stipanovic 2020). PdM akan menjimatkan kos kerana penyelenggaraan hanya akan dilakukan apabila diperlukan dan jadual penyelenggaraan dirancang dengan tepat supaya proses aplikasi pam empar dalam industri tidak terganggu. Analisis boleh dilakukan bagi mendapatkan corak tersembunyi dengan menggunakan kaedah Pembelajaran Mesin, ML di mana tingkah laku mesin boleh dipelajari daripada rekod masa lampau. Jika tingkah laku mesin dapat diramalkan, kegagalan komponen dapat dikesan lalu membantu membuat keputusan dengan tepat.

Jika kerosakan komponen dapat dikesan lebih awal, ia akan memberi ruang yang cukup bagi pengendali mesin untuk melakukan penyelenggaraan. Dengan kaedah PdM, ramalan kerosakan awal dapat dilakukan dengan memanfaatkan *signal* sensor yang berubah-ubah terhadap masa. Pengesanan kerosakan awal penting untuk mengelakkan pemberhentian operasi mesin dan menganggu proses pengeluaran (Gaurkar et al. 2021; Ayvaz and Alpay 2021). Dalam metodologi ML, kejuruteraan ciri membina ciri baharu dari ciri pada data sedia ada. Data diperoleh dari sensor mempunyai setem masa iaitu format siri masa yang merekod bacaan sensor pada sela masa yang tetap (Orrù et al. 2020). Ini dikenali sebagai kejuruteraan ciri bagi analisis siri masa. Ciri baharu yang dicipta digunakan untuk meramal kerosakan lebih awal dengan memanfaatkan setem masa pada bacaan sensor. Berdasarkan rekod masa lampau daripada data sensor, ciri lengah (*lag feature*) dicipta bagi meramal kerosakan lebih awal.

Terdapat pelbagai sensor dalam pam empar yang boleh dipantau bagi memastikan keadaan mesin berada dalam keadaan baik. Pelbagai sensor diperoleh perlu dianalisis bagi meramal kerosakan pam empar menggunakan metodologi ML (Hu et al. 2020). Sensor dari data harus dipilih menggunakan kaedah pemilihan ciri untuk memperoleh set sensor yang tepat untuk meramal kerosakan pam empar. ML banyak digunakan dalam industri bagi membuat keputusan penyelenggaraan yang optimum dengan melakukan kaedah PdM. Dengan memanfaatkan ML bagi PdM, penjadualan penyelenggaraan mesin dapat dicadangkan, proses penyelenggaraan diuruskan dengan cekap dan meningkatkan kualiti pengeluaran.

Oleh itu, kajian ini mencadangkan kejuruteraan ciri bagi analisis siri masa dapat meramal kerosakan lebih awal pada pam empar untuk melakukan penyelenggaraan. Pemilihan ciri menggunakan kaedah pembungkus dengan algoritma Pemilihan Ke Belakang Berjujukan, SBS untuk mendapatkan set sensor bersesuaian. Algoritma ML digunakan bagi meramal kerosakan adalah Hutan Rawak (RF), Pohon Keputusan (DT), Penggalak Kecerunan (GB), Rangkaian Neural (NN) dan Mesin Vektor Sokongan (SVM). Algoritma ML dinilai prestasinya untuk meramal kerosakan pam empar dengan baik menggunakan penilaian metrik bersesuaian seperti Ketepatan, Kejituhan, Dapatkan Semula, Skor-F1 dan lingkungan di bawah ROC serta Matriks Kekeliruan. Justeru, perbandingan prestasi antara algoritma ML dilakukan untuk memilih algoritma yang optimum bagi meramal kerosakan lebih awal pada pam empar untuk melakukan penyelenggaraan.

A. Penyataan Masalah

Analisis ramalan melibatkan penggunaan ML dapat memberi amaran awal mengenai keadaan pam empar. Data pam empar adalah dalam masa nyata dan sensor pada data mempunyai setem masa. Setem masa adalah masa pengukuran pada bacaan sensor dimanfaatkan supaya ramalan kerosakan lebih

awal pada pam empar dapat dilakukan. Pengesahan kerosakan awal berpotensi menghalang kegagalan mesin dengan teruk dan tindakan penyelenggaraan sewajarnya boleh diambil tepat pada masanya oleh pengendali mesin (Nagdev Amruthnath and Tarun Gupta 2018). Menggunakan kejuruteraan ciri, ciri lengah dicipta bagi meramal kerosakan lebih awal dengan memilih tetingkap gelongsor bersetujuan dengan sifat pam empar. Ciri lengah adalah cara menukar peramalan siri masa bagi membentuk set data sebagai masalah pembelajaran terselia (Khorsheed and Beyca 2021). Kerosakan pam empar dapat diramalkan lebih awal berdasarkan nilai masa lampau rekod sensor. Ciri lengah sesuai bagi kajian ini yang menggunakan pendekatan pembelajaran terselia. Oleh itu, kejuruteraan ciri dalam analisis siri masa membina ciri baharu daripada rekod data masa lampau untuk meramal kerosakan lebih awal pada pam empar.

Data pam empar mengandungi sensor iaitu ciri dalam kajian untuk meramal kerosakan pam empar. Bilangan sensor yang pelbagai perlu dipilih melalui kaedah pemilihan ciri bagi memperoleh set sensor yang tepat. Ciri yang terlalu banyak tidak akan meningkatkan prestasi algoritma dan *overfitting* boleh berlaku terhadap set data latihan. Set sensor yang tepat walaupun sedikit dapat mempengaruhi prestasi algoritma dalam meramal kerosakan pam empar supaya penyelenggaraan dapat dijalankan tepat pada masanya. Oleh itu, pemilihan sensor yang sesuai dari data pam empar harus dikenal pasti untuk memperoleh prestasi algoritma yang baik dalam meramal kerosakan pam empar.

Penghasilan data yang kompleks dan pelbagai dari mesin pam empar menyebabkan perlunya alat analisis ramalan seperti ML. Dengan menggunakan algoritma ML bagi PdM, ia mampu untuk mengendalikan data yang mempunyai dimensi tinggi dan belajar dari corak tersembunyi bagi membuat keputusan yang boleh membantu pengendali mesin. Pemilihan algoritma ML amat penting bagi mendapat prestasi ramalan yang baik. Peringkat pemilihan algoritma ML adalah penting kerana ia merupakan komponen asas yang mestilah belajar daripada data sebelumnya dan digeneralisasikan untuk tujuan PdM (Stetco et al. 2019). Pemilihan algoritma ML harus dipilih dengan tepat bagi mengekstrak maklumat bermakna daripada pam empar bagi melaksanakan PdM yang cekap. Pengujian dilakukan terhadap set data ujian untuk menilai prestasi algoritma yang telah dipilih. Prestasi algoritma ML dibandingkan untuk memilih algoritma yang optimum bagi meramal kerosakan pam empar. Algoritma optimum dipilih adalah algoritma ML yang sesuai digunakan pada data pam empar dalam kajian PdM ini untuk penyelenggaraan pam empar.

B. Objektif Kajian

Antara objektif kajian terperinci yang hendak dicapai adalah seperti berikut:

- i. Mengimplementasi kejuruteraan ciri dengan mencipta ciri lengah di dalam algoritma ML bagi meramal kerosakan pam empar dengan lebih awal.
- ii. Mengenal pasti sensor daripada data pam empar yang mempengaruhi prestasi algoritma menggunakan kaedah pembungkus dengan algoritma Pemilihan Ke Belakang Berjujukan untuk meramal kerosakan pam empar.
- iii. Membandingkan algoritma pembelajaran mesin iaitu Hutan Rawak, Pohon Keputusan, Penggalak Kecerunan, Rangkaian Neural dan Mesin Vektor Sokongan bagi meramal kerosakan pam empar dengan optimum.

Jurnal ini mengandungi lima bahagian. Bahagian I membincangkan tentang pengenalan, pernyataan masalah dan objektif kajian. Bahagian II menunjukkan kajian kesusteraan berkenaan PdM, ML dalam PdM, kejuruteraan ciri dan pemilihan ciri. Bahagian III berkaitan dengan metodologi yang digunakan dalam kajian ini. Bahagian IV menerangkan keputusan kajian dan perbincangan analisis kajian. Akhir sekali, Bahagian V ialah cadangan dan rumusan kajian.

II. KAJIAN KESUSASTERAAN

A. Penyelenggaraan Ramalan, PdM

PdM merupakan kaedah pengurusan penyelenggaraan bagi menyelenggara mesin industri sebelum kerosakan berlaku. Ia menggunakan pendekatan berasaskan data dengan algoritma ML. Menurut (Carvalho et al. 2019), terdapat kajian mengenai PdM sejak tahun 2009 sehingga kini dan sebelum 2013, hanya dua kajian berkenaan PdM dilaksanakan. Selepas 2013, sudah semakin bertambah kajian dilakukan bagi PdM. Ini menunjukkan kajian bagi PdM menggunakan algoritma ML masih giat dijalankan oleh penyelidik selari dengan penghasilan data yang banyak oleh mesin industri. Matlamat PdM adalah untuk meramal kerosakan pada masa hadapan untuk merancang penyelenggaraan yang paling sesuai pada masa yang tepat dengan menggunakan data dan algoritma (Orrù et al. 2020). Kaedah PdM dapat mengatasi masalah di mana kegagalan pada mesin dapat diramal dan berpotensi untuk mengesan kerosakan awal. PdM diaplikasikan melalui data mesin industri bagi meramal kerosakan mesin sebelum tidak berfungsi. Oleh itu, data sensor yang banyak dapat meramal dan mendiagnosa kerosakan mesin selain mengurangkan kos penyelenggaraan menggunakan kaedah PdM (Hsu et al. 2020).

Kaedah PdM boleh digunakan sebagai pengurusan penyelenggaraan bagi sistem pengepaman dan kajian ini boleh diaplikasikan dalam industri lain juga (Olesen and Shaker 2020). Salah satu jenis pam sering digunakan adalah pam empar di mana ia digunakan untuk menggerakkan cecair daripada satu tangki kepada tangki lain atau dalam sistem pam bangunan mengikut industri masing-masing. Pam empar merupakan komponen kritikal dalam sistem pengepaman untuk memastikan proses-proses dalam industri yang menggunakan berjalan dengan lancar. 80% pam yang dihasilkan di dunia adalah pam empar untuk kegunaan kebanyakan industri dan 90% pam empar digunakan dalam industri kimia (Olesen and Shaker 2020). Pam empar mempunyai komponen-komponen dalaman yang perlu dijaga dengan baik bagi mengelakkan ia rosak. Oleh kerana data mesin industri kebanyakan mempunyai rekod masa lampau, teknik klasifikasi berdasarkan pendekatan pembelajaran terselia sering digunakan bagi mendiagnosa kerosakan mesin.

B. Pembelajaran Mesin, ML dalam PdM

Perkembangan penggunaan ML diguna pakai dalam menyelesaikan masalah daripada kebanyakan data sedia ada dalam sains komputer dan bidang lain seperti PdM mempunyai potensi menggunakan pendekatan algoritma ML bagi data dari mesin industri (Zhang et al. 2019). Algoritma ML kerap digunakan bagi melakukan PdM adalah RF, DT, GB, SVM dan NN. Kelima-lima algoritma ML ini banyak diguna pakai oleh penyelidik di mana RF, SVM dan NN mendahului yang lain dalam meramal kerosakan pada mesin industri. Manakala, algoritma DT dan GB kerap dipakai untuk sistem pengepaman.

Menurut kajian (Cardoso and Ferreira 2021), ML yang sering diguna bagi PdM adalah RF (33%), NN (27%), SVM (25%) dan k-Min (13%). RF dan DT sering dipilih kerana keputusan daripada algoritma pokok mempunyai kesan ketara ke atas ketepatan prestasi diagnosis dalam pelbagai bidang seperti pengecaman huruf, diagnosis perubatan dan pengecaman pertuturan (Zhang et al. 2019). Ini adalah kerana hasil daripada keputusan algoritma pokok mempunyai cabang pokok yang boleh difahami menunjukkan ciri mana akan memberi impak besar kepada ramalan. Dalam kes PdM, ini bermaksud daripada cabang pokok tersebut, parameter data dapat dikenal pasti komponen rosak pada mesin dan dapat melakukan penyelenggaraan terhadap komponen tersebut. GB juga merupakan algoritma pokok untuk teknik klasifikasi. Ia algoritma pokok menggalakkan untuk mengurangkan perbezaan antara kelas sebenar dengan kelas yang hendak diramal (Khorsheed and Beyca 2021). GB merupakan algoritma pengelasan yang dapat memisahkan kelas data dengan baik.

RF dan DT lebih banyak diguna kerana SVM dan NN perlu lebih banyak masa dan sumber pengkomputeran bagi memproses pelbagai parameter. Namun, SVM dan NN masih diguna kerana

boleh memisahkan data secara tidak linear kepada linear. Data yang lebih kompleks boleh dikendalikan di mana SVM mencari *hyperplane* sempadan keputusan yang terbaik bagi pemisahan kelas manakala NN memisahkan kelas daripada beberapa lapisan neuron (Stetco et al. 2019). Algoritma SVM dan NN perlu bagi mengendalikan data yang besar dan kompleks bagi memperoleh prestasi algoritma yang baik. Oleh itu, lima algoritma ML iaitu RF, DT, GB, SVM dan NN kerap digunakan kerana setiap industri mempunyai kes yang berbeza dan pilihan algoritma juga bergantung kepada masalah yang hendak diselesaikan.

Kesemua algoritma ML ini menggunakan teknik klasifikasi pembelajaran terselia. Beberapa ukuran prestasi digunakan untuk membandingkan dan menilai kuasa ramalan algoritma (Khorsheed and Beyca 2021). Ia bertujuan untuk menilai prestasi ramalan algoritma dalam meramal kerosakan pada mesin industri. Prestasi ramalan algoritma yang bagus akan menentukan penyelenggaraan dapat dijalankan pada masa yang tepat sebelum kerosakan berlaku. Prestasi algoritma ML dinilai dengan metrik Ketepatan, Kejituhan, Dapatkan Semula, Skor F1 dan lingkungan di bawah ROC serta Matriks Kekeliruan (Calabrese et al. 2020; Velimirović et al. 2021; Fan 2022). Matriks kekeliruan digunakan bagi menilai prestasi algoritma yang menggunakan teknik klasifikasi pembelajaran terselia. Bagi mendapatkan ramalan kerosakan yang tepat supaya penyelenggaraan dapat dijalankan, prestasi algoritma dibandingkan untuk memilih algoritma yang optimum.

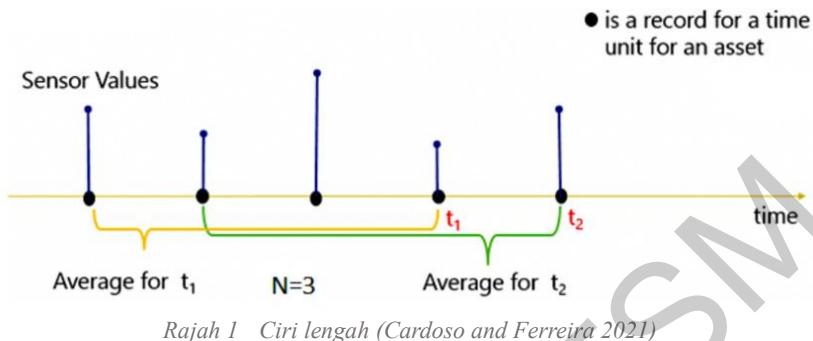
Algoritma RF dan SVM kerap digunakan bagi meramal kesalahan (*fault prediction*) dan mendiagnosis kesalahan bagi kaedah PdM (Zhang et al. 2019). Ketepatan diperoleh bagi kajian terdahulu yang disenaraikan adalah antara 50.1% sehingga 99.3% bagi algoritma SVM. Manakala ketepatan diperoleh bagi algoritma RF adalah antara 82.0% sehingga 99.2%. Selain itu, algoritma DT memperoleh ketepatan antara 80.6% sehingga 95% manakala NN memperoleh ketepatan 93.0% sehingga 100% bagi mendiagnosis kerosakan mesin industri (Zhang et al. 2019). Algoritma RF dan GB memperoleh keseluruhan prestasi model terbaik dari penilaian metrik untuk meramal kerosakan pada sistem pengepaman (Khorsheed and Beyca 2021; Velimirović et al. 2021). Prestasi algoritma pada kajian terdahulu menunjukkan bahawa algoritma RF, SVM, DT, NN dan GB mampu memperoleh keputusan yang baik untuk meramal kerosakan pada mesin industri.

C. Kejuruteraan Ciri

Kejuruteraan ciri dilakukan dengan mencipta ciri baharu daripada ciri-ciri dalam data sedia ada. Tujuan mencipta ciri baharu adalah untuk mewakilkan data dalam bentuk yang lebih bermaklumat dan memberi makna. Menurut kajian (Cardoso and Ferreira 2021), penciptaan ciri lengah boleh dijana daripada masa dengan menetapkan berapa jauh algoritma hendak meramal sesuatu keadaan berdasarkan keperluan projek. Ciri lengah ini akan dijadikan panduan bagi melatih algoritma untuk meramal kerosakan lebih awal dengan menentukan tetingkap gelongsor. Ciri lengah ialah sejenis ciri berdasarkan tetingkap yang dicipta dengan mengalihkan nilai siri masa dengan beberapa langkah masa tertentu. Ini dikenali sebagai kejuruteraan ciri bagi analisis siri masa. Penciptaan ciri lengah menangkap kebergantungan antara nilai berturut-turut dalam data siri masa dan ketepatan algoritma untuk menangkap kerosakan dapat ditingkatkan.

Ciri lengah memberikan maklumat penting tentang tingkah laku yang membawa kepada kegagalan kerana ia dilatih oleh nilai sensor dalam masa berturutan. Sebagai contoh, jika siri masa terdapat data setiap sela masa 1 jam, ciri lengah bersamaan 1 akan mewakili nilai dari satu jam sebelumnya. Manakala ciri lengah bersamaan 2 akan mewakili nilai dari dua jam sebelumnya. Kerosakan mesin dapat diramalkan lebih awal sebelum kerosakan berdasarkan nilai masa lampau rekod sensor hasil dari penciptaan sensor dengan ciri lengah ini. Salah satu aspek terpenting bagi set data jenis siri masa ialah korelasi antara rekod data dan rekod sebelumnya dalam susunan kronologi. Ia adalah sesuai untuk menggunakan kejuruteraan ciri untuk memasukkan pengetahuan terdahulu ini ke dalam algoritma ML (Orrù et al. 2020). Oleh itu, kejuruteraan ciri dalam siri masa membina ciri baharu daripada rekod data masa lampau untuk meramal kerosakan.

Berdasarkan Rajah 1, ciri lengah akan dicipta berdasarkan parameter N iaitu tetingkap gelongsor bersesuaian dipilih untuk kajian. Terdapat 5 rekod sensor pada rajah dan tetingkap gelongsor dilakukan adalah 3 jam. Ini bermakna nilai pada siri masa t_1 dan t_2 telah digerakkan 3 jam ke belakang dari rekod sensor asal. Ciri lengah dikira untuk tempoh N berdasarkan rekod sebelum masa di permulaan rekod data dan berikutnya. Parameter N boleh ditentukan dalam minit atau jam bergantung pada sifat data (Cardoso and Ferreira 2021).



Rajah 1 Ciri lengah (Cardoso and Ferreira 2021)

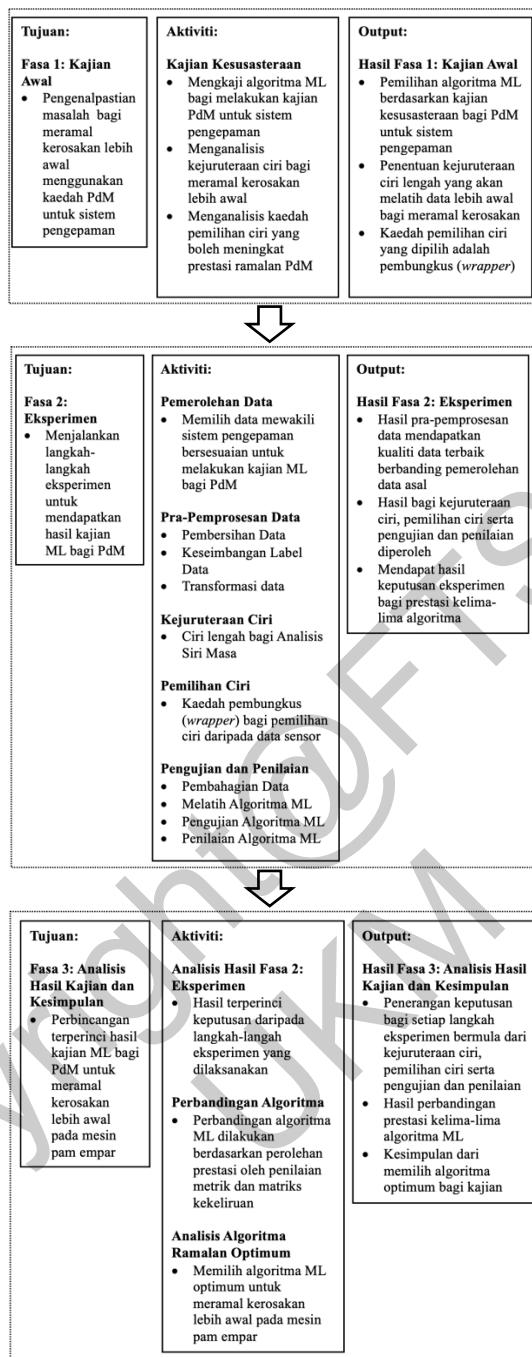
D. Pemilihan Ciri

Pemilihan ciri adalah teknik penting digunakan dalam kajian ML bagi memilih set ciri bersesuaian untuk meningkatkan prestasi ramalan algoritma. Pemilihan bertujuan memilih subset ciri yang akan dijadikan sebagai input untuk melatih algoritma dan mendapat keputusan prestasi ramalan yang baik. Terdapat tiga kaedah pemilihan ciri iaitu penapis, terbenam dan pembungkus. Teknik penapis dan terbenam menggunakan nilai ambang untuk menentukan ciri berkepentingan. Ciri mempunyai di bawah nilai ambang ditapkan akan dibuang dari menjadi set ciri yang akan digunakan. Kaedah ini tidak mengambil kira hubungan antara ciri data dan label sasaran. Manakala kaedah pembungkus sebaliknya menggunakan output pengelasan untuk membimbing pencarian subset ciri yang baik (Žagar et al.). Ia menggunakan algoritma pengelasan untuk membimbing membuat keputusan berdasarkan metrik skor diperoleh dan diuji setiap ciri sehingga mendapat set bersesuaian bagi kajian.

Menurut kajian (Nugroho et al. 2021), kaedah pembungkus menggunakan algoritma Pemilihan Ke Belakang Berjujukan, SBS mempunyai keputusan lebih baik berbanding Pemilihan Ke Depan Berjujukan, SFS. SBS memperoleh keputusan ketepatan 99.03% berbanding ketepatan SFS iaitu 98.04% dengan jumlah 11 ciri hasil diperoleh dari pemilihan ciri. SFS menguji semua ciri satu per satu dan akan meletakkan ciri tersebut jika ia meningkatkan prestasi algoritma pengelasan. Namun, dengan cara ini akan menyebabkan ciri yang telah dibuang terlebih dahulu tidak akan diuji bersama ciri lain yang masih belum diuji. Ini kerana ia menambah ciri satu per satu mengikut turutan dan terus membuang ciri tersebut apabila tidak meningkatkan prestasi. Manakala SBS akan menguji kesemua ciri secara serentak dan akan membuang ciri tersebut satu demi satu dengan memerhatikan prestasi pengelasan terendah. SBS dianggap lebih baik daripada SFS untuk pemilihan ciri kerana ia menilai kesan pembuangan setiap ciri pada prestasi pengelasan.

III. METODOLOGI KAJIAN

Kaedah kajian yang terlibat dalam membuat dan menganalisis hasil kajian ML bagi PdM terhadap sistem pengepaman terdiri daripada tiga fasa utama iaitu Fasa 1: Kajian Awal, Fasa 2: Eksperimen dan Fasa 3: Analisis Hasil Kajian dan Kesimpulan. Rajah 2 menunjukkan kaedah kajian secara keseluruhan.



Rajah 2 Kaedah kajian

A. Fasa 1: Kajian Awal

Fasa 1 bertujuan bagi mengenal pasti kajian-kajian terdahulu berkaitan implementasi algoritma ML untuk meramal kerrosakan terhadap sistem pengepaman menggunakan kaedah PdM. Pada fasa ini, pengenalpastian masalah dalam sistem pengepaman dan kajian kesusasteraan dilakukan bagi menentukan algoritma ML yang kerap digunakan dalam aplikasi PdM bagi teknik klasifikasi pembelajaran terselia. Ini adalah kerana algoritma ML digunakan mesti bersesuaian dengan data yang digunakan dalam kajian ini. Data digunakan mempunyai label oleh itu penting untuk menggunakan algoritma ML bagi teknik pembelajaran terselia. Algoritma ML ini akan dibandingkan prestasi mereka bagi menentukan algoritma optimum untuk meramal kerrosakan lebih awal pada pam empar.

B. Fasa 2: Eksperimen

Fasa 2 akan memeroleh data bersesuaian dengan sistem pengepaman untuk melaksanakan kajian PdM. Pra-pemprosesan data dilakukan bagi menyediakan kualiti data terbaik untuk dijadikan input sewaktu melatih lima algoritma ML bagi meramal kerosakan. Kejuruteraan ciri mencipta ciri baharu berdasarkan analisis siri masa untuk meramal kerosakan dengan lebih awal. Kaedah pemilihan ciri pembungkus digunakan dan algoritma ML dilatih. Fasa 2 berakhir dengan pengujian lima algoritma ML dan hasil penilaian prestasi kelima-lima algoritma diperoleh bagi tujuan analisis.

i. Pemerolehan Data

Data mempunyai 220,320 rekod bagi tempoh masa 5 bulan pada tahun 2018 bermula dari bulan April hingga Ogos dengan sela masa 1 minit. Manakala, jumlah atribut adalah 54 terdiri daripada 52 sensor, 1 *timestamp* dan 1 *machine_status*. *timestamp* adalah masa pengukuran bagi bacaan sensor, sensor merupakan bacaan data mentah dan *machine_status* iaitu *Normal*, *Recovering* dan *Broken* diguna sebagai label sasaran untuk meramal kerosakan pam empar. Parameter *machine_status* digunakan sebagai label kelas mempunyai kelas *Normal* sebanyak 205,836 rekod, *Recovering* sebanyak 14,477 rekod dan *Broken* sebanyak 7 rekod.

ii. Pra-Pemprosesan Data

Pra-pemprosesan merupakan kepentingan utama untuk menyediakan data sebelum melatih algoritma (Bekar et al. 2020). Seperti yang ditunjukkan dalam Rajah 2, pra-pemprosesan data melibatkan pembersihan data, keseimbangan label data dan transformasi data. Pembersihan data membuang atribut sensor_15 kerana mempunyai 100% kehilangan, membaiki nilai hilang pada sensor_51 menggunakan sensor_50, membuang sensor_00 dan sensor_37 dan mengendali nilai hilang selebihnya menggunakan teknik *Last Observation Carried Forward* (LOCF). Seterusnya, data tidak harus ada pengulangan pada masa merekod bacaan sensor. Atribut *timestamp* telah disemak tidak mempunyai rekod data yang berulang. Atribut *timestamp* ditukar jenis data kepada *datetime*.

Label *machine_status* pada data cuba diseimbangkan kerana data tidak seimbang tidak elok untuk melatih algoritma ML. Label sasaran adalah atribut *machine_status* di mana ia memberi status keadaan mesin terdiri daripada tiga kelas iaitu *Normal*, *Recovering* dan *Broken*. Namun, tiga label kelas ini tidak seimbang. Bagi mendapat prestasi algoritma ML yang bagus, data kerosakan yang banyak diperlukan bagi meningkatkan distribusi kelas supaya algoritma mempelajari corak dengan lebih baik (Calabrese et al. 2020; Velimirović et al. 2021). Kelas *Recovering* dan *Broken* digabungkan menjadi kelas *Broken* bagi melatih algoritma ML untuk meramal kerosakan pam empar. Kini, atribut *machine_status* mempunyai dua label kelas iaitu 205,836 rekod bagi *Normal* dan 14,484 rekod bagi *Broken*. Pengekodan label dilakukan bagi label *Normal* kepada angka 0 dan label *Broken* kepada angka 1. Atribut *machine_status* telah ditukar kepada *label*. Kini, atribut *label* mempunyai pengelasan binari 0 dan 1.

Transformasi data dilakukan bagi normalisasi data supaya nilai data berada dalam skala sama. Teknik digunakan adalah normalisasi penskalaan min-max (Cardoso and Ferreira 2021). Hasil prapemprosesan data, sebanyak 220,320 rekod masih dikenalkan kerana turutan masa adalah penting bagi kajian ini. Daripada 54 atribut asal, 50 atribut diperoleh. 50 atribut terdiri daripada 48 sensor, 1 *timestamp* dan 1 *label*.

iii. Kejuruteraan Ciri

Tujuan kejuruteraan ciri dilakukan bagi meningkatkan prestasi ramalan algoritma ML dengan mencipta ciri baharu daripada data sedia ada. Kejuruteraan ciri dilakukan berdasarkan analisis siri masa iaitu menggunakan atribut *timestamp* daripada data untuk mencipta ciri lengah. Ciri lengah yang dicipta adalah dari atribut sensor yang akan menggunakan setem masa sebagai panduan pemilihan tetingkap gelongsor. Tempoh tetingkap gelongsor yang ditetapkan untuk meramal kerosakan pam empar dalam

kajian ini adalah 10 minit. 10 minit adalah masa yang mencukupi bagi permasalahan dalam bidang kejuruteraan di mana mempunyai masa untuk bertindak bagi mengelakkan kerosakan seperti menutup pam dan sebagainya (Werth Jan 2021). Penggunaan tetingkap gelongsor bagi mencipta ciri lengah ini bersesuaian dengan kaedah PdM di mana ramalan awal dilakukan supaya langkah penyelenggaraan sepatutnya dijalankan. Dalam tempoh masa 10 minit, pelbagai masalah pada pam empar boleh berlaku kerana sifat ia sendiri. Oleh itu, pemantauan berterusan bagi keadaan pam empar lebih baik dilakukan.

Hasil dari kejuruteraan ciri menyebabkan 10 rekod pertama data nilai sensor hilang kerana nilai sensor telah dijadikan sebagai ciri baharu kepada selang 10 rekod berikutnya bagi meramal kerosakan pam empar 10 minit sebelum kerosakan. Penggunaan ciri lengah dalam kajian ini memanfaatkan nilai sensor pada langkah masa 10 minit sebelumnya bagi meramal kerosakan pam empar untuk masa hadapan. Kini, rekod data adalah 220,310 dan kekal 50 atribut hasil dari membuang nilai sensor hilang selepas penciptaan ciri lengah. Justeru, ciri lengah 10 minit dicipta dan pemilihan ciri akan dilakukan untuk memilih set ciri lengah yang tepat bagi meramal keadaan pam empar dengan baik.

iv. Pemilihan Ciri

Pemilihan ciri dilakukan bagi mengurangkan dimensi data dan membuang data tidak memberi makna. Ciri dalam kajian adalah atribut sensor. Terdapat 48 atribut sensor setelah pra-pemprosesan data dilakukan. Selepas kejuruteraan ciri dilakukan, atribut sensor masih kekal sebanyak 48. Daripada 48 sensor ini, pemilihan ciri akan dilakukan bagi memilih set sensor yang tepat bagi meramal kerosakan pam empar dengan baik. Dalam kajian ini, kaedah pembungkus menggunakan algoritma SBS dengan klasifikasi algoritma RF digunakan bagi memilih set sensor. Kaedah pembungkus menggunakan algoritma RF dapat memberikan ketepatan bagus dan bersesuaian dengan ciri jenis angka (Nugroho et al. 2021).

v. Pengujian dan Penilaian

Selepas mendapatkan set sensor terbaik daripada kaedah pembungkus, langkah Pengujian dan Penilaian dilakukan. Ia bertujuan melatih dan menguji algoritma ML iaitu RF, DT, GB, NN dan SVM yang telah dipilih dari Fasa 1. Langkah ini penting dilakukan untuk membina algoritma klasifikasi yang mampu mempelajari corak sensor dari data bagi meramal kerosakan pam empar. Hasil keputusan dari melatih algoritma ini akan diuji prestasinya supaya pemilihan algoritma yang optimum dapat dipilih dan dibincangkan dalam Fasa 3.

- *Pembahagian Data*

Pembahagian data harus dilakukan bagi melatih dan menguji algoritma ML. Ia bertujuan membina algoritma ramalan terbaik yang boleh memberi generalisasi dengan baik pada data apabila menguji prestasi algoritma hasil dari latihan (Muraina 2022). Pembahagian data dipilih dalam kajian ini adalah nisbah 60:40.

- *Latihan Algoritma ML*

Tujuan melatih algoritma adalah untuk algoritma ML mempelajari maklumat dari set ciri diperoleh untuk meramal kerosakan pam empar. Hiperparameter pada algoritma ML akan dilatih menggunakan penalaan hiperparameter. Ia bertujuan bagi mencari nilai hiperparameter untuk mengoptimumkan prestasi algoritma ML bagi membolehkan fleksibiliti dan meningkatkan atau mengurangkan bias algoritma (Olesen and Shaker 2020). 60% set data latihan akan menentukan nilai hiperparameter optimum bagi setiap algoritma ML. Pada set latihan ini, pengesahan silang (CV) menggunakan pemisahan siri masa secara k-lipatan dilakukan untuk memperoleh nilai hiperparameter optimum yang baik. CV dilakukan dalam turutan masa. Teknik penalaan hiperparameter yang dipilih untuk mencari nilai hiperparameter optimum pada set latihan adalah carian grid. Jadual 1 menunjukkan nilai hiperparameter optimum hasil dari carian grid yang telah dilakukan CV bagi algoritma ML. Nilai hiperparameter optimum akan digunakan sewaktu menguji algoritma ML.

Jadual 1 Nilai hiperparameter optimum hasil carian grid dilakukan CV bagi algoritma ML

Algoritma ML	Hiperparameter	Nilai Terpilih
RF	<i>n_estimators</i>	10
	<i>max_depth</i>	50
DT	<i>splitter</i>	<i>best</i>
	<i>max_depth</i>	5
GB	<i>learning_rate</i>	0.1
	<i>n_estimators</i>	25
NN	<i>hidden_layer_sizes</i>	(100,)
	<i>alpha</i>	0.0001
SVM	<i>C</i>	10
	<i>gamma</i>	0.1

- *Menguji Algoritma ML*

Selepas nilai set hiperparameter yang optimum dilatih pada keseluruhan algoritma, hasilnya akan dinilai prestasinya pada set ujian algoritma RF, DT, GB, NN dan SVM. Menguji algoritma ML amat penting untuk melihat cara algoritma berkelakuan terhadap set ujian (Cardoso and Ferreira 2021). Pemilihan algoritma optimum akan dilakukan dengan membuat perbandingan algoritma berdasarkan prestasi pada set ujian.

- *Penilaian Algoritma ML*

Prestasi algoritma ML dinilai dengan metrik Ketepatan, Kejituhan, Dapatkan Semula, Skor F1 dan lingkungan di bawah ROC serta Matriks Kekeliruan. Bahagian ini akan menerangkan penilaian prestasi algoritma yang digunakan. Ketepatan tidak boleh dijadikan sebagai satu-satunya penilaian bagi prestasi algoritma. Dapatkan semula amat penting dalam kajian PdM untuk dinilai kerana perkara yang diinginkan adalah algoritma yang mampu meramal kerosakan yang sebenar (Cardoso and Ferreira 2021; Khorsheed and Beyca 2021). Metrik kejituhan juga penting bagi mengelakkan penyelenggaraan tidak perlu apabila pam berada dalam keadaan baik. Skor F1 adalah metrik seimbang dalam menilai ketidakseimbangan data. Kebiasaan ROC diguna untuk menilai algoritma pengelasan secara keseluruhan di mana nilai yang menghampiri 1 menunjukkan algoritma boleh membezakan dua kelas yang lain dengan tepat. Nilai ROC melebihi 0.7 menandakan algoritma pengelasan yang bagus dan 0.8 menunjukkan algoritma membuat pengelasan dengan sangat baik (Khorsheed and Beyca 2021). Matriks Kekeliruan adalah bentuk jadual mengandungi nisbah kelas sebenar dan nisbah kelas yang diramalkan bagi label kelas dibandingkan dalam lajur dan baris berbentuk matriks segi empat sama sebagai output. Tujuan penilaian adalah untuk mengetahui kemampuan algoritma dalam meramal kerosakan pam empar terhadap data yang tidak pernah dilihat atau dipelajari hasil dari latihan yang telah dilakukan. Dengan mendapatkan hasil prestasi algoritma, perbincangan terperinci boleh dilakukan dan pemilihan algoritma yang optimum dapat ditentukan.

C. Fasa 3: Analisis Hasil Kajian dan Kesimpulan

Fasa 3 akan membincangkan dengan lebih lanjut hasil langkah-langkah eksperimen daripada Fasa 2. Hasil penilaian prestasi kelima-lima algoritma ML diterangkan. Perbandingan antara prestasi algoritma dilakukan untuk memilih algoritma optimum bagi meramal kerosakan lebih awal pada pam empar. Analisis secara terperinci melibatkan kajian terdahulu dibincangkan bagi pemilihan algoritma ML optimum. Akhir sekali, kesimpulan dibuat bagi kajian ini.

IV. HASIL KAJIAN

Bahagian ini membincangkan tentang hasil kajian berdasarkan Fasa 3 yang telah diuraikan.

A. Hasil Kejuruteraan Ciri

Berikut adalah perbincangan keputusan eksperimen bagi prestasi algoritma apabila kejuruteraan ciri dilakukan dan tidak dilakukan. Apabila kejuruteraan ciri tidak dilakukan, keputusan eksperimen diperoleh melibatkan pra-pemprosesan data, pemilihan ciri, melatih algoritma menggunakan parameter asal dan menguji algoritma ML.

Jadual 2 menunjukkan perbandingan keputusan eksperimen bagi prestasi algoritma sebelum dan selepas melakukan kejuruteraan ciri pada set data ujian. Ketepatan bagi sebelum dan selepas kejuruteraan ciri tidak mempunyai nilai yang terlalu berbeza untuk dibandingkan. Kejituhan mengalami kenaikan selepas kejuruteraan ciri dilakukan bagi algoritma RF, DT dan NN manakala penurunan bagi algoritma GB dan sama bagi algoritma SVM. Dapatan semula serta lingkungan bawah ROC mengalami penurunan bagi semua algoritma namun nilai diperoleh masih melebihi 0.970. Skor F1 mengalami kenaikan selepas kejuruteraan ciri dilakukan bagi algoritma RF, DT dan NN manakala penurunan bagi algoritma GB dan SVM.

Jadual 2 Perbandingan algoritma ML sebelum dan selepas kejuruteraan ciri bagi set data ujian

Algoritma	Ketepatan		Kejituuan		Dapatan Semula	
	Sebelum	Selepas	Sebelum	Selepas	Sebelum	Selepas
Kejuruteraan Ciri						
RF	99.7%	99.8%	0.960	0.974	0.987	0.982
DT	99.7%	99.7%	0.958	0.974	0.984	0.972
GB	99.8%	99.7%	0.980	0.972	0.985	0.975
NN	99.7%	99.7%	0.944	0.957	0.989	0.985
SVM	99.8%	99.8%	0.970	0.970	0.989	0.985

Algoritma	Skor F1		Lingkungan bawah ROC	
	Sebelum	Selepas	Sebelum	Selepas
Kejuruteraan Ciri				
RF	0.973	0.978	0.992	0.990
DT	0.971	0.973	0.991	0.985
GB	0.982	0.973	0.992	0.987
NN	0.966	0.971	0.993	0.991
SVM	0.979	0.978	0.994	0.992

Penurunan dan kenaikan nilai tidak begitu berbeza menunjukkan selepas kejuruteraan ciri dilakukan, algoritma masih mampu memberi prestasi yang baik. Penurunan yang berlaku dapat dijelaskan dengan penggunaan set ciri yang dipilih berlainan bagi set data apabila kejuruteraan ciri dilakukan dan tidak dilakukan. Pada tetingkap gelongsor 10 minit, prestasi algoritma selepas kejuruteraan ciri dilakukan didapati tiada perbezaan ketara. Prestasi algoritma ML yang telah melalui kejuruteraan ciri masih menunjukkan skor yang baik untuk meramal kerosakan pam empar. Ia dapat memberi lebih konteks dalam kajian PdM dengan melibatkan tetingkap gelongsor bagi pengesanan awal kerosakan pam empar.

B. Hasil Pemilihan Ciri

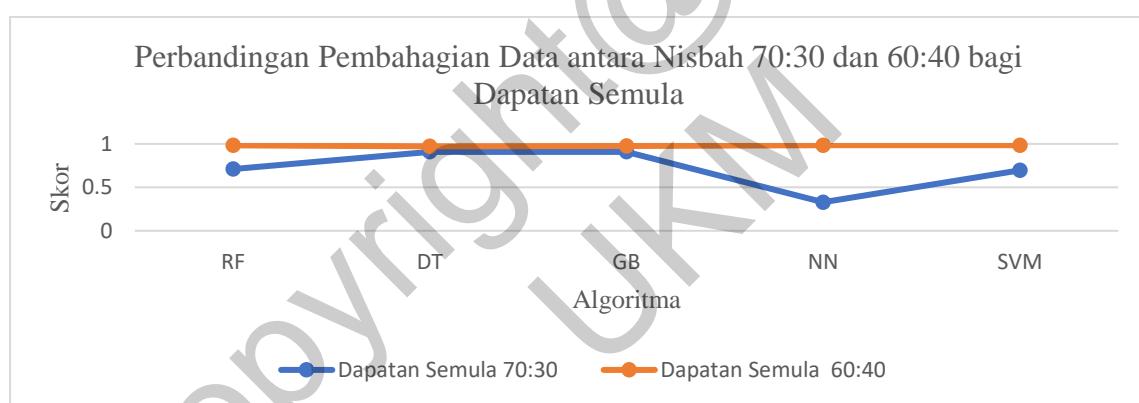
Dengan menggunakan algoritma SBS, pada mulanya semua ciri akan dipilih untuk diuji dengan algoritma RF dan prestasinya diperhatikan. Satu per satu ciri yang tidak akan meningkatkan skor *f1_macro* akan dibuang. Ciri dalam kajian terdiri daripada 48 atribut sensor yang antaranya akan terpilih sebagai input untuk melatih algoritma bagi meramal kerosakan pam empar dengan baik. Daripada 48 sensor yang diuji, 5 sensor telah dipilih sebagai set ciri input iaitu sensor_05, sensor_17, sensor_30, sensor_32 dan sensor_51. Hasil pemilihan ciri iaitu 5 sensor terpilih dari algoritma SBS selepas kejuruteraan ciri dilakukan dan menggunakan penalaan hiperparameter, didapati tiada *overfitting*.

berlaku pada set data latihan. Algoritma yang biasanya berlaku *overfitting* mempunyai ciri yang berlebihan diberi kepada input algoritma dan kerumitan algoritma memberi prestasi baik pada set data latihan namun memberi prestasi buruk bagi ramalan data (Khalaf Allamy and Khalaf Jabbar Rafiqul Zaman Khan 2015). Oleh itu, dapat disimpulkan dengan ciri yang tepat dan sedikit dapat memberikan prestasi algoritma ML yang baik dan tidak menjurus kepada *overfit*.

C. Hasil Pembahagian Data

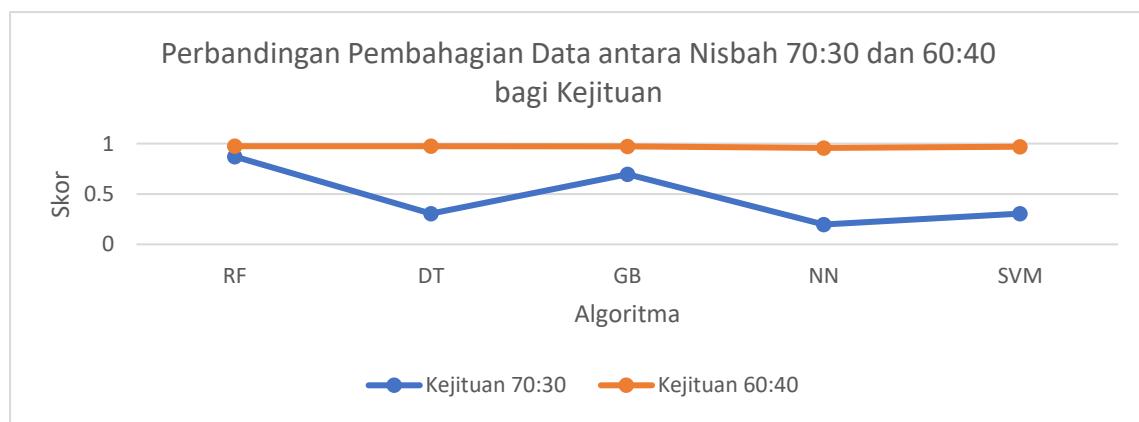
Pembahagian data untuk set latihan dan ujian dipilih bagi melakukan kajian ini adalah nisbah 60:40. Set data latihan akan mempunyai 60% untuk dilatih dan selebihnya 40% untuk diuji. Ia kerana apabila melakukan nisbah 70:30, keputusan tidak memuaskan diperoleh terutama bagi kejituhan dan dapatan semula bagi set data ujian. Kedua-dua metrik penilaian tersebut adalah sangat penting bagi kajian ini. Bagi kajian ini, prestasi algoritma yang sangat penting adalah dapatan semula diikuti dengan kejituhan. Berdasarkan pembahagian data dengan nisbah 70:30, nilai diperoleh kedua-dua metrik ini sangat tidak baik bagi meramal kerosakan pam empar. Ia penting kerana dapatan semula yang baik akan menyebabkan algoritma dapat meramal dengan tepat bila pam empar akan rosak. Manakala kejituhan tinggi akan mengurangkan ramalan salah apabila pam empar berada dalam keadaan normal. Dapatan semula adalah paling penting kerana memperoleh algoritma yang dapat meramal kerosakan yang tepat adalah diingini. Tujuan PdM juga adalah bagi meramal kerosakan sebelum ia berlaku.

Rajah 3 menunjukkan perbandingan prestasi dapatan semula yang sangat ketara apabila pembahagian data dengan nisbah 60:40 dilakukan. Dapatan semula pada algoritma NN, SVM dan RF menunjukkan peningkatan prestasi dengan jelas bagi nisbah 60:40 berbanding 70:30.



Rajah 3 Perbandingan prestasi algoritma dapatan semula bagi pembahagian data dengan nisbah 70:30 dan 60:40

Rajah 4 menunjukkan perbandingan prestasi kejituhan yang sangat ketara apabila pembahagian data dengan 60:40 dilakukan. Kejituhan pada algoritma NN, SVM, DT dan GB menunjukkan peningkatan prestasi dengan jelas bagi nisbah 60:40 berbanding 70:30.



Rajah 4 Perbandingan prestasi algoritma kejituhan bagi pembahagian data dengan nisbah 70:30 dan 60:40

D. Hasil Latihan Algoritma ML

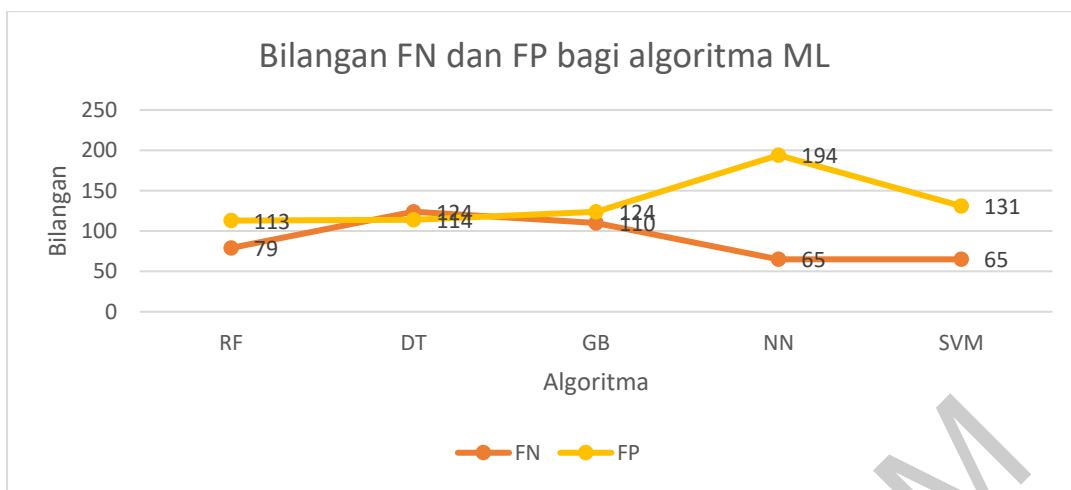
Algoritma dilatih bagi memperoleh nilai hiperparameter yang optimum. Ia bertujuan bagi meningkatkan prestasi ramalan algoritma dengan mengubahsuai parameter pada algoritma ML menggunakan julat nilai yang disiasat sewaktu melatih data (Raschka 2018). Mencari nilai optimum sepatutnya mendapatkan prestasi algoritma yang lebih baik berbanding nilai hiperparameter asal yang disetkan. Namun, hasil diperoleh dari melatih algoritma NN tidak meningkatkan prestasi dengan julat nilai yang disiasat berbanding algoritma RF, DT, GB dan SVM.

Nilai hiperparameter optimum terpilih selepas menggunakan penalaan hiperparameter akan digunakan pada algoritma RF, DT, GB dan SVM kerana prestasi algoritma yang lebih baik. Manakala algoritma NN masih menggunakan nilai hiperparameter optimum terpilih bagi *hidden_layer_sizes* = (100,) dan *alpha* = 0.0001 namun *activation* digunakan adalah *relu* bukannya *logistic*. Nilai hiperparameter optimum terpilih adalah sama dengan nilai asal hiperparameter bagi algoritma NN. Dalam kajian ini, hanya algoritma NN tidak akan menggunakan keputusan selepas penalaan hiperparameter dan akan menggunakan nilai asal hiperparameter disetkan pada algoritma. Oleh itu, penalaan hiperparameter secara keseluruhannya mampu memberi prestasi algoritma yang optimum untuk meramal kerosakan pam empar dan wajar dilakukan.

E. Perbandingan Prestasi Algoritma

Selepas keputusan eksperimen diperoleh, perbandingan prestasi algoritma dilakukan bagi memilih algoritma optimum. Algoritma optimum dipilih bagi meramal kerosakan pam empar berdasarkan keputusan matriks kekeliruan serta penilaian metrik. Daripada matriks kekeliruan diperoleh bagi kesemua algoritma, bilangan Negatif Palsu (FN) dan Positif Palsu (FP) akan dibincangkan. Bilangan FN yang kecil adalah lebih penting dari FP bagi kajian ini. Secara umum, bilangan TP dan TN sentiasa ingin dimaksimumkan manakala FN dan FP diminimumkan sebaiknya (Khorsheed and Beyca 2021). Bagi PdM, FN adalah paling kritikal di mana algoritma mesti meramal dengan tepat bila kerosakan akan berlaku untuk melakukan penyelenggaraan. Bilangan FN yang rendah akan mengurangkan kemungkinan algoritma salah meramal pam empar yang memerlukan penyelenggaraan. Dalam kajian ini, algoritma optimum yang akan dipilih mampu untuk meramal kerosakan 10 minit lebih awal bagi membuat penyelenggaraan sepatutnya. Selain itu, FP juga penting untuk memperoleh bilangan yang rendah. Ia untuk mengelakkan pembaziran pemberhentian mesin dan tenaga pekerja jika algoritma salah meramal keadaan yang baik sebagai rosak. Oleh itu, memperoleh bilangan rendah yang memuaskan antara FN dan FP akan menentukan pemilihan algoritma optimum.

Rajah 5 menunjukkan perbandingan bilangan FN dan FP bagi algoritma ML. FN bagi algoritma SVM, NN dan RF menunjukkan bilangan terendah iaitu 65 bagi SVM dan NN serta 79 bagi RF. Manakala algoritma DT dan GB menunjukkan bilangan tinggi iaitu 124 dan 110. FP bagi algoritma RF dan DT menunjukkan bilangan terendah dengan 113 dan 114. Algoritma GB dan SVM menunjukkan bilangan rendah sederhana iaitu 124 dan 131. Manakala algoritma NN menunjukkan bilangan tertinggi bagi FP iaitu 194. Walaupun algoritma NN memperoleh bilangan FN terendah, bilangan FP terlalu tinggi berbanding algoritma lain. Algoritma NN tidak akan dipilih sebagai algoritma optimum. Algoritma DT dan GB juga tidak optimum kerana memperoleh bilangan FN yang tinggi. Algoritma SVM memperoleh bilangan terendah bagi FN namun sederhana rendah bagi FP. Algoritma RF menunjukkan bilangan ketiga terendah bagi FN dan terendah bagi FP. Algoritma RF dan SVM mempunyai bilangan yang memuaskan bagi FN dan FP. Kedua-dua algoritma akan dipertimbangkan dengan lebih lanjut untuk dipilih sebagai algoritma optimum. Penilaian metrik akan dibincangkan untuk membandingkan algoritma.



Rajah 5 Perbandingan bilangan FN dan FP bagi algoritma ML

Jadual 3 menunjukkan perbandingan keputusan prestasi algoritma ML bagi set data ujian. Ketepatan algoritma RF dan SVM adalah sama iaitu 99.8% dan tertinggi berbanding yang lain. Kejituhan algoritma NN iaitu 0.957 adalah terendah dibandingkan algoritma lain yang mempunyai nilai melebihi 0.970. Algoritma RF dan DT mempunyai kejituuan tertinggi yang sama iaitu 0.974 diikuti dengan GB dan SVM dengan 0.972 dan 0.970 masing-masing. Dapatan semula bagi algoritma NN dan SVM adalah tertinggi iaitu 0.985. Dapatan semula bagi algoritma RF adalah ketiga tertinggi iaitu 0.982 diikuti dengan GB dan DT dengan 0.975 dan 0.972 masing-masing.

Dalam kajian ini, prestasi dapatan semula akan diutamakan diikuti kejituuan. Algoritma RF dan SVM memperoleh prestasi dapatan semula sangat baik serta kejituuan tertinggi bagi RF dan memuaskan bagi SVM. Walaupun dapatan semula bagi algoritma NN paling tinggi bersama SVM, kejituuan rendah diperoleh tidak menjadikan ia algoritma optimum untuk dipilih. Algoritma RF dan SVM akan dipertimbangkan untuk dipilih sebagai algoritma optimum. Skor F1 bagi algoritma RF dan SVM juga adalah tertinggi iaitu 0.978 berbanding algoritma lain. Metrik ini penting kerana ia mengambil kira ketidakseimbangan data dalam kajian. Lingkungan bawah ROC bagi algoritma RF dan SVM juga melebihi 0.990 menunjukkan kebolehan algoritma ini untuk meramal kerosakan dengan baik. Semakin dekat nilai ROC dengan 1, semakin bagus algoritma dapat membezakan pam empar adalah normal atau rosak.

Jadual 3 Perbandingan keputusan prestasi algoritma ML bagi set data ujian

Algoritma	Ketepatan	Kejituun	Dapatan Semula	Skor F1	Lingkungan bawah ROC
RF	99.8%	0.974	0.982	0.978	0.990
DT	99.7%	0.974	0.972	0.973	0.985
GB	99.7%	0.972	0.975	0.973	0.987
NN	99.7%	0.957	0.985	0.971	0.991
SVM	99.8%	0.970	0.985	0.978	0.992

Berdasarkan perbincangan prestasi matriks kekeliruan iaitu FN dan FP serta penilaian metrik dapatan semula dan kejituuan, algoritma RF dan SVM dipilih sebagai algoritma optimum untuk meramal kerosakan pam empar. FN berkait rapat dengan dapatan semula manakala FP berkait rapat dengan kejituuan. Untuk menilai prestasi algoritma dalam kajian PdM, fokus diutamakan adalah dapatan semula bagi mengurangkan FN berlaku sewaktu meramal kerosakan. Ini bagi mengelakkan pemberhentian pam empar dengan tiba-tiba akibat algoritma tidak dapat meramal kerosakan dengan tepat. Impak adalah lebih besar jika kerosakan tidak dapat diramal dengan tepat dibandingkan algoritma salah meramal mesin berada dalam keadaan baik. Sekurang-kurangnya, pemantauan pada komponen pam empar dapat dilakukan jika salah meramal pam empar sebagai rosak namun normal. Sebaliknya berlaku jika gagal

meramal kerosakan dengan tepat akan menyebabkan kerugian lebih besar dari segi kos penyelenggaraan dan menganggu aktiviti manusia.

F. Analisis Algoritma Ramalan Optimum

Algoritma ramalan yang optimum bagi kajian ini adalah RF dan SVM. Analisis terhadap kajian terdahulu berbanding kajian ini akan dilakukan untuk menyokong mengapa kedua-dua algoritma ini dipilih. Berdasarkan kajian PdM terdahulu, algoritma ML seperti RF sering diguna sebanyak 33%, NN sebanyak 27%, SVM sebanyak 25% dan k-Min sebanyak 13% (Cardoso and Ferreira 2021; Vallim Filho et al. 2022). Berdasarkan kepada penggunaan terdahulu, peratus bagi algoritma RF dan SVM menyokong bahawa kedua-duanya adalah algoritma yang optimum adalah bertepatan. Manakala bagi algoritma NN, ia juga sering diguna bagi PdM. Namun, keputusan eksperimen diperoleh bagi kajian ini iaitu hasil dari prestasi algoritma tidak dapat mempertimbangkannya sebagai algoritma optimum. Algoritma NN boleh dilakukan penalaan terhadap hiperparameter lain supaya memperoleh prestasi lebih baik untuk kajian masa hadapan. Ini kerana algoritma NN mampu untuk meramal kerosakan kerana dapatan semula yang tinggi diperoleh dari keputusan eksperimen.

Algoritma pokok seperti RF, DT dan GB turut dibandingkan di dalam kajian ini. Kelebihan algoritma berasaskan pokok adalah ramalannya mudah ditafsir dan mampu menyediakan set peraturan (Calabrese et al. 2020). Dengan mengetahui peraturan dan cara meramal kerosakan akan memberi lebih banyak maklumat untuk mendiagnosis kesalahan mesin (*sault diagnosis*) bagi kaedah PdM. Secara keseluruhannya, algoritma RF, DT dan GB memberi prestasi baik pada set data ujian. Namun, algoritma RF didapati memperoleh dapatan semula yang lebih tinggi berbanding dua algoritma pokok yang digunakan bagi keputusan eksperimen dari kajian ini. Justeru, algoritma RF dipilih sebagai paling optimum antara algoritma berasaskan pokok ini.

Selain itu, keputusan eksperimen bagi kajian terdahulu akan dibandingkan dengan kajian ini. Ramalan kerosakan menggunakan kaedah PdM dibincangkan untuk menganalisis pemilihan algoritma optimum. Kajian terdahulu menggunakan algoritma KNN, DT, RF, NB dan NN bagi meramal kerosakan pada 4 komponen dari mesin industri (Cardoso and Ferreira 2021). Algoritma RF juga dinyatakan dalam kajian terdahulu dipilih sebagai terbaik bersama NN berbanding algoritma lain yang diuji. Jadual 4 menunjukkan perbandingan keputusan eksperimen bagi kajian terdahulu (Cardoso and Ferreira 2021) dan kajian ini.

Keputusan terbaik diperoleh oleh algoritma RF dengan hiperparameter $n_estimators = 70$ dan NN dengan hiperparameter $hidden_layer_sizes = (100,)$. Algoritma NN mempunyai prestasi dapatan semula lebih tinggi daripada RF bagi keempat-empat komponen. Manakala kejituuan algoritma RF mempunyai prestasi lebih tinggi yang ketara pada komponen 1 berbanding NN. Skor F1 bagi algoritma NN adalah lebih baik daripada RF dari keputusan kajian terdahulu. Ini bermakna algoritma NN mampu meramal kerosakan dengan baik bagi kajian PdM. Namun keputusan diperoleh algoritma dalam kajian ini memperoleh keputusan tidak memuaskan pada kejituuan NN iaitu 0.957 berbanding RF iaitu 0.974. Maka, algoritma NN tidak dipilih menjadi algoritma optimum walaupun memperoleh dapatan semula lebih tinggi berbanding RF. Ia kerana selain mendapatkan keutamaan dapatan semula yang tinggi, kejituuan juga harus diambil kira. Ini menunjukkan algoritma RF meramal kerosakan dengan baik pada komponen mesin berdasarkan data sensor diberi. Oleh itu, ini menyokong salah satu pemilihan algoritma optimum terpilih bagi kajian ini iaitu RF.

Jadual 4 Perbandingan keputusan eksperimen bagi kajian terdahulu (Cardoso and Ferreira 2021) dan kajian ini

Algoritma		Kejituuan			
Kajian		Terdahulu			Ini
Komponen	1	2	3	4	Pam Empar
RF	0.9718	0.9711	0.9855	0.9830	0.974
NN	0.9030	0.9941	0.9858	0.9725	0.957

Algoritma		Dapatkan Semula			
		Terdahulu		Ini	
Kajian		1	2	3	4
Komponen	1	0.8150	0.9882	0.9189	0.9611
RF		0.8865	0.9796	0.9510	0.9719
NN		0.8425	0.9853	0.9392	0.9833
					0.985

Algoritma		Skor F1			
		Terdahulu		Ini	
Kajian		1	2	3	4
Komponen	1	0.8717	0.9897	0.9619	0.9779
RF		0.8865	0.9796	0.9510	0.9719
NN		0.8425	0.9853	0.9392	0.9833
					0.971

Seterusnya, kajian terdahulu melibatkan kaedah PdM terhadap sistem pengepaman dianalisis bagi membincangkan keputusan eksperimen yang diperoleh. Algoritma digunakan untuk meramal kerosakan pada sistem pengepaman adalah RF, GB, NN dan KNN (Velimirović et al. 2021). Algoritma RF, GB dan NN akan dibincangkan keputusannya manakala KNN tidak dibincangkan kerana tidak digunakan dalam kajian ini. Jadual 5 menunjukkan perbandingan keputusan eksperimen bagi kajian terdahulu (Velimirović et al. 2021) dan kajian ini.

Secara keseluruhannya, algoritma GB dan RF dinyatakan mempunyai prestasi algoritma terbaik bagi kajian terdahulu. Dapatkan semula dan kejituhan algoritma RF dan GB adalah lebih tinggi berbanding NN. Algoritma NN menunjukkan keputusan lebih rendah berbanding RF dan GB bagi kajian terdahulu dan ini. Ini kerana algoritma NN tidak menunjukkan keputusan memuaskan terutama pada kejituhan. Algoritma NN tidak dipilih sebagai algoritma optimum bagi kedua-dua kajian. Algoritma RF bagi kajian mampu meramal kerosakan pada sistem pengepaman dengan tepat hasil dari keputusan kedua-dua kajian. Lingkungan bawah ROC juga baik bagi algoritma RF dan GB menunjukkan ramalan data dibezakan dengan baik antara keadaan rosak dan tidak rosak manakala terendah bagi NN bagi kedua-dua kajian. Justeru, algoritma RF dibuktikan mampu meramal kerosakan dengan baik pada kedua-dua kajian.

Jadual 5 Perbandingan keputusan eksperimen bagi kajian terdahulu (Velimirović et al. 2021) dan kajian ini

Algoritma	Ketepatan		Kejituhan		Dapatkan Semula	
	Terdahulu	Ini	Terdahulu	Ini	Terdahulu	Ini
Kajian						
RF	91.0%	99.8%	0.650	0.974	0.850	0.982
GB	92.0%	99.7%	0.660	0.972	0.870	0.975
NN	87.0%	99.7%	0.590	0.957	0.790	0.985

Algoritma	Skor F1		Lingkungan bawah ROC	
	Terdahulu	Ini	Terdahulu	Ini
Kajian				
RF	0.690	0.978	0.850	0.990
GB	0.710	0.973	0.869	0.987
NN	0.610	0.971	0.793	0.991

Jadual 6 menunjukkan perbandingan keputusan eksperimen bagi kajian terdahulu (Khorsheed and Beyca 2021) dan kajian ini. Algoritma ML digunakan adalah DT, GB, RF dan SVM untuk meramal kerosakan sistem pengepaman (Khorsheed and Beyca 2021). Algoritma GB mempunyai prestasi terbaik diikuti RF, SVM dan DT. Algoritma RF dan GB menunjukkan kejituhan tinggi dengan nilai melebihi 0.900 berbanding SVM dan DT pada kajian terdahulu. Manakala dapatan semula algoritma GB tertinggi diikuti RF hampir melebihi 0.800 bagi kajian terdahulu dan SVM tertinggi diikuti RF melebihi 0.900 dari kajian ini. Ini menunjukkan algoritma RF mempunyai keupayaan meramal kerosakan dengan baik

hasil dari kedua-dua kajian. Algoritma SVM tidak memperoleh keputusan terbaik bagi dapatan semula kajian terdahulu namun prestasinya sangat baik untuk meramal kerosakan pam empar dalam kajian ini. Algoritma DT mempunyai prestasi terendah bagi kajian terdahulu dan mempunyai persamaan dengan kajian ini di mana mempunyai dapatan semula terendah berbanding algoritma lain. Ia menunjukkan algoritma DT tidak dapat meramal kerosakan dengan tepat lalu tidak dipilih sebagai algoritma optimum bagi kedua-dua kajian.

Skor F1 menunjukkan prestasi baik bagi algoritma RF dan GB dari kajian terdahulu dan tertinggi bagi RF dan SVM bagi kajian ini. Lingkungan bawah ROC untuk algoritma RF dan GB bagi kajian terdahulu dan RF dan SVM bagi kajian ini melebihi 0.900 iaitu menghampiri 1.000 menandakan kerosakan diramal dengan sangat baik. Walaupun SVM mempunyai prestasi rendah dari RF dan GB dalam kajian terdahulu, lingkungan bawah ROC diperoleh melebihi 0.800. Ini bermakna algoritma SVM boleh meramal kelas rosak dan tidak rosak dengan baik. Algoritma RF dan GB dinyatakan mempamerkan keseluruhan prestasi terbaik pada kajian terdahulu kerana keputusan yang hampir sama dan tertinggi berbanding yang lain. Namun, kajian ini memperlihatkan algoritma GB tidak menunjukkan prestasi optimum untuk dipilih. Algoritma RF dan SVM lebih bersesuaian dipilih bagi algoritma optimum bagi data kajian ini dan ia dapat disokong dengan keputusan dari kajian terdahulu mengikut turutan prestasi algoritma serta lingkungan bawah ROC iaitu 0.885.

Jadual 6 Perbandingan keputusan eksperimen bagi kajian terdahulu (*Khorsheed and Beyca 2021*) dan kajian ini

Algoritma	Ketepatan		Kejituhan		Dapatkan Semula	
	Kajian	Terdahulu	Ini	Terdahulu	Ini	Terdahulu
RF	87.6%	99.8%	0.906	0.974	0.799	0.982
DT	82.9%	99.7%	0.847	0.974	0.721	0.972
GB	92.3%	99.7%	0.926	0.972	0.895	0.975
SVM	82.2%	99.8%	0.824	0.970	0.758	0.985

Algoritma	Skor F1		Lingkungan bawah ROC		
	Kajian	Terdahulu	Ini	Terdahulu	Ini
RF	0.847	0.978	0.912	0.990	
DT	0.775	0.973	0.745	0.985	
GB	0.909	0.973	0.928	0.987	
SVM	0.785	0.978	0.885	0.992	

Kajian terdahulu melibatkan kaedah PdM terhadap pam empar dalam industri minyak dan gas dianalisis bagi membincangkan keputusan eksperimen diperoleh. Algoritma digunakan adalah NN dan SVM untuk meramal kerosakan pam empar (Orrù et al. 2020). Jadual 7 menunjukkan perbandingan keputusan eksperimen bagi kajian terdahulu (Orrù et al. 2020) dan kajian ini. Algoritma NN mempunyai keputusan keseluruhan terbaik bagi kajian terdahulu manakala sebaliknya bagi kajian ini. Kejituhan menunjukkan NN memperoleh prestasi lebih baik berbanding SVM pada kajian terdahulu dan sebaliknya bagi kajian ini. Dapatkan semula pada kajian terdahulu menunjukkan NN memperoleh prestasi lebih tinggi dari SVM. Namun nilai dapatan semula pada kajian terdahulu tidak memuaskan dan prestasinya lebih rendah berbanding dengan kajian ini.

Hasil dari langkah eksperimen dilakukan dalam kajian ini menunjukkan prestasi dapatan semula lebih tinggi. Ia menandakan kemampuan algoritma meramal kerosakan dengan lebih tepat berbanding kajian terdahulu walaupun kedua-dua kajian terdapat ketidakseimbangan data. Skor F1 bagi kajian ini tidak menunjukkan perbezaan ketara antara algoritma NN dan SVM manakala sebaliknya bagi kajian terdahulu. Kajian terdahulu menyatakan kedua-dua algoritma dicadangkan memberikan prestasi ramalan yang baik dan MLP memperoleh keputusan meramal dengan tepat berbanding SVM. Kajian ini menunjukkan keputusan SVM lebih baik berbanding NN dan penggunaan setiap langkah eksperimen memberikan prestasi algoritma lebih baik. Oleh itu, algoritma SVM bersesuaian dipilih

sebagai algoritma optimum kerana ia juga dicadangkan untuk diguna bagi meramal kerosakan pam empar pada kajian terdahulu.

Jadual 7 Perbandingan keputusan eksperimen bagi kajian terdahulu (*Orrù Et Al. 2020*) dan kajian ini

Algoritma	Ketepatan		Kejituhan		Dapatkan Semula	
Kajian	Terdahulu	Ini	Terdahulu	Ini	Terdahulu	Ini
NN	98.2%	99.7%	0.668	0.957	0.422	0.985
SVM	98.1%	99.8%	0.711	0.970	0.277	0.985

Algoritma	Skor F1	
Kajian	Terdahulu	Ini
NN	0.516	0.971
SVM	0.399	0.978

Akhir sekali, kajian terdahulu melibatkan kaedah PdM menggunakan data sama seperti kajian ini dianalisis bagi membincangkan keputusan eksperimen diperoleh. Algoritma ML digunakan adalah SVM, Regresi Logistik dan KNN (Chidhananda and Kulkarni 2020). Hanya algoritma SVM dibincangkan untuk perbandingan dengan kajian ini. Jadual 8 menunjukkan perbandingan prestasi algoritma SVM antara kajian terdahulu (Chidhananda and Kulkarni 2020) dan kajian ini. Prestasi yang dibandingkan adalah ketepatan algoritma SVM dengan bilangan sensor terpilih untuk meramal kerosakan pam empar.

51 sensor dan 22 sensor adalah diperoleh dari kaedah penapis dari kajian terdahulu dan kejuruteraan ciri tidak dilakukan. Manakala 5 sensor diperoleh dari kajian ini melibatkan pemilihan ciri menggunakan kaedah pembungkus dan kejuruteraan ciri dilakukan. Prestasi kajian ini menunjukkan peningkatan prestasi ketepatan daripada kajian terdahulu. Menggunakan setiap langkah eksperimen pada kajian ini dapat meramal kerosakan 10 minit lebih awal dengan baik. Hasil pemilihan ciri menggunakan kaedah pembungkus memberikan ketepatan lebih baik membuktikan ciri terpilih tepat untuk meramal kerosakan. Dengan pemilihan 5 sensor, prestasi SVM dapat ditingkatkan. Justeru, proses eksperimen dijalankan dalam kajian ini memperoleh prestasi ketepatan lebih baik untuk algoritma SVM.

Jadual 8 Perbandingan prestasi algoritma SVM antara kajian terdahulu (*Chidhananda And Kulkarni 2020*) dan kajian ini

Algoritma	Ketepatan		
Kajian	Terdahulu	Ini	
Pemilihan Ciri	51 sensor	22 sensor	5 sensor
SVM	96.47%	99.23%	99.80%

Hasil dari analisis ramalan optimum menunjukkan algoritma RF sering mendapat keputusan terbaik dalam meramal kerosakan bagi kajian terdahulu. Algoritma SVM juga memperoleh keputusan memuaskan walaupun bukan terpilih sebagai paling optimum dalam kajian terdahulu dan memberi keputusan baik bagi metrik lingkungan di bawah ROC. Algoritma SVM juga menunjukkan keputusan yang lebih baik berbanding kajian terdahulu apabila menggunakan langkah eksperimen dalam kajian ini. Berdasarkan analisis, algoritma RF dan SVM dipilih sebagai algoritma yang optimum bagi meramal kerosakan lebih awal pada pam empar untuk melakukan penyelenggaraan bagi kajian ini.

V. CADANGAN DAN RUMUSAN

Kajian ini secara keseluruhan berjaya menjawab objektif kajian iaitu menggunakan kejuruteraan ciri dengan mencipta ciri lengah dengan tetingkap gelongsor 10 minit untuk meramal kerosakan pam empar dengan lebih awal. Selain itu, dapat mengenal pasti 5 sensor daripada data pam empar yang

mempengaruhi prestasi algoritma. Akhir sekali, pemilihan algoritma RF dan SVM dipilih sebagai yang optimum hasil perbandingan prestasi algoritma ML untuk meramal kerosakan pam empar.

Data pam empar diperoleh adalah mewakili keadaan sebenar sistem pengepaman. Butiran teknikal sensor tidak diperoleh. Untuk kajian masa depan, dicadangkan untuk mengkaji dengan lebih jelas mengenai jenis sensor diperoleh. Terdapat 52 sensor dari data dan mengetahui jenisnya akan bermanfaat untuk memilih sensor khusus bagi melakukan kajian. Langkah eksperimen dari kajian ini boleh dijadikan rujukan setelah pemilihan sensor khusus yang hendak dikaji. Daripada data yang diproses oleh ML, punca kerosakan pam empar juga boleh diketahui dengan lebih jelas apabila mengetahui jenis sensor. Justeru, penggantian komponen boleh diganti dengan cepat sebelum berlaku kerosakan yang lebih teruk.

Selain itu, cadangan bagi kajian masa depan adalah melakukan perbandingan tetingkap gelongsor dengan ciri lengah untuk meramal kerosakan dengan lebih awal. Masa tetingkap gelongsor yang lain boleh dipilih untuk melihat prestasi algoritma ML apabila corak data lari jauh dari keadaan asal. Ia bergantung juga pada mesin industri digunakan. Kejuruteraan ciri digunakan dalam kajian ini boleh dijadikan panduan untuk meramal kerosakan dalam tempoh tetingkap gelongsor bersesuaian bagi keperluan industri.

Seterusnya, penilaian risiko pam empar dicadangkan supaya penyelenggaraan bersesuaian dilakukan berdasarkan nilai kemungkinan. Ini untuk mengelakkan penyelenggaraan yang tidak perlu dilakukan jika mesin masih berada dalam keadaan baik namun diramal sebagai rosak. Kajian ini terhad kepada meramal sama ada pam empar berada dalam keadaan normal atau rosak sahaja. Akhir sekali, kajian masa depan boleh mencuba pelbagai hiperparameter lain untuk ditala bagi mendapatkan prestasi algoritma ML yang lebih baik terutama bagi algoritma NN. Algoritma NN merupakan salah satu algoritma kerap digunakan untuk PdM namun ia tidak memperoleh prestasi memuaskan bagi kajian ini.

PENGHARGAAN

Penulis ingin mengucapkan ribuan terima kasih kepada Fakulti Teknologi dan Sains Maklumat, Universiti Kebangsaan Malaysia atas peluang untuk menjalankan kajian ini.

RUJUKAN

Abelin SM, Iseppon A, Water Steve Kratzke Ross Mackay PC, et al (2006) Improving Pumping System Performance A Sourcebook for Industry Improving Pumping System Performance A Sourcebook for Industry

Ayvaz S, Alpay K (2021) Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time. Expert Syst Appl 173:.
<https://doi.org/10.1016/j.eswa.2021.114598>

Bekar ET, Nyqvist P, Skoogh A (2020) An intelligent approach for data pre-processing and analysis in predictive maintenance with an industrial case study. Advances in Mechanical Engineering 12:.
<https://doi.org/10.1177/1687814020919207>

Bukhsh ZA, Stipanovic I (2020) Predictive Maintenance for Infrastructure Asset Management. IT Prof 22:40–45. <https://doi.org/10.1109/MITP2020.2975736>

- Calabrese M, Cimmino M, Fiume F, et al (2020) SOPHIA: An event-based IoT and machine learning architecture for predictive maintenance in industry 4.0. *Information* (Switzerland) 11:. <https://doi.org/10.3390/INFO11040202>
- Cardoso D, Ferreira L (2021) Application of predictive maintenance concepts using artificial intelligence tools. *Applied Sciences* (Switzerland) 11:1–18. <https://doi.org/10.3390/app11010018>
- Carvalho TP, Soares FAAMN, Vita R, et al (2019) A systematic literature review of machine learning methods applied to predictive maintenance. *Comput Ind Eng* 137:. <https://doi.org/10.1016/j.cie.2019.106024>
- Chidhananda RS, Kulkarni A (2020) Application of automation strategies to prevent failure in mechatronic water plant system. In: *Materials Today: Proceedings*. Elsevier Ltd, pp 1480–1485
- Fan CL (2022) Evaluation of Classification for Project Features with Machine Learning Algorithms. *Symmetry* (Basel) 14:. <https://doi.org/10.3390/sym14020372>
- Gaurkar S, Kotalwar A, Gabale S (2021) Predictive Maintenance of Industrial Machines using Machine Learning. *International Research Journal of Engineering and Technology*
- Hsu JY, Wang YF, Lin KC, et al (2020) Wind turbine fault diagnosis and predictive maintenance through statistical process control and machine learning. *IEEE Access* 8:23427–23439. <https://doi.org/10.1109/ACCESS.2020.2968615>
- Hu Q, Ohata EF, Silva FHS, et al (2020) A new online approach for classification of pumps vibration patterns based on intelligent IoT system. *Measurement* (Lond) 151:. <https://doi.org/10.1016/j.measurement.2019.107138>
- Khalaf Allamy H, Khalaf Jabbar Rafiqul Zaman Khan HD (2015) METHODS TO AVOID OVER-FITTING AND UNDER-FITTING IN SUPERVISED MACHINE LEARNING (COMPARATIVE STUDY)
- Khorsheed RM, Beyca OF (2021) An integrated machine learning: Utility theory framework for real-time predictive maintenance in pumping systems. *Proc Inst Mech Eng B J Eng Manuf* 235:887–901. <https://doi.org/10.1177/0954405420970517>
- Muraina IO (2022) IDEAL DATASET SPLITTING RATIOS IN MACHINE LEARNING ALGORITHMS: GENERAL CONCERNS FOR DATA SCIENTISTS AND DATA ANALYSTS
- Nagdev Amruthnath, Tarun Gupta (2018) A Research Study on Unsupervised Machine Learning Algorithms for Early Fault Detection in Predictive Maintenance. pp 1–7
- Nugroho A, Fanani AZ, Shidik GF (2021) Evaluation of Feature Selection Using Wrapper for Numeric Dataset with Random Forest Algorithm. In: *Proceedings - 2021 International Seminar on Application for Technology of Information and Communication: IT Opportunities and Creativities for Digital Innovation and Communication within Global Pandemic*, iSemantic 2021. Institute of Electrical and Electronics Engineers Inc., pp 179–183
- Olesen JF, Shaker HR (2020) Predictive maintenance for pump systems and thermal power plants: State-of-the-art review, trends and challenges. *Sensors* (Switzerland) 20
- Orrù PF, Zoccheddu A, Sassu L, et al (2020) Machine learning approach using MLP and SVM algorithms for the fault prediction of a centrifugal pump in the oil and gas industry. *Sustainability* (Switzerland) 12:. <https://doi.org/10.3390/su12114776>
- Raschka S (2018) Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning

Stetco A, Dinmohammadi F, Zhao X, et al (2019) Machine learning methods for wind turbine condition monitoring: A review. *Renew Energy* 133:620–635

Vallim Filho AR de A, Farina Moraes D, Bhering de Aguiar Vallim MV, et al (2022) A Machine Learning Modeling Framework for Predictive Maintenance Based on Equipment Load Cycle: An Application in a Real World Case. *Energies (Basel)* 15:. <https://doi.org/10.3390/en15103724>

Velimirović LZ, Janković R, Velimirović JD, Janjić A (2021) Wastewater plant reliability prediction using the machine learning classification algorithms. *Symmetry (Basel)* 13:. <https://doi.org/10.3390/sym13081518>

Werth Jan (2021) LSTM for Predictive Maintenance on Pump Sensor Data. In: *Towards Data Science*. <https://towardsdatascience.com/lstm-for-predictive-maintenance-on-pump-sensor-data-b43486eb3210>. Accessed 20 Dec 2022

Žagar D, Institute of Electrical and Electronics Engineers. Region 8, Institute of Electrical and Electronics Engineers. Croatia Section, et al Proceedings of 2020 International Conference on Smart Systems and Technologies (SST) : Faculty of Electrical Engineering, Computer Science and Information Technology Osijek, Josip Juraj Strossmayer University of Osijek, Osijek, Croatia, October 14-16, 2020

Zhang W, Yang D, Wang H (2019) Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey. *IEEE Syst J* 13:2213–2227. <https://doi.org/10.1109/JSYST.2019.2905565>