

**PEMBANGUNAN MODEL RAMALAN HARGA
MATA WANG**

NURUL ATIQAH BINTI ROHAIZAR

UNIVERSITI KEBANGSAAN MALAYSIA

PEMBANGUNAN MODEL RAMALAN MATA WANG

NURUL ATIQAH BINTI ROHAIZAR

**PROJEK YANG DIKEMUKAKAN UNTUK MEMENUHI SEBAHAGIAN
DARIPADA SYARAT MEMPEROLEH IJAZAH SARJANA SAINS DATA**

**FAKULTI TEKNOLOGI DAN SAINS MAKLUMAT
UNIVERSITI KEBANGSAAN MALAYSIA
BANGI**

2024

PENGAKUAN

Saya akui karya ini adalah hasil kerja saya sendiri kecuali nukilan dan ringkasan yang tiap-tiap satunya telah saya jelaskan sumbernya.

15 Julai 2024

NURUL ATIQAH BINTI ROHAIZAR
P117806

PENGHARGAAN

Alhamdulillah syukur ke hadrat Illahi kerana saya dapat menyiapkan kajian projek akhir ini. Pertama sekali saya ingin mengucapkan penghargaan jutaan terima kasih kepada penyelia saya, Dr Ahmad Tarmizi di atas bimbingan dan tunjuk ajar sehingga terhasilnya kajian ini. Segala nasihat dan dorongan yang diberikan sepanjang penyeliaan adalah sangat bermakna buat saya. Tidak lupa juga ucapan terima kasih kepada semua tenaga pengajar terlibat bagi Program Master Sains Data di Fakulti Teknologi Dan Sains Maklumat, Universiti Kebangsaan Malaysia.

Saya ingin mengucapkan terima kasih kepada pihak penaja biasiswa kerajaan iaitu Kemeterian Pengajian Tinggi yang memberi kepercayaan membiayai pengajian penuh dalam bidang ini.

Terima kasih dan penghargaan kedua-dua ibu ayah dan seluruh ahli keluarga yang sentiasa memberi dorongan, sokongan dan doa yang berterusan sepanjang pengajian dalam bidang sains data ini. Tidak lupa juga kepada rakan-rakan seperjuangan yang sama-sama sedia memberi bantuan dan berkongsi idea dalam menyiapkan kajian ini.

Terima kasih

ABSTRAK

Kajian ini bertujuan untuk membangunkan model ramalan kadar pertukaran mata wang yang berkesan menggunakan beberapa teknik pembelajaran mesin, termasuk Regresi Linear (LR), Regresi Vektor Sokongan (SVR), Regresi Penggalakan Kecerunan (GBR), Hutan Rawak (RF), dan XGBoost Regressor. Objektif kajian ini adalah untuk mengenal pasti algoritma terbaik untuk ramalan mata wang, membangunkan model ramalan mata wang yang berkesan, dan membangunkan aplikasi untuk ramalan mata wang. Pengenalan menekankan kepentingan ramalan kadar pertukaran yang tepat disebabkan oleh ketidakstabilan ekonomi. Kajian kesusasteraan membincangkan faktor-faktor yang mempengaruhi kadar pertukaran dan meninjau kajian-kajian terdahulu yang menggunakan teknik pembelajaran mesin, menunjukkan potensinya untuk meningkatkan ketepatan ramalan. Metodologi kajian menerangkan reka bentuk penyelidikan, pengumpulan data, teknik pra-pemprosesan, dan pembangunan aplikasi web menggunakan Flask untuk ramalan masa nyata dan nasihat beli/jual. Keputusan kajian mengenal pasti RF dan XGBoost sebagai model yang paling berkesan, dengan nilai R^2 yang tinggi dan Ralat Kuasa Dua Min (MSE) yang rendah, dan RF dipilih sebagai model utama. Kesimpulan menekankan sumbangan kajian dalam ramalan kadar pertukaran, menyatakan keberkesanannya pembelajaran mesin dan kekangan yang dihadapi, seperti ketersediaan data dan keterbatasan pengiraan. Cadangan untuk kajian masa depan termasuk menggunakan data yang lebih komprehensif, bereksperimen dengan algoritma tambahan, dan mengintegrasikan faktor ekonomi makro untuk meningkatkan ketepatan dan kekuahan ramalan.

EXCHANGE RATE PREDICTION USING MACHINE LEARNING TECHNIQUES

ABSTRACT

This study aims to develop an effective exchange rate prediction model using several machine learning techniques, including Linear Regression (LR), Support Vector Regression (SVR), Gradient Boosting Regression (GBR), Random Forest (RF), and XGBoost Regressor. The objectives of this study are to identify the best algorithm for currency prediction, develop an effective currency prediction model, and develop an application for currency forecasting. The introduction highlights the importance of accurate exchange rate predictions due to economic volatility. The literature review discusses factors influencing exchange rates and reviews previous studies using machine learning techniques, demonstrating their potential to improve prediction accuracy. The methodology describes the research design, data collection, preprocessing techniques, and the development of a web application using Flask for real-time predictions and buy/sell advice. The results identify RF and XGBoost as the most effective models, with high R^2 values and low Mean Squared Error (MSE), and RF is chosen as the primary model. The conclusion emphasizes the study's contributions to exchange rate prediction, highlighting the effectiveness of machine learning and the limitations faced, such as data availability and computational constraints. Recommendations for future research include using more comprehensive data, experimenting with additional algorithms, and integrating macroeconomic factors to enhance prediction accuracy and robustness.

KANDUNGAN

PENGAKUAN	ii
PENGHARGAAN	iii
ABSTRAK	iv
ABSTRACT	v
KANDUNGAN	vi
SENARAI JADUAL	viii
SENARAI ILUSTRASI	ix
	x

BAB I	PENDAHULUAN	
1.1	Pengenalan	1
1.2	Latar Belakang Kajian	1
1.3	Penyataan Masalah	2
1.4	Objektif Kajian	3
1.5	Persoalan Kajian	4
1.6	Skop Kajian	4
1.7	Kepentingan Kajian	4
1.8	Organisasi Tesis	5
BAB II	KAJIAN KESUSASTERAAN	
2.1	Pengenalan	7
2.2	Faktor Yang Mempengaruhi Kadar Mata Wang	8
2.3	Teknik Meramal Mata Wang	9
2.4	Kajian Lepas	10
	2.4.1 Ulasan Terperinci Kajian Lepas	14
2.5	Metrik PRESTASI	26
2.6	Pembelajaran Mesin (Algorithm)	29
	2.6.1 Algorithma Regresi Linear (RL)	29
	2.6.2 Algorithma Regresi Hutan Rawak (RF)	30
	2.6.3 Algorithma Regresi Vektor Sokongan (SVR)	31
	2.6.4 Algorithma Regresi Penggalakan Kecerunan (GBR)	32
	2.6.5 Algorithma Regresi XGBoost (XGB)	33
2.7	Kesimpulan	35

BAB III	METODOLOGI KAJIAN	
3.1	Pengenalan	36
3.2	Senarai Perisian Yang Digunakan Dalam Kajian	36
3.3	Kerangka Metodologi Kajian	37
3.4	Penerangan Data	40
3.5	Pembangunan Antaramuka Pengguna	43
3.6	Kesimpulan	45
BAB IV	DAPATAN KAJIAN	
4.1	Pengenalan	46
4.2	Keputusan Dapatan Ujian Pengagihan Data	46
	4.2.1 Model SVR	46
	4.2.2 Model GBR	47
	4.2.3 Model Hutan Rawak	47
	4.2.4 Model Regresi Linear	48
	4.2.5 Model XGB	48
4.3	Penghasilan Model Ramalan Mata Wang	49
4.4	Pembangunan Aplikasi Mata Wang	51
4.5	Kesimpulan	56
BAB V	RUMUSAN DAN CADANGAN	
5.1	Pengenalan	57
5.2	Rumusan Keseluruhan Kajian	57
5.3	Rumusan Objektif Kajian	58
5.4	Kekangan Kajian	59
5.5	Cadangan Perluasan Kajian	60
RUJUKAN		62

SENARAI JADUAL

No. Jadual		Halaman
Jadual 2.1	Ringkasan Kajian Lepas	11
Jadual 2.2	Keputusan Kajian USD / PKR	17
Jadual 3.1	Penerangan Atribut Data	40
Jadual 3.2	Penerangan Atribut Tambahan	42
Jadual 4.1	Hasil Keputusan SVR	47
Jadual 4.2	Hasil Keputusan GBR	47
Jadual 4.3	Hasil Keputusan RF	48
Jadual 4.4	Hasil Keputusan LR	48
Jadual 4.5	Hasil Keputusan XGB	49

SENARAI ILUSTRASI

No. Rajah		Halaman
Rajah 3.1	Carta Aliran Metodologi	38
Rajah 4.1	Harga sebenar dan ramalan mata wang	50
Rajah 4.2	Log Masuk	51
Rajah 4.3	Bahasa Melayu	52
Rajah 4.4	English	52
Rajah 4.5	Papan Pemuka Admin	52
Rajah 4.6	Papan Pemuka Pengguna	52
Rajah 4.7	Papan Pemuka Kemas Kini Kadar Semasa	53
Rajah 4.8	Papan Pemuka Pemilihan Julat Data	53
Rajah 4.9	Kadar Pertukaran USD / MYR	54
Rajah 4.10	Kadar Pertukaran EUR / MYR	55

BAB I

PENDAHULUAN

1.1 PENGENALAN

Bab ini menjelaskan secara umum keseluruhan kajian merangkumi latar belakang kajian, penyataan masalah, objektif kajian, skop kajian, metodologi kajian, ringkasan sumbangan kajian dan diakhiri dengan struktur kandungan bagi tesis ini.

1.2 LATAR BELAKANG KAJIAN

Setiap negara mempunyai mata wang berbeza dan mata wang ini merujuk kepada duit rasmi negara tersebut. Nilai mata wang setiap negara itu berbeza mengikut kadar tukaran dan keadaan ekonomi negara tersebut. Hal ini kerana, ada mata wang tidak boleh digunakan untuk urusan pelaburan atau perdagangan. Kebanyakan negara yang mempunyai kes seperti ini mereka akan bergantung pada mata wang USD untuk urusan pelaburan atau perdagangan. Sebagai contoh negara Sudan mereka menggunakan USD sebagai urusan pembayaran untuk urusan-urusan luar. Mata wang mereka hanya boleh digunakan didalam negara mereka dan akibat peperangan juga menjadi salah satu punca mata wang negara itu tidak lagi dapat digunakan secara meluas.

Seterusnya, Ringgit Malaysia (RM) telah menjadi mata wang rasmi negara sejak 1967 tetapi sebenarnya telah menjadi mata wang negara sejak zaman negara dijajah lagi. Malaysia juga bergantung pada USD untuk urusan pelaburan dan perdagangan untuk merancak ekonomi negara. Bermula tahun 2023 negara telah berunding dengan beberapa buah negara seperti Indonesia , Thailand dan China untuk menjadi RM sebagai mata wang bagi urusan perdagangan import dan eksport

barang. Dengan adanya rundingan ini sedikit sebanyak akan mengurangkan kebergantungan kepada mata wang USD yang semakin hari semakin merundum.

Seterusnya, Bank Negara Malaysia berfungsi sebagai mengekalkan kuasa beli ringgit dengan kadar inflasi yang rendah dan stabil. Bank juga bertanggungjawab untuk membawa kepada kestabilan sistem kewangan dan menggalakkan sektor kewangan yang sihat dan progresif. Terdapat sektor kewangan yang pelbagai, komprehensif dan tahan lama, yang mampu memenuhi keperluan yang semakin canggih konsumen dan perniagaan, dan yang telah menjadi penggerak pertumbuhan dalam ekonomi.

1.3 PENYATAAN MASALAH

Dalam dekad yang lalu, nilai Ringgit Malaysia (RM) berbanding Dolar Amerika Syarikat (USD) telah mengalami ketidakstabilan yang ketara. Statistik Bank Negara Malaysia menunjukkan bahawa dari 2013 hingga 2023, nilai tukaran telah meningkat dari USD 1 bersamaan dengan tiga Ringgit Malaysia kepada eknik lima Ringgit Malaysia. Peningkatan ini menunjukkan penurunan nilai mata wang negara yang berpotensi membawa kepada peningkatan harga barang perdagangan dan ketidakstabilan ekonomi.

Masalah ini menjadi lebih kritikal selepas fasa COVID-19, di mana banyak penyelidik mula mengkaji impak eknik n terhadap nilai tukaran mata wang. Melalui kajian ini, punca utama yang menyebabkan ketidakstabilan nilai mata wang negara perlu dikenal pasti dan dianalisis. Di samping itu, penting untuk memahami bagaimana data sejarah dan masa nyata boleh digunakan untuk menjangkakan nilai mata wang pada masa hadapan dengan menggunakan teknik pembelajaran mesin yang berkesan.

Data dari Bank Negara Malaysia digunakan dalam kajian ini kerana ia merupakan sumber data yang rasmi, boleh dipercayai, dan menyeluruh mengenai eknik n kewangan dan ekonomi negara. Data yang disediakan oleh Bank Negara Malaysia adalah terkini dan merangkumi pelbagai aspek ekonomi seperti kadar faedah, inflasi, dan pertumbuhan Produk Domestik Kasar (PDK), yang sangat penting

untuk model ramalan mata wang yang tepat. Selain itu, menggunakan data dari sumber rasmi ini memastikan kebolehpercayaan dan ketepatan hasil kajian, yang merupakan teknik kritikal dalam penyelidikan kewangan.

Dengan menggunakan teknik pembelajaran mesin, seperti Regresi Linear (LR), Regresi Vektor Sokongan (SVR), Regresi Penggalakan Kecerunan (GBR), Hutan Rawak (RF), dan XGBoost Regressor, kajian ini bertujuan untuk membangunkan model ramalan kadar tukaran mata wang yang berkesan. Model ini akan melalui proses pra-pemprosesan data yang teliti untuk memastikan kebersihan dan kesesuaian data bagi analisis. Evaluasi model akan dilakukan menggunakan metrik prestasi seperti Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan R-squared (R^2) untuk memastikan ketepatan dan kebolehpercayaan model. Hasil kajian akan disokong dengan visualisasi data untuk memudahkan pemahaman dan penyampaian hasil kepada pihak berkepentingan.

Kajian ini juga menghadapi beberapa kekangan seperti ketersediaan data yang mencukupi, teknik dalam pasaran mata wang, dan keupayaan teknik dalam yang terhad. Walaupun begitu, kajian ini memberikan sumbangan penting dalam bidang ramalan kadar pertukaran mata wang dan menunjukkan potensi besar penggunaan pembelajaran mesin dalam kewangan. Dengan melaksanakan teknik dalam untuk kajian masa depan, model ramalan yang lebih tepat, kukuh, dan berguna dapat dihasilkan.

1.4 OBJEKTIF KAJIAN

Kajian ini secara khususnya dilaksanakan untuk mencapai objektif-objektif seperti berikut:

1. Mengenal pasti algorithma terbaik untuk ramalan mata wang
2. Membangunkan model ramalan mata wang berkesan.
3. Membangunkan aplikasi untuk ramalan mata wang.

1.5 PERSOALAN KAJIAN

Bagi mencapai objektif di atas, berikut adalah persoalan kajian:

1. Algoritma pembelajaran mesin manakah yang menunjukkan ketepatan dan kebolehpercayaan tertinggi dalam ramalan nilai tukar mata wang?
2. Apakah teknik pra-pemprosesan data yang sesuai untuk memastikan kebersihan dan kesesuaian data bagi analisis?
3. Bagaimanakah aplikasi ramalan mata wang dapat direka bentuk untuk memberikan ramalan yang tepat dan mudah difahami?

1.6 SKOP KAJIAN

Kajian ini memfokuskan kepada data yang diperoleh dari laman web rasmi Bank Negara Malaysia dan laman web Yahoo Finance. Pelaksanaan projek ini menggunakan Python sebagai teknik pengaturcaraan. Setiap hasil analisis dan teknik n kajian akan dinilai untuk memilih model ramalan terbaik bagi kajian ini. Skop kajian juga termasuk menjangkakan nilai Ringgit Malaysia berbanding USD atau EUR untuk tempoh sehingga 6 bulan akan teknik n.

1.7 KEPENTINGAN KAJIAN

Kajian ini menyediakan wawasan yang lebih mendalam terhadap teknik ekonomi yang mempengaruhi nilai tukaran mata wang dengan menggunakan teknik pembelajaran mesin yang dapat menganalisis pelbagai teknik ekonomi secara lebih tepat. Dengan meningkatkan ketepatan ramalan kadar tukaran mata wang, model yang dibangunkan dalam kajian ini dapat membantu teknik n dan institusi kewangan dalam membuat teknik n yang lebih baik berkaitan dengan dasar teknik n dan teknik. Aplikasi web yang dihasilkan menyediakan ramalan kadar tukaran masa nyata serta nasihat beli/jual yang berguna bagi pelabur dan pengurus kewangan untuk mengurangkan risiko dan memaksimumkan keuntungan melalui strategi pelaburan yang lebih baik.

Kajian ini juga memperkayakan penyelidikan dalam bidang sains data dengan mengaplikasikan dan mengevaluasi pelbagai algoritma pembelajaran mesin dalam konteks ramalan kadar tukaran mata wang, yang boleh dijadikan rujukan bagi penyelidik dan pengamal sains data. Selain itu, kajian ini menekankan kepentingan penggunaan data rasmi dan berkualiti tinggi dari Bank Negara Malaysia untuk memastikan kebolehpercayaan dan ketepatan hasil analisis. Aplikasi yang dibangunkan juga menyediakan alat visualisasi data yang membantu pengguna memahami hasil ramalan dengan lebih mudah, memudahkan penyampaian maklumat secara efektif dan efisien. Dengan adanya ramalan yang lebih tepat dan alat visualisasi yang interaktif, pembuat dasar dan pelabur dapat membuat eknik n yang lebih baik berdasarkan data yang dianalisis, sejajar dengan matlamat sains data untuk mengubah data menjadi wawasan yang boleh diambil eknik n.

1.8 ORGANISASI TESIS

Tesis ini mengandungi lima (5) bab secara keseluruhan yang merangkumi:

1. Bab 1: Bab ini membincangkan kajian yang ingin dilaksanakan iaitu latar belakang kajian, pernyataan masalah, objektif kajian, kepentingan kajian dan skop kajian secara keseluruhan.
2. Bab 2: Bab ini merupakan aspek terpenting bagi sesuatu kajian yang akan dilaksanakan. Dalam bab ini akan dibincangkan dengan lebih lanjut tentang sorotan tinjauan lepas dan kajian-kajian terdahulu yang berkaitan dengan konsep dan eknik ramalan terutamanya dalam masalah menentukan harga rumah.
3. Bab 3: Bab ini merupakan metodologi kajian yang membincangkan secara terperinci kaedah kajian yang dilaksanakan. Ia merangkumi fasa data yang merangkumi mengenal pasti ciri-ciri data, analisis struktur data serta prapemprosesan data. Reka bentuk kajian juga diterangkan dengan lanjut di dalam bab ini.

4. Bab 4: Bab ini mengupas hasil analisis teknik dan model pembelajaran mesin yang telah dibuat. Selain itu, ia turut membincangkan ketepatan atau kualiti teknik dan model yang diperoleh dari hasil eksperimen. Seterusnya perbandingan prestasi dari segi ketepatan model akan dibuat dan dinilai.
5. Bab 5: Bab ini akan membuat teknik dan rumusan secara keseluruhan tentang kajian yang telah dilaksanakan. Ini termasuk sumbangan kajian dan teknik peluasan serta penambahbaikan yang boleh dibuat pada masa akan teknik.

Pusat Sumber
FTSM

BAB II

KAJIAN KESUSASTERAAN

2.1 PENGENALAN

Dalam bab ini menerangkan mengenai hasil kajian kesusasteraan yang melibatkan kajian-kajian terdahulu. Kajian ini berkaitan dengan peramalan harga rumah di Malaysia. Beberapa model telah dibangunkan sebelum ini dikaji dan diteliti serta dikupas untuk menilai keberkesanan model ramalan yang telah dibuat. Perbandingan antara model juga dilihat sebagai salah satu kaedah untuk menilai ketepatan teknik dalam model dari beberapa segi dan aspek. Model yang berasaskan pembelajaran mesin, regresi dan tradisional masing-masing menunjukkan keupayaan untuk membuat ramalan harga rumah bagi dalam jangkauan beberapa tahun yang akan datang. Kesesuaian model-model yang dibangunkan adalah berdasarkan data dan ciri-ciri sesebuah rumah. Bab ini mengandungi enam (6) bahagian iaitu:

1. Faktor yang mempengaruhi kadar mata wang
2. Teknik untuk meramal mata wang
3. Kajian lepas yang berkaitan ramalan mata wang
4. Pendekatan Pembelajaran Mesin
5. Metrik Prestasi
6. Kesimpulan.

2.2 FAKTOR YANG MEMPENGARUHI KADAR MATA WANG

Kadar mata wang sentiasa akan berubah sebaliknya setiap hari mengikut keadaan semasa. Terdapat banyak faktor yang mempengaruhi kadar mata wang berubah seperti keadaan ekonomi semasa negara atau keadaan ekonomi dunia. Yu Ma & Xinqian Du (2020) menjelaskan kadar pelaburan juga menjadi faktor yang menyebabkan kadar tukaran mata wang berubah dan tahap pendapatan sesebuah negara juga boleh menjadi faktor yang mempengaruhi kadar mata wang. Kadar mata wang dipengaruhi oleh pelbagai faktor ekonomi, politik, dan kewangan. Beberapa faktor utama termasuk:

1. **Kadar Faedah:** Kadar faedah yang ditetapkan oleh bank pusat sebuah negara boleh mempengaruhi aliran modal dan kekuatan mata wangnya. Kadar faedah yang lebih tinggi cenderung menarik pelabur, meningkatkan permintaan untuk mata wang tersebut, dan oleh itu, memperkuat nilainya.
2. **Kesihatan Ekonomi:** Prestasi ekonomi secara keseluruhan sebuah negara, termasuk pertumbuhan ekonomi, pengangguran, dan inflasi, boleh mempengaruhi nilai mata wangnya. Negara dengan pertumbuhan ekonomi yang kukuh cenderung menarik pelabur, yang boleh menyebabkan penguatan mata wang mereka.
3. **Ketidakstabilan Politik:** Ketidakstabilan politik atau konflik politik dalam sebuah negara boleh mengakibatkan ketidakpastian dan menurunkan kepercayaan pelabur, yang mungkin mempengaruhi nilai mata wangnya.
4. **Defisit Perdagangan:** Jika sebuah negara mengalami sebaliknya perdagangan yang besar (lebih banyak mengimpor berbanding mengeksport), mata wangnya mungkin mengalami tekanan penurunan nilai berbanding dengan negara yang memiliki kelebihan perdagangan.
5. **Intervensi Bank Pusat:** Tindakan langsung bank pusat untuk membeli atau menjual mata wangnya dalam pasaran antarabangsa boleh mempengaruhi kadar pertukaran. Ini biasa dilakukan untuk menstabilkan nilai mata wang atau merangsang pertumbuhan ekonomi.

6. **Faktor Geopolitik:** Konflik antara negara, perubahan dalam hubungan antarabangsa, atau kejadian geopolitik lainnya boleh memberi kesan kepada nilai mata wang.
7. **Spekulasi Pasaran:** Kepercayaan dan jangkaan pelabur mengenai prestasi ekonomi masa depan sebuah negara juga boleh mempengaruhi nilai mata wang melalui spekulasi pasaran.

2.3 TEKNIK MERAMAL MATA WANG

Terdapat beberapa kaedah dan teknik yang digunakan oleh pakar dan pengamal pasaran kewangan untuk membantu membuat ramalan tentang pergerakan mata wang. Di antara teknik-teknik tersebut adalah:

1. **Analisis Asas:** Analisis asas melibatkan kajian terperinci terhadap faktor-faktor ekonomi, politik, dan kewangan yang mempengaruhi nilai mata wang. Ini termasuk data ekonomi seperti pertumbuhan ekonomi, inflasi, pengangguran, teknik perdagangan, serta keadaan politik dan kewangan dalam dan luar negara (Mankiw, 2020).
2. **Analisis Teknikal:** Analisis teknikal menggunakan carta harga dan data perdagangan pasaran untuk mengenal pasti corak dan tren dalam pergerakan mata wang. Ini termasuk penggunaan petunjuk teknikal seperti purata bergerak, garisan sokongan dan rintangan, dan isyarat perdagangan lainnya (Murphy, 2018).
3. **Model Ekonomi:** Model ekonomi adalah pendekatan berdasarkan teori ekonomi yang digunakan untuk meramal pergerakan mata wang. Ini mungkin termasuk model ekonomi makro, model keseimbangan pembayaran, atau model nilai tukar (Krugman, Obstfeld & Melitz, 2018).
4. **Analisis Sentimen:** Analisis teknikal melibatkan memahami faktor pelabur dan peserta pasaran terhadap mata wang tertentu. Ini boleh melibatkan mengkaji berita, ulasan analis, atau data dari platform media sosial dan forum pasaran (Shiller, 2019).

5. **Penggunaan Algoritma dan Kecerdasan Buatan:** Semakin banyak penggunaan teknologi seperti algoritma perdagangan dan kecerdasan buatan (AI) dalam meramal pergerakan mata wang. Ini termasuk penggunaan rangkaian neural dalam model ramalan dan sistem perdagangan eknik n (Hull, 2018).
6. **Model Campuran:** Pendekatan yang sering digunakan adalah model campuran, yang menggabungkan analisis asas, teknikal, dan eknik-faktor lain untuk memberikan ramalan yang lebih komprehensif (Murphy, 2018).

2.4 KAJIAN LEPAS

Kajian lepas merupakan asas penting dalam memahami pendekatan dan eknik yang telah digunakan dalam meramalkan nilai tukar mata wang dan harga saham. Dalam era kewangan digital yang semakin berkembang, penggunaan pembelajaran mesin dan pembelajaran mendalam telah menjadi alat utama dalam menghasilkan ramalan yang lebih tepat dan berwawasan. Kajian-kajian ini memberikan pandangan yang mendalam mengenai pelbagai metodologi, algoritma, dan hasil yang telah dicapai dalam konteks ramalan kewangan. Ini adalah eknik n dalam bentuk jadual yang meringkaskan kajian lepas mengenai ramalan nilai tukar mata wang dan harga saham menggunakan pelbagai eknik pembelajaran mesin dan diterangkan lebih terperinci dibawah. Berikut adalah beberapa kajian lepas yang relevan dalam bidang ini:

Jadual 2.1 Ringkasan Kajian Lepas

Tajuk Kajian	Pengarang	Ringkasan Kajian
Ramalan Nilai Tukar Bitcoin	Wiliani, N., Hesananda, R.,	Kajian mengenai ramalan nilai tukar Bitcoin terhadap dolar AS menggunakan
Menggunakan Pembelajaran Mesin	Rahmawati, N. S., & Prianggara, E. H. (2020)	pembelajaran mesin. Data diperoleh dari API Binance.com. Algoritma yang digunakan termasuk regresi linear dan jaringan saraf buatan. Hasil menunjukkan jaringan saraf buatan menghasilkan ramalan yang lebih tepat daripada regresi linear.
Ramalan Nilai Tukar Menggunakan Pembelajaran Mesin dan Pembelajaran Mendalam Semasa Pandemik COVID-19	Abedin, M. Z., Moon, M. H., Hassan, M. K., & Hajek, P. (2021)	Kajian menggunakan pendekatan Bi-LSTM BR untuk meramalkan kadar pertukaran mata wang semasa dan sebelum pandemik COVID-19. Hasil menunjukkan pendekatan ini memberikan prestasi ramalan yang lebih baik berbanding model lain seperti pokok regresi dan regresi vektor sokongan.
Ramalan Kadar Pertukaran USD/PKR Menggunakan Pembelajaran Mesin	Naeem, S., Mashwani, W. K., Ali, A., Uddin, M. I., Mahmoud, M., Jamal, F., & Chesneau, C. (2020)	Menggunakan analisis sentimen dari data Twitter untuk meramalkan kadar pertukaran USD/PKR. Teknik NLP digunakan untuk prapemprosesan data. Lima pengklasifikasi digunakan: logistic sederhana, hutan rawak, bagging, Naïve Bayes, dan mesin vektor sokongan. Logistic sederhana menunjukkan prestasi terbaik dengan ketepatan 82.14%.

Ramalan Kadar Pertukaran Mata Wang Menggunakan Pembelajaran Mesin	Sekar, V. B., Yoloye, M., Vasudevan, N., & Dommeti, S. M. (2017)	Menggunakan model EMD-RNN dan ARIMA untuk meramalkan kadar pertukaran mata wang asing. Model hibrid EMD-RNN menunjukkan prestasi lebih baik berbanding model RNN dan ARIMA dalam jangka panjang.
Pemodelan dan Perdagangan Kadar Pertukaran EUR/USD Menggunakan Teknik Pembelajaran Mesin	Theofilatos, K., Likothanassis, S., & Karathanasopoulos, A. (2017)	Menggunakan lima teknik klasifikasi pembelajaran terarah untuk meramalkan pergerakan kadar pertukaran EUR/USD satu hari ke hadapan. Teknik SVM dan Hutan Rawak menunjukkan prestasi terbaik dari segi pulangan tahunan dan nisbah informasi.
Ramalan Kadar Pertukaran Mata Wang Menggunakan Teknik Pembelajaran Mesin	Mittal, V., & Goel, N. (2017)	Menyelidik keberkesanan pelbagai teknik pembelajaran mesin untuk meramalkan kadar pertukaran mata wang. Hutan Rawak dan Mesin Sokongan Vektor menunjukkan prestasi yang lebih baik berbanding kaedah tradisional seperti ARIMA.
Ramalan Harga Bitcoin Menggunakan Algoritma Pembelajaran Mendalam	Pintelas, P., Stavroyiannis, S., Pintelas, E., & Tsiliras, A. (2020)	Menggunakan pelbagai model pembelajaran mendalam seperti LSTM, CNN, dan BiLSTM untuk meramalkan harga Bitcoin. Model CNN-LSTM dan CNN-BiLSTM menunjukkan prestasi terbaik dalam ramalan harga dan arah pergerakan harga.
Ramalan Harga Saham Menggunakan Pembelajaran Mesin	Singh, S., Gutta, S., & Hadaegh, A. (2019)	Menggunakan teknik pembelajaran mesin seperti LSTM untuk meramalkan harga saham. Model LSTM menunjukkan prestasi baik dengan nilai RMSE yang lebih rendah berbanding model lain

Ramalan Harga Saham Google

Peng, L. (2022)

Menggunakan pembelajaran mesin

Menggunakan model regresi linear dan regresi hutan rawak untuk meramalkan harga

saham Google. Regresi linear mempunyai ketepatan yang lebih baik berbanding hutan

rawak

Pusat Sumber
FTSM

2.4.1 Ulasan Terperinci Kajian Lepas

1. Ramalan Nilai Tukar Bitcoin Menggunakan Pembelajaran Mesin

Kajian mengenai ramalan nilai tukar Bitcoin terhadap dolar AS menggunakan pembelajaran mesin adalah bidang yang menarik dan semakin penting dalam era kewangan digital. Berikut adalah tinjauan literatur yang relevan berdasarkan artikel ini dan sumber lain yang berkaitan. Kepentingan ramalan nilai tukar matawang merupakan salah satu aspek ekonomi makro yang penting kerana ia mempengaruhi kestabilan dan aktiviti ekonomi sesebuah negara. Bitcoin adalah aset kripto pertama yang desentralisasi dan dikawal sepenuhnya oleh penggunanya tanpa otoriti pusat atau perantara. Ia menggunakan rangkaian konsensus untuk membolehkan sistem pembayaran baru dan sepenuhnya digital. Perubahan tingkah laku Bitcoin terhadap dolar AS dipengaruhi oleh banyak faktor ekonomi asas seperti kadar inflasi dan bekalan wang.

Data untuk kajian ini diperoleh melalui API yang disediakan oleh Binance.com, yang mengandungi nilai tukar harian Bitcoin terhadap dolar AS, termasuk atribut seperti tarikh, nilai pembukaan, tertinggi, terendah, penutupan, dan volume. Pemodelan dilakukan dengan aplikasi RapidMiner, bermula dengan pengumpulan data latihan dan data ujian. Data latihan digunakan untuk melatih model ramalan, sementara data ujian digunakan untuk menguji ketepatan model yang dihasilkan. Algoritma yang digunakan ialah regresi linear dan jaringan saraf buatan. Hasil pengujian dengan Regresi Linear, menunjukkan hasil ramalan dengan harga minimum 31,683.539 dan maksimum 64,893.474, dengan purata ramalan harga 48,282.402. Manakala dengan saraf buatan menunjukkan hasil ramalan dengan harga minimum 31,509.256 dan maksimum 64,029.358, dengan purata ramalan harga 48,271.341. Dari segi perbandingan hasil kedua-dua algoritma menunjukkan hasil yang hampir serupa, saraf buatan menghasilkan ramalan yang sedikit lebih tepat berbanding dengan Regresi Linear. Neural Networks memerlukan lebih banyak masa dan eksperimen untuk menentukan bilangan input data, bilangan neuron, lapisan, dan tahap pembelajaran yang

optimum. Kajian ini menyimpulkan bahawa pembelajaran mesin, khususnya Neural Networks, lebih berkesan dalam membuat ramalan nilai tukar Bitcoin berbanding dengan Regresi Linear. Dengan prestasi maksimum dari operator Neural Networks, tahap ketepatan yang lebih tinggi dapat dicapai, menjadikannya alat yang berharga untuk ramalan kewangan dalam pasaran kripto yang sangat berubah-ubah.

2. Ramalan Nilai Tukar Menggunakan Pembelajaran Mesin dan Pembelajaran Mendalam Semasa Pandemik COVID-19

Ramalan nilai tukar menggunakan pembelajaran mesin dan pembelajaran mendalam merupakan bidang kajian yang semakin penting dalam konteks kewangan digital dan ekonomi global yang tidak menentu. Penyelidik telah melakukan pendekatan pembelajaran mendalam yang menggabungkan regresi *Bagging Ridge (BR)* dengan *Bi-directional Long Short-Term Memory (Bi-LSTM)* untuk meramalkan kadar pertukaran mata wang semasa dan sebelum pandemik COVID-19. Kajian ini menunjukkan bahawa pendekatan Bi-LSTMBR memberikan prestasi ramalan yang lebih baik berbanding model pembelajaran mesin dan pembelajaran mendalam yang lain, seperti pokok regresi, regresi vektor sokongan, dan regresi hutan rawak serta algoritma LSTM dan Bi-LSTM.

Kajian menunjukkan bahawa kaedah gabungan seperti yang digabungkan dalam Bi-LSTM BR dapat mengurangkan varians dan memberikan prestasi yang lebih kukuh dalam ramalan pasaran kewangan yang kompleks dan berubah-ubah. Beberapa kajian juga menunjukkan bahawa pandemik COVID-19 mempunyai kesan signifikan terhadap volatiliti pasaran pertukaran asing. Sebagai contoh, Hofmann et al. (2020) menunjukkan bahawa hutang melalui bon mata wang tempatan tidak melindungi ekonomi pasaran baru muncul dari kejutan kewangan yang dicetuskan oleh COVID-19. Kajian ini menekankan pentingnya model ramalan yang kuat semasa tempoh volatiliti tinggi seperti pandemik COVID-19 untuk membantu pelabur dan pengawal selia memahami dan mengurus risiko mata wang dengan lebih baik.

Hasil kajian menunjukkan bahawa pendekatan ensemble Bi-LSTM BR memberikan prestasi yang lebih baik dalam meramalkan kadar pertukaran berbanding dengan model lain. Keputusan ini penting untuk pedagang pertukaran asing dan pihak berkepentingan lain kerana menawarkan peluang untuk keuntungan perdagangan yang berpotensi dan mengurangkan risiko mata wang semasa pandemik. Ujian Diebold-Mariano (DM) menunjukkan bahawa pendekatan Bi-LSTM BR lebih efektif dalam fungsi kehilangan RMSE berbanding dengan algoritma benchmark dalam kajian ini untuk mata wang utama seperti AUD, CNY, GBP, dan JPY. Kajian ini menyimpulkan bahawa pendekatan pembelajaran mendalam ensemble Bi-LSTM dan BR memberikan prestasi ramalan yang lebih baik dalam meramalkan kadar pertukaran mata wang semasa tempoh bukan COVID-19 dan COVID-19. Model ini menawarkan potensi untuk meningkatkan keuntungan perdagangan dan mengurangkan risiko mata wang semasa tempoh volatiliti pasaran yang tinggi, seperti yang dialami semasa pandemik COVID-19.

3. Ramalan Kadar Pertukaran USD/PKR Menggunakan Pembelajaran Mesin

Ramalan kadar pertukaran adalah penting dalam pasaran kewangan global, dan penggunaan pembelajaran mesin untuk meramalkan kadar pertukaran USD/PKR menjadi tumpuan kajian ini. Kajian ini menggunakan analisis sentimen dari data Twitter untuk meramalkan kadar pertukaran antara Dolar Amerika Syarikat (USD) dan Rupee Pakistan (PKR). Data dikumpulkan dari laman web forex dan Twitter, di mana data Twitter terdiri daripada ciapan masyarakat perniagaan di Pakistan yang mengandungi perkataan berkaitan kewangan.

Data yang dikumpulkan dalam format mentah diprapemproses menggunakan teknik pemprosesan bahasa semula jadi (NLP) seperti pembuangan simbol tidak teratur, penerimaan hanya ciapan dalam bahasa Inggeris, pengekstrakan, lemmatisasi, dan pembuangan perkataan berhenti. Dataset dilabel menggunakan *Natural Language Toolkit* (NLTK) dari perpustakaan Python yang memberikan skor sentimen numerik kepada data.

Nilai “1” diberikan kepada ciapan yang menunjukkan peningkatan kadar pertukaran, “-1” untuk penurunan, dan “0” untuk ciapan neutral. Data divisualisasikan menggunakan analisis diskriminan linear (LDA) dan analisis komponen utama (PCA) untuk memahami dan mewakili data secara lebih baik. Visualisasi ini membantu dalam menentukan kebolehpercayaan dataset. Lima pengklasifikasi pembelajaran mesin digunakan untuk membina model klasifikasi: logistic sederhana (SL), hutan rawak (RF), bagging (B), Naïve Bayes (NB), dan mesin vektor sokongan (SVM). Pengklasifikasi logistic sederhana menunjukkan prestasi terbaik dengan ketepatan 82.14% dalam ramalan kadar pertukaran USD/PKR.

Keputusan kajian menunjukkan bahawa pengklasifikasi logistic sederhana (SL) memberikan hasil klasifikasi terbaik di antara lima pengklasifikasi pembelajaran mesin yang digunakan. Berikut adalah keputusan prestasi untuk kelima-lima pengklasifikasi:

Jadual 2.2 Keputusan Kajian USD/PKR

Algoritma	Ketepatan (%)	Kappa Statistik	Ralat Mutlak Min (MAE)	Ralat Kuasa Dua Min Punca (RMSE)
Logistic Sederhana (SL)	82.14	0.6875	0.0762	0.2157
Hutan Rawak (RF)	81.42	0.6579	0.0787	0.2536
Bagging (B)	77.85	0.6265	0.0738	0.2717
Naïve Bayes (NB)	76.42	0.6048	0.0852	0.2646
Mesin Vektor Sokongan (SVM)	74.28	0.5789	0.0898	0.2637

Kajian ini mencadangkan kaedah untuk meramalkan kadar pertukaran USD/PKR menggunakan analisis sentimen yang digabungkan dengan kaedah pembelajaran mesin. Hasil kajian menunjukkan bahawa pengklasifikasi

logistic sederhana memberikan prestasi terbaik dengan ketepatan tertinggi. Kaedah yang dicadangkan dan hasilnya boleh digunakan oleh masyarakat perniagaan di Pakistan untuk melabur di pasaran tempatan dan meramalkan kadar pertukaran untuk masa depan. Kajian literatur ini menyediakan gambaran menyeluruh mengenai penggunaan pembelajaran mesin dan analisis sentimen dalam ramalan kadar pertukaran USD/PKR, menekankan metodologi yang digunakan, hasil, dan implikasi praktikal dalam konteks pasaran kewangan global.

4. Ramalan Kadar Pertukaran Mata Wang Menggunakan Pembelajaran Mesin

Penulis menyelesaikan kajian ini sebagai sebahagian daripada subjek "Pattern Recognition and Data Mining" pada bulan Jun 2017. Ramalan kadar pertukaran mata wang asing adalah satu aspek penting dalam pasaran kewangan global. Projek ini bertujuan untuk membangunkan model yang tepat untuk meramalkan kadar pertukaran mata wang asing dengan menggunakan model EMD-RNN dan ARIMA serta membandingkan prestasi kedua-dua model tersebut.

Kajian ini menggunakan pendekatan Hibrid. Dengan menggunakan model hibrid EMD-RNN dan membandingkannya dengan model ARIMA untuk menunjukkan model mana yang lebih baik dalam ramalan kadar pertukaran mata wang asing. Ini kerana model RNN dapat menangani masalah kompleks dengan lebih baik manakala model ARIMA diketahui lebih cekap dalam ramalan siri masa jangka pendek. Hipotesis awal kajian ini adalah bahawa model EMD-RNN akan lebih tepat dalam meramalkan kadar pertukaran berbanding model ARIMA. Kami menjangkakan model RNN akan mempunyai kadar ralat yang lebih rendah berbanding model ARIMA. Data dikumpulkan dari laman web Quandl yang menyediakan kadar pertukaran sejarah untuk pelbagai mata wang. Data input akan dimasukkan ke dalam penapis EMD untuk prapemprosesan sebelum dimasukkan ke dalam model RNN. Model ARIMA juga akan digunakan pada data yang sama. Keputusan kedua-dua model akan diplotkan dan dibandingkan dengan nilai sebenar. Ralat

bagi setiap model akan diukur menggunakan RMSE (Ralat Kuasa Dua Min Punca).

Analisis menunjukkan bahawa model hibrid EMD-RNN memberikan prestasi yang lebih baik berbanding model RNN dan ARIMA dalam jangka panjang. Keputusan ini selari dengan hipotesis kami bahawa model EMD-RNN akan lebih tepat dalam meramalkan kadar pertukaran mata wang asing. Keputusan menunjukkan bahawa model EMD-RNN lebih baik daripada model RNN dan ARIMA dalam ramalan jangka panjang. Walau bagaimanapun, model ARIMA menunjukkan prestasi yang baik untuk dataset yang lebih kecil dan ramalan jangka pendek. Kajian ini menyokong hipotesis bahawa model EMD-RNN adalah yang terbaik di antara model yang dipilih untuk ramalan jangka panjang. Cadangan masa depan termasuk melatih model RNN untuk ramalan jangka pendek dan set data kecil, serta menerapkan model EMD-RNN untuk ramalan dengan set data yang lebih besar. Kajian literatur ini memberikan gambaran menyeluruh mengenai penggunaan pembelajaran mesin untuk ramalan kadar pertukaran asing, menekankan metodologi, hasil, dan kepentingan dalam konteks pasaran kewangan global.

5. Pemodelan dan Perdagangan Kadar Pertukaran EUR/USD Menggunakan Teknik Pembelajaran Mesin

Kajian ini bertujuan untuk menyelidik prestasi teknik pembelajaran mesin terkini dalam perdagangan kadar pertukaran EUR/USD menggunakan data penetapan ECB. Lima teknik klasifikasi pembelajaran terarah (K-Nearest Neighbors, Pengklasifikasi Naïve Bayesian, Rangkaian Neural Tiruan, Mesin Vektor Sokongan, dan Hutan Rawak) telah digunakan untuk meramalkan pergerakan kadar pertukaran EUR/USD satu hari ke hadapan dengan hanya menggunakan terma autoregressive sebagai input. Kajian ini juga membandingkan prestasi teknik pembelajaran mesin dengan dua teknik tradisional (strategi Naïve dan model MACD).

Data kadar pertukaran harian EUR/USD yang digunakan dalam kajian ini diperoleh dari Thomson Reuters Datastream dan dibahagikan kepada dataset latihan, pengesahan, dan pengujian. Mengklasifikasikan objek

berdasarkan contoh latihan terdekat dalam ruang ciri. Dalam kajian ini, K=8 adalah nilai K optimum yang ditemui. Keputusan kajian menunjukkan bahawa teknik SVM dan Hutan Rawak mengatasi semua model lain dari segi pulangan tahunan dan nisbah informasi walaupun selepas mengambil kira kos transaksi. Hutan Rawak menunjukkan prestasi terbaik dengan pulangan tahunan tertinggi dan ramalan arah pergerakan yang paling tepat. Hutan Rawak menunjukkan prestasi perdagangan terbaik dari segi pulangan tahunan dan nisbah informasi, walaupun selepas kos transaksi diambil kira. SVM dan Hutan Rawak jelas mengatasi strategi perdagangan tradisional yang masih digunakan oleh ahli ekonomi.

Kajian ini menunjukkan bahawa teknik pembelajaran mesin seperti SVM dan Hutan Rawak menawarkan prestasi yang unggul dalam perdagangan kadar pertukaran EUR/USD berbanding dengan teknik tradisional. Hasil kajian ini mendorong penyelidikan masa depan dalam menerapkan teknik pembelajaran mesin dalam perdagangan siri masa kewangan lain untuk menilai prestasi mereka dan menetapkan mereka sebagai alat perdagangan kuantitatif yang boleh dipercayai.

6. Ramalan Kadar Pertukaran Mata Wang Menggunakan Teknik Pembelajaran Mesin

Kajian yang menyeluruh mengenai penggunaan pelbagai teknik pembelajaran mesin untuk meramalkan kadar pertukaran mata wang. Kajian ini bertujuan untuk menentukan teknik mana yang memberikan ketepatan ramalan terbaik, dengan memberi tumpuan khusus kepada tiga teknik utama: Regresi Linear, Hutan Rawak, dan Mesin Sokongan Vektor. Teknik pembelajaran mesin telah menunjukkan potensi besar dalam menghasilkan ramalan yang lebih tepat berbanding kaedah tradisional. Kajian ini menyelidik keberkesanan pelbagai teknik pembelajaran mesin dalam konteks ini.

Data kadar pertukaran harian bagi pasangan mata wang utama seperti EUR/USD, USD/JPY, dan GBP/USD dikumpulkan untuk tempoh 10 tahun. Selain itu, data ekonomi makro seperti kadar faedah, inflasi, pertumbuhan GDP, dan indikator ekonomi lain yang relevan juga dikumpulkan. Tempoh

data yang panjang ini memastikan terdapat cukup variasi dalam data untuk analisis jangan Panjang Data didinormalisasikan menggunakan teknik seperti Min-Max Scaling untuk memastikan semua ciri mempunyai skala yang sama dan tidak mendominasi model. Data ini kemudian dibahagikan kepada set latihan (70%), set pengesahan (15%), dan set ujian (15%). Kajian ini menggunakan tiga teknik utama. Regresi linear digunakan untuk memahami hubungan linear antara pembolehubah bebas (ciri-ciri ekonomi) dan pembolehubah bergantung (kadar pertukaran). Hutan Rawak adalah teknik ensemble yang menggabungkan beberapa pokok keputusan untuk mendapatkan ramalan yang lebih stabil dan tepat. Setiap pokok keputusan dilatih pada subset rawak data dan subset ciri, dan keputusan akhir diperoleh dengan mengambil purata ramalan dari semua pokok keputusan. Mesin Sokongan Vektor mencari hyperplane terbaik yang memaksimumkan margin antara kelas data dalam ruang ciri. Teknik ini sesuai untuk klasifikasi dan regresi dengan dimensi tinggi dan data yang tidak linear. Ia menggunakan kernel trick untuk mengubah data ke ruang dimensi yang lebih tinggi. Model-model ini dinilai berdasarkan beberapa metrik prestasi seperti Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan ketepatan ramalan. Teknik K-fold cross-validation (contohnya, 10-fold cross-validation) digunakan untuk mengelakkan overfitting dan memastikan model boleh generalisasi pada data yang tidak dilihat.

Hasil kajian mendapati bahawa Regresi Linear menunjukkan prestasi yang memuaskan tetapi kurang tepat berbanding model lain dalam ramalan jangka pendek. Model ini tidak mampu menangkap hubungan yang tidak linear dalam data. Hutan Rawak memberikan ketepatan yang lebih tinggi kerana keupayaannya untuk menangani data yang tidak linear dan kompleks. Ia juga mengurangkan risiko overfitting kerana sifat ensemble model. **Mesin Sokongan Vektor** menunjukkan prestasi yang sangat baik dalam meramalkan kadar pertukaran, terutamanya untuk data jangka pendek. Mesin Sokongan Vektor mampu menangkap pola yang tidak linear dan kompleks dalam data. Kajian ini mendapati bahawa teknik pembelajaran mesin memberikan ramalan yang lebih tepat berbanding kaedah tradisional seperti ARIMA. Hutan Rawak

dan Mesin Sokongan Vektor adalah teknik yang paling berkesan untuk ramalan kadar pertukaran mata wang dalam kajian ini. Penulis mencadangkan penggunaan model ensemble dan penggabungan pelbagai teknik pembelajaran mesin untuk meningkatkan ketepatan ramalan. Selain itu, mereka juga mencadangkan untuk meneroka teknik pembelajaran mendalam (deep learning) seperti LSTM untuk menangkap pola jangka panjang dalam data masa.

7. Ramalan Harga Bitcoin Menggunakan Algoritma Pembelajaran Mendalam

Ramalan harga Bitcoin telah menjadi topik penting dalam bidang kewangan dan perniagaan kerana potensinya untuk membantu pelabur membuat keputusan yang lebih baik. Walau bagaimanapun, ramalan harga Bitcoin adalah tugas yang sangat mencabar disebabkan sifatnya yang kacau dan kompleks. Dalam kajian ini mereka meneroka penggunaan pelbagai model pembelajaran mendalam untuk meramalkan harga Bitcoin dan cryptocurrency lain. Model pembelajaran mendalam yang digunakan dalam kajian ini termasuk Memori Jangka Pendek Panjang (LSTM), Rangkaian Neural Konvolusi (CNN), dan LSTM Dwihala (BiLSTM). Memori Jangka Pendek Panjang (LSTM) adalah jenis rangkaian neural berulang yang direka untuk mengatasi masalah pergantungan jangka panjang dalam data siri masa. Ia menggunakan sel memori yang membantu untuk mengingati maklumat penting dari masa lalu dan menggunakan maklumat tersebut untuk membuat ramalan masa depan. Rangkaian Neural Konvolusi (CNN) pula adalah rangkaian neural yang digunakan terutamanya untuk pemprosesan imej dan pengecaman corak. CNN menggunakan lapisan konvolusi dan pooling untuk mengekstrak ciri-ciri berharga dari data input. LSTM Dwihala (BiLSTM) menggabungkan dua lapisan LSTM yang berjalan ke arah yang bertentangan untuk mengingati keadaan sel rangkaian dari masa lalu dan masa depan, yang memberikan konteks masa lalu dan masa depan kepada model.

Dalam kajian ini, mereka menggunakan data harga Bitcoin, Ethereum (ETH), dan Ripple (XRP) dari Januari 2018 hingga Ogos 2019. Data

dibahagikan kepada set latihan dan ujian. Model pembelajaran mendalam seperti CNN, LSTM, dan BiLSTM dinilai menggunakan metrik seperti RMSE (Root Mean Squared Error), ketepatan, dan skor F1 untuk ramalan harga dan arah pergerakan harga. Keputusan kajian menunjukkan bahawa model CNN-LSTM dan CNN-BiLSTM menunjukkan prestasi terbaik secara keseluruhan dalam ramalan harga dan arah pergerakan harga untuk semua dataset yang diuji. Walau bagaimanapun, variasi prestasi antara semua model pembelajaran mendalam adalah minimum, menunjukkan bahawa model pembelajaran mendalam sedikit mengatasi model pembelajaran mesin tradisional tetapi tidak mencapai peningkatan prestasi yang ketara. Kajian ini menyimpulkan bahawa model pembelajaran mendalam mungkin tidak cukup cekap dalam meramalkan harga cryptocurrency kerana masalah ini mungkin hampir dengan proses rawak berjalan atau terlalu rumit untuk dipecahkan oleh model pembelajaran mendalam sedia ada.

Implikasi kajian ini menunjukkan terdapat keperluan untuk metodologi yang lebih canggih, teknik baru, dan pendekatan alternatif untuk ramalan harga cryptocurrency. Teknik validasi baru perlu diterokai untuk menilai model ramalan harga cryptocurrency dengan lebih berkesan. Penyelidikan lebih lanjut diperlukan untuk mengenal pasti dan menggabungkan strategi kejuruteraan ciri baru serta kaedah ensemble algoritmik untuk meningkatkan ketepatan dan

8. Ramalan Harga Saham Menggunakan Pembelajaran Mesin

Ramalan harga saham telah menjadi topik yang semakin penting dalam bidang kewangan kerana potensinya untuk membantu pelabur membuat keputusan yang lebih baik. Walaupun begitu, ramalan harga saham adalah tugas yang mencabar disebabkan sifatnya yang tidak menentu dan kompleks.

Kajian ini menggunakan beberapa algorithma yang berkaitan seperti Memori Jangka Pendek Panjang (LSTM) **adalah** jenis rangkaian neural berulang (RNN) yang direka untuk mengatasi masalah pergantungan jangka panjang dalam data siri masa. LSTM menggunakan sel memori yang membantu untuk mengingati maklumat penting dari masa lalu dan

menggunakan maklumat tersebut untuk membuat ramalan masa depan. **Rangkaian Neural Konvolusi (CNN)** adalah rangkaian neural yang digunakan terutamanya untuk pemprosesan imej dan pengecaman corak. CNN menggunakan lapisan konvolusi dan pooling untuk mengekstrak ciri-ciri berharga dari data input. LSTM Dwihala (BiLSTM) menggabungkan dua lapisan LSTM yang berjalan ke arah yang bertentangan untuk mengingati keadaan sel rangkaian dari masa lalu dan masa depan, yang memberikan konteks masa lalu dan masa depan kepada model.

Dalam kajian ini., data harga saham dikumpulkan dari Yahoo Finance untuk tiga syarikat dari sektor yang berbeza selama kira-kira 10 tahun. Data tersebut digunakan untuk melatih model LSTM untuk meramalkan harga saham. Mereka membahagikan data kepada set latihan dan ujian dengan nisbah 80:20, dan menggunakan teknik normalisasi data untuk meningkatkan pembelajaran model. Keputusan kajian menunjukkan bahawa model LSTM menunjukkan prestasi yang baik dalam meramalkan harga saham dengan nilai RMSE yang lebih rendah berbanding model lain seperti ARIMA, Regresi Linear, dan SVM. Walau bagaimanapun, mereka juga menekankan bahawa tiada model yang dapat meramalkan harga saham dengan tepat disebabkan oleh pelbagai faktor yang mempengaruhi pasaran saham, seperti berita dan perubahan mendadak dalam pasaran.

Kajian ini menyimpulkan bahawa teknik pembelajaran mesin seperti LSTM boleh meningkatkan ketepatan ramalan harga saham dengan menggunakan data sejarah untuk mengenal pasti corak dan trend dalam pergerakan harga saham. Walau bagaimanapun, penting untuk memahami parameter yang mempengaruhi ramalan untuk membangunkan model yang cekap dan tepat.

9. Ramalan Harga Saham Google berdasarkan Pembelajaran Mesin

Dalam kajian ini penulis telah meneroka penggunaan pelbagai teknik pembelajaran mesin untuk meramalkan harga saham Google. Kajian ini menumpukan kepada model regresi linear dan regresi hutan rawak untuk meramalkan harga saham dan membandingkan ketepatannya. Pada tahun

2022, banyak negara telah mengisytiharkan berakhirnya wabak, yang merupakan peluang dan cabaran bagi ramai pelabur. Semakin banyak pelabur yang memanipulasi harga untuk mempengaruhi pasaran saham.

Oleh itu, para pelabur ingin meramalkan harga saham untuk membuat pelaburan yang sesuai. Pengarang ingin memulakan dengan platform YouTube untuk mengkaji trend harga saham ini dan membuat ramalan untuk menganalisis sama ada terdapat jejak faktor yang mempengaruhi harga saham berdasarkan model regresi linear dan regresi hutan rawak. Pengarang terlebih dahulu menguji kembali harga saham ini dan menganalisis data mengikut hari tertinggi dan terendah. Kemudian, pengarang menggunakan kaedah Regresi Linear dan Regresi Hutan Rawak untuk meramalkan harga. Kesilapan hasil ramalan Regresi Linear adalah dalam lingkungan 5%, dalam julat yang normal, tetapi ketepatan ramalan 5 hari Regresi Hutan Rawak jauh lebih rendah (65%). Ini menunjukkan bahawa model ramalan harga saham--Regresi Linear lebih dipercayai dan patut dijadikan rujukan bagi para pelabur.

Penyelidikan menunjukkan bahawa harga yang diramalkan oleh regresi linear sangat dekat dengan harga sebenar dan merupakan model ramalan harga yang baik. Walau bagaimanapun, kerana kesilapan terlalu kecil dan turun naik pulangan harian saham terlalu kecil, nilai rujukan adalah kurang bermakna. Dalam kajian susulan, para sarjana boleh mengira harga lima hari atau meramalkan pulangan harian, dan hasilnya akan lebih bernilai untuk rujukan. Regresi hutan rawak meramalkan bahawa harga lima hari terlalu berbeza daripada harga sebenar. Menurut hasilnya, ketepatannya hanya 65%, yang jauh lebih rendah daripada regresi linear. Walau bagaimanapun, ini juga menunjukkan bahawa beberapa pembolehubah input tidak berkait rapat dengan harga Google itu sendiri. Tambahan pula, regresi hutan rawak meramalkan harga untuk lima hari berturut-turut, yang lebih rendah daripada harga harian yang diramalkan oleh regresi linear.

2.5 METRIK PRESTASI

Metrik prestasi atau ukuran ralat adalah komponen penting yang digunakan dalam kerangka penilaian sejak dahulu. Dalam eksperimen kajian regresi pembelajaran mesin, metrik prestasi digunakan untuk membandingkan ramalan model dengan set data yang diperolehi dari sumber-sumber Tertentu (Makridakis Et Al., 2018). Terdapat pelbagai metrik yang digunakan namun mengikut kesesuaian eksperimen dan tujuan kajian. Dalam bidang pembelajaran mesin, pemilihan metrik prestasi yang tepat adalah kritikal untuk menilai dan mengoptimumkan model ramalan. Terdapat pelbagai metrik yang boleh digunakan, namun, empat yang sering dianggap sebagai yang terbaik adalah ralat kuasa dua purata (*mean squared error, mse*), akar kuasa dua ralat purata (*root mean squared error, rmse*), r-kuasa dua (*r-squared, r²*), dan skor f1 (*f1 score*). Setiap metrik ini mempunyai kegunaan dan kelebihan unik yang menjadikannya sesuai untuk pelbagai jenis masalah pembelajaran mesin (Abidin et al., 2018; Zainuri et al., 2015).

1. Mean Squared Error (MSE)

MSE adalah salah satu metrik utama dalam model regresi. Ia mengukur purata kuasa dua perbezaan antara nilai yang diramalkan oleh model dan nilai sebenar. Salah satu kelebihan utama MSE adalah ia memberikan penalti yang lebih besar kepada ralat yang lebih besar, menjadikannya sangat peka terhadap data luar biasa (outliers). Ini berguna dalam pengoptimuman model kerana ia membantu mengenal pasti dan memperbaiki ralat yang besar. Dalam proses latihan model, MSE sering digunakan sebagai fungsi kerugian yang membimbing pengoptimuman parameter model. Semakin rendah nilai RMSE, semakin baik prestasi model ramalan (Makridakis et al., 2018). Formula seperti berikut;

$$MSE = \frac{\sum_{i=1}^n (y_i - y_i^p)^2}{n}$$

di mana : y_i ialah nilai ramalan

y_i^p ialah nilai sebenar

n ialah bilangan sampel

2. Root Mean Squared Error (RMSE)

RMSE adalah variasi MSE yang lebih mudah difahami kerana ia mengembalikan nilai dalam unit yang sama dengan data asal. RMSE memberikan tafsiran yang jelas tentang magnitud ralat dalam ramalan model. Seperti MSE, RMSE juga sangat peka terhadap ralat yang besar, menjadikannya metrik yang sangat baik untuk menilai ketepatan model regresi. Ia sering digunakan dalam laporan prestasi model kerana ia memberikan gambaran yang lebih intuitif kepada pemegang kepentingan (Abidin et al., 2018).

$$RMSE = \sqrt{[\sum(P_i - O_i)^2 / n]}$$

di mana Σ ialah jumlah

P_i ialah nilai ramalan dalam setdata

O_i ialah nilai sebenar dalam setdata

n ialah size sampel

3. R-Squared (R^2)

R^2 adalah metrik yang digunakan untuk menilai sejauh mana model menerangkan variasi dalam data. Nilai R^2 berkisar antara 0 dan 1, dengan nilai yang lebih tinggi menunjukkan bahawa model memberikan ramalan yang lebih tepat. Kelebihan utama R^2 adalah ia memudahkan perbandingan antara model yang berbeza. R^2 digunakan secara meluas dalam model regresi linear dan pelbagai untuk memberikan pandangan tentang keupayaan model dalam menerangkan variasi dalam data sebenar (Zainuri et al., 2015). Formula seperti berikut;

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

di mana: y_i adalah nilai sebenar, \hat{y}_i adalah nilai yang diramalkan oleh

model, \bar{y} adalah purata nilai sebenar, n adalah bilangan pemerhatian.

4. Skor F1

Skor F1 adalah metrik utama dalam masalah klasifikasi, terutama apabila terdapat ketidakseimbangan kelas. Ia menggabungkan Precision dan Recall dalam satu metrik, memberikan gambaran yang seimbang tentang prestasi model. Kelebihan utama Skor F1 adalah ia memastikan keseimbangan antara Precision dan Recall, yang penting dalam konteks di mana kedua-dua kesalahan positif palsu dan negatif palsu mempunyai implikasi yang signifikan. Skor F1 sangat berguna dalam bidang seperti perubatan dan pengesahan penipuan, di mana ketepatan pengelasan adalah kritikal (Abidin et al., 2018). Formula seperti berikut;

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Ketepatan (Precision): Mengukur kebolehpastian bahawa suatu contoh yang diramalkan sebagai positif benar-benar positif. Ketepatan yang lebih tinggi bermakna model mempunyai kadar positif palsu yang rendah. Formula seperti berikut;

$$\text{Precision} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Positives (FP)}}$$

Kepulangan (Recall): Mengukur kebolehan model untuk mengenal pasti semua contoh positif sebenar. Kepulangan yang lebih tinggi bermakna model mempunyai kadar negatif palsu yang rendah. Formula seperti berikut;

$$\text{Recall} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Negatives (FN)}}$$

2.6 PEMBELAJARAN MESIN (ALGORITHM)

2.6.1 Algorithm Regresi Linear (RL)

Regresi linear adalah salah satu algoritma pembelajaran mesin yang paling asas dan paling banyak digunakan untuk masalah regresi, di mana matlamatnya adalah untuk meramalkan nilai berterusan berdasarkan pemboleh ubah bebas. Ia berfungsi dengan mengandaikan hubungan linear antara pemboleh ubah bebas (ciri) dan pemboleh ubah bersandar (sasaran). Regresi linear berusaha untuk mencari garis lurus yang paling sesuai dengan data, yang boleh digunakan untuk meramalkan nilai baru. Persamaan garis lurus dalam regresi linear adalah:

$$y = b_0 + b_1 x$$

Ini bermakna y adalah nilai yang diramalkan, x adalah pemboleh ubah bebas, b_0 adalah pintasan y (intercept), yang mewakili titik di mana garis memotong paksi- y , b_1 adalah kecerunan (slope) garis, yang mewakili kadar perubahan y berkenaan dengan x .

Regresi linear adalah algoritma pembelajaran mesin yang sangat mudah difahami dan digunakan, dengan kelebihan utamanya terletak pada kesederhanaan dan kecekapan pengiraan. Ia memerlukan sumber yang sedikit dan memberikan gambaran yang jelas tentang hubungan linear antara pemboleh ubah bebas dan bersandar. Namun, regresi linear mengandaikan bahawa hubungan antara pemboleh ubah ini adalah linear, yang mungkin tidak benar dalam semua kes, dan ia juga sangat sensitif terhadap data yang luar biasa yang boleh menjelaskan ketepatan model. Walaupun ia alat yang kuat dan fleksibel untuk masalah regresi, penting untuk memastikan bahawa model ini sesuai dengan sifat data yang dianalisis (Makridakis et al., 2018; Abidin et al., 2018).

2.6.2 Algorithma Regresi Hutan Rawak (RF)

Regresi Hutan Rawak adalah algoritma pembelajaran mesin yang digunakan untuk tugas regresi. Algoritma ini merupakan varian daripada Hutan Rawak, yang terdiri daripada gabungan pelbagai pokok keputusan (decision trees) yang dilatih pada subset data yang berbeza. Hasil akhir diperoleh dengan mengambil purata ramalan daripada semua pokok tersebut, membantu meningkatkan ketepatan model dan mengurangkan masalah lebihan muat. Regresi Hutan Rawak sering digunakan dalam pelbagai bidang seperti kewangan untuk ramalan harga saham, dalam pertanian untuk ramalan hasil tanaman, dan dalam bidang perubatan untuk meramalkan hasil rawatan berdasarkan data pesakit (Zainuri et al., 2015).

Pertama, dari set data asal yang mengandungi n pemerhatian, dipilih n sampel dengan penggantian. Ini bermaksud sebahagian data mungkin dipilih lebih daripada sekali, sementara sebahagian mungkin tidak dipilih sama sekali. Kedua, untuk setiap pokok dalam hutan, latih pokok keputusan menggunakan sampel bootstrap yang berbeza. Pada setiap nod pembelahan dalam pokok, pilih subset rawak daripada ciri-ciri yang tersedia, dan cari pembelahan terbaik berdasarkan subset ini. Akhirnya, untuk mendapatkan ramalan akhir, purata ramalan dari semua pokok keputusan dalam hutan diambil. Dalam kes regresi, ini bermakna nilai ramalan akhir adalah purata ramalan semua pokok.

Kelebihan model Hutan Rawak cenderung kurang lebihan muat berbanding pokok keputusan tunggal kerana ia menggabungkan hasil daripada pelbagai pokok. Algoritma ini stabil dan tahan terhadap perubahan kecil dalam data, yang boleh menyebabkan perubahan besar dalam pokok keputusan tunggal. Selain itu, algoritma ini biasanya memberikan prestasi yang baik dalam pelbagai jenis set data dan masalah regresi, dan mampu menangani data yang hilang dengan baik. Kekurangan bagi algoritma ini, model Hutan Rawak boleh memakan masa dan memerlukan sumber pengiraan yang besar, terutama dengan set data yang besar dan banyak pokok. Selain itu, sukar untuk mentafsir model Hutan Rawak kerana ia adalah "black box" yang menggabungkan pelbagai pokok keputusan.

2.6.3 Algorithma Regresi Vektor Sokongan (SVR)

Regresi Vektor Sokongan (Support Vector Regression, SVR) adalah varian daripada Mesin Vektor Sokongan (Support Vector Machine, SVM) yang digunakan untuk masalah regresi. Walaupun SVM lebih dikenali sebagai algoritma klasifikasi, SVR digunakan untuk meramalkan nilai berterusan dan berusaha untuk mengekalkan kesimbangan antara kerumitan model dan ketepatan ramalan. SVR berfungsi dengan mencari hiperpesawat (hyperplane) yang memaksimumkan margin antara data dalam ruang ciri. Dalam kes regresi, matlamatnya adalah untuk mencari hiperpesawat yang mempunyai sisihan minimum daripada nilai sebenar dengan menggunakan parameter tertentu untuk mengawal margin dan ralat (Makridakis et al., 2018).

Langkah-langkah dalam SVR termasuk pemetaan data input ke dalam ruang berdimensi tinggi menggunakan fungsi kernel. Fungsi kernel ini membolehkan SVR berfungsi dengan baik walaupun dalam kes di mana hubungan antara boleh ubah bebas dan bersandar adalah tidak linear. Seterusnya, SVR mencari hiperpesawat yang meminimumkan jumlah ralat dan mempunyai jalur margin (ϵ -insensitive tube) di mana kesalahan ramalan kurang daripada ϵ . Parameter C digunakan untuk mengawal kerumitan model dengan memberi penalti kepada data yang berada di luar jalur margin, manakala parameter ϵ menentukan lebar jalur margin di mana ralat diabaikan. Fungsi objektif SVR bertujuan untuk meminimumkan jumlah ralat sambil memaksimumkan margin, dan ini diselesaikan menggunakan pengoptimuman kuadratik.

Kelebihan SVR termasuk ketepatan tinggi, fleksibiliti dalam menangani datayang mempunyai hubungan tidak linear, dan kawalan lebihan muat melalui parameter C dan ϵ . Namun, kekurangan SVR termasuk masa pengiraan yang panjang dan pemilihan parameter yang kompleks, yang memerlukan pencarian grid atau pengesahan silang (cross-validation). SVR digunakan dalam pelbagai bidang termasuk kewangan untuk ramalan harga saham, pertanian untuk meramalkan hasil tanaman, dan perubatan untuk ramalan hasil rawatan pesakit. Kesimpulannya, Regresi Vektor Sokongan (SVR) adalah algoritma yang kuat untuk masalah regresi, menawarkan ketepatan tinggi dan fleksibiliti dalam menangani data yang tidak linear. Walaupun latihan model SVR boleh memakan masa dan kompleks, kelebihannya

dalam kawalan lebahan muat dan keupayaan untuk memberikan ramalan yang tepat menjadikannya pilihan yang popular dalam pelbagai aplikasi pembelajaran mesin (Makridakis et al., 2018; Abidin et al., 2018).

2.6.4 Algoritma Regresi Penggalakan Kecerunan (GBR)

Regresi Penggalakan Kecerunan adalah algoritma pembelajaran mesin yang kuat dan fleksibel, digunakan untuk masalah regresi. Algoritma ini membina model regresi yang kuat dengan menggabungkan kekuatan beberapa model yang lemah, biasanya pokok keputusan, dengan cara yang iteratif. Pada setiap langkah, model baru dibina untuk membetulkan kesilapan yang dibuat oleh model sebelumnya. Ini membolehkan Regresi Penggalakan Kecerunan mencapai ketepatan yang tinggi dan prestasi yang baik dalam pelbagai jenis data. Algoritma Regresi Penggalakan Kecerunan bekerja berdasarkan prinsip penggalakan (boosting), di mana model baru ditambah secara iteratif untuk meningkatkan prestasi keseluruhan. Setiap model baru dibina untuk mengurangkan ralat yang tinggal (residual error) dari model sebelumnya. Proses ini menggunakan pendekatan penurunan kecerunan (gradient descent) untuk mengoptimalkan fungsi kerugian. Dengan kata lain, setiap model baru mempelajari pola yang tidak dapat ditangkap oleh model-model sebelumnya dengan memminimumkan ralat secara beransur-ansur (Makridakis et al., 2018).

Langkah-langkah dalam Regresi Penggalakan Kecerunan termasuk inisialisasi model asas, biasanya pokok keputusan tunggal yang ringkas, yang digunakan untuk membuat ramalan awal. Kemudian, ralat (residual error) antara ramalan model dan nilai sebenar dikira, menunjukkan sejauh mana model semasa gagal membuat ramalan yang tepat. Model baru kemudian dibina untuk meramalkan ralat yang tinggal dari model sebelumnya, dan ditambah kepada model keseluruhan untuk meningkatkan ketepatan ramalan. Langkah-langkah ini diulang beberapa kali sehingga bilangan model yang ditentukan atau sehingga ralat tidak lagi lagi berkurangan dengan ketara. Model akhir adalah gabungan linear dari semua model yang telah dibina, dengan setiap model memberikan sumbangan kepada ramalan akhir berdasarkan pemberat yang ditentukan oleh proses penurunan kecerunan.

Kelebihan Regresi Penggalakan Kecerunan termasuk ketepatan tinggi kerana ia mampu mencapai ketepatan ramalan yang sangat tinggi dengan mempelajari pola kompleks dalam data, fleksibiliti kerana ia boleh digunakan dengan pelbagai jenis fungsi kerugian dan sangat sesuai untuk data yang tidak seimbang, serta penanganan outliers kerana algoritma ini cenderung kurang terpengaruh oleh outliers. Namun, kekurangan Regresi Penggalakan Kecerunan termasuk masa pengiraan yang panjang, terutamanya dengan dataset yang besar, kerumitan model yang boleh menjadi sangat kompleks dan sukar untuk ditafsirkan, serta sensitiviti terhadap pemilihan parameter yang tepat seperti bilangan pokok, kedalaman pokok, dan kadar pembelajaran (learning rate). Regresi Penggalakan Kecerunan sering digunakan dalam pelbagai bidang seperti kewangan untuk ramalan harga saham, pemasaran untuk analisis nilai pelanggan, dan sains data untuk pelbagai jenis ramalan dan analisis. Algoritma ini sangat berguna dalam situasi di mana ketepatan ramalan adalah kritikal dan terdapat pola kompleks dalam data yang sukar ditangkap oleh model yang lebih sederhana. Kesimpulannya, Regresi Penggalakan Kecerunan adalah algoritma yang kuat dan serba boleh untuk masalah regresi. Dengan menggabungkan kekuatan beberapa model yang lemah secara iteratif, ia mampu mencapai ketepatan ramalan yang tinggi. Walaupun latihan model boleh menjadi memakan masa dan memerlukan pemilihan parameter yang teliti, kelebihannya dalam menangani pola kompleks dan outliers menjadikannya pilihan yang popular dalam banyak aplikasi pembelajaran mesin.

2.6.5 Algorithma Regresi XGBoost (XGB)

XGBoost (*Extreme Gradient Boosting*) Regressor adalah algoritma pembelajaran mesin yang sangat popular dan kuat, digunakan untuk masalah regresi. Ia adalah versi yang lebih efisien dan dioptimumkan daripada algoritma penggalakan keceruna. XGBoost terkenal dengan prestasi tinggi dan keupayaan untuk menangani dataset yang besar dan kompleks. Ia direka untuk meningkatkan kelajuan dan prestasi model penggalakan kecerunan melalui pelbagai pengoptimuman dan peningkatan algoritma. XGBoost Regressor bekerja berdasarkan prinsip penggalakan (boosting), di mana model baru ditambah secara iteratif untuk meningkatkan prestasi keseluruhan. Pada setiap langkah, model baru dibina untuk membetulkan kesilapan yang dibuat oleh model sebelumnya dengan meminimumkan ralat. Proses ini menggunakan pendekatan

penurunan kecerunan untuk mengoptimumkan fungsi kerugian. XGBoost juga memperkenalkan teknik-teknik seperti regularisasi, pengendalian data yang hilang, dan pengoptimuman hardware untuk meningkatkan prestasi dan mengurangkan lebihan muat (Abidin et al., 2018).

Langkah-langkah dalam XGBoost Regressor termasuk inisialisasi model asas, biasanya pokok keputusan tunggal yang ringkas, untuk membuat ramalan awal. Kemudian, ralat (residual error) antara ramalan model dan nilai sebenar dikira, menunjukkan sejauh mana model semasa gagal membuat ramalan yang tepat. Model baru kemudian dibina untuk meramalkan ralat yang tinggal dari model sebelumnya, dan ditambah kepada model keseluruhan untuk meningkatkan ketepatan ramalan. XGBoost menggunakan regularisasi untuk mengawal kerumitan model dan mengurangkan lebihan muat. Langkah-langkah pengiraan ralat dan pembinaan model baru diulang beberapa kali sehingga bilangan model yang ditentukan atau sehingga ralat tidak lagi berkurangan dengan ketara. Model akhir adalah gabungan linear dari semua model yang telah dibina, dengan setiap model memberikan sumbangan kepada ramalan akhir berdasarkan pemberat yang ditentukan oleh proses penurunan kecerunan.

Kelebihan XGBoost Regressor termasuk prestasi tinggi, keupayaan mencapai ketepatan ramalan yang sangat tinggi dengan mempelajari pola kompleks dalam data, serta pengoptimuman dan kelajuan yang tinggi, direka untuk menjadi cepat dan efisien dengan pengoptimuman hardware dan software. Algoritma ini juga fleksibel, menyokong pelbagai fungsi kerugian dan boleh digunakan dengan pelbagai jenis data, serta cenderung kurang terpengaruh oleh outliers dan mempunyai mekanisme untuk mengendalikan data yang hilang. Namun, kekurangan XGBoost Regressor termasuk masa latihan yang panjang, terutamanya dengan dataset yang sangat besar, serta kerumitan model yang boleh menjadi sangat kompleks dan sukar untuk ditafsirkan. Prestasi algoritma juga sangat bergantung pada pemilihan parameter yang tepat, seperti bilangan pokok, kedalaman pokok, dan kadar pembelajaran.

XGBoost Regressor sering digunakan dalam pelbagai bidang seperti kewangan untuk ramalan harga saham, pemasaran untuk analisis nilai pelanggan, dan sains data untuk pelbagai jenis ramalan dan analisis. Algoritma ini sangat berguna dalam situasi

di mana ketepatan ramalan adalah kritikal dan terdapat pola kompleks dalam data yang sukar ditangkap oleh model yang lebih sederhana. Kesimpulannya, XGBoost Regressor adalah algoritma yang kuat dan serba boleh untuk masalah regresi. Dengan menggabungkan kekuatan beberapa model yang lemah secara iteratif dan menggunakan pelbagai teknik pengoptimuman, ia mampu mencapai ketepatan ramalan yang tinggi. Walaupun latihan model boleh menjadi memakan masa dan memerlukan pemilihan parameter yang teliti, kelebihannya dalam menangani pola kompleks dan keupayaan untuk mengendalikan dataset besar menjadikannya pilihan yang popular dalam banyak aplikasi pembelajaran mesin.

2.7 KESIMPULAN

Kajian Kesusasteraan ini mendapati adanya hubungan atau kolerasi data antara atribut bagi membantu menghasilkan model analisis kajian ramalan berketepatan tinggi. Penggunaan algoritma pembelajaran mesin dan pembelajaran mendalam dalam ramalan nilai tukar mata wang dan harga saham menunjukkan potensi besar untuk meningkatkan ketepatan ramalan. Algoritma seperti Regresi Linear, SVM, Hutan Rawak, ANN, LSTM, dan XGBoost adalah antara yang paling banyak digunakan dan telah menunjukkan prestasi yang baik dalam kajian-kajian terkini. Setiap algoritma mempunyai kelebihan dan kekurangan tersendiri, dan pemilihan algoritma yang tepat bergantung pada sifat data dan masalah yang dihadapi.

BAB III

METODOLOGI KAJIAN

3.1 PENGENALAN

Dalam bab ini diuraikan dan dijelaskan metodologi kajian yang digunakan dalam kajian yang dijalankan. Metodologi kajian merupakan cara, kaedah dan pendekatan yang digunakan bagi mencapai matlamat dan objektif kajian. Kajian yang dijalankan akan menjadi lebih bersistematis dan berarah dalam mencapai sasaran objektif. Pendekatan kajian ini berasaskan kepada penyelidikan eksperimental yang dibahagikan kepada tiga fasa penyelidikan iaitu fasa input, fasa pembangunan model dan fasa output. Bab ini akan membincangkan beberapa perkara penting dalam metodologi dan strategi yang digunakan.

3.2 SENARAI PERISIAN YANG DIGUNAKAN DALAM KAJIAN

Bagi melaksanakan kajian dengan berkesan dan memenuhi objektif kajian, penggunaan perisian yang sesuai adalah penting. Senarai perisian yang digunakan dalam kajian ini adalah seperti dalam keterangan berikut:

a. *Python*

Python merupakan bahasa pengaturcaraan yang digunakan dalam projek pengaturcaraan yang besar atau kompleks. Ia digunakan secara meluas kerana merupakan bahasa yang mudah dan pembelajaran boleh didapati dengan mudah di Internet. *Python* membolehkan data saintis atau pengaturcara komputer menggunakan dalam penggunaan pembelajaran mesin, kecerdasan buatan, analisis sentimen dan pembangunan model ramalan.

b. Scikit-Learn (SKLearn)

SKLearn adalah perpustakaan pembelajaran mesin percuma yang dikhurusukan dalam *Python*. Ia mempunyai pelbagai algoritma seperti mesin vektor sokongan, hutan rawak, jiran tetangga dan ia juga menyokong perpustakaan lain dalam *Python* seperti NumPy dan SciPy. SKLearn mengandungi alat yang efisien untuk pembelajaran mesin dan pemodelan statistik seperti klasifikasi, regresi, pengurangan dimensi dan pengelompokan disediakan (Webyog Inc. 2019).

c. Microsoft Excel Workbook

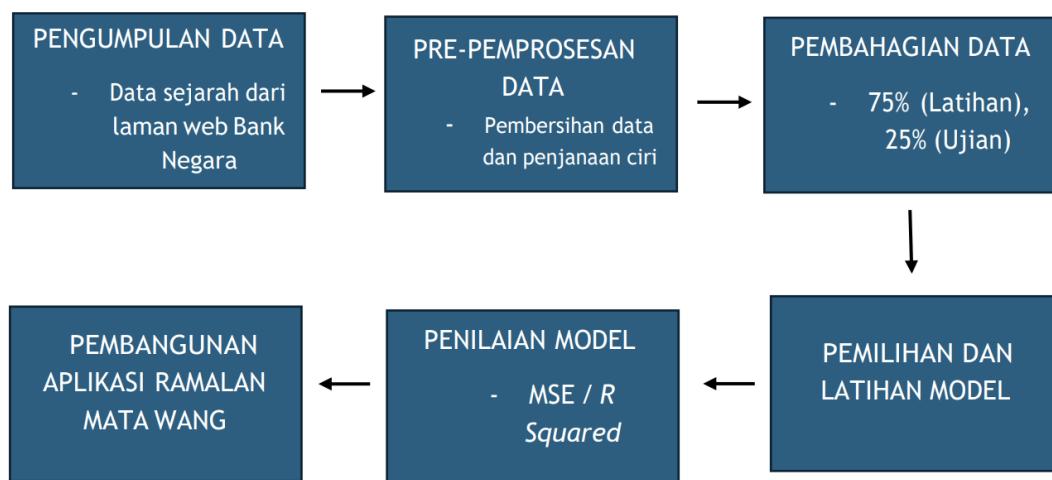
Merupakan program perisian di dalam Microsoft Office. Perisian ini membantu dalam pengiraan matematik set data, penyediaan dalam proses pre-pemprosesan, analisis data dan visualisasi data.

d. HTML

HTML (*HyperText Markup Language*) adalah bahasa markup yang digunakan untuk membuat dan menyusun bahagian, paragraf, dan pautan pada halaman web. Dalam konteks kajian ini, HTML digunakan untuk pembangunan antaramuka web yang memaparkan hasil ramalan nilai tukar mata wang. HTML membolehkan pengguna membina laman web yang mudah diakses dan mesra pengguna untuk tujuan visualisasi data dan interaksi dengan model ramalan yang dibangunkan.

3.3 KERANGKA METODOLOGI KAJIAN

Metodologi kajian untuk ramalan harga mata wang melibatkan beberapa langkah utama yang merangkumi pengumpulan data, pra-pemprosesan data, pemilihan dan latihan model, penilaian model, dan akhirnya membuat ramalan. Berikut adalah langkah-langkah terperinci yang biasanya diambil dalam kajian ramalan harga mata wang seperti Rajah 3.1.



Rajah 3.1 Carta Aliran Metodologi

Pengumpulan Data: Langkah pertama dalam metodologi kajian adalah pengumpulan data sejarah harga mata wang. Data ini biasanya diperoleh dari sumber-sumber seperti laman web perdagangan mata wang, bank, dan penyedia data kewangan seperti Yahoo Finance atau Bank Negara. Data yang dikumpulkan mungkin termasuk nilai tukar harian, mingguan, atau bulanan, serta faktor ekonomi lain yang berkaitan seperti kadar faedah, inflasi, dan indikator ekonomi makro lain.

Pra-Pemprosesan Data: Data yang dikumpulkan sering kali mengandungi nilai yang hilang, anomali, atau data yang tidak terstruktur. Oleh itu, langkah pra-pemprosesan adalah penting untuk memastikan kualiti data yang digunakan dalam model. Langkah-langkah pra-pemprosesan termasuk:

- Pembersihan Data: Menghapus data mata wang yang tidak digunakan apabila memuat turun data mata wang daripada Bank Negara.
- Penjanaan Ciri: Menambah ciri-ciri baru yang relevan, seperti purata bergerak (*moving averages*), kadar perubahan, atau indikator teknikal lain.

Pembahagian Data: Data yang dipra-pemproses dibahagikan kepada set latihan, set pengesahan, dan set ujian. Set latihan digunakan untuk melatih model, set pengesahan digunakan untuk mengoptimumkan parameter model, dan set ujian digunakan untuk

menilai prestasi model pada data yang tidak pernah dilihat sebelumnya. Pembahagian yang biasa digunakan adalah 75% untuk latihan, 25% untuk ujian.

Pemilihan dan Latihan Model: Beberapa algoritma pembelajaran mesin boleh digunakan untuk ramalan harga mata wang. Dalam kajian ini, kita menggunakan empat model utama iaitu Regresi Linear, SVR, RGB, dan XGBoost. Setiap model ini mempunyai kelebihan tersendiri dan diaplikasikan berdasarkan sifat data yang dikaji.

1. **Regresi Linear:** Digunakan untuk memahami hubungan linear antara ciri-ciri dan harga mata wang. Model ini mudah untuk difahami dan cepat untuk dilatih.
2. **Regresi Vektor Sokongan(SVR):** Digunakan untuk mencari hyperplane terbaik yang memaksimumkan margin antara kelas data dalam ruang ciri. Sesuai untuk data yang tidak linear dan berdimensi tinggi.
3. **Regresi Penggalakan Kecerunan (RGB):** Teknik gabungan yang menggabungkan kekuatan beberapa model lemah secara iteratif untuk meningkatkan prestasi keseluruhan. Setiap model baru dibina untuk mengurangkan ralat yang tinggal dari model sebelumnya.
4. **XGBoost:** Algoritma penggalakan kecerunan yang sangat efisien dan dioptimumkan. Dikenali dengan prestasi tinggi dan keupayaan untuk menangani dataset yang besar dan kompleks. Ia menggunakan teknik regularisasi untuk mengurangkan lebihan muat.

Penilaian Model: Penilaian model adalah langkah kritikal dalam metodologi kajian untuk ramalan harga mata wang. Dua metrik yang sering digunakan untuk menilai prestasi model ramalan adalah Ralat Kuasa Dua Min (MSE) dan R-squared (R^2). Kedua-dua metrik ini memberikan pandangan yang berbeza mengenai ketepatan dan kebolehpercayaan model. Ralat Kuasa Dua Min (MSE) adalah metrik penilaian yang mengukur purata kuasa dua kesalahan antara nilai sebenar dan nilai yang diramalkan oleh model. MSE memberikan gambaran sejauh mana ramalan model berbeza daripada nilai sebenar. Nilai MSE yang lebih rendah menunjukkan bahawa model mempunyai ketepatan yang lebih tinggi dalam meramalkan harga mata wang. R-squared (R^2), juga dikenali sebagai koefisien determinasi, mengukur sejauh mana variasi dalam data sebenar dapat dijelaskan oleh model. Nilai R^2 berada dalam julat 0

hingga 1, di mana nilai yang lebih tinggi menunjukkan model yang lebih baik dalam menjelaskan variasi data. Nilai R^2 yang lebih tinggi menunjukkan bahawa model tersebut adalah lebih baik dalam meramalkan harga mata wang berdasarkan data yang ada.

Membuat Ramalan: Setelah model dinilai dan didapati berprestasi baik, model tersebut digunakan untuk membuat ramalan harga mata wang pada masa hadapan. Ramalan ini boleh membantu dalam membuat keputusan perdagangan dan pelaburan.

Pembanguna Aplikasi : Setelah model dipilih, aplikasi akan dibangunkan mengikut kriteria yang telah ditetapkan. Aplikasi untuk melihat data sejarah dan ramalan mata wang untuk enam bulan akan datang dari tarikh semasa.

3.4 PENERANGAN DATA

Dataset yang digunakan dalam kajian ini mengandungi beberapa atribut penting yang berkaitan dengan nilai tukar mata wang USD/MYR dan EUR/MYR. Data ini juga diambil dari laman web rasmi Bank Negara Malaysia. Jadual dibawah adalah attribut dan data yang digunakan untuk membuat analisan ramalan harga mata wang.

Jadual 3.1 Penerangan Attribut Data

Atribut	Penerangan	Format	Contoh	Kepentingan
Date	Tarikh rekod nilai tukar mata wang diambil.	YYYY-MM-DD (Tahun-Bulan-Hari)	2014-01-02	Tarikh adalah penting untuk mengenal pasti kronologi data dan untuk analisis siri masa.
USD/MYR_Buying	Nilai tukar beli (buying rate) untuk 1 Dolar Amerika Syarikat (USD) kepada Ringgit Malaysia (MYR) pada tarikh yang dinyatakan.	Nilai titik perpuluhan	3.2765	Nilai ini menunjukkan berapa banyak MYR diperlukan untuk membeli 1 USD dan digunakan dalam analisis untuk melihat tren perubahan nilai tukar.

USD/MYR_Selling	Nilai tukar jual (selling rate) untuk 1 Dolar Amerika Syarikat (USD) kepada Ringgit Malaysia (MYR) pada tarikh yang dinyatakan.	Nilai titik perpuluhan	3.2795	Nilai ini menunjukkan berapa banyak MYR akan diperoleh apabila menjual 1 USD. Ia berguna dalam analisis untuk menentukan keuntungan atau kerugian perdagangan mata wang.
EUR/MYR_Buying	Nilai tukar beli (buying rate) untuk 1 Euro (EUR) kepada Ringgit Malaysia (MYR) pada tarikh yang dinyatakan.	Nilai titik perpuluhan	4.5101	Nilai ini menunjukkan berapa banyak MYR diperlukan untuk membeli 1 EUR. Ia digunakan untuk melihat perubahan dalam nilai tukar EUR/MYR.
EUR/MYR_Selling	Nilai tukar jual (selling rate) untuk 1 Euro (EUR) kepada Ringgit Malaysia (MYR) pada tarikh yang dinyatakan.	Nilai titik perpuluhan	4.5152	Nilai ini menunjukkan berapa banyak MYR akan diperoleh apabila menjual 1 EUR. Ini penting untuk analisis perdagangan dan keputusan kewangan.
USD/MYR_Advice	Nasihat perdagangan untuk pasangan mata wang USD/MYR pada tarikh yang dinyatakan.	Teks (Buy, Sell, Hold)	Sell	Nasihat ini berdasarkan analisis pasaran dan membantu pedagang membuat keputusan perdagangan yang bijak.
EUR/MYR_Advice	Nasihat perdagangan untuk pasangan mata wang EUR/MYR pada tarikh yang dinyatakan.	Teks (Buy, Sell, Hold)	Sell	Nasihat ini membantu dalam membuat keputusan perdagangan yang lebih baik berdasarkan analisis pasaran terkini.

Jadual 3.2 Penerangan attribut tambahan yang digunakan

Atribut	Penerangan	Format	Contoh	Kepentingan
USD/MYR_Moving_Avg	Purata bergerak 90 hari bagi nilai tukar beli USD/MYR.	Nilai titik perpuluhan	3.3000	Purata bergerak membantu mengenal pasti tren jangka panjang dalam nilai tukar dan digunakan sebagai penanda aras untuk nasihat perdagangan.
EUR/MYR_Moving_Avg	Purata bergerak 90 hari bagi nilai tukar beli EUR/MYR.	Nilai titik perpuluhan	4.5000	Purata bergerak membantu mengenal pasti tren jangka panjang dalam nilai tukar dan digunakan sebagai penanda aras untuk nasihat perdagangan.

Bagi menentukan nasihat pembelian harga mata wang bergerak dibawah 98% daripada harga purata, dinasihatkan untuk ‘Beli’ dan sebaliknya ‘Jual’ mata wang tersebut. Dengan menambahkan atribut tambahan dan menggunakan purata bergerak, nasihat dapat dihasilkan secara automatik berdasarkan analisis data. Ini membantu pedagang membuat keputusan yang lebih tepat dan berdasarkan data dalam pasaran mata wang. Memahami setiap atribut dengan terperinci membolehkan kita memastikan pra-pemprosesan data yang tepat dan penggunaan yang betul dalam model ramalan. Ini akan membantu meningkatkan ketepatan ramalan dan membuat keputusan kewangan yang lebih baik dalam pasaran mata wang yang dinamik.

3.5 PEMBANGUNAN ANTARAMUKA PENGGUNA

Pembangunan antaramuka pengguna adalah satu langkah penting dalam memastikan hasil ramalan model dapat diakses dan digunakan dengan mudah oleh pengguna. Dalam konteks kajian ini, html digunakan untuk membina antaramuka pengguna yang membolehkan pengguna berinteraksi dengan aplikasi ramalan nilai tukar mata wang. Berikut adalah penerangan terperinci mengenai penggunaan html dalam kod di atas:

1. Struktur Asas Laman Web

HTML digunakan untuk menentukan struktur asas laman web, termasuk tajuk, borang login, dan butang navigasi. Struktur asas ini memastikan bahawa laman web mempunyai elemen-elemen yang diperlukan untuk fungsi-fungsi utama aplikasi.

2. Borang Log Masuk

Pada halaman utama, borang log masuk disediakan untuk pengguna. Borang ini mengandungi medan untuk nama pengguna dan kata laluan. Apabila borang ini dihantar, data akan dihantar ke pelayan untuk disahkan.

3. Pemilihan Bahasa

Pengguna boleh memilih bahasa antaramuka (English atau Bahasa Melayu) melalui menu senarai juntai bawah . Apabila pilihan bahasa ditukar, halaman akan dimuat semula dengan bahasa yang dipilih.

4.Papan Pemuka (Dashboard)

Setelah pengguna log masuk, mereka akan diarahkan ke papan pemuka. Papan pemuka ini membolehkan pengguna melihat dan mengakses fungsi utama aplikasi, seperti mengemas kini kadar semasa dan melihat data sejarah atau ramalan.

5.Borang Kemas Kini Kadar

Hanya pengguna dengan peranan admin yang boleh mengakses halaman untuk kini kadar semasa. Borang ini mengandungi medan untuk memasukkan kadar belian dan jualan USD dan EUR.

6.Paparan Data dan Carta

Pengguna boleh melihat data sejarah dan ramalan serta carta yang menggambarkan kadar pertukaran belian dan jualan. Data sejarah dan ramalan dipaparkan dalam jadual, dan carta dihasilkan menggunakan matplotlib dan disematkan dalam halaman web sebagai imej.

7.Borang Pilihan Julat Data

Pengguna boleh memilih julat data yang mereka mahu lihat dengan memasukkan tarikh mula dan tarikh tamat serta memilih pasangan mata wang (USD/MYR atau EUR/MYR).

Dengan menggunakan HTML dalam kajian ini, aplikasi ramalan nilai tukar mata wang dapat menyediakan antaramuka yang interaktif dan mudah digunakan. Pengguna boleh berinteraksi dengan aplikasi melalui borang input, melihat hasil ramalan dan carta visualisasi, serta mengemas kini kadar seasa dengan mudah. Ini menjadikan keseluruhan proses penggunaan aplikasi lebih lancar dan mesra pengguna.

3.6 KESIMPULAN

Dengan menggunakan metodologi yang tersusun dan sistematik, kajian ini berjaya mencapai matlamat dan objektif yang ditetapkan. Penggunaan pelbagai perisian seperti Python, Scikit-Learn, Microsoft Excel, dan HTML memastikan setiap fasa kajian, dari pengumpulan data hingga pembangunan antaramuka pengguna, dilakukan dengan cekap dan efektif. Pendekatan berasaskan pembelajaran mesin seperti Regresi Linear, SVR, Gradient Boosting Regressor, dan XGBoost membolehkan model ramalan nilai tukar mata wang yang dibangunkan mencapai tahap ketepatan yang tinggi. Penilaian menggunakan metrik seperti Ralat Kuasa Dua Min (MSE) dan R-squared (R^2) memberikan gambaran jelas mengenai prestasi model. Akhir sekali, pembangunan antaramuka pengguna yang interaktif dan mesra pengguna memastikan hasil ramalan dapat diakses dan digunakan dengan mudah, membantu dalam membuat keputusan perdagangan dan pelaburan yang lebih baik. Dengan memahami dan memanfaatkan setiap atribut data dengan tepat, kajian ini menyumbang kepada peningkatan ketepatan ramalan dan pengambilan keputusan kewangan dalam pasaran mata wang yang dinamik. Bab seterusnya akan menerangkan setiap keputusan eksperimen yang dijalankan dalam kajian ini.

BAB IV

DAPATAN KAJIAN

4.1 PENGENALAN

Bab ini menerangkan output yang diperolehi dalam fasa pemodelan yang merangkumi tiga sub fasa utama iaitu pembangunan model, pengujian model dan penilaian model. Pemilihan atribut dan analisa deskriptif telah dilakukan di dalam bab III di mana pembangunan model dibuat bagi menilai hasil ujikaji eksperimen dalam kajian ini. Dalam bab ini juga penilaian prestasi model ramalan harga rumah di Selangor dilakukan bagi menentukan model terbaik di antara model-model yang dipilih dalam bab-bab sebelum ini.

4.2 KEPUTUSAN DAPATAN UJIAN PENGAGIHAN DATA

Dalam uji kaji ini, pengagihan data dilakukan melalui kaedah iaitu peratusan pecahan (*split percentage*). Kaedah peratusan pecahan (75-25) di mana 75% adalah data latihan dan 25% adalah data ujian.

Berikut adalah ringkasan keputusan daripada pelbagai model untuk meramalkan kadar pertukaran:

4.2.1 Model SVR

Model SVR digunakan untuk meramalkan kadar pertukaran USD/MYR dan EUR/MYR bagi kedua-dua transaksi membeli dan menjual. Nilai R² yang lebih tinggi (hampir kepada 1) menunjukkan bahawa model ini dapat menjelaskan variasi data dengan baik. Namun, untuk model SVR ini, nilai R² sekitar 0.7 hingga 0.9,

menunjukkan prestasi yang agak baik tetapi tidak sekuat model lain seperti RF atau XGB.

Jadual 4.1 Hasil Keputusan SVR

Pasangan Mata Wang	Jenis	Latihan MSE	Latihan R2	Ujian MSE	Ujian R2
USD/MYR	Membeli	0.014120	0.899127	0.016721	0.877822
USD/MYR	Menjual	0.014140	0.899454	0.016984	0.876446
EUR/MYR	Membeli	0.016312	0.760210	0.020450	0.684812
EUR/MYR	Menjual	0.016299	0.762022	0.021048	0.675877

4.2.2 Model GBR

Model GBR menunjukkan prestasi yang sangat baik dengan nilai R2 yang hampir kepada 1 bagi kedua-dua pasangan mata wang dan jenis transaksi. Ini menunjukkan bahawa model GBR dapat meramalkan kadar pertukaran dengan tepat. MSE yang rendah juga menunjukkan bahawa ralat ramalan adalah sangat kecil, menjadikan model ini boleh dipercayai untuk ramalan kadar pertukaran.

Jadual 4.2 Hasil Keputusan GBR

Pasangan Mata Wang	Jenis	Latihan MSE	Latihan R2	Ujian MSE	Ujian R2
USD/MYR	Membeli	0.000763	0.994552	0.001022	0.992531
USD/MYR	Menjual	0.000820	0.994171	0.001011	0.992646
EUR/MYR	Membeli	0.001159	0.982956	0.001377	0.978774
EUR/MYR	Menjual	0.001182	0.982744	0.001414	0.978230

4.2.3 Model Hutan Rawak

Model RF adalah model yang paling cemerlang dengan nilai R2 yang hampir sempurna (0.999) dan MSE yang sangat rendah. Ini bermaksud model RF dapat meramalkan kadar pertukaran dengan ketepatan yang sangat tinggi. Model ini sesuai untuk digunakan dalam aplikasi di mana ketepatan ramalan adalah kritikal.

Jadual 4.3 Hasil Keputusan RF

Pasangan Mata Wang	Jenis	Latihan MSE	Latihan R2	Ujian MSE	Ujian R2
USD/MYR	Membeli	0.000026	0.999815	0.000221	0.998382
USD/MYR	Menjual	0.000025	0.999821	0.000208	0.998489
EUR/MYR	Membeli	0.000054	0.999207	0.000414	0.993617
EUR/MYR	Menjual	0.000054	0.999218	0.000441	0.993203

4.2.4 Model Regresi Linear

Model LR menunjukkan prestasi yang kurang memuaskan berbanding model lain. Nilai R2 yang lebih rendah (sekitar 0.4 hingga 0.6) menunjukkan bahawa model ini kurang baik dalam menjelaskan variasi data. MSE yang lebih tinggi menunjukkan ralat ramalan yang lebih besar. Model ini mungkin tidak sesuai untuk digunakan dalam ramalan kadar pertukaran yang memerlukan ketepatan tinggi.

Jadual 4.4 Hasil Keputusan LR

Pasangan Mata Wang	Jenis	Latihan MSE	Latihan R2	Ujian MSE	Ujian R2
USD/MYR	Membeli	0.057728	0.587593	0.059629	0.564297
USD/MYR	Menjual	0.057871	0.588494	0.060651	0.558792
EUR/MYR	Membeli	0.037932	0.442380	0.038968	0.399406
EUR/MYR	Menjual	0.037992	0.445310	0.039415	0.393053

4.2.5 Model XGB

Model XGB juga menunjukkan prestasi yang sangat baik, hampir setanding dengan model RF. Nilai R2 yang tinggi dan MSE yang rendah menunjukkan bahawa model ini sangat tepat dalam meramalkan kadar pertukaran. Model ini adalah pilihan yang sangat baik untuk ramalan kadar pertukaran jangka panjang.

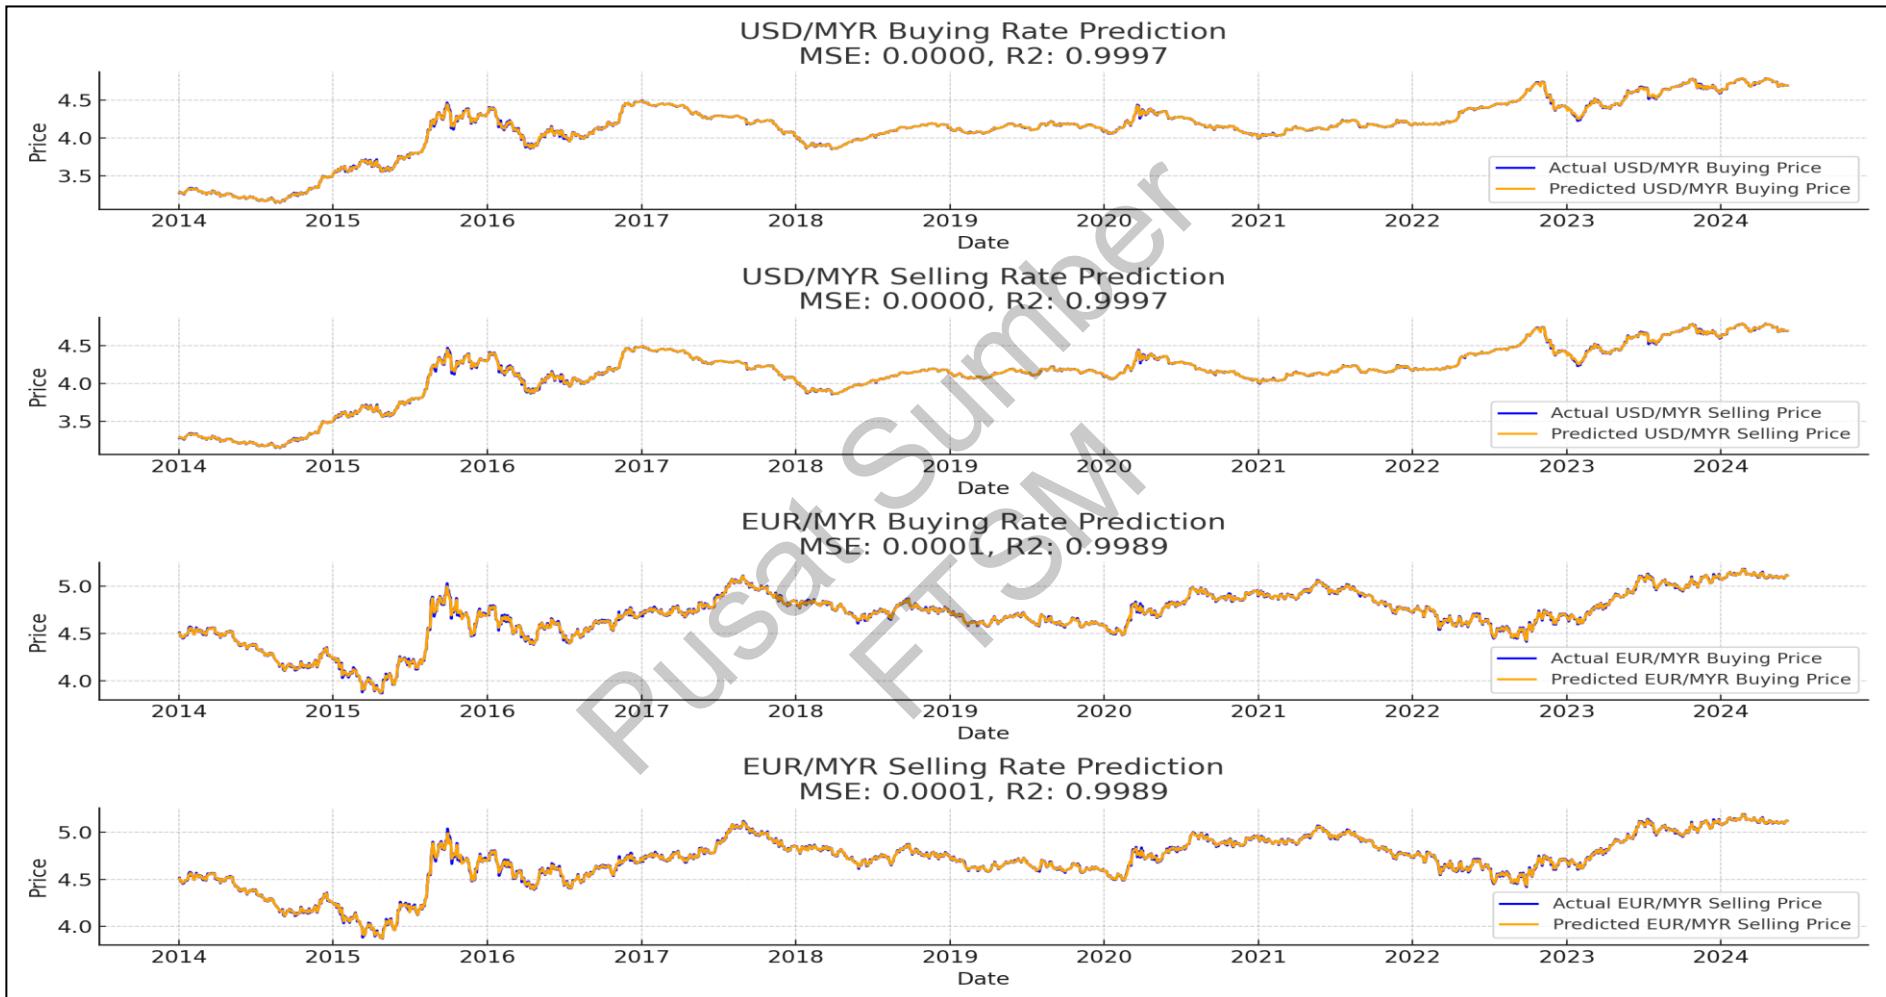
Jadual 4.5 Hasil Keputusan XGB

Pasangan Mata Wang	Jenis	Latihan MSE	Latihan R2	Ujian MSE	Ujian R2
USD/MYR	Membeli	0.000490	0.996496	0.000840	0.993861
USD/MYR	Menjual	0.000490	0.996515	0.000709	0.994843
EUR/MYR	Membeli	0.000858	0.987381	0.001371	0.978863
EUR/MYR	Menjual	0.000900	0.986854	0.001300	0.979982

Secara keseluruhannya, kajian ini menunjukkan bahawa model Hutan Rawak (RF) dan Regresi XGBoost (XGB) adalah yang terbaik untuk digunakan dalam ramalan kadar pertukaran. Kedua-dua model ini memberikan ketepatan ramalan yang tinggi dan ralat yang sangat kecil, menjadikannya pilihan yang sangat baik untuk aplikasi ramalan kadar pertukaran jangka panjang. Dengan menggunakan model-model ini, kita dapat membuat keputusan yang lebih baik dan tepat dalam perdagangan mata wang, sekaligus meningkatkan keuntungan dan mengurangkan risiko. Bagi kajian ini, model Hutan Rawak (RF) dipilih untuk digunakan kerana mempunyai nilai MSE dan R2 yang lebih baik ketika latihan dan ujian data dijalankan.

4.3 PENGHASILAN MODEL RAMALAN MATA WANG

Daripada hasil ujikaji pembangunan model ramalan dan penilaian yang dibuat ke atas setiap model, model ramalan RF digunakan dalam menghasilkan model ramalan harga mata wang. Dalam proses ini, parameter yang telah dipilih melalui ujikaji dan data rumah dari tahun Januari 2014 sehingga Jun 2024 digunakan dengan menggunakan perpustakaan *sklearn import RandomForestRegressor*. Rajah 4.1 di bawah menunjukkan graf nilai ramalan dan nilai sebenar mata wang yang diplotkan bagi tahun Januari 2014 sehingga Jun 2024 untuk kedua-dua pasangan mata wang. Titik biru menunjukkan nilai sebenar harga rumah manakala titik jingga menandakan nilai ramalan harga mata wang.



Rajah 4.1 Harga sebenar dan ramalan mata waang

Daripada Rajah 4.1, dapat dilihat bahawa model ramalan mata wang hampir menyamai nilai sebenar harga mata wang untuk kedua-dua. Secara keseluruhannya dapat dirumuskan bahawa hasil ujikaji menunjukkan proses pre-pemprosesan data yang telah dibuat menyumbang kepada peningkatan dan ketepatan prestasi model selain daripada pemilihan ciri yang betul.

4.4 PEMBANGUNAN APLIKASI MATA WANG

Aplikasi dicipta melalui aplikasi web Flask untuk meramalkan kadar pertukaran mata wang dan memberikan nasihat beli/jual. Berikut adalah ringkasan fungsi utama yang dilaksanakan:

1. Pengesahan Pengguna:

Rajah 4.2 dibawah menunjukkan papan pemuka log masuk untuk pengesahan pengguna. Terdapat dua jenis pengguna iaitu admin dan *user*.

The screenshot shows a login page with the following elements:

- Header: Nurul Atiqah Rahaizar, Prediction Exchange Rate Apps
- Language Selection: Bahasa Melayu
- Title: Log Masuk
- Input Fields:
 - Nama Pengguna (User Name)
 - Kata Laluan (Password)
- Button: Log Masuk (Login)

Rajah 4.2 Log Masuk

2. Sokongan Bahasa:

Rajah 4.3 dan Rajah 4.4 dibawah menunjukkan sokongan dwibahasa (Bahasa Inggeris dan Bahasa Melayu) dengan kebolehan untuk menukar bahasa.

Nurul Atiqah Rohaizar, Prediction Exchange Rate Apps

Bahasa Melayu

Log Masuk

Nama Pengguna

Kata Laluan

Log Masuk

Rajah 4.3 Bahasa Melayu

Nurul Atiqah Rohaizar, Prediction Exchange Rate Apps

English

Login

Username

Password

Login

Rajah 4.4 English

3. Papan Pemuka:

Rajah 4.5 dan Rajah 4.6 menunjukkan paparan berbeza untuk kedua-dua jenis pengguna. Kedua-dua pengguna boleh melihat data sejarah dan ramalan tetapi untuk admin boleh kemas kini kadar semasa.

Nurul Atiqah Rohaizar, Prediction Exchange Rate Apps

Bahasa Melayu

Papan Pemuka

Kemas Kini Kadar Semasa

Lihat Data Sejarah / Ramalan

Log Keluar

Rajah 4.5 Papan Pemuka Admin

Nurul Atiqah Rohaizar, Prediction Exchange Rate Apps

Bahasa Melayu

Papan Pemuka

Lihat Data Sejarah / Ramalan

Log Keluar

Rajah 4.6 Papan Pemuka Pengguna

4. Kemas Kini Kadar Semasa:

Rajah 4.7 dibawah untuk papan pemuka kadar kini semasa bagi kedua-dua pasangan mata wang. Kadar tersebut akan ditambah dan disimpan dalam data sejarah.

Nurul Atiqah Rohaizer, Prediction Exchange Rate Apps

Bahasa Melayu

Kemas Kini Kadar Semasa

Kadar Belian USD
Kadar Jualan USD
Kadar Belian EUR
Kadar Jualan EUR

Kemas Kini

Rajah 4.7 Papan Pemuka Kemas Kini Kadar Semasa

5. Lihat Data:

Rajah 4.8 dibawah menunjukkan pengguna boleh memilih julat tarikh dan pasangan mata wang.

Nurul Atiqah Rohaizer, Prediction Exchange Rate Apps

Bahasa Melayu

Pilih Julat Data

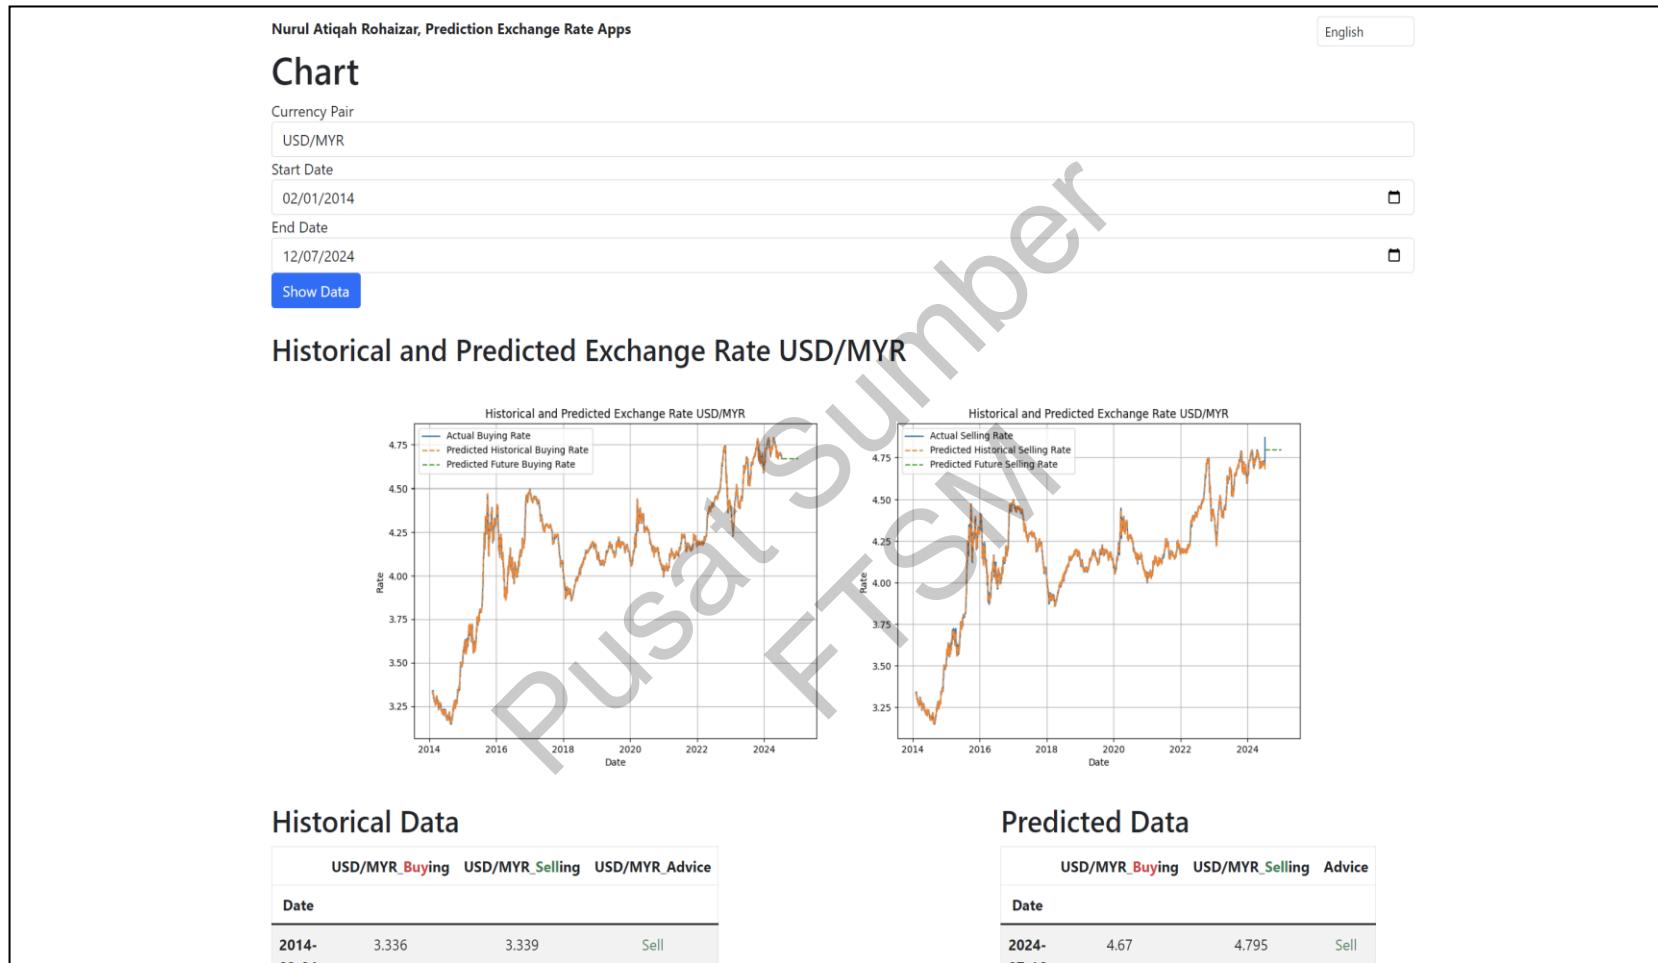
Pasangan Mata Wang
USD/MYR
Tarikh Mula
dd/mm/yyyy
Tarikh Tamat
dd/mm/yyyy

Tunjukkan Data

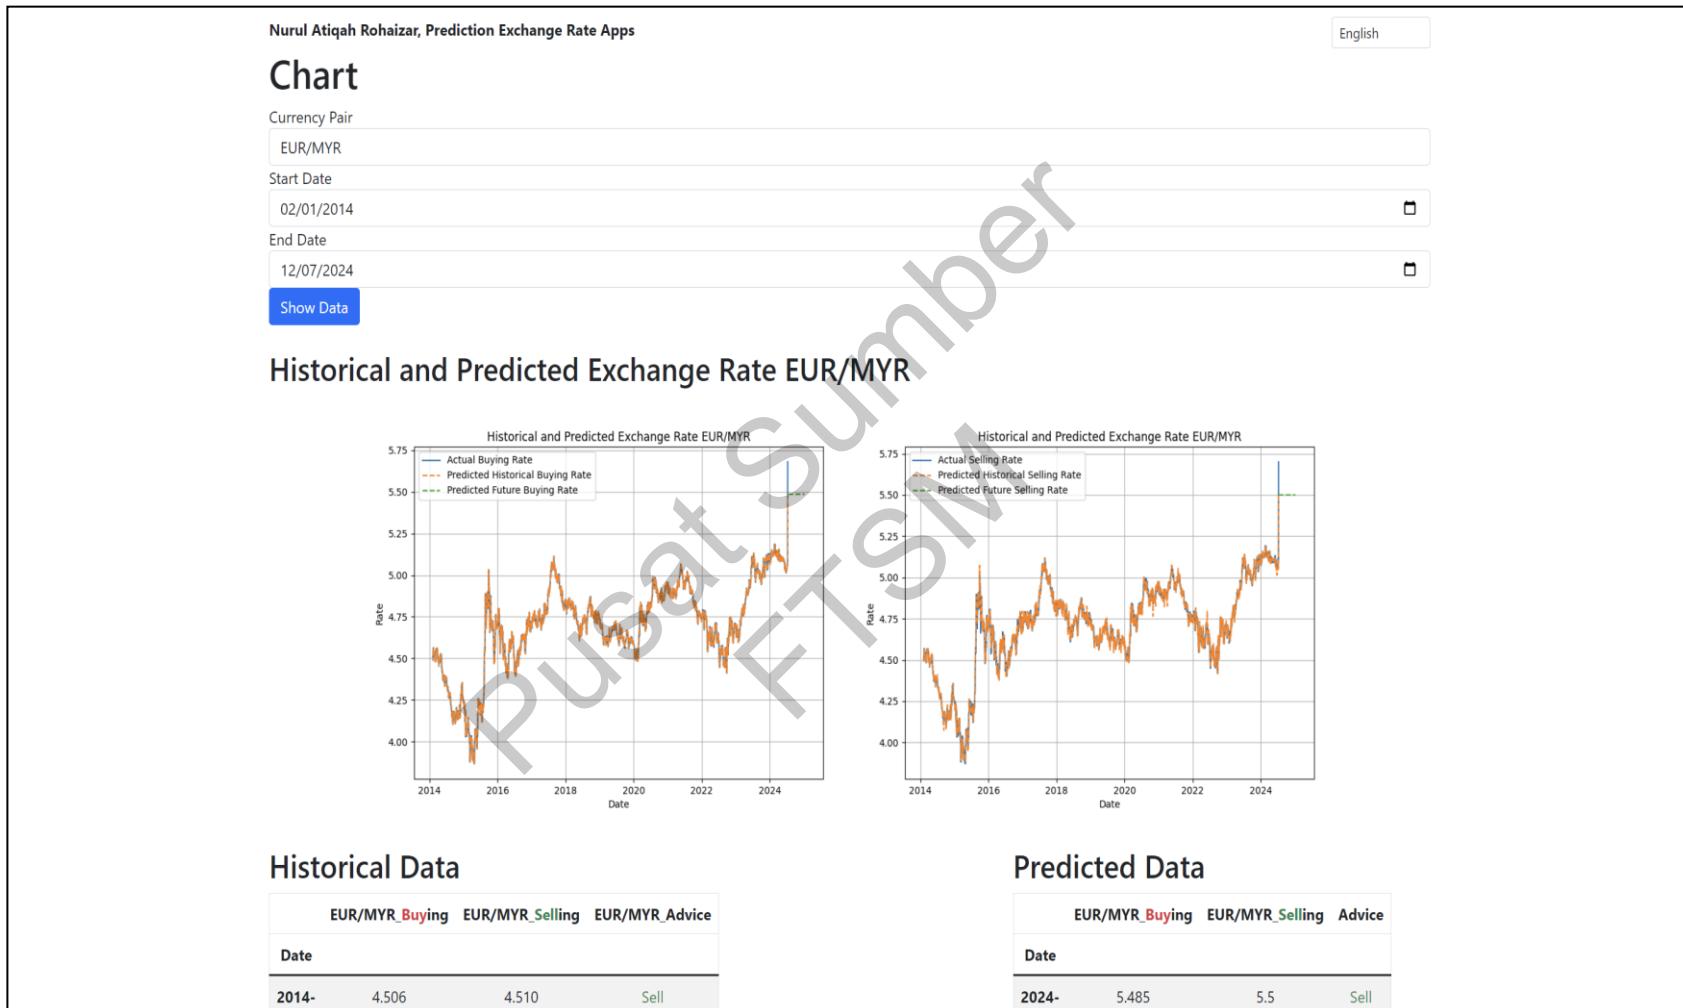
Rajah 4.8 Papan pemuka pilih julat data

6. Visualisasi Data:

Rajah 4.9 dan Rajah 4.10 aplikasi telah menghasilkan dan memaparkan carta kadar beli dan jual untuk data sejarah serta ramalan. Jadual data dipaparkan dengan nasihat pembelian



Rajah 4.9 Kadar Pertukaran USD/MYR



Rajah 4.10 Kadar Pertukaran EUR/MYR

Untuk menjalankan aplikasi Flask ini, pastikan anda telah memasang kebergantungan yang diperlukan (Flask, pandas, numpy, matplotlib, sklearn) dan gantikan file_path dengan laluan sebenar kepada fail CSV anda. Aplikasi ini berjalan di localhost dan boleh diakses melalui pelayar web.

4.5 KESIMPULAN

Kajian ini menunjukkan bahawa model Hutan Rawak (RF) dan Regresi XGBoost (XGB) adalah yang terbaik untuk digunakan dalam ramalan kadar pertukaran. Dengan model-model ini, keputusan yang lebih baik dan tepat dapat dibuat dalam perdagangan mata wang, sekaligus meningkatkan keuntungan dan mengurangkan risiko. Model RF dipilih untuk digunakan dalam aplikasi ramalan mata wang kerana prestasi yang cemerlang dalam ujian dan latihan data. Aplikasi web yang dibangunkan menggunakan Flask membantu pengguna untuk meramalkan kadar pertukaran dan memberikan nasihat beli/jual, menjadikannya alat yang berguna untuk perdagang.

BAB V

RUMUSAN DAN CADANGAN

5.1 PENGENALAN

Bab ini merumuskan keseluruhan kajian yang telah dijalankan. Di antara perkara yang dibincangkan dalam bab ini merangkumi rumusan hasil kajian, pencapaian objektif, penerangan mengenai sumbangan kajian, limitasi kajian dan kajian di masa hadapan bagi proses penambahbaikan hasil penyelidikan model ramalan harga rumah dengan menggunakan teknik pembelajaran mesin.

5.2 RUMUSAN KESELURUHAN KAJIAN

Kajian ini bertujuan untuk membangunkan model ramalan kadar pertukaran mata wang yang berkesan menggunakan beberapa teknik pembelajaran mesin, termasuk Regresi Linear, Regresi Vektor Sokongan (SVR), Regresi Penggalakan Kecerunan (GBR), Hutan Rawak (RF), dan XGBoost Regressor. Melalui kajian ini, beberapa penemuan utama telah dibuat. Dari segi prestasi model, Hutan Rawak (RF) dan XGBoost Regressor menunjukkan prestasi yang sangat baik dalam meramalkan kadar pertukaran mata wang. Kedua-dua model ini memberikan nilai R^2 yang tinggi dan MSE yang rendah, menunjukkan ketepatan ramalan yang tinggi. Regresi Penggalakan Kecerunan (GBR) juga menunjukkan prestasi yang baik dengan nilai R^2 yang hampir kepada 1 dan MSE yang rendah. Regresi Vektor Sokongan (SVR) memberikan prestasi yang agak baik dengan nilai R^2 antara 0.7 hingga 0.9. Namun, Regresi Linear (LR) menunjukkan prestasi yang paling rendah berbanding model-model lain, dengan nilai R^2 yang lebih rendah (sekitar 0.4 hingga 0.6) dan MSE yang lebih tinggi.

Penggunaan algoritma menunjukkan bahawa model Hutan Rawak (RF) dipilih sebagai model utama untuk digunakan dalam aplikasi ramalan kadar pertukaran mata

wang kerana prestasinya yang cemerlang dalam ujian dan latihan data. Pembangunan aplikasi web yang dibangunkan menggunakan Flask membolehkan pengguna meramalkan kadar pertukaran mata wang dan memberikan nasihat beli/jual. Fungsi utama aplikasi ini termasuk pengesahan pengguna, sokongan dwibahasa, papan pemuka untuk admin dan pengguna biasa, kemas kini kadar semasa, paparan data sejarah dan ramalan, serta visualisasi data dalam bentuk carta dan jadual.

Kajian ini memberikan sumbangan penting dalam bidang kewangan dengan menyediakan model ramalan yang tepat dan boleh dipercayai untuk kadar pertukaran mata wang. Model yang dibangunkan boleh membantu dalam membuat keputusan perdagangan dan pelaburan yang lebih baik, meningkatkan keuntungan dan mengurangkan risiko. Aplikasi web yang dibangunkan boleh digunakan oleh pelbagai pihak termasuk individu, syarikat, dan kerajaan untuk merancang strategi kewangan yang lebih baik berdasarkan ramalan kadar pertukaran mata wang.

Secara keseluruhannya, kajian ini menunjukkan bahawa penggunaan teknik pembelajaran mesin dapat meningkatkan ketepatan ramalan kadar pertukaran mata wang. Model Hutan Rawak (RF) dan XGBoost Regressor adalah yang paling berkesan dalam kajian ini. Dengan pembangunan aplikasi web yang mesra pengguna, hasil kajian ini dapat diakses dan dimanfaatkan oleh pengguna untuk membuat keputusan perdagangan dan pelaburan yang lebih bijak. Penemuan ini menunjukkan potensi besar penggunaan pembelajaran mesin dalam bidang kewangan dan menyumbang kepada kemajuan teknologi dalam ramalan kadar pertukaran mata wang.

5.3 RUMUSAN OBJEKTIF KAJIAN

Kajian ini dilaksanakan untuk mencapai tiga objektif utama dalam meramalkan kadar pertukaran mata wang menggunakan teknik pembelajaran mesin. Berikut adalah rumusan objektif yang dicapai:

Mengenal pasti algoritma terbaik untuk ramalan mata wang: Kajian ini telah menguji pelbagai algoritma pembelajaran mesin seperti Regresi Linear (LR), Regresi Vektor Sokongan (SVR), Regresi Penggalakan Kecerunan (GBR), Hutan Rawak (RF), dan XGBoost Regressor. Hasil kajian menunjukkan bahawa algoritma Hutan Rawak

(RF) dan XGBoost Regressor adalah yang paling berkesan dan tepat dalam meramalkan kadar pertukaran mata wang dengan nilai R^2 yang tinggi dan MSE yang rendah.

Membangunkan model ramalan mata wang: Model Hutan Rawak (RF) telah dipilih sebagai model utama untuk ramalan kadar pertukaran mata wang berdasarkan prestasinya yang cemerlang. Model ini dibangunkan menggunakan data sejarah harga mata wang dan faktor-faktor ekonomi lain yang relevan.

Membangunkan aplikasi untuk ramalan mata wang: Aplikasi web telah dibangunkan menggunakan Flask yang membolehkan pengguna meramalkan kadar pertukaran mata wang dan memberikan nasihat beli/jual. Aplikasi ini menyokong fungsi pengesahan pengguna, sokongan dwibahasa, papan pemuka untuk admin dan pengguna biasa, kemas kini kadar semasa, paparan data sejarah dan ramalan, serta visualisasi data dalam bentuk carta dan jadual. Aplikasi ini juga menggunakan model Hutan Rawak (RF) untuk menghasilkan ramalan kadar pertukaran dan nasihat beli/jual berdasarkan analisis purata bergerak.

Kajian ini berjaya mencapai objektif utamanya dalam mengenal pasti algoritma terbaik, membangunkan model ramalan yang tepat, dan menghasilkan aplikasi ramalan kadar pertukaran mata wang yang berfungsi dengan baik. Penggunaan model Hutan Rawak (RF) dalam aplikasi ini membuktikan keberkesanan teknik pembelajaran mesin dalam meningkatkan ketepatan ramalan kadar pertukaran mata wang. Aplikasi yang dibangunkan bukan sahaja membantu dalam membuat keputusan perdagangan dan pelaburan yang lebih bijak, tetapi juga menyumbang kepada kemajuan teknologi dalam bidang kewangan. Penemuan ini menunjukkan potensi besar penggunaan pembelajaran mesin dalam bidang kewangan dan menyumbang kepada kemajuan teknologi dalam ramalan kadar pertukaran mata wang.

5.4 KEKANGAN KAJIAN

Kajian ini menghadapi beberapa kekangan yang mempengaruhi proses dan hasilnya. Kekangan utama adalah ketersediaan data yang mencukupi dan berkualiti. Data sejarah kadar pertukaran mata wang yang digunakan mungkin tidak lengkap atau tidak

cukup terperinci, yang boleh menjelaskan ketepatan ramalan model. Selain itu, pasaran mata wang sangat berubah-ubah dan dipengaruhi oleh pelbagai faktor ekonomi, politik, dan sosial yang sukar diramalkan. Model pembelajaran mesin mungkin tidak dapat menangkap semua variabel ini, menyebabkan ramalan yang kurang tepat dalam keadaan pasaran yang luar biasa. Proses pemilihan parameter yang optimum untuk model pembelajaran mesin adalah rumit dan memerlukan banyak ujian dan penalaan. Kekangan masa dan sumber daya mungkin mengehadkan kemampuan untuk melakukan pemilihan parameter yang komprehensif.

Latihan model pembelajaran mesin, terutamanya model yang kompleks seperti Hutan Rawak (RF) dan XGBoost, memerlukan keupayaan pengiraan yang tinggi. Kekangan dalam keupayaan komputer dan masa pemprosesan boleh mempengaruhi sejauh mana model dapat dioptimumkan dan diuji. Pembangunan aplikasi web yang mesra pengguna dan efisien memerlukan pengetahuan mendalam dalam pembangunan perisian serta pembelajaran mesin. Kekangan dalam kemahiran teknikal atau sumber untuk pembangunan aplikasi boleh menjelaskan kualiti dan kebolehgunaan aplikasi yang dihasilkan.

Faktor-faktor luaran seperti perubahan polisi kerajaan, kejadian geopolitik, dan bencana alam boleh memberi kesan besar kepada kadar pertukaran mata wang. Model pembelajaran mesin mungkin tidak dapat menyesuaikan diri dengan cepat kepada perubahan mendadak ini, menyebabkan ramalan yang kurang tepat. Aplikasi web yang dibangunkan menyokong dwibahasa, namun penyediaan dan penyelenggaraan kandungan dalam dua bahasa memerlukan usaha tambahan. Kesukaran dalam memastikan terjemahan yang tepat dan konteks yang sesuai mungkin menjadi kekangan. Walaupun menghadapi kekangan-kekangan ini, kajian ini tetap memberikan sumbangan penting dalam bidang ramalan kadar pertukaran mata wang dan menunjukkan potensi besar penggunaan pembelajaran mesin dalam bidang kewangan.

5.5 CADANGAN PERLUASAN KAJIAN

Kajian ini membuka beberapa peluang untuk perluasan di masa hadapan yang boleh meningkatkan lagi ketepatan dan kebolehgunaan model ramalan kadar

pertukaran mata wang. Meningkatkan kualiti dan kuantiti data dengan memasukkan lebih banyak data sejarah dan faktor-faktor ekonomi lain yang relevan adalah langkah penting. Penggunaan data dari pelbagai sumber dan termasuk data masa nyata dapat memberikan gambaran yang lebih menyeluruh dan tepat mengenai perubahan kadar pertukaran. Selain itu, kajian masa depan boleh menguji algoritma pembelajaran mesin yang lain seperti Long Short-Term Memory (LSTM), Convolutional Neural Networks (CNN), atau model hibrid yang menggabungkan pelbagai algoritma. Ini dapat membantu untuk menentukan algoritma yang paling berkesan dalam meramalkan kadar pertukaran mata wang.

Memperbaiki teknik pra-pemprosesan data seperti pengendalian nilai hilang, penormalan data, dan pemilihan ciri yang lebih baik juga boleh meningkatkan prestasi model. Teknik seperti peningkatan data (*data augmentation*) dan pemilihan ciri automatik boleh diteroka untuk menghasilkan set data yang lebih tepat. Model pembelajaran mendalam (*deep learning*) seperti LSTM dan CNN yang mempunyai kemampuan untuk menangkap corak kompleks dalam data masa boleh diteroka. Model-model ini telah menunjukkan prestasi yang cemerlang dalam pelbagai aplikasi ramalan masa dan boleh memberikan ketepatan yang lebih tinggi dalam ramalan kadar pertukaran mata wang.

Mengintegrasikan faktor ekonomi makro seperti kadar faedah, inflasi, dan data perdagangan antarabangsa ke dalam model juga boleh memberikan konteks tambahan yang membantu dalam memahami perubahan kadar pertukaran dengan lebih baik. Peningkatan aplikasi web dengan menambah ciri-ciri seperti notifikasi masa nyata, analisis sentimen dari media sosial dan berita, serta ramalan jangka pendek dan jangka panjang akan menjadikan aplikasi lebih interaktif dan berguna. Aplikasi juga boleh ditingkatkan dengan antaramuka pengguna yang lebih interaktif dan mudah digunakan. Selain itu, mengkaji kesan faktor luaran seperti perubahan polisi kerajaan, kejadian geopolitik, dan bencana alam terhadap kadar pertukaran mata wang adalah penting. Model yang dapat mengintegrasikan dan menyesuaikan diri dengan cepat kepada perubahan mendadak ini boleh dibangunkan untuk meningkatkan ketepatan ramalan. Dengan melaksanakan cadangan-cadangan ini, kajian masa depan dapat memberikan model ramalan kadar pertukaran mata wang yang lebih tepat, dan berguna untuk pelbagai aplikasi dalam bidang kewangan dan ekonomi.

RUJUKAN

- Abedin, M. Z., Moon, M. H., Hassan, M. K., & Hajek, P. 2020. Currency Exchange Rate Prediction Using Bi-LSTM During COVID-19 Pandemic.
- Balasubramanian, V., Mose, S., Yoloye, N., Vasudevan, N., & Dommeti, S. M. 2017. Predicting Currency Exchange Rate Using EMD-RNN and ARIMA Models.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). Time Series Analysis: Forecasting and Control. Wiley.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32.
- Bontempi, G., Taieb, S. B., & Le Borgne, Y.-A. 2012. Machine Learning Strategies for Time Series Forecasting. European Business Intelligence Summer School, 62-77.
- Chen, T., & Guestrin, C. 2016. XGBoost: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785-794.
- Goodfellow, I., Bengio, Y., & Courville, A. 2016. Deep Learning. MIT Press.
- Hastie, T., Tibshirani, R., & Friedman, J. 2009. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer.
- Hochreiter, S., & Schmidhuber, J. 1997. Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
- Hull, J. C. 2018. *Options, Futures, and Other Derivatives* (10th ed.). Upper Saddle River, NJ: Pearson Education.
- Hyndman, R. J., & Athanasopoulos, G. 2018. Forecasting: Principles and Practice.

- Hyndman, R. J., & Khandakar, Y. 2008. Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 27(3), 1-22.
- Krugman, P. R., Obstfeld, M., & Melitz, M. J. 2018. *International Economics: Theory and Policy* (11th ed.). New York: Pearson.
- LeCun, Y., Bengio, Y., & Hinton, G. 2015. Deep Learning. *Nature*, 521(7553), 436-444.
- Livieris, I. E., Stavroyiannis, S., Pintelas, E., Pintelas, P., & Tsiliras, A. 2020. Bitcoin Price Prediction Using Deep Learning Algorithms. *Applied Sciences*, 10(1), 50.
- Louppe, G. 2014. Understanding Random Forests: From Theory to Practice.
- Mankiw, N. G. 2020. *Principles of Economics* (9th ed.). Boston: Cengage Learning.
- Mittal, A., & Goel, S. 2017. Forecasting Foreign Exchange Rates Using Machine Learning Techniques.
- Murphy, J. J. 2018. *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. New York: New York Institute of Finance.
- Naeem, S., Mashwani, W. K., Ali, A., Uddin, M. I., Mahmoud, M., Jamal, F., & Chesneau, C. (2020). Prediction of USD/PKR Exchange Rate Using Sentiment Analysis from Twitter Data.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. 2011. Scikit-

- learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
- Peng, L. 2019. Stock Price Prediction of Google Based on Machine Learning.
- Shiller, R. J. 2019. *Narrative Economics: How Stories Go Viral and Drive Major Economic Events*. Princeton: Princeton University Press.
- Singh, S., Gutta, S., & Hadaegh, A. 2019. Stock Prediction Using Machine Learning.
- Theofilatos, K., Likothanassis, S., & Karathanasopoulos, A. 2019. Modeling and Trading the EUR/USD Exchange Rate Using Machine Learning Techniques.
- Wiliani, N., Hesananda, R., Sari, N., Rahmawati, S., & Prianggara, E. 2020. Application Of Machine Learning For Bitcoin Exchange Rate Prediction Against Us Dollar. Retrieved from API Binance.com.
- Yu, M., & Du, X. 2020. Impact of Economic Factors on Exchange Rate Fluctuations.
- Zhang, G. P. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159-175.

**SENARAI SEMAK URUSAN PENYERAHAN TESIS YANG TELAH DIBUAT
PEMBETULAN
CHECK LIST OF AMENDED THESIS SUBMISSION**

**PERAKUAN TESIS SARJANA / DOKTOR FALSAFAH
(CERTIFICATION OF MASTERS / DOCTORAL THESIS)**

Nama Penuh Pengarang : _____
(Author's Full Name)

No. Pendaftaran Pelajar : _____ Sesi Akademik
(Student's Registration No.) : _____ (Academic Session) : _____

Tajuk Tesis : _____
(Thesis Title) _____

Merujuk kepada Klausula 4.2 Dasar Harta Intelek Pelajar UKM (Tambahan), tesis adalah hak milik pelajar. Saya mengaku tesis ini sebagai:

(With regard to Clause 4.2 of the UKM Student Intellectual Property Policy (Supplementary), the thesis is the student's property. I hereby declare this thesis as:)

**RAHSIA
(CONFIDENTIAL)**

Mengandungi maklumat rahsia di bawah AKTA RAHSIA RASMI 1972
(Consisting of classified information under the OFFICIAL SECRETS ACT 1972)

**TERHAD
(RESTRICTED)**

Mengandungi maklumat TERHAD yang telah ditentukan oleh organisasi/badan di mana penyelidikan dijalankan
(Consisting of RESTRICTED information which has been determined by the organisation/body where the research was conducted)

**AKSES
TERBUKA
/TIDAK TERHAD
(OPEN ACCESS/
NON-
RESTRICTED)**

Saya membenarkan tesis ini diterbitkan secara akses terbuka, teks penuh atau dibuat salinan untuk tujuan pengajian, pembelajaran, penyelidikan sahaja.
(I allow this thesis to be published through open access, full text or copied for study, learning and research purposes only.)

Bagi kategori Akses Terbuka/Tidak Terhad, saya membenarkan tesis (Sarjana/Doktor Falsafah) ini di simpan di Perpustakaan Universiti Kebangsaan Malaysia (UKM)* dengan syarat-syarat kegunaan seperti berikut:

(For the Open Access/Non-Restricted category, I allow this (Master's/Doctoral) Thesis to be kept in the Universiti Kebangsaan Malaysia (UKM) Library with the following usage conditions:)

- Perpustakaan UKM mempunyai hak untuk membuat salinan untuk tujuan pengajian, pembelajaran, penyelidikan sahaja.
(UKM Library has the right to reproduce the thesis for study, learning and research purposes only.)
- Perpustakaan Universiti Kebangsaan Malaysia dibenarkan membuat satu (1) salinan tesis ini untuk tujuan pertukaran antara institusi pengajian tinggi dan mana-mana badan/ agensi kerajaan, tertakluk kepada terma dan syarat.
(UKM Library is allowed to make one (1) copy of this thesis for exchange purpose among higher education institutions and any government body/agency, subject to terms and conditions.)

**SENARAI SEMAK URUSAN PENYERAHAN TESIS YANG TELAH DIBUAT
PEMBETULAN
CHECK LIST OF AMENDED THESIS SUBMISSION**

DISAHKAN OLEH:
(VERIFIED BY:)

**TANDATANGAN PELAJAR
(STUDENT'S SIGNATURE)**

**TANDATANGAN PENYELIA /
PENGERUSI JK SISWAZAH
(SUPERVISOR'S / CHAIRPERSON
SUPERVISION COMMITTEE
SIGNATURE)**

**KAD PENGENALAN /
NO. PASPORT
(IDENTITY CARD/PASSPORT
NO.)**

**NAMA PENYELIA/
PENGERUSI JK SISWAZAH
(SUPERVISOR'S / CHAIRPERSON
SUPERVISION COMMITTEE NAME)**

Tarikh/
Date:

Tarikh/
Date: